

**METODOLOGI KLASIFIKASI DATA POLARIMETRIK
SYNTHETIC APERTURE RADAR MENGGUNAKAN INFORMASI
KOMPLEMENTER PARAMETER POLARIMETRIK,
DEKOMPOSISI POLARIMETRIK, DAN SPASIAL
KONTEKSTUAL**

DISERTASI

Diajukan sebagai salah satu syarat untuk memperoleh gelar Doktor Ilmu
Komputer

KATMOKO ARI SAMBODO
9205000069



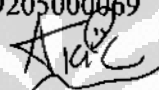
**UNIVERSITAS INDONESIA
FAKULTAS ILMU KOMPUTER
PROGRAM STUDI ILMU KOMPUTER**

**DEPOK
JULI 2009**



HALAMAN PERNYATAAN ORISINALITAS

Disertasi ini adalah hasil karya saya sendiri,
dan semua sumber baik yang dikutip maupun dirujuk
telah saya nyatakan dengan benar.

Nama : Katmoko Ari Sambodo
NPM : 9205000069
Tanda Tangan : 
Tanggal : 10 Juli 2009

HALAMAN PENGESAHAN

Disertasi ini diajukan oleh :

Nama : Katmoko Ari Sambodo

NPM : 9205000069

Program Studi : Ilmu Komputer


Judul Disertasi : Metodologi Klasifikasi Data Polarimetrik
Synthetic Aperture Radar Menggunakan
Informasi Komplementer Parameter Polarimetrik,
Dekomposisi Polarimetrik, dan Spasial
Kontekstual


Telah berhasil dipertahankan di hadapan Dewan Penguji dan diterima sebagai bagian persyaratan yang diperlukan untuk memperoleh gelar Doktor pada Program Studi Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Indonesia


DEWAN PENGUJI


Promotor : Prof. Dr. Aniati Murni


Kopromotor : Ir. Mahdi Kartasasmita, M.S., Ph.D.


Tim Penguji : Prof. Heru Suhartanto, Ph.D. (Ketua) ()

: Wisnu Jatmiko, Dr. Eng. (Anggota) ()

: Dana Indra Sensusc, Ph.D. (Anggota) ()

: M. Rahmat Widyanto, Dr. Eng. (Anggota) ()

: Prof. Dr. Ir. Marimin, M.Sc. (Anggota) ()



Ditetapkan di : Depok

Tanggal : 10 Juli 2009

KATA PENGANTAR

Puji syukur saya panjatkan kepada Allah SWT, karena atas berkat dan rahmat-Nya, saya dapat menyelesaikan disertasi ini. Saya menyadari bahwa, tanpa bantuan dan bimbingan dari berbagai pihak, dari masa perkuliahan sampai pada penyusunan disertasi ini, sangatlah sulit bagi saya untuk menyelesaikan disertasi ini. Oleh karena itu, saya mengucapkan terima kasih kepada:

- (1) Prof. Dr. Aniati Murni, selaku promotor yang telah menyediakan waktu, tenaga, dan pikiran untuk mengarahkan saya dalam penyusunan disertasi ini;
- (2) Ir. Mahdi Kartasasmita, M.S., Ph.D., selaku kopromotor yang telah menyediakan waktu, tenaga, dan pikiran untuk mengarahkan saya dalam penyusunan disertasi ini;
- (3) Dr. Ir. Adi Sadewo Salatun, M.Sc., selaku Ketua LAPAN yang telah memberi dukungan baik berupa program beasiswa maupun fasilitas lainnya;
- (4) Panitia penguji yang telah bersedia meluangkan waktunya menjadi penguji pada ujian disertasi ini;
- (5) Deputy Penginderaan Jauh LAPAN, Karo Umum, Kapusbangja, Karo Humasmagan, Kabid Bangfatja beserta staf masing-masing yang telah memberi dukungan moral dan fasilitas lainnya;
- (6) Ibu, Bapak, dan keluarga saya yang telah memberikan bantuan dukungan moral; dan
- (7) Sahabat-sahabat saya yang telah banyak membantu saya dalam menyelesaikan disertasi ini.

Akhir kata, saya berharap Allah SWT berkenan membalas segala kebaikan semua pihak yang telah membantu. Semoga disertasi ini membawa manfaat bagi pengembangan ilmu.

Depok, 10 Juli 2009

Penulis

**HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI
TUGAS AKHIR UNTUK KEPENTINGAN AKADEMIS**

Sebagai sivitas akademik Universitas Indonesia, saya yang bertanda tangan di bawah ini:

Nama : Katmoko Ari Sambodo

NPM : 9205000069

Program Studi : Ilmu Komputer

Departemen : Ilmu Komputer

Fakultas : Ilmu Komputer

Jenis karya : Disertasi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Indonesia **Hak Bebas Royalti Noneksklusif (*Non-exclusive Royalty-Free Right*)** atas karya ilmiah saya yang berjudul:

Metodologi Klasifikasi Data Polarimetrik *Synthetic Aperture Radar*
Menggunakan Informasi Komplementer Parameter Polarimetrik, Dekomposisi
Polarimetrik, dan Spasial Kontekstual

beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Noneksklusif ini Universitas Indonesia berhak menyimpan, mengalihmedia/formatkan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan memublikasikan tugas akhir saya tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Depok

Pada tanggal : 10 Juli 2009

Yang menyatakan



(Katmoko Ari Sambodo)

ABSTRAK

Nama : Katmoko Ari Sambodo
Program Studi : Ilmu Komputer
Judul : Metodologi Klasifikasi Data Polarimetrik *Synthetic Aperture Radar* Menggunakan Informasi Komplementer Parameter Polarimetrik, Dekomposisi Polarimetrik, dan Spasial Kontekstual

Disertasi ini membahas suatu metodologi alternatif untuk mengklasifikasi secara tidak terbimbing (*unsupervised classification*) data polarimetrik-SAR. Pada tahap permulaan dua metode pengekstraksian fitur diterapkan untuk mengeksploitasi secara optimal berbagai informasi yang terkandung dalam data polarimetrik-SAR tersebut. Metode pengekstraksi yang pertama didasarkan atas penurunan berbagai fitur dari representasi matriks kovarian polarimetrik (totalnya terdapat sembilan parameter yang merepresentasikan masing-masing power kanal polarisasinya, koherensi polarimetriknya, dan perbedaan fase polarimetriknya), dan metode yang kedua didasarkan atas dekomposisi polarimetrik Cloude (totalnya terdapat tiga parameter yang memberikan informasi mengenai karakteristik hamburan balik sinyal radar atas berbagai target yang berbeda-beda). Selanjutnya suatu teknik penyeleksian (pereduksian) fitur berdasarkan transformasi *maximum noise fraction* (MNF) diaplikasikan pada fitur-fitur tersebut untuk mendapatkan informasi-informasi yang paling berguna dan mengurangi informasi lain yang sifatnya redundan ataupun informasi yang tidak terkait lainnya. Tahapan klasifikasi kemudian dilakukan dengan algoritma klustering *fuzzy maximum likelihood estimation* (FMLE). Algoritma FMLE tersebut memungkinkan pembentukan kluster-kluster yang berbentuk elips dalam sembarang arah sehingga lebih fleksibel dibandingkan dengan algoritma klustering *fuzzy K-means* yang standar. Namun demikian, algoritma dasar FMLE semata-mata hanya menggunakan informasi spektral (atau intensitas) dari masing-masing vektor piksel dan informasi spasial-kontekstual tidak ikut diperhitungkan dalam proses klustering. Oleh karena itu, hasil klasifikasi yang kurang bagus (ber-noise) biasanya akan didapatkan apabila diterapkan pada data SAR sebagai akibat

keberadaan noise speckle. Pada penelitian ini diajukan suatu metode baru yang mengintegrasikan antara hasil klustering FMLE (yang berbasis piksel per piksel) dengan informasi spasial-kontekstual yang dieksploitasi dengan analisa statistik atas informasi kelas piksel-piksel yang bersebelahan dan informasi spasial-kontekstual tambahan yang diperoleh dari hasil analisa klustering menggunakan fitur-fitur hasil dekomposisi wavelet.

Metodologi yang diajukan tersebut telah diujicoba dengan menggunakan data polarimetrik E-SAR yang diakuisisi di daerah Penajam, Kalimantan Timur dan data polarimetrik ALOS-PALSAR yang diakuisisi di daerah Lumajang, Jawa Timur, Indonesia. Dari hasil-hasil eksperimen dapat disimpulkan bahwa hasil klasifikasi yang diperoleh lebih meningkatkan perfomansi pembedaan berbagai objek tutupan lahan, lebih homogen pada area yang bersifat homogen, dan tetap mempertahankan batas-batas objek dan struktur-struktur detail lainnya.

Kata kunci : polarimetrik-SAR, klasifikasi tidak terbimbing, koherensi polarimetrik, perbedaan fase polarimetrik, mekanisme hamburan balik sinyal radar, dekomposisi polarimetrik Cloude, transformasi *maximum noise fraction* (MNF), klustering *fuzzy maximum likelihood estimation* (FMLE), informasi spasial-kontekstual, dekomposisi wavelet.


ABSTRACT

Name : Katmoko Ari Sambodo
Study Program : Computer Science
Title : Classification Methodology of Polarimetric-Synthetic Aperture Radar Data Using Complementary Information of Polarimetric Parameters, Polarimetric Decomposition, and Spatial Context

This dissertation shows a study on an alternative method for unsupervised classification of polarimetric-SAR data. First, two feature extraction methods are performed in order to exploit the information of fully polarimetric-SAR data properly. One is based on derivation of features from polarimetric covariance matrix (totally nine parameters which represent each polarisation power, polarimetric coherence, and polarimetric phase difference), and other is based on Cloude's polarimetric decomposition (totally three parameters which characterize the target's backscattering mechanism). A feature reduction technique based on maximum noise fraction (MNF) transformation is then applied to these features to obtain most pertinent information and remove any redundant and other irrelevant information. Classification stage is then performed using fuzzy maximum likelihood estimation (FMLE) clustering algorithm. FMLE algorithm allows for ellipsoidal clusters of arbitrary extent and is consequently more flexible than standard fuzzy K-means clustering algorithm. However, basic FMLE algorithm makes use exclusively the spectral (or intensity) properties of the individual pixel vectors and spatial-contextual information of the image was not taken into account. Hence, poor (noisy) classification result is usually obtained from SAR data due to the presence of speckle noise. In this study, we propose a modified FMLE which integrate basic FMLE (pixel-by-pixel basis) clustering result with spatial-contextual information by statistical analysis of local neighborhoods and additional context-depend support information exploited using clustering result analysis of wavelet-based decomposed feature images.

The proposed method has been tested on E-SAR polarimetric data acquired on the area of Penajam, East Kalimantan and ALOS-PALSAR polarimetric data acquired on the area of Lumajang, East Java, Indonesia. Results obtained show classified images improving land-cover discrimination performance, exhibiting homogeneous region, and preserving edge and other fine structures.

Key words: polarimetric-SAR, unsupervised classification, polarimetric coherence, polarimetric phase difference, wave scattering mechanism, Cloude's polarimetric decomposition, maximum noise fraction (MNF) transformation, fuzzy maximum likelihood estimation (FMLE) clustering, spatial-contextual, wavelet decomposition.



DAFTAR ISI

| | |
|---|-----------|
| HALAMAN JUDUL | i |
| HALAMAN PERNYATAAN ORISINALITAS | ii |
| LEMBAR PENGESAHAN | iii |
| KATA PENGANTAR | iv |
| LEMBAR PERSETUJUAN PUBLIKASI KARYA ILMIAH | v |
| ABSTRAK | vi |
| ABSTRACT | viii |
| DAFTAR ISI | x |
| DAFTAR GAMBAR | xii |
| DAFTAR TABEL | xv |
| DAFTAR LAMPIRAN | xvi |
| DAFTAR SINGKATAN DAN ISTILAH | xvii |
| 1. PENDAHULUAN | 1 |
| 1.1 Latar Belakang | 1 |
| 1.2 Permasalahan Terkini terkait dengan Ekstraksi Fitur dan Klasifikasi Data Polarimetrik-SAR | 5 |
| 1.3 Perumusan Permasalahan | 10 |
| 1.4 Tujuan Penelitian | 12 |
| 1.5 Metodologi Penyelesaian Masalah yang Diusulkan dan Kerangka Dasar Pemikirannya | 13 |
| 1.6 Lingkup Penelitian | 15 |
| 1.7 Kontribusi Penelitian | 23 |
| 1.8 Sistematika Penulisan | 24 |
| 2. EKSTRAKSI DAN SELEKSI FITUR DARI DATA POLARIMETRIK-SAR | 26 |
| 2.1 Prinsip Dasar dan Pemanfaatan Data SAR Konvensional (<i>Single-Channel Single-Polarisation SAR</i>) | 26 |
| 2.2 Prinsip Dasar SAR Polarimetry dan Keuntungannya | 31 |
| 2.3 Representasi Dasar Data Polarimetrik-SAR dan Pengekstraksian Fitur Parameter Polarimetrik | 33 |
| 2.4 Pengekstraksian Fitur berdasarkan Dekomposisi Polarimetrik Cloude | 41 |
| 2.5 Penyeleksian (Pereduksian) Fitur berdasarkan Transformasi <i>Maximum Noise Fraction</i> (MNF) | 51 |
| 3. KLASIFIKASI BERDASARKAN FUZZY MAXIMUM LIKELIHOOD ESTIMATION CLUSTERING (FMLE) | 57 |
| 3.1 <i>Fuzzy Clustering</i> | 57 |
| 4. INFORMASI SPASIAL-KONTEKSTUAL | 61 |
| 4.1 Informasi Spasial-kontekstual berdasarkan <i>Probabilistic Relaxation</i> | 61 |
| 4.1.1 Ujicoba Pengaruh Penyertaan Informasi Spasial-kontekstual berdasarkan <i>Probabilistic Relaxation</i> Menggunakan Data Citra Buatan | 63 |

| | |
|---|------------|
| 4.2 Informasi Spasial-kontekstual berdasarkan Analisa Klustering dengan Citra Aproksimasi Wavelet | 67 |
| 5. METODOLOGI PENYELESAIAN MASALAH | 76 |
| 5.1 Metodologi Klasifikasi <i>Unsupervised</i> Data Polarimetrik-SAR yang Diajukan | 76 |
| 6. UJICOBA DAN ANALISA HASIL | 81 |
| 6.1 Ujicoba Lanjutan dan Analisa Hasil Menggunakan Data Citra Buatan | 81 |
| 6.2 Ujicoba dan Analisa Hasil Menggunakan Data Polarimetrik-E-SAR Daerah Penajam, Kalimantan Timur | 88 |
| 6.3 Ujicoba dan Analisa Hasil Menggunakan Data Polarimetrik-ALOS-PALSAR Daerah Lumajang, Jawa Timur | 101 |
| 6.4 Analisa Hasil Klasifikasi Dikaitkan dengan Tingkat (Kebutuhan) Komputasinya | 108 |
| 7. KESIMPULAN DAN SARAN | 112 |
| 7.1 Kesimpulan | 112 |
| 7.2 Kontribusi Penelitian | 114 |
| 7.3 Saran | 115 |
| DAFTAR REFERENSI | 117 |
| LAMPIRAN | 125 |

DAFTAR GAMBAR

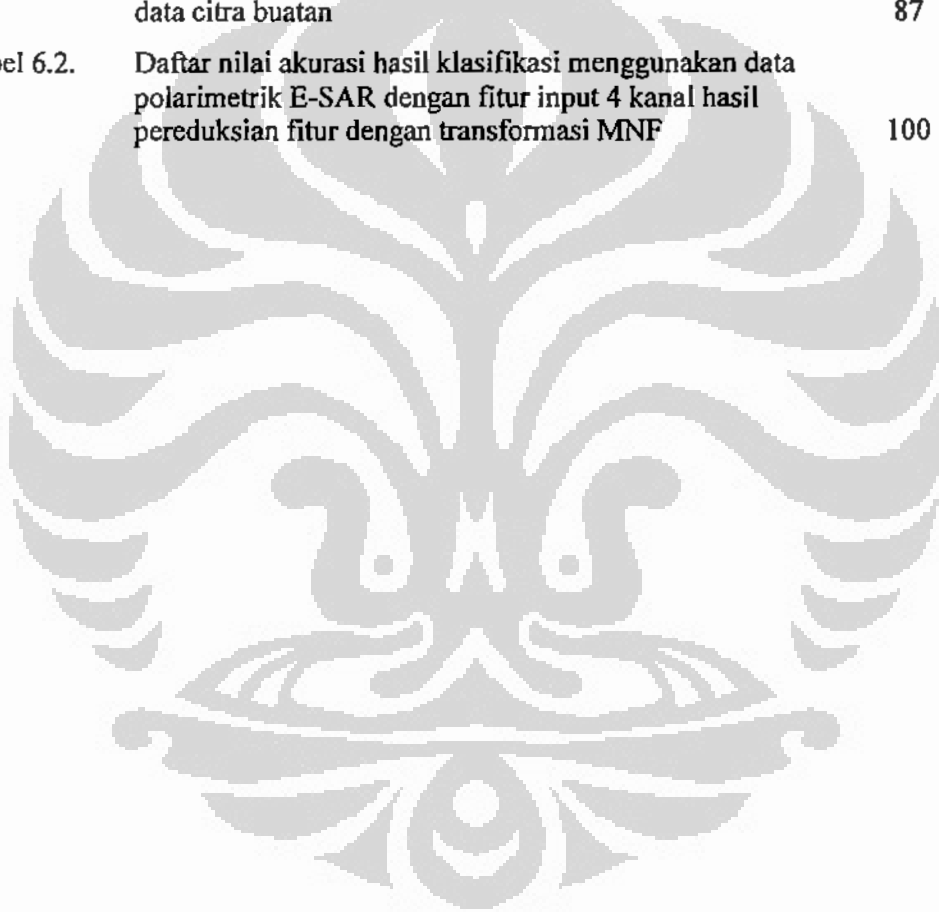
| | | |
|--------------|---|----|
| Gambar 1.1. | Diagram alur klasifikasi dalam penelitian ini | 13 |
| Gambar 1.2. | Data polarimetrik pertama yang dipergunakan (Data E-SAR) | 19 |
| Gambar 1.3. | Ringkasan hasil survei lapangan di daerah Penajam, Kalimantan Timur yang telah dilaksanakan 26 Juni – 4 Juli 2006 | 20 |
| Gambar 1.4. | Data sekunder/referensi lain berupa citra optis ASTER untuk daerah Penajam, Kalimantan Timur | 20 |
| Gambar 1.5. | Data polarimetrik kedua yang dipergunakan (Data ALOS-PALSAR) | 21 |
| Gambar 1.6. | Data sekunder/referensi lain yang diakses dari Google Earth untuk daerah Lumajang, Jawa Timur yang diakses tanggal 20 Februari 2009 | 22 |
| Gambar 2.1. | Penginderaan jauh sistem <i>Synthetic Aperture Radar</i> (SAR) | 27 |
| Gambar 2.2. | Sketsa beberapa tipe/mekanisme hamburan balik sinyal radar (<i>backscattering mechanisms</i>) | 29 |
| Gambar 2.3. | Gelombang mikro yang terpolarisasi | 32 |
| Gambar 2.4. | Contoh ilustrasi efek polarisasi pada objek berbentuk dipol-dipol pendek | 33 |
| Gambar 2.5. | Sembilan fitur parameter polarimetrik yang diekstraksi dari matriks kovarian polarimetrik (<i>polarimetric covariance matrix</i>) untuk data polarimetrik E-SAR daerah Penajam, Kalimantan Timur | 39 |
| Gambar 2.6. | Sembilan fitur parameter polarimetrik yang diekstraksi dari matriks kovarian polarimetrik (<i>polarimetric covariance matrix</i>) untuk data polarimetrik ALOS-PALSAR daerah Lumajang, Jawa Timur | 40 |
| Gambar 2.7. | Pengaruh ukuran jendela pada proses pemfilteran speckle | 41 |
| Gambar 2.8. | Interpretasi tipe hamburan balik berdasar <i>alpha angle</i> | 46 |
| Gambar 2.9. | Bidang <i>entropy-alpha</i> dengan pembagian zona untuk klasifikasi <i>unsupervised</i> berdasarkan karakteristik hamburan baliknya | 47 |
| Gambar 2.10. | Tiga fitur hasil dekomposisi polarimetrik Cloude untuk data polarimetrik E-SAR daerah Penajam, Kalimantan Timur | 49 |
| Gambar 2.11. | Tiga fitur hasil dekomposisi polarimetrik Cloude untuk data polarimetrik ALOS-PALSAR daerah Lumajang, Jawa Timur | 49 |
| Gambar 2.12. | Contoh hasil klasifikasi <i>unsupervised entropy-alpha</i> dari | |

| | | |
|--------------|---|----|
| | hasil dekomposisi polarimetrik Cloude untuk data polarimetrik E-SAR daerah Penajam, Kalimantan Timur | 50 |
| Gambar 2.13. | Contoh hasil klasifikasi <i>unsupervised entropy-alpha</i> dari hasil dekomposisi polarimetrik Cloude untuk data polarimetrik ALOS-PALSAR daerah Lumajang, Jawa Timur | 50 |
| Gambar 2.14. | Hasil transformasi <i>maximum noise fraction</i> (MNF) untuk tujuan pereduksian fitur pada data polarimetrik E-SAR daerah Penajam, Kalimantan Timur | 54 |
| Gambar 2.15. | Hasil transformasi <i>maximum noise fraction</i> (MNF) untuk tujuan pereduksian fitur pada data polarimetrik ALOS-PALSAR daerah Lumajang, Jawa Timur | 55 |
| Gambar 2.16. | Hasil transformasi <i>principal component</i> (PC) sebagai perbandingan dengan hasil transformasi MNF pada data E-SAR (Gambar 2.14) dan pada data ALOS-PALSAR (Gambar 2.15) | 56 |
| Gambar 3.1. | Contoh hasil klasifikasi FMLE dan FKM dengan fitur input 4 kanal hasil pereduksian fitur dengan transformasi MNF data E-SAR (Gambar 2.14) | 60 |
| Gambar 4.1. | Data citra buatan | 64 |
| Gambar 4.2. | Hasil klasifikasi FMLE dengan menggunakan citra buatan dan pengaruh penyertaan informasi spasial-kontekstual berdasar <i>probabilistic relaxation</i> | 65 |
| Gambar 4.3. | Hasil penghitungan <i>compatibility coefficient</i> dari hasil klustering FMLE dengan informasi spektral data citra buatan yang digunakan sebagai dasar penghitungan informasi spasial-kontekstual berdasar <i>probabilistic relaxation</i> | 66 |
| Gambar 4.4. | Grafik perubahan nilai akurasi terhadap jumlah iterasi <i>probabilistic relaxation</i> | 66 |
| Gambar 4.5. | Dekomposisi wavelet dengan <i>discrete wavelet transform</i> (DWT) | 70 |
| Gambar 4.6. | Contoh hasil dekomposisi DWT | 70 |
| Gambar 4.7. | Contoh hasil dekomposisi <i>à trous wavelet transform</i> (ATWT) level 1 | 72 |
| Gambar 4.8. | Contoh hasil klasifikasi dengan menggunakan fitur input citra aproksimasi ATWT level 1 dan perbandingannya dengan menggunakan fitur input citra orisinalnya | 72 |
| Gambar 5.1. | Metodologi klasifikasi <i>unsupervised</i> data polarimetrik-SAR yang diajukan | 77 |
| Gambar 6.1. | Hasil klasifikasi dengan menggunakan citra buatan dan pengaruh penyertaan informasi spasial-kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet | 83 |

| | | |
|--------------|---|-----|
| Gambar 6.2. | Perbandingan hasil klasifikasi FMLE dengan menggunakan citra buatan antara sebelum dan sesudah penyertaan kedua informasi spasial-kontekstual, serta sesudah dilakukan pengolahan akhir dengan <i>majority filtering</i> | 85 |
| Gambar 6.3. | Hasil klasifikasi FMLE menggunakan data polarimetrik E-SAR dengan fitur input parameter polarimetrik, dekomposisi polarimetrik, gabungan parameter polarimetrik dan dekomposisi polarimetrik, 4 kanal hasil pereduksian fitur dengan MNF, dan fitur input data polarisasi tunggal | 91 |
| Gambar 6.4. | Hasil klasifikasi FMLE menggunakan data polarimetrik E-SAR dengan fitur input 4 kanal hasil pereduksian fitur dengan transformasi MNF (dataset 4) dan pengaruh penyertaan informasi spasial-kontekstual berdasar <i>probabilistic relaxation</i> | 94 |
| Gambar 6.5. | Hasil penghitungan <i>compatibility coefficient</i> dari hasil klustering FMLE dengan informasi spektral data polarimetrik E-SAR yang digunakan sebagai dasar penghitungan informasi spasial-kontekstual berdasar <i>probabilistic relaxation</i> | 95 |
| Gambar 6.6. | Hasil klasifikasi FMLE menggunakan data polarimetrik E-SAR dengan fitur input 4 kanal hasil pereduksian fitur dengan transformasi MNF (dataset 4) dan pengaruh penyertaan informasi spasial-kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet | 96 |
| Gambar 6.7. | Perbandingan hasil klasifikasi FMLE (menggunakan data polarimetrik E-SAR dengan fitur input 4 kanal hasil pereduksian fitur dengan transformasi MNF) antara sebelum dan sesudah penyertaan kedua informasi spasial-kontekstual, serta sesudah dilakukan pengolahan akhir dengan <i>majority filtering</i> | 99 |
| Gambar 6.8. | Hasil klasifikasi FMLE menggunakan data polarimetrik ALOS-PALSAR dengan fitur input parameter polarimetrik, dekomposisi polarimetrik, gabungan parameter polarimetrik dan dekomposisi polarimetrik, 4 kanal hasil pereduksian fitur dengan MNF, dan fitur input data polarisasi tunggal | 105 |
| Gambar 6.9. | Perbandingan hasil klasifikasi FMLE (menggunakan data polarimetrik ALOS-PALSAR dengan fitur input 4 kanal hasil pereduksian fitur dengan transformasi MNF) antara sebelum dan sesudah penyertaan kedua informasi spasial-kontekstual, serta sesudah dilakukan pengolahan akhir dengan <i>majority filtering</i> | 109 |
| Gambar 6.10. | Perbesaran hasil pada Gambar 4.12 dan dilengkapi dengan gambar referensi dari Google Earth, gambar kriteria homogenitas, dan gambar hasil FMLE citra aproksimasi hasil dekomposisi wavelet ATWT | 110 |

DAFTAR TABEL

| | | |
|------------|---|-----|
| Tabel 1.1. | Data polarimetrik-SAR yang digunakan | 18 |
| Tabel 2.1. | <i>Pauli basis matrices</i> dan mekanisme hamburan balik yang diasosiasikannya | 36 |
| Tabel 2.2. | Contoh nilai parameter $\alpha, \beta, \phi, \delta, \gamma$ untuk media penghamburbalik standar (<i>canonical scatterer</i>) | 46 |
| Tabel 2.3. | Transformasi <i>maximum noise fraction</i> (MNF) | 52 |
| Tabel 6.1. | Daftar nilai akurasi hasil klasifikasi dengan menggunakan data citra buatan | 87 |
| Tabel 6.2. | Daftar nilai akurasi hasil klasifikasi menggunakan data polarimetrik E-SAR dengan fitur input 4 kanal hasil pereduksian fitur dengan transformasi MNF | 100 |



DAFTAR LAMPIRAN

- Lampiran 1. Daftar paper dan keikutsertaan dalam kegiatan ilmiah terkait dengan penelitian tentang pengolahan data polarimetrik-SAR. 125
- Lampiran 2. Paper yang dipublikasikan dalam International Conference on Information & Communication Technology and Systems (2008), dengan judul "Classification of polarimetric-SAR data using fuzzy maximum likelihood estimation clustering with consideration of complementary information based-on polarimetric parameters, target scattering characteristics, and spatial context". 127
- Lampiran 3. Paper yang dipublikasikan dalam International Journal of Remote Sensing and Earth Sciences (2007), dengan judul "Classification of polarimetric-SAR data with neural network using combined features extracted from scattering models and texture analysis". 139

DAFTAR SINGKATAN DAN ISTILAH

Singkatan

| | |
|-------------|--|
| ALOS-PALSAR | : Advanced Land Observing Satellite -- Phased Array type L-band Synthetic Aperture Radar |
| ATWT | : A Trous Wavelet Transform |
| DWT | : Discrete Wavelet Transform |
| E-SAR | : Experimental Synthetic Aperture Radar |
| ESA | : European Space Agency |
| FKM | : Fuzzy K-Means |
| FMLE | : Fuzzy Maximum Likelihood Estimation |
| HH | : Horizontal Polarisation Transmitted/Horizontal Polarisation Received |
| HV | : Horizontal Polarisation Transmitted/Vertical Polarisation Received |
| INDREX | : Indonesian Airborne Radar Experiment |
| JAXA | : Japan Aerospace Exploration Agency |
| MNF | : Maximum Noise Fraction |
| PC | : Principal Component |
| RESTEC | : Remote Sensing Technology Center of Japan |
| SAR | : Synthetic Aperture Radar |
| SLC | : Single Look Complex |
| SNR | : Signal-to-Noise Ratio |
| VH | : Vertical Polarisation Transmitted/Horizontal Polarisation Received |
| VV | : Vertical Polarisation Transmitted/Vertical Polarisation Received |

Istilah

- Alpha angle* : Parameter hasil dekomposisi polarimetrik Cloude yang memberikan informasi mengenai tipe mekanisme hamburan balik (diantaranya mekanisme hamburan balik dasar *single-bounce/surface scattering*, *double-bounce scattering*, dan *volume scattering*) dalam suatu sel/area tertentu (*resolution cell*).
- Anisotropy* : Parameter hasil dekomposisi polarimetrik Cloude sebagai komplementer parameter *entropy* yang memberikan informasi keterhubungan antar mekanisme hamburan balik selain hamburan balik yang dominan.
- Data Polarimetrik-SAR : Data yang diakusisi dari suatu sistem SAR Polarimetry. Terdiri atas empat kombinasi polarisasi yang dimungkinkan, yaitu: 1) HH (*horizontal transmit dan horizontal receive*); 2) VV (*vertical transmit dan vertical receive*); 3) HV (*horizontal transmit dan vertical receive*); dan 4) VH (*vertical transmit dan horizontal receive*).
- Dekomposisi Polarimetrik : Dekomposisi dari data polarimetrik-SAR yang bertujuan untuk mengekstraksi informasi mengenai berbagai mekanisme hamburan balik dari objek yang berbeda yang selanjutnya dapat dipergunakan untuk membantu proses interpretasi dan klasifikasi data polarimetrik-SAR. Tipe (mekanisme) hamburan balik tersebut diantaranya:
- hamburan balik tunggal atau hamburan balik permukaan (*single-bounce/surface scattering*)
 - hamburan balik ganda (*double-bounce scattering*)
 - hamburan balik volume (*volume scattering*)
- Efek “*salt-and-pepper*” : Efek yang terlihat pada hasil klasifikasi sebagai bintik-bintik (butir-butir berukuran kecil) yang tersebar secara acak di seluruh area. Biasanya didapatkan dari hasil klasifikasi berbasis piksel per piksel.
- Entropy* : Parameter hasil dekomposisi polarimetrik Cloude yang mengukur tingkat kerandoman berbagai mekanisme hamburan balik dalam suatu sel/area tertentu (*resolution cell*).

- Foreshortening* : Distorsi pada citra SAR yang terjadi pada area dengan kemiringan (*slope*) yang menghadap pada arah datangnya sinyal radar sehingga luasan area tersebut tampak menjadi lebih pendek (termampatkan). Apabila kemiringan area tersebut sangat tajam dan posisinya dekat dengan nadir, dapat terjadi *layover* yang mana posisi bagian puncak objek (seperti gunung) dan posisi bagian yang lebih rendah (kaki gunung) menjadi berkebalikan.
- Fuzzy Clustering* : Teknik klasifikasi atau klustering data menggunakan fuzzy yang memungkinkan masing-masing sampel datanya (misalkan: piksel pada data citra) masuk ke dalam lebih dari satu kluster menurut masing-masing derajat keanggotaan tertentu pada tiap klusternya.
- Hamburan balik : *Backscatter*. Sinyal gelombang mikro yang dipantulkan balik oleh target/objek di permukaan bumi ke arah antena penerima SAR.
- Interferometry* : Suatu teknik yang mengkombinasikan hasil dua pengukuran sensor SAR pada titik yang sama di permukaan bumi, namun diakusisi dengan posisi sensor (sudut datang) yang berbeda untuk mendapatkan data ketinggian atau DEM (Digital Elevation Model).
- Koherensi polarimetrik : Parameter yang mengukur kesamaan (*similarity*) gelombang antar dua kanal polarimetrik. Semakin tinggi nilainya maka berarti kedua kanal tersebut saling berkorelasi satu sama lain, dan sebaliknya semakin rendah nilainya berarti kedua kanal tersebut semakin tidak berkorelasi atau tidak koheren (*incoherent*).
- Majority filtering* : Suatu teknik pengolahan akhir (pemfilteran) hasil klasifikasi dengan mengelaskan piksel sentral dalam suatu ukuran jendela tertentu berdasarkan kelas mayoritas dari piksel-piksel di dalam jendela tersebut.
- Noise speckle : Noise yang tampak sebagai bintik-bintik terang-gelap yang tidak beraturan dalam citranya. Pada citra SAR, noise tersebut timbul akibat interferensi konstruktif dan destruktif diantara sinyal-sinyal hamburan balik dari berbagai objek (penghambur-balik) secara random dalam suatu sel/area tertentu (*resolution cell*) yang disinarnya.

- Perbedaan fase polarimetrik** : Parameter yang mengukur nilai perbedaan fase gelombang antar dua kanal polarimetrik. Seperti misalnya, perbedaan fase HH-VV menyatakan nilai perbedaan fase antara kanal HH dengan kanal VV.
- Polarisasi** : Arah dan keteraturan (pola) pergerakan vektor medan listrik pada suatu gelombang elektromagnetik.
- Power (intensitas)** : Parameter yang menyatakan power (energi) gelombang dari masing-masing kanal polarisasi. Seperti misalnya, power (intensitas) HH, HV, VV.
- Probabilistic Relaxation** : Suatu teknik yang diterapkan pada hasil klasifikasi untuk mengoreksi sejumlah piksel-piksel yang berpotensi salah klasifikasi dengan menggunakan informasi probabilitas keanggotaan piksel-piksel yang bertetangga (*local neighborhoods*).
- SAR Polarimetry** : Suatu sistem SAR yang dirancang untuk mengirimkan gelombang mikro yang terpolarisasi secara horisontal (H) dan juga secara vertikal (V). Demikian pula antena penerimanya dapat dirancang untuk menerima sinyal hamburan balik (*backscattered*) baik yang terpolarisasi secara horisontal (H) maupun vertikal (V).
- Shadow** : Suatu area gelap dalam citra SAR dimana tidak terdapat sinyal balik radar yang terdeteksi oleh sensor SAR akibat terhalangi oleh objek dengan ketinggian/tingkat kecuraman yang tajam (seperti gunung, gedung tinggi).
- Speckle Filtering** : Suatu teknik pemfilteran untuk mengurangi (mereduksi) noise speckle namun dengan tetap meminimalkan hilangnya informasi yang berlebihan.

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Synthetic Aperture Radar (SAR) merupakan salah satu teknik penginderaan jauh sistem aktif yang menggunakan daerah gelombang mikro dari spektrum elektromagnetik antara frekuensi 0.3 GHz sampai 300 GHz (atau bisa dinyatakan dengan panjang gelombang, antara 1 m sampai 1 mm). Suatu sistem SAR terdiri atas pemancar (*transmitter*), penerima (*receiver*), dan sistem elektronis untuk memproses dan merekam data. Bagian pemancar akan mengirimkan pulsa gelombang mikro secara kontinyu yang terfokus dalam suatu *beam* ke permukaan bumi dengan arah menyamping (*side looking*). Antena penerima akan menerima bagian dari energi yang kemudian dihamburkan (*backscattered*) oleh objek untuk kemudian direkam dan diproses lebih lanjut. Masing-masing gelombang mikro tersebut dapat dideskripsikan dengan *amplitude* (simpangan/amplitudo gelombang) dan *phase* (fase gelombang). Karena mempunyai sumber energi sendiri tanpa tergantung dengan sumber energi matahari, radar dapat beroperasi siang maupun malam dalam segala kondisi cuaca (karena gelombang mikro dapat menembus awan, asap, dan hujan). Gelombang mikro juga memiliki kemampuan untuk menembus lapisan permukaan, sebagai contoh kanopi vegetasi, lebih dalam daripada panjang gelombang optis. Radar juga sensitif terhadap kekasaran permukaan, bentuk dan orientasi objek, kelembaban, sifat elektris, dan gerakan dalam permukaan yang disinari. Informasi unik yang diberikan citra SAR seperti ini dapat dipakai sebagai komplemen satu sama lain dengan citra-citra optis (Tso and Matter, 2001; Bruzzone *et al.*, 2004; Woodhouse, 2006).

Data SAR kanal tunggal dan polarisasi tunggal (*single-channel single-polarisation SAR*) telah lama dikenal dan dimanfaatkan di berbagai bidang. Secara garis besar terdapat dua aplikasi utama yang dapat diturunkan dari data SAR, yakni: 1) aplikasi untuk keperluan pencitraan (*SAR imaging*) yang terutama

memanfaatkan informasi *amplitude* gelombang hamburan balik yang diproses lebih lanjut membentuk piksel-piksel dalam citra SAR; dan 2) aplikasi interferometrik-SAR (*SAR interferometry*) yang memanfaatkan informasi perbedaan *phase* yang diturunkan dari dua data SAR yang diakuisisi dengan posisi sensor yang berbeda untuk mendapatkan data ketinggian atau DEM (Digital Elevation Model) (Tso and Matter, 2001; Woodhouse, 2006).

Berbeda dengan aplikasi interferometrik-SAR yang secara teknik (metode) telah teruji keefektifannya dan saat ini telah dipergunakan (dioperasionalkan) secara luas, aplikasi pencitraan SAR masih menemui banyak kendala sehingga sedikit banyak menghalangi pemakaian data SAR secara luas dibandingkan dengan data dari penginderaan jauh sistem optis. Kendala-kendala tersebut diantaranya diakibatkan oleh permasalahan geometris yang khas pada citra SAR (*SAR imaging geometry*, seperti terjadinya '*shadow*', '*layover*', dan '*foreshortening*' pada objek dengan ketinggian/tingkat kecuraman yang tajam yang sulit untuk dikompensasi lebih lanjut), proses hamburan balik yang sangat kompleks, dan timbulnya noise speckle pada citra SAR yang nampak sebagai noise/tekstur bintik-bintik terang-gelap yang tidak beraturan dalam citranya (Tso and Matter, 2001; Woodhouse, 2006). Noise tersebut timbul akibat interferensi konstruktif dan destruktif diantara sinyal-sinyal hamburan balik dari berbagai objek (penghambur-balik) secara random dalam suatu sel/area tertentu (*resolution cell*) yang disinarnya. Hal ini berimplikasi pada proses ekstraksi atau diskriminasi berbagai objek dalam data SAR karena sulitnya menentukan (mengestimasi) informasi kontribusi relatif dari masing-masing objek tersebut terhadap gabungan proses hamburan baliknya secara tepat (Hajnsek, 2001; Woodhouse, 2006). Walaupun informasi tertentu yang diharapkan terkandung dalam datanya, hal ini terkadang tidak dapat diakses (diekstraksi) dengan mudah dan tepat dikarenakan hanya total hamburan baliknya saja yang diukur. Sebagai contoh, dari beberapa penelitian telah diketahui bahwa terdapat korelasi antara koefisien hamburan balik radar misalnya dengan kondisi vegetasi atau biomasa kehutanan, namun juga diketahui bahwa hal tersebut terutama berlaku terbatas pada tingkatan biomasa yang rendah dan gagal (mengalami saturasi) pada tingkatan yang tinggi. Hasilnya juga banyak tergantung pada spesies vegetasinya serta terkadang bersifat khas

untuk daerah tertentu saja (*site specific*) (Fransson, 1999; McNeill and Pairman, 2003; Santoro, 2003; Woodhouse, 2006). Keterbatasan tersebut juga dilaporkan pada aplikasi di bidang pertanian (Ferrazzoli *et al.*, 1997) dan perbedaan berbagai tipe es (Bogdanov *et al.*, 2005). Walaupun noise ini dapat direduksi dengan proses *speckle-filtering* namun masih tetap menyisakan beberapa permasalahan (seperti turunnya resolusi spasial, efek *blur* yang berlebihan, berubahnya parameter statistik atas datanya secara signifikan) sehingga pada umumnya sulit untuk memperoleh tingkat identifikasi dan klasifikasi objek tutupan lahan yang tinggi apabila hanya digunakan sebuah data SAR kanal tunggal. Oleh karenanya, pada beberapa penelitian dipergunakan metode pengolahan dengan penyertaan informasi tambahan baik itu berupa informasi tambahan yang dapat diekstraksi dari data SAR tersebut secara langsung seperti misalnya informasi tekstural citranya, ataupun dari data tambahan lain dari sumber yang berbeda. Data tambahan tersebut dapat berupa data SAR dari kanal yang berbeda (pendekatan multi-kanal), data SAR dengan kanal yang sama namun berbeda tanggal akuisisi (pendekatan multi-temporal), maupun data citra multi-spektral dari sensor optis (Fransson, 1999; Bruzzone *et al.*, 2004; Bogdanov *et al.*, 2005). Apabila digunakan metode pengolahan dan klasifikasi yang tepat, metode ini dapat memberikan peningkatan akurasi klasifikasi tutupan lahan yang tinggi. Namun demikian, dalam praktek penerapannya terkadang susah untuk mendapatkan data citra multi-spektral yang bebas awan, dan terkadang data tersebut (baik optis maupun SAR) diakuisisi dalam tanggal yang berbeda sehingga kurang sesuai untuk pemantauan objek tutupan lahan yang sifatnya dinamis. (Seperti misalnya satelit-satelit penginderaan jauh yang memuat sensor SAR saat ini rata-rata interval mengunjungi daerah yang sama dalam waktu yang lama, misalnya 35 hari untuk ERS-2 dan ENVISAT, dan 24 hari untuk RADARSAT.)

SAR polarimetry merupakan perkembangan utama dari pencitraan SAR kanal tunggal konvensional (*single-channel SAR*) yang menambahkan sifat polarisasi dari suatu gelombang elektromagnetik dalam rangka memperkaya parameter hasil pengukuran sensor radar. Suatu sistem SAR polarimetry dirancang untuk mengirimkan gelombang mikro yang terpolarisasi secara horisontal (H) dan juga secara vertikal (V). Demikian pula antena penerimanya

dapat dirancang untuk menerima sinyal hamburan balik (*backscattered*) baik yang terpolarisasi secara horisontal (H) maupun vertikal (V). Dengan demikian terdapat empat kombinasi polarisasi yang dimungkinkan, yaitu: 1) HH (*horizontal transmit dan horizontal receive*); 2) VV (*vertical transmit dan vertical receive*); 3) HV (*horizontal transmit dan vertical receive*); dan 4) VH (*vertical transmit dan horizontal receive*). Ketika gelombang radar berinteraksi dengan permukaan bumi atau target, polarisasi tersebut akan termodifikasi sesuai dengan karakteristik permukaan bumi atau target tersebut yang pada gilirannya akan memberikan efek yang berbeda-beda pada energi hamburan baliknya. Hal ini selanjutnya akan berpengaruh pada kenampakan citra SAR yang didapatkan dari masing-masing kombinasi polarisasi tersebut. Keempat informasi polarisasi tersebut diakuisisi dalam waktu yang bersamaan sehingga tidak menjadi masalah walaupun tutupan lahan yang dipantau bersifat dinamis dan juga dapat diperoleh data yang bebas awan. Lebih jauh, terdapat banyak keuntungan lain dengan data polarimetrik-SAR ini dibandingkan dengan data SAR konvensional, diantaranya: 1) data polarimetrik-SAR akan mampu memberikan informasi (deskripsi) atas target (objek) secara lebih lengkap; 2) mampu membedakan secara lebih baik antara target-target berdasarkan mekanisme hamburan baliknya, diantaranya hamburan balik tunggal atau hamburan balik permukaan (*single-bounce/surface scattering*), hamburan balik ganda (*double-bounce scattering*), dan hamburan balik volume (*volume scattering*); dan 3) lebih mampu menyajikan kontrasan di antara objek-objek yang selanjutnya dapat dipakai sebagai dasar bagi proses pengklasifikasian objek secara lebih akurat (Corr *et al.*, 2003; Skriver *et al.*, 2003; Karathanassi and Dabboor, 2004; Woodhouse, 2006).

Dengan keuntungan-keuntungan tersebut diharapkan aplikasi-aplikasi yang dapat diturunkan dari data polarimetrik-SAR ini semakin berkembang, diantaranya untuk aplikasi kehutanan, pertanian, hidrologi, geologi, kelautan, mitigasi bencana, dan lain-lain (Ferrazzoli *et al.*, 1997; Skriver *et al.*, 2003; Quegan *et al.*, 2003; Woodhouse, 2006). Namun demikian untuk saat ini masih terdapat beberapa kendala, diantaranya masih terbatasnya wahana satelit penginderaan jauh SAR yang mensupport *fully polarimetric* (seperti ALOS PALSAR – kanal L yang telah diluncurkan Januari 2006 dan TerraSAR - kanal X

yang telah diluncurkan Juni 2007). Di samping itu juga metode (algoritma) untuk mengekstraksi maupun mengklasifikasi data polarimetrik-SAR untuk berbagai aplikasi secara tepat dan efisien masih sangat terbatas. Apalagi khususnya di Indonesia, data polarimetrik-SAR ini masih relatif baru, belum banyak dikenal dan dimanfaatkan oleh masyarakat luas dibandingkan dengan data SAR konvensional. Hal tersebut menjadi salah satu motivasi penulis untuk melakukan penelitian dengan tema utama ekstraksi dan klasifikasi berbagai informasi objek tutupan lahan dari data polarimetrik-SAR, khususnya yang bermanfaat untuk aplikasi-aplikasi penginderaan jauh di Indonesia.

1.2 Permasalahan Terkini terkait dengan Ekstraksi Fitur dan Klasifikasi Data Polarimetrik-SAR

Salah satu tujuan dari penginderaan jauh adalah untuk mengidentifikasi dan mengklasifikasi berbagai objek tutupan lahan di permukaan bumi. Penggunaan gelombang multi-polarisasi pada sistem SAR polarimetry memungkinkan pengguna data untuk mengekstraksi berbagai informasi tambahan yang dapat dipakai sebagai fitur-fitur input pengklasifikasi sehingga memberikan hasil klasifikasi tutupan lahan yang lebih baik dibandingkan dengan data SAR konvensional dengan kanal tunggal dan polarisasi tunggal (*single-channel single-polarisation SAR*) (Reigber, 2001; Acqua and Gamba, 2003; Karathanassi and Dabboor, 2004; Beaulieu and Touzi, 2004; Woodhouse, 2006). Dengan alasan tersebut, pada beberapa tahun terakhir ini, data polarimetrik-SAR mulai secara intensif dikaji sebagai data dasar untuk menghasilkan peta tutupan lahan yang lebih akurat.

Klasifikasi secara tidak terbimbing (*unsupervised classification*) adalah salah satu teknik penting untuk analisa secara otomatis atas data polarimetrik-SAR, karena dapat dilakukan tanpa perlu adanya dataset training yang biasanya diturunkan dari informasi lapangan (*ground truth*) atau informasi tambahan lainnya mengenai area tersebut. Informasi seperti data lapangan tersebut biasanya didapatkan dengan biaya, waktu, dan tenaga yang tidak sedikit. Pada berbagai literatur, beberapa pendekatan klasifikasi tidak terbimbing atas data polarimetrik-SAR telah diajukan. Secara garis besar terdapat dua tipe pendekatan,

yakni: 1) pendekatan yang didasarkan hanya pada klasifikasi (klustering) secara statistik atas data hasil pengukuran parameter polarimetrik-SAR secara langsung; 2) pendekatan yang didasarkan atas analisa sifat-sifat fisik hamburan balik sinyal radar.

Pada pendekatan pertama, parameter-parameter hasil pengukuran sensor SAR polarimetry biasanya dipergunakan secara langsung sebagai fitur input ke klasifier setelah melalui tahapan pengolahan awal. Sebagian besar dipergunakan fitur input yang berformat matriks kovarian polarimetrik (*complex polarimetric covariance matrix*) berukuran 3x3 yang mengandung informasi baik itu power yang diterima sensor untuk masing-masing kanal polarisasinya maupun besaran koherensi kompleks antar kanal polarisasinya. Beberapa metode klustering (klasifikasi) seperti dengan ISODATA, *fuzzy c-mean method* (Du and Lee, 1996), *expectation method* (Davidson *et al.*, 2002), *hierarchical segmentation* (Beaulieu and Touzi, 2004) telah dikaji. Pada umumnya, distribusi probabilitas masing-masing kelas dari representasi matriks kovarian polarimetrik tersebut diasumsikan mengikuti *complex Wishart distribution*.

Pada pendekatan kedua, beberapa pemodelan hamburan balik sinyal radar yang disebut dengan dekomposisi polarimetrik (*target/polarimetric decomposition*) telah diajukan. Dekomposisi ini bertujuan untuk mengekstraksi informasi mengenai berbagai mekanisme hamburan balik (diantaranya *single-bounce/surface scattering*, *double-bounce scattering*, dan *volume scattering*) dari objek yang berbeda yang selanjutnya dapat dipergunakan untuk membantu proses interpretasi dan klasifikasi data polarimetrik-SAR (Cloude and Pottier, 1997; Freeman and Durden, 1998). Model dekomposisi polarimetrik Cloude (Cloude and Pottier, 1997) adalah model dekomposisi yang paling banyak dipergunakan untuk keperluan tersebut, diantaranya karena didasarkan atas pemodelan hamburan balik yang lebih realistik, kesederhanaannya (*simplicity*), dan mudah diimplementasikan dalam pengolahan citra (Lee *et al.*, 1999a; Hellmann, 2001; Pottier *et al.*, 2005; Sambodo *et al.*, 2007b; Sambodo *et al.*, 2008). Model tersebut mengajukan suatu pendekatan klasifikasi secara tidak terbimbing (yang disebut dengan klasifikasi *unsupervised entropy-alpha*) berdasarkan suatu teori dekomposisi eigen. Mekanisme hamburan balik dari berbagai medium dibedakan

(diklasifikasikan) berdasarkan parameter *entropy* dan *alpha angle* yang diturunkan dari hasil dekomposisi eigen. *Entropy* merupakan parameter yang mengukur tingkat kerandoman berbagai mekanisme hamburan balik, sedangkan parameter *alpha angle* memberikan informasi mengenai tipe mekanisme hamburan baliknya. Bidang *entropy-alpha* tersebut kemudian dibagi menjadi 9 zona dengan batas yang tetap (*fix*), yang mana masing-masing zona tersebut mempunyai karakteristik hamburan balik yang berbeda yang dapat diasosiasikan dengan suatu tipe tutupan lahan tertentu.

Dalam perkembangan selanjutnya, terdapat pula beberapa penelitian yang mencoba mengkombinasikan kedua pendekatan tersebut, terutama dengan menggunakan informasi 9 zona hasil dekomposisi polarimetrik Cloude untuk menginisialisasi klustering dengan metode *Wishart* (Lee *et al.*, 1999a; Kersten *et al.*, 2005; Reigber *et al.*, 2007). Algoritma-algoritma tersebut dilaporkan telah dapat diaplikasikan dalam berbagai keperluan klasifikasi tutupan lahan (Cloude and Pottier, 1997; Lumsdon, 2003; Sambodo dan Teguh, 2005), klasifikasi tipe es laut (Scheuchl *et al.*, 2001), dan klasifikasi area hutan (Ferro-Famil *et al.*, 2005; Lee *et al.*, 2005). Pada umumnya, hasil penelitian tersebut melaporkan bahwa hasil klasifikasi yang didapatkan cukup baik. Namun demikian, pada beberapa kasus, mereka juga melaporkan keterbatasan metode-metode tersebut untuk membedakan (mendiskriminasikan) dan mengklasifikasikan lebih lanjut ke dalam berbagai tipe objek tutupan lahan khususnya yang berkarakteristik hamburan balik yang sejenis. Seperti misalnya untuk mengklasifikasikan area hutan menjadi beberapa tipe hutan dan umur (tahap) pertumbuhannya. Bahkan terkadang metode tersebut memberikan hasil kluster-kluster (kelas-kelas) yang arti sifat fisiknya tidak jelas. Untuk mengatasi permasalahan-permasalahan tersebut, beberapa penelitian menganjurkan untuk menggunakan informasi tambahan yang dapat dipakai sebagai fitur input tambahan sehingga menurunkan ambiguitas antar kelas dan meningkatkan performansi klasifikasi (Borghys *et al.*, 2006; Sambodo *et al.*, 2007b). Meskipun informasi tambahan seperti itu dapat diperoleh dari sumber data yang lain (seperti misalnya data citra satelit optis, data radar multi-frekuensi, data koherensi interferometrik, peta geologi, dan lain lain), akan lebih efisien dan efektif apabila digunakan informasi tambahan yang dapat diekstraksi dari data

polarimetrik-SAR yang sama namun dari aspek yang berbeda. Seperti misalnya dari tekstur citranya, konteks, relasi struktur/objek dalam citranya, dan lain-lain. Namun demikian, sebagian besar algoritma-algoritma di atas menggunakan fitur input yang berformat *complex polarimetric covariance matrix* 3x3 (atau sebagai alternatif *complex polarimetric coherency matrix* 3x3), sehingga fitur-fitur tambahan yang biasanya memiliki format atau tipe data yang beragam tidak dapat dimasukkan ke dalam format input tersebut.

Pada beberapa penelitian terkini, khususnya untuk aplikasi kehutanan, telah dikaji dan dilaporkan bahwa suatu analisa atas koherensi interferometrik dapat dipergunakan untuk membeda-bedakan berbagai tipe area hutan (Ferro-Famil *et al.*, 2005; Lee *et al.*, 2005). Namun demikian, metode ini akan efektif bila sepasang data polarimetrik-interferometrik (yakni dua data pada objek yang sama yang diakuisisi dengan posisi sensor radar yang berbeda) tersedia untuk penghitungan informasi koherensi interferometrik tersebut (untuk mengestimasi ketinggian vegetasi). Selain terbatas bidang aplikasinya (dalam hal ini untuk kehutanan) dan proses penghitungan yang sangat kompleks, terkadang hasil yang didapatkan pun bersifat khas untuk daerah tertentu saja dan belum tentu memberikan hasil yang sama apabila diimplementasikan pada daerah lain (*site-specific*).

Keterbatasan lain dari algoritma-algoritma tersebut di atas adalah dilakukan dalam basis piksel per piksel. Hal ini berarti masing-masing piksel diperlakukan secara independen terpisah dari piksel-piksel tetangganya. Padahal, tentu saja informasi tetangga-tetangga sekitarnya akan sangat mempengaruhi keanggotaan suatu piksel dalam suatu kelas tertentu. Apabila suatu wilayah telah diklasifikasikan ke dalam suatu kelas tertentu dengan keyakinan yang tinggi, maka kecillah kemungkinannya bahwa sebuah piksel di dalam wilayah tersebut masuk dalam kelas yang berbeda. Dalam hal data polarimetrik-SAR, kemungkinan besar hal tersebut disebabkan oleh salah estimasi dalam penghitungan matriks kovarian akibat adanya noise speckle, yang biasanya menghasilkan hasil klasifikasi yang bernoise (sering muncul sebagai efek "*salt-and-pepper*" walaupun berada pada area yang homogen). Akibat dari adanya tingkat noise yang tinggi yang merupakan sifat-sifat khas dari data SAR tersebut,

maka penyertaan informasi tetangga sekitarnya dalam pengambilan keputusan pengkelasan suatu piksel tertentu akan membantu dalam memberikan hasil klasifikasi yang homogen (Canty, 2006; Reigber *et al.*, 2007; Sambodo *et al.*, 2008).

Berdasarkan permasalahan-permasalahan tersebut di atas, penelitian ini mencoba untuk mengupayakan peningkatan performansi identifikasi dan klasifikasi berbagai objek tutupan lahan dari data polarimetrik-SAR dengan metode yang lebih tepat dan efektif. Penulis berpendapat bahwa terdapat peluang untuk mempergunakan dan mengintegrasikan berbagai informasi yang dapat diekstraksi secara langsung dari data polarimetrik-SAR yang sama namun dengan menggunakan aspek yang berbeda. Bukan hanya parameter polarimetrik hasil pengukuran sensor SAR secara langsung, fitur turunan hasil dekomposisi polarimetrik juga patut dipertimbangkan karena memberikan informasi dari aspek yang berbeda yakni karakteristik hamburan balik dari suatu objek. Selain itu, aspek spasial-kontekstual yang memberikan informasi atas struktur spasial dari suatu citra polarimetrik-SAR patut pula dipertimbangkan. Dari berbagai penelitian, informasi spasial-kontekstual dilaporkan mempunyai kemampuan untuk meningkatkan performansi hasil klasifikasi (Tso and Matter, 2001; Canty and Nielsen, 2004; Canty, 2006; Reigber *et al.*, 2007; Sambodo *et al.*, 2008). Hal yang krusial selanjutnya adalah pengintegrasian fitur-fitur dari beberapa aspek tersebut ke dalam suatu metode klasifikasi yang tepat dan efisien. Metode klasifikasi tidak terbimbing (*unsupervised classification*) menjadi fokus pada penelitian ini dengan alasan metode ini akan melakukan pengklusteran atau pengkelasan masing-masing jenis objek tutupan lahan secara langsung dari data inputnya sehingga meminimalkan interaksi oleh user/operator pada awal prosesnya yang terkadang bersifat sangat subjektif. Berbeda dengan pendekatan klasifikasi terbimbing (*supervised classification*) yang membutuhkan dataset training (untuk "melatih" klasifier yang akan dipakai tersebut) yang biasanya diperoleh melalui survei lapangan (*ground truth*) dengan biaya, waktu, dan tenaga yang tidak sedikit. Hasil yang diperoleh pun terkadang sangat dipengaruhi oleh kualitas dataset training yang dipilih oleh user/operator tersebut (Tso and Matter, 2001).

1.3 Perumusan Permasalahan

Poin-poin masalah yang menjadi titik tolak dalam penelitian ini dapat dirinci sebagai berikut:

- a) Data SAR konvensional (kanal tunggal dan polarisasi tunggal) memiliki berbagai keterbatasan dalam mengidentifikasi dan mengklasifikasikan berbagai objek tutupan lahan akibat minimnya parameter hasil pengukuran sensor radar dan gangguan noise speckle. Teknologi terkini SAR polarimetry berusaha memperkaya informasi tersebut dengan mengukur empat informasi polarisasi (HH, VV, HV, dan VH) secara bersamaan yang selanjutnya dapat dipakai sebagai fitur-fitur input pengklasifikasi sehingga memberikan hasil klasifikasi tutupan lahan yang lebih baik dibandingkan dengan data SAR konvensional (Reigber; 2001; Acqua and Gamba, 2003; Karathanassi and Dabboor, 2004; Beaulieu and Touzi, 2004; Woodhouse, 2006). Selanjutnya untuk melakukan klasifikasi *unsupervised*, secara garis besar terdapat dua pendekatan. Pertama dengan menggunakan metode klustering (klasifikasi) dengan menggunakan format matriks kovarian polarimetrik berukuran 3x3 yang berisi parameter hasil pengukuran sensor SAR polarimetry secara langsung. Yang kedua adalah metode klasifikasi *unsupervised* menggunakan dekomposisi polarimetrik dengan menganalisa karakteristik hamburan balik sinyal radar atas suatu objek serta membaginya menjadi 9 zona (kelas) dengan batas yang tetap (fix). Beberapa keterbatasan dari pendekatan-pendekatan tersebut diantaranya:
 - keterbatasan kemampuan algoritma-algoritma tersebut dalam mengidentifikasi dan mengklasifikasikan berbagai objek tutupan lahan secara akurat dan bahkan terkadang memberikan hasil kelas-kelas yang arti fisiknya tidak jelas;
 - potensi data polarimetrik yang mampu memberikan informasi suatu objek tutupan lahan dari tinjauan dua atau lebih aspek yang berbeda (seperti misalnya berdasar karakteristik hamburan balik, aspek spasial-kontekstual, dan lain-lain) belum terintegrasikan atau termanfaatkan secara maksimal dalam algoritma-algoritma tersebut;

- tidak fleksibelnya fitur input ke klasifier yakni berformat matriks kovarian polarimetrik berukuran 3×3 , sehingga fitur-fitur tambahan (baik yang dieksploitasi dari data polarimetrik yang sama maupun yang berasal dari sumber data yang berbeda) yang dapat menurunkan ambiguitas antar kelas dan meningkatkan performansi klasifikasi tidak dapat dimasukkan ke dalam format input tersebut;
 - proses klasifikasi secara umum dilakukan dalam basis piksel per piksel, sehingga biasanya menghasilkan hasil klasifikasi yang bernoise (sering muncul sebagai efek "*salt-and-pepper*" walaupun berada pada area yang homogen) akibat adanya noise speckle.
- b) Untuk mengupayakan peningkatan performansi identifikasi dan klasifikasi berbagai objek tutupan lahan, pada beberapa penelitian telah dikaji penggunaan data tambahan (seperti data multi-temporal, multi-kanal, citra optis, informasi koherensi interferometrik) menggunakan metode pengolahan dengan kompleksitas tinggi (Ferrazzoli *et al.*, 1997; Fukuda and Hirose, 1999; Quegan *et al.*, 2003;). Namun sayangnya cenderung bersifat terbatas untuk aplikasi tertentu saja (*application-dependent*) dan hasilnya terkadang bersifat khas untuk daerah tertentu saja (*site-specific*). Tentunya akan lebih efisien dan efektif apabila informasi tambahan tersebut dapat diekstraksi dari data polarimetrik-SAR yang sama namun dari tinjauan aspek yang berbeda (seperti misalnya selain dari berbagai parameter polarimetrik, juga informasi seperti karakteristik hamburan baliknya, informasi spasial-kontekstual, relasi struktur/objek dalam citranya, dan lain-lain). Apabila dimungkinkan pengekstraksian fitur-fitur dari beberapa aspek tersebut, selanjutnya bagaimanakah metode yang tepat untuk mengintegrasikan fitur-fitur dari aspek yang berbeda tersebut agar dapat bersifat saling melengkapi (komplementer) dalam mengidentifikasi dan mendiskriminasi objek?
- c) Secara umum, sifat dasar data/hasil pengukuran sensor SAR adalah bersifat ambigu (yakni tidak persis, tidak komplet, dan tidak sepenuhnya dapat dipercaya) akibat sistem pengakuisisian data dengan arah menyamping (*side looking*), pengaruh ketidakstabilan antena/sensor ketika

mengakuisisi data, maupun akibat proses hamburan balik sinyal radar yang sangat kompleks. Oleh karena itu, pada proses klasifikasinya yang dalam penelitian ini difokuskan dengan pendekatan klasifikasi *unsupervised* diperlukan suatu pertimbangan khusus yang mampu mengeksploitasi informasi dari data ataupun fitur-fitur turunan tersebut secara lebih tepat. Apakah dalam hal ini teknik klustering fuzzy lebih efektif dan aplikabel untuk tujuan tersebut? Hal ini mengingat dari beberapa penelitian, konsep fuzzy dilaporkan memberikan performansi yang bagus dalam penanganan terkait masalah-masalah klasifikasi di dalam suatu lingkungan yang bersifat ambigu (Tzeng and Chen, 1998; Liew *et al.*, 2000; Tso and Matter, 2001; Kersten *et al.*, 2005).

- d) Keberadaan noise speckle yang merupakan sifat yang melekat pada data SAR menjadikan hasil klasifikasi yang didapatkan biasanya sangat bernoise (*'salt-and-pepper'*). Sebagai solusinya, penyertaan informasi spasial-kontekstual dalam pengambilan keputusan pengkelasan suatu piksel akan membantu dalam memberikan hasil klasifikasi yang homogen (Canty, 2006; Reigber *et al.*, 2007; Sambodo *et al.*, 2008). Dalam kaitan dengan hal ini, bagaimanakah metode yang tepat untuk mengeksploitasi informasi spasial-kontekstual dari data polarimetrik-SAR?

1.4 Tujuan Penelitian

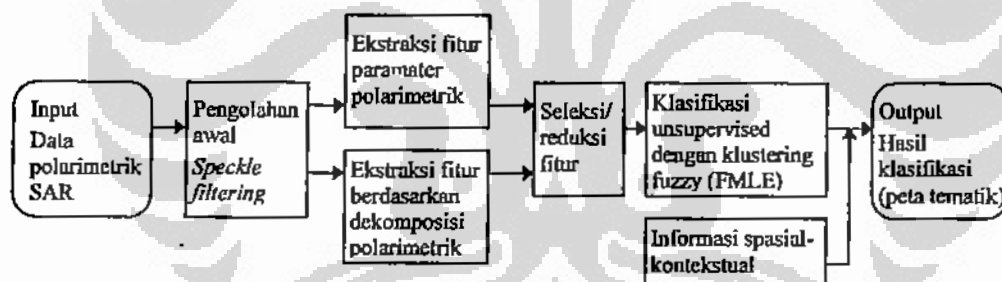
Penelitian ini dilakukan dengan tujuan utama untuk :

- a) menggali potensi keunggulan penggunaan data polarimetrik-SAR dibanding data SAR konvensional
- b) mengembangkan suatu metodologi alternatif untuk mengeksploitasi secara optimal informasi-informasi yang terkandung dalam data polarimetrik-SAR dengan tinjauan dari multi aspek (yakni parameter polarimetrik-SAR, dekomposisi polarimetrik, dan informasi spasial-kontekstual) sehingga didapatkan hasil identifikasi dan klasifikasi objek tutupan lahan yang lebih akurat namun tetap meminimalkan kompleksitas pengolahan datanya.

1.5 Metodologi Penyelesaian Masalah yang Diusulkan dan Kerangka Dasar Pemikirannya

Penelitian ini mengajukan suatu metodologi alternatif klasifikasi *unsupervised* untuk mengupayakan tercapainya peningkatan performansi identifikasi dan klasifikasi berbagai objek tutupan lahan dari data polarimetrik-SAR. Ide dasar dari metodologi ini adalah:

- mengkombinasikan berbagai fitur-fitur yang diekstraksi dari tinjauan aspek yang berbeda yang berpotensi memiliki sifat saling komplementer untuk meningkatkan kemampuan identifikasi berbagai objek tutupan lahan,
- mengintegrasikan hasil klasifikasi berbasis piksel per piksel dengan informasi spasial-kontekstual untuk menghasilkan keputusan pengkelasan yang lebih optimal sehingga didapatkan hasil klasifikasi yang tidak bernoise (lebih homogen) namun tetap dapat mempertahankan batas-batas (*edge*) dan objek-objek yang berukuran kecil.



Gambar 1.1 Diagram alur klasifikasi dalam penelitian ini.

Untuk mewujudkan hal tersebut, secara garis besar diagram alur klasifikasi yang akan ditempuh dalam penelitian ini ditunjukkan pada Gambar 1.1. Pertama-tama dilakukan pereduksian noise speckle terhadap data input polarimetrik SAR dengan ukuran jendela *speckle-filtering* yang tidak terlalu besar untuk menghindari *blur* yang berlebihan dan rusaknya batas-batas objek. Selanjutnya dilakukan proses ekstraksi fitur, yang dalam penelitian ini dikaji pengoptimalan eksploitasi informasi semaksimal mungkin dari data polarimetrik yang sama tanpa

ketergantungan data lainnya (seperti data citra optis, data SAR multifrekuensi, dan lain-lain). Untuk tujuan tersebut, dipertimbangkan pengekstraksian fitur dengan dua metode. Pertama, dari representasi dasar polarimetrik-SAR dalam format matriks kovarian 3x3 dilakukan ekstraksi beberapa fitur parameter polarimetrik, sehingga didapatkan: 1) tiga fitur power (intensitas) HH, HV, dan VV yang menyatakan power dari masing-masing kanal polarisasi tersebut; 2) tiga fitur parameter koherensi antar kanal polarimetriknya yang mengukur kesamaan (*similarity*) antar dua kanal polarimetrik; 3) tiga fitur parameter perbedaan fase yang mengukur nilai perbedaan fase masing-masing kanal polarimetrik. Kedua adalah ekstraksi fitur berdasarkan dekomposisi polarimetrik Cloude yang bertujuan untuk mengekstraksi informasi mengenai berbagai karakteristik hamburan balik dari objek-objek yang berbeda. Dari dekomposisi ini didapatkan tiga parameter, yakni: 1) parameter *alpha angle* memberikan informasi mengenai tipe mekanisme hamburan baliknya (diantaranya mekanisme hamburan balik dasar *single-bounce/surface scattering*, *double-bounce scattering*, dan *volume scattering*); 2) parameter *entropy* yang mengukur tingkat kerandoman berbagai mekanisme hamburan balik; 3) parameter *anisotropy* yang merupakan parameter komplemen *entropy* (memberikan informasi keterhubungan antar mekanisme hamburan balik selain hamburan balik yang dominan).

Dari hasil pengamatan visual, fitur-fitur dari kedua aspek tersebut juga memberikan informasi yang berbeda, namun demikian sebelum dilakukan pengintegrasian tetap perlu dikaji lebih lanjut apakah fitur-fitur dari kedua aspek tersebut (yang secara keseluruhan akan didapatkan dua belas fitur) mempunyai sifat yang saling komplementer dalam mengidentifikasi dan mendiskriminasi objek. Bersamaan dengan hal tersebut, patut pula dipertimbangkan untuk memeriksa dan sekaligus menghilangkan informasi (fitur) yang sifatnya redundan terlebih dahulu sebelum dilakukan proses klasifikasinya. Tahap seleksi (reduksi) fitur ini penting mengingat klasifikasi data berdimensi tinggi merupakan suatu hal yang kompleks dan biasanya membutuhkan komputasi yang tinggi.

Tahap berikutnya adalah klasifikasi yang dalam hal ini menggunakan klustering fuzzy. Teknik klasifikasi menggunakan fuzzy memungkinkan masing-masing piksel pada data citra masuk ke dalam lebih dari satu kluster menurut

masing-masing derajat keanggotaan tertentu untuk tiap-tiap klusternya (Gath and Geva, 1989; Canty and Nielsen, 2004; Canty, 2006). Oleh karena itu, hal ini sangat sesuai untuk mengklasifikasikan data SAR yang mana keberadaan noise speckle sering mengakibatkan banyak piksel pada datanya benar-benar bersifat ambigu (yakni, tidak persis, tidak komplet, dan tidak sepenuhnya dapat dipercaya). Metode klustering *fuzzy maximum likelihood estimation* (FMLE) dipilih dalam penelitian ini karena memungkinkan pembentukan kluster-kluster yang berbentuk elips dan oleh karenanya dipertimbangkan lebih fleksibel dibandingkan dengan metode klustering *fuzzy K-means* (FKM) yang standar. Pada FKM digunakan jarak Euclidean, sehingga hanya memungkinkan pembentukan kluster yang berbentuk lingkaran (Gath and Geva, 1989; Canty and Nielsen, 2004; Canty, 2006). Keuntungan lainnya adalah bahwa fitur-fitur tambahan dapat ditambahkan ke dalam proses klustering FMLE dengan menambah dimensi dari vektor data inputnya. Oleh karenanya, berbagai fitur yang dapat diturunkan dari data polarimetrik-SAR dengan menggunakan beberapa metode ekstraksi fitur maupun yang telah direduksi dapat dikombinasikan dengan mudah.

Namun demikian, algoritma dasar FMLE juga merupakan klasifier yang berbasis piksel per piksel. Oleh karena itu, untuk mengkoreksi kesalahan klasifikasi yang mungkin terjadi dalam tingkat piksel dan untuk mensupport hasil klasifikasi yang lebih homogen, dikaji kemungkinan penyertaan informasi spasial-kontekstual yang disebut dengan *probabilistic relaxation* (Canty, 2006; Reigber *et al.*, 2007). Teknik ini terutama ditujukan untuk mengeksploitasi informasi spasial-kontekstual suatu piksel dengan berdasarkan analisa statistik terbatas dari piksel-piksel yang bertetangga (*local neighborhoods*). Perlu dipertimbangkan di sini, apakah teknik eksploitasi secara mikro informasi spasial-kontekstual tersebut telah mencukupi untuk diterapkan di sini mengingat hasil klasifikasi yang didapatkan dari data SAR biasanya sangat bernoise ("*salt-and-pepper*").

1.6 Lingkup Penelitian

- a) Dalam penelitian ini, serangkaian eksperimen dilakukan untuk menguji keefektifan metode yang diajukan dengan menggunakan data polarimetrik-SAR. Hal-hal berikut ini yang menjadi fokus dalam eksperimen tersebut:

- Pengamatan kemampuan dan keterbatasan masing-masing metode pengestraksian fitur (fitur parameter polarimetrik dan fitur hasil dekomposisi polarimetrik) tersebut dalam mengidentifikasi objek, dan pengamatan bagaimana pengintegrasian fitur dari kedua metode tersebut dapat membantu proses identifikasi dan diskriminasi berbagai tipe tutupan lahan secara lebih baik (pengamatan sifat komplementernya).
- Pengamatan terhadap pengaruh proses pengolahan awal untuk mereduksi noise-noise yang terkandung dari data polarimetrik-SAR. Noise-noise tersebut selain timbul akibat interferensi konstruktif dan destruktif diantara sinyal-sinyal hamburan balik dari berbagai objek (penghambur-balik) secara random dalam suatu sel/area tertentu yang mengakibatkan noise speckle pada kenampakan citra SAR, terdapat pula kontribusi noise yang diakibatkan oleh sistem internal pengakuisisian data oleh sensor SAR itu sendiri. Menurut Woodhouse (2006), beberapa diantaranya adalah:
 - pengaruh ketidakstabilan elemen-elemen antenna pemancarnya (yang berjumlah banyak) untuk dapat memancarkan pulsa gelombang mikro dengan frekuensi dan perbedaan fase yang telah ditentukan;
 - pengaruh performansi elemen-elemen antenna penerimanya untuk dapat memproses dan merekam secara akurat baik amplitudo maupun fase gelombang hamburan baliknya untuk masing-masing kanal polarisasi;
 - pengaruh ketidakstabilan antenna/sensor ketika mengakuisisi data (menganalisis berat dan ukuran antenna SAR yang sangat besar).

Dalam hal ini, walaupun pengolahan awal dengan *speckle-filtering* dapat mereduksi noise speckle tersebut, namun di lain pihak berpotensi menurunkan resolusi spasialnya dan juga mengaburkan (*blur*) batas-batas objek dalam citranya (Lee *et al.*, 1999b; Kersten *et al.*, 2005; Lee *et al.*, 2006; Woodhouse, 2006; Sambodo dan Murni, 2006).

- Pengamatan terhadap pengaruh proses penyeleksian (pereduksian) fitur. Hal ini perlu diamati karena walaupun dimensi fitur input dapat

diturunkan untuk mengurangi redundansi dan kompleksitas klasifikasi, namun di lain pihak berpotensi mengorbankan keakurasian hasil klasifikasi apabila dibandingkan dengan hasil klasifikasi menggunakan fitur-fitur utuhnya.

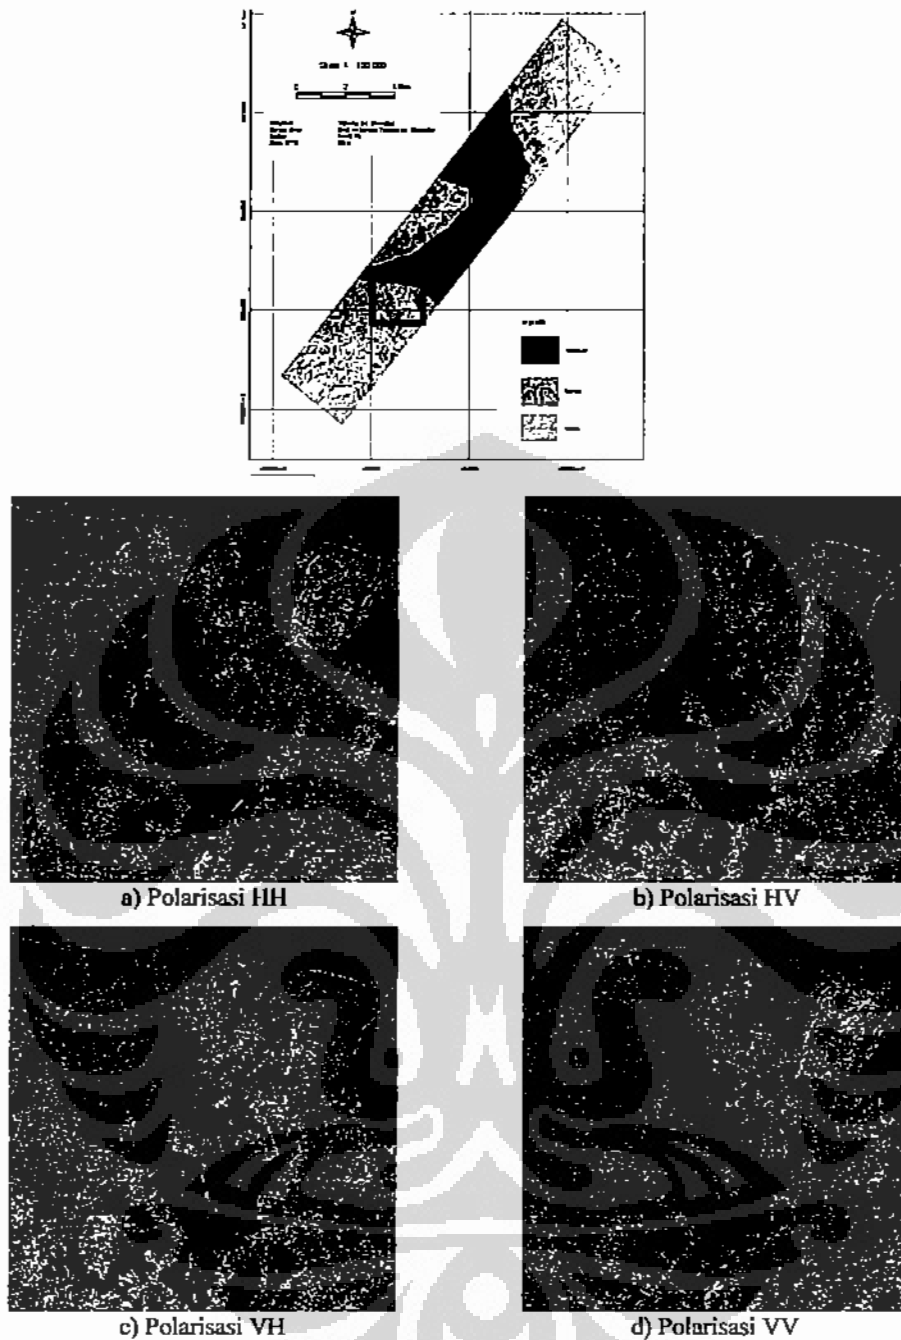
- Pengamatan kemampuan klasifier FMLE dalam mengeksploitasi informasi dari kombinasi fitur-fitur tersebut, termasuk perbandingan performansinya dengan klasifier jenis lain.
 - Pengamatan terhadap pengaruh penyertaan informasi spasial-kontekstual terhadap hasil klasifikasi, termasuk pengaruh pemilihan berbagai parameter yang dipergunakan dalam pengintegrasian informasi spasial-kontekstual tersebut dalam klustering FMLE.
 - Pengamatan kemungkinan dan kesesuaian penerapan metode tersebut khususnya untuk kondisi objek permukaan bumi di daerah tropis seperti di Indonesia yang tentu saja berbeda, seperti dalam hal jenis vegetasi atau tutupan lahannya, kelembaban tanah (*soil moisture*), sifat elektrik, dan lain-lain (Hajsek *et al.*, 2005).
- b) Data yang dipergunakan adalah dua buah data polarimetrik-SAR seperti yang ditunjukkan pada Tabel 1.1. Terdapat perbedaan resolusi spasial keduanya, yakni data E-SAR beresolusi sekitar 3 m dan data ALOS-PALSAR sekitar 30 m. Hal ini juga dapat dipergunakan untuk menguji apakah metodologi yang diajukan bersifat umum tanpa ketergantungan dari resolusi spasial datanya.
- c) Evaluasi akurasi hasil klasifikasi dilakukan baik dengan pengamatan secara visual atas hasil-hasil klasifikasi tersebut maupun dengan penghitungan nilai akurasi hasil klasifikasi. Nilai tersebut dihitung berdasarkan persentase jumlah piksel yang terklasifikasi secara benar oleh klasifier sesuai dengan area sampel yang telah ditentukan seperti yang ditunjukkan pada Gambar 1.3 untuk data polarimetrik pertama. Sedangkan untuk data polarimetrik kedua, karena ketiadaan data lapangan maka hanya dilakukan dengan pengamatan visual terutama dengan membandingkan dengan data referensi yang diakses dari Google Earth seperti yang ditunjukkan pada Gambar 1.6.
- d) Untuk mengamati potensi keunggulan data polarimetrik-SAR dibandingkan dengan data SAR konvensional (yang berpolarisasi tunggal), secara ideal

Tabel 1.1 Data polarimetrik-SAR yang digunakan

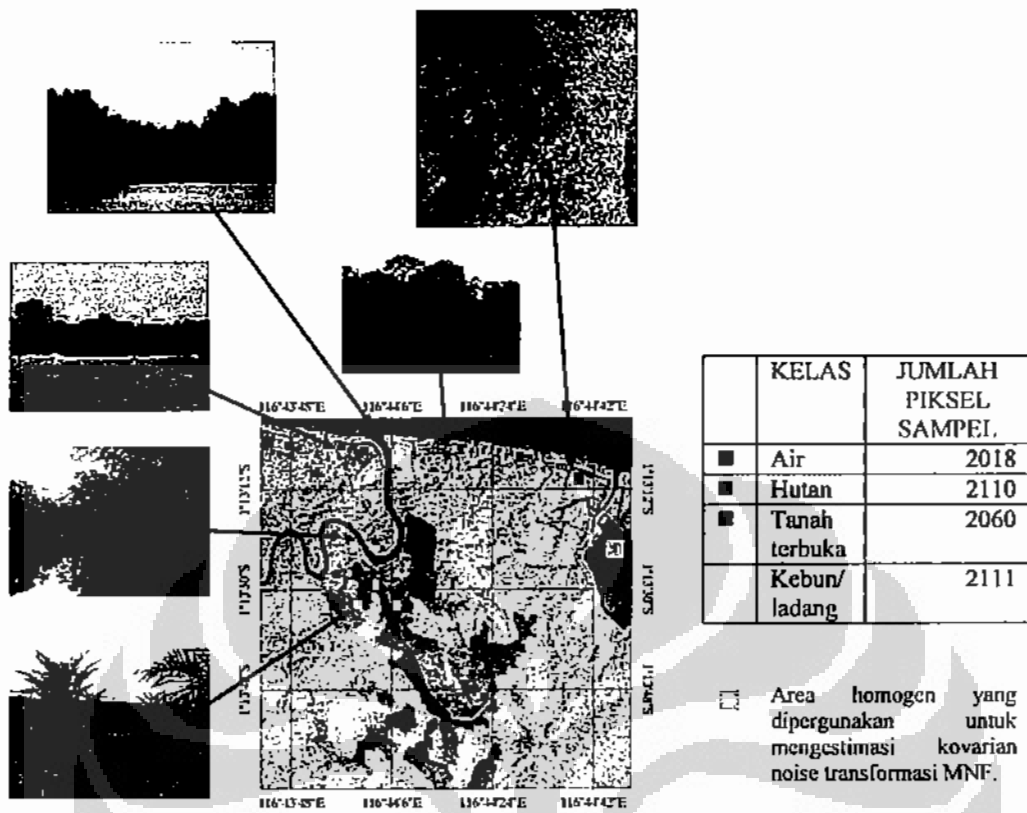
| | Data Polarimetrik 1 | Data Polarimetrik 2 |
|--|---|--|
| Polarisasi | HH, HV, VH, dan VV (Gambar 1.2) | HH, HV, VH, dan VV (Gambar 1.5) |
| Wahana dan Sensor | Airborne E-SAR | Satelit ALOS - PALSAR |
| Kanal | L | L |
| Format Data | <i>Single-look complex</i> (SLC) | <i>Single-look complex</i> (SLC), Level 1.1 |
| Resolusi | 1.99 m (arah range) dan 3.0 m (arah azimuth) | 30 m |
| Tanggal Akuisisi | 17 November 2004 | 10 Maret 2007 |
| Daerah | Penajam, Kalimantan Timur | Kawasan kaki Gunung Semeru, Lumajang, Jawa Timur |
| Kelas-kelas objek tutupan lahan | Hutan, air, tanah terbuka, dan kebun/ladang | Hutan, air, tanah terbuka/sawah, dan kebun/kampung |
| Data/referensi untuk menentukan sampel yang dipakai dalam mengevaluasi akurasi hasil klasifikasi | <ul style="list-style-type: none"> - Data survei lapangan (<i>ground truth data</i>), 26 Juni – 4 Juli 2006, ditunjukkan pada Gambar 1.3 - Data citra optis ASTER, tanggal akuisisi 12 Maret 2006, resolusi 15 m, ditunjukkan pada Gambar 1.4 | <ul style="list-style-type: none"> - Tidak tersedia data survei lapangan - Referensi dari Google Earth, yang diakses tanggal 20 Februari 2009, ditunjukkan pada Gambar 1.6 |

dilakukan dengan membandingkan hasil-hasil klasifikasi menggunakan data satelit SAR lainnya yang berpolarisasi tunggal. Namun demikian, dalam penelitian ini tidak tersedia data tersebut. Sebagai gantinya, dilakukan eksperimen dengan hanya menggunakan salah satu data polarisasi yang merupakan bagian dari data polarimetrik-SAR tersebut. Seperti misalnya, untuk data E-SAR hanya dilakukan dengan menggunakan data polarisasi HH seperti yang ditunjukkan pada Gambar 1.2-a.


- e) Sebelum ujicoba dengan menggunakan data polarimetrik-SAR, dilakukan ujicoba pula dengan menggunakan data citra buatan dengan tujuan: 1) mengujicoba dan menganalisa efektifitas dari metode klustering yang diajukan tersebut dan mengevaluasinya dengan menggunakan informasi



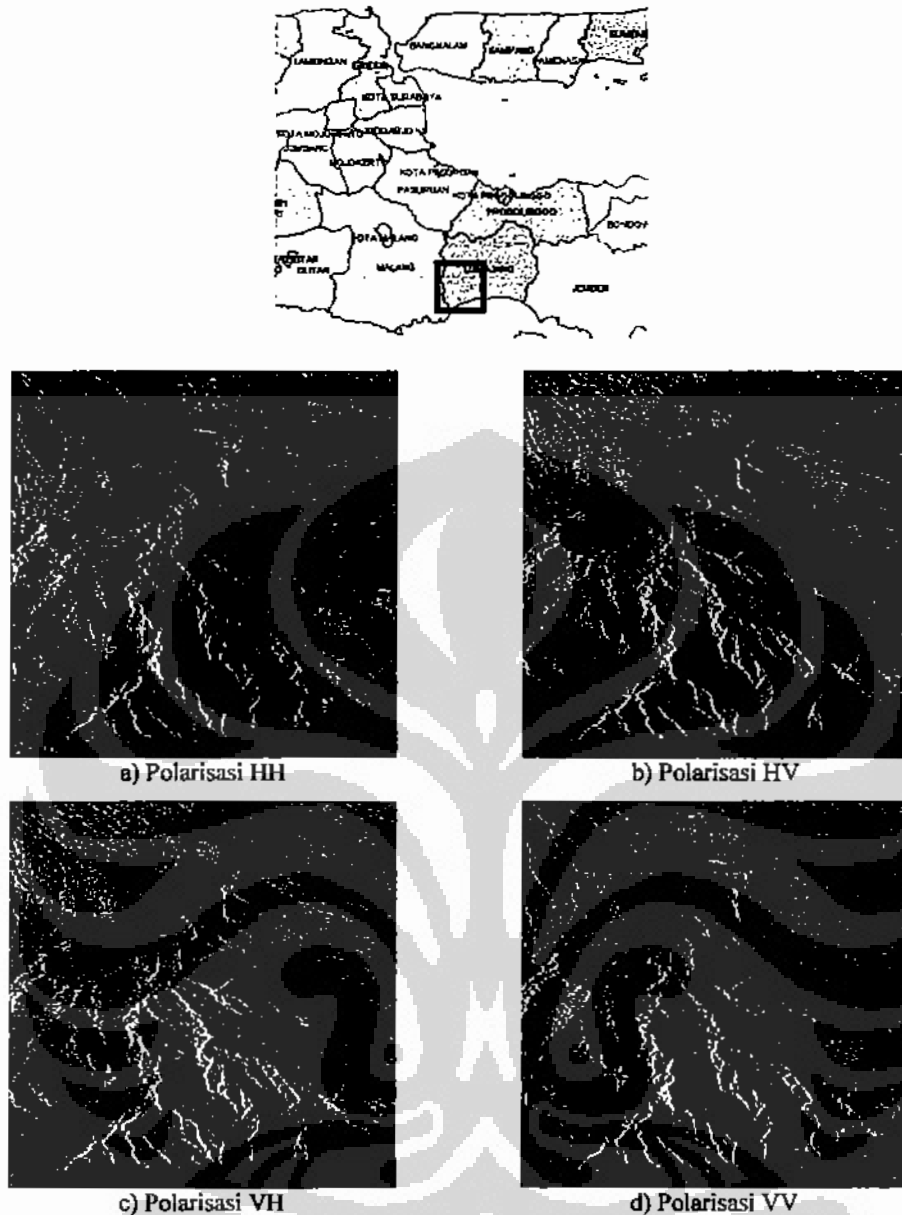
Gambar 1.2 Data polarimetrik pertama yang dipergunakan. (Data E-SAR, kanal L, *Single Look Complex*, daerah Penajam, Kalimantan Timur, Akuisisi: 17 November 2004, resolusi arah range 1.99 m dan arah azimuth 3.0 m, Courtesy: Departemen Kehutanan Republik Indonesia dan European Space Agency/ESA melalui kampanye Radar INDREX II)



Gambar 1.3 Ringkasan hasil survei lapangan di daerah Penajam, Kalimantan Timur yang telah dilaksanakan 26 Juni – 4 Juli 2006. (Gambar citra RGB polarimetrik disusun dengan metode Pauli)




Gambar 1.4 Data sekunder/referensi lain berupa citra optis ASTER untuk daerah Penajam, Kalimantan Timur (tanggal akuisisi 12 Maret 2003, resolusi 15 m)



Gambar 1.5 Data polarimetrik kedua yang dipergunakan. (Data ALOS-PALSAR, kanal L, *Single Look Complex* level 1.1, daerah Lumajang, Jawa Timur, Akuisisi: 10 Maret 2007, resolusi 30 m, Courtesy: RESTEC/JAXA – Japan melalui kerjasama mengenai sistem monitoring aktivitas gunung api menggunakan satelit ALOS)

pengkelasan yang telah diketahui secara pasti; 2) menentukan parameter-parameter yang optimal yang selanjutnya dapat dipakai sebagai acuan pada waktu ujicoba dengan kedua data polarimetrik-SAR yang sesungguhnya.



Gambar 1.6 Data sekunder/referensi lain yang diakses dari Google Earth untuk daerah Lumajang, Jawa Timur yang diakses tanggal 20 Februari 2009. (Gambar citra RGB polarimetrik disusun dengan metode Pauli)

- e) Pengembangan metode dan pengolahan data tersebut dilakukan dengan menggunakan perangkat lunak diantaranya ENVI + IDL Programming (Interactive Data Language), ER-Mapper, Matlab, dan beberapa library open source Radar Tools dan Polsarpro (Lee *et al.*, 1999b; Pottier *et al.*, 2005;

Sambodo, 2006; Sambodo *et al.*, 2006). Sedangkan perangkat keras yang dipergunakan mempunyai spesifikasi Processor Intel Core2 1.86 GHz, RAM 1 GB, HD 500 GB.

1.7 Kontribusi Penelitian

Kontribusi yang dapat diberikan dari penelitian ini, diantaranya adalah:

- a) Penelitian ini mengajukan suatu metodologi alternatif untuk mengekstraksi dan mengklasifikasi data polarimetrik-SAR secara tidak terbimbing (*unsupervised*) yang didasarkan atas tinjauan tiga aspek yang berbeda. Ketiga aspek tersebut adalah tinjauan dari aspek parameter polarimetrik hasil pengukuran sensor SAR secara langsung, aspek fisik berupa informasi polarisasi gelombang hamburan balik radar yang berpotensi membedakan berbagai objek berdasar karakteristik hamburan baliknya, dan aspek spasial-kontekstual berupa informasi keterhubungan antar piksel-piksel yang berdekatan yang membentuk citra polarimetrik-SAR. Pendekatan klasifikasi dengan multi aspek yang dieksploitasi dari data polarimetrik yang sama tersebut merupakan hal yang relatif baru dalam bidang penelitian polarimetrik-SAR. Pendekatan ini lebih menguntungkan karena mampu memberikan peningkatan kemampuan identifikasi dan klasifikasi objek tutupan lahan tanpa perlu adanya tambahan data lain seperti data multi-temporal, data multi-kanal, data citra optis, informasi koherensi interferometrik, dan lain-lain.
- b) Hasil-hasil penelitian ini diharapkan dapat memberikan kontribusi dalam berbagai bidang aplikasi penginderaan jauh di Indonesia, diantaranya adalah:
 - Aplikasi kehutanan, seperti untuk pemantauan area deforestasi akibat pembalakan liar maupun kebakaran hutan, pemetaan berbagai tipe (kelas) hutan maupun untuk keperluan manajemen kehutanan lainnya.
 - Aplikasi pertanian dan perkebunan, seperti untuk pemetaan berbagai tipe (jenis) vegetasi budidayanya, pemantuan kondisi pertumbuhan vegetasi maupun untuk estimasi produksinya.
 - Aplikasi mitigasi bencana alam, seperti untuk pemetaan risiko bahaya bencana, pemetaan dan pemantauan kerusakan akibat bencana seperti

misalnya gempa bumi, tsunami, banjir, longsor, kebakaran hutan, dan lain-lain.

Selain tentunya, diharapkan menjadi pembuka jalan bagi pengenalan teknologi SAR polarimetry dan pemanfaatan data polarimetrik-SAR di Indonesia yang relatif baru (terutama untuk wilayah-wilayah yang hampir selalu diliputi awan dan kabut) dan belum banyak dikenal masyarakat luas dibandingkan dengan data SAR konvensional.

1.8 Sistematika Penulisan

Penulisan disertasi ini dibagi menjadi tujuh bab, dengan perincian sebagai berikut.

BAB 1 : PENDAHULUAN

Bab ini menjelaskan tentang latar belakang, permasalahan terkini terkait dengan ekstraksi dan klasifikasi data polarimetrik-SAR, perumusan permasalahan, tujuan penelitian, ringkasan metodologi penyelesaian masalah yang diusulkan dan kerangka pikirnya, lingkup penelitian, dan ringkasan kontribusi yang didapatkan dari penelitian ini.

BAB 2 : EKSTRAKSI DAN SELEKSI FITUR DARI DATA POLARIMETRIK-SAR

Bab ini membahas tentang landasan teori dan konsep yang terkait dengan pengolahan dan pengekstraksian fitur data polarimetrik-SAR baik itu dari beberapa parameter polarimetrik yang terkait dengan hasil pengukuran sensor SAR secara langsung maupun berdasarkan dekomposisi polarimetrik. Selanjutnya akan dibahas mengenai perlunya suatu skema penyeleksian (pereduksian) fitur yang digunakan untuk mereduksi jumlah fitur dengan menghilangkan informasi yang bersifat redundan dan informasi lainnya yang tidak relevan dari ruang fitur utuh (asal) tersebut sebagai tahap awal proses klasifikasi.

BAB 3 : KLASIFIKASI BERDASARKAN *FUZZY MAXIMUM LIKELIHOOD ESTIMATION CLUSTERING* (FMLE)

Bab ini menjelaskan tentang metode klasifikasi *unsupervised* yang akan diterapkan dalam penelitian ini, yakni dengan klustering *fuzzy maximum likelihood estimation* (FMLE).

BAB 4 : INFORMASI SPASIAL-KONTEKSTUAL

Bab ini menjelaskan tentang metode terkait penghitungan informasi spasial-kontekstual dan pengintegrasian ke dalam hasil-hasil klustering FMLE. Pertama-tama akan dikaji efektifitas penyertaan informasi spasial-kontekstual yang disebut dengan *probabilistic relaxation* terhadap data-data bernoise. Berlandaskan dari hasil ujicoba pendahuluan dengan data citra buatan (yang berkarakteristik mirip dengan citra SAR), dipertimbangkan perlu adanya informasi spasial-kontekstual lain yang mampu lebih memperbaiki kehomogenan hasil klasifikasi terutama pada area-area dalam citra yang homogen. Metode pengeksploitasi informasi spasial-kontekstual tersebut dan kerangka dasar pemikirannya akan dijelaskan pada bagian kedua bab 4 ini.

BAB 5 : METODOLOGI PENYELESAIAN MASALAH

Bab ini menjelaskan tentang metodologi penyelesaian masalah yang diajukan dalam penelitian ini secara detail yang disusun berlandaskan kerangka dasar pemikiran pada bab-bab sebelumnya.

BAB 6 : UJICoba DAN ANALISA HASIL

Bab ini menjelaskan tentang alur ujicoba yang dilakukan untuk menguji efektifitas dari metodologi yang diajukan dalam penelitian ini serta analisa terhadap hasil-hasil yang diperoleh.

BAB 7 : KESIMPULAN DAN SARAN

Bab penutup ini berisi kesimpulan yang diperoleh dari penelitian, kontribusi penelitian, serta saran yang dapat diberikan untuk penelitian selanjutnya.


BAB 2

EKSTRAKSI DAN SELEKSI FITUR DARI DATA POLARIMETRIK-SAR

Pada bab ini akan dijelaskan mengenai landasan teori dan konsep yang menjadi dasar penelitian ini yang diperoleh dari kajian berbagai literatur. Dimulai dengan penjelasan mengenai prinsip dasar dan pemanfaatan data SAR konvensional, prinsip dasar SAR polarimetry dan berbagai representasi datanya. Berikutnya dibahas metode ekstraksi informasi yang dapat dieksploitasi baik dari representasi dasar data polarimetrik-SAR tersebut maupun berdasarkan suatu pemodelan hamburan balik sinyal radar (dekomposisi polarimetrik) beserta keterbatasan-keterbatasannya dalam mengidentifikasi dan mengklasifikasi objek tutupan lahan. Walaupun dari beberapa metode ekstraksi fitur tersebut dapat diperoleh fitur yang berjumlah banyak, terdapat kemungkinan bahwa dalam fitur-fitur tersebut terkandung informasi yang bersifat redundan maupun yang tidak relevan. Oleh karena itu, suatu skema penyeleksian (pereduksian) fitur diperlukan untuk menurunkan jumlah fitur dengan menghilangkan informasi yang bersifat redundan dan informasi lainnya yang tidak relevan tersebut dari ruang fitur utuh (asal) sebagai tahap awal proses klasifikasi. Untuk tujuan tersebut, penelitian ini akan mengkaji penerapan transformasi *maximum noise fraction* (MNF) seperti yang akan dijelaskan pada bagian akhir bab ini.

2.1 Prinsip Dasar dan Pemanfaatan Data SAR Konvensional (*Single-Channel Single-Polarisation SAR*)

Instrumen SAR, seperti yang ditunjukkan pada Gambar 2.1, akan mengirimkan pulsa-pulsa gelombang mikro secara berulang ke arah area (target) di permukaan bumi yang akan dicitrakan. Masing-masing gelombang mikro tersebut dapat dideskripsikan dengan *amplitude* dan *phase*. Ketika mengenai permukaan bumi, energi gelombang mikro tersebut akan dihamburkan ke berbagai arah. Sebagian dari energi tersebut akan dihamburbalikkan ke antena penerima (*backscattered energy*), dan kemudian direkam untuk diproses lebih lanjut membentuk piksel-piksel dalam citra SAR. Semakin kuat hamburan balik dari



Gambar 2.1 Penginderaan jauh sistem *Synthetic Aperture Radar* (SAR).
(Sumber: Woodhouse, 2006)

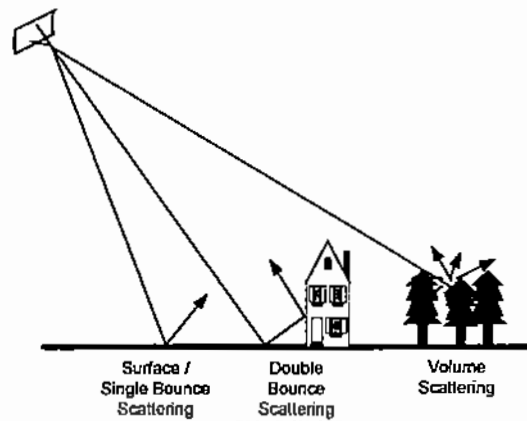
suatu area target, maka semakin terang (*bright*) piksel yang berkorelasi dalam citranya. Tingkat hamburan balik tersebut ditentukan diantaranya oleh berbagai kondisi target permukaan buminya (seperti bentuk fisik dan orientasi objek, tingkat kekasaran permukaan, dan sifat listrik targetnya) dan juga oleh parameter-parameter yang dipakai dalam sistem radar tersebut. Hubungan antara energi (power) yang diterima dengan parameter target dan dengan parameter radar lainnya dapat dijelaskan dengan persamaan radar (*radar equation*) berikut:

$$P_r = \frac{P_t \lambda G_t(\gamma) G_r(\gamma)}{(4\pi)^3 R^4} \sigma^0 A \quad (2.1)$$

dimana P_t adalah power yang dipancarkan dari antenna, λ adalah panjang gelombang yang dipancarkan, R adalah jarak dari antenna ke target, γ adalah sudut look radar (*radar look angle*), A adalah luas area efektif pada permukaan

bumi (*ground*) penghasil scattering tersebut, G_t dan G_r adalah *gain* antenna pemancar dan penerima (menjelaskan kemampuan sistem untuk memfokuskan pemancaran energi gelombang mikro) pada sudut look γ , dan σ^0 adalah koefisien hamburan balik radar (*radar backscattered coefficient*). Seluruh parameter pada Rumus (2.1) mempengaruhi power yang diterima oleh antenna P_r , namun hanya σ^0 yang berkaitan erat dengan sifat-sifat (properti) permukaan yang disinarnya (Tso and Matter, 2001). Pada sebagian besar format data citra radar, terkadang nilai digital (*digital number*) yang terkandung dalam citranya telah dikuantisasi (misalnya dikuantisasi 8 bit menjadi nilai 0-255) setelah melalui beberapa proses kalibrasi. Oleh karenanya, nilai digital tersebut perlu dikonversikan ke σ^0 terlebih dahulu sebelum dilakukan interpretasi maupun klasifikasi lebih lanjut (formula dan faktor konversi biasanya disertakan pada data tersebut, dan berbeda-beda sesuai dengan tingkat pemrosesan/*processing level* dari data tersebut).

Ekstraksi informasi dari citra SAR menjadi berbagai informasi tutupan lahan dapat dilakukan dengan menganalisa koefisien hamburan balik tersebut. Terkait dengan tingkat kekasaran permukaan (*surface roughness*), semakin kasar permukaan maka semakin tinggi hamburan baliknya (semakin terang piksel citranya). Lebih jauh, tingkat kekasaran permukaan tersebut tergantung dari panjang gelombang radar dan sudut datang sinyal (*incidence angle*). Secara umum, suatu permukaan dikategorikan permukaan rata (*smooth surface*) apabila variasi ketinggian pada daerah yang diamati jauh lebih kecil daripada gelombang radar yang dipakai. Dan ketika variasi ketinggian tersebut mendekati panjang gelombangnya, permukaan tersebut akan mulai nampak "kasar" ("*rough*"). Oleh karenanya, pada suatu permukaan tertentu akan nampak semakin kasar apabila panjang gelombang radar yang dipakai semakin pendek, dan sebaliknya akan semakin nampak rata apabila panjang gelombangnya bertambah panjang. Permukaan yang rata akan menyebabkan pemantulan (*specular-reflection/single-bounce*) energi datangnya (yang pada umumnya menjauhi sensor) dan menyebabkan energi hamburan baliknya kecil (piksel dalam citranya menjadi gelap). Sedangkan, pada permukaan yang kasar energi datangnya akan dihamburkan hampir sama rata ke segala arah (*diffusely*) dan sebagian energinya



Gambar 2.2 Sketsa beberapa tipe/mekanisme hamburan balik sinyal radar (*backscattering mechanisms*). (Sumber: Tso and Matter, 2001)

akan balik ke sensor radar (piksel dalam citranya nampak lebih terang). Kuat lemahnya hamburan balik juga dipengaruhi oleh sudut datang sinyal. Pada suatu kondisi kekasaran tertentu dan panjang gelombang tertentu, apabila sudut datangnya semakin besar, energi hamburan balik menjadi lebih lemah dan permukaan tersebut akan nampak lebih rata. Beberapa objek di permukaan bumi bersifat seperti pemantul sudut (*corner reflector*), sehingga akan menyebabkan energi hamburan balik yang tinggi pada sensor, dan menyebabkan piksel-piksel terang dalam citra radar. Fenomena tersebut sering terjadi pada area urban karena energi datangnya akan dipantulkan secara ganda (*double-bounce*) oleh sudut-sudut yang ada di bangunan tersebut (Gambar 2.2). Sedangkan pada area bervegetasi atau area hutan (dimana biasanya terdiri atas kanopi daun, ranting, dan batang pohon), energi datangnya akan mampu menembus ke bawah kanopi tergantung dari panjang gelombangnya, dan akan menimbulkan *volume scattering*. *Volume scattering* merupakan proses hamburan balik dari energi radar dalam suatu volume atau medium, dan biasanya terdiri atas pantulan/refleksi berganda (*multiple-bounce*) dari komponen-komponen yang berbeda-beda (baik bentuk, ukuran, maupun orientasinya) dalam volume tersebut. *Volume scattering* dapat menimbulkan peningkatan atau penurunan tingkat terang piksel dalam citra tergantung dari banyak sedikitnya energi yang dihamburkan keluar dari volume tersebut dan diterima kembali oleh sensor radar.

Frekuensi atau panjang gelombang dari gelombang mikro yang menyertai juga memainkan peranan penting dalam interaksi dengan permukaan bumi. Beberapa kanal yang dipakai dalam sensor SAR saat ini adalah kanal X (frekuensi f 8-12 GHz atau panjang gelombang λ 2.5-3.8 cm), kanal C (f 4-8 GHz atau λ 3.8-7.5 cm), kanal S (f 2-4 GHz atau λ 7.5-15 cm), kanal L (f 1-2 GHz atau λ 15-30 cm), dan kanal P (f 0.3-1 GHz atau λ 30-100 cm). Parameter yang berkaitan dengan panjang gelombang radar bervariasi seperti kekasaran permukaan dan kelembaban. Pemilihan panjang gelombang tertentu juga menentukan tingkatan penetrasi tipe liputan permukaan yang berbeda-beda. Untuk material kebanyakan, kedalaman penetrasi berubah-ubah secara linear dengan panjang gelombang yang digunakan. Seperti misalnya pada area hutan, pada panjang gelombang yang lebih pendek maka proses hamburan balik akan lebih didominasi oleh interaksi gelombang radar dengan ujung kanopi vegetasinya saja. Sedangkan pada gelombang yang lebih panjang akan menyebabkan interaksi yang signifikan diantara ujung kanopi dengan bagian dasar vegetasinya sehingga lebih potensial memberikan informasi volume vegetasinya. Namun demikian, terdapat untung rugi yang musti dipertimbangkan dan disesuaikan dengan aplikasi yang diharapkan, karena semakin besar panjang gelombang yang dipakai semakin besar ukuran antena radar yang diperlukan dan semakin besar konsumsi power yang dibutuhkan (Woodhouse, 2006).

Sifat listrik dari objek yang disinari juga akan mempengaruhi energi hamburan baliknya. Objek yang berkonduktifitas tinggi akan cenderung mempunyai tingkat reflektifitas yang tinggi dibandingkan dengan objek yang berkonduktifitas rendah. Logam dan air merupakan contoh suatu konduktor yang bagus, oleh karenanya hamburan balik radar akan lebih sensitif pada objek-objek logam (seperti rel kereta, jembatan) dan pada tingkat kelembaban objek yang disinarinya, walaupun mungkin kandungan uap air dalam objek tersebut kecil. Hal ini dapat terlihat pada citra SAR yang akan nampak lebih terang apabila menyinari tanah atau area bervegetasi yang kondisinya lembab (basah) dibandingkan dengan yang kondisinya kering.

Salah satu karakteristik citra SAR adalah timbulnya noise/tekstur "*salt-and-pepper*" yang terdistribusi secara random dalam citranya. Noise tersebut

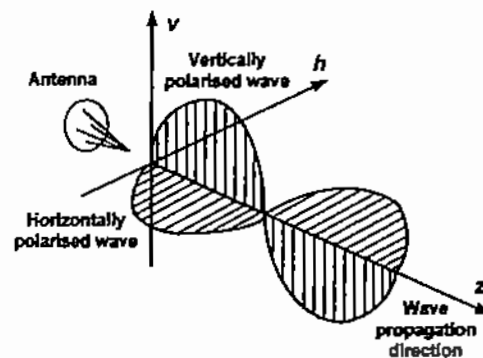
timbul akibat interferensi konstruktif dan destruktif diantara sinyal-sinyal hamburan balik dari berbagai objek (penghamburbalik) secara random dalam suatu sel/area tertentu (*resolution cell*) yang disinarnya. Walaupun noise ini dapat direduksi dengan proses *speckle-filtering* namun masih tetap menyisakan beberapa permasalahan (seperti turunnya resolusi spasial, mengaburkan atau *blurring* batas-batas objek dalam citranya, berubahnya parameter statistik atas datanya secara signifikan) sehingga sedikit banyak mempersulit proses ekstraksi (analisa) informasi hamburan balik berbagai objek yang terkandung di dalam suatu sel/area tersebut (Lee *et al.*, 1999b; Woodhouse, 2006).

Di samping untuk keperluan pencitraan, informasi *phase* yang diturunkan dari data SAR juga dapat dipergunakan dalam aplikasi interferometrik-SAR (*SAR interferometry*) untuk mendapatkan data ketinggian atau DEM (Digital Elevation Model). Proses penurunan data tersebut membutuhkan penghitungan perbedaan *phase* dari dua buah data SAR (dalam format kompleks) yang diakuisisi dengan posisi sensor yang berbeda (Woodhouse, 2006). Pembahasan detail mengenai proses tersebut tidak akan dibahas pada penelitian ini, karena domain atau penggunaan aplikasi tersebut yang berbeda dengan aplikasi pencitraan. Namun, pada beberapa penelitian terkini dikaji potensi penggunaan informasi tersebut untuk membantu pendiskriminasian dan pengklasifikasian berbagai tutupan lahan (Santoro, 2003; Ferro-Famil *et al.*, 2005; Lee *et al.*, 2005).

2.2 Prinsip Dasar SAR Polarimetry dan Keuntungannya

SAR polarimetry merupakan perkembangan utama dari pencitraan SAR kanal tunggal konvensional yang menambahkan sifat polarisasi dari suatu gelombang elektromagnetik dalam rangka memperkaya parameter hasil pengukuran sensor radar.


Pada umumnya, energi gelombang mikro yang dipancarkan dan diterima oleh antena radar dapat merambat ke segala arah yang tegak lurus dengan arah rambatan gelombangnya. Namun demikian, pada sebagian besar sistem SAR saat ini mempolarisasikan gelombang mikro tersebut sedemikian rupa sehingga gelombang yang dipancarkan dan diterima terbatas pada suatu bidang tertentu yang tegak lurus dengan arah rambatan gelombang tersebut seperti yang



Gambar 2.3 Gelombang mikro yang terpolarisasi.
(Sumber: Tso and Matter, 2001)

ditunjukkan pada Gambar 2.3 (Tso and Matter, 2001; Woodhouse, 2006). Dengan demikian, gelombang yang terpolarisasi tersebut dapat dipancarkan dan diterima baik dalam arah bidang horisontal (H) maupun arah bidang vertikal (V).

Salah satu keuntungan utama dari SAR polarimetri adalah teknik ini memungkinkan untuk membedakan beberapa tipe/mekanisme hamburan balik yang berbeda-beda. Hal ini dikarenakan pola polarimetrik (*polarimetric signatures*) hasil pengamatan sangat tergantung dari proses hamburan balik secara aktualnya dari berbagai objek di permukaan bumi (Tso and Matter, 2001; Woodhouse, 2006). Untuk memberikan ilustrasi efek dari polarisasi, misalkan pada model sederhana yang bentuk fisiknya dominan bersifat vertikal seperti pada Gambar 2.4 (seperti misalnya pada vegetasi tanaman gandum, padi pada fase awal pertumbuhan). Objek penghambur balik tersebut dapat kita asumsikan berlaku seperti dipol-dipol pendek vertikal (*short vertical dipoles*), sehingga energi gelombang mikro yang terpolarisasi secara horisontal yang mengenainya tidak banyak berinteraksi dengan kanopi tersebut dan akan diteruskan ke permukaan tanah di bawahnya. Sebaliknya, energi gelombang mikro yang terpolarisasi secara vertikal akan berinteraksi secara kuat dengan dipol-dipol tersebut sehingga mengakibatkan energi hamburan balik pada polarisasi tersebut kuat dibandingkan dengan yang horisontalnya. Sedangkan pada objek/vegetasi yang berbeda (misalnya yang cenderung mempunyai daun lebar dan berkanopi lebar), berpotensi menimbulkan efek depolarisasi. Arah polarisasi pada gelombang hamburan baliknya akan termodifikasi sedemikian rupa sehingga



Gambar 2.4 Contoh ilustrasi efek polarisasi pada objek berbentuk dipol-dipol pendek. (Sumber: Woodhouse, 2006)

merupakan kombinasi dari komponen vertikal dan komponen horisontal. Dengan demikian semakin lengkap kombinasi polarisasi yang diterapkan (diukur) dalam radar akan memberikan informasi yang lebih banyak mengenai objek yang disinarnya.

Apabila dibandingkan dengan data SAR kanal tunggal konvensional, maka penyertaan informasi polarimetrik akan membantu menurunkan ambiguitas problem hamburan balik dalam suatu sel/area tertentu (*resolution cell*) sehingga memberikan perbaikan yang signifikan dalam hal kualitas hasil ekstraksi maupun hasil klasifikasinya (Fransson, 1999; Woodhouse, 2006). Beberapa pemodelan hamburan balik polarimetrik tertentu (Cloude and Pottier, 1997) berpotensi memberikan interpretasi fisik secara langsung dari proses hamburan baliknya, sehingga memungkinkan untuk mengestimasi parameter-parameter fisik permukaan seperti kandungan air tanah (*soil moisture*) dan kekasaran permukaan (Hajnsek, 2001). Beberapa metode klasifikasi tak terbimbing mencoba mengidentifikasi secara otomatis (tanpa ketergantungan data lapangan) berbagai karakteristik hamburan balik dari objek/target yang berbeda-beda (Cloude and Pottier, 1997; Freeman and Durden, 1998).

2.3 Representasi Dasar Data Polarimetrik-SAR dan Pengekstraksian Fitur Parameter Polarimetrik

Apabila gelombang mikro yang terpolarisasi secara horisontal dipancarkan dan mengenai suatu target, gelombang hamburan baliknya dapat terdiri atas

komponen yang terpolarisasi secara horisontal maupun vertikal. Hal yang sama berlaku pula untuk gelombang mikro yang dipancarkan secara terpolarisasi vertikal. Salah satu cara untuk merepresentasikan sifat hamburan balik suatu target dari komponen-komponen gelombang tersebut secara lengkap adalah dengan matriks scattering (*scattering matrix*) S sebagai berikut:

$$S = \begin{bmatrix} s_{HH} & s_{HV} \\ s_{VH} & s_{VV} \end{bmatrix} \quad (2.2)$$

dimana elemen s_{HV} adalah bilangan kompleks yang diperoleh dari pengukuran *amplitude* dan *phase* dari gelombang pancar (*transmit*) terpolarisasi secara horisontal (H) dan gelombang terima (*receive*) terpolarisasi secara vertikal (V). Ketiga elemen lainnya diperoleh dengan cara yang serupa. Pengukuran dengan polarisasi yang sama baik gelombang pancar maupun terima (yakni HH dan VV) disebut dengan *co-polarised* (atau disingkat *co-pol*), dan apabila berbeda (yakni HV dan VH) disebut dengan *cross-polarised* (atau disingkat *cross-pol*).

Pada *monostatic radar* (dimana antena penerima berada pada lokasi yang sama dengan antena pemancar gelombang radar), berlaku prinsip *reciprocity*, yang berarti $s_{HV} = s_{VH}$, sehingga matriks scattering ini bersifat simetri dan hanya terdiri atas 3 elemen yang independen. Karena hanya terdiri atas tiga pengukuran (elemen) yang efektif dalam sistem *fully polarimetric* tersebut, sehingga terkadang lebih disukai pendefinisian menggunakan vektor target (*target vector*) k sebagai berikut:

$$k = [s_{HH} \quad \sqrt{2}s_{HV} \quad s_{VV}]^T \quad (2.3)$$

dimana "T" menunjukkan *transpose* dan $\sqrt{2}$ dalam s_{HV} dipakai untuk menjaga konsistensi dalam perhitungan span (*total power*). Vektor target k yang sering disebut dengan vektor target berbasis *lexicographic* ini merupakan cara penyusunan vektor target yang langsung terkait dengan sistem pengukuran radar (*system measurable*). Selain itu, terdapat alternatif metode penyusunan serupa berdasar basis "Pauli", dimana vektor target k_p disusun dengan penjumlahan dan pengurangan (perbedaan) kanal *co-pol*, dan kanal *cross-pol*nya sebagai berikut:

$$\mathbf{k}_p = \frac{1}{\sqrt{2}} [s_{HH} + s_{VV} \quad s_{HH} - s_{VV} \quad 2s_{HV}]^T \quad (2.4)$$

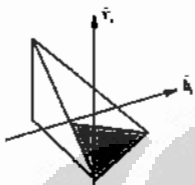
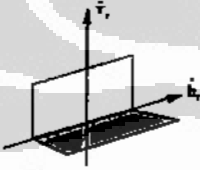
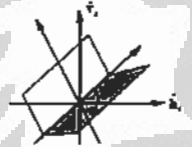
Dalam banyak aplikasi, vektor target Pauli \mathbf{k}_p ini lebih banyak dipakai karena terdapat kaitan erat dengan sifat fisik hamburan balik gelombang. Seperti yang diilustrasikan pada Tabel 2.1, elemen-elemen target vektor Pauli dapat mengindikasikan tipe/mekanisme hamburan balik objek yang berbeda-beda (*odd-bounce*, *even-bounce*, *volume scattering*). Dan hasil perhitungan energi hamburan baliknya (*scattered power*) dapat dipergunakan untuk menyusun citra RGB (dengan mengkorespondensikan $|P_r|^2$, $|P_g|^2$, dan $|P_b|^2$ masing-masing dengan kanal *Blue*, kanal *Red*, dan kanal *Green*) yang selanjutnya dapat dipakai untuk menginterpretasikan informasi secara kualitatif maupun tujuan interpretasi visual (Lee et al., 1999; Hellmann, 2001; Reigber; 2001; Pottier et al., 2005).

Dari beberapa vektor target tersebut, beberapa jenis matriks lainnya dapat didefinisikan untuk mengkarakterisasikan hubungan (keterkaitan) antar kanal-kanal polarimetriknya. Salah satunya adalah matriks kovarian polarimetrik (*polarimetric covariance matrix*) \mathbf{C} yang disusun melalui perkalian vektor target \mathbf{k} dan *complex conjugate transposenya*:

$$\mathbf{C} = \mathbf{k} \mathbf{k}^T = \begin{bmatrix} s_{HH} \\ \sqrt{2}s_{HV} \\ s_{VV} \end{bmatrix} \begin{bmatrix} s_{HH}^* & \sqrt{2}s_{HV}^* & s_{VV}^* \end{bmatrix} = \begin{bmatrix} |s_{HH}|^2 & \sqrt{2}s_{HH}s_{HV}^* & s_{HH}s_{VV}^* \\ \sqrt{2}s_{HV}s_{HH}^* & 2|s_{HV}|^2 & \sqrt{2}s_{HV}s_{VV}^* \\ s_{VV}s_{HH}^* & \sqrt{2}s_{VV}s_{HV}^* & |s_{VV}|^2 \end{bmatrix} \quad (2.5)$$

Pada beberapa penelitian, dikaji metode klasifikasi dengan menggunakan format matriks kovarian polarimetrik \mathbf{C} ini langsung sebagai inputnya. Pada umumnya, mereka mengasumsikan bahwa distribusi probabilitas masing-masing kelas dari representasi matriks kovarian polarimetrik tersebut mengikuti *complex Wishart distribution*. Beberapa contohnya adalah klasifikasi (klustering) seperti dengan ISODATA, *fuzzy c-mean method* (Du and Lee, 1996), *Wishart classifier* (Lee et al, 1999a), *expectation method* (Davidson et al., 2002), *hierarchical segmentation* (Beaulieu and Touzi, 2004). Pendekatan-pendekatan tersebut memiliki keterbatasan diantaranya adalah bahwa format matriks kovarian berukuran 3x3 tersebut berisi elemen-elemen kompleks sebagai suatu kesatuan, sehingga data tambahan seperti dari sumber data yang berformat (tipe data)

Tabel 2.1 *Pauli basis matrices* dan mekanisme hamburan balik yang diasosiasikannya. (Sumber: Hellmann, 2001)

| <i>Pauli basis matrix</i> dan vektor targetnya | Model penghambur balik (<i>scatterer</i>) | Energi hamburan bali (<i>scattered power</i>) | Mekanisme hamburan balik yang diasosiasikan | Keterangan |
|---|---|---|--|--|
| $\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$ $\mathbf{k}_p = \sqrt{2} \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}$ | Flat surface, sphere, trihedral corner reflector  | $ P_s ^2$ dimana $P_s = \frac{s_{HH} + s_{VV}}{\sqrt{2}}$ | <i>Single- or odd-bounce scattering</i> | Trihedral corner reflector sering dipergunakan untuk mengkalibrasi sistem radar ketika akuisisi. (Kedua polarisasinya tidak berubah) |
| $\begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$ $\mathbf{k}_p = \sqrt{2} \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix}$ | Dihedral (oriented in the horizontal axis)  | $ P_d ^2$ dimana $P_d = \frac{s_{HH} - s_{VV}}{\sqrt{2}}$ | <i>Double- or even-bounce scattering</i> | Polarisasi dari gelombang baliknya dipantulkan (dirubah arahnya) hanya pada salah satu arah polarisasi gelombang datangnya. |
| $\begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$ $\mathbf{k}_p = \sqrt{2} \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}$ | 45° tilted dihedral (oriented with an angle θ)  | $ P_v ^2$ dimana $P_v = \sqrt{2} s_{HV}$ | <i>Even-bounce 45° tilted</i> (Contohnya untuk target yang bersifat <i>volume scattering</i>) | Target akan memantulkan gelombang terpolarisasi yang ortogonal terhadap arah polarisasi pada gelombang datangnya. |

berbeda tidak dapat dimasukkan ke dalam format input matriks kovarian polarimetrik tersebut. Padahal data (fitur) tambahan baik dari sumber data yang berbeda (seperti data multi-temporal, data multi frekuensi, data citra sensor optis, dan lain-lain) maupun yang diekstraksi dari data yang sama dengan tinjauan yang berbeda (seperti yang dikaji pada penelitian ini) sangat dibutuhkan untuk meningkatkan performansi hasil identifikasi dan klasifikasinya.

Untuk mengatasi hal tersebut, pada penelitian ini dikaji suatu alternatif lain dengan cara menggunakan masing-masing elemen yang terkandung dalam matriks

kovarian tersebut. Matriks kovarian C ini adalah matriks Hermitian 3×3 (berarti merupakan matriks bujur sangkar, *conjugate symmetry*, memiliki *real eigenvalue*) sehingga berarti hanya terdapat 6 elemen yang independen, yakni 3 elemen riil pada diagonal utama dan 3 elemen kompleks pada bagian atas (atau bawah) diagonal utamanya. Tiga elemen riil pada diagonal utama masing-masing menyatakan *intensity (power)* dari masing-masing elemen (kanal) vektor target yang membentuknya. Seperti misalnya elemen c_{11} akan menyatakan power dari kanal polarimetrik HH. Penjumlahan ketiga elemen diagonal dari matriks kovarian C , yakni:

$$SPAN = |s_{HH}|^2 + 2|s_{HV}|^2 + |s_{VV}|^2 \quad (2.6)$$

disebut dengan *span* (atau *total power*) yang menyatakan jumlah power total yang diterima pada keempat kanal polarimetrik sistem radar tersebut. Terkait dengan kenampakannya sebagai citra, parameter power (intensitas) HH, HV, dan VV merupakan fitur parameter yang paling jelas untuk dapat mendiskriminasi objek tutupan lahan yang berbeda-beda. Sebagai gambaran umum, intensitas VV akan menunjukkan nilai yang tinggi pada objek-objek yang struktur fisiknya didominasi oleh dipol-dipol pendek vertikal (*short vertical dipoles*, seperti misalnya pada vegetasi tanaman gandum, padi pada fase awal pertumbuhan). Di lain pihak, intensitas HH lebih sensitif pada objek yang relatif datar (seperti misalnya pada tanaman kentang, vegetasi berdaun datar lainnya). Pada area hutan, efek depolarisasi (berubahnya arah polarisasi pada gelombang hamburan baliknya) cenderung semakin meningkat, sehingga apabila dikombinasikan dengan penggunaan panjang gelombang SAR yang lebih panjang, maka intensitas HV yang didapatkan berpotensi dalam membedakan kondisi vegetasi maupun tingkatan biomasa area hutan yang berbeda-beda (Ferrazzoli *et al.*, 1997; Quegan *et al.*, 2003; Woodhouse, 2006).

Selanjutnya, tiga elemen kompleks lainnya pada bagian *off-diagonal* merepresentasikan koherensi kompleks antar kanal polarimetriknya (*interchannel polarimetric coherence*). Dalam konteks gelombang elektromagnetik, koherensi dapat dipergunakan sebagai parameter untuk mengukur kesamaan (*similarity*) antar dua gelombang yang diperoleh dengan mengalikan representasi kompleks


gelombang pertama dengan konjugasi kompleks (*complex conjugate*) gelombang kedua. Seperti misalnya pada elemen c_{1j} akan diperoleh:

$$s_{HH} s_{VV}^* = s_{0HH} e^{j\phi_{HH}} s_{0VV} e^{-j\phi_{VV}} = s_{0HH} s_{0VV} e^{j(\phi_{HH} - \phi_{VV})} \quad (2.7)$$

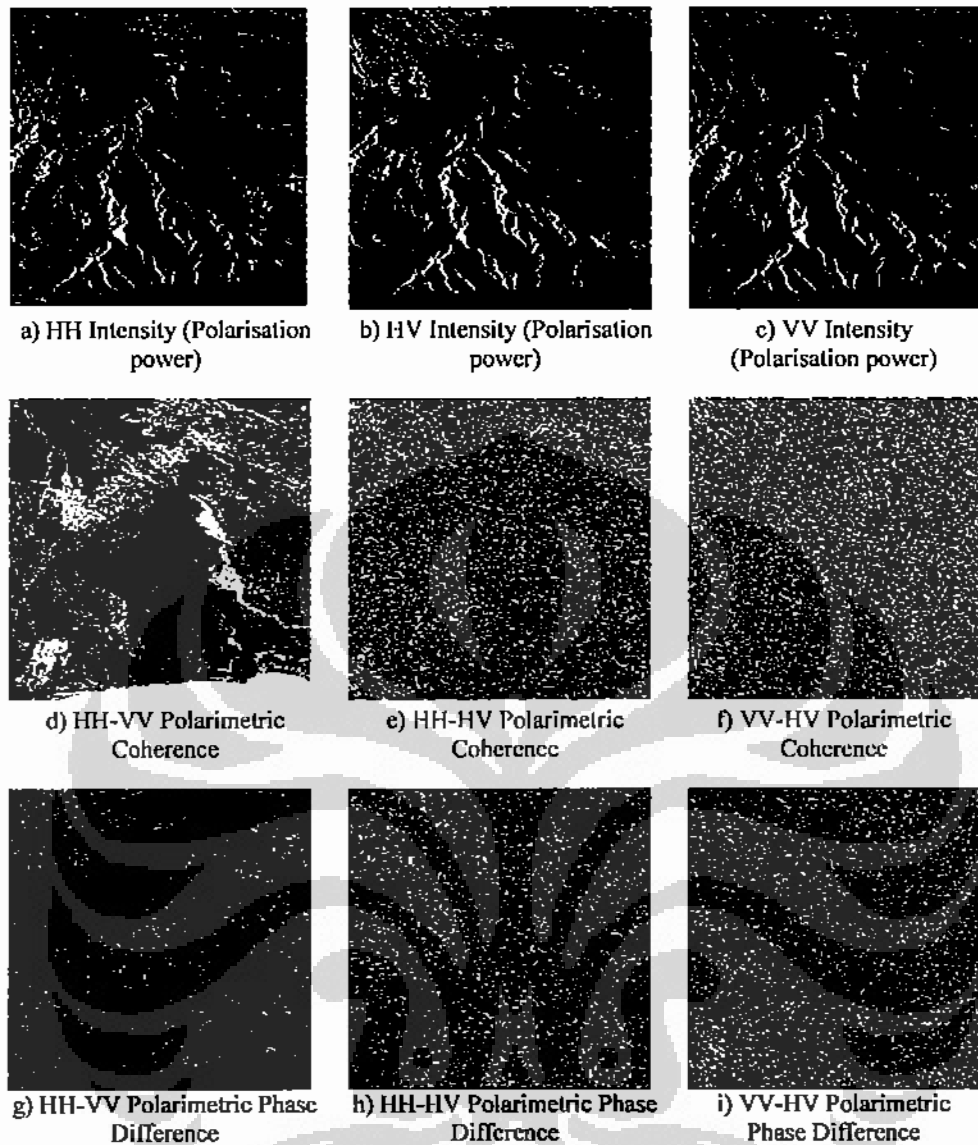
dimana s_{0HH} , s_{0VV} masing-masing merupakan *amplitude* pada kanal HH dan VV, sedangkan ϕ_{HH} , ϕ_{VV} masing-masing merupakan *phase* kanal HH dan VV. Nilai riil $s_{0HH} s_{0VV}$ akan menyatakan modulus koherensi kompleks antar kanal HH dan VV, sedangkan $(\phi_{HH} - \phi_{VV})$ merupakan perbedaan fase (*phase difference*) diantara kedua kanal tersebut. Nilai modulus $s_{0HH} s_{0VV}$ dapat bervariasi sesuai dengan perubahan nilai *amplitude* kedua kanal HH dan VV. Sedangkan untuk menyatakan tingkatan koherensinya (*degree of coherence*) dipergunakan nilai normalisasi dari Rumus (2.7) menjadi bernilai 0~1 (yakni $\gamma_{HH, VV} = \langle s_{HH} s_{VV}^* \rangle / \sqrt{\langle |s_{HH}|^2 \rangle \langle |s_{VV}|^2 \rangle}$). Semakin tinggi nilai $|\gamma|$ maka berarti kedua kanal tersebut saling berkorelasi satu sama lain. Demikian sebaliknya, semakin rendah nilainya berarti kedua kanal tersebut semakin tidak berkorelasi atau tidak koheren (*incoherent*). Tinggi rendah nilai tingkat koherensi tersebut tergantung dari jenis objek di permukaan bumi yang disinari gelombang radar tersebut, sehingga parameter tersebut berpotensi dipergunakan dalam klasifikasi objek tutupan lahan. Di samping itu, perbedaan fase antar kanalnya juga telah banyak dikaji sebagai parameter yang dapat membedakan mekanisme hamburan balik objek yang berbeda-beda (Hoekman, 2003; Woodhouse, 2006). Terutama perbedaan fase antar kanal HH dan VV sebelumnya telah dikaji sebagai pembeda mekanisme hamburan balik, dimana pada kisaran 0° diinterpretasikan sebagai *single-bounce*, kisaran 180° sebagai *double-bounce*, dan nilai diantara keduanya sebagai *multiple-scattering*. Namun, dalam penelitian selanjutnya didapatkan bahwa interpretasi tersebut tidak selalu dapat diaplikasikan (banyak mengandung ketidakpastian), berbeda dengan hasil dekomposisi polarimetrik yang akan dijelaskan pada sub-bab berikut.

Pada Gambar 2.5 ditunjukkan 9 parameter yang diekstraksi dari elemen-elemen matriks kovarian tersebut menggunakan data polarimetrik E-SAR daerah Penajam, Kalimantan Timur (seperti yang telah ditunjukkan pada Gambar 1.2). Sedangkan pada Gambar 2.6 ditunjukkan hasil ekstraksi untuk data polarimetrik

ALOS-PALSAR daerah Lumajang, Jawa Timur (seperti yang telah ditunjukkan pada Gambar 1.5). Dari hasil ekstraksi kedua data polarimetrik tersebut terlihat bahwa power (intensitas) dari masing-masing kanal polarisasi, yakni intensitas HH, HV, dan VV, merupakan fitur-fitur yang paling jelas untuk dapat mendiskriminasikan objek tutupan lahan yang berbeda-beda. Khususnya untuk membedakan area-area berdasar kondisi vegetasinya, intensitas HV terlihat paling




Gambar 2.5 Sembilan fitur parameter polarimetrik yang diekstraksi dari matriks kovarian polarimetrik (*polarimetric covariance matrix*) untuk data polarimetrik E-SAR daerah Penajam, Kalimantan Timur.



Gambar 2.6 Sembilan fitur parameter polarimetrik yang diekstraksi dari matriks kovarian polarimetrik (*polarimetric covariance matrix*) untuk data polarimetrik ALOS-PALSAR daerah Lumajang, Jawa Timur.

berpotensi. Fitur koherensi polarimetrik dan fitur perbedaan fase juga memiliki kemampuan pendiskriminasian tersebut, namun dengan kemampuan yang relatif lebih rendah dibanding dengan fitur intensitasnya. Fitur koherensi polarimetrik HH-VV dan fitur perbedaan fase HH-VV terutama paling berpotensi untuk membedakan hutan (area bervegetasi) dengan area lainnya (non-hutan). Koherensi pada area terbuka bernilai tinggi, sedangkan pada area bervegetasi bernilai rendah



Gambar 2.7 Pengaruh ukuran jendela pada proses pemfilteran speckle. (Diambil dari sebagian data polarimetrik E-SAR, daerah Penajam, Kalimantan Timur)

atau sedang.

Fitur-fitur yang ditunjukkan pada Gambar 2.5 dan Gambar 2.6 telah melalui pengolahan awal berupa pemfilteran speckle (*speckle filtering*) dengan menggunakan J.S. Lee polarimetric filter (Lee *et al.*, 1999b). Ukuran jendela yang dipakai adalah 3x3. Semakin besar ukuran jendela yang dipergunakan akan mengurangi efek speckle namun di lain pihak akan mengakibatkan *blurring*, seperti yang ditunjukkan pada Gambar 2.7 yang diambil dari sebagian data polarimetrik E-SAR.

2.4 Pengekstraksian Fitur berdasarkan Dekomposisi Polarimetrik Cloude

Salah satu keuntungan utama dari data polarimetrik-SAR adalah potensinya untuk membedakan (memisahkan) beberapa tipe/mekanisme hamburan balik dari objek tutupan lahan yang berbeda, sehingga memberikan hasil identifikasi dan klasifikasi tutupan lahan yang lebih baik dibandingkan data

SAR konvensional (*single-channel single-polarisation SAR*) (Reigber; 2001; Karathanassi Daboor, 2004; Beaulieu and Touzi, 2004; Woodhouse, 2006). Beberapa pendekatan pemodelan hamburan balik sinyal radar yang disebut dengan dekomposisi polarimetrik (*target/polarimetric decomposition*) telah diajukan untuk mengekstraksi informasi mengenai berbagai mekanisme hamburan balik dari objek yang berbeda yang selanjutnya dapat dipergunakan untuk membantu proses interpretasi dan klasifikasi data polarimetrik-SAR.

Untuk keperluan pengekstraksian berbagai mekanisme hamburan balik tersebut, pendekatan menggunakan matriks koherensi polarimetrik lebih disukai karena elemen-elemen pada matriks tersebut mempunyai kaitan erat dengan sifat fisik hamburan balik gelombang. Matriks koherensi polarimetrik (*polarimetric coherency matrix*) T tersebut disusun serupa dengan matriks kovarian polarimetrik C , hanya saja menggunakan vektor target Pauli k_p (seperti yang telah dijelaskan pada Rumus (2.4)) sebagai berikut:

$$T = k_p k_p^* = \frac{1}{2} \begin{bmatrix} |s_{HH} + s_{VV}|^2 & (s_{HH} + s_{VV})(s_{HH} - s_{VV})^* & 2(s_{HH} + s_{VV})s_{HV}^* \\ (s_{HH} - s_{VV})(s_{HH} + s_{VV})^* & |s_{HH} - s_{VV}|^2 & 2(s_{HH} - s_{VV})s_{HV}^* \\ 2s_{HV}(s_{HH} + s_{VV})^* & 2s_{HV}^*(s_{HH} - s_{VV}) & 4|s_{HV}|^2 \end{bmatrix} \quad (2.8)$$

Seperti yang diilustrasikan pada Tabel 2.1, elemen-elemen target vektor Pauli dapat mengindikasikan tipe/mekanisme hamburan balik objek yang berbeda-beda (*odd-bounce, even-bounce, volume scattering*). Berdasarkan atas representasi matriks koherensi polarimetrik tersebut, Cloude and Pottier (1997) mengajukan suatu dekomposisi polarimetrik yang dapat mencakup berbagai mekanisme hamburan balik secara lebih luas dan mengajukan suatu skema klasifikasi secara *unsupervised*. Dekomposisi polarimetrik ini mengupayakan pengidentifikasian mekanisme hamburan balik sinyal berdasarkan atas dekomposisi eigen (*eigen decomposition*) dari representasi matriks koherensi T . Menurut teori dekomposisi eigen, matriks koherensi yang merupakan matriks Hermitian 3x3 (yang berarti merupakan matriks bujur sangkar, *conjugate symmetry*, memiliki *real eigenvalue*, dan memiliki *eigenvector-eigenvector* yang ortogonal) dapat didekomposisi sebagai berikut:

$$T = MDM^* \quad (2.9)$$

Matriks diagonal D (3x3, *real*) berisi *eigenvalue-eigenvalue* dari T

$$\mathbf{D} = \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix} \quad (2.10)$$

dimana $\infty > \lambda_1 > \lambda_2 > \lambda_3 > 0$.

Matriks unitary \mathbf{M} berisi *eigenvector-eigenvector* \mathbf{m}_i (untuk $i = 1, 2, 3$) dari \mathbf{T} :

$$\mathbf{M} = [\mathbf{m}_1 \quad \mathbf{m}_2 \quad \mathbf{m}_3] \quad (2.11)$$

Matriks koherensi \mathbf{T} selanjutnya didekomposisi menjadi hasil penjumlahan 3 matriks koherensi \mathbf{T}_i , yang masing-masing diboboti dengan *eigenvaluenya* λ_i .

$$\mathbf{T} = \sum_{i=1}^3 \lambda_i \mathbf{T}_i = \lambda_1 (\mathbf{m}_1 \mathbf{m}_1^{*T}) + \lambda_2 (\mathbf{m}_2 \mathbf{m}_2^{*T}) + \lambda_3 (\mathbf{m}_3 \mathbf{m}_3^{*T}) \quad (2.12)$$

(* \mathbf{T} menunjukkan *complex conjugate transpose*). Masing-masing matrix \mathbf{T}_i dapat dihubungkan dengan suatu mekanisme hamburan balik tertentu/spesifik (*deterministic scattering*). Besar kecilnya kontribusi tersebut ditentukan oleh *eigenvalue* λ_i , sedangkan tipe hamburan baliknya berkaitan erat dengan masing-masing *eigenvector*nya.

Cloude and Pottier (1997) kemudian memformulasikan *eigenvector* \mathbf{m}_i , untuk $i = 1, 2, 3$ tersebut dalam bentuk:

$$\mathbf{m}_i = [\cos \alpha_i \quad \sin \alpha_i \cos \beta_i e^{j\delta_i} \quad \sin \alpha_i \sin \beta_i e^{j\gamma_i}]^T \quad (2.13)$$

Dengan demikian secara lengkap matriks \mathbf{M} menjadi:

$$\mathbf{M} = \begin{bmatrix} \cos \alpha_1 & \cos \alpha_2 & \cos \alpha_3 \\ \sin \alpha_1 \cos \beta_1 e^{j\delta_1} & \sin \alpha_2 \cos \beta_2 e^{j\delta_2} & \sin \alpha_3 \cos \beta_3 e^{j\delta_3} \\ \sin \alpha_1 \sin \beta_1 e^{j\gamma_1} & \sin \alpha_2 \sin \beta_2 e^{j\gamma_2} & \sin \alpha_3 \sin \beta_3 e^{j\gamma_3} \end{bmatrix} \quad (2.14)$$

Eigenvalue dan *eigenvector* merupakan parameter-parameter primer dari hasil dekomposisi eigen atas \mathbf{T} . Untuk membantu analisa atas informasi fisik yang diberikan oleh dekomposisi eigen ini, Cloude and Pottier kemudian mendefinisikan tiga parameter sekunder dari *eigenvalue* dan *eigenvector* atas \mathbf{T} ini (Cloude and Pottier, 1997; Pottier *et al.*, 2005), yakni:

- *Entropy* E

$$E = -\sum_{i=1}^3 P_i \log_3 P_i \quad , \quad P_i = \frac{\lambda_i}{\sum_{j=1}^3 \lambda_j} \quad (2.15)$$

dimana P_i (*normalized eigenvalues*) dapat diinterpretasikan sebagai intensitas relatif mekanisme hamburan balik 'i'. Nilai *entropy* E , berada pada interval $0 \leq E \leq 1$, merepresentasikan tingkat kerandoman dari proses hamburan baliknya. Nilai $E = 0$ mengindikasikan bahwa T hanya memiliki sebuah *eigenvalue* yang bukan nol dan ini berarti hanya terdapat sebuah mekanisme hamburan balik. Sedangkan nilai $E = 1$ mengindikasikan bahwa T memiliki tiga buah *eigenvalue* yang sama ($\lambda_1 = \lambda_2 = \lambda_3$) dan ini berarti proses hamburan balik yang terjadi merupakan kombinasi dari tiga mekanisme hamburan balik secara random sepenuhnya (*totally random scattering*). Sebagai contoh untuk objek perairan laut tenang atau permukaan yang tidak begitu kasar, akan didominasi oleh *surface scattering*, dan nilai E akan mendekati nol. Sedangkan untuk area yang bervegetasi sangat lebat (misalnya area hutan) nilai E akan tinggi, disebabkan oleh kombinasi berbagai mekanisme hamburan baliknya.

- *Anisotropy A*

$$A = \frac{\lambda_2 - \lambda_3}{\lambda_2 + \lambda_3} \quad (2.16)$$

Anisotropy merupakan parameter yang bersifat komplemen terhadap *entropy*. *Entropy* terutama hanya menjadi indikator hubungan antara λ_1 dan kedua *eigenvalue* lainnya λ_2 , λ_3 , dan tidak ada informasi lebih lanjut yang dapat diperoleh dari *entropy* ini terkait dengan hubungan λ_2 dan λ_3 . Parameter *anisotropy* menutupi kekurangan tersebut, dengan memberikan informasi mengenai hubungan antara nilai λ_2 dan λ_3 tersebut. Namun demikian, pada *entropy* tinggi, *anisotropy* tidak memberikan informasi tambahan karena ketiga *eigenvalue* relatif bernilai sama ($E \cong 1 \rightarrow \lambda_1 \cong \lambda_2 \cong \lambda_3$). Demikian juga pada nilai *entropy* yang sangat rendah, karena *eigenvalue* λ_2 dan λ_3 bernilai mendekati nol. *Anisotropy* memberikan informasi lanjut terutama pada nilai *entropy* rendah dan sedang, dimana nilai *anisotropy* tinggi berarti bahwa selain mekanisme hamburan balik yang pertama mekanisme hamburan balik yang kedua saja yang penting. Sedangkan nilai *anisotropy* yang rendah

mengindikasikan bahwa mekanisme hamburan balik yang ketiga juga memegang peranan.

- *Mean alpha angle* $\bar{\alpha}$

$$\bar{\alpha} = \sum_{i=1}^3 P_i \alpha_i \quad (2.17)$$

Mean alpha angle merupakan rata-rata mekanisme hamburan balik dari *alpha angle* α_1 , α_2 , dan α_3 yang diboboti dengan masing-masing P_i nya. *Alpha angle* tersebut masing-masing mengindikasikan tipe hamburan balik yang informasinya dapat diperoleh menggunakan *Scattering Vector Reduction Theorem* berikut (Hellmann, 2001):

"Any polarimetric back-scattering mechanism, represented by a complex unitary vector \mathbf{k}_i , obeying reciprocity can be reduced to the identity $[1,0,0]^T$, by a series of 3 matrix transformations:





$$\begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} \cos \alpha & \sin \alpha & 0 \\ -\sin \alpha & \cos \alpha & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \beta & \sin \beta \\ 0 & -\sin \beta & \cos \beta \end{bmatrix} \begin{bmatrix} e^{j\phi} & 0 & 0 \\ 0 & e^{j\delta} & 0 \\ 0 & 0 & e^{j\gamma} \end{bmatrix} \mathbf{k}_i \quad (2.18)$$


where the angles are interpreted as follows:

- α ; target scattering type $0 \leq \alpha \leq 90^\circ$
- β ; orientation of target $-180^\circ \leq \beta \leq 180^\circ$
- ϕ, δ, γ ; target phase angles. "

Rangkuman hasil pengaplikasian teorema tersebut ditunjukkan dalam Tabel 2.2 dan Gambar 2.8. *Beta angle* β terkait dengan sudut orientasi suatu target hamburan balik terhadap arah garis pandang radarnya (*line-of-sight direction*). Seperti misalnya apabila dalam pemodelan *dihedral scatterer* dipertimbangkan pula sudut perputaran atau kemiringannya terhadap sumbu horizontalnya (seperti pada Tabel 2.2). Sedangkan, *alpha angle* α yang bernilai $0 \leq \alpha \leq 90^\circ$ tidak terkait dengan sudut orientasi target, namun dapat dipergunakan untuk mendiskripsikan tipe dari mekanisme hamburan baliknya. Nilai $\alpha = 0^\circ$ terjadi pada mekanisme hamburan balik tunggal (*single/odd bounce scattering*) dari sekumpulan objek sferikal yang random (*random*

Tabel 2.2 Contoh nilai parameter $\alpha, \beta, \phi, \delta, \gamma$ untuk media penghambur balik standar (*canonical scatterer*). ∞ diartikan sebagai tidak ada nilai yang tetap/fix. (Sumber: Hellmann, 2001)

| Canonical Scatterer | α | β | γ | δ | ϕ |
|--|------------|-----------------|-------------------|-------------------|-------------------|
| Sphere  | 0° | ∞ | ∞ | ∞ | ψ° |
| Dihedral at θ°  | 90° | $2\theta^\circ$ | $-\delta$ | $-\gamma$ | ψ° |
| Dipole at ψ°  | 45° | $2\theta^\circ$ | ψ° | ψ° | ∞ |
| Surface at θ°  | 0° | $2\theta^\circ$ | $\approx 0^\circ$ | $\approx 0^\circ$ | $\approx 0^\circ$ |




Gambar 2.8 Interpretasi tipe hamburan balik berdasar α angle. (Sumber: Hellmann, 2001)

cloud of spherical objects), atau dari sebuah permukaan isotropik (*isotropic surface*). (Nilai \mathbf{k}_i pada Rumus (2.18) berkisar pada $\mathbf{k}_i = [1 \ 0 \ 0]^T$, dan ini berasosiasi dengan vektor target Pauli yang pertama pada Tabel 2.1). Apabila nilai α membesar, permukaan tersebut menjadi anisotropik (yakni $s_{HH} \neq s_{VV}$). Kemudian pada $\alpha = 45^\circ$ menjadi mekanisme hamburan balik dari suatu dipol dimana sudut orientasi dipol tersebut ditentukan oleh β (mekanisme hamburan balik seperti ini berkorespondensi dengan *volume scattering*). Apabila $\alpha > 45^\circ$ akan didapatkan *anisotropic dihedral* ($s_{HH} \neq s_{VV}$), atau dapat dikatakan berupa mekanisme hamburan balik *double-*

bounce akibat pemantulan dua permukaan. Dan akhirnya pada $\alpha = 90^\circ$ akan didapatkan mekanisme hamburan balik dari *dihedral reflector* (dua permukaan metalik) dengan sudut orientasi 0° . (Nilai k , pada Rumus (2.18) berkisar pada $k = [0 \ 1 \ 0]^T$, dan ini berasosiasi dengan vektor target Pauli yang kedua pada Tabel 2.1).

Nilai *mean alpha angle* $\bar{\alpha}$ untuk selanjutnya bersama-sama dengan *entropy* E dari Rumus (2.15) dapat diplot ke dalam suatu bidang *entropy-alpha* seperti yang ditunjukkan pada Gambar 2.9. Bidang *entropy-alpha* dan juga parameter *anisotropy* selanjutnya dapat dijadikan dasar bagi klasifikasi berdasarkan mekanisme hamburan baliknya. Cloude and Pottier (1997) selanjutnya mencoba membagi bidang *entropy-alpha* tersebut menjadi 9 zona yang selanjutnya memungkinkan dilakukan pengklasifikasian secara tidak terbimbing (yang disebut dengan klasifikasi *unsupervised entropy-alpha*). Karakteristik hamburan balik dari masing-masing zona tersebut ditunjukkan pada



Physical scattering characteristics:

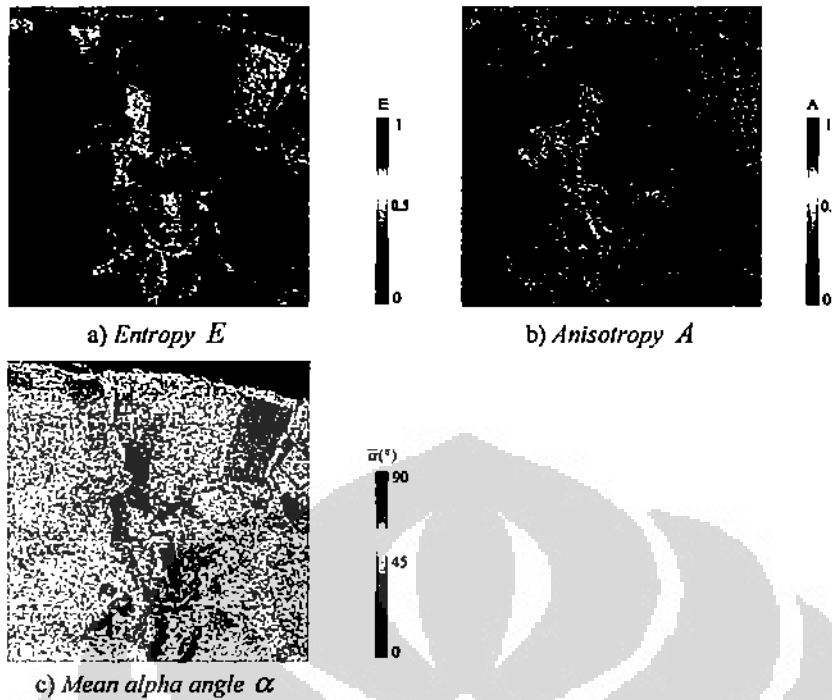
- Z9 : Low Entropy Surface Scattering
- Z8 : Low Entropy Dipole Scattering
- Z7 : Low Entropy Multiple Scattering
- Z6 : Medium Entropy Surface Scattering
- Z5 : Medium Entropy Vegetation Scattering
- Z4 : Medium Entropy Multiple Scattering
- Z3 : (Not a Feasible Region in entropy-alpha space)
- Z2 : High Entropy Vegetation Scattering
- Z1 : High Entropy Multiple Scattering

Gambar 2.9 Bidang *entropy-alpha* dengan pembagian zona untuk klasifikasi *unsupervised* berdasarkan karakteristik hamburan baliknya. (Sumber: Cloude and Pottier, 1997)


Gambar 2.9 bagian bawah.

Pada Gambar 2.10 dan Gambar 2.11 ditunjukkan gambar fitur parameter *entropy*, *mean alpha angle*, dan *anisotropy* yang diekstraksi menggunakan dekomposisi polarimetrik Cloude dari data polarimetrik E-SAR dan ALOS-PALSAR. Dengan menganalisa *mean alpha angle* dan *entropy*, terlihat bahwa untuk area perairan bersifat *surface scattering* (nilai *alpha* lebih kecil daripada 42.5°) dengan nilai *entropy* yang rendah. Sementara itu, area hutan cenderung bersifat *volume scattering* (nilai *alpha* berada pada kisaran 45°) dengan nilai *entropy* tinggi (lebih besar daripada 0.9). Baik area tanah terbuka maupun ladang keduanya secara relatif mempunyai nilai *entropy* yang medium dan nilai *alpha* yang rendah, dan hal ini berpotensi menyebabkan tingkat kemampuan pembedaan diantara kedua kelas tersebut menjadi rendah. *Anisotropy* kurang memberikan sensitifitas yang cukup untuk membedakan berbagai tipe tutupan lahan, namun demikian masih berpotensi sebagai pembeda diantara area tanah terbuka dan area ladang seperti yang terlihat pada Gambar 2.10-b dan Gambar 2.11-b. Selanjutnya apabila ketiga fitur tersebut dibandingkan secara visual dengan sembilan fitur parameter yang diekstraksi dari metode ekstraksi pertama (Gambar 2.5 dan Gambar 2.6), maka terlihat bahwa ketiga fitur tersebut memberikan informasi yang berbeda terutama dengan fitur intensitas baik HH, VV, maupun HV. Fitur dari dekomposisi Cloude ini terutama lebih berpotensi untuk membedakan antara area yang bervegetasi (yang bersifat *volume scattering* dengan *entropy* yang tinggi) dengan area tanah terbuka atau tidak bervegetasi (yang cenderung bersifat *surface/single-bounce scattering* dengan *entropy* yang relatif rendah).


Selanjutnya pada Gambar 2.12 dan Gambar 2.13 ditunjukkan hasil klasifikasi *unsupervised entropy-alpha* dengan menggunakan batas-batas kelas seperti yang ditunjukkan pada Gambar 2.8 masing-masing untuk data polarimetrik E-SAR dan ALOS-PALSAR. Terlihat bahwa metode pengestimasi berbagai mekanisme hamburan balik secara *unsupervised* ini mempunyai beberapa keterbatasan yang diakibatkan oleh penentuan batas-batas zona (kelas) secara linear pada bidang *entropy-alpha* yang mungkin tidak sesuai dengan distribusi datanya sehingga mengakibatkan hasil klasifikasi yang tidak sesuai (Lee *et al.*, 1999a; Ferro-Famil *et al.*, 2005). Oleh karena itu, dalam penelitian ini jumlah




Gambar 2.10 Tiga fitur hasil dekomposisi polarimetrik Cloude untuk data polarimetrik E-SAR daerah Penajam, Kalimantan Timur.




Gambar 2.11 Tiga fitur hasil dekomposisi polarimetrik Cloude untuk data polarimetrik ALOS-PALSAR daerah Lumajang, Jawa Timur.




a) Hasil klasifikasi

b) Informasi kelas dan warna pada bidang *entropy-alpha*

Gambar 2.12 Contoh hasil klasifikasi *unsupervised entropy-alpha* dari hasil dekomposisi polarimetrik Cloude untuk data polarimetrik E-SAR daerah Penajam, Kalimantan Timur.



a) Hasil klasifikasi

b Informasi kelas dan warna pada bidang *entropy-alpha*

Gambar 2.13 Contoh hasil klasifikasi *unsupervised entropy-alpha* dari hasil dekomposisi polarimetrik Cloude untuk data polarimetrik ALOS-PALSAR daerah Lumajang, Jawa Timur.

kelas dan batas-batasnya dalam bidang *entropy-alpha* tidak diterapkan. Fitur-fitur *entropy*, *anisotropy*, dan *mean alpha angle* akan langsung digunakan sebagai fitur input pengklasifikasinya bersamaan dengan fitur parameter polarimetrik yang diekstraksi dari matriks kovarian polarimetrik. Untuk menghilangkan informasi yang redundan maupun informasi yang tidak relevan yang mungkin terkandung dalam fitur-fitur tersebut, maka dikaji kemungkinan penggunaan metode

penyeleksian (pereduksian) fitur berikut ini sebagai step awal sebelum proses klasifikasi tersebut dilakukan.

2.5 Penyeleksian (Pereduksian) Fitur berdasarkan Transformasi *Maximum Noise Fraction* (MNF)

Dengan mengaplikasikan dua metode ekstraksi fitur seperti yang telah dijelaskan di atas, secara keseluruhan akan didapatkan dua belas fitur. Namun demikian, klasifikasi data berdimensi tinggi merupakan suatu hal yang kompleks dan biasanya membutuhkan komputasi yang tinggi. Oleh karena itu, suatu skema penyeleksian (pereduksian) fitur diperlukan untuk menurunkan jumlah fitur dengan menghilangkan informasi yang bersifat redundan dan informasi lainnya yang tidak relevan dari ruang fitur utuh (asal) sebagai tahap awal proses klasifikasi. Untuk tujuan tersebut, dalam penelitian ini dikaji penerapan transformasi *maximum noise fraction* (MNF). Transformasi ini telah diterapkan, terutama dalam penelitian terkait dengan data hiperspektral, yakni diantaranya untuk menentukan dimensi inheren dari sekumpulan data hiperspektral tersebut, untuk memisahkan noise-noise yang terkandung dalam data tersebut, dan untuk menurunkan kompleksitas komputasi dalam proses berikutnya (Boardman, *et al.* 1995; Tso and Matter, 2001; Canty, 2006).

Transformasi MNF, yang penjelasannya terangkum dalam Tabel 2.3, pada dasarnya merupakan transformasi *principal component* (PC) dua tahap. Transformasi pertama, mendekorelasikan dan mereskala noise dari datanya berdasarkan dari matriks kovarian noise (*noise covariance matrix*) yang diestimasi sebelumnya. Hasil dari transformasi tahap pertama merupakan kanal-kanal data dimana noisenya memiliki variansi satu (*unit variance*) dan tidak terdapat korelasi antar kanal-kanal tersebut (*no band-to-band correlations*). Transformasi tahap dua adalah transformasi *principal component* standar dari data yang telah diputihkan noisenya (*noise-whitened data*). Dimensi yang inheren dari data tersebut kemudian ditentukan dengan memeriksa hasil akhir *eigenvalue-eigenvalue*nya dan masing-masing kanal (citra) terkaitnya. Kanal-kanal data hasil transformasi akhir tersebut dapat dibagi menjadi dua bagian, yaitu satu bagian data yang memiliki nilai eigen (*eigenvalue*) besar dan citra eigen yang koheren,

Tabel 2.3 Transformasi *maximum noise fraction* (MNF)

Tahap 1) Estimasi *noise covariance matrix* Σ_N . Lakukan transformasi *principal component* (PC) menggunakan *eigenvector matrix* Φ dari *noise covariance matrix* tersebut terhadap data orisinal X :

$$Z = \Phi^T X, \quad \Phi^T \Sigma_N \Phi = \Lambda_N$$

dimana Λ_N adalah matriks diagonal yang tersusun dari nilai-nilai *eigenvalue noise covariance matrix*.

Kemudian, aplikasikan *whitening transformation* sehingga menjadikan *covariance matrix* komponen noisanya sama dengan I (matriks identitas)

$$Z' = \Lambda_N^{-1/2} Z$$

Tahap 2) Lakukan transformasi PC terhadap Z' :

$$Y = \Theta^T Z', \quad \Theta^T \Sigma_{Z'} \Theta = \Lambda_Z$$

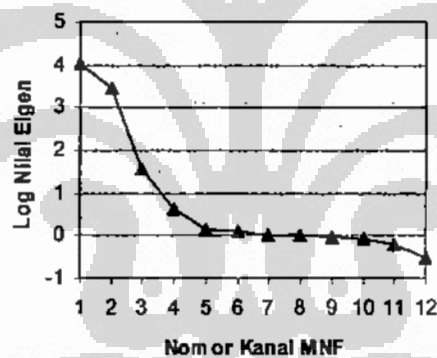

dan bagian lain (sisanya) yang memiliki nilai eigen mendekati satu dan citra terkaitnya yang didominasi oleh noise. Pada penelitian ini, jumlah fitur input untuk klasifikasi dapat direduksi dengan menggunakan bagian yang koheren hasil dari transformasi MNF dari data asal, dan menghilangkan kanal-kanal sisanya (tidak dipakai dalam proses klasifikasi selanjutnya).

Transformasi MNF ini, walaupun menggunakan transformasi PC, namun secara mendasar terdapat perbedaan antara kedua transformasi tersebut. Transformasi MNF lebih bertujuan memaksimalkan *signal to noise ratio* (SNR), sedangkan transformasi PC bertujuan memaksimalkan variansi (*variance*) dalam kanal-kanal hasil transformasinya secara berurutan. Padahal, seperti telah diketahui, pada dataset-dataset citra penginderaan jauh boleh dikatakan selalu mengandung noise yang cukup signifikan, dan ada kemungkinan bahwa noise tersebut mempunyai variansi yang lebih besar dibandingkan sumber-sumber informasinya. Oleh karena itu, transformasi PC berpotensi memberikan hasil-hasil hasil-hasil yang kurang memuaskan karena diterapkan tanpa mempertimbangkan keberadaan noise-noise tersebut. Tidak demikian halnya dengan transformasi MNF yang melakukan pemutihan noise-noise tersebut (yang diasumsikan bersifat *additive noise*) sebelum dilakukan transformasi PC di tahapan berikutnya. Dalam hal ini, pengestimasian kovarian noise cukup menentukan keberhasilan

transformasi ini. Kovarian noise tersebut secara ideal dapat diestimasi dari “*dark reference*”. Beberapa instrumen penginderaan jauh mengumpulkan “*dark reference*” tersebut sebagai bagian dari pengkalibrasian atau pengumpulan data yang dapat dipergunakan untuk mengukur (mengkarakterisasikan) noise dari instrumen tersebut (Carvalho *et al.*, 2000; Tso and Matter, 2001). Namun demikian, pada data polarimetrik-SAR yang dipergunakan pada penelitian ini tidak tersedia informasi “*dark reference*” tersebut. Sebagai gantinya, penelitian ini menggunakan area yang homogen dari data citra input asalnya seperti misalnya area perairan yang tenang (lihat Gambar 1. 3). Ide dasar pengekstraksian kovarian noise seperti ini adalah didasarkan pada asumsi bahwa sifat-sifat hamburan balik sinyal radar dari area yang homogen tersebut seharusnya menunjukkan karakteristik yang seragam, sehingga variasi-variasi yang terkandung dari hasil pengukuran instrumen tersebut dapat dipertimbangkan sebagai suatu noise.

Pada Gambar 2.14 ditunjukkan kanal-kanal hasil transformasi MNF dari total dua belas fitur yang dihasilkan dari dua metode pengekstraksian fitur untuk data polarimetrik E-SAR daerah Penajam, Kalimantan Timur. Yakni sembilan fitur dari matriks kovarian polarimetrik (Gambar 2.5) dan tiga fitur dari dekomposisi polarimetrik Cloude (Gambar 2.10). Masing-masing nilai eigen untuk kanal-kanal tersebut ditunjukkan pada Gambar 2.14-b. Dengan menganalisa masing-masing nilai eigen dan kanal MNF terkaitnya, didapatkan bahwa sebagian besar konten informasinya terkonsentrasi hanya pada empat kanal yang pertama saja. Dalam hal ini, nilai-nilai eigennya lebih besar dari 4.2. Kanal-kanal lainnya memiliki nilai eigen yang mendekati satu dan citra yang dihasilkannya juga didominasi oleh noise. Empat kanal pertama MNF tersebut merupakan hasil akhir proses pereduksian fitur ini, dan selanjutnya akan dipergunakan pada proses selanjutnya (yakni sebagai input ke klasifier).


Sebagai perbandingan, pada Gambar 2.16-a juga ditunjukkan hasil apabila proses pereduksian fitur tersebut dilakukan dengan transformasi *principal component* (PC) biasa. Terlihat bahwa transformasi PC tidak mampu mengkonsentrasikan informasinya pada kanal-kanal awal dan pada kanal-kanal berikutnya justru terlihat informasi/kekонтрасан citranya lebih terlihat jelas kembali. Padahal pada kanal-kanal akhir tersebut memiliki nilai-nilai variansi




Gambar 2.14 Hasil transformasi *maximum noise fraction* (MNF) untuk tujuan pereduksian fitur pada data polarimetrik E-SAR daerah Penajam, Kalimantan Timur.

yang justru lebih rendah bila dibandingkan dengan kanal-kanal awal PC.

Hasil yang identik juga didapatkan pada hasil transformasi MNF untuk data polarimetrik ALOS-PALSAR daerah Lumajang, Jawa Timur seperti yang ditunjukkan pada Gambar 2.15. Pada hasil ini juga terlihat bahwa sebagian besar konten informasinya terkonsentrasi pada empat kanal yang pertama saja. Dalam hal ini, nilai-nilai eigennya lebih besar dari 4.5. Kanal-kanal lainnya memiliki





a) Kanal-kanal MNF



b) Nilai-nilai eigen MNF

Gambar 2.15 Hasil transformasi *maximum noise fraction* (MNF) untuk tujuan pereduksian fitur pada data polarimetrik ALOS-PALSAR daerah Lumajang, Jawa Timur.

nilai eigen yang mendekati satu dan citra yang dihasilkannya juga didominasi oleh noise. Perbandingan hasil dengan transformasi PC ditunjukkan pada Gambar 2.16-b. Sekali lagi terlihat bahwa transformasi MNF lebih sesuai dibandingkan transformasi PC. Dan sama halnya dengan data E-SAR, empat kanal pertama MNF yang merupakan hasil akhir proses pereduksian fitur ini selanjutnya akan dipergunakan sebagai input ke klasifier yang akan dikaji pada bab berikutnya.



Gambar 2.16 Hasil transformasi *principal component* (PC) sebagai perbandingan dengan hasil transformasi MNF pada data E-SAR (Gambar 2.14) dan pada data ALOS-PALSAR (Gambar 2.15). (Nilai dalam tanda kurung merupakan nilai eigennya masing-masing)

BAB 3

KLASIFIKASI BERDASARKAN FUZZY MAXIMUM LIKELIHOOD ESTIMATION CLUSTERING (FMLE)

Pada Bab 1 telah disampaikan ringkasan global metodologi penyelesaian masalah yang diusulkan dalam penelitian ini untuk mengupayakan tercapainya peningkatan performansi identifikasi dan klasifikasi berbagai objek tutupan lahan dari data polarimetrik-SAR. Selanjutnya pada Bab 2 telah dibahas landasan teori dan kerangka dasar pemikiran terkait dengan metode pengekstraksian fitur dan penyeleksian fitur. Pada bab ini, akan dijelaskan *fuzzy clustering* terutama difokuskan pada algoritma klustering *fuzzy maximum likelihood estimation* (FMLE) yang akan dipergunakan sebagai klasifier *unsupervised* bagi fitur-fitur input tersebut.

3.1 Fuzzy Clustering

Suatu algoritma *fuzzy clustering* pada prinsipnya memungkinkan suatu piksel menjadi anggota dari beberapa kelas sekaligus dimana masing-masing piksel memiliki suatu derajat keanggotaan yang berbeda-beda pada tiap kelasnya (Gath and Geva, 1989; Tso and Mather, 2001; Kersten *et al.*, 2005; Canty, 2006). Suatu set fitur input (vektor piksel) $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ terdiri atas n vektor $\mathbf{x}_i \in R^d$ (dimana d adalah dimensi dari fitur input). Apabila terdapat K kelas, maka $u_{ki} = u_k(\mathbf{x}_i) \in [0,1]$ adalah derajat keanggotaan dari sampel ke- i pada kelas ke- k dan $\mathbf{U} = [u_{ki}]$ adalah matriks keanggotaan yang berisi seluruh elemen u_{ki} . Kumpulan (set) dari pusat-pusat kluster (*cluster centers*) \mathbf{v}_k ditunjukkan dengan $\mathbf{V} = \{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_K\}$. Masing-masing sampel \mathbf{x}_i memenuhi batasan-batasan keanggotaan seperti berikut:

$$u_{ki} \in [0,1] \text{ dan } \sum_{k=1}^K u_{ki} = 1, \quad i=1 \dots n \quad (3.1)$$

Algoritma klustering *fuzzy K-means* (FKM) adalah berdasarkan atas minimisasi dari *fuzzy objective function* berikut:

$$J_g(\mathbf{U}, \mathbf{V}) = \sum_{k=1}^K \sum_{i=1}^n u_{ki}^g D_E^2(\mathbf{x}_i, \mathbf{v}_k) \quad (3.2)$$

dimana D_E adalah *Euclidean distance* $D_E^2(\mathbf{x}_i, \mathbf{v}_k) = (\mathbf{x}_i - \mathbf{v}_k)^2$. Parameter g ($g > 1$) menentukan tingkatan kefuzzian (*degrees of fuzziness*) dan sering dipilih dengan nilai $g = 2$. Untuk $g > 1$ dan $\mathbf{x}_i \neq \mathbf{v}_k$, untuk seluruh i, k , suatu nilai minimum dari J_g dapat dicapai dalam kondisi berikut:

$$u_{ki} = \frac{\left(\frac{1}{\|\mathbf{x}_i - \mathbf{v}_k\|^2} \right)^{1/(g-1)}}{\sum_{k=1}^K \left(\frac{1}{\|\mathbf{x}_i - \mathbf{v}_k\|^2} \right)^{1/(g-1)}}, \quad k = 1 \dots K, \quad i = 1 \dots n \quad (3.3)$$

dan *cluster center* ke- k dihitung dari:

$$\mathbf{v}_k = \frac{\sum_{i=1}^n u_{ki}^g \mathbf{x}_i}{\sum_{i=1}^n u_{ki}^g}, \quad k = 1 \dots K \quad (3.4)$$

Klustering FKM kemudian dapat dilakukan dengan mengaplikasikan secara iteratif Rumus (3.3) dan (3.4). Iterasi tersebut berhenti apabila *cluster center* \mathbf{v}_k atau alternatif lain apabila elemen-elemen matriks u_{ki} telah berhenti berubah-ubah secara signifikan.

Algoritma FKM telah sukses diimplementasikan dalam banyak aplikasi, seperti misalnya pada klasifikasi pola (*pattern classification*) dan segmentasi citra (*image segmentation*). Namun demikian, algoritma FKM yang standar adalah berdasarkan atas *fuzzy objective function* dalam Rumus (3.2) yakni menggunakan *Euclidean distance*. Hal ini sesuai untuk pembentukan *hyperspherical clusters* yang memiliki radius yang sama (*similar radii*). Suatu algoritma alternatif lainnya yang disebut dengan *fuzzy maximum likelihood estimation* (FMLE) memungkinkan pembentukan kluster-kluster berbentuk elips (*ellipsoidal clusters*) dengan sembarang arah (*arbitrary extent*) dan karenanya lebih fleksibel.

Algoritma FMLE dapat diturunkan dari algoritma FKM dengan mengganti Rumus (3.3) untuk penentuan derajat keanggotaan kelas u_{ki} dengan *posterior probability* $P(k|\mathbf{x}_i)$ untuk kelas k pada observasi \mathbf{x}_i . Yakni dengan menggunakan *Bayes' Theorem*, sebagai berikut (Canty, 2006):

$$u_{ki} \rightarrow P(k | \mathbf{x}_i) = \frac{P(\mathbf{x}_i | k)P(k)}{P(\mathbf{x}_i)} \quad (3.5)$$

$P(\mathbf{x}_i | k)$ adalah suatu *class-specific probability density function*, dan diasumsikan mengikuti *multivariate normal distribution*. *Cluster center* \mathbf{v}_k dan *covariance matrix* \mathbf{s}_k diperoleh dengan:

$$\mathbf{v}_k = \frac{\sum_{i=1}^n u_{ki} \mathbf{x}_i}{\sum_{i=1}^n u_{ki}} \quad \mathbf{s}_k = \frac{\sum_{i=1}^n u_{ki} (\mathbf{x}_i - \mathbf{v}_k)(\mathbf{x}_i - \mathbf{v}_k)^T}{\sum_{i=1}^n u_{ki}}, \quad k = 1 \dots K \quad (3.6)$$

Prior probability dari kluster ke- k , $P(k)$, diperoleh dengan:

$$P(k) = \frac{n_k}{n} = \frac{\sum_{i=1}^n u_{ki}}{n} \quad (3.7)$$

Dengan demikian, terlepas dari faktor konstan yang independen terhadap k , akan diperoleh:

$$u_{ki} = P(\mathbf{x}_i | k)P(k) = \frac{1}{\sqrt{|\mathbf{s}_k|}} \exp \left[-\frac{1}{2} (\mathbf{x}_i - \mathbf{v}_k)^T \mathbf{s}_k^{-1} (\mathbf{x}_i - \mathbf{v}_k) \right] \frac{n_k}{n} \quad (3.8)$$

Algoritma FMLE terdiri atas iterasi dari Rumus (3.1), (3.6), (3.7), dan (3.8) sampai dengan derajat keanggotaannya konvergen. Dalam penelitian ini, kriteria yang dipergunakan adalah sebagai berikut:

$$\max_k (\|u'_{ki} - u_{ki}\|) < \varepsilon \quad (3.9)$$

dimana ε adalah suatu *threshold* dan dipilih $\varepsilon = 0.001$. Dan setelah konvergen, keputusan pengkelasan masing-masing pikselnya dapat ditentukan dengan memilih kelas yang memiliki derajat keanggotaan tertinggi, yakni dengan:

$$\text{class}(\mathbf{x}_i) = \arg \max_k u_{ki} \quad (3.10)$$

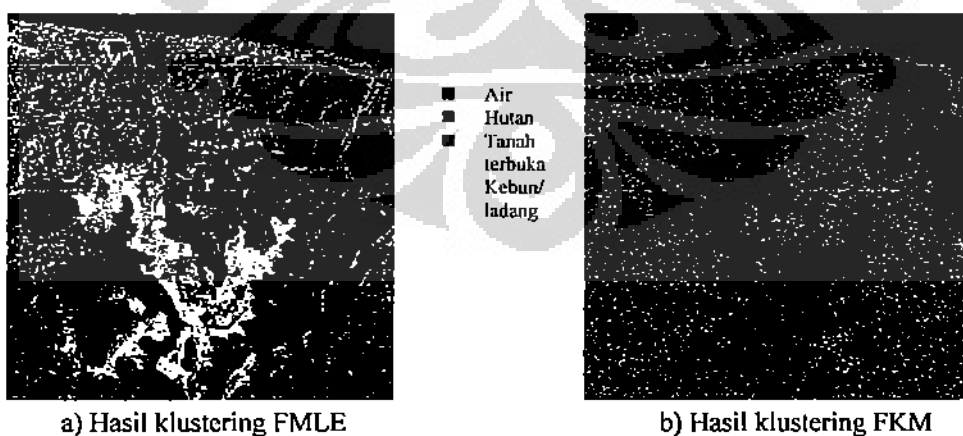
Berbeda dengan algoritma FKM, derajat keanggotaan u_{ki} pada FMLE adalah merupakan fungsi dari *Mahalanobis distance*

$D_M(\mathbf{x}_i, \mathbf{v}_k) = \sqrt{(\mathbf{x}_i - \mathbf{v}_k)^T \mathbf{s}_k^{-1} (\mathbf{x}_i - \mathbf{v}_k)}$ yang sensitif terhadap arah (*directionally-sensitive*). Karena pada Rumus (3.8) derajat keanggotaan merupakan fungsi eksponensial D_M^2 , maka komputasi ini menjadi sangat sensitif terhadap kondisi awal (*initialization condition*) dan bahkan menjadi tidak stabil. Untuk menghindari hal tersebut, penelitian ini mengikuti saran Gath and Geva (Gath and

Geva, 1989; Canty, 2006) dengan langkah pertama memperoleh nilai inisial untuk u_k dengan perhitungan pendahuluan menggunakan algoritma FKM.

Dalam beberapa literatur algoritma ini sering disebut dengan klustering *fuzzy maximum likelihood estimation* (Gath and Geva, 1989; Tso and Mather, 2001; Canty, 2006). Padahal apabila ditelaah lebih jauh, perbedaannya FKM standar hanyalah pada jenis *distance* yang dipakai. FKM menggunakan *Euclidean distance*, sedangkan FMLE menggunakan *Mahalanobis distance*. Penggunaan kata-kata "*maximum likelihood*" yang sering diasosiasikan dengan metode klasifikasi supervised "*maximum likelihood*" dapat menimbulkan kerancuan pemahaman terhadap algoritma ini. Berdasarkan hal tersebut, penulis berpendapat lebih tepat kiranya apabila algoritma ini cukup disebut dengan algoritma klustering fuzzy dengan *Mahalanobis distance*.

Pada Gambar 3.1 ditunjukkan contoh hasil klasifikasi FMLE dan FKM dengan fitur input 4 kanal hasil MNF data polarimetrik E-SAR (Gambar 2.14). Terlihat bahwa untuk fitur-fitur tersebut FMLE memberikan hasil yang lebih baik daripada FKM. Selain itu, dari kedua hasil klasifikasi tersebut terlihat terjadi efek "*salt-and-pepper*" meskipun berada pada area yang homogen. Hal tersebut merupakan ciri umum dari penerapan klasifier berbasis piksel per piksel apabila diterapkan pada data SAR. Hal ini pulalah yang mendorong perlunya penerapan informasi spasial-kontekstual seperti yang akan dikaji pada bab berikutnya.



Gambar 3.1 Contoh hasil klasifikasi FMLE dan FKM dengan fitur input 4 kanal hasil reduksian fitur dengan transformasi MNF data E-SAR (Gambar 2.14).

BAB 4

INFORMASI SPASIAL-KONTEKSTUAL

Baik algoritma klustering FKM maupun FMLE, seperti yang dijelaskan pada Bab 3, menggunakan informasi spektral (atau intensitas) dari masing-masing piksel dan informasi konteks spasial dari citra tersebut tidak ikut dipertimbangkan dalam proses klustering. Akibat dari adanya noise speckle yang terkandung dalam data SAR, penggunaan klasifier berbasis piksel per piksel (*pixel-by-pixel basis classifier*) biasanya akan menghasilkan hasil klasifikasi yang mengandung banyak kesalahan klasifikasi dalam tingkat piksel yang terdistribusi secara random. Hal ini seringkali muncul sebagai efek bintik terang-gelap ("*salt-and-pepper*" effect) dalam peta hasil klasifikasi meskipun berada pada area yang homogen. Salah satu metode untuk mengoreksi kesalahan klasifikasi yang mungkin terjadi dalam tingkat piksel adalah dengan menggunakan skema *probabilistic relaxation* (Canty, 2006; Reigber *et al.*, 2007). Pada bab ini, pertama-tama akan dijelaskan prinsip dasar *probabilistic relaxation*. Selanjutnya efektifitasnya terhadap data bernoise seperti SAR akan dikaji lebih lanjut dengan menggunakan data citra buatan yang berkarakteristik mirip dengan data SAR dan telah diketahui informasi pengkelasannya.

4.1 Informasi Spasial-kontekstual berdasarkan *Probabilistic Relaxation*

Salah satu metode untuk mengoreksi kesalahan klasifikasi yang mungkin terjadi dalam tingkat piksel dan untuk mensupport hasil klasifikasi yang lebih homogen terutama pada area yang homogen adalah dengan menggunakan skema *probabilistic relaxation* (Canty, 2006; Reigber *et al.*, 2007). Prinsip dasarnya adalah berdasarkan atas asumsi bahwa piksel-piksel yang bersebelahan tidaklah sepenuhnya independen secara statistikal. Pada kenyataannya, hasil-hasil klasifikasi yang random secara spasial adalah kecil kemungkinannya, dan justru sebaliknya area-area yang kontinyu dalam suatu ukuran (objek) tertentu adalah yang lebih diharapkan. Oleh karena itu, jelas bahwa informasi dari piksel-piksel yang bersebelahan akan meningkatkan kapabilitas diskriminasi dari hasil

pengukuran yang hanya berbasis piksel saja, dan karenanya akan meningkatkan akurasi klasifikasinya dan efisiensi interpretasinya.

Informasi tambahan tersebut dapat dinyatakan dengan suatu fungsi kebertetanggaan (*neighborhood function*) q , yang dapat merefleksikan informasi kontekstual dari piksel-piksel yang bersebelahan tersebut (Canty, 2006; Reigber *et al.*, 2007). Untuk mendefinisikan fungsi tersebut, digunakan suatu *compatibility coefficient*:

$$P(x_i, k | y_i, r) \quad (4.1)$$

yakni suatu *conditional probability* bahwa suatu piksel x_i masuk dalam kelas k , jika piksel yang bersebelahan y_i masuk dalam kelas r . Apabila terdapat K kelas yang memungkinkan, dan lebih jauh memasukkan pertimbangan dari piksel-piksel yang bersebelahan yang terdiri dari L piksel, maka suatu *neighborhood function* berikut dapat didefinisikan:

$$q_k = q_k(x_i) = \sum_{y_i=1}^L \sum_{r=1}^K P(x_i, k | y_i, r) P(y_i, r) \quad (4.2)$$

Fungsi ini menjelaskan *total joint probability* pada seluruh piksel-piksel yang bersebelahan beserta informasi penempatan kelas-kelasnya bahwa suatu piksel x_i masuk dalam kelas k . Probabilitas $q_k = q_k(x_i)$ memberikan informasi mengenai derajat keanggotaan dari piksel x_i yang semata-mata diperoleh dari informasi kebertetanggaan dan tanpa mempertimbangkan isi (konten) dari piksel itu sendiri.

Apabila diterapkan pada hasil FMLE pada Bab 3, setelah proses klustering dilakukan, probabilitas keanggotaan masing-masing piksel diketahui (menurut Rumus (3.8)). Dalam hal ini untuk mempermudah penjelasan selanjutnya, nilai u_{ki} hasil akhir klustering FMLE (setelah tercapai konvergen) dinotasikan sebagai u_{ki}^S . Dimana simbol "S" menyatakan bahwa hasil probabilitas keanggotaan tersebut diperoleh hanya dengan menggunakan informasi "spektral" saja (berbasis piksel). Berdasarkan hasil tersebut, informasi konteks spasial q_{ki} pada Rumus (4.2) dapat dihitung untuk masing-masing pikselnya. Selanjutnya, integrasi antara informasi spektral u_{ki}^S dan informasi spasial q_{ki} dapat dilakukan dengan:

$$u_k^s = \frac{u_k^s q_k}{\sum_{k=1}^K u_k^s q_k} \quad (4.3)$$

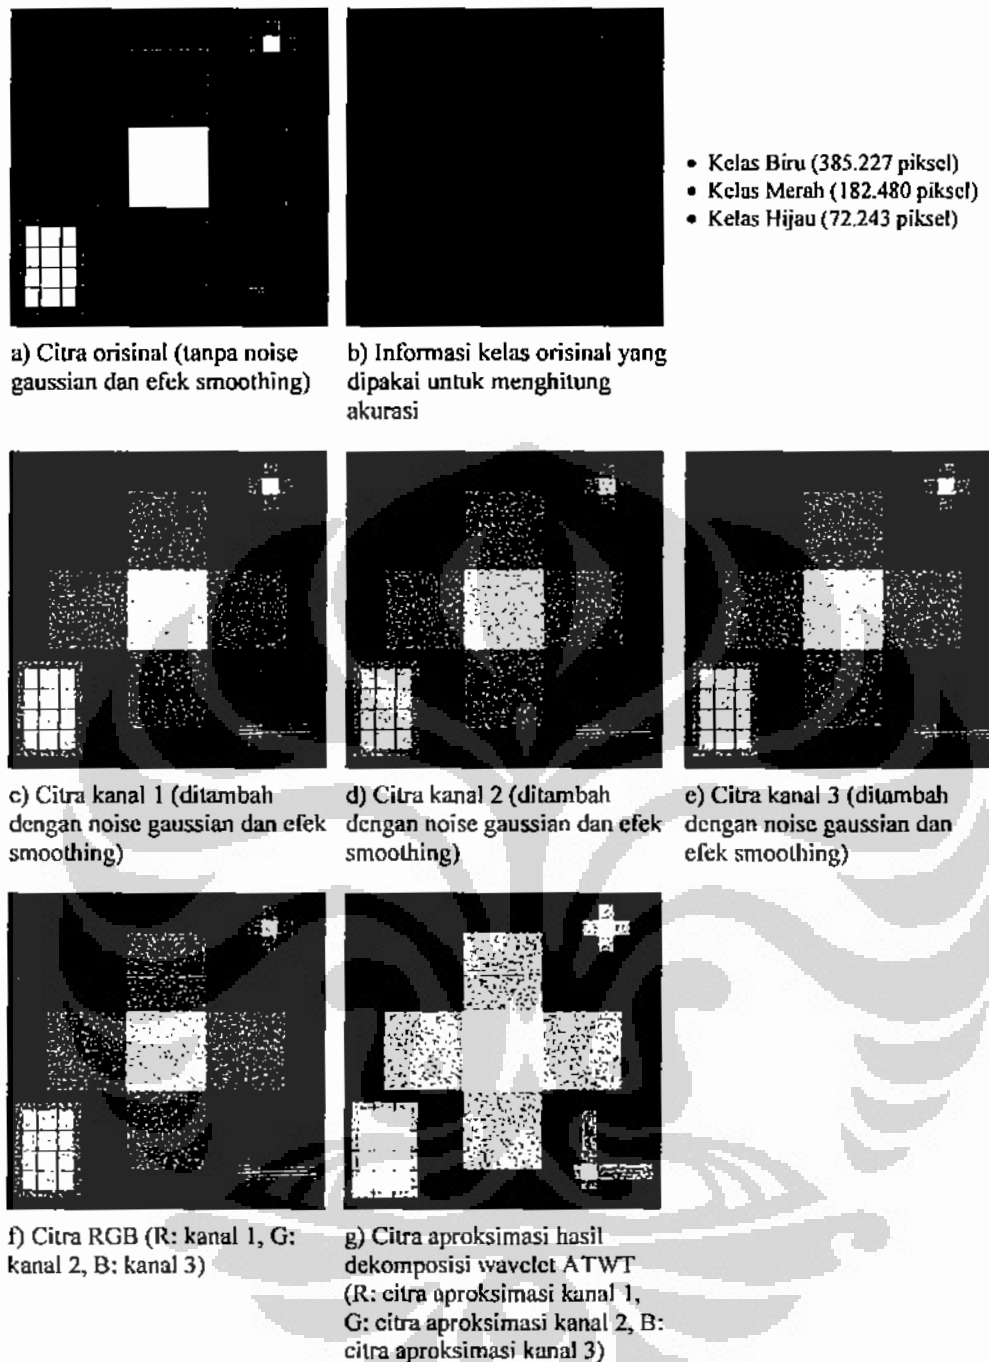
Sebagai alternatif, prosedur *probabilistic relaxation* ini dapat dilakukan secara berulang kali dengan mengaplikasikan Rumus (4.2) dan (4.3) secara iteratif. Dalam penelitian ini akan diobservasi pengaruh jumlah iterasi dalam *probabilistic relaxation* tersebut terhadap hasil klasifikasi. Kemudian jumlah iterasi yang optimal akan ditentukan dengan eksperimen.

4.1.1 Ujicoba Pengaruh Penyertaan Informasi Spasial-kontekstual berdasarkan *Probabilistic Relaxation* Menggunakan Data Citra Buatan

Untuk lebih diperoleh pemahaman yang lebih lengkap mengenai efektifitas klasifier FMLE dan sekaligus efek penyertaan informasi spasial-kontekstual berdasarkan *probabilistic relaxation* terutama pada data bernoise, maka dilakukan ujicoba menggunakan data citra buatan. Dengan menggunakan citra buatan yang informasi pengkelasannya telah diketahui sebelumnya, maka efektifitas metode ini dapat dievaluasi bukan hanya dengan penilaian secara visual namun dapat pula dinyatakan secara kuantitatif.

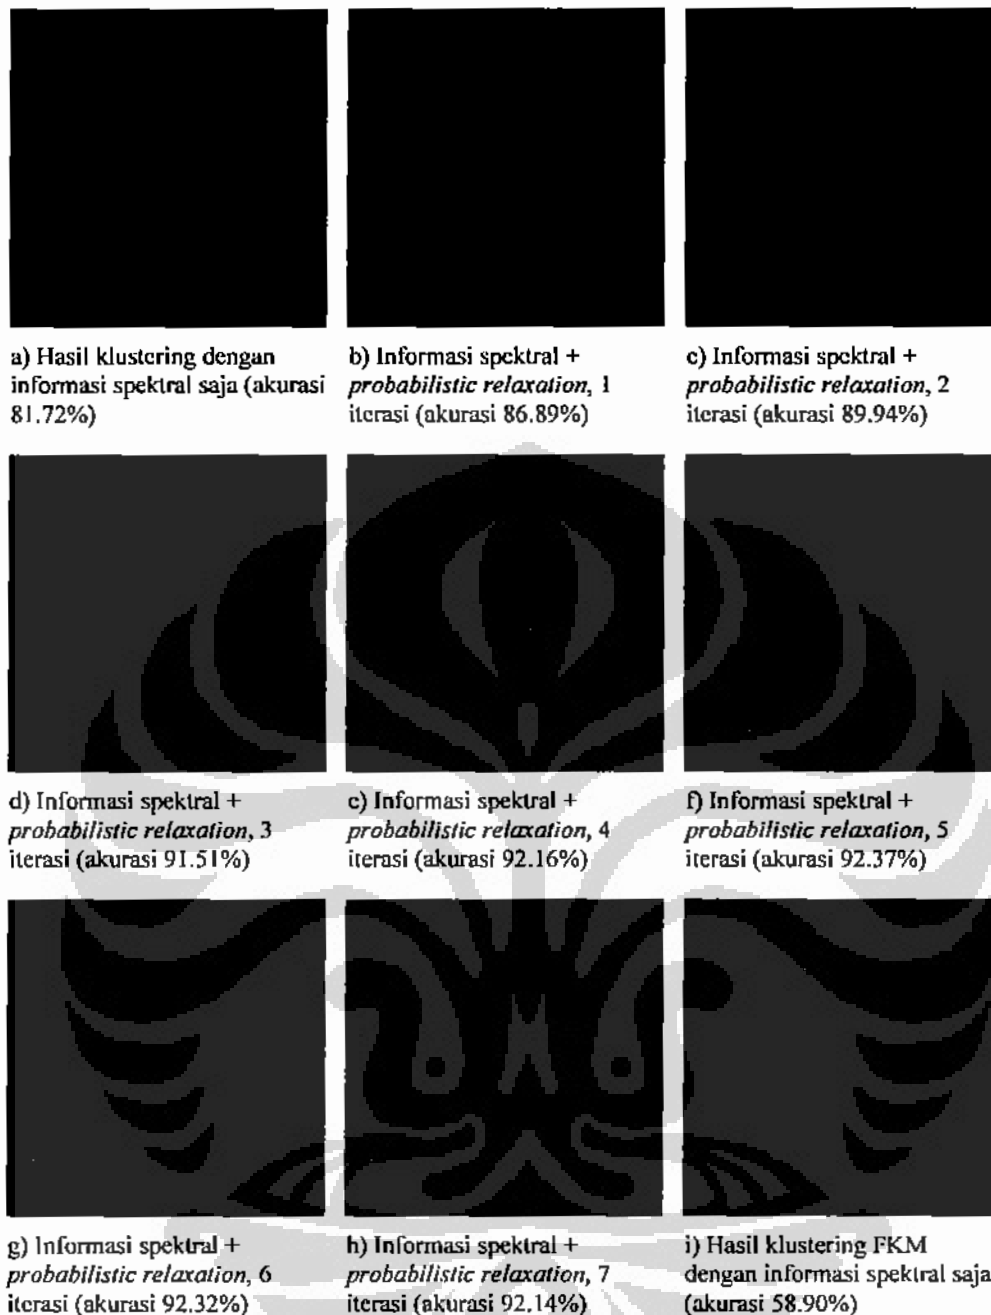
Pada Gambar 4.1 ditunjukkan data citra buatan tersebut, yang terdiri atas tiga kanal citra buatan berukuran 800 x 800 piksel yang berisi tiga kelas (kelas "biru", kelas "merah", dan kelas "hijau"). Suatu noise *gaussian* dan efek *smoothing* juga ditambahkan ke dalam ketiga citra tersebut dengan besaran yang berbeda-beda dengan tujuan mendapatkan kanal-kanal citra yang relatif mempunyai kesamaan sifat dengan citra SAR sesungguhnya.

Hasil-hasil klasifikasi dengan menggunakan FMLE ditunjukkan pada Gambar 4.2 beserta nilai akurasi masing-masing. Nilai akurasi tersebut dihitung berdasarkan persentase jumlah piksel yang terklasifikasi secara benar oleh klasifier sesuai dengan informasi kelas-kelas yang diturunkan dari citra orisinalnya seperti yang ditunjukkan pada Gambar 4.1-b. Apabila digunakan klasifikasi FMLE berbasis piksel per piksel (dengan informasi spektral) saja menggunakan fitur input 3 kanal pada Gambar 4.1-c, 4.1-d, dan 4.1-e, hasilnya seperti ditunjukkan pada Gambar 4.2-a terlihat sangat bernoise di semua wilayah



Gambar 4.1 Data citra buatan.

citra. (Sebagai perbandingan pada Gambar 4.2-i, hasil dengan menggunakan FKM juga ditampilkan yang mana hasilnya jauh lebih jelek dibandingkan dengan FMLE). Kemudian, apabila informasi spasial-kontekstual berdasarkan *probabilistic relaxation* diterapkan, maka akan diperoleh hasil yang lebih



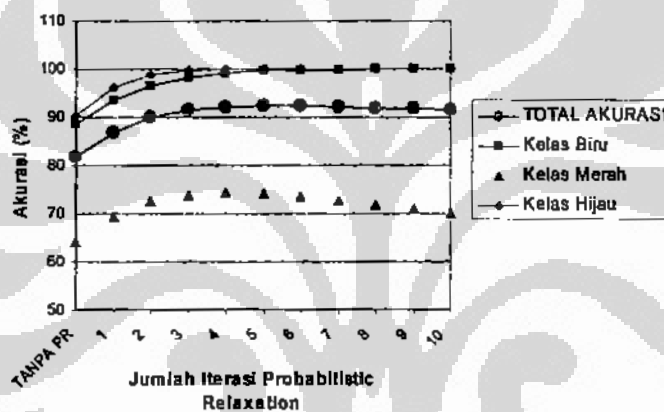
Gambar 4.2 Hasil klasifikasi FMLE dengan menggunakan citra buatan dan pengaruh penyertaan informasi spasial-kontekstual berdasar *probabilistic relaxation*. (Hasil klasifikasi dengan FKM ditampilkan pula sebagai perbandingan)

homogen. Dengan bertambahnya jumlah iterasi, tingkat kehomogenan juga semakin meningkat. Namun demikian, tingkat perbaikan yang dibicarakan dengan penyertaan informasi spasial-kontekstual berdasar *probabilistic relaxation* ini

$$\begin{bmatrix} P(x, k = \text{biru} | y, r = \text{biru}) & P(x, k = \text{biru} | y, r = \text{merah}) & P(x, k = \text{biru} | y, r = \text{hijau}) \\ P(x, k = \text{merah} | y, r = \text{biru}) & P(x, k = \text{merah} | y, r = \text{merah}) & P(x, k = \text{merah} | y, r = \text{hijau}) \\ P(x, k = \text{hijau} | y, r = \text{biru}) & P(x, k = \text{hijau} | y, r = \text{merah}) & P(x, k = \text{hijau} | y, r = \text{hijau}) \end{bmatrix} \\
 = \begin{bmatrix} 0.824 & 0.156 & 0.020 \\ 0.345 & 0.483 & 0.172 \\ 0.073 & 0.286 & 0.641 \end{bmatrix}$$

- Contoh: $P(x, k = \text{merah} | y, r = \text{hijau})$ merupakan *compatibility coefficient* untuk piksel tersebut berkelas "merah" sedangkan piksel tetangganya berkelas "hijau".

Gambar 4.3 Hasil penghitungan *compatibility coefficient* dari hasil klustering FMLE dengan informasi spektral data citra buatan yang digunakan sebagai dasar penghitungan informasi spasial-kontekstual berdasar *probabilistic relaxation*.



Gambar 4.4 Grafik perubahan nilai akurasi terhadap jumlah iterasi *probabilistic relaxation*.

masih relatif kecil yakni di bawah 11% dan masih terdapat sekitar 8% lagi untuk mencapai keakurasian 100%. Lebih jauh, apabila diperhatikan dengan detail hal itu terjadi pada kelas "biru" dan kelas "hijau" saja, sedangkan kelas "merah" justru sebaliknya. Hal ini disebabkan hasil klasifikasi dengan informasi spektral saja untuk kelas "merah" kurang bagus (sangat bernoise), sehingga akan mempengaruhi perhitungan *compatibility coefficient* untuk kelas tersebut menjadi rendah. Hasil penghitungan *compatibility coefficient* untuk ketiga kelas tersebut ditunjukkan pada Gambar 4.3. Nilai *compatibility coefficient* untuk piksel berkelas

“merah” dengan piksel tetangganya juga berkelas “merah” hanya bernilai 0.483. Akibatnya dalam proses penghitungan *probabilistic relaxation* kemungkinan kelas suatu piksel (yang salah klasifikasi) tersebut dikoreksi menjadi berkelas “merah” akan lebih kecil walaupun piksel-piksel tetangganya telah berkelas “merah”. Hal ini juga dapat dikonfirmasi pada grafik perubahan nilai akurasi masing-masing kelas (Gambar 4.4) yang mana kekurasian kelas “merah” justru menurun dengan bertambahnya jumlah iterasi.

Dapat disimpulkan di sini bahwa penerapan informasi spasial-kontekstual berdasar *probabilistic relaxation* hanya mampu memperbaiki hasil klasifikasi pada skala mikro, dan justru berpotensi menurunkan kehomogenan apabila diterapkan pada kelas yang hasil dari identifikasi dan klasifikasi awal dengan informasi spektralnya saja kurang bagus. Padahal, tidak ada jaminan bahwa suatu hasil klasifikasi dari suatu klasifier berbasis piksel per piksel akan memberikan hasil yang optimum pada semua kelas-kelasnya.

Berdasarkan hal tersebut, perlu adanya suatu dukungan informasi spasial-kontekstual lain yang mampu lebih memperbaiki kehomogenan hasil klasifikasi terutama pada area-area dalam citra yang memang homogen. Hal inilah yang kemudian mendorong penelitian ini untuk mengkaji suatu metode pengeksploitasi informasi spasial-kontekstual secara lebih makro berdasarkan analisa klustering dengan menggunakan citra aproksimasi wavelet. Pada sub-bab berikut, akan dijelaskan kerangka dasar pemikiran metode tersebut.

4.2 Informasi Spasial-kontekstual berdasarkan Analisa Klustering dengan Citra Aproksimasi Wavelet

Informasi spasial-kontekstual kedua ini, yang diajukan untuk mengupayakan hasil klasifikasi yang lebih homogen terutama pada area-area dengan tutupan lahan yang bersifat homogen, adalah informasi yang dieksploitasi dari hasil analisa klustering menggunakan citra yang telah didekomposisi menggunakan transformasi wavelet. Berikut kerangka dasar pemikirannya.

Dekomposisi wavelet merupakan suatu teknik yang efisien dan efektif untuk menganalisa suatu sinyal secara sistematis dalam beragam skala atau resolusi (Mallat, 1989; Aiazzi *et al.*, 2002; Gonzalez and Woods, 2002; Canty,

2006). *Discrete wavelet transform* (DWT) merupakan salah satu jenis transformasi wavelet yang paling banyak dipergunakan untuk keperluan tersebut. Menurut algoritma tersebut, suatu fungsi $f(x) \in L^2(\mathbb{R})$ dapat didekomposisi sebagai berikut:

$$f(x) = \sum_k a_{j,k} \tilde{\phi}_{j,k}(x) + \sum_{j \leq J} \sum_k w_{j,k} \tilde{\psi}_{j,k}(x) \quad (4.4)$$

Fungsi $\tilde{\phi}_{j,k}(x)$ dan $\{\tilde{\psi}_{j,k}(x)\}_{j \in \mathbb{Z}}$ diperoleh dari translasi dan dilasi atas fungsi *scaling* $\phi(x)$ dan fungsi *mother wavelet* $\psi(x)$ yang perlu didefinisikan lebih lanjut untuk menjamin proses rekonstruksinya. Koefisien $w_{j,k}$ adalah koefisien wavelet, dan $a_{j,k}$ adalah koefisien scaling dengan J yang menyatakan tingkat (level) dekomposisi maksimumnya. Koefisien-koefisien tersebut diperoleh dengan produk skalar sebagai berikut:

$$a_{j,k} = \langle f, \phi_{j,k} \rangle \text{ dan } w_{j,k} = \langle f, \psi_{j,k} \rangle \quad (4.5)$$

Dimana $\phi_{j,k}(x) = 2^{-j/2} \phi(2^{-j}x - k)$ adalah famili dari fungsi-fungsi scalingnya dan $\psi_{j,k}(x) = 2^{-j/2} \psi(2^{-j}x - k)$ adalah famili dari fungsi-fungsi waveletnya.

Dalam prakteknya, DWT dapat diimplementasikan secara efisien (cepat penghitungannya) dengan menggunakan *dyadic filter tree algorithm*. Konsep dasar dari algoritma tersebut adalah dengan merepresentasikan basis wavelet sebagai suatu set *low-pass filter* $H = \{h_i\}$ dan *high-pass filter* $G = \{g_i\}$ dalam suatu *filter bank*. Setelah proses filter tersebut dilakukan, sinyal tersebut kemudian didesimasi (*downsampled*) dengan faktor dua. Hal ini diilustrasikan pada Gambar 4.5-a. Output dari bagian *low-pass* disebut dengan koefisien-koefisien aproksimasi, dan output dari bagian *high-pass* disebut dengan koefisien-koefisien detail wavelet. Dekomposisi wavelet tersebut dapat dilakukan secara iteratif hingga mencapai tingkat (level) dekomposisi maksimum $J = \log_2 N$, dimana N adalah panjang sinyal diskrit inputnya. Pendekatan dengan *filter tree* ini dapat diimplementasikan dengan rumus berikut:

$$\begin{aligned} a_{j+1,k} &= \langle f, \phi_{j+1,k} \rangle = \sum_i h_{i-2k} a_{j,i} \\ w_{j+1,k} &= \langle f, \psi_{j+1,k} \rangle = \sum_i g_{i-2k} a_{j,i} \end{aligned} \quad (4.6)$$


dimana $h_i = \langle \phi, \phi_{-1,i} \rangle$ dan $g_i = \langle \psi, \phi_{-1,i} \rangle$ adalah koefisien-koefisien filter yang dapat diturunkan dari *mother wavelet* yang dipilih. Beberapa contoh fungsi *mother wavelet* yang sering dipergunakan adalah Haar dan Daubechies D4 (Gonzalez and Woods, 2002; Canty, 2006).

Prosedur tersebut dapat dikembangkan pula untuk fungsi-fungsi dua dimensi seperti halnya citra, seperti yang diilustrasikan pada Gambar 4.5-b. Gambar 4.6 menunjukkan contoh hasil dekomposisi dari suatu citra ke dalam 4 buah sub-citra sebagai berikut:

- Sub-citra aproksimasi (Gambar 4.6-b kiri atas) yang diperoleh dengan pemfilteran *low-pass* baik arah baris maupun arah kolom yang diikuti dengan *downsampling*.
- Sub-citra detail vertikal (Gambar 4.6-b kanan atas) yang diperoleh dengan pemfilteran *low-pass* pada arah baris kemudian pemfilteran *high-pass* pada arah kolom yang diikuti dengan *downsampling*.
- Sub-citra detail horisontal (Gambar 4.6-b kiri bawah) yang diperoleh dengan pemfilteran *high-pass* pada arah baris kemudian pemfilteran *low-pass* pada arah kolom yang diikuti dengan *downsampling*.
- Sub-citra detail diagonal (Gambar 4.6-b kanan bawah) yang diperoleh pemfilteran *high-pass* baik arah baris maupun arah kolom yang diikuti dengan *downsampling*.

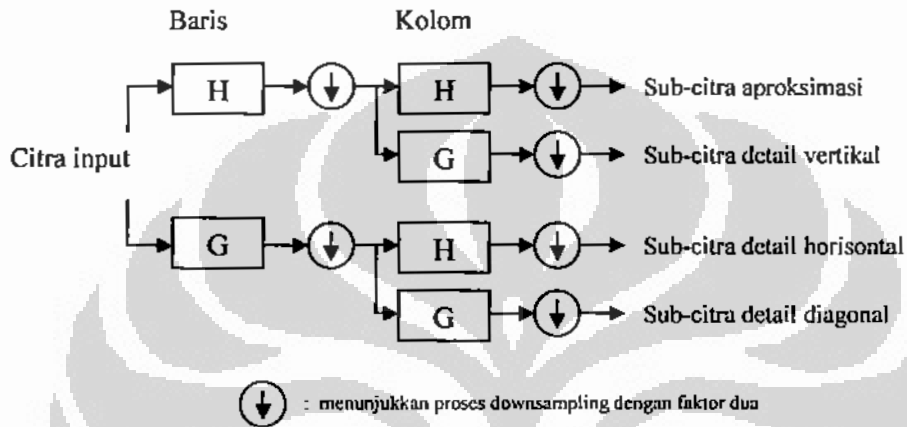
Dengan mendekomposisi kembali citra aproksimasi pada masing-masing level dekomposisi secara iteratif akan didapatkan suatu pohon citra berbentuk piramida (*pyramidal image tree*).

Pada citra aproksimasi, terutama hanya objek-objek yang berukuran besar yang akan tampak dan hanya akan diperoleh gambaran kasar mengenai konteks yang terkandung dalam citra tersebut. Noise speckle dan informasi-informasi yang tidak relevan lainnya terutama pada area-area yang sifatnya homogen dapat lebih direduksi. Sehingga apabila citra aproksimasi tersebut dipergunakan sebagai input ke klasifier maka hasil klasifikasi yang didapatkan juga akan lebih homogen. Namun demikian, sayangnya pada dekomposisi yang *dyadic*, output-output hasil pemfilteran didesimasi (*downsampled*) oleh faktor dua, dan oleh karenanya citra yang dihasilkan akan berukuran lebih kecil dari citra orisinalnya. Hal ini tentu saja



⬇ : menunjukkan proses downsampling dengan faktor dua


a) Skema implementasi *discrete wavelet transform* (DWT) satu dimensi dengan suatu set *low-pass filter* H dan *high-pass filter* G




⬇ : menunjukkan proses downsampling dengan faktor dua

b) Skema implementasi *discrete wavelet transform* (DWT) dua dimensi untuk mendekomposisi citra menjadi empat buah sub-citra

Gambar 4.5 Dekomposisi wavelet dengan *discrete wavelet transform* (DWT).



a) Citra orisinal



b) Citra DWT level 1

Gambar 4.6 Contoh hasil dekomposisi DWT

akan menimbulkan masalah apabila hasil klasifikasi dari citra aproksimasi tersebut kemudian diintegrasikan (difusikan) bersama dengan hasil klasifikasi dari citra orisinalnya karena keduanya mempunyai ukuran yang berbeda.

Untuk memecahkan permasalahan tersebut, sebagai alternatif pada penelitian ini dipakai suatu transformasi wavelet yang disebut dengan *à trous wavelet transform* (ATWT) (Aiazzi *et al.*, 2002; Canty, 2006). ATWT merupakan salah satu dekomposisi wavelet nonorthogonal dengan menggunakan *low-pass filter* $H = \{h(0), h(1), \dots\}$ dan *high-pass filter* $G = \{g_i = \delta_i - h_i\}$, yang mana δ_i menyatakan *all-pass filter*. Bagian berfrekuensi tinggi merupakan selisih diantara citra orisinalnya dengan citra hasil pemfilteran *low-pass*. Dengan demikian tidak terjadi desimasi (tidak dilakukan *downsampled*). Pada iterasi ke j dari proses pemfilteran *low-pass*nya, angka nol sejumlah 2^{j-1} buah disisipkan di antara elemen-elemen H . Seperti misalnya, pada iterasi pertama digunakan


$$H = \{h(0), 0, h(1), 0, \dots\}$$

selanjutnya pada iterasi kedua digunakan


$$H = \{h(0), 0, 0, h(1), 0, 0, \dots\}$$

dan seterusnya. (Oleh sebab itu dinamakan *à trous* yang berarti *hole* atau lubang). *Low-pass filter* biasanya dipilih yang simetrik. Salah satunya adalah *cubic B-spline filter* dengan $H = \{1/16, 1/4, 3/8, 1/4, 1/16\}$ (Canty, 2006).


Pada Gambar 4.7 ditunjukkan salah satu contoh citra hasil dekomposisi wavelet dengan ATWT. Masing-masing level dekomposisi akan memberikan satu pasang citra aproksimasi dan citra detail yang berukuran sama dengan citra orisinalnya. Sama halnya dengan hasil transformasi DWT, pada citra aproksimasi terutama hanya objek-objek yang berukuran besar yang akan tampak dan hanya akan diperoleh gambaran kasar mengenai konteks yang terkandung dalam citra tersebut. (Pada Gambar 4.1-g juga ditunjukkan contoh citra aproksimasi untuk data citra buatan). Noise speckle dan informasi yang tidak relevan lainnya terutama pada area-area yang sifatnya homogen juga dapat lebih direduksi. Namun demikian, sayangnya batas-batas antar objek (*edge*) dan struktur-struktur (atau objek-objek tutupan lahan) yang berukuran kecil juga berpotensi dikaburkan (*blur*). Oleh karena itu, apabila citra aproksimasi tersebut digunakan sebagai fitur



a) Citra orisinal




b) Citra aproksimasi ATWT




c) Citra detail ATWT

Gambar 4.7 Contoh hasil dekomposisi *à trous wavelet transform* (ATWT) level 1



a) Hasil klasifikasi dengan fitur input citra orisinal

- Air
- Hutan
- Tanah terbuka
- Kebun/ladang



b) Hasil klasifikasi dengan fitur input citra aproksimasi

Gambar 4.8 Contoh hasil klasifikasi dengan menggunakan fitur input citra aproksimasi ATWT level 1 dan perbandingannya dengan menggunakan fitur input citra orisinalnya (Kanal 1, 2, 3, dan 4 hasil pereduksian fitur dengan transformasi MNF pada data polarimetrik E-SAR daerah Penajam, Kalimantan Timur).

input klasifier maka akan berpotensi memberikan hasil klasifikasi dengan batas-batas objek yang tidak terjaga dengan baik dan kurang dapat dipercaya dibandingkan dengan hasil klasifikasi yang diperoleh dengan menggunakan citra orisinalnya. Untuk lebih jelasnya, pada Gambar 4.8 ditunjukkan contoh perbandingan hasil klasifikasi FMLE dengan menggunakan fitur input citra orisinal dan dengan menggunakan fitur input citra aproksimasi dari data polarimetrik E-SAR daerah Penajam. Terlihat bahwa untuk area yang homogen hasil klasifikasi dengan fitur input citra aproksimasi memberikan hasil yang lebih homogen dibandingkan dengan fitur input citra orisinalnya. Namun di lain pihak, pada batas-batas objek atau objek-objek yang berukuran kecil akan menjadi rusak (seperti misalnya terlihat di sekitar sungai, garis pematang tambak di sebelah kanan).

Berdasarkan alasan tersebut, maka hasil klasifikasi menggunakan citra aproksimasi ini dapat dipakai untuk mempertegas (meningkatkan) kehomogenan hasil klasifikasi dengan informasi spektral yang kemudian diikuti dengan *probabilistic relaxation* (yakni derajat keanggotaan u_k^S pada Rumus (4.3)), namun terbatas pada area-area yang bersifat homogen saja. Misalkan hasil klasifikasi dengan citra aproksimasi wavelet tersebut memiliki nilai derajat keanggotaan u_k^W (dimana simbol “W” menyatakan bahwa hasil/nilai derajat keanggotaan tersebut diperoleh dari klasifikasi menggunakan citra aproksimasi “wavelet”). Maka ketika dilakukan pengintegrasian (fusi) antara u_k^S dengan u_k^W tersebut perlu adanya suatu kriteria yang dapat dipergunakan untuk membedakan apakah piksel tersebut berada pada area yang homogen atau tidak homogen.

Dalam penelitian ini, perbedaan antara area yang bersifat homogen dan yang tidak homogen tersebut dilakukan dengan menggunakan suatu kriteria ambang batas (*threshold*) yang diturunkan dari koefisien variasi lokal masing-masing pikselnya dan koefisien variasi global dari keseluruhan wilayah citranya. Koefisien variasi lokal $LCV_{local}(x_i)$ didefinisikan sebagai rasio antara nilai deviasi standar lokal $\sigma_{local}(x_i)$ dan nilai rata-rata lokal $\mu_{local}(x_i)$ yang dihitung pada piksel x_i pada suatu ukuran jendela yang ditentukan (Bovolo and Bruzzone, 2005):

$$LCV_{local}(x_i) = \frac{\sigma_{local}(x_i)}{\mu_{local}(x_i)} \quad (4.7)$$

Selanjutnya suatu piksel termasuk dalam kategori homogen apabila syarat berikut terpenuhi:

$$[LCV_{local}(x_i)]^2 \leq [LCV_{entire_image}]^2 \quad (4.8)$$

Dimana LCV_{entire_image} adalah koefisien variasi yang dihitung dari keseluruhan wilayah citranya.

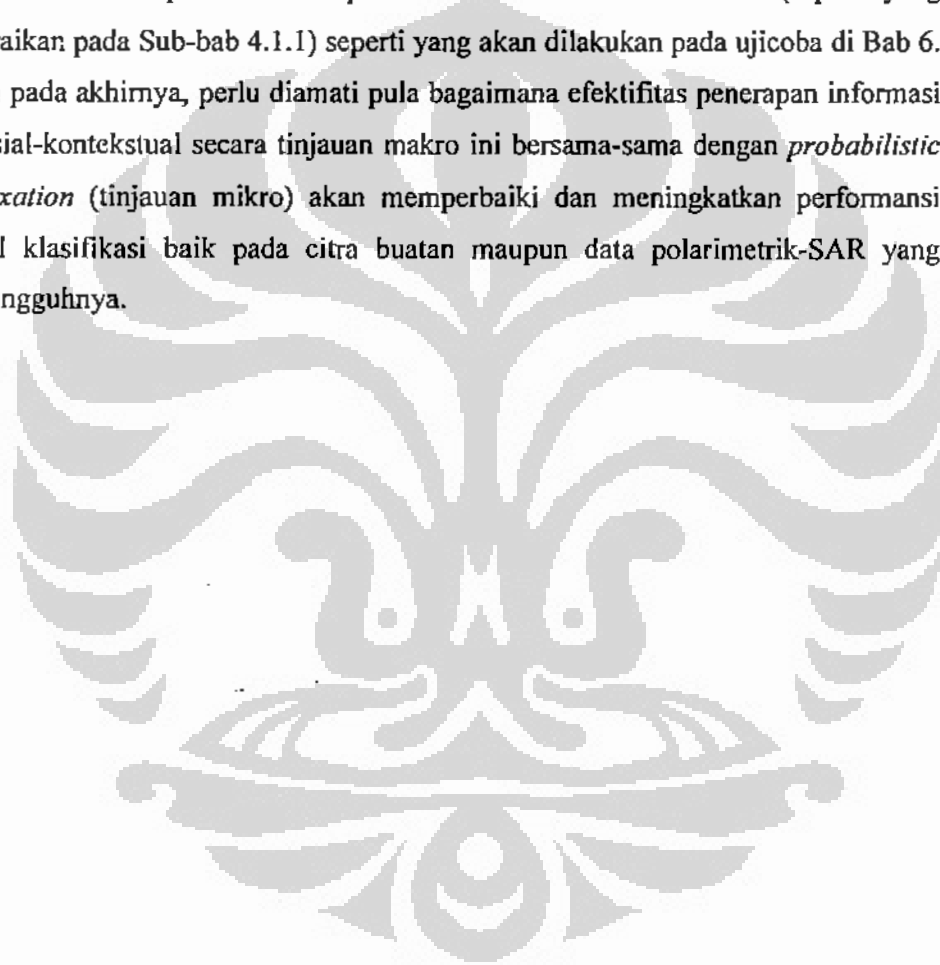
Dengan menggunakan kriteria tersebut, selanjutnya fusi antara derajat keanggotaan hasil *probabilistic relaxation* u_{ki}^S (Rumus (4.3)) dengan derajat keanggotaan hasil klasifikasi dengan citra aproksimasi wavelet u_{ki}^W dapat dilakukan dengan rumus berikut:

$$u_{ki}^{S*} = \begin{cases} \frac{u_{ki}^S u_{ki}^W}{\sum_{k=1}^K u_{ki}^S u_{ki}^W}, & \text{if } [LCV_{local}(x_i)]^2 \leq [LCV_{entire_image}]^2 \text{ (untuk area homogen)} \\ u_{ki}^S, & \text{otherwise (untuk area non-homogen)} \end{cases} \quad (4.9)$$

Selanjutnya perlu dipertimbangkan dari fitur (citra) mana kriteria homogenitas tersebut dihitung. Seperti telah dijelaskan pada Bab 2, fitur-fitur input yang dipergunakan berjumlah banyak. Dari proses ekstraksi fitur didapatkan dua belas fitur (yakni 9 fitur parameter polarimetrik dan 3 fitur dekomposisi polarimetrik Cloude), atau setelah direduksi dengan MNF misalnya didapatkan 4 fitur. Dengan demikian, kriteria homogenitas seperti pada Rumus (4.8) dapat dihitung dari keseluruhan dua belas fitur tersebut (atau 4 fitur kanal MNF tersebut). Akan tetapi, hal tersebut tentulah kurang efisien apabila ditinjau dari segi komputasi dan akan membuat penentuan kriteria homogen tidaknya suatu area menjadi sangat kompleks dikarenakan banyaknya jumlah nilai *threshold* homogenitas yang didapatkan. Oleh karena itu, penelitian ini mengajukan penggunaan hanya satu citra saja yang disebut dengan citra span yang dapat dihitung dengan mudah dari data polarimetrik-SAR menggunakan Rumus (2.6). Citra span (atau sering pula disebut dengan *total power*) merupakan hasil penjumlahan intensitas HH, HV, dan VV dan oleh karenanya memiliki noise speckle yang lebih rendah dibanding masing-masing citra HH, HV, dan VV secara individual. Di samping itu, masing-masing citra HH, HV, dan VV mengandung karakteristik hamburan balik yang berbeda-beda, sehingga berbagai macam

struktur atau objek yang terpantau berbeda-beda pada masing-masing polarisasinya tersebut akan lebih diperjelas dalam citra span ini (Lee *et al.*, 1999b; Sambodo *et al.*, 2008). Sebagai alternatif, citra kanal pertama MNF juga dapat dipergunakan, karena citra ini juga memiliki ketajaman dan kontras yang hampir sama dengan citra span tersebut.

Lebih jauh, pada kriteria homogenitas tersebut perlu ditentukan ukuran jendela yang akan dipergunakan. Pengaruh ukuran jendela tersebut pada hasil klasifikasi akhir perlu diamati pula termasuk untuk citra buatan (seperti yang diuraikan pada Sub-bab 4.1.1) seperti yang akan dilakukan pada uji coba di Bab 6. Dan pada akhirnya, perlu diamati pula bagaimana efektifitas penerapan informasi spasial-kontekstual secara tinjauan makro ini bersama-sama dengan *probabilistic relaxation* (tinjauan mikro) akan memperbaiki dan meningkatkan performansi hasil klasifikasi baik pada citra buatan maupun data polarimetrik-SAR yang sesungguhnya.



BAB 5

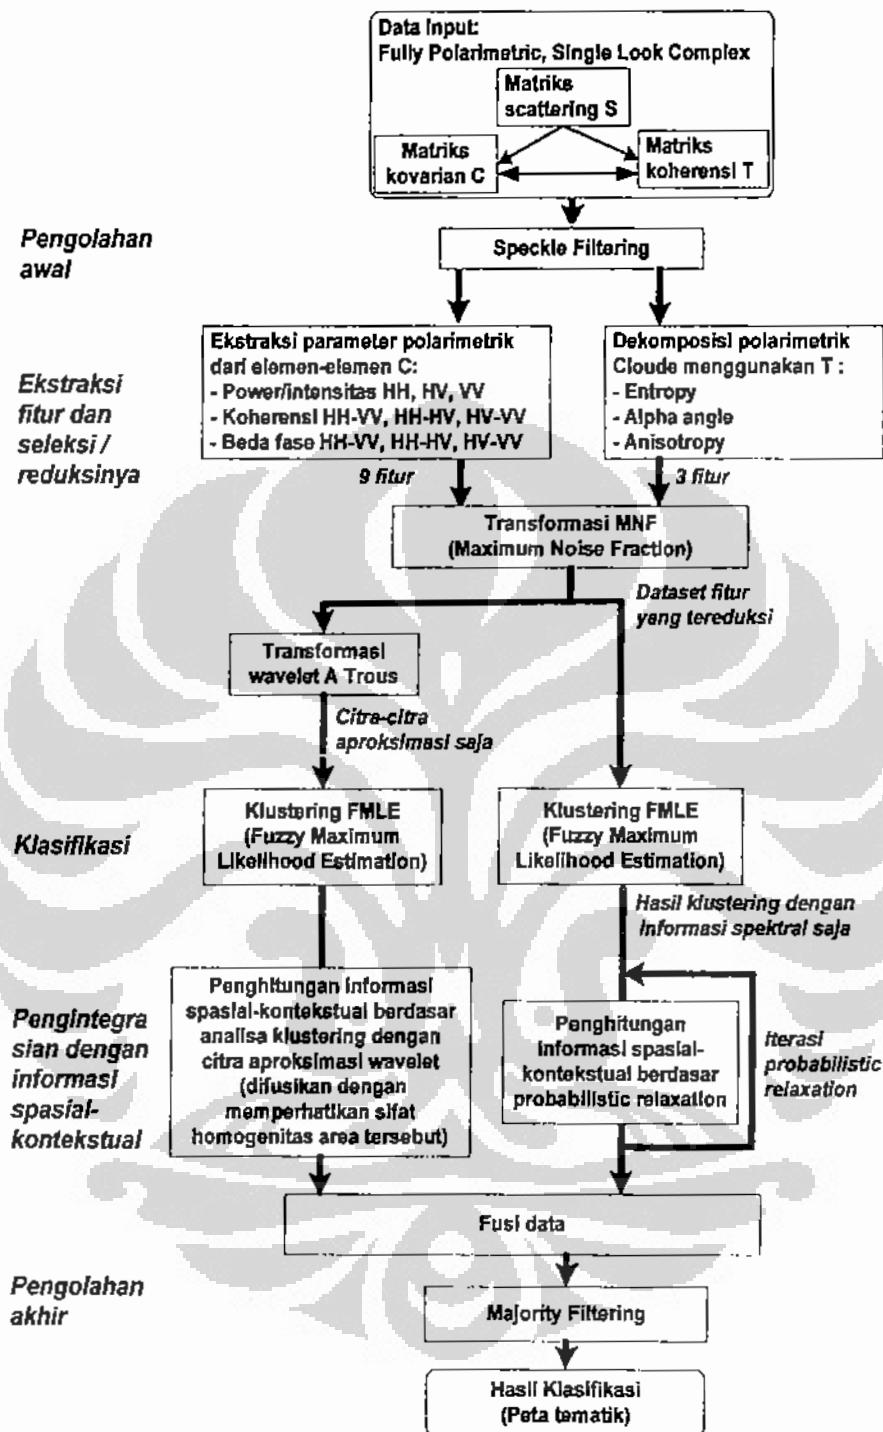
METODOLOGI PENYELESAIAN MASALAH

Pada Bab 2 telah dibahas landasan teori dan kerangka dasar pemikiran terkait dengan metode pengekstraksian fitur dan penyeleksian fitur. Selanjutnya pada Bab 3 telah dibahas mengenai metode klustering FMLE yang akan dipergunakan sebagai klasifier. Berikutnya pada Bab 4 juga telah dibahas mengenai metode pengeksploitasian informasi spasial-kontekstual secara mikro berdasarkan *probabalistic relaxation* dan informasi spasial-kontekstual secara makro berdasarkan analisa klustering dengan citra aproksimasi wavelet. Berlandaskan kerangka dasar pemikiran yang telah diuraikan dalam bab-bab sebelumnya tersebut, maka dalam bab ini akan dirangkai suatu metode penyelesaian masalah dalam suatu kesatuan alur.

5.1 Metodologi Klasifikasi *Unsupervised* Data Polarimetrik-SAR yang Diajukan

Diagram blok metodologi klasifikasi *unsupervised* data polarimetrik-SAR yang diajukan dalam penelitian ini ditunjukkan pada Gambar 5.1. Secara global, ide dasar dari metodologi ini adalah:

- Mengkombinasikan fitur parameter polarimetrik yang diekstraksi dari elemen matriks kovarian polarimetrik dan fitur dekomposisi polarimetrik untuk meningkatkan kemampuan identifikasi berbagai objek tutupan lahan,
- Melakukan transformasi MNF untuk memeriksa dan sekaligus menghilangkan informasi/fitur yang sifatnya redundan atau bernoise,
- Mengintegrasikan hasil klustering FMLE yang berbasis piksel per piksel dengan informasi spasial-kontekstual agar didapatkan hasil klasifikasi yang tidak bernoise (lebih homogen) namun tetap dapat mempertahankan batas-batas (*edge*) dan objek-objek yang berukuran kecil. Hal tersebut ditempuh dengan menerapkan:
 - Informasi spasial-kontekstual berdasarkan *probabilistic relaxation*, yang terutama ditujukan untuk mengoreksi secara mikro pengkelasan



Gambar 5.1 Metodologi klasifikasi *unsupervised* data polarimetrik-SAR yang diajukan.

suatu piksel berdasarkan atas informasi kelas piksel-piksel yang bersebelahan,

- o Informasi spasial-kontekstual berdasarkan analisa klustering dengan citra aproksimasi wavelet yang ditujukan untuk meningkatkan kehomogenan pada hasil klasifikasi terutama pada area-area yang bersifat homogen (perbaikan secara makro).

Apabila metodologi tersebut dijabarkan lebih lanjut, langkah-langkah dalam masing-masing tahapannya adalah sebagai berikut:

1. Persiapkan data input polarimetrik dalam format matriks scattering S , konversikan ke format matriks kovarian polarimetrik C , dan matriks koherensi polarimetrik T . Atau sebagai alternatif, T dapat juga diperoleh langsung dari C dengan (Lee *et al.*, 1999a):

$$T = RCR^T \quad \text{dimana} \quad R = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 0 & 1 \\ 1 & 0 & -1 \\ 0 & \sqrt{2} & 0 \end{bmatrix} \quad (5.1)$$

2. Pengolahan awal:
 - Lakukan *speckle-filtering* menggunakan J.S. Lee polarimetric filter (Lee *et al.*, 1999b), atau sebagai alternatif dengan *Boxcar Filter*, dengan ukuran jendela 3x3.
3. Ekstraksi fitur:
 - Lakukan ekstraksi fitur parameter polarimetrik dari elemen-elemen matriks kovarian polarimetrik C (Rumus 2.5), sehingga diperoleh 9 fitur parameter polarimetrik.
 - Lakukan dekomposisi polarimetrik Cloude (sesuai Sub-bab 2.4) menggunakan input data matriks koherensi polarimetrik T sehingga diperoleh 3 fitur *alpha angle*, *entropy*, dan *anisotropy*.
 - Gabungkan keduanya sehingga diperoleh 12 fitur.
4. Seleksi (reduksi) fitur:
 - Lakukan transformasi MNF (sesuai Tabel 2.3) dengan input 12 fitur hasil langkah 3. Ambil suatu area yang paling homogen dalam citra untuk mengestimasi *noise covariance matrix* Σ_N .

- Dengan mengamati nilai eigen dan citra-citra terkait dalam kanal-kanal MNF tersebut, tentukan jumlah fitur tereduksi M (pilih kanal-kanal dengan nilai-nilai eigen yang jauh lebih besar dari satu).
5. Klasifikasi dengan klustering FMLE:
- Tentukan jumlah kelas objek tutupan lahan K , kriteria penghentian $\varepsilon = 0.001$.
 - Lakukan klustering FMLE dengan menggunakan input M kanal hasil transformasi MNF pada langkah 4. (Iterasi dengan menggunakan Rumus (3.1), (3.6), (3.7), dan (3.8) sampai dengan konvergen).
 - Misalkan sebut hasil yang didapat dari klustering dengan informasi spektral saja ini dengan u_k^s .
6. Penghitungan informasi spasial-kontekstual secara mikro berdasar *probabilistic relaxation*:
- Tentukan jumlah iterasi *probabilistic relaxation*.
 - Lakukan penghitungan *probabilistic relaxation* dengan menggunakan Rumus (4.2) dan Rumus (4.3) sejumlah iterasi tersebut.
 - Misalkan sebut hasil yang didapat dari *probabilistic relaxation* ini u_{ki}^s .
7. Penghitungan informasi spasial-kontekstual secara makro berdasar analisa klustering dengan citra aproksimasi wavelet:
- Lakukan dekomposisi wavelet ATWT (*à trous wavelet transform*) level 1 dengan menggunakan input M kanal hasil transformasi MNF pada langkah 4.
 - Ambil citra-citra aproksimasinya saja (M buah).
 - Lakukan klustering FMLE seperti pada langkah 5 dengan menggunakan input M buah citra aproksimasi tersebut.
 - Misalkan sebut hasil yang didapat dari klustering dengan citra aproksimasi wavelet ini dengan u_{ki}'' .
8. Fusi data:
- Hitung kriteria homogenitas dengan Rumus (4.8) dengan menggunakan citra span (Rumus 2.6), atau sebagai alternatif citra kanal pertama hasil MNF.

- Lakukan fusi bersyarat $u_k^{S'}$ (hasil tahap 6) dengan $u_k^{R'}$ (hasil tahap 7) dengan menggunakan Rumus (4.9), yakni:
 - Untuk area homogen, $u_k^{S''} = \frac{u_k^{S'} u_k^{R'}}{\sum_{k=1}^K u_k^{S'} u_k^{R'}}$
 - Untuk area tidak homogen tidak dilakukan perubahan ($u_k^{S''} = u_k^{S'}$)
- Misalkan sebut hasil yang didapat dari fusi ini $u_k^{S''}$.

9. Pengolahan akhir:

- Lakukan *Majority Filtering* (dengan ukuran jendela 3x3) terhadap $u_k^{S''}$ untuk lebih mengurangi efek “*salt-and-pepper*” yang mungkin masih tersisa dalam hasil klasifikasi tersebut.

Untuk menguji efektifitas metodologi yang diajukan tersebut, pada bab berikutnya akan dilakukan ujicoba menggunakan dua buah data polarimetrik-SAR seperti yang telah dijelaskan pada Bab 1.

BAB 6

UJICоба DAN ANALISA HASIL

Pada Bab 5 telah disampaikan metodologi penyelesaian masalah yang diusulkan dalam penelitian ini. Selanjutnya pada Bab 6 ini, metodologi yang diajukan tersebut akan diujicoba menggunakan dua buah data polarimetrik-SAR seperti yang telah dijelaskan pada Bab 1. Namun sebelum itu, dilakukan ujicoba menggunakan data citra buatan yang terutama dilakukan untuk mengujicoba efektifitas penyertaan informasi spasial-kontekstual berdasarkan analisa klustering dengan citra aproksimasi wavelet. Ini merupakan kelanjutan dari hasil ujicoba dengan informasi spasial-kontekstual berdasarkan *probabilistic relaxation* yang telah disampaikan pada Sub-bab 4.1.1. Selanjutnya dengan citra buatan tersebut akan diamati pula bagaimana pengaruh perbaikan apabila kedua informasi spasial-kontekstual tersebut diterapkan bersama. Parameter-parameter yang didapat dari hasil-hasil ujicoba dengan citra buatan tersebut juga dapat dipakai sebagai acuan pada waktu ujicoba dengan data polarimetrik-SAR yang sesungguhnya.

6.1 Ujicoba Lanjutan dan Analisa Hasil Menggunakan Data Citra Buatan

Ujicoba menggunakan data citra buatan ini merupakan kelanjutan dari ujicoba pada Sub-bab 4.1.1. Secara ringkas, pada bagian tersebut didapat kesimpulan bahwa penerapan informasi spasial-kontekstual berdasar *probabilistic relaxation* hanya mampu memperbaiki hasil klasifikasi pada skala mikro, dan justru berpotensi menurunkan kehomogenan apabila diterapkan pada kelas yang hasil dari identifikasi dan klasifikasi awal dengan informasi spektralnya saja kurang bagus. Selanjutnya, pada sub-bab ini eksperimen tersebut dilanjutkan dengan menyertakan informasi spasial-kontekstual secara makro berdasar analisa klustering dengan citra aproksimasi wavelet dan mengamati pengaruhnya apabila kedua informasi spasial-kontekstual tersebut kemudian diterapkan bersama.

Hasil eksperimen dengan menyertakan informasi spasial-kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet ditunjukkan pada Gambar 6.1. Hasil klasifikasi dengan citra aproksimasi saja (yang menjadi dasar

penghitungan informasi spasial-kontekstual metode kedua ini) ditunjukkan pada Gambar 6.1-b yang mana walaupun memberikan hasil yang homogen namun tidak mampu mempertahankan objek-objek kecil seperti garis-garis dan batas-batas objek pun menjadi rusak. Untuk area-area tersebut justru informasi spektral yang lebih mampu memberikan hasil yang lebih optimal. Hasil pengintegrasian (fusi) antara hasil klustering menggunakan citra aproksimasi (Gambar 6.1-b) dengan hasil klustering menggunakan informasi spektralnya saja (tanpa menggunakan kriteria homogenitas) ditunjukkan pada Gambar 6.1-c. Walaupun terjadi perbaikan dibandingkan dengan hasil informasi spektralnya saja (Gambar 6.1-a) namun pada objek-objek berukuran kecil dan pada batas-batas objek belum memberikan hasil yang benar (salah klasifikasi).

Apabila dalam pengintegrasian (fusi) tersebut diterapkan kriteria homogenitas seperti pada Gambar 6.1-d, 6.1-e, 6.1-f, 6.1-j, 6.1-k, dan 6.1-l yang masing-masing menggunakan kriteria homogenitas yang dihitung dengan ukuran jendela 3x3 (Gambar 6.1-g), 5x5 (Gambar 6.1-h), 7x7 (Gambar 6.1-i), 9x9 (Gambar 6.1-m), 11x11 (Gambar 6.1-n), dan 13x13 (Gambar 6.1-o), maka didapatkan hasil yang lebih bagus. Pada area yang sifatnya homogen akan didapatkan hasil yang homogen karena pada area tersebut informasi spasial-kontekstual dari hasil klustering dengan citra aproksimasi wavelet (Gambar 6.1-b) akan diperhitungkan. Sedangkan pada area seperti objek-objek yang berukuran kecil dan batas-batas objek tetap hanya menggunakan informasi spektralnya saja.

Ukuran jendela kriteria homogenitas cukup berpengaruh, apabila terlalu kecil maka banyak area yang sifatnya homogen yang seharusnya dapat disupport oleh informasi spasial-kontekstual menjadi tidak disupport. Namun di lain pihak, apabila ukuran jendela terlalu besar maka pada area sekitar batas-batas objek menjadi terlalu melebar (meluas) area yang tidak disupport oleh informasi spasial-kontekstual tersebut. Padahal sebetulnya area tersebut sudah bukan lagi termasuk batas-batas objek dan termasuk dalam kategori yang bisa disupport oleh informasi spasial-kontekstual metode kedua ini. Hal ini juga bisa dikonfirmasi dari turunnya kembali nilai akurasi apabila ukuran jendela tersebut diperbesar. Dari pengamatan hasil-hasil eksperimen, ukuran jendela kriteria homogenitas 5x5 atau 7x7 memberikan hasil yang paling optimal yang mana didapatkan peningkatan



a) Hasil klustering dengan informasi spektral saja (akurasi 81.72%)



b) Hasil klustering dengan informasi spektral citra aproksimasi wavelet A1WT saja, yang menjadi dasar informasi spasial kontekstual (akurasi 92.72%)



c) Informasi spektral + informasi spasial kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet (gambar b) tanpa kriteria homogenitas (akurasi 94.76%)




d) Informasi spektral + informasi spasial kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet (gambar b) dengan kriteria homogenitas 3x3 (akurasi 94.92%)




e) Informasi spektral + informasi spasial kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet (gambar b) dengan kriteria homogenitas 5x5 (akurasi 95.49%)




f) Informasi spektral + informasi spasial kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet (gambar b) dengan kriteria homogenitas 7x7 (akurasi 95.53%)



g) Kriteria homogenitas 3x3 yang dipakai pada data d) (putih: homogen, hitam: non-homogen)

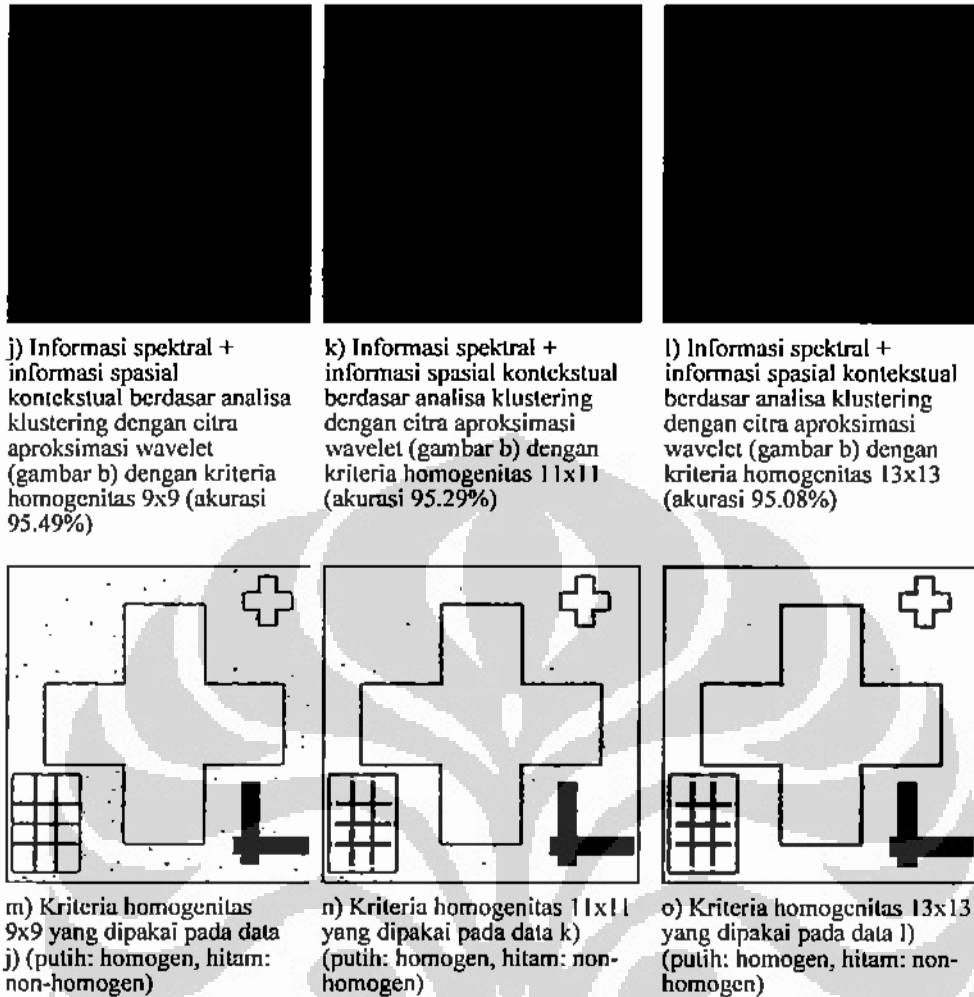


h) Kriteria homogenitas 5x5 yang dipakai pada data e) (putih: homogen, hitam: non-homogen)



i) Kriteria homogenitas 7x7 yang dipakai pada data f) (putih: homogen, hitam: non-homogen)

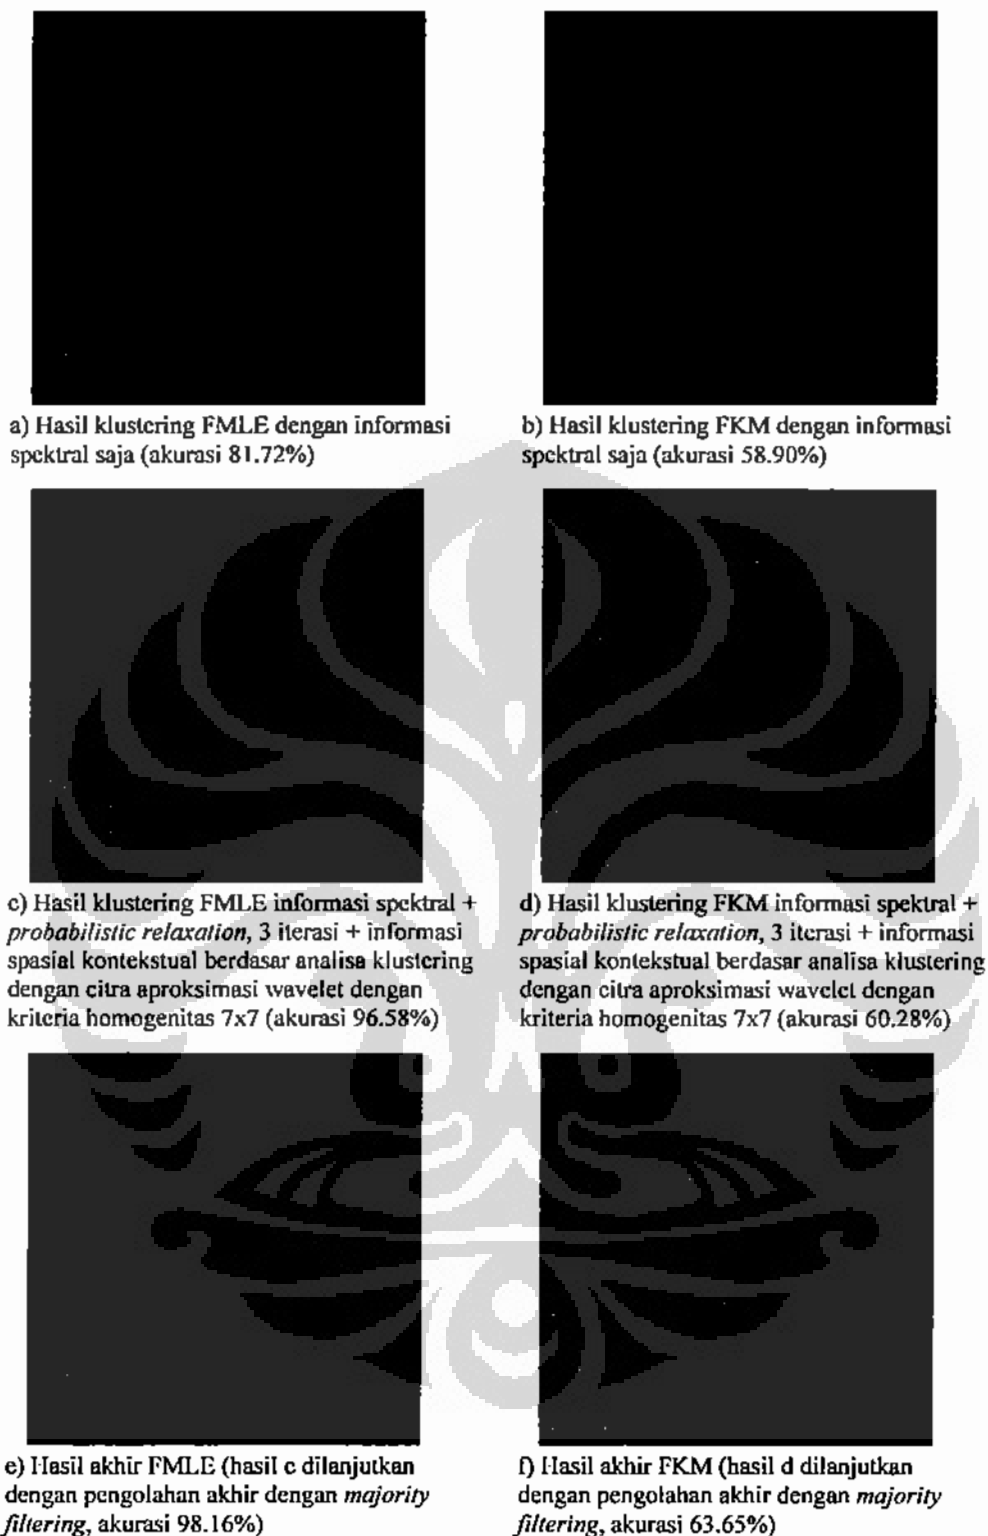
Gambar 6.1 Hasil klasifikasi dengan menggunakan citra buatan dan pengaruh penyertaan informasi spasial-kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet.



Gambar 6.1(sambungan) Hasil klasifikasi dengan menggunakan citra buatan dan pengaruh penyertaan informasi spasial-kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet.

akurasi tertinggi sekitar 13.8%.

Eksperimen selanjutnya dilakukan dengan menyertakan kedua informasi spasial-kontekstual tersebut. Hasil klasifikasi terbaik (lihat Gambar 6.2-c) didapatkan apabila kedua informasi spasial-kontekstual diterapkan yakni dengan *probabilistic relaxation* dengan 3 iterasi dan informasi spasial-kontekstual berdasarkan analisa klustering dengan citra aproksimasi wavelet diterapkan dengan ukuran jendela 7x7. Apabila kita bandingkan dengan hasil klustering menggunakan informasi spektralnya saja terjadi peningkatan yang sangat besar



Gambar 6.2 Perbandingan hasil klasifikasi FMLE dengan menggunakan citra buatan antara sebelum dan sesudah penyertaan kedua informasi spasial-kontekstual, serta sesudah dilakukan pengolahan akhir dengan *majority filtering*. (Hasil klasifikasi dengan FKM ditampilkan pula sebagai perbandingan)

yakni sekitar 14.9%. Terlihat di sini bahwa kedua informasi spasial-kontekstual tersebut saling bekerjasama untuk mensupport perbaikan (kehomogenan) hasil klasifikasi. Informasi spasial-kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet berkontribusi dalam meningkatkan kehomogenan pada hasil klasifikasi di seluruh area secara global kecuali pada area yang bersifat tidak homogen (seperti pada batas-batas antar objek dan struktur-struktur atau objek-objek tutupan lahan yang berukuran kecil). Sedangkan pada area sekitar batas objek atau objek yang berukuran kecil tersebut (yang tidak disupport oleh tinjauan makro), akan disupport perbaikannya oleh informasi spasial-kontekstual berdasar *probabilistic relaxation* (disupport oleh tinjauan mikro).

Selanjutnya, apabila dari hasil pengintegrasian (fusi) tersebut diterapkan pengolahan akhir dengan *majority filtering*, maka masih dapat ditingkatkan kembali dalam kisaran 1.58% menjadi 98.16% seperti yang ditunjukkan pada Gambar 6.2-e. (Daftar nilai akurasi hasil klasifikasi dengan menggunakan data citra buatan ini selengkapnya ditunjukkan pada Tabel 6.1.)

Dari hasil akhir klasifikasi FMLE pada Gambar 6.2-e tersebut, masih tersisa sekitar 1.84% lagi untuk mencapai hasil sempurna 100%. Apabila diamati secara detail, kesalahan tersebut terjadi sebagian besar pada kelas "merah" dan sebagian lainnya pada batas-batas objek. Pada area yang salah klasifikasi tersebut (yang sebagian besar berupa kumpulan atau gerombolan beberapa piksel yang salah klasifikasi), terlihat bahwa baik hasil klustering dengan informasi spektral saja maupun hasil klustering menggunakan citra aproksimasi wavelet keduanya memberikan informasi pengkelasan yang salah sehingga sulit untuk dikoreksi menjadi kelas yang benar.

Sebagai perbandingan, pada Gambar 6.2 sebelah kanan juga ditunjukkan hasil klasifikasi apabila digunakan algoritma klustering *fuzzy K-means* (FKM). Dari hasil tersebut dan keseluruhan hasil-hasil dengan FKM lainnya seperti yang ditunjukkan pada Tabel 6.1, terlihat bahwa algoritma klustering FMLE secara konsisten memberikan performansi yang lebih bagus dibandingkan algoritma FKM. Seperti misalnya, kelas "merah" dan kelas "hijau" dapat teridentifikasi dengan jelas dengan menggunakan FMLE, sedangkan algoritma FKM kurang mampu mengidentifikasinya secara jelas perbedaan kelas-kelas tersebut.

Tabel 6.1 Daftar nilai akurasi hasil klasifikasi dengan menggunakan data citra buatan.

| Cara penerapan informasi spasial kontekstual berdasar <i>probabilitistic relaxation</i> | Cara penerapan informasi spasial kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet | Hasil dengan FMLE | | Hasil dengan FKM |
|---|---|----------------------------|------------------------------|------------------------------|
| | | Tanpa pengolahan akhir (%) | Setelah pengolahan akhir (%) | Setelah pengolahan akhir (%) |
| Tidak diterapkan | Tidak diterapkan (berarti hanya hasil klustering dengan informasi spektral saja) | 81.72 | 85.56 | 58.90 |
| | Diterapkan tanpa kriteria homogenitas | 94.76 | 96.14 | 59.27 |
| | Kriteria homogenitas 3x3 | 94.92 | 96.79 | 58.41 |
| | Kriteria homogenitas 5x5 | 95.49 | 97.14 | 58.79 |
| | Kriteria homogenitas 7x7 | 95.53 | 97.10 | 58.87 |
| | Kriteria homogenitas 9x9 | 95.49 | 97.05 | 58.78 |
| | Kriteria homogenitas 11x11 | 95.29 | 96.88 | 58.69 |
| | Kriteria homogenitas 13x13 | 95.08 | 96.71 | 58.61 |
| Diterapkan 1x iterasi | Tidak diterapkan | 86.89 | 92.66 | 61.54 |
| | Diterapkan tanpa kriteria homogenitas | 95.22 | 97.03 | 60.66 |
| | Kriteria homogenitas 3x3 | 95.69 | 97.97 | 59.72 |
| | Kriteria homogenitas 5x5 | 96.15 | 98.12 | 60.10 |
| | Kriteria homogenitas 7x7 | 96.18 | 98.11 | 60.20 |
| | Kriteria homogenitas 9x9 | 96.14 | 98.06 | 60.11 |
| | Kriteria homogenitas 11x11 | 95.98 | 98.12 | 59.99 |
| | Kriteria homogenitas 13x13 | 95.84 | 98.05 | 59.89 |
| Diterapkan 2x iterasi | Tidak diterapkan | 89.94 | 93.79 | 61.68 |
| | Diterapkan tanpa kriteria homogenitas | 95.43 | 97.08 | 62.33 |
| | Kriteria homogenitas 3x3 | 96.09 | 97.78 | 61.34 |
| | Kriteria homogenitas 5x5 | 96.48 | 98.14 | 61.73 |
| | Kriteria homogenitas 7x7 | 96.49 | 98.15 | 61.84 |
| | Kriteria homogenitas 9x9 | 96.44 | 98.06 | 61.73 |
| | Kriteria homogenitas 11x11 | 96.31 | 98.11 | 61.61 |
| | Kriteria homogenitas 13x13 | 96.21 | 98.04 | 61.48 |
| Diterapkan 3x iterasi | Tidak diterapkan | 91.51 | 94.06 | 61.62 |
| | Diterapkan tanpa kriteria homogenitas | 95.46 | 97.21 | 64.17 |
| | Kriteria homogenitas 3x3 | 96.21 | 97.89 | 63.14 |
| | Kriteria homogenitas 5x5 | 96.58 | 98.15 | 63.54 |
| | Kriteria homogenitas 7x7 | 96.58 | 98.16 | 63.65 |
| | Kriteria homogenitas 9x9 | 96.51 | 98.08 | 63.53 |
| | Kriteria homogenitas 11x11 | 96.39 | 97.95 | 63.39 |
| | Kriteria homogenitas 13x13 | 96.31 | 97.89 | 63.25 |

Tabel 6.1(sambungan) Daftar nilai akurasi hasil klasifikasi dengan menggunakan data citra buatan.

| Cara penerapan informasi spasial kontekstual berdasar <i>probabilistic relaxation</i> | Cara penerapan informasi spasial kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet | Hasil dengan FMLE | | Hasil dengan FKM |
|---|---|----------------------------|------------------------------|------------------------------|
| | | Tanpa pengolahan akhir (%) | Setelah pengolahan akhir (%) | Setelah pengolahan akhir (%) |
| Diterapkan 4x iterasi | Tidak diterapkan | 92.16 | 93.95 | 61.80 |
| | Diterapkan tanpa kriteria homogenitas | 95.35 | 96.74 | 65.93 |
| | Kriteria homogenitas 3x3 | 96.13 | 97.61 | 64.92 |
| | Kriteria homogenitas 5x5 | 96.48 | 97.83 | 65.30 |
| | Kriteria homogenitas 7x7 | 96.48 | 97.87 | 65.39 |
| | Kriteria homogenitas 9x9 | 96.40 | 97.78 | 65.27 |
| | Kriteria homogenitas 11x11 | 96.27 | 97.64 | 65.11 |
| | Kriteria homogenitas 13x13 | 96.21 | 97.58 | 64.97 |
| Diterapkan 5x iterasi | Tidak diterapkan | 92.37 | 93.67 | 62.41 |
| | Diterapkan tanpa kriteria homogenitas | 95.11 | 96.36 | 67.42 |
| | Kriteria homogenitas 3x3 | 95.89 | 97.20 | 66.48 |
| | Kriteria homogenitas 5x5 | 96.23 | 97.47 | 66.84 |
| | Kriteria homogenitas 7x7 | 96.23 | 97.46 | 66.90 |
| | Kriteria homogenitas 9x9 | 96.15 | 97.36 | 66.77 |
| | Kriteria homogenitas 11x11 | 96.02 | 97.21 | 66.63 |
| | Kriteria homogenitas 13x13 | 95.96 | 97.16 | 66.49 |
| Diterapkan 6x iterasi | Tidak diterapkan | 92.32 | 93.29 | 62.55 |
| | Diterapkan tanpa kriteria homogenitas | 94.79 | 95.87 | 67.63 |
| | Kriteria homogenitas 3x3 | 95.55 | 97.70 | 66.80 |
| | Kriteria homogenitas 5x5 | 95.89 | 96.97 | 66.91 |
| | Kriteria homogenitas 7x7 | 95.90 | 96.96 | 66.95 |
| | Kriteria homogenitas 9x9 | 95.81 | 96.85 | 66.83 |
| | Kriteria homogenitas 11x11 | 95.68 | 96.71 | 66.79 |
| | Kriteria homogenitas 13x13 | 95.62 | 96.65 | 66.78 |

6.2 Ujicoba dan Analisa Hasil Menggunakan Data Polarimetrik E-SAR Daerah Penajam, Kalimantan Timur

Ujicoba selanjutnya adalah ujicoba menggunakan data polarimetrik-SAR yang sesungguhnya. Pada ujicoba yang kedua ini digunakan data polarimetrik E-SAR daerah Penajam, Kalimantan Timur. Fitur input yang akan digunakan terutama adalah 4 kanal hasil dari pereduksian fitur berdasar transformasi MNF seperti yang telah ditunjukkan pada Gambar 2.14. Namun demikian, untuk mendapatkan pemahaman yang lebih menyeluruh mengenai pengaruh masing-

masing metode pengekstraksian fitur maupun efektifitas pengaplikasian metode pereduksian fitur berdasarkan transformasi MNF, dilakukan beberapa eksperimen dengan menggunakan lima dataset sebagai berikut :

- 1) Dataset yang berisi 9 fitur parameter polarimetrik dari elemen matriks kovarian polarimetrik (Gambar 2.5)
- 2) Dataset yang berisi 3 fitur hasil dekomposisi polarimetrik Cloude (Gambar 2.10)
- 3) Dataset yang berisi 12 fitur gabungan dataset 1) dan dataset 2)
- 4) Dataset yang berisi hasil pengaplikasian transformasi MNF atas dataset 3) (terdiri atas 4 fitur, yakni empat kanal MNF pertama seperti yang ditunjukkan pada Gambar 2.14)
- 5) Dataset yang berisi hanya 1 fitur intensitas HH (Gambar 2.5-a).

Dataset 5 disertakan pula dalam eksperimen dengan tujuan untuk melihat potensi keunggulan data polarimetrik-SAR dibandingkan dengan data SAR konvensional (yang berpolarisasi tunggal). Dalam penelitian ini, tidak tersedia data satelit SAR lainnya yang berpolarisasi tunggal. Oleh karena itu, eksperimen dengan hanya menggunakan salah satu data polarisasi saja (dalam hal ini digunakan hanya polarisasi HH) yang merupakan bagian dari data polarimetrik-SAR tersebut dapat dianalogikan dengan eksperimen menggunakan data SAR konvensional yang berpolarisasi tunggal.

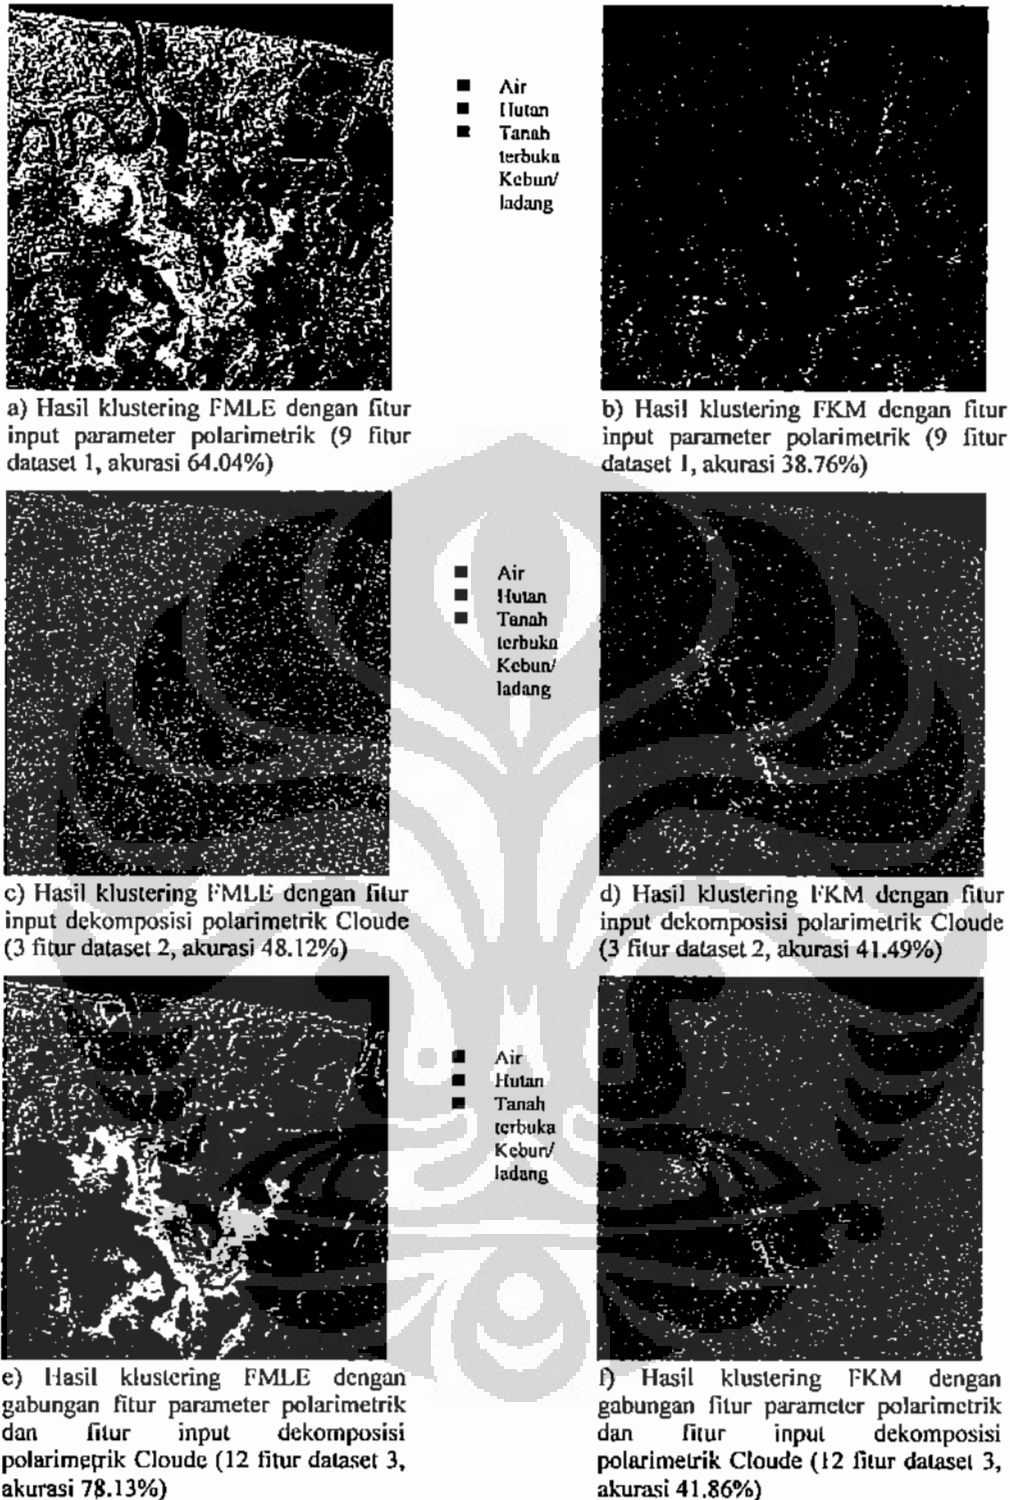
Lima dataset tersebut kemudian digunakan sebagai input untuk klasifier FMLE. Dalam eksperimen-eksperimen yang dilakukan, evaluasi hasil klasifikasi dilakukan baik dengan pengamatan secara visual atas hasil-hasil klasifikasi tersebut maupun dengan penghitungan nilai akurasi hasil klasifikasi. Nilai tersebut dihitung berdasarkan persentase jumlah piksel yang terklasifikasi secara benar oleh klasifier sesuai dengan area sampel yang telah ditentukan berdasarkan informasi lapangan seperti yang ditunjukkan pada Gambar 1.3.

Pertama-tama, eksperimen dilakukan dengan tanpa menyertakan informasi spasial-kontekstualnya. Hasil-hasil klasifikasi dengan menggunakan dataset 1, dataset 2, dataset 3, dataset 4, dan dataset 5 masing-masing ditunjukkan pada Gambar 6.3-a, 6.3-c, 6.3-e, 6.3-g, dan 6.3-i. Dengan mengamati hasil-hasil tersebut, dapat disimpulkan bahwa fitur parameter polarimetrik saja (dataset 1)


memberikan hasil yang lumayan, namun dengan banyak dijumpai salah klasifikasi diantara kelas hutan, ladang, dan tanah terbuka. Seperti misalnya, area tanah terbuka pada sebelah tengah dan kanan atas dari citra yang banyak mengalami salah klasifikasi sebagai hutan. Di lain pihak, fitur dekomposisi polarimetrik Cloude (dataset 2) dapat membedakan secara lebih akurat area tanah terbuka tersebut dan secara umum memberikan peningkatan kemampuan pembedaan diantara area hutan (yang lebih bersifat *volume scattering* dengan nilai *entropy* yang tinggi) dan area non-hutan (yang lebih bersifat *surface/single-bounce scattering* dengan nilai *entropy* yang relatif rendah). Dengan menggabungkan dua dataset tersebut menjadi dataset 3, kemampuan pembedaan antara beberapa tipe tutupan lahan dapat lebih ditingkatkan, sehingga memberikan hasil klasifikasi yang lebih baik (Gambar 6.3-e, dengan akurasi 78.13%) dibandingkan hanya menggunakan dataset masing-masing metode pengekstraksian fitur.

Pada Gambar 6.3-g ditunjukkan hasil klasifikasi menggunakan dataset yang telah tereduksi menjadi 4 fitur dari hasil MNF (dataset 4). Apabila hasil klasifikasi 6.3-e dan 6.3-g dibandingkan, terlihat jelas bahwa meskipun dimensi dari fitur input diturunkan (dari 12 fitur menjadi 4 fitur) tidak terjadi penurunan yang signifikan pada hasil klasifikasinya (akurasi turun sekitar 0.74%) Bahkan, perlu diperhatikan bahwa hasil yang diperoleh dari dataset fitur yang tereduksi ini memberikan hasil klasifikasi yang mengandung efek "*salt-and-pepper*" yang lebih sedikit dibandingkan hasil klasifikasi dengan menggunakan dataset fitur yang komplet (dataset 3). Hal ini menunjukkan bahwa transformasi MNF yang dipergunakan dalam penelitian ini tidak hanya efektif untuk mereduksi fitur dari dataset komplet namun lebih jauh juga bermanfaat untuk mereduksi noise speckle.

Sebagai perbandingan, hasil-hasil klasifikasi menggunakan *fuzzy K-means* (FKM) juga ditunjukkan pada Gambar 6.3-b, 6.3-d, 6.3-f, dan 6.3-h. Pada seluruh dataset didapatkan kesimpulan bahwa FMLE secara konsisten memberikan hasil yang lebih baik dibandingkan dengan FKM (rata-rata selisihnya adalah 23.8%). Kesalahan-kesalahan klasifikasi diantara hutan, kebun/ladang, perairan, dan tanah terbuka banyak terjadi pada hasil FKM. Secara jelas, FKM terutama tidak dapat mengidentifikasi secara akurat perbedaan antara kelas kebun/ladang dan kelas perairan.




Gambar 6.3 Hasil klasifikasi FMLE menggunakan data polarimetrik E-SAR dengan fitur input parameter polarimetrik, dekomposisi polarimetrik, gabungan parameter polarimetrik dan dekomposisi polarimetrik, 4 kanal hasil pereduksian fitur dengan MNF, dan fitur input data polarisasi tunggal. (Hasil klasifikasi FKM ditunjukkan pula sebagai perbandingan)




- Air
- Hutan
- Tanah terbuka
- Kebun/ladang

g) Hasil klustering FMLE dengan fitur input 4 kanal hasil reduksi fitur dengan transformasi MNF (4 fitur dataset 4, akurasi 77.39%)



h) Hasil klustering FKM dengan fitur input 4 kanal hasil reduksi fitur dengan transformasi MNF (4 fitur dataset 4, akurasi 51.36%)



- Air
- Hutan
- Tanah terbuka
- Kebun/ladang

i) Hasil klustering FMLE dengan fitur input data polarisasi tunggal (1 fitur dataset 5, akurasi 56.65%)



j) Hasil klustering FKM dengan fitur input data polarisasi tunggal (1 fitur dataset 5, akurasi 31.70%)


Gambar 6.3(sambungan) Hasil klasifikasi FMLE menggunakan data polarimetrik E-SAR dengan fitur input parameter polarimetrik, dekomposisi polarimetrik, gabungan parameter polarimetrik dan dekomposisi polarimetrik, 4 kanal hasil reduksi fitur dengan transformasi MNF, dan fitur input data polarisasi tunggal. (Hasil klasifikasi FKM ditunjukkan pula sebagai perbandingan)

Pada Gambar 6.3-i ditunjukkan hasil klasifikasi FMLE menggunakan dataset 5 yakni apabila hanya digunakan data SAR konvensional berpolarisasi tunggal. Sedangkan pada Gambar 6.3-j ditunjukkan hasil klasifikasi apabila menggunakan FKM. Apabila dibandingkan dengan hasil menggunakan keempat dataset polarimetrik sebelumnya, dapat diperoleh kesimpulan bahwa potensi data polarimetrik-SAR untuk membedakan berbagai objek tutupan lahan jauh lebih baik bila dibandingkan dengan data SAR konvensional berpolarisasi tunggal.


Eksperimen selanjutnya dilakukan dengan menyertakan informasi spasial-kontekstual berdasarkan *probabilistic relaxation*. Hasil pengaplikasian *probabilistic relaxation* dengan jumlah iterasi 1, 2, 3, 4, dan 6 ditunjukkan masing-masing pada Gambar 6.4-b, 6.4-c, 6.4-d, 6.4-e dan 6.4-f. Dalam hal ini ditampilkan hanya hasil dari dataset 4, dan untuk lebih memperjelas hasilnya ditampilkan hanya seperempat bagian kiri atas dari keseluruhan hasil klasifikasi. Apabila dibandingkan dengan Gambar 6.4-a, hasil yang diperoleh terlihat lebih homogen, namun demikian tingkat perbaikannya masih sangat kecil. Hasil klasifikasi menjadi lebih homogen (efek "*salt-and-pepper*" lebih berkurang) dengan semakin bertambahnya jumlah iterasi.

Apabila diperhatikan secara lebih detail, pada semua kelas terjadi peningkatan homogenitas walaupun pada tingkatan yang berbeda-beda. Kelas "air" merupakan kelas yang paling meningkat homogenitasnya, disusul kelas "hutan" dan kelas "kebun/ladang". Walaupun kelas "tanah terbuka" merupakan kelas yang paling kecil terjadi peningkatan homogenitasnya, namun tidak terjadi penurunan homogenitas seperti pada kelas "merah" dalam eksperimen pertama menggunakan data citra buatan. Hal ini juga dapat dikonfirmasi dari hasil penghitungan *compatibility coefficient* untuk keempat kelas tersebut seperti yang ditunjukkan pada Gambar 6.5. Nilai *compatibility coefficient* untuk piksel berkelas "tanah terbuka" dengan piksel tetangganya juga berkelas "tanah terbuka" masih cukup tinggi yakni bernilai 0.683. Sehingga dalam proses pengaplikasian *probabilistic relaxation* secara iteratif, apabila terdapat suatu piksel yang terisolasi diantara piksel-piksel tetangganya yang telah berkelas "tanah terbuka", masih terbuka kemungkinannya untuk dikoreksi menjadi kelas "tanah terbuka" juga.


Selanjutnya, hasil eksperimen dengan menyertakan informasi spasial-kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet ditunjukkan pada Gambar 6.6. Hasil klasifikasi dengan citra aproksimasi saja (yang menjadi dasar penghitungan informasi spasial-kontekstual metode kedua ini) ditunjukkan pada Gambar 6.6-b yang mana walaupun memberikan hasil yang homogen namun tidak mampu mempertahankan objek-objek kecil seperti garis-garis dan batas-batas objek pun menjadi rusak. Sama halnya dengan hasil eksperimen dengan menggunakan data citra buatan, untuk




a) Hasil klustering dengan informasi spektral saja (akurasi 77.39%)




b) Informasi spektral + *probabilistic relaxation*, 1 iterasi (akurasi 78.67%)




c) Informasi spektral + *probabilistic relaxation*, 2 iterasi (akurasi 79.50%)



d) Informasi spektral + *probabilistic relaxation*, 3 iterasi (akurasi 80.23%)



e) Informasi spektral + *probabilistic relaxation*, 4 iterasi (akurasi 80.93%)



f) Informasi spektral + *probabilistic relaxation*, 6 iterasi (akurasi 81.74%)

Gambar 6.4 Hasil klasifikasi FMLE menggunakan data polarimetrik E-SAR dengan fitur input 4 kanal hasil reduksi fitur dengan transformasi MNF (dataset 4) dan pengaruh penyertaan informasi spasial-kontekstual berdasar *probabilistic relaxation*.

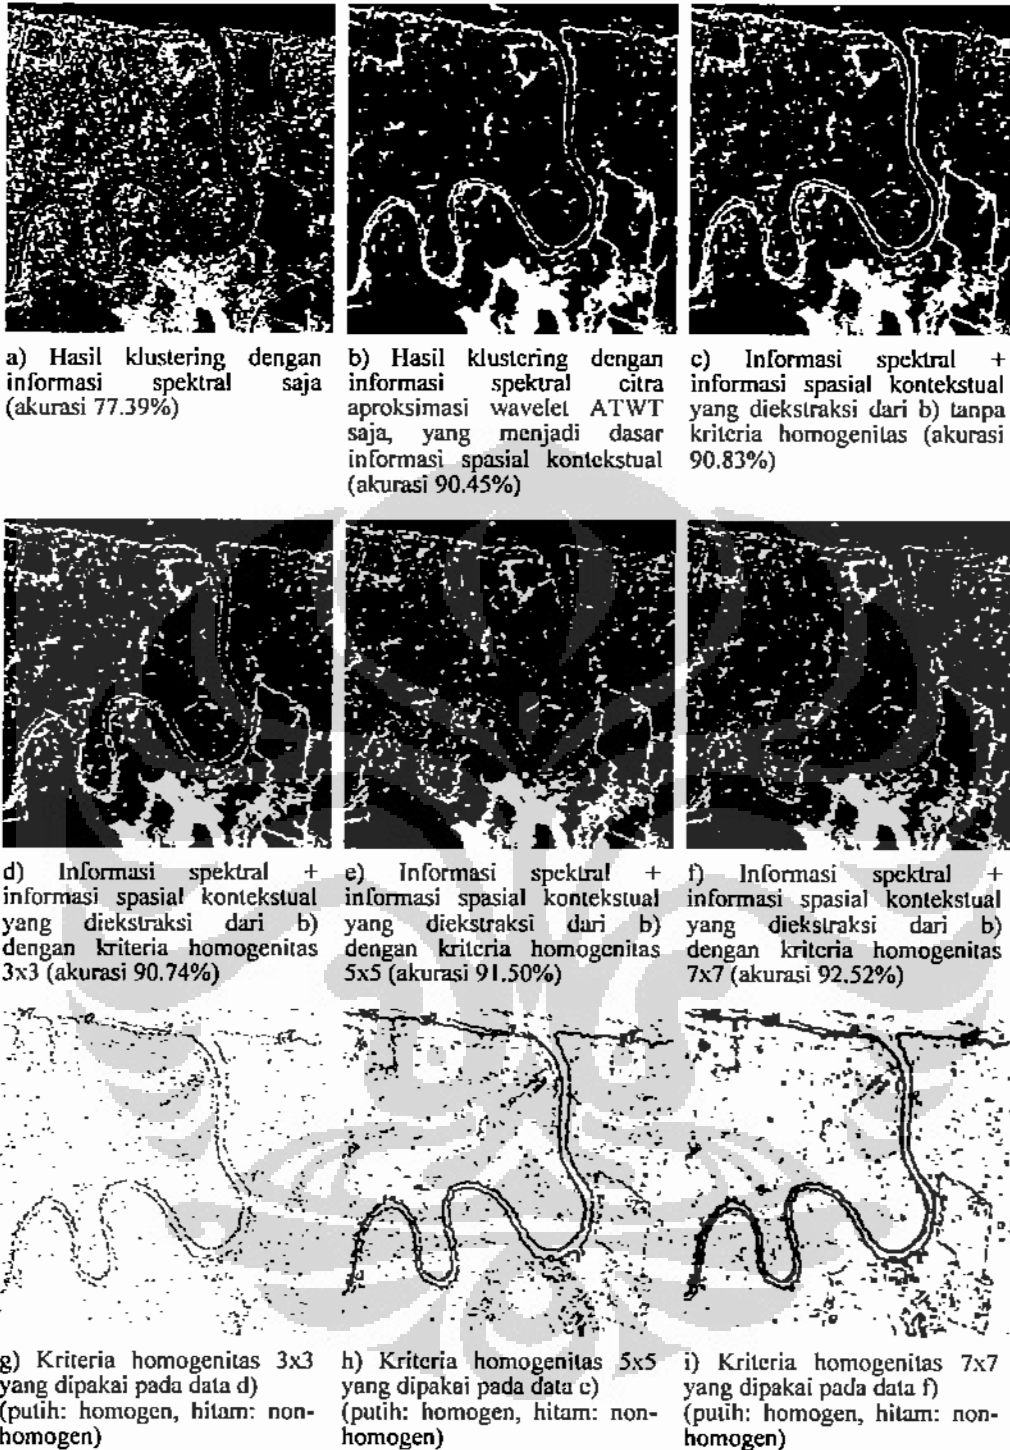
$$\begin{aligned}
 & \begin{bmatrix} P(x,k = \text{air} | y,r = \text{air}) & P(x,k = \text{air} | y,r = \text{hutan}) & P(x,k = \text{air} | y,r = \text{tanah}) & P(x,k = \text{air} | y,r = \text{kebun}) \\ P(x,k = \text{hutan} | y,r = \text{air}) & P(x,k = \text{hutan} | y,r = \text{hutan}) & P(x,k = \text{hutan} | y,r = \text{tanah}) & P(x,k = \text{hutan} | y,r = \text{kebun}) \\ P(x,k = \text{tanah} | y,r = \text{air}) & P(x,k = \text{tanah} | y,r = \text{hutan}) & P(x,k = \text{tanah} | y,r = \text{tanah}) & P(x,k = \text{tanah} | y,r = \text{kebun}) \\ P(x,k = \text{kebun} | y,r = \text{air}) & P(x,k = \text{kebun} | y,r = \text{hutan}) & P(x,k = \text{kebun} | y,r = \text{tanah}) & P(x,k = \text{kebun} | y,r = \text{kebun}) \end{bmatrix} \\
 & = \begin{bmatrix} 0.936 & 0.001 & 0.002 & 0.061 \\ 0 & 0.790 & 0.113 & 0.097 \\ 0.002 & 0.288 & 0.683 & 0.027 \\ 0.026 & 0.187 & 0.018 & 0.769 \end{bmatrix}
 \end{aligned}$$

- Contoh: $P(x,k = \text{kebun} | y,r = \text{air})$ merupakan *compatibility coefficient* untuk piksel tersebut berkelas "kebun" sedangkan piksel tetangganya berkelas "air".

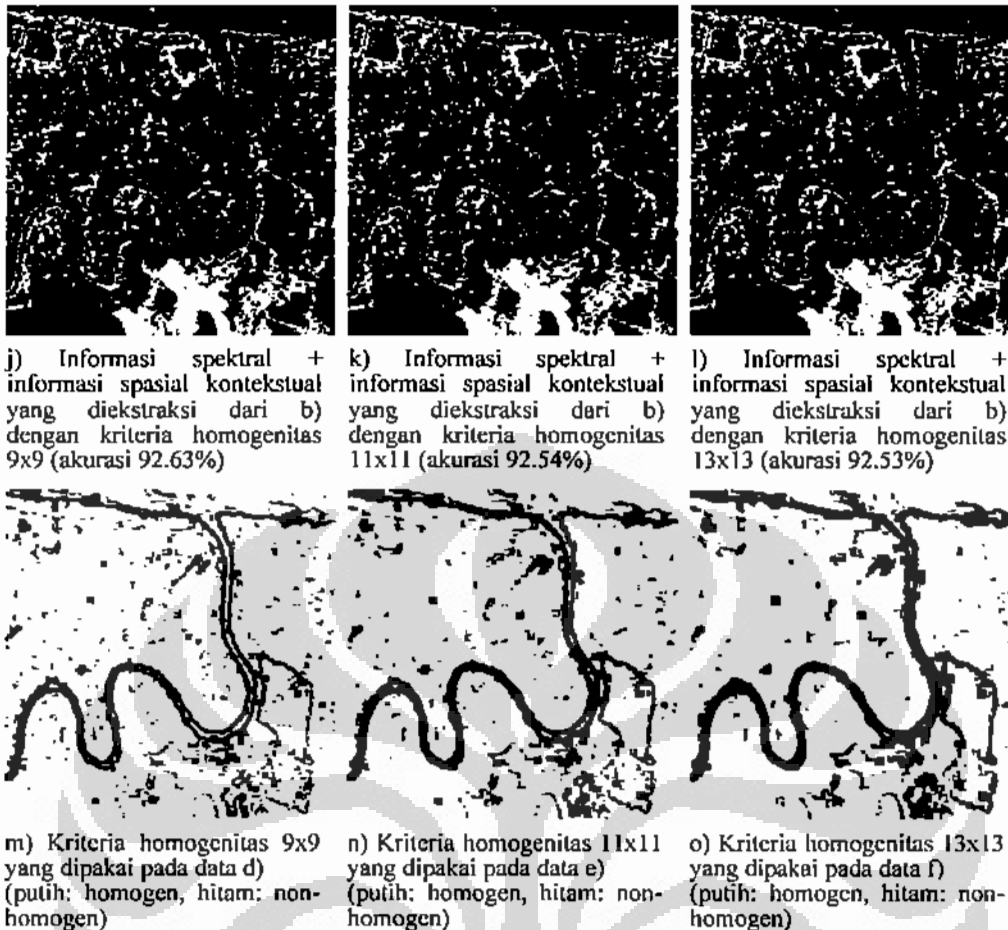
Gambar 6.5 Hasil penghitungan *compatibility coefficient* dari hasil klustering FMLE dengan informasi spektral data polarimetrik E-SAR yang digunakan sebagai dasar penghitungan informasi spasial-kontekstual berdasar *probabilistic relaxation*.

area-area tersebut justru informasi spektral yang lebih mampu memberikan hasil yang lebih optimal. Hasil pengintegrasian (fusi) informasi spasial-kontekstual untuk metode kedua ini dengan hasil klustering dengan informasi spektralnya saja (tanpa menggunakan kriteria homogenitas) ditunjukkan pada Gambar 6.6-c. Walaupun terjadi perbaikan dibandingkan dengan hasil informasi spektralnya saja (Gambar 6.6-a) namun pada objek-objek berukuran kecil dan pada batas-batas objek belum memberikan hasil yang benar (salah klasifikasi). Kemudian apabila dalam pengintegrasian tersebut diterapkan kriteria homogenitas seperti pada Gambar 6.6-d, 6.6-e, 6.6-f, 6.6-j, 6.6-k, dan 6.6-l yang masing-masing menggunakan kriteria homogenitas yang dihitung dengan ukuran jendela 3x3 (Gambar 6.6-g), 5x5 (Gambar 6.6-h), 7x7 (Gambar 6.6-i), 9x9 (Gambar 6.6-m), 11x11 (Gambar 6.6-n), dan 13x13 (Gambar 6.6-o), maka didapatkan hasil yang lebih bagus. Pada area yang homogen akan didapatkan hasil yang homogen karena pada area tersebut informasi spasial-kontekstual dari hasil klustering dengan citra aproksimasi wavelet (Gambar 6.6-b) akan diperhitungkan. Sedangkan pada area objek (struktur) yang berukuran kecil dan batas-batas objek tetap hanya menggunakan informasi spektralnya saja.

Ukuran jendela kriteria homogenitas cukup berpengaruh, apabila terlalu kecil maka banyak area yang sifatnya homogen yang seharusnya dapat disupport oleh informasi spasial-kontekstual menjadi tidak disupport. Namun di lain pihak,



Gambar 6.6 Hasil klasifikasi FMLE menggunakan data polarimetrik E-SAR dengan fitur input 4 kanal hasil reduksian fitur dengan transformasi MNF (dataset 4) dan pengaruh penyertaan informasi spasial-kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet.

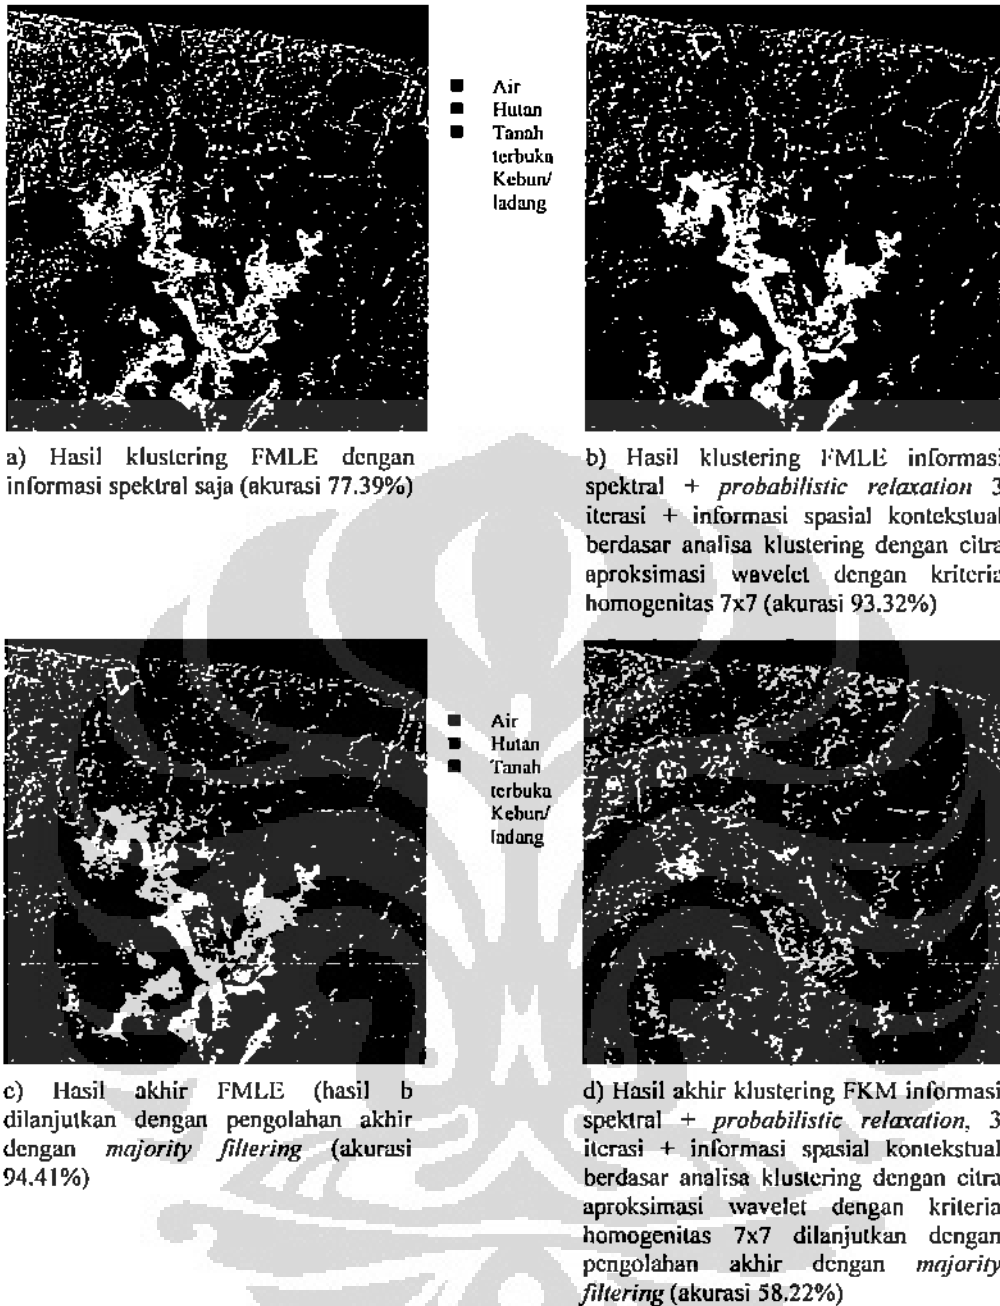


Gambar 6.6(sambungan) Hasil klasifikasi FMLE menggunakan data polarimetrik E-SAR dengan fitur input 4 kanal hasil pereduksian fitur dengan transformasi MNF (dataset 4) dan pengaruh penyertaan informasi spasial-kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet.

apabila ukuran jendela terlalu besar, maka pada area sekitar batas-batas objek menjadi terlalu melebar (meluas) area yang tidak disupport oleh informasi spasial-kontekstual tersebut. Padahal sebetulnya area tersebut sudah bukan lagi termasuk batas-batas objek dan termasuk dalam kategori yang bisa disupport oleh informasi spasial-kontekstual metode kedua ini. Hal ini juga bisa dikonfirmasi dari turunnya kembali nilai akurasi apabila ukuran jendela tersebut diperbesar. Dari pengamatan hasil-hasil eksperimen, ukuran jendela 7x7 atau 9x9 memberikan hasil yang paling optimal yang mana didapatkan peningkatan akurasi tertinggi sekitar 15.2%.

Eksperimen selanjutnya dilakukan dengan menyertakan kedua informasi spasial-kontekstual tersebut. Hasil klasifikasi terbaik (lihat Gambar 6.7-b) didapatkan apabila kedua informasi spasial-kontekstual diterapkan yakni dengan *probabilistic relaxation* dengan 3 iterasi dan informasi spasial-kontekstual berdasarkan analisa klustering dengan citra aproksimasi wavelet diterapkan dengan ukuran jendela 7x7. Apabila dibandingkan dengan hasil klustering menggunakan informasi spektralnya saja terjadi peningkatan yang besar yakni sekitar 15.9%. Sama halnya dengan ujicoba dengan citra buatan, terlihat di sini bahwa kedua informasi spasial-kontekstual tersebut saling bekerjasama untuk mensupport perbaikan (kehomogenan) hasil klasifikasi (masing-masing memperbaiki secara tinjauan makro dan mikro). Selanjutnya, apabila dari hasil pengintegrasian tersebut diterapkan pengolahan akhir dengan *majority filtering*, maka masih dapat ditingkatkan kembali dalam kisaran 1.1% menjadi 94.41% seperti yang ditunjukkan pada Gambar 6.7-c.

Sebagai perbandingan, pada Gambar 6.7-d juga ditunjukkan hasil klasifikasi apabila digunakan algoritma klustering FKM. Dari hasil tersebut dan keseluruhan hasil-hasil dengan FKM lainnya seperti yang ditunjukkan pada Tabel 6.2, terlihat bahwa algoritma klustering FMLE secara konsisten memberikan performansi yang lebih bagus dibandingkan algoritma FKM. Kesalahan-kesalahan klasifikasi diantara hutan, ladang, perairan, dan tanah terbuka banyak terjadi pada hasil FKM. Secara jelas, FKM tidak dapat membedakan dengan baik antara kelas ladang dengan kelas air. Nilai akurasi, berada jauh di bawah 36% bila dibandingkan dengan FMLE yakni 58.22% (perbandingan nilai-nilai akurasi selengkapnya ditunjukkan pada Tabel 6.2). Dengan demikian dapat disimpulkan bahwa algoritma klustering FMLE yang mampu membentuk kluster-kluster yang berbentuk elips dalam berbagai arahnya adalah lebih sesuai untuk pembentukan batas-batas kelas dari ruang fitur-fitur data polarimetrik-SAR yang dipakai dalam penelitian ini dibandingkan dengan algoritma klustering *fuzzy K-means* yang standar (yang hanya mampu membentuk kluster-kluster yang berbentuk lingkaran).



Gambar 6.7 Perbandingan hasil klasifikasi FMLE (menggunakan data polarimetrik E-SAR dengan fitur input 4 kanal hasil pereduksian fitur dengan transformasi MNF) antara sebelum dan sesudah penyertaan kedua informasi spasial-kontekstual, serta sesudah dilakukan pengolahan akhir dengan *majority filtering*. (Hasil klasifikasi dengan FKM ditampilkan pula sebagai perbandingan)

Tabel 6.2 Daftar nilai akurasi hasil klasifikasi menggunakan data polarimetrik E-SAR dengan fitur input 4 kanal hasil pereduksian fitur dengan transformasi MNF.

| Cara penerapan informasi spasial kontekstual berdasar <i>probabilistic relaxation</i> | Cara penerapan informasi spasial kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet | Hasil dengan FMLE | | Hasil dengan FKM |
|---|---|----------------------------|------------------------------|------------------------------|
| | | Tanpa pengolahan akhir (%) | Setelah pengolahan akhir (%) | Setelah pengolahan akhir (%) |
| Tidak diterapkan | Tidak diterapkan (berarti hanya hasil klustering dengan informasi spektral saja) | 77.39 | 79.13 | 52.24 |
| | Diterapkan tanpa kriteria homogenitas | 90.83 | 92.49 | 61.56 |
| | Kriteria homogenitas 3x3 | 90.74 | 92.26 | 61.56 |
| | Kriteria homogenitas 5x5 | 91.50 | 93.01 | 61.56 |
| | Kriteria homogenitas 7x7 | 92.52 | 94.18 | 61.46 |
| | Kriteria homogenitas 9x9 | 92.63 | 94.08 | 61.32 |
| | Kriteria homogenitas 11x11 | 92.54 | 93.91 | 61.27 |
| | Kriteria homogenitas 13x13 | 92.53 | 93.98 | 61.27 |
| Diterapkan 1x iterasi | Tidak diterapkan | 78.67 | 79.91 | 52.71 |
| | Diterapkan tanpa kriteria homogenitas | 91.39 | 92.49 | 60.50 |
| | Kriteria homogenitas 3x3 | 91.31 | 92.55 | 60.52 |
| | Kriteria homogenitas 5x5 | 92.02 | 93.26 | 60.52 |
| | Kriteria homogenitas 7x7 | 93.02 | 94.39 | 60.45 |
| | Kriteria homogenitas 9x9 | 93.21 | 94.35 | 60.38 |
| | Kriteria homogenitas 11x11 | 93.03 | 96.76 | 60.33 |
| | Kriteria homogenitas 13x13 | 92.95 | 94.07 | 60.32 |
| Diterapkan 2x iterasi | Tidak diterapkan | 79.50 | 80.53 | 52.89 |
| | Diterapkan tanpa kriteria homogenitas | 91.54 | 92.48 | 59.35 |
| | Kriteria homogenitas 3x3 | 91.44 | 92.51 | 59.37 |
| | Kriteria homogenitas 5x5 | 92.14 | 93.21 | 59.32 |
| | Kriteria homogenitas 7x7 | 93.14 | 94.37 | 59.27 |
| | Kriteria homogenitas 9x9 | 93.29 | 94.27 | 59.26 |
| | Kriteria homogenitas 11x11 | 93.27 | 94.19 | 59.18 |
| | Kriteria homogenitas 13x13 | 93.15 | 94.04 | 59.17 |
| Diterapkan 3x iterasi | Tidak diterapkan | 80.23 | 81.08 | 52.81 |
| | Diterapkan tanpa kriteria homogenitas | 91.72 | 92.52 | 58.30 |
| | Kriteria homogenitas 3x3 | 91.61 | 92.55 | 58.32 |
| | Kriteria homogenitas 5x5 | 92.31 | 93.22 | 58.27 |
| | Kriteria homogenitas 7x7 | 93.32 | 94.41 | 58.22 |
| | Kriteria homogenitas 9x9 | 93.31 | 94.26 | 58.18 |
| | Kriteria homogenitas 11x11 | 93.28 | 94.11 | 58.11 |
| | Kriteria homogenitas 13x13 | 93.16 | 93.96 | 58.11 |

Tabel 6.2(sambungan) Daftar nilai akurasi hasil klasifikasi menggunakan data polarimetrik E-SAR dengan fitur input 4 kanal hasil pereduksian fitur dengan transformasi MNF.

| Cara penerapan informasi spasial kontekstual berdasar <i>probabilistic relaxation</i> | Cara penerapan informasi spasial kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet | Hasil dengan FMLE | | Hasil dengan FKM |
|---|---|----------------------------|------------------------------|------------------------------|
| | | Tanpa pengolahan akhir (%) | Setelah pengolahan akhir (%) | Setelah pengolahan akhir (%) |
| Diterapkan 4x iterasi | Tidak diterapkan | 80.93 | 81.55 | 52.47 |
| | Diterapkan tanpa kriteria homogenitas | 91.46 | 92.24 | 57.51 |
| | Kriteria homogenitas 3x3 | 91.34 | 92.25 | 57.52 |
| | Kriteria homogenitas 5x5 | 92.05 | 92.95 | 57.47 |
| | Kriteria homogenitas 7x7 | 93.04 | 94.07 | 57.41 |
| | Kriteria homogenitas 9x9 | 93.15 | 93.96 | 57.41 |
| | Kriteria homogenitas 11x11 | 93.02 | 93.83 | 57.35 |
| | Kriteria homogenitas 13x13 | 92.84 | 93.63 | 57.35 |
| Diterapkan 5x iterasi | Tidak diterapkan | 81.38 | 81.85 | 52.30 |
| | Diterapkan tanpa kriteria homogenitas | 91.02 | 91.81 | 56.51 |
| | Kriteria homogenitas 3x3 | 90.91 | 91.83 | 56.53 |
| | Kriteria homogenitas 5x5 | 91.62 | 92.52 | 56.48 |
| | Kriteria homogenitas 7x7 | 92.62 | 93.58 | 56.44 |
| | Kriteria homogenitas 9x9 | 92.67 | 93.46 | 56.41 |
| | Kriteria homogenitas 11x11 | 92.54 | 93.32 | 56.38 |
| | Kriteria homogenitas 13x13 | 92.36 | 93.14 | 56.38 |
| Diterapkan 6x iterasi | Tidak diterapkan | 81.74 | 82.13 | 52.07 |
| | Diterapkan tanpa kriteria homogenitas | 90.68 | 91.44 | 55.87 |
| | Kriteria homogenitas 3x3 | 90.57 | 91.44 | 55.88 |
| | Kriteria homogenitas 5x5 | 91.25 | 92.10 | 55.82 |
| | Kriteria homogenitas 7x7 | 92.21 | 93.16 | 55.78 |
| | Kriteria homogenitas 9x9 | 92.25 | 92.99 | 55.77 |
| | Kriteria homogenitas 11x11 | 92.10 | 92.85 | 55.74 |
| | Kriteria homogenitas 13x13 | 91.95 | 92.68 | 55.72 |

6.3 Ujicoba dan Analisa Hasil Menggunakan Data Polarimetrik ALOS-PALSAR Daerah Lumajang, Jawa Timur

Ujicoba yang ketiga adalah ujicoba menggunakan data polarimetrik ALOS-PALSAR. Ujicoba ketiga ini, selain untuk menguji efektifitas dari metodologi yang diajukan itu sendiri, juga bertujuan untuk mengamati apakah terjadi perbedaan hasil apabila dipergunakan data polarimetrik dari sumber yang berbeda, resolusi spasial yang berbeda, dan daerah yang berbeda. Yang mana pada

ujicoba ketiga ini dipergunakan data polarimetrik dari wahana satelit ALOS-PALSAR dengan resolusi 30 m, sedangkan pada ujicoba kedua dipergunakan data polarimetrik dari wahana pesawat E-SAR dengan resolusi sekitar 3 m.

Sama halnya dengan ujicoba kedua, pada ujicoba ini disusun lima dataset sebagai berikut :

- 1) Dataset yang berisi 9 fitur parameter polarimetrik dari elemen matriks kovarian polarimetrik (Gambar 2.6)
- 2) Dataset yang berisi 3 fitur hasil dekomposisi polarimetrik Cloude (Gambar 2.11)
- 3) Dataset yang berisi 12 fitur gabungan dataset 1) dan dataset 2)
- 4) Dataset yang berisi hasil pengaplikasian transformasi MNF atas dataset 3) (terdiri atas 4 fitur, yakni empat kanal MNF pertama seperti yang ditunjukkan pada Gambar 2.15)
- 5) Dataset yang berisi hanya 1 fitur intensitas HH (Gambar 2.6-a).

Namun demikian, untuk ujicoba ketiga ini penghitungan nilai akurasi hasil klasifikasi tidak dapat dilakukan karena ketiadaan data survei lapangan. Oleh karena itu evaluasi dilakukan melalui pengamatan visual atas hasil-hasil klasifikasi dengan membandingkannya dengan citra optis yang diperoleh dari Google Earth seperti yang ditunjukkan pada Gambar 1.6.

Demikian pula halnya dengan jumlah kelas yang dipakai, berdasarkan informasi dari Google Earth tersebut dan berdasarkan citra RGB yang disusun dari data polarimetriknya (Gambar 1.6 bagian tengah) ditentukan kelas-kelasnya adalah kelas perairan, kelas hutan, kelas kebun/kampung, dan kelas tanah terbuka/sawah. Untuk objek kebun dan kampung digabungkan menjadi satu kelas, alasannya adalah keterbatasan resolusi spasial yang ada pada data polarimetrik ALOS-PALSAR tersebut yakni hanya sekitar 30 m dan sebagian besar objek kampung/perumahan tidaklah mengumpul (bergerombol) namun bercampur dengan kebun atau ladang. Demikian halnya untuk objek tanah terbuka (daerah berpasir di pinggir pantai dan daerah aliran sungai serta tanah terbuka yang dipenuhi pasir lahar dari Gunung Semeru) dan sawah yang masih sulit dibedakan dengan data polarimetrik ALOS-PALSAR baik karena keterbatasan resolusi

spasial maupun karena objek-objek tersebut mempunyai karakteristik yang hampir sama yakni bersifat *surface/single bounce scattering*.

Namun di lain pihak, kelas hutan dalam proses klasifikasinya perlu dibedakan menjadi dua kelas (kelas hutan 1 dan kelas hutan 2). Hal ini akibat adanya perbedaan arah kemiringan (*slope*) lereng terhadap arah datangnya sinyal radar (*radar beam*). Kelas hutan 2 merupakan area hutan yang mana arah kemiringan permukaan hutan tersebut hampir atau mendekati tegak lurus dengan *radar beam*, sehingga hampir keseluruhan sinyal radar tersebut akan dipantulkan balik ke sensor radar penerimanya. Hal ini juga bisa dikonfirmasi dalam citra polarimetriknya yang nampak jauh lebih terang dibandingkan kelas hutan 1 (yang berada pada area dengan arah kemiringan yang berbeda dengan kelas hutan 2). Selain itu, pada bagian kemiringan (*slope*) seperti pada kelas hutan 1 tersebut luasan area dalam citranya tampak menjadi lebih pendek (termampatkan). Efek yang menjadi salah ciri khas citra radar ini sering disebut dengan *foreshortening*, dan sulit untuk dikompensasi lebih lanjut apabila hanya terdapat satu buah data (Tso and Matter, 2001; Woodhouse, 2006).

Hasil-hasil klasifikasi menggunakan kelima dataset tersebut ditunjukkan pada Gambar 6.8. Dengan mengamati hasil-hasil tersebut, dapat disimpulkan bahwa fitur parameter polarimetrik saja (dataset 1) memberikan hasil yang lumayan, namun dengan banyak dijumpai salah klasifikasi diantara kelas hutan, kebun/kampung, dan tanah terbuka/sawah. Seperti misalnya, area hutan pada sebelah kiri atas dan tengah dari citra banyak mengalami salah klasifikasi sebagai kebun/kampung, dan juga area tanah terbuka pada bagian tengah citra banyak mengalami salah klasifikasi sebagai hutan. Di lain pihak, fitur dekomposisi polarimetrik Cloude (dataset 2) dapat membedakan secara lebih akurat diantara area hutan (yang lebih bersifat *volume scattering* dengan nilai *entropy* yang tinggi) dan area non-hutan, serta mempertegas area-area yang berkelas tanah terbuka/sawah (yang lebih bersifat *surface/single-bounce scattering* dengan nilai *entropy* yang relatif rendah). Dengan menggabungkan dua dataset tersebut menjadi dataset 3, kemampuan pembedaan antara beberapa tipe tutupan lahan dapat lebih ditingkatkan, sehingga memberikan hasil klasifikasi yang lebih baik (Gambar 6.8-e) dibandingkan hanya menggunakan dataset masing-masing metode


pengekstraksian fitur. Dengan demikian, seperti halnya dengan ujicoba kedua, dapat disimpulkan bahwa fitur parameter polarimetrik matriks kovarian dan fitur dekomposisi polarimetrik Cloude mengandung informasi yang saling komplementer yang apabila digabungkan akan sangat bermanfaat dalam meningkatkan kemampuan pembedaan antara beberapa tipe tutupan lahan.

Hasil klasifikasi menggunakan dataset yang telah tereduksi menjadi 4 fitur dari hasil pengaplikasian MNF (dataset 4) seperti yang ditunjukkan pada Gambar 6.8-g juga menunjukkan hasil yang serupa dengan hasil dari data polarimetrik E-SAR pada ujicoba 2, yakni: 1) tidak terjadi penurunan yang signifikan pada hasil klasifikasi meskipun dimensi fitur inputnya diturunkan; 2) didapatkan hasil klasifikasi yang mengandung efek "*salt-and-pepper*" yang lebih sedikit dibandingkan hasil klasifikasi dengan menggunakan dataset fitur yang lengkap (dataset 3).

Terkait dengan perbandingan hasil apabila menggunakan data SAR konvensional berpolarisasi tunggal seperti yang ditunjukkan pada Gambar 6.8-i, maka pada ujicoba dengan data polarimetrik ALOS-PALSAR ini juga didapatkan kesimpulan bahwa potensi data polarimetrik-SAR untuk membedakan berbagai objek tutupan lahan jauh lebih baik bila dibandingkan dengan data SAR konvensional berpolarisasi tunggal.


Apabila hasil-hasil dengan FMLE itu tersebut di atas masing-masing dibandingkan dengan hasil-hasil klasifikasi menggunakan FKM didapatkan kesimpulan yang serupa dengan ujicoba kedua, yakni bahwa FMLE secara konsisten memberikan hasil yang lebih baik dibandingkan dengan FKM. Kesalahan-kesalahan klasifikasi diantara hutan, kebun/kampung, perairan, dan tanah terbuka banyak terjadi pada hasil FKM. Secara jelas, FKM terutama tidak dapat mengidentifikasi secara akurat perbedaan antara kelas perairan dan kelas tanah terbuka.

Selanjutnya, hasil-hasil eksperimen dengan menyertakan informasi spasial-kontekstual ditunjukkan pada Gambar 6.9. Dalam hal ini, untuk menghemat halaman penulisan, hanya ditampilkan hasil dari dataset 4 yang disertai dengan: 1) penerapan informasi spasial-kontekstual berdasar *probabilistic relaxation* 3 iterasi saja (Gambar 6.9-b); 2) penerapan informasi spasial-kontekstual berdasarkan




- Air
- Hutan 1
- Hutan 2
- Tanah terbuka/sawah/Kebun/kampung

a) Hasil klustering FMLE dengan fitur input parameter polarimetrik (9 fitur dataset 1)




b) Hasil klustering FKM dengan fitur input parameter polarimetrik (9 fitur dataset 1)




- Air
- Hutan 1
- Hutan 2
- Tanah terbuka/sawah/Kebun/kampung

c) Hasil klustering FMLE dengan fitur input dekomposisi polarimetrik Cloude (3 fitur dataset 2)



d) Hasil klustering FKM dengan fitur input dekomposisi polarimetrik Cloude (3 fitur dataset 2)



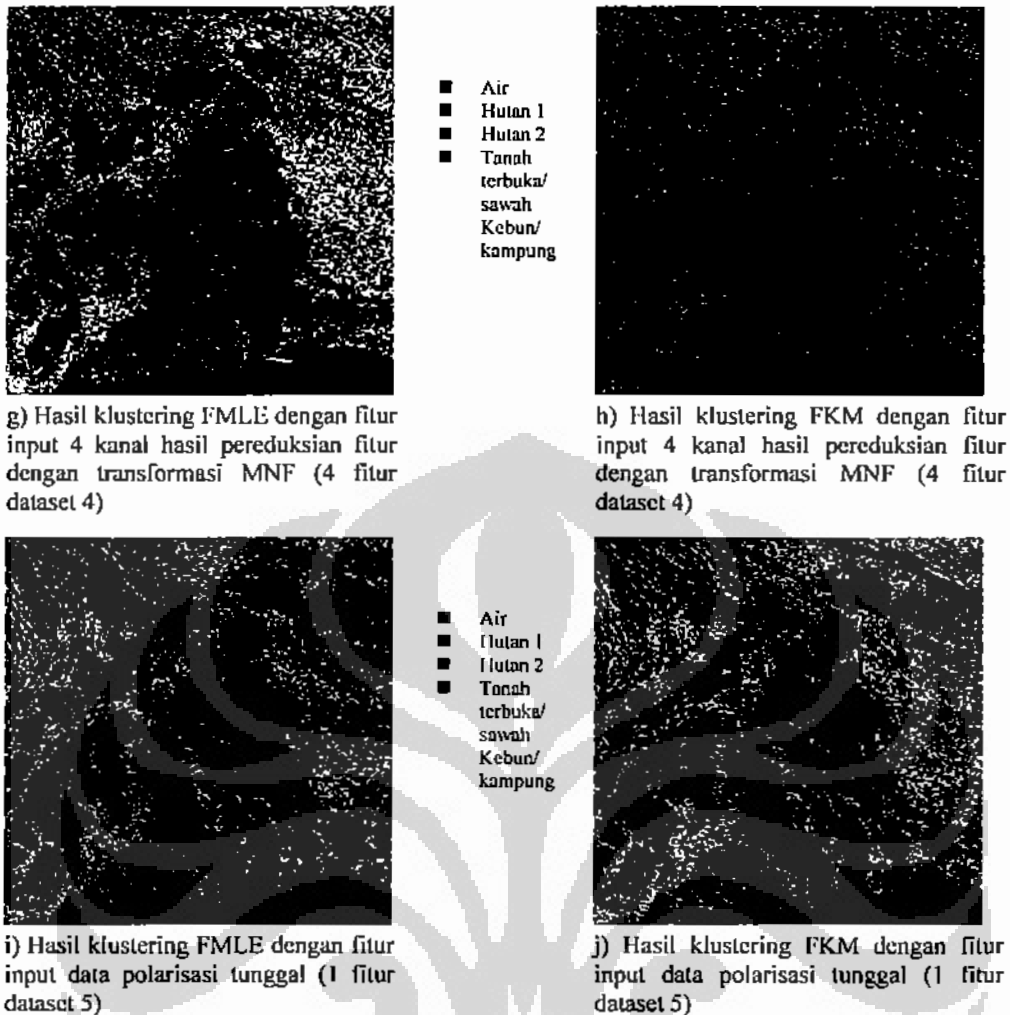
- Air
- Hutan 1
- Hutan 2
- Tanah terbuka/sawah/Kebun/kampung

e) Hasil klustering FMLE dengan gabungan fitur parameter polarimetrik dan fitur input dekomposisi polarimetrik Cloude (12 fitur dataset 3)



f) Hasil klustering FKM dengan gabungan fitur parameter polarimetrik dan fitur input dekomposisi polarimetrik Cloude (12 fitur dataset 3)

Gambar 6.8 Hasil klasifikasi FMLE menggunakan data polarimetrik ALOS-PALSAR dengan fitur input parameter polarimetrik, dekomposisi polarimetrik, gabungan parameter polarimetrik dan dekomposisi polarimetrik, 4 kanal hasil pereduksian fitur dengan MNF, dan fitur input data polarisasi tunggal. (Hasil klasifikasi FKM ditunjukkan pula sebagai perbandingan)



Gambar 6.8(sambungan) Hasil klasifikasi FMLE menggunakan data polarimetrik ALOS-PALSAR dengan fitur input parameter polarimetrik, dekomposisi polarimetrik, gabungan parameter polarimetrik dan dekomposisi polarimetrik, 4 kanal hasil pereduksian fitur dengan transformasi MNF, dan fitur input data polarisasi tunggal. (Hasil klasifikasi FKM ditunjukkan pula sebagai perbandingan)

analisa klustering dengan citra aproksimasi wavelet diterapkan dengan ukuran jendela 7x7 saja (Gambar 6.9-c); 3) penerapan kedua jenis informasi spasial-kontekstual tersebut yang dilanjutkan dengan pengolahan akhir dengan *majority filtering* (Gambar 6.9-e). Untuk lebih memperjelas efek perbaikan yang diberikan oleh kedua informasi spasial-kontekstual tersebut dan sekaligus mempermudah

evaluasi dengan menggunakan data referensi (Google Earth), maka sebagian hasil pada Gambar 6.9 ditampilkan perbesarannya pada Gambar 6.10.

Dengan menganalisa hasil-hasil yang ditunjukkan pada Gambar 6.9 dan Gambar 6.10, seperti halnya dengan ujicoba kedua, didapatkan kesimpulan bahwa untuk mendapatkan hasil yang paling optimal diperlukan kedua informasi spasial-kontekstual. Yakni informasi spasial-kontekstual berdasarkan *probabilistic relaxation* dan informasi spasial-kontekstual berdasarkan analisa klustering dengan citra aproksimasi wavelet. Informasi spasial-kontekstual berdasarkan *probabilistic relaxation* terutama berguna untuk mengkoreksi kesalahan suatu piksel secara mikro yakni berdasarkan analisa statistik terbatas dari piksel-piksel yang bertetangga. Oleh karena itu, efek perbaikan hasil klasifikasinya juga hanya terjadi pada skala mikro saja (tidak meluas ke area yang lebih luas), sehingga masih menyisakan area-area hasil klasifikasi yang masih bernoise seperti terlihat pada Gambar 6.9-b dan Gambar 6.10-d. Dalam hal ini, hasil-hasil klasifikasi dengan berbagai jumlah iterasi, walaupun untuk menghemat ruang penulisan tidak disertakan dalam bab ini, namun pada dasarnya menunjukkan kecenderungan yang sama dengan ujicoba kedua.

Di lain pihak, informasi spasial-kontekstual berdasarkan analisa klustering dengan citra aproksimasi wavelet berguna untuk memberikan hasil klasifikasi yang lebih homogen pada area-area yang homogen. Namun, seperti yang terlihat pada Gambar 6.9-c dan Gambar 6.10-f, tidak mampu mempertahankan batas-batas objek dengan baik demikian pula halnya dengan objek-objek yang berukuran kecil menjadi tidak jelas keberadaannya. Selain itu, pada area yang homogen pun, terlihat masih terdapat noise-noise pada hasil klasifikasinya. Hal ini terutama terjadi apabila nilai derajat keanggotaan untuk piksel tersebut yang diperoleh dari hasil klustering menggunakan informasi spektral saja jauh lebih tinggi dibandingkan derajat keanggotaan yang diperoleh dari informasi support spasial-kontekstual pada piksel tersebut. Padahal informasi yang diperoleh dari hasil klustering dengan informasi spektral saja tersebut berupa informasi pengkelasan yang salah. Sehingga walaupun digabungkan keduanya (informasi spektral dan informasi spasial-kontekstual), informasi pengkelasan pada piksel tersebut tidak berubah (tetap berkelas yang salah).

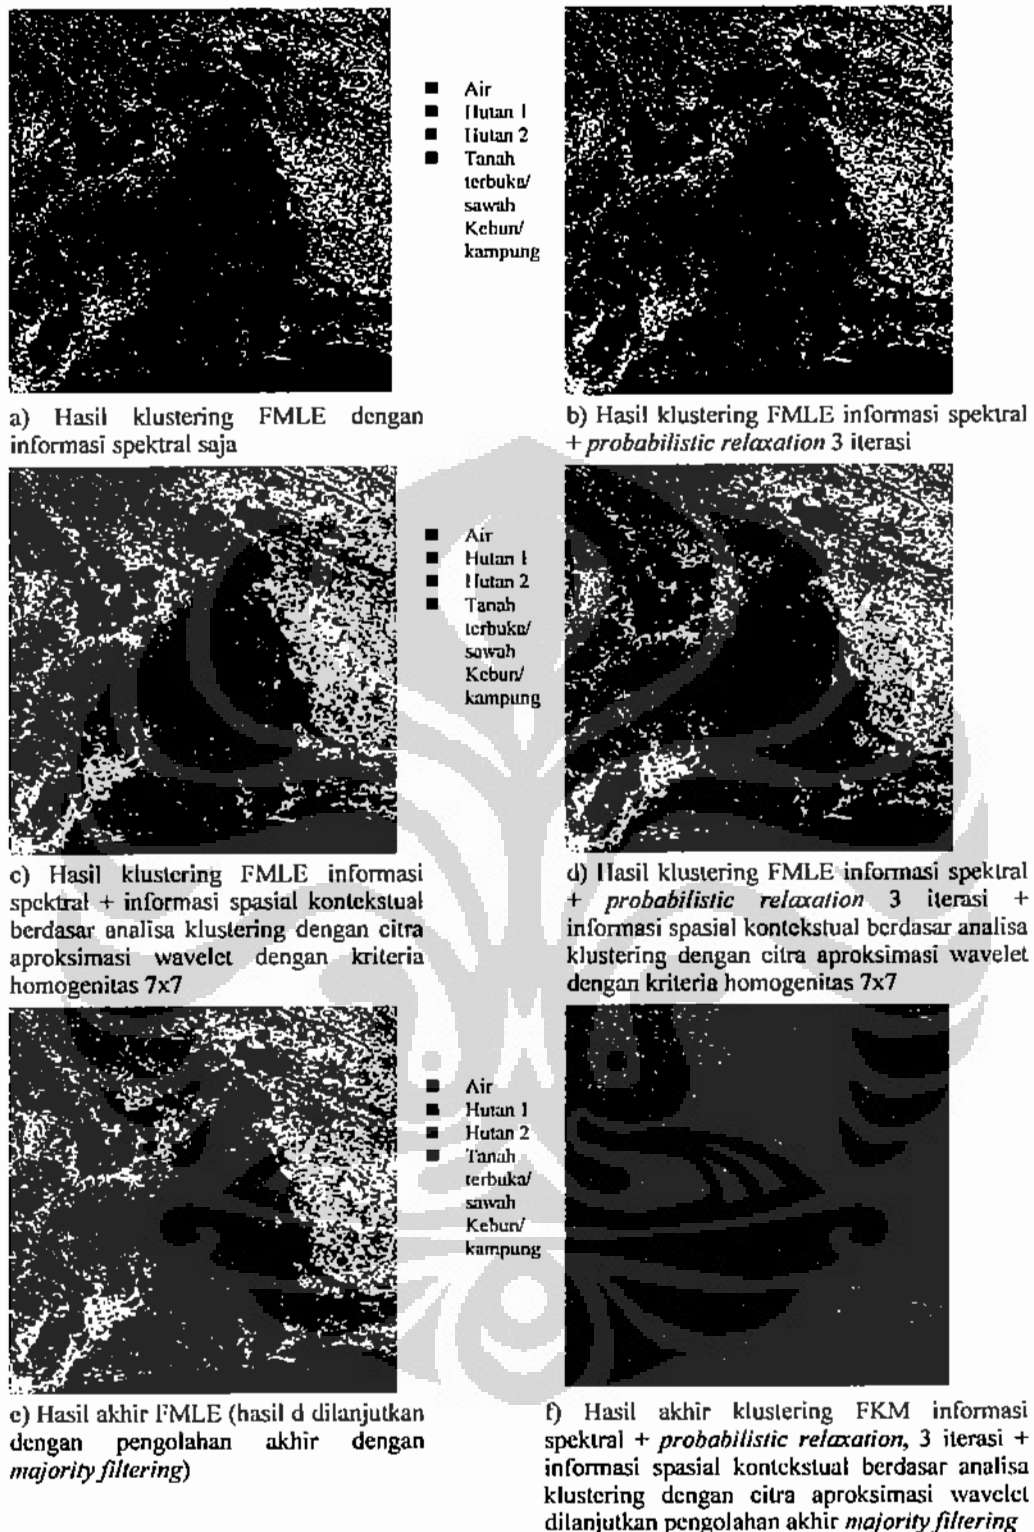
Dengan menggunakan kedua informasi spasial-kontekstual tersebut secara bersamaan, seperti yang terlihat pada Gambar 6.9-d dan Gambar 6.10-g, maka kekurangan-kekurangan dari informasi spasial-kontekstual berdasarkan analisa klustering dengan citra aproksimasi wavelet dapat ditutupi (diatasi). Bagian batas-batas objek dan objek-objek yang berukuran kecil tetap terjaga, karena terutama pada bagian tersebut hanya disupport oleh informasi spasial-kontekstual berdasar *probabilistic relaxation* saja. Hal ini dapat dikonfirmasi pula dengan membandingkan hasil klasifikasi tersebut dengan gambar referensi dari Google Earth seperti yang terlihat pada Gambar 6.10-b dan Gambar 6.10-c. Selain terjaga konsistensi hasil identifikasi objek dan batas-batas objeknya, juga didapatkan hasil klasifikasi yang lebih homogen pada area-area yang bersifat homogen. Hasil ini kemudian lebih diperbaiki lagi dengan menggunakan pengolahan akhir menggunakan *majority filtering*, seperti yang terlihat pada Gambar 6.9-e dan Gambar 6.10-h.

6.4 Analisa Hasil Klasifikasi Dikaitkan dengan Tingkat (Kebutuhan) Komputasinya

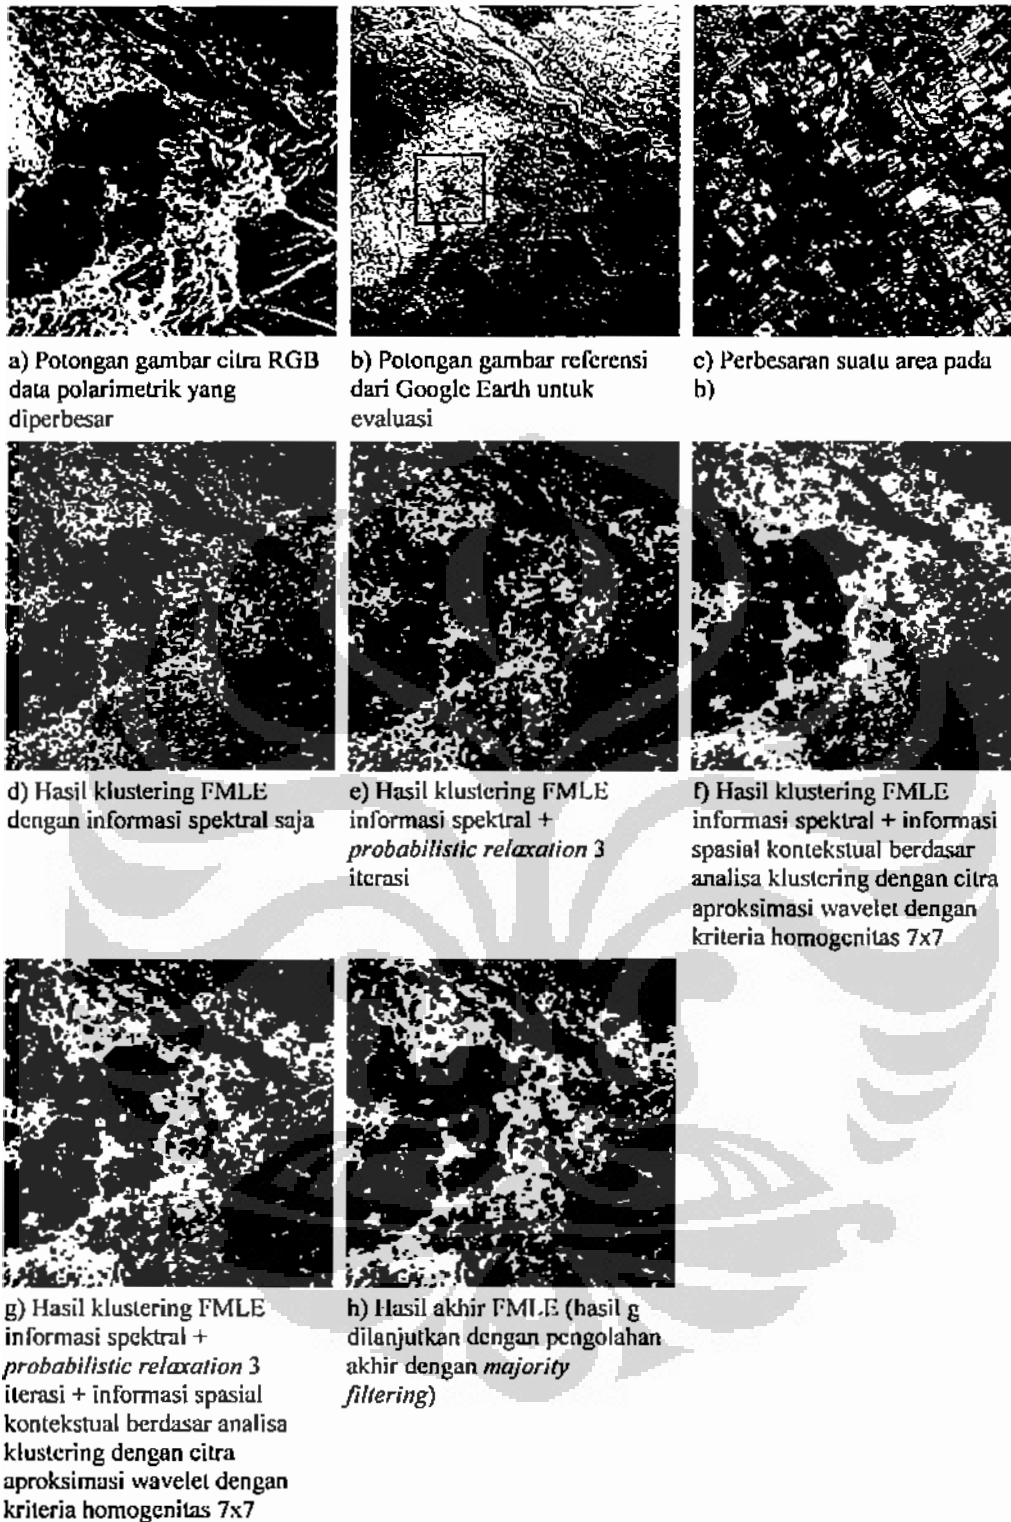
Berdasarkan hasil ujicoba dengan kedua data polarimetrik-SAR didapatkan bahwa metodologi yang diajukan dalam penelitian ini mampu meningkatkan performansi identifikasi dan klasifikasi objek tutupan lahan secara signifikan. Namun demikian, metodologi ini cukup kompleks terutama karena dibutuhkan dua kali proses klustering, yakni klustering dengan menggunakan fitur input kanal-kanal hasil transformasi MNF dan klustering dengan menggunakan fitur input citra aproksimasi wavelet dari kanal MNF tersebut (lihat Gambar 5.1).

Pada umumnya, tingkat (kebutuhan) komputasi pada berbagai proses klasifikasi berkorelasi secara positif dengan jumlah (dimensi) fitur input yang dipergunakan. Seperti misalnya, pada klasifier (*supervised*) *maximum likelihood*, apabila dipergunakan d dimensi fitur input maka komputasi yang dibutuhkan berbanding dengan d^2 (Tso and Matter, 2001). Oleh karenanya, apabila d semakin besar akan terjadi peningkatan komputasi secara non-linear (kuadratik).


Dalam algoritma klustering FMLE juga dilakukan penghitungan *cluster*



Gambar 6.9 Perbandingan hasil klasifikasi FMLE (menggunakan data polarimetrik ALOS-PALSAR dengan fitur input 4 kanal hasil reduksi fitur dengan transformasi MNF) antara sebelum dan sesudah penyertaan kedua informasi spasial-kontekstual, serta sesudah dilakukan pengolahan akhir dengan *majority filtering*. (Hasil klasifikasi dengan FKM ditampilkan pula sebagai perbandingan)



Gambar 6.10 Perbesaran hasil pada Gambar 6.9 dan dilengkapi dengan gambar referensi dari Google Earth, gambar kriteria homogenitas, dan gambar hasil FMLE citra aproksimasi hasil dekomposisi wavelet ATWT.



i) Gambar kriteria homogenitas

j) Hasil FMLE dengan citra aproksimasi (ATWT level 1)

Gambar 6.10(sambungan) Perbesaran hasil pada Gambar 6.9 dan dilengkapi dengan gambar referensi dari Google Earth, gambar kriteria homogenitas, dan gambar hasil FMLE citra aproksimasi hasil dekomposisi wavelet ATWT.

center dan *covariance matrix* seperti halnya dengan algoritma *maximum likelihood* tersebut. Namun perbedaannya, penghitungan tersebut dilakukan secara iteratif untuk mengupdate derajat keanggotaan (u_{ij} pada Rumus (3.8)) sampai dengan konvergen. Tentu saja hal ini akan membutuhkan beban komputasi yang lebih besar sesuai dengan jumlah iterasi tersebut. Lebih jauh, karena dibutuhkan dua kali klustering FMLE (lihat Gambar 5.1) maka komputasi yang dibutuhkannya pun menjadi bertambah kembali. Oleh karena itu, penurunan dimensi fitur input menjadi sangat penting. Dalam penelitian ini, hal tersebut dilakukan dengan transformasi MNF (yang hanya terdiri dari dua tahap transformasi *principal component* biasa dengan beban komputasi yang tidak besar). Pada kedua ujicoba didapatkan bahwa dimensi fitur input yang semula 12 fitur dapat diturunkan menjadi 4 fitur saja dengan tanpa mengorbankan keakurasian hasil klasifikasi. Misalnya, pada ujicoba dengan data E-SAR terjadi penurunan sekitar 0.74% (lihat Gambar 6.3-e dan Gambar 6.3-g). Namun di lain pihak, selain beban komputasinya lebih menurun juga didapatkan hasil positif lainnya yakni berupa berkurangnya efek “*salt-and-pepper*” pada hasil klasifikasi dengan fitur input hasil pereduksian MNF tersebut. Hal ini dapat dikonfirmasi secara jelas, baik pada hasil klasifikasi dengan data E-SAR maupun data ALOS-PALSAR (lihat Gambar 6.8-e dan Gambar 6.8-g) terutama pada area perairan.

BAB 7

KESIMPULAN DAN SARAN

7.1 Kesimpulan

Penelitian ini mengajukan suatu metodologi alternatif untuk mengklasifikasi data polarimetrik-SAR secara tidak terbimbing (*unsupervised*). Metodologi tersebut dirancang dengan mengintegrasikan pengkombinasian fitur parameter polarimetrik yang diekstraksi dari matriks kovarian polarimetrik dan fitur dekomposisi polarimetrik Cloude (yang memberikan informasi berupa karakteristik hamburan balik objek) dengan klasifier *fuzzy maximum likelihood estimation* (FMLB) yang disupport dengan informasi spasial-kontekstual.

Metodologi yang diajukan tersebut telah diujicoba dengan dua buah data polarimetrik-SAR yakni data *single look complex* E-SAR (kanal L) yang diakuisisi pada daerah sekitar Penajam, Kalimantan Timur dan data ALOS-PALSAR (kanal L) yang diakuisisi di daerah Lumajang, Jawa Timur, Indonesia. Dengan menganalisa hasil-hasil yang didapatkan dari eksperimen-eksperimen tersebut didapatkan kesimpulan bahwa metodologi yang diajukan mampu memberikan peningkatan performansi pembedaan objek tutupan lahan, dan memberikan hasil klasifikasi yang memuaskan dan lebih homogen namun tetap mempertahankan batas-batas objek dan struktur-struktur detail lainnya. Lebih jauh, melalui pengamatan dan analisa hasil-hasil yang diperoleh dalam penelitian ini secara lebih detail, didapatkan poin-poin kesimpulan sebagai berikut:

- Fitur parameter polarimetrik dan fitur dekomposisi polarimetrik mengandung informasi yang saling komplementer yang dapat diintegrasikan untuk meningkatkan kemampuan pembedaan antar berbagai tipe objek tutupan lahan. Sembilan fitur parameter polarimetrik walaupun secara visual mengandung informasi yang paling jelas untuk mendiskriminasikan berbagai objek tutupan lahan, namun ternyata kurang mampu membedakan area daratan dengan kondisi (tingkatan) vegetasi yang berbeda. Sedangkan fitur dekomposisi polarimetrik mampu mengkompensasi kekurangan tersebut dan juga lebih mempertajam pembedaan antara area yang bervegetasi (yang lebih

bersifat *volume scattering* dengan nilai *entropy* yang tinggi) dengan area tanah terbuka atau tidak bervegetasi (yang lebih bersifat *surface/single-bounce scattering* dengan nilai *entropy* yang relatif rendah). Hal ini juga dapat dikonfirmasi dari hasil ujicoba dengan data E-SAR, dimana sembilan fitur parameter polarimetrik memberikan akurasi klasifikasi 64.04%, tiga fitur dekomposisi polarimetrik memberikan akurasi 48.12%, sedangkan gabungan keduanya (dua belas fitur) menghasilkan akurasi 78.13%.

- Transformasi *maximum noise fraction* (MNF) merupakan suatu skema pereduksian fitur yang efektif yang mampu mereduksi informasi yang bersifat redundan maupun informasi yang tidak relevan lainnya (seperti misalnya noise speckle) yang terkandung dalam fitur-fitur tersebut. Dengan mereduksi dimensi fitur inputnya, baik kompleksitas maupun beban komputasi pada proses klasifikasi berikutnya dapat diturunkan namun dengan tanpa mengorbankan akurasi hasil klasifikasinya. Pada ujicoba dengan data E-SAR terjadi penurunan akurasi sekitar 0.74% menjadi 77.39%, namun di lain pihak didapatkan hasil positif lainnya yakni berupa berkurangnya efek “*salt-and-pepper*” apabila dibandingkan dengan hasil menggunakan fitur-fitur utuhnya.
- Metode klustering FMLE adalah metode yang tepat untuk mengeksploitasi informasi-informasi yang terkandung dalam fitur-fitur tersebut. Dengan menggunakan metode tersebut, baik informasi/fitur berbagai jenis (tipe) yang dapat diekstraksi dari data polarimetrik-SAR maupun dari sumber data lainnya dapat ditambahkan dengan mudah ke dalam proses klusteringnya. Selain itu, kemampuan algoritma klustering FMLE untuk membentuk kluster-kluster yang berbentuk elips dalam berbagai arahnya adalah sesuai untuk pembentukan batas-batas kelas dari ruang fitur-fitur tersebut, sehingga memberikan hasil klasifikasi yang lebih baik dibandingkan dengan algoritma klustering *fuzzy K-means* (FKM) yang standar. Pada ujicoba dengan data E-SAR (dengan menggunakan informasi spektral saja), rata-rata selisih antara hasil FMLE dengan FKM adalah 23.8%.
- Pengintegrasian informasi spasial-kontekstual yang diekstraksi berdasar *probabilistic relaxation* dan informasi spasial-kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet ke dalam hasil klustering FMLE

yang berbasis piksel per piksel dapat memberikan perbaikan yang memuaskan pada hasil klasifikasi akhirnya. Hasil terbaik fusi informasi spektral dan informasi spasial-kontekstual tersebut diperoleh dengan mengkombinasikan *probabilistic relaxation* dengan 3~5 iterasi, dan informasi spasial-kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet menggunakan ukuran jendela penghitungan kriteria homogenitas 7x7 atau 9x9. Pada ujicoba dengan data E-SAR diperoleh peningkatan sekitar 17%, sehingga diperoleh akurasi hasil klasifikasi terbaik 94,41%. Terlihat bahwa informasi spasial-kontekstual *probabilistic relaxation* terutama berkontribusi dalam mengoreksi secara mikro pengkelasan suatu piksel berdasarkan analisa statistik atas informasi kelas piksel-piksel yang bersebelahan (bertetangga). Selanjutnya informasi spasial-kontekstual berdasar analisa klustering dengan citra aproksimasi wavelet berkontribusi dalam meningkatkan kehomogenan pada hasil klasifikasi di seluruh area secara global kecuali pada area yang bersifat tidak homogen (seperti pada batas-batas antar objek dan struktur atau objek tutupan lahan yang berukuran kecil).

- Perbaikan hasil-hasil yang didapatkan tersebut relatif mempunyai kecenderungan yang sama walaupun terdapat perbedaan wahana pengakuisisi data maupun resolusi spasial datanya (yakni data dari wahana pesawat E-SAR dengan resolusi sekitar 3 m dan data dari wahana satelit ALOS-PALSAR dengan resolusi 30 m).
- Secara khusus apabila dibandingkan dengan data SAR konvensional berpolarisasi tunggal maka dapat diambil kesimpulan bahwa metodologi yang diajukan dalam penelitian ini mampu mengeksploitasi secara optimal informasi yang terkandung dalam data polarimetrik-SAR sehingga memberikan hasil identifikasi dan klasifikasi objek tutupan lahan yang jauh lebih baik.

7.2 Kontribusi Penelitian

Kontribusi yang dapat diberikan dari penelitian ini khususnya yang terkait dengan algoritma klasifikasi data polarimetrik-SAR adalah:

”Suatu metodologi alternatif klasifikasi *unsupervised* data polarimetrik-SAR dengan:

- mengkombinasikan fitur-fitur komplementer yang dieksploitasi dari data yang sama dengan tinjauan aspek yang berbeda (yakni parameter polarimetrik-SAR dan dekomposisi polarimetrik) untuk meningkatkan kemampuan identifikasi berbagai objek tutupan lahan,
- mengimplementasikan transformasi MNF untuk memeriksa dan sekaligus menghilangkan informasi/fitur dari gabungan kedua aspek tersebut yang bersifat redundan maupun noise (dengan mengajukan usulan teknik pengestimasi kovarian noise menggunakan area yang homogen sebagai pengganti sinyal '*dark reference*'),
- dan mengintegrasikan hasil klasifikasi berbasis piksel per piksel dengan informasi spasial-kontekstual untuk menghasilkan keputusan pengkelasan yang lebih optimal sehingga didapatkan hasil klasifikasi yang lebih homogen namun tetap dapat mempertahankan batas-batas objek (*edge*) dan objek-objek yg berukuran kecil (dengan pendekatan *data fusion*).”

7.3 Saran

Saran yang dapat diberikan untuk penelitian selanjutnya adalah sebagai berikut:

- Meskipun dengan pengkombinasian fitur parameter polarimetrik dan fitur dekomposisi polarimetrik Cloude telah mampu meningkatkan kemampuan pembedaan antar berbagai tipe objek tutupan lahan, namun keakurasian hasil klasifikasi masih belum mencapai 100%. Oleh karena itu, perlu dipertimbangkan penambahan fitur-fitur lain yang dapat diekstraksi dengan metode pengekstraksian fitur berdasarkan tinjauan dari aspek yang berbeda (yang bersifat komplementer) untuk lebih meningkatkan keakurasian tersebut.
- Metodologi yang diajukan pada penelitian ini adalah metodologi klasifikasi *unsupervised*, yang mana memiliki keuntungan besar dari sisi praktikalnya karena pada dasarnya tidak memerlukan dataset training yang biasanya diperoleh dari survei lapangan (*ground truth*). Namun demikian, dalam

metodologi ini penentuan jumlah kelas tutupan lahan masih harus ditentukan secara manual oleh user/operator berdasarkan konten citranya ataupun berdasarkan informasi lainnya mengenai area yang dianalisa tersebut. Oleh karena itu, perlu dikembangkan suatu algoritma tambahan untuk menentukan secara otomatis jumlah kelas yang optimal yang didasarkan atas struktur internal yang terkandung dalam data itu sendiri.

- Perlu dilakukan perbandingan keakurasian hasil klasifikasi dengan metodologi-metodologi klasifikasi *unsupervised* data polarimetrik-SAR lainnya. Seperti misalnya dengan metodologi klasifikasi *unsupervised wishart entropy-alpha* dan beberapa variasinya (Lee *et al.*, 1999a; Kersten *et al.*, 2005; Reigber *et al.*, 2007) yang mengkombinasikan informasi 9 zona hasil dekomposisi polarimetrik Cloude untuk menginisialisasi klustering dengan metode *Wishart*. Dalam pembandingannya, tentu saja diperlukan penggabungan atau penyesuaian jumlah kluster-klusternya agar berjumlah sama sesuai objek tutupan lahan yang terkandung dalam data polarimetrik-SAR tersebut.
- Kedua data polarimetrik-SAR yang dipergunakan dalam penelitian ini adalah data kanal L. Oleh karena itu, perlu diteliti lebih lanjut apakah metodologi yang diajukan ini tetap dapat diimplementasikan pada data polarimetrik-SAR dengan kanal yang berbeda terutama yang berpanjang gelombang lebih pendek (seperti kanal C atau kanal X).

Sebagai penutup, dengan mempertimbangkan potensi peningkatan performansi identifikasi dan klasifikasi dari data polarimetrik-SAR yang begitu besar dibandingkan dengan data SAR konvensional yang berpolarisasi tunggal seperti yang juga terlihat dari hasil penelitian ini, maka dapat disarankan pemanfaatan (pencrapan) data polarimetrik-SAR secara lebih luas di berbagai bidang aplikasi penginderaan jauh. Khususnya di Indonesia, yang mana sebagian besar wilayahnya selalu berawan, pemanfaatan data polarimetrik-SAR adalah sangat tepat karena selain bebas awan dan dapat memantau siang maupun malam dalam segala kondisi cuaca, data polarimetrik-SAR ini juga sangat berpotensi dalam membedakan area-area dengan kondisi vegetasi yang berlainan.

DAFTAR REFERENSI

- Acqua, F.D. and Gamba P. (2003, January). Multitemporal and/or polarimetric SAR characterization of urban areas. In *Proceedings of the 1st International Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry*. Frascati, Italy.
- Aiazzi, B., Alparone, L., Baronti, S., and Garzelli, A. (2002). Context-driven fusion of high spatial and spectral resolution images based on oversampled multiresolution analysis. *IEEE Trans. Geosci. Remote Sensing*, vol. 40, no. 10, pp. 2300-2312.
- Beaulieu, J. and Touzi, R. (2004). Segmentation of textured polarimetric SAR scenes by likelihood approximation. *IEEE Trans. Geosci. Remote Sensing*, vol. 42, pp. 2063-2072.
- Boardman, J.W., Kruse, K.A., and Green, R.O. (1995, January). Mapping target signatures via partial unmixing of AVIRIS data. In *Summaries of the Fifth Annual JPL Airborne Geosciences Workshop*. Pasadena, CA.
- Bogdanov, A.V., Toussaint, M., and Sandven, S. (2005, September). Recurrent modular network architecture for sea ice classification in the marginal ice zone using ERS SAR images. In *Proceedings of the 12th SPIE International Symposium on Remote Sensing*. Bruges, Belgium.
- Borghys, D., Yvinec, Y., Pernecl, C., Pizurica, A., and Philips, W. (2006, March). Supervised feature-based classification of multi-channel SAR images. In *Pattern Recognition Letters*, vol. 27, issue 4.
- Bovolo, F. and Bruzzone, L. (2005, September). An adaptive multiscale approach to unsupervised change detection in multitemporal SAR images. In *Proceedings of IEEE International Conference on Image Processing, ICIP 2005*. Genoa, Italy.

- Bruzzone, L., Marconcini, M., Wegmuller, U., and Wiesmann, A. (2004). An advanced method for the automatic classification of multitemporal SAR images. *IEEE Trans. Geosci. Remote Sensing*, vol. 42, no. 6, pp. 1321-1334.
- Canty, M.J. and Nielsen, A.A. (2004, September). Unsupervised classification of changes in multispectral satellite imagery. In *Proceedings of SPIE, Image and Signal Processing for Remote Sensing X*, vol. 5573, pp. 356-363. Gran Canaria, Spain.
- Canty, M.J. (2006). *Image Analysis, Classification and Change Detection in Remote Sensing*. Boca Raton: CRC Press Taylor & Francis.
- Carvalho, O.A., Carvalho, A.P.F., and Meneses, P.R. (2000). Sequential minimum noise fraction use: An approach to noise elimination. In *AVIRIS Proceedings:2000*. Pasadena, CA.
- Cloude, S.R. and Pottier, E. (1997). An entropy based classification scheme for land applications of polarimetric SAR. *IEEE Trans. Geosci. Remote Sensing*, vol. 35, no. 1, pp. 68-78.
- Corr, D.G., Cloude, S.R., Ferro-Famil, L., Hoekman, D.H., Partington, K., Pottier, E., and Rodrigues, A. (2003, January). Review of the applications of SAR polarimetry and polarimetric interferometry. An ESA-funded study. In *Proceedings of the 1st International Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry*. Frascati, Italy.
- Davidson, G., Ouchi, K., Saito, G., Ishitsuka, N., Mohri, K., and Uratsuka, S. (2002, August). Polarimetric classification using expectation methods. In *Proceedings of PISAR02: Polarimetric and Interferometric SAR Workshop 2002*. Tokyo, Japan.
- Du, L.J. and Lee, J.S. (1996). Fuzzy classification of earth terrain covers using multi-look polarimetric SAR image data. *Int J. Remote Sensing*, vol. 17, no. 4, pp. 809-826.

- Ferrazzoli, P., Paloscia, S., Pampaloni, P., Schiavon, G., Sigismondi, S., and Solimini, D. (1997). The potential of multifrequency polarimetric SAR in assessing agricultural and arboreous biomass. *IEEE Trans. Geosci. Remote Sensing*, vol. 35, no. 1, pp. 5-17.
- Ferro-Famil, L., Pottier, E., Skriver, H., Lumsdon, P., Moshammer, R., and Papathanassiou, K. (2005, January). Forest mapping and classification using L-Band Polinsar data. In *Proceedings of the 2nd International Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry*. Frascati, Italy.
- Fransson, J. (1999). *Analysis of Synthetic Aperture Radar Images for Forestry Applications*. Ph.D. thesis, Department of Forest Resource Management and Geomatics, Swedish University of Agricultural Sciences, Swedish.
- Freeman, A. and Durden, S.L. (1998). A three-component scattering model for polarimetric SAR data. *IEEE Trans. Geosci. Remote Sensing*, vol. 36, no. 3, pp. 963-973.
- Fukuda, S. and Hirose, H. (1999). A wavelet-based texture feature set applied to classification of multifrequency Polarimetric SAR images. *IEEE Trans. Geosci. Remote Sensing*, vol. 37, no. 5, pp. 2282-2286.
- Gath, I. and Geva, A.B. (1989). Unsupervised optimal fuzzy clustering. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, pp. 773-781.
- Google Earth 4.3.7284.3916 (2009, February). February 20, 2009. <http://earth.google.com/>.
- Gonzalez, R. and Woods, R. (2002). *Digital Image Processing* (2nd ed.). New Jersey: Prentice-Hall.

- Hajnsek, I. (2001). *Inversion of Surface Parameters using Polarimetric SAR*. Ph.D. thesis, Department of Geomatics, Friedrich-Schiller University Jena, Germany.
- Hajnsek, I., Kugler, F., Papathanassiou, K., Scheiber, R., Horn, R., Moreira, A., Hoekman, D., Davidson, M., and Attema, E. (2005, January). Indrex II – Indonesian airborne radar experiment campaign over tropical forest in L- and P-Band. In *Proceedings of the 2nd International Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry*. Frascati, Italy.
- Hellmann, M.P. (2001, October). *SAR Polarimetry Tutorial, Beta version 0.1a*. SAR Polarimetry Tutorial.
- Hoekman, D.H. (2003, January). A new polarimetric classification approach using polarimetric SAR data. In *Proceedings of the 1st International Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry*. Frascati, Italy.
- Karathanassi, V. and Dabboor, M. (2004, July). Land cover classification using E-SAR polarimetric data. In *Proceedings of the XXth ISPRS Congress*. Istanbul, Turkey.
- Kersten, P.R., Lee, J.S., and Ainsworth, T.L. (2005). Unsupervised classification of polarimetric synthetic aperture radar images using fuzzy clustering and EM clustering. *IEEE Trans. Geosci. Remote Sensing*, vol. 43, no. 3, pp. 519-527.
- Lee, J.S., Grunes, M.R., Ainsworth, T.L., Du, L.J., Schuler, D.L., and Cloude, S.R. (1999a). Unsupervised classification using polarimetric decomposition and the complex Wishart classifier. *IEEE Trans. Geosci. Remote Sensing*, vol. 37, no. 5, pp. 2249-2258.
- Lee, J.S., Grunes, M.R., and Grandi, G.D. (1999b). Polarimetric SAR speckle filtering and its impact on terrain classification. *IEEE Trans. Geosci. Remote Sensing*, vol. 37, no. 5, pp. 2363-2373.

- Lee, J.S., Grunes, M.R., Ainsworth, T.L., Hajnsek, I., Mette, T., and Papathanassiou, K.P. (2005, January). Forest classification based-on L-band polarimetric and interferometric SAR data. In *Proceedings of the 2nd International Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry*. Frascati, Italy.
- Lee, J.S., Grunes, M.R., Schuler, D.L., Pottier, E., and Ferro-Famil, L. (2006). Scattering-model-based speckle filtering of polarimetric SAR data. *IEEE Trans. Geosci. Remote Sensing*, vol. 44, no. 1, pp. 176-187.
- Liew, A.W.C., Leung, S.H., and Lau, W.H. (2000). Fuzzy image clustering incorporating spatial continuity. *IEE Proc-Vis. Image Signal Process*, vol. 147, no. 2, pp. 185-192.
- Lumsdon, P. (2003, January). Land cover classification and height estimation in polarimetric SAR interferometry. In *Proceedings of the 1st International Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry*. Frascati, Italy.
- Mallat, S.G. (1989). A theory for multiresolution signal decomposition: The wavelet representation. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, pp. 674-693.
- McNeill, S. and Pairman, D. (2003, November). A description of New Zealand forest using full-polarisation radar imagery. In *Proceedings of Image and Vision Computing New Zealand*. Palmerston North, New Zealand.
- Pottier, E., Famil, L., Cloude, S., Hajnsek, I., Papathanassiou, K., Moreira, A., Pearson, T., and Desnos, Y. (2005, January). PolSARPro v2.0 software. A versatile polarimetric SAR data processing and educational toolbox. In *Proceedings of the 2nd International Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry*. Frascati, Italy.
- Quegan, S., Toan, T.L., Skriver, H., Gomez-Dans, J., Carmen Gonzalez-Sampedro, M., and Hockman, D.H. (2003, January). Crop classification with

- multitemporal polarimetric SAR data. In *Proceedings of the 1st International Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry*. Frascati, Italy.
- Reigber, A. (2001). *Airborne Polarimetric SAR Tomography*. Ph.D. thesis, Institute for Navigation, University of Stuttgart, Germany.
- Reigber, A., Jager, M., Neumann, M., and Ferro-Famil, L. (2007, January). Polarimetric fuzzy K-means classification with consideration of spatial context. In *Proceedings of the 3rd International Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry*. Frascati, Italy.
- Sambodo, K.A. dan Teguh, K. (2005, September). Klasifikasi data polarimetrik radar dengan metode dekomposisi Cloude & Pottier. *Prosiding pada Pertemuan Ilmiah Tahunan XIV Masyarakat Penginderaan Jauh Indonesia (PIT-MAPIN 2005)*. Surabaya, Indonesia.
- Sambodo, K.A. dan Murni, A. (2006, Desember). Klasifikasi data polarimetrik-SAR dengan menggunakan jaringan syaraf tiruan beserta observasi efek speckle-filteringnya. *Prosiding pada Pertemuan Ilmiah Tahunan XV Masyarakat Penginderaan Jauh Indonesia (PIT-MAPIN 2006)*. Bandung, Indonesia.
- Sambodo, K.A. (2006, Juni). Aplikasi open source untuk pengolahan data polarimetrik-SAR. *Prosiding pada Workshop II Indonesia Goes Remote Sensing Open Source (IGORSOS-2)*. Bandung, Indonesia.
- Sambodo, K.A., Murni, A., Nur, M., Harwikarya, Cahyati, D., Hardianto, D., dan Teguh, K. (2006, Desember). *Pemanfaatan dan pengembangan model dan software berbasis open source untuk klasifikasi data polarimetrik synthetic aperture radar dengan jaringan syaraf tiruan*. Laporan Akhir Riset Unggulan Kemandirian Kedirgantaraan (RUKK) LAPAN.
- Sambodo, K.A., Murni, A., and Nur, M. (2007a, March). *Classification of polarimetric-SAR data with neural network using combined features extracted*

from scattering models and texture analysis. Paper presented at JAXA Workshop and IReSES Symposium 2007. Bali, Indonesia.

- Sambodo, K.A., Murni, A., and Kartasasmita, M. (2007b). Classification of polarimetric-SAR data with neural network using combined features extracted from scattering models and texture analysis. *International Journal of Remote Sensing and Earth Sciences*, vol. 4, pp. 1-17.
- Sambodo, K.A., Murni, A., and Kartasasmita, M. (2008, August). Classification of polarimetric-SAR data using fuzzy maximum likelihood estimation clustering with consideration of complementary information based-on polarimetric parameters, target scattering characteristics, and spatial context. In *Proceeding of the 4th International Conference on Information & Communication Technology and Systems*, vol. 1, number 1, pp. 562-571. Surabaya, Indonesia.
- Santoro, M. (2003). *Estimation of Biophysical Parameters in Boreal Forests from ERS and JERS SAR Interferometry*. Ph.D. thesis, Department of Geoinformatics, Friedrich-Schiller University Jena, Germany.
- Scheuchl, B., Caves, R., Cumming, I., and Staples, G. (2001, August). H/A/ α -based classification of sea ice using SAR polarimetry. In *Proceedings of the 23rd Canadian Symposium on Remote Sensing*. Quebec, Canada.
- Skriver, H., Dierking, W., Gudmandsen, P., Le Toan, T., Moreira, A., Papathanassiou, K., and Quegan, S. (2003, January). Applications of synthetic aperture radar polarimetry. In *Proceedings of the 1st International Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry*. Frascati, Italy.
- Tso, B. and Mather, P.M. (2001). *Classification Methods for Remotely Sensed Data*. London: Taylor & Francis.

Tzeng, Y.C. and Chen, K.S. (1998). A fuzzy neural network to SAR image classification. *IEEE Trans. Geosci. Remote Sensing*, vol. 36, No 1, pp. 301-307.

Universitas Indonesia (2008, Juni). *Keputusan Rektor Universitas Indonesia Nomor 628/SK/R/UI/2008 tentang Pedoman Teknis Penulisan Tugas Akhir Mahasiswa Universitas Indonesia*. 16 Juni 2008.

Woodhouse, I.H. (2006). *Introduction to Microwave Remote Sensing*. Boca Raton: CRC Press Taylor & Francis.



LAMPIRAN I


Daftar paper dan keikutsertaan dalam kegiatan ilmiah terkait dengan penelitian tentang pengolahan data polarimetrik-SAR

- 1) Sambodo, K.A. dan Teguh, K. (2005, September). Klasifikasi data polarimetrik radar dengan metode dekomposisi Cloude & Pottier. *Prosiding pada Pertemuan Ilmiah Tahunan XIV Masyarakat Penginderaan Jauh Indonesia (PIT-MAPIN 2005)*. Surabaya, Indonesia.
- 2) Sambodo, K.A. dan Murni, A. (2006, Desember). Klasifikasi data polarimetrik-SAR dengan menggunakan jaringan syaraf tiruan beserta observasi efek speckle-filteringnya. *Prosiding pada Pertemuan Ilmiah Tahunan XV Masyarakat Penginderaan Jauh Indonesia (PIT-MAPIN 2006)*. Bandung, Indonesia.
- 3) Sambodo, K.A. (2006, Juni). Aplikasi open source untuk pengolahan data polarimetrik-SAR. *Prosiding pada Workshop II Indonesia Goes Remote Sensing Open Source (IGORSOS-2)*. Bandung, Indonesia.
- 4) Sambodo, K.A., Murni, A., Nur, M., Harwikarya, Cahyati, D., Hardianto, D., dan Teguh, K. (2006, Desember). *Pemanfaatan dan pengembangan model dan software berbasis open source untuk klasifikasi data polarimetrik synthetic aperture radar dengan jaringan syaraf tiruan*. Laporan Akhir Riset Unggulan Kemandirian Kedirgantaraan (RUKK) LAPAN.
- 5) Sambodo, K.A., Murni, A., and Nur, M. (2007a, March). *Classification of polarimetric-SAR data with neural network using combined features extracted from scattering models and texture analysis*. Paper presented at JAXA Workshop and IReSES Symposium 2007. Bali, Indonesia.

- 6) Sambodo, K.A., Murni, A., and Kartasasmita, M. (2007b). Classification of polarimetric-SAR data with neural network using combined features extracted from scattering models and texture analysis. *International Journal of Remote Sensing and Earth Sciences*, vol. 4, pp. 1-17.
- 7) Sambodo, K.A., Murni, A., and Kartasasmita, M. (2008, August). Classification of polarimetric-SAR data using fuzzy maximum likelihood estimation clustering with consideration of complementary information based-on polarimetric parameters, target scattering characteristics, and spatial context. In *Proceeding of the 4th International Conference on Information & Communication Technology and Systems*, vol. 1, number 1, pp. 562-571. Surabaya, Indonesia.
- 8) Sambodo, K.A., Murni, A., Dewanti, R. dan Kartasasmita, M. (2009, April). *Klasifikasi data polarimetrik ALOS-PALSAR menggunakan fuzzy maximum likelihood estimation clustering dengan mengintegrasikan informasi komplementer parameter polarimetrik, karakteristik hamburan balik sinyal radar, dan spasial kontekstual*. Paper dipresentasikan pada Semiloka Geomatika SAR Nasional (GeoSARNas) IPB tanggal 21 April 2009. Bogor, Indonesia.

LAMPIRAN 2

Paper yang dipublikasikan dalam International Conference on Information & Communication Technology and Systems (Agustus 2008), dengan judul “Classification of polarimetric-SAR data using fuzzy maximum likelihood estimation clustering with consideration of complementary information based-on polarimetric parameters, target scattering characteristics, and spatial context”.



The 4th International Conference on Information & COMMUNICATION TECHNOLOGIES AND SYSTEMS

ICTS

August 5 2008, Surabaya - Indonesia



Proceedings

INFORMATICS Department
Faculty of Information Technology
Institut Teknologi SEPULUH NOPEMBER



ITS



JICA PREDICT

Metodologi Klasifikasi..., Katmoko Ari Sambodo, Fasilkom UI, 20
Faculty of Engineering



CLASSIFICATION OF POLARIMETRIC-SAR DATA USING FUZZY MAXIMUM LIKELIHOOD ESTIMATION CLUSTERING WITH CONSIDERATION OF COMPLEMENTARY INFORMATION BASED-ON POLARIMETRIC PARAMETERS, TARGET SCATTERING CHARACTERISTICS, AND SPATIAL CONTEXT

Katmoko Ari Sambodo*, Aniati Murni**, and Mahdi Kartasasmita*

* Lembaga Penerbangan dan Antariksa Nasional (LAPAN), Jl. LAPAN No. 70, Pekayon, Pasar Rebo, Jakarta, Indonesia.

** Faculty of Computer Science, University of Indonesia, Kampus UI Depok, 16424, Indonesia.

email : katmoko_ari@yahoo.com

ABSTRACT

This paper shows a study on an alternative method for unsupervised classification of polarimetric-SAR data. First, two feature extraction methods are performed in order to exploit the information of fully polarimetric-SAR data properly. One is based on derivation of features from polarimetric covariance matrix (totally nine parameters which represent each polarization power, polarimetric coherence, and polarimetric phase difference), and other is based on Cloude's polarimetric decomposition (totally three parameters which characterize the target's scattering mechanism). A feature reduction technique based on maximum noise fraction (MNF) transformation is then applied to these features to obtain most pertinent information and remove any redundant and other irrelevant information. Classification stage is then performed using fuzzy maximum likelihood estimation (FMLE) clustering algorithm. FMLE algorithm allows for ellipsoidal clusters of arbitrary extent and is consequently more flexible than standard fuzzy K-means clustering algorithm. However, basic FMLE algorithm makes use exclusively the spectral (or intensity) properties of the individual pixel vectors and spatial-contextual information of the image was not taken into account. Hence, poor (noisy) classification result is usually obtained from SAR data due to the presence of speckle noise. In this paper, we propose a modified FMLE which integrate basic FMLE (pixel-by-pixel basis) clustering result with spatial-contextual information by statistical analysis of local neighborhoods.

The proposed method has been tested on E-SAR polarimetric data acquired on the area of Penajam, East Kalimantan, Indonesia. Results obtained show classified images improving land-cover discrimination performance, exhibiting

homogeneous region, and preserving edge and other fine structures.

Keywords : Polarimetric-SAR, unsupervised classification, polarimetric parameters and decomposition, wave scattering mechanism, maximum noise fraction (MNF) transformation, fuzzy maximum likelihood estimation (FMLE) clustering, spatial-contextual.

1 INTRODUCTION

Fully Polarimetric - Synthetic Aperture Radar (SAR) sensors are becoming more and more important in remote sensing applications due to: 1) its all-weather, day and night operational capability; 2) its sensitivity of the polarization state of the backscattered wave to physical characteristics of the ground target (e.g. shape, size, orientation, surface roughness, moisture content, dielectric properties of the target) [1], [2]. The utilization of multi-polarized wave in polarimetric-SAR system allows us to extract additional information which can be employed as classification features, thus giving better land use/cover classification results than single-channel single-polarization SAR data [1]-[3]. For this reasons, in recent years, the remote sensing community has become increasingly interested in the use of polarimetric-SAR data for the production of high accuracy land-cover maps.

Unsupervised classification is an important technique for automatic analysis of polarimetric-SAR data, since it can be performed regardless the availability of training dataset derived usually from ground truth information or other priori information about analyzed areas (which often both cost and time consumption). In the literature, many unsupervised classification approaches for polarimetric-SAR have been proposed. Basically, there are two types of algorithms: One type is based on the analysis of physical scattering properties,

which has the advantage that some information about class type is available [4]. Another type is based purely on statistical clustering of polarimetric-SAR data [5], [6]. Additionally, several interesting combinations of these types of classification approaches have been found [7]-[9].

These algorithms have been found to be applicable to land cover classification [10] and forest classification [11]. In general, acceptable classification results were obtained, however, in some cases, they also reported some limitations of these methods for further possibility to discriminate and classify into different object/ land cover types especially with similar scattering mechanism and often yield clusters (classes) whose physical meaning is uncertain. To overcome these problems, it is advisable to use the additional information which can be included as extension input features thus reduce inter-class ambiguity and improve the classification performance [12], [13]. Although such additional information can be obtained from other data sources (such optical data, multi-frequency radar data, interferometric coherence, geological maps, etc), the consideration of additional information which can be extracted directly from same polarimetric-SAR data but using different aspect would be meaningful (such image texture, context, structural relationships, etc). However, most of these algorithms use a 3x3 complex covariance matrix (or coherency matrix) form as an input feature, thus other additional features (which usually represent as various data types) can not be added into this input form.

Another limitation of these algorithms is that they performed on a pixel-by-pixel basis, i.e., each pixel is treated independently of its neighbors; spatial context is only indirectly considered during speckle filtering. The local neighborhood does indeed have a significant influence on a pixel's class membership: When a certain region already has already been classified, with high confidence, as belonging to a single class, it becomes comparatively unlikely that a pixel in this region belongs to another class. The much more likely scenario is misestimation of its covariance matrix due to speckle noise, which usually produced very noisy classification results (often appear as "salt-and-pepper" effect even in homogeneous areas). Due to inherently high noise level of SAR data, the inclusion of local neighborhoods in statistical decision about class membership is helpful to support homogeneous classification results [9], [14].

In this paper, we propose an unsupervised classification method based on fuzzy maximum likelihood estimation (FMLE) clustering algorithm

that integrates complementary information of several polarimetric parameters and target scattering characteristic features, and spatial contextual information (see Fig.1). Fuzzy classification techniques allow each pixel in the image to belong to more than one cluster according to its degree of membership in each cluster [14]-[16]. Therefore, it is suitable for classification of SAR data as the presence of speckle noise often causes many pixels in the data are really ambiguous (i.e., imprecise, incomplete, and not totally reliable). A FMLE clustering has been chosen which it allows for ellipsoidal forms of the clusters and is consequently considerably more flexible than standard fuzzy K-means (FKM) clustering (with the use of Euclidean distance, thus giving circular clusters) [14]-[16]. Further advantage is that other features can be easily

added into FMLE clustering process by extending the dimension of the input data vectors. These properties enable us to combine the wide range of information (features) which can be derived from polarimetric-SAR data using different feature extraction methods. In our case, motivate by our previous publication [13], we will combine a number of polarimetric parameters (polarization power, coherence, and phase difference) extracted from polarimetric covariance matrix and physical scattering characteristics of land use/cover based on Cloude's polarimetric decomposition. These features have complementary information which can be integrated in order to improve the discrimination of different land use/cover types. To remove any redundant information and irrelevant information which may contain in these features, we apply a feature reduction scheme based on maximum noise fraction (MNF) transformation as a precursor step of FMLE classification.

However, the basic FMLE algorithm is a pixel-by-pixel basis classifier. Thus, in order to exploit the spatial-contextual information, we investigate the possibility of using probabilistic relaxation scheme. It iteratively adjust some initial estimates of the class-membership probabilities by reference to the class-membership probabilities of pixels in its neighborhood.

The proposed method has been tested on a fully polarimetric E-SAR (L-Band) data acquired on the area of Penajam, East Kalimantan, Indonesia.

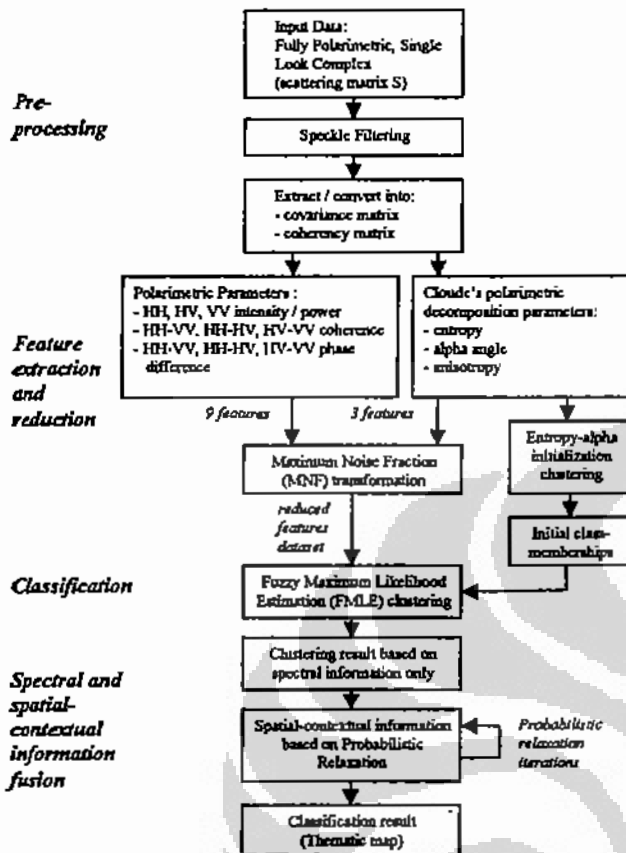


Fig. 1. Block scheme of the proposed method.

2 FEATURE EXTRACTION SCHEMES

2.1 Polarimetric Data Representation and Polarimetric Parameter Feature Extraction

For radar polarimetry, the backscattering properties of the target can be completely described by a 2×2 complex scattering matrix, S , such that

$$S = \begin{bmatrix} S_{hh} & S_{hv} \\ S_{vh} & S_{vv} \end{bmatrix} \quad (1)$$

where S_{hh} is the scattering element of horizontal transmitting and horizontal receiving polarization, and the other three elements are similarly defined. For the reciprocal backscattering case, $S_{hv} = S_{vh}$. Because there are effectively only three independent elements, the polarimetric scattering information can also be represented by a target vector, $k = [S_{hh} \ \sqrt{2}S_{hv} \ S_{vv}]^T$ (where, the superscript "T" denotes the matrix transpose). The $\sqrt{2}$ on the S_{hv} term is to ensure consistency in the

span (total power) computation. A polarimetric covariance matrix C can be formed by [1]

$$C = k k^T = \begin{bmatrix} |S_{hh}|^2 & \sqrt{2}S_{hh}S_{hv}^* & S_{hh}S_{vv}^* \\ \sqrt{2}S_{hv}S_{hh}^* & 2|S_{hv}|^2 & \sqrt{2}S_{hv}S_{vv}^* \\ S_{vv}S_{hh}^* & \sqrt{2}S_{vv}S_{hv}^* & |S_{vv}|^2 \end{bmatrix} \quad (2)$$

where the superscript "*" denotes the complex conjugate.

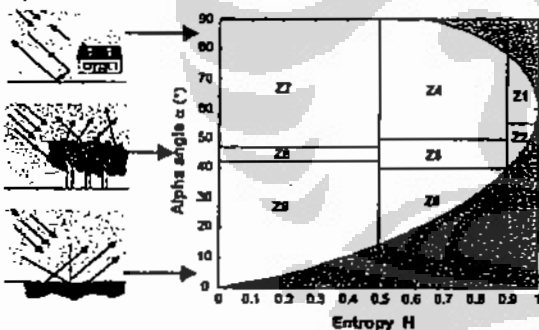
C is a 3×3 Hermitian matrix, and has only six independent elements which can be employed as feature sets for classification purposes. Three real numbers on the main diagonal represent the powers (or intensity) of each polarization channels. The other three complex numbers on the off diagonal represent the complex correlations, which can be used to quantify the similarity of waves (or coherence) at different polarization. The magnitude of each complex number gives a measure of the degree of polarimetric coherence and lies between zero (incoherent) and one (completely coherent). The phase of each complex number represents the phase difference between two polarization states and lies between 0 and 180° . The degree of polarimetric coherence and polarimetric phase difference closely related to the physical characteristics of the target scene so it can be used as a feature set to discriminate different land-cover types [1].

2.2 Feature Extraction based on Cloude's Polarimetric Decomposition

Fully polarimetric data provides unique possibility to separate scattering contributions of different nature, which can be associated to certain elementary scattering mechanisms (e.g. surface or single-bounce, double-bounce, and volume scattering). Several decomposition techniques have been proposed for extracting and identifying this valuable information. One method is based on polarimetric target decomposition theory proposed by Cloude and Pottier [4], which is capable of covering whole range of scattering mechanisms and yields an unsupervised classification scheme. The target's scattering mechanism can be parameterized by entropy H , anisotropy A , and mean alpha angle $\bar{\alpha}$ which derived from the eigenvalue decomposition of the coherency matrix. (The coherency matrix is formed, similarly with the covariance matrix C , but using the Pauli target vector $k_p = 1/\sqrt{2} [S_{hh} + S_{vv} \ S_{hh} - S_{vv} \ 2S_{hv}]^T$). The entropy H , ranging from 0 to 1 , represents the randomness of the scattering, with $H = 0$ indicating a single scattering mechanism (isotropic scattering) and

$H = 1$ representing a random mixture of scattering mechanisms. For ocean and less rough surfaces, surface scattering will dominate, and H is near 0. For heavily vegetated areas, the H value will be high, due to multiple scattering mechanisms. The anisotropy A represents the relative importance of the second and third scattering mechanisms. A high anisotropy states that only the second scattering mechanism is important, while a low anisotropy indicates that the third scattering mechanism also plays a role. The mean alpha angle $\bar{\alpha}$ reveals the averaged scattering mechanisms from surface scattering ($\bar{\alpha} \rightarrow 0^\circ$), volume scattering ($\bar{\alpha} \rightarrow 45^\circ$), to double bounce scattering ($\bar{\alpha} \rightarrow 90^\circ$). H and $\bar{\alpha}$ clearly characterize the scattering characteristics of a medium.

Cloude and Pottier further suggest an unsupervised classification scheme, using the $H - \bar{\alpha}$ plane sub-divide into 8 basic zones characteristic of different scattering behaviors, as shown in Fig. 2. However, this unsupervised estimation of the type of scattering mechanisms may reach some limitations due to the arbitrarily fixed linear boundaries in the $H - \bar{\alpha}$ plane which may not fit to data distribution, leading to noisy classification results [7], [11]. Hence, in this work, we use entropy H , anisotropy A , and mean alpha angle $\bar{\alpha}$ directly as classification



Physical scattering characteristics :
 Z0 : Low Entropy Surface Scattering
 Z1 : Low Entropy Dipole Scattering
 Z2 : Low Entropy Multiple Scattering
 Z3 : Medium Entropy Surface Scattering
 Z4 : Medium Entropy Vegetation Scattering
 Z5 : Medium Entropy Multiple Scattering
 Z6 : (Not a Feasible Region in H- α space)
 Z7 : High Entropy Vegetation Scattering
 Z8 : High Entropy Multiple Scattering

Fig. 2. $H - \bar{\alpha}$ plane

feature sets together with features extracted from first feature extraction method. To remove any redundant information and irrelevant information which may contain in these features, we apply the following feature reduction scheme as a precursor step of FMLE classification.

2.3 Feature Reduction based on Maximum Noise Fraction (MNF) Transformation

Classification of high-dimensional data is inherently difficult and generally high computational-cost. A feature reduction scheme is, therefore, needed to reduce the number of input features by removing any redundant information and irrelevant information from the complete feature space as a precursor step of classification process. For this purpose, in this paper, we use the maximum noise fraction (MNF) transformation. This transform have been commonly used, especially in the study of hyperspectral data, to determine the inherent dimensionality of image data, to segregate noise in the data, and to reduce the computational requirements for subsequent processing [14], [17]. The MNF transform is essentially two cascaded principal components (PC) transformations. The first transformation, based on an estimated noise covariance matrix, decorrelates and rescales the noise in the data. This first step results in transformed data in which the noise has unit variance and no band-to-band correlations. The second transform is a standard principal components transformation of the noise-whitened data. The inherent dimensionality of the data is then determined by examination of the final eigenvalues and the associated images. The data space could be divided into two parts: one part associated with large eigenvalues and coherent eigenimages, and a complementary part with near-unity eigenvalues and noise-dominated images. In this work, the noise covariance is estimated from a homogeneous area of the original (input) feature datasets. The idea of extracting noise covariance in this way is based on the assumption that the backscattering properties of radar signal should exhibit similar characteristics over the homogeneous area, thus any variations in the measured values can be viewed as a noise.

3 PROPOSED FUZZY MAXIMUM LIKELIHOOD ESTIMATION CLUSTERING INCLUDING SPATIAL CONTEXT

There have been many different families of fuzzy clustering algorithms proposed in the last decade. In this paper, a fuzzy maximum likelihood estimation (FMLE) clustering has been chosen which it allows for ellipsoidal forms of the clusters and is consequently considerably more flexible than standard fuzzy K-means (FKM) clustering (with the use of Euclidean distance, thus giving circular

clusters) [14]-[16]. Further advantage is that other features can be easily added into FMLE clustering process by extending the dimension of the input data vectors. These properties enable us to combine the wide range of information (features) which can be derived from polarimetric-SAR data using different feature extraction methods, as described in previous section.

3.1 Fuzzy Maximum Likelihood Estimation Clustering (FMLE) Algorithm

Let $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ be the input features set which consists of n vectors $\mathbf{x}_i \in R^d$ (d is dimension of input features). Assuming there are K clusters (classes), $\mu_{ki} = \mu_k(\mathbf{x}_i) \in [0,1]$ is the membership of the i -th sample \mathbf{x}_i in the k -th cluster. Each sample point \mathbf{x}_i satisfies the following two constraint

$$\mu_{ki} \in [0,1] \text{ and } \sum_{k=1}^K \mu_{ki} = 1, \quad k=1..n \quad (3)$$

The probability of cluster k is given by

$$P(k) = \frac{n_k}{n} = \frac{\sum_{i=1}^n \mu_{ki}}{n}, \quad k=1..K \quad (4)$$

The cluster means \mathbf{m}_k and covariance matrices \mathbf{s}_k can then be written in the form

$$\mathbf{m}_k = \frac{\sum_{i=1}^n \mu_{ki} \mathbf{x}_i}{\sum_{i=1}^n \mu_{ki}} \quad \mathbf{s}_k = \frac{\sum_{i=1}^n \mu_{ki} (\mathbf{x}_i - \mathbf{m}_k)(\mathbf{x}_i - \mathbf{m}_k)^T}{\sum_{i=1}^n \mu_{ki}}, \quad k=1..K \quad (5)$$

These moments in turn determine the membership probabilities according to $u_{ki} = P(k | \mathbf{x}_i)$, the posterior probability $P(k | \mathbf{x}_i)$ for cluster k given the observation \mathbf{x}_i . That is, invoking Bayes' Theorem and assuming each cluster to have a multivariate normal density distribution, we have

$$u_{ki} = P(k | \mathbf{x}_i) = cP(k)P(\mathbf{x}_i | k) \\ = cP(k) \frac{1}{\sqrt{|\mathbf{s}_k|}} \exp \left[-\frac{1}{2} (\mathbf{x}_i - \mathbf{m}_k)^T \mathbf{s}_k^{-1} (\mathbf{x}_i - \mathbf{m}_k) \right] \quad (6)$$

where c is a normalization constant independent of k which can be determined from (3). Starting from some initial choice of the memberships μ_{ki} , the

FMLE algorithm consists of a simple iteration of Equations (3-6) until convergence.

Because of the exponential distance dependence of the memberships in Equation (6), the algorithm is very sensitive to initialization conditions, and can even become unstable. To avoid this problem, we follow the suggestion of Gath and Geva [16] and first obtain initial values for the μ_{ki} by preceding the calculation with the FKM algorithm. For this purpose, in this work, we use only the entropy H and mean alpha angle $\bar{\alpha}$ features to obtain initial μ_{ki} . However, the eight zones (or classes) in the $H-\bar{\alpha}$ plane are not applied here, instead, we determine the number of classes based on the image content and a ground survey information.

3.2 Spatial-contextual Information based on Probabilistic Relaxation

The FMLE clustering algorithm described above make use exclusively the spectral (or intensity) properties of the individual pixel vectors and spatial-contextual information of the image was not taken into account.

In order to incorporate spatial-contextual information in classification process, in this paper, we adapted the probabilistic relaxation scheme. This idea is based on the assumption that two neighboring pixels are not entirely statistically independent: In reality, spatially random classification results are not very likely, instead continuous areas of certain sizes are to be expected. It seems clear that information from neighboring pixels should increase the discrimination capabilities of the pixel-based measured data, and thus, improve the classification accuracy and the interpretation efficiency. Such ancillary information can be expressed by a neighborhood function q , which must somehow reflect the contextual information of the neighborhood [9], [14]. In order to define it, a compatibility coefficient $P(\mathbf{x}_i, k | \mathbf{y}_i, r)$ is introduced, i.e., the conditional probability that pixel \mathbf{x}_i falls into class k , if a neighboring pixel \mathbf{y}_i belongs into class r . As mentioned before, K possible class assignments are possible; furthermore it is possible to incorporate a larger neighborhood consisting of L pixels. Based on this, a neighborhood function

$$q_k = q_k(\mathbf{x}_i) = \sum_{r=1}^L \sum_{j=1}^K P(\mathbf{x}_i, k | \mathbf{y}_i, r) P(\mathbf{y}_i, r) \quad (7)$$

can be defined, which describes the total joint probability over all neighbours and their class assignments, that a pixel \mathbf{x}_i falls into class k . The

probability $q_k = q_k(\mathbf{x}_i)$ gives information about class membership of pixel \mathbf{x}_i solely by examination of its neighborhood and without considering content of the pixel itself.

After the FMLE clustering procedure, the class membership probabilities (according to Equation 6) are known. This allows to evaluate Equation (7) and results in two kinds of class probabilities for each pixels: One, q_k , based only on spatial-contextual information, and another, μ_k , based on spectral information only. A combined spectral-spatial class membership is then determined by

$$\mu_k = \frac{\mu_k q_k}{\sum_{k=1}^K \mu_k q_k} \quad (8)$$

In our case, the compatibility coefficient is estimated from the initially classified image (result of pixel-by-pixel basis FMLE clustering).

Alternatively, this probabilistic relaxation procedure can also be iterated arbitrarily often by applying Equations (7) and (8) iteratively. In this work, we will observe the influence of number iterations of the probabilistic relaxation process on the classification result. An optimal number of iterations then will be determined by experiments.

4 RESULT

The proposed method is tested using single look complex (SLC) fully polarimetric-SAR data acquired over Penajam area, East Kalimantan Province. These data were acquired in L-band by Airborne E-SAR method on November 17th, 2004. The spatial resolution of the data used is 1.99 m and 3.0 m, in range and azimuth respectively. The scene under study contains different type of land covers: forest, fields, bare soils, and water area. Fig. 3 shows the RGB image (formed using Pauli decomposition) and a set of ground survey information.




Fig. 3. Ground survey information.

For preprocessing, we construct scattering matrix from single look data (SLC) data for each polarization, then convert into polarimetric covariance matrix and coherency matrix, and apply speckle filtering using Lee Polarimetric Filter. In this experiment, a 3x3 window has been used. Larger windows provide more speckle smoothing but may smear fine details in the image. Totally, nine polarimetric parameters, i.e.: three power / intensity (HH, HV, and VV), three polarimetric coherence, and three polarimetric phase difference are then extracted from polarimetric covariance matrix. Applying feature extraction based on Cloude's polarimetric decomposition, three features i.e.: entropy H , mean alpha angle $\bar{\alpha}$, and anisotropy A are obtained. We then combine these two feature extraction results from both methods to form totally twelve features set and perform feature reduction using MNF transformation. Noise covariance is estimated using a homogeneous area in the images as shown in Fig. 3. The resulting bands of the MNF transformed data are shown in Fig. 4-a, with the associated eigenvalues are presented in Fig. 4-b. By analyzing eigenvalues and associated MNF bands, we can determine that most of the information contents are concentrated only on four first bands. In this case, eigenvalues are larger than 3. The remaining bands have

eigenvalues near one and the associated images are also predominantly by noise.




Fig. 4. Results of maximum noise fraction (MNF) transformation for feature reduction purpose.

In order to better understand the behavior of the different feature extraction methods as well as the effectiveness of the feature reduction scheme based on MNF transformation, we carried out several trials generating four datasets as following:

- 1) A dataset with the nine features of polarimetric parameters
- 2) A dataset with the three features of Cloude's polarimetric decomposition
- 3) A combined dataset of 1) and 2) (totally 12 features)
- 4) A dataset which contain reduced features after applying MNF transformation on dataset 3) (totally 4 features, i.e., four first MNF bands)

These four datasets are then employed as input for FMLE classifier. First, we carried out experiments without inclusion of spatial-contextual information. The classification results using dataset (1), dataset (2), dataset (3), and dataset (4) are shown in Fig. 5-a, 5-b, 5-c, and 5-d respectively. We can observe that polarimetric parameter features alone (see Fig. 5-a) can provide reasonable result, but with some misclassification between forest, fields, and bare soils. For example, the bare soil areas in upper left corners of the image were

erroneously classified as forest. On the other hand, Cloude's decomposition features (see Fig. 5-b) can identify accurately these bare soil areas and enhance the discrimination between forest and non-forest areas. By combining these two feature datasets, the discrimination of different land cover types can be improved, thus giving better classification result (see Fig. 5-c) than those obtained using datasets of each feature extraction methods. Fig. 5-d shows the classification result using reduced features dataset (MNF band 1-4). When the classification results in Fig. 5-c and 5-d are compared, it is clearly shown that although the dimension of the input features have been reduced (from 12 to 4 features), there is no significant deterioration in the classification result. Moreover, it is worth noting that the result obtained with reduced features dataset exhibit less "salt-and-pepper" effect than those obtained with the original (complete) dataset. These indicate that MNF transformation used in this study are not only effective for features reduction of our complete datasets but also useful for further speckle noise reduction.

Next, we apply probabilistic relaxation to these classification results to obtain spatial contextual information, and the results with 1, 3, 5, and 9 iterations are presented in Fig. 5-e, 5-f, 5-g, and 5-h respectively. To conserve the space, we only present the results of reduced features dataset (dataset (4)). Comparing with Fig. 5-d, although more homogeneous result is obtained, but the improvement is marginal. The classification results get more homogeneous (suppress more "salt and pepper" effect in homogeneous areas) by increasing the number of iteration. However, too many iterations lead to a widening of the effective neighborhood of a pixel to such an extent that fully irrelevant spatial information falsifies the final classification results. It can also be confirmed in Fig. 5-g and 5-h (with 5 and 9 iterations), which some erosion of the object boundaries (particularly when the objects are small in size) are occurred evidently. We conclude that the best results are obtained with 2-4 iterations, as it provide homogeneous classification result, but still preserve edge and other fine structures.

As comparison, the classification results using standard fuzzy K-means (FKM) clustering (using Euclidean distance) is also presented in Fig. 5-i. In all trials, we observed that the FMLE clustering perform consistently better than the FKM clustering. Some misclassification between forest, fields, water, and bare soils are occurred evidently, and particularly field class can not be accurately identified by FKM clustering algorithm.

A quantitative evaluation of the overall accuracy obtained in this proposed method was not possible, because a detailed ground truth of the analyzed region was not available. However, on the

basis of the information available on some areas and of a careful visual inspection of RGB image (Fig. 3), we can conclude that the proposed approach provided satisfactory results.

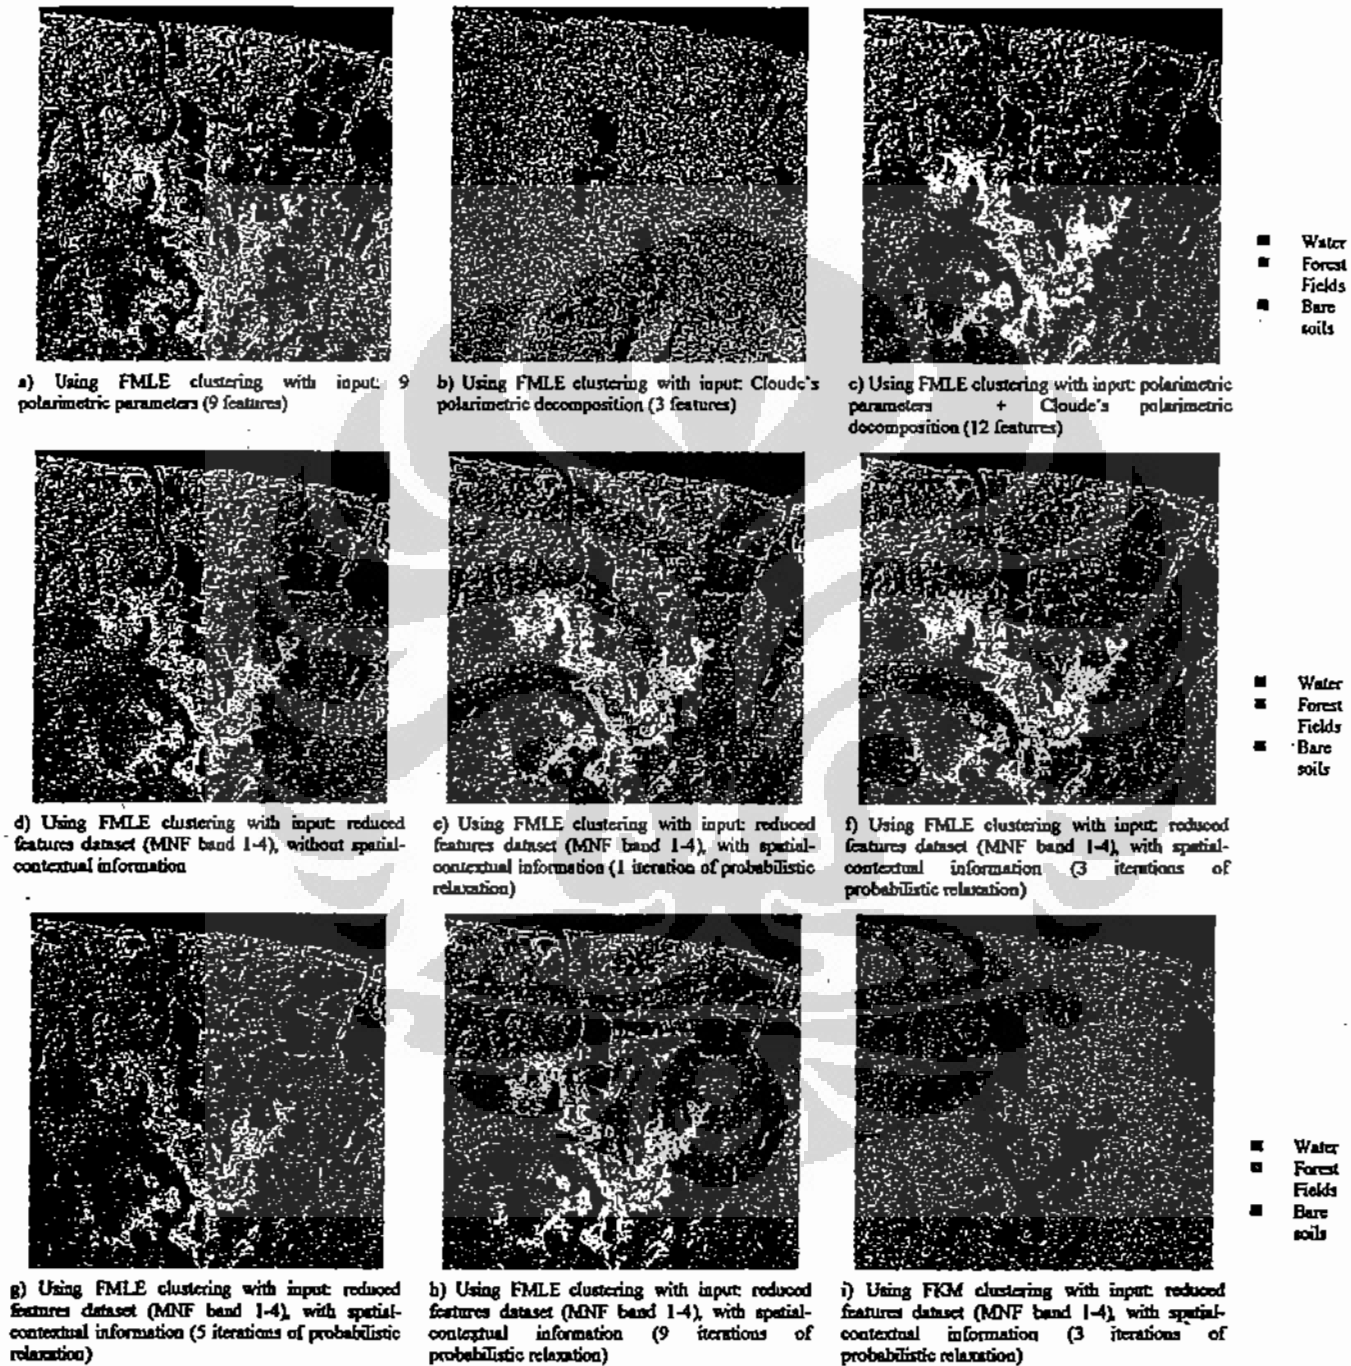


Fig. 5. Classification results using FMLE clustering without and with spatial-contextual information based on probabilistic relaxation. (Classification result using FKM clustering is also presented as comparison.)

5 CONCLUSION

An alternative method for unsupervised classification of polarimetric-SAR data has been proposed. The method was designed by integrating the combined features extracted from polarimetric covariance matrix and Cloude's polarimetric decomposition (which characterize the target's scattering mechanism) with spatial contextual-supported fuzzy maximum likelihood estimation (FMLE) classifier.

The proposed method has been tested on a fully polarimetric, single look complex E-SAR (L-Band) data acquired on the area of Penajam, East Kalimantan, Indonesia. Experimental results show that the proposed method improves land-cover discrimination performance, and provides robust and homogeneous classification results but still preserve edge and other fine structures.

ACKNOWLEDGEMENT


The authors would like to thank The Ministry of Forestry Republic of Indonesia for providing the E-SAR polarimetric data. The used polarimetric data set was acquired through Indonesian Airborne Radar II Experiment supported by the European Space Agency.

REFERENCE

- [1] I. Woodhouse, *Introduction to Microwave Remote Sensing*, Boca Raton, CRC Press Taylor & Francis, 2006.
- [2] L. Bruzzone, M. Marconcini, U. Wegmuller, and A. Wiesmann, An Advanced method for the automatic classification of multitemporal SAR images, *IEEE Trans. Geosci. Remote Sensing*, vol. 42, no. 6, Jun. 2004, 1321-1334.
- [3] V. Karathanassi and M. Dabboor, Land cover classification using E-SAR polarimetric data, in *Proceedings of the XXth ISPRS Congress*, 2004.
- [4] S.R. Cloude and E. Pottier, An entropy based classification scheme for land applications of polarimetric SAR, *IEEE Trans. Geosci. Remote Sensing*, vol. 35, no. 1, Jan 1997, 68-78.
- [5] G. Davidson, K. Ouchi, G. Saito, N. Ishitsuka, N. Mohri, and S. Uratsuka, Polarimetric classification using expectation methods, *Polarimetric and Interferometric SAR Workshop, Communications Research Laboratory, Tokyo*, 2002.
- [6] J. Beaulieu, and R. Touzi, Segmentation of textured polarimetric SAR scenes by likelihood approximation, *IEEE Trans. Geosci. Remote Sensing*, vol. 42, Oct. 2004, 2063-2072.
- [7] J.S. Lee, M.R. Grunes, T.L. Ainsworth, L.J. Du, D.L. Schuler, and S.R. Cloude, Unsupervised classification using polarimetric decomposition and the complex Wishart classifier, *IEEE Trans. Geosci. Remote Sensing*, vol. 37, no. 5, Sep. 1999, 2249-2258.
- [8] P.R. Kersten, J.S. Lee, and T.L. Ainsworth, Unsupervised classification of polarimetric synthetic aperture radar images using fuzzy clustering and EM clustering, *IEEE Trans. Geosci. Remote Sensing*, vol. 43, no. 3, Mar. 2005, 519-527.
- [9] A. Reigber, M. Jager, M. Neumann, and L. Ferro-Famil, Polarimetric fuzzy K-means classification with consideration of spatial context, in *Proceedings of the Workshop on POLINSAR - Applications of SAR Polarimetry and Polarimetric Interferometry*, 2007.
- [10] P. Lumsdon, Land cover classification and height estimation in polarimetric SAR interferometry, in *Proceedings of the Workshop on POLINSAR - Applications of SAR Polarimetry and Polarimetric Interferometry*, 2003.
- [11] L. Ferro-Famil, E. Pottier, H. Skriver, P. Lumsdon, R. Moshammer, and K. Papathanassiou, Forest mapping and classification using L-Band Polinsar data, in *Proceedings of the Workshop on POLINSAR - Applications of SAR Polarimetry and Polarimetric Interferometry*, 2005.
- [12] D. Borghys, Y. Yvinec, C. Perneel, A. Pizurica, and W. Philips, Supervised feature-based classification of multi-channel SAR images, in *Pattern Recognition Letters*, vol. 27, Mar. 2006.
- [13] K.A. Sambodo, A. Murni, and M. Kartasasmita, Classification of polarimetric-SAR data with neural network using combined features extracted from scattering models and texture analysis, *International Journal of Remote Sensing*

and Earth Sciences, vol. 4, Sept. 2007, 1-17.

- [14] M.J. Canty, *Image Analysis, Classification and Change Detection in Remote Sensing*, Boca Raton, CRC Press Taylor & Francis, 2006.
- [15] M.J. Canty and A.A. Nielsen, Unsupervised classification of changes in multispectral satellite imagery, in *Proceedings of SPIE, Image and Signal Processing for Remote Sensing X*, vol. 5573, 2004, 356-363.
- [16] I. Gath and A.B. Geva, Unsupervised optimal fuzzy clustering, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, Jul 1989, 773-781.
- [17] J.W. Boardman, K.A. Kruse, and R.O. Green, Mapping target signatures via partial unmixing of AVIRIS data, in *Summaries of the Fifth Annual JPL Airborne Geosciences Workshop*, 1995.



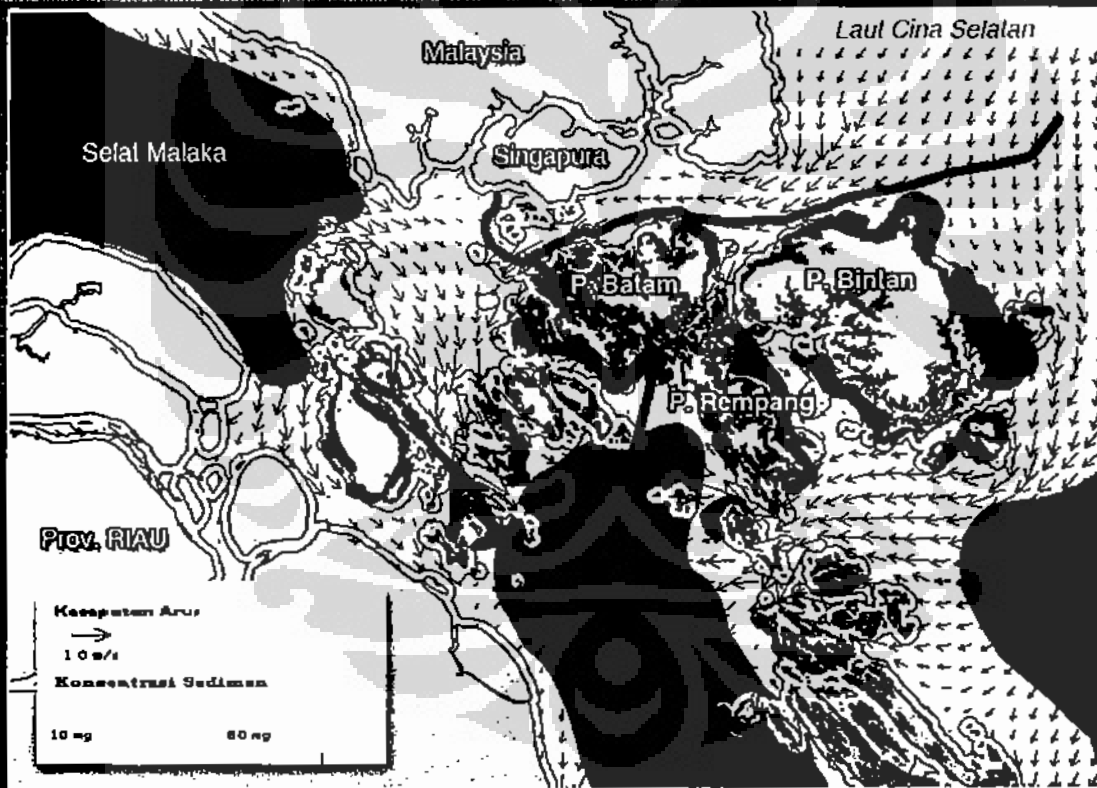
LAMPIRAN 3

Paper yang dipublikasikan dalam *International Journal of Remote Sensing and Earth Sciences* (2007), dengan judul "Classification of polarimetric-SAR data with neural network using combined features extracted from scattering models and texture analysis".





International Journal of Remote Sensing and Earth Sciences



Published by
International Society of Remote Sensing and Earth Sciences
IRESES

September 2007
Volume 4

ISSN: 0216-6739

INTERNATIONAL JOURNAL OF
**REMOTE SENSING
AND EARTH SCIENCES**



Published by
**International Society of Remote Sensing and Earth Sciences
(IReSES)**

CLASSIFICATION OF POLARIMETRIC-SAR DATA WITH NEURAL NETWORK USING COMBINED FEATURES EXTRACTED FROM SCATTERING MODELS AND TEXTURE ANALYSIS

KATMOKO ARI SAMBODO¹, ANIATI MURNI² AND MAHDI KARTASASMITA¹

Abstract

This paper shows a study on an alternative method for classification of polarimetric-SAR data. The method is designed by integrating the combined features extracted from two scattering models (i.e., Freeman decomposition model and Cloude decomposition model) and textural analysis with distribution-free neural network classifier. The neural network classifier (which is based on a feed-forward back-propagation neural network architecture) properly exploits the information in the combined features for providing high accuracy classification results. The effectiveness of the proposed method is demonstrated using E-SAR polarimetric data acquired on the area of Penajam, East Kalimantan, Indonesia.

Keywords: Polarimetric-SAR, scattering model, Freeman decomposition, Cloude decomposition, texture analysis, feature extraction, classification, neural networks.

1. Introduction

Fully polarimetric-SAR data can define the scattering behavior of land use/cover, thus giving better land use/cover classification results than single-channel single-polarization SAR data (Karathanassi and Dabboor, 2004; Woodhouse, 2006). Many different approaches for the so called target (polarimetric) decomposition have been proposed to extract the information about the scattering mechanisms of different nature, which can be employed to assist the interpretation and the classification of polarimetric-SAR data. Freeman decomposition model and Cloude decomposition model are the most intensively used decomposition method for this purpose, because they are based on more realistic scattering models, their simplicity and easy implementation for image processing (Lee *et al.*, 2006; Yamaguchi *et al.*, 2005). In Freeman and Durden, (1998), radar backscatter responses are decomposed into three basic

scattering mechanisms: surface scattering, double bounce scattering, and volume scattering. Volume scattering is modeled by a cloud of randomly oriented dipoles for tree canopy and vegetation. Double-bounce scattering component is modeled by scattering from dihedrals, but allows for reflector surfaces with different dielectric properties, corresponding to, for example trunk-ground interaction in forest scatter. Surface or single-bounce scattering is modeled by a Bragg surface scatterer. Cloude and Pottier (1997) proposed an unsupervised classification based on their target decomposition theory. The medium's scattering mechanism, characterized by entropy H and alpha angle α , are used for classification. The entropy H is a measure of randomness of scattering mechanisms, and the alpha angle α characterizes the scattering mechanisms. The H - α plane was divided into eight zones. The physical scattering characteristic associated with each zone provides information for terrain type assignment.

¹ Lembaga Penerbangan dan Antariksa Nasional (LAPAN), Jl. Lapan No. 70, Pekayon, Pasar Rebo, Jakarta, Indonesia.

² Faculty of Computer Science, University of Indonesia, Kampus UI Depok, 16424, Indonesia.

These polarimetric decomposition methods have been found to be applicable to land cover classification (Cloude and Pottier, 1997; Freeman and Durden, 1998; Lumsdon 2003), sea ice classification (Scheuchl, 2001), and forest classification (Ferro-Famil *et al.*, 2005; Lee *et al.*, 2005). In general, they reported that applying decomposition polarimetric permits to identify in a macroscopic way the type of scattering mechanism. For example, open water and bare soils are characterized by surface scattering. Scattering over forested areas is dominated by volume scattering while urban areas mainly characterized by double bounce scattering. However, in some cases they also observed that these schemes do not provide sufficient sensitivity especially for the separation of the volume scattering class and double scattering class. For example, urban areas (double scattering) are frequently interpreted as forest (volume scattering). It was also reported some limitation for further possibility to discriminate and classify into different object / land cover types in same scattering mechanism, for example, for classifying forested area into different forest types and growth stages.

In order to reduce inter-class ambiguity and improve the classification accuracy, further information has to be used. An analysis of the interferometric coherence can be useful to discriminate various types of forested area (Lee *et al.*, 2005; Ferro-Famil *et al.*, 2005). However, this method works effectively if a pair of polarimetric interferometric data (i.e., two data of the same object acquired from different sensor positions) is available to compute the interferometric coherence information. In this paper, the consideration of additional information which can be extracted directly from a polarimetric image but using different aspect would be meaningful. A texture

approach has been chosen which it can measure several aspects of spatial structure of an image. And we investigate how the textural features can be of help in discriminating different land-cover types. Textural features have a demonstrated ability to support image segmentation in many areas (Tso and Mather, 2001) and have also demonstrated potential for classifying sea ice types (Deng and Clausi, 2005; Clausi and Jernigan, 1998) and urban areas (Acqua and Gamba, 2003) in SAR imagery. Various texture methods are found in the research literature to extract textural features. For SAR image classification, it has been shown that the grey-level cooccurrence matrix (GLCM) method is an effective method to generate appropriate textural features (Deng and Clausi, 2005; Tso and Mather, 2001).

The selection of the classification algorithm is critical issue in the classification of polarimetric data using multi-aspect information. When standard features associated with the intensity or amplitude of SAR signals are exploited, maximum-likelihood classifiers are commonly used. However, our features are extracted from different aspect, so parametric classifiers become more difficult to use, as it is not possible to make reasonable assumptions on the class distributions of these combined features (Tso and Mather, 2001; Bruzzone *et al.*, 2004). In this paper, we propose a classification method that integrates the combined features extracted from two different aspects with distribution-free neural network classifier.

The proposed method is consisted of five main modules: 1) a pre-processing module; 2) a feature-extraction module based on scattering models; 3) a feature-extraction based on texture analysis; 4) a classification module based on neural network; and 5) a post-processing module.

The pre-processing module is based on a set of procedures commonly used in polarimetric-SAR data processing, we first prepare/construct scattering matrix from single look complex (SLC) data for each polarization, then apply speckle reduction filtering. The feature extraction module based on scattering models computes two sets of features derived from two polarimetric decomposition methods: Freeman decomposition and Cloude decomposition. The feature extraction

module based on image texture computes a set of GLCM textural features. The classification module is based on feed-forward back-propagation neural network. The post-processing module is used to improve the classification result by correcting a possible misclassification of a pixel using the membership probability of pixel in its neighborhood. The block scheme of the proposed method is shown in Fig. 1.

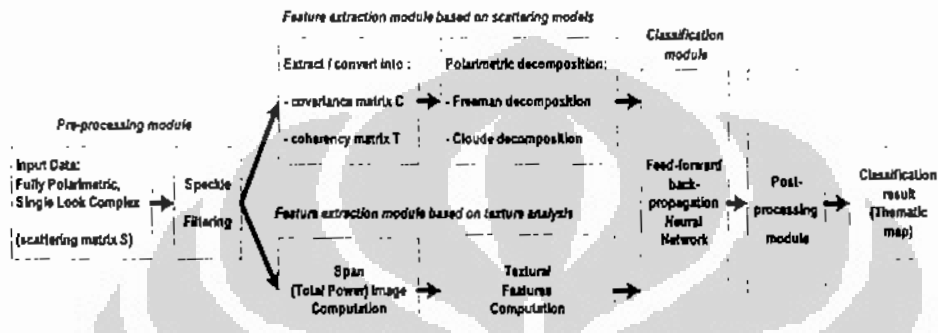


Fig. 1. Block scheme of the proposed method

The proposed method has been tested on a fully polarimetric E-SAR (L-Band) data acquired on the area of Penajam, East Kalimantan, Indonesia. We examined the method using: 1) the combined features of Freeman decomposition model and textural features and 2) the combined features of Cloude decomposition and textural features, and compared both results.

This paper is organized into the following fashions. Section I is introductory. Section II briefly describes the feature extraction based on scattering models. Section III briefly presents feature extraction based on GLCM texture analysis. Section IV explains the classification module, which is based on feed-forward back-propagation neural network and post-processing techniques. The experimental results are reported in

section V, and finally, Section VI provides a discussion and conclusion.

II. Feature Extraction based on Scattering Models

a. Polarimetric Data Representation

For radar polarimetry, the backscattering properties of the target can be completely described by a 2×2 complex scattering matrix, S , such that:

$$S = \begin{bmatrix} S_{hh} & S_{hv} \\ S_{vh} & S_{vv} \end{bmatrix} \quad (1)$$

where S_{hv} is the scattering element of horizontal transmitting and horizontal receiving polarization, and the other three elements are similarly defined. For the reciprocal backscattering case, $S_{hv} = S_{vh}$. The polarimetric scattering information can be represented by a target vector,

$$k = [S_{hh} \quad \sqrt{2}S_{hv} \quad S_{vv}]^T \quad (2)$$

where the superscript "T" denotes the matrix transpose. The $\sqrt{2}$ on the S_{hv} term is to ensure consistency in the span (total power) computation. Polarimetric information can also be represented by a covariance matrix C in the following form

$$C = k k^T = \begin{bmatrix} |S_{hh}|^2 & \sqrt{2}S_{hh}S_{hv}^* & S_{hh}S_{vv}^* \\ \sqrt{2}S_{hh}S_{hv}^* & 2|S_{hv}|^2 & \sqrt{2}S_{hv}S_{vv}^* \\ S_{vv}S_{hh}^* & \sqrt{2}S_{vv}S_{hv}^* & |S_{vv}|^2 \end{bmatrix} \quad (3)$$

where the superscript "*" denotes the complex conjugate. From (3), the span (or total power) is expressed as

$$SPAN = k^T k = |S_{hh}|^2 + 2|S_{hv}|^2 + |S_{vv}|^2 \quad (4)$$

Alternatively, the Pauli based target vector k_p can be used to form coherency matrix T .

$$k_p = \frac{1}{\sqrt{2}} [S_{hh} + S_{vv} \quad S_{hh} - S_{vv} \quad 2S_{hv}]^T \quad (5)$$

$$T = k_p \cdot k_p^T \quad (6)$$

The coherency matrix representation has the advantage over the covariance matrix of relating to underlying physical scattering mechanisms (Lee *et al.*, 1999-a).

Fully polarimetric data provides unique possibility to separate scattering contributions of different nature, which can be associated to certain elementary scattering mechanisms. Several decomposition techniques have been proposed for this purpose. Freeman decomposition model and Cloude decomposition model are the most intensively used in several researches.

a.1. Feature Extraction based on Freeman Decomposition

The Freeman decomposition (Freeman and Durden, 1998) models is the covariance matrix C as the contribution

of three basic scattering mechanisms: surface or single-bounce, double-bounce, and volume scattering. Volume scattering is modeled by a cloud of randomly oriented dipoles for tree canopy and vegetation. Double-bounce scattering is realistically described by scattering from dihedrals, but allows for reflector surfaces with different dielectric properties, corresponding to, for example trunk-ground interaction in forest scatter. Surface or single-bounce scattering is modeled by a Bragg surface scatterer. Hence, the Freeman decomposition expresses the measured covariance matrix C as follows:

$$C = C_v + C_d + C_s \quad (7)$$

where C_v , C_d , and C_s are covariance matrix corresponding to each scattering component (volume, double, surface) as presented in Table 1. From these matrices, then the contributions of each scattering mechanisms P_v , P_d , P_s to the span (total power) P can be estimated. These scattered powers P_v , P_d , P_s can be employed to generate RGB image and can be used as classification features to allow differentiation between different land cover types (Freeman and Durden, 1998; Lumsdon, 2003).

$$P = P_v + P_d + P_s = (|S_{hh}|^2 + |S_{vv}|^2 + 2|S_{hv}|^2) \quad (8)$$

a.2. Feature Extraction based on Cloude Decomposition

The polarimetric decomposition theorem introduced by Cloude and Pottier (1997) proposed to identify polarimetric scattering mechanisms based on the eigenvalue analysis of a coherency matrix T . Applying eigenvalue analysis, the matrix T is decomposed into a sum of three coherence matrices T_i , each weighted by its corresponding eigenvalue λ_i .

$$T = \sum_{i=1}^3 \lambda_i T_i = \lambda_1 (\mu_1 \mu_1^T) + \lambda_2 (\mu_2 \mu_2^T) + \lambda_3 (\mu_3 \mu_3^T) \quad (9)$$

Each matrix T_i is a unitary scattering matrix representing a deterministic scattering contribution. The amount of the contributions is given by the eigenvalues λ_i , while the type of scattering is related to the eigenvectors μ_i . The eigenvectors can be formulated as

$$\mu_i = [\cos\alpha_i \quad \sin\alpha_i \cos\beta_i e^{i\delta_i} \quad \sin\alpha_i \sin\beta_i e^{i\gamma_i}]^T \quad (10)$$

The α angle corresponds to the continuous change from surface scattering ($\alpha = 0^\circ$), moving into dipole or volume scattering ($\alpha = 45^\circ$), moving into double bounce scattering between two dielectric surfaces, and finally reaching dihedral scatter from metallic surfaces at $\alpha = 90^\circ$. The β angle is twice of the polarization orientation angle. The δ angle is the phase difference between the decomposed $S_{hh} + S_{vv}$ and $S_{hh} - S_{vv}$ terms, and the γ angle is the phase difference between the decomposed $S_{hh} + S_{vv}$ and S_{hv} terms. The ϕ angle is phase of the decomposed $S_{hh} + S_{vv}$ term.

Cloude and Pottier defined three secondary parameters, entropy H , anisotropy A , and mean alpha angle $\bar{\alpha}$, to characterize the result of the decomposition.

$$H = -\sum_{i=1}^3 P_i \log_2 P_i \quad \text{where } P_i = \frac{\lambda_i}{\sum_{j=1}^3 \lambda_j} \quad (11)$$

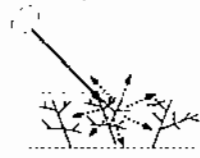

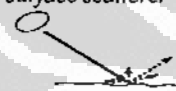
$$A = \frac{\lambda_2 - \lambda_3}{\lambda_2 + \lambda_3} \quad (12)$$


$$\bar{\alpha} = \sum_{i=1}^3 P_i \alpha_i \quad (13)$$

The entropy H , ranging from 0 to 1, represents the randomness of the scattering, with $H = 0$ indicating a single scattering mechanism (isotropic scattering) and $H = 1$ representing a random mixture of scattering mechanisms. For ocean and less rough surfaces, surface scattering will dominate, and H is near 0. For heavily vegetated areas, the H value will be high, due to multiple scattering mechanisms. The anisotropy A represents the relative importance of the second and third scattering mechanisms. A high anisotropy states that only the second scattering mechanism is important, while a low anisotropy indicates that the third scattering mechanism also plays a role. The mean alpha angle $\bar{\alpha}$ reveals the averaged scattering mechanisms from surface scattering ($\bar{\alpha} \rightarrow 0^\circ$), volume scattering ($\bar{\alpha} \rightarrow 45^\circ$), to double bounce scattering ($\bar{\alpha} \rightarrow 90^\circ$). H and $\bar{\alpha}$ clearly characterize the scattering characteristics of a medium.

Cloude and Pottier further suggest an unsupervised classification scheme, using the H - α plane sub-divide into 8 basic zones characteristic of different scattering behaviors, as shown in Fig. 2. However, this unsupervised estimation of the type of scattering mechanisms may reach some limitations due to the arbitrarily fixed linear boundaries in the H - α plane which may not fit to data distribution, leading to noisy classification results (Ferro-Famil *et al.*, 2005; Lee *et al.*, 1999-a). Hence, in this work, we use entropy H , anisotropy A , and mean alpha angle $\bar{\alpha}$ directly as classification feature inputs to the neural network classifier.

Table 1. Three basic scattering mechanisms used in the Freeman decomposition model

| Basic Scattering Mechanism | Model Scatterer | Corresponding Covariance Matrix | Scattered Power |
|-------------------------------------|--|---|------------------------------|
| Volume scattering | <p>Set of randomly oriented dipoles</p>  $S = \begin{bmatrix} S_v \cos^2 \phi + S_h \sin^2 \phi & (S_v - S_h) \cos \phi \sin \phi \\ (S_v - S_h) \cos \phi \sin \phi & S_v \sin^2 \phi + S_h \cos^2 \phi \end{bmatrix}$ <p>Assume a thin cylindrical scatterer ($S_v = 1, S_h = 0$)</p> | $C_v = f_v \begin{bmatrix} 1 & 0 & 1/3 \\ 0 & 2/3 & 0 \\ 1/3 & 0 & 1 \end{bmatrix}$ $f_v = 3 S_{hv} ^2$ | $P_v = \frac{8f_v}{3}$ |
| Double-bounce scattering | <p>Dihedral corner reflector</p>  $S = \begin{bmatrix} e^{i\gamma} R_g R_a & 0 \\ 0 & e^{i\gamma} R_v R_a \end{bmatrix}$ <p>R_g: Ground / Horizontal Surface Reflection Coefficient R_v: Tank / Vertical Surface Reflection Coefficient γ: Attenuation or phase change effect</p> | $C_d = f_d \begin{bmatrix} \alpha ^2 & 0 & \alpha \\ 0 & 0 & 0 \\ \alpha^* & 0 & 1 \end{bmatrix}$ $\alpha = e^{i2(\tau_v - \tau_g)} \frac{R_{gv} R_{va}}{R_{gv} R_{vv}}$ $f_d = R_{gv} R_{vv} ^2$ | $P_d = f_d (1 + \alpha ^2)$ |
| Surface or single-bounce scattering | <p>Bragg surface scatterer</p>  $S = \begin{bmatrix} R_h & 0 \\ 0 & R_v \end{bmatrix}$ <p>R_h: Bragg Surface Reflection Coefficient for Horizontal Polarization R_v: Bragg Surface Reflection Coefficient for Vertical Polarization</p> | $C_s = f_s \begin{bmatrix} \beta ^2 & 0 & \beta \\ 0 & 0 & 0 \\ \beta^* & 0 & 1 \end{bmatrix}$ $\beta = \frac{R_h}{R_v}$ $f_s = R_v ^2$ | $P_s = f_s (1 + \beta ^2)$ |



Physical scattering characteristics :
 Z9 : Low Entropy Surface Scattering
 Z8 : Low Entropy Dipole Scattering
 Z7 : Low Entropy Multiple Scattering
 Z6 : Medium Entropy Surface Scattering
 Z5 : Medium Entropy Vegetation Scattering
 Z4 : Medium Entropy Multiple Scattering
 Z3 : (Not a Feasible Region in H- α space)
 Z2 : High Entropy Vegetation Scattering
 Z1 : High Entropy Multiple Scattering

Fig. 2. H - α plane

Then train the network sufficiently in a supervised method, and let the network to determine the optimal decision boundaries in feature space.

III. Feature Extraction based on Image Texture Analysis

Texture features calculated from grey-level cooccurrence matrices (GLCM) are often used for remote sensing image interpretation (Clausi and Jernigan, 1998; Acqua and Gamba, 2003; Tso and Mather, 2001), and the results have generally been successful. A GLCM contains the conditional-joint probabilities ($P_{i,j}$) of all pairwise combinations of grey levels for a fixed window size (N) given two parameters: interpixel distance (δ) and interpixel orientation (θ). A different GLCM is required for each (δ, θ) pair. Each GLCM is dimensioned to the number of quantized grey-levels (G). Applying statistics to a GLCM generates different texture features. Eleven common features are presented in Table 2. These statistics extract several fundamental characteristics from the cooccurrence matrices. Moments about the main diagonal indicate the degree of smoothness of the texture (i.e., *contrast*, *dissimilarity*, and *inverse difference moment*). Another fundamental characteristic of the cooccurrence matrix is

the uniformity of its entries (i.e., *entropy*, *maximum probability*, and *angular second moment*). If the grey-levels in the window tend to be homogeneous, then only a few grey-level pairs represent the texture. The features measure statistical property of GLCM (i.e., *mean*, *variance*, and *correlation*). And finally, features measure the grouping of pixels that have similar grey-level values (i.e., *cluster shade* and *cluster prominence*).

A shortcoming of determine texture features derived from GLCM is the excessive computational burden. For fully polarimetric images data, we can calculate textural features from four individual intensity images, i.e., HH, HV, VH, and VV images. However, this method may not be practical in terms of computational cost and make more complicated in interpretation due to large number of derived textural features. In this paper, we use only one span image, as calculated using (4). The span (or total power) image is a weighted average of HH, HV, and VV intensities and consequently has a lower speckle noise than HH, HV or VV individually. HH, HV, and VV may have different scattering characteristics. Consequently, many features that may appear differently in each polarization channel will show up in the span image (Lee *et al.*, 1999-b).

Table 2. Some textural features extracted from GLCM

| Textural Feature | Formula |
|---------------------------|--|
| Contrast | $\sum_{i,j=0}^{G-1} P_{i,j} (i-j)^2$ |
| Dissimilarity | $\sum_{i,j=0}^{G-1} P_{i,j} i-j $ |
| Inverse Difference Moment | $\sum_{i,j=0}^{G-1} \frac{P_{i,j}}{1+(i-j)^2}$ |
| Angular Second Moment | $\sum_{i,j=0}^{G-1} P_{i,j}^2$ |

| | |
|---------------------|---|
| Entropy | $-\sum_{i,j=0}^{G-1} P_{i,j} \log P_{i,j}$ |
| Maximum Probability | $\max_{i,j} (P_{i,j})$ |
| Mean | $\mu_i = \sum_{i,j=0}^{G-1} iP_{i,j}$, $\mu_j = \sum_{i,j=0}^{G-1} jP_{i,j}$ |
| Variance | $\sigma_i^2 = \sum_{i,j=0}^{G-1} P_{i,j} (i - \mu_i)^2$, $\sigma_j^2 = \sum_{i,j=0}^{G-1} P_{i,j} (j - \mu_j)^2$ |
| Correlation | $\sum_{i,j=0}^{G-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sigma_i \sigma_j} \right]$ |
| Cluster Shade | $\sum_{i,j=0}^{G-1} ((i - \mu_i) + (j - \mu_j))^2 P_{i,j}$ |
| Cluster Prominence | $\sum_{i,j=0}^{G-1} ((i - \mu_i) + (j - \mu_j))^4 P_{i,j}$ |

IV. Neural Network Classifier and Post-Processing Technique

a. Neural Network Classifier based on Feed-Forward Back-propagation Neural Network

The multilayer feed-forward using the back-propagation learning algorithm is one of the most widely used neural network. In this work, we apply multilayer feed-forward neural network architecture as depicted in Fig. 3., with an input layer, a hidden layer, and an output layer (Canty, 2006). The network contains L neurons in the hidden layer for classification of N -dimensional data into K classes.

The input layer accepts $N+1$ (biased) input feature vector $\mathbf{g}(\nu)$ ($\mathbf{g}(\nu) = (1, g_1(\nu) \dots g_N(\nu))^T$), and broadcast them to all of the L neurons in the hidden layer via weighted connections \mathbf{W}^h . Neurons in the hidden layer sum all incoming signals and then computes its activation to form an $(L+1)$ -component vector of intermediate outputs $\mathbf{n}(\nu)$ ($\mathbf{n}(\nu) = (1, n_1(\nu) \dots n_L(\nu))^T$). The logistic sigmoid function ($f(x) = 1/(1 + e^{-x})$) is the most commonly used activation function. Intermediate outputs $\mathbf{n}(\nu)$ then

transferred to all of the K neurons in the output layer via weighted connections \mathbf{W}^o . Similarly, each neuron in the output layer sum of all incoming signals and then computes its activation to form the output signal $\mathbf{m}(\nu)$ ($\mathbf{m}(\nu) = (m_1(\nu) \dots m_K(\nu))^T$). However, in the output layer we use a modified logistic activation function for the output neurons, called softmax. The softmax function is defined as:

$$m_k(\nu) = \frac{e^{I_k^o(\mathbf{n}(\nu))}}{e^{I_1^o(\mathbf{n}(\nu))} + e^{I_2^o(\mathbf{n}(\nu))} + \dots + e^{I_K^o(\mathbf{n}(\nu))}} \quad (14)$$

where:

$$I_k^o(\mathbf{n}(\nu)) = \mathbf{W}_k^{oT} \mathbf{n}(\nu), \quad k = 1 \dots K \quad (15)$$

This activation function, not only satisfy the condition $0 \leq m_k(\nu) \leq 1$, but also guarantee that the output signals sum to unity ($\sum_{k=1}^K m_k(\nu) = 1$). By using this activation function, the final network output will not only classify input feature vector into a class K (by selecting maximum value of m_k), but also generate class membership probability vectors $\mathbf{m}(\nu)$ for each observation. (These results will be used at post-processing module.)

Neural network must learn how to process inputs before they can be utilized in an application. According to the supervised learning scheme, the process of neural network training involves adjusting the weights on each layer (W^h and W^o) in such a manner that output of the network is consistent with the desired output (target class). The most well-known and extensively used for updating these weights is back-propagation learning algorithm. The back-propagation algorithm trains a neural network iteratively using a gradient descent algorithm in which the mean square error between the network output and the

desired output is minimized. Once the network error has decreased to less than a specified threshold, the network has converged and is considered to be trained. However, the standard back-propagation learning algorithm is notoriously slow to convergence. To overcome this problem, we adopt two learning algorithms, i.e., Kalman filter and scaled conjugate gradient learning algorithm presented in Canty (2006). Learning process, then beginning with the former in order to approach a minimum (error) quickly, and then using the latter to refine the weights. Convergence is extremely fast when compared to standard back-propagation.

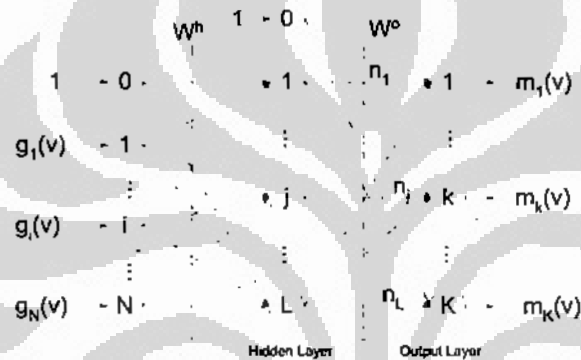


Fig. 3. A feed-forward neural network with L hidden neurons for classification of N -dimensional data into K classes.

b. Augmented-Vector Classification Method

The proposed method, as mentioned before, uses features extracted from two different aspects. In this work, we combine these features using *stacked-vector* or *augmented-vector* method as inputs to the classifier module, by simply extending the dimension of the data vectors to include each source from two aspects (Tso and Mather, 2001). For example, if we have three features extracted from scattering models and eleven features extracted from texture

analysis, then fourteen features can be used together as inputs to the classifier module.

c. Post Processing Technique

Pixel-oriented classifiers sometimes provide classification result that contains misclassification at the pixel level that randomly distributed, and appear as "salt-and-pepper" effect in the classification map result. Richards and Jia proposed a method for correcting a possible misclassification of a pixel by examining the membership probability of the pixel in

its neighborhood (Canty, 2006). They describe a method referred to as *probabilistic label relaxation*, which we have adapted here to improve our classification result and take spatial information into account. The class membership vectors $\mathbf{m}_i = (m_{i_1}, \dots, m_{i_K})^T$ are updated according to

$$\mathbf{m}'_i = \mathbf{m}_i * \frac{\mathbf{P} \mathbf{m}_n}{\mathbf{m}'_i{}^T \mathbf{P} \mathbf{m}_n} \quad (16)$$

where $\mathbf{P} = (P)_{kl}$ is a $K \times K$ matrix of compatibility measures expressing the probability that a pixel in class k has a neighbor in class l , \mathbf{m}_n is the average class membership vector for a 4-neighborhood of pixel i , and $*$ denotes Hadamard (component-by-component) multiplication. \mathbf{P} is easily estimated directly from the originally classified image. The probabilistic label relaxation procedure can be iterated arbitrarily often. However too many iterations may lead to a widening of the effective neighborhood of a pixel to such an extent that irrelevant spatial information may falsify the final classification. Experiences show that the best results are obtained after 3–4 iterations.

V. Experimental Results

The proposed method is tested using single look complex (SLC) fully polarimetric-SAR data acquired over Penajam area, East Kalimantan Province. These data were acquired in L-band by Airborne E-SAR method on September 17th, 2004. The spatial resolution of the data used is 1.99 m and 3.0 m, in range and azimuth respectively. The scene under study contains different type of land covers: forest, fields, bare soils, and water area. Fig. 4 shows a set of ground survey information, and then by analyzing these data, a set of regions of interest (ROI) was

defined. The whole ROI dataset then divide into two datasets, around 8.3% for training and around 91.7% for testing the neural network classifier (described in Table 3). From the testing dataset, we estimate the classification accuracy based on analysis of the confusion matrix.

As stated in Section IV, the feed-forward neural network classifier is consisted of three layers. The input layer has a number equal to a number of features of the used dataset, while output layer has a number equal to a number of classes to be recognized (i.e., four neurons in the classification of forest, fields, bare soils, and water area). However, then we must determine the number of neurons in the hidden layer. For this purpose, we carried experiments with classification using several combined features (3 features of scattering model and 11 textural features), and increase the number of hidden neurons incrementally (with 2, 10, 20, 30, 40, and 50). When a few neurons are used, the classification results are not satisfactory, whereas the larger number of the neurons cause longer neural network training times. We found that 30 neurons are the most appropriate selection in this experiment, larger then 30 neurons just provide slightly better classification performance. Then we used this neural network structure as classifier on the classification module.

For preprocessing, we construct scattering matrix from SLC data for each polarization and then apply speckle filtering using J.S. Lee Polarimetric Filter (Lee *et al.*, 1999-b). In order to investigate the effect of window size selection on classification performance, five windows: 3x3, 5x5, 7x7, 9x9 have been implemented, and without speckle filtering. In this experiment, larger then 9x9 windows is not used, because it causes too much blurring.

To extract GLCM textural features (11 features), first we compute the span images for filtered images using (4). In this experiment, these features are computed on a window size 15x15 pixels and grey-level quantization equal 64. The interpixel distance is set equal to one in all four interpixel orientations, i.e., 0, 45, 90, and 135° to account for possible directionality of the objects. Then classifications are performed for each data

using neural network in order to determine the most appropriate textural feature sets. We observe that the highest accuracy, 84.30% is obtained from dataset without speckle filtering, and the classification result is shown in Fig. 7-b. (Filtering has the potential to reduce textural information from the image). Then we use these textural feature sets as combined features with other features extracted from scattering models.

Table 3. Number of training and testing samples used in the experiments

| Land-cover Class | Training Set | Testing Set |
|------------------|--------------|-------------|
| Water | 761 | 8,361 |
| Forest | 348 | 3,822 |
| Fields | 284 | 3,128 |
| Bare soils | 302 | 3,327 |
| Total Pixels | 1,695 | 18,638 |

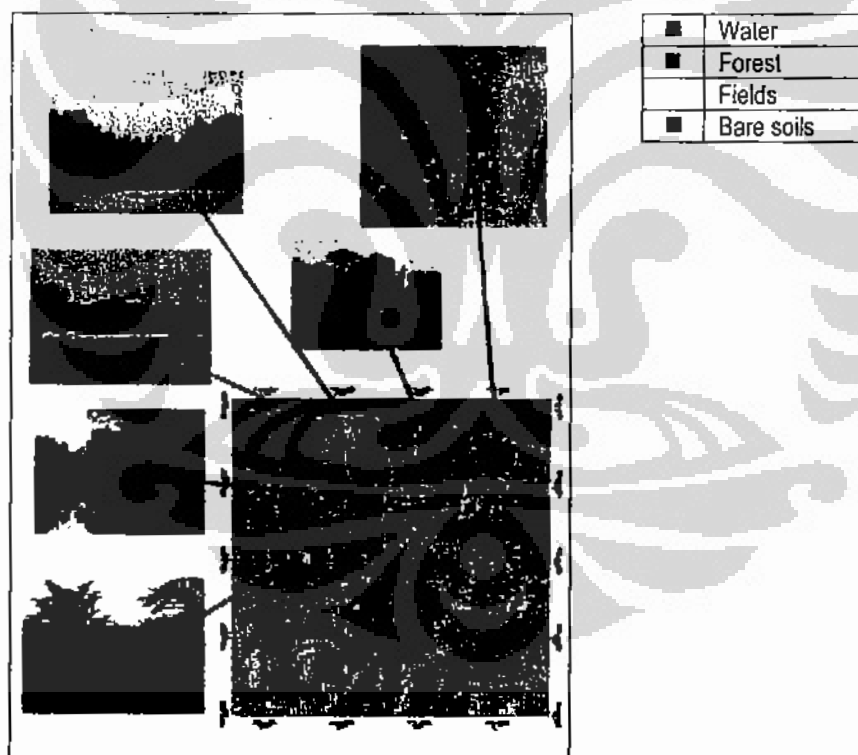


Fig. 4. Ground survey information




Fig. 5. Features extracted from Freeman decomposition model


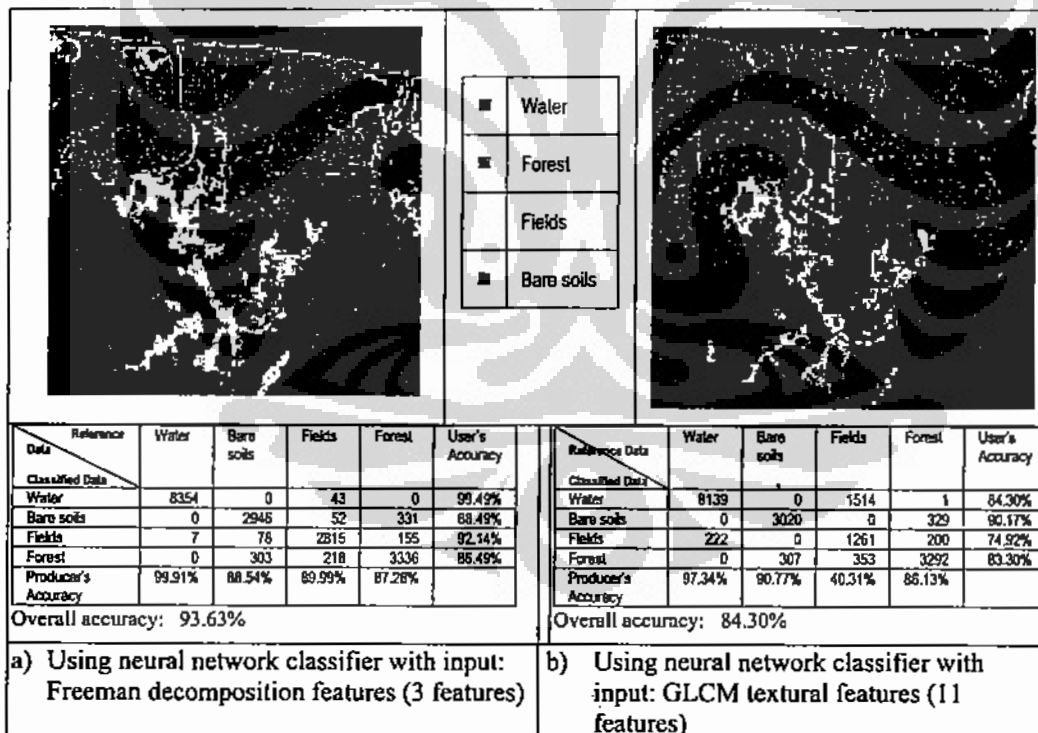


Fig. 6. Features extracted from Cloude decomposition model



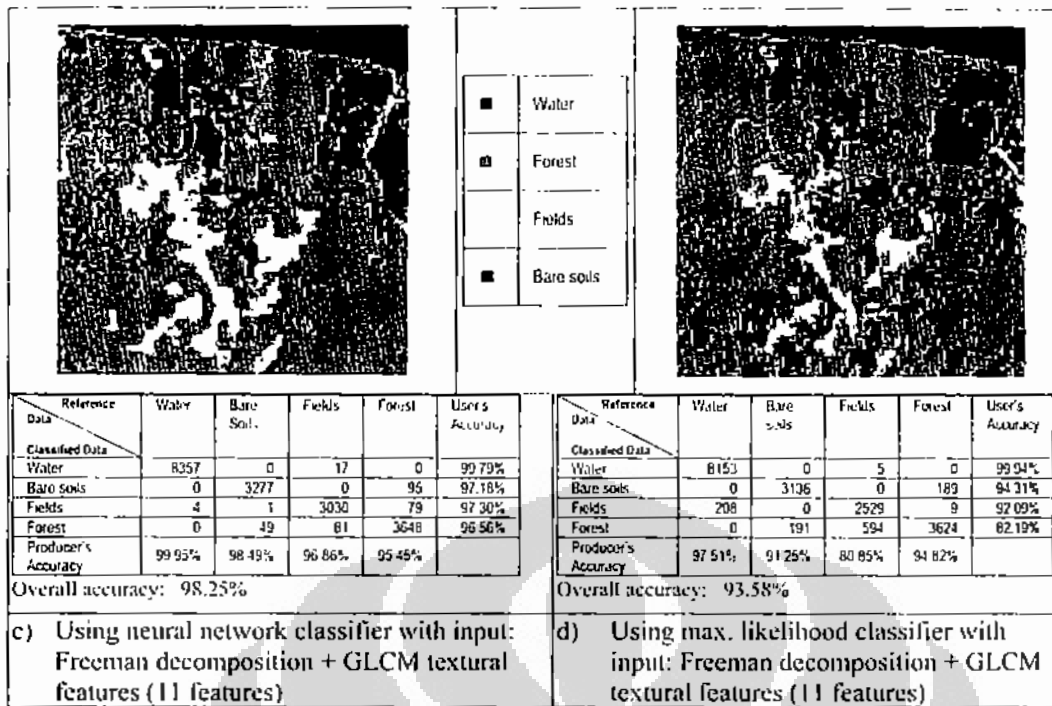


Figure 7. Classification results (thematic map and confusion matrix of testing dataset) using neural network classifier with combined features of Freeman decomposition model and GLCM textural. These results are obtained with speckle filter window size equal to 7x7 pixels. (Classification result using maximum likelihood classifier is also presented as comparison)

To extract features based on scattering models, first we convert the scattering matrix representation into covariance matrix and coherency matrix using (3) and (6), respectively. Then, we apply Freeman decomposition and Cloude decomposition for each speckle-filtered data. Fig. 5 shows the features extraction results from Freeman decomposition. We can observe that this decomposition provide good discrimination of different land cover types. Forested areas is dominated by volume scattering while water areas mainly characterized by surface scattering. Surface scattering is still dominant for bare soils, but a significant amount of double bounce scattering is present. This indicates that a number of the fallen tree trunks and branches lying on the clear-cut areas may cause double-bounce scattering.

However, the similar scattering mechanisms are also observed on field areas, and may cause poor separability between fields and bare soils. We then use these features as input for neural network classifier module. The classification result for 7x7 speckle-filtered data is shown in Fig. 7-a. High accuracy (93.63%) is obtained, but some misclassification between forest, fields, and bare soils occurred. However, when we combine these features with textural features, the classification accuracy is improved more than 4.5%. Results for each speckle-filtered data are shown in Fig. 9 (We plot the overall accuracy as a function of the window size of the speckle filter). It was found that for each case, the classification accuracy was improved by 3% ~ 20%.

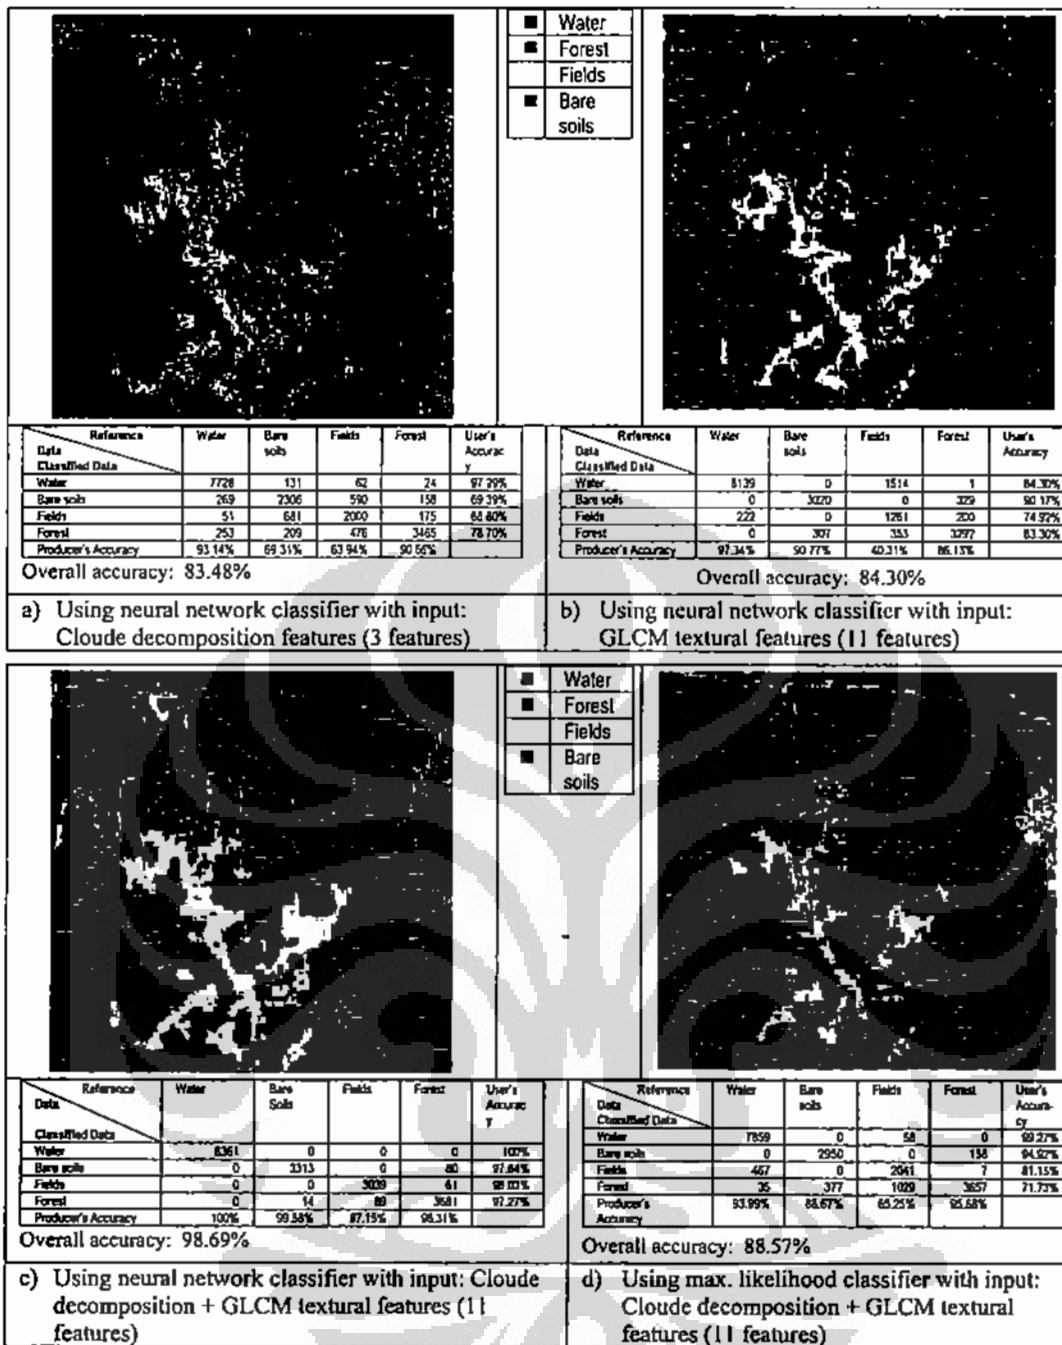


Fig. 8. Classification results (thematic map and confusion matrix of testing dataset) using neural network classifier with combined features of Cloude decomposition model and GLCM textural. These results are obtained with speckle filter window size equal to 7x7 pixels. (Classification result using maximum likelihood classifier is also presented as comparison)




Fig. 9. Classification results for all the experiments. (Overall accuracy as a function of the window size of the speckle filter.)

Fig. 6 shows the features extraction results from Cloude decomposition. By analyzing mean alpha angle α and entropy H , we can observe that open water area is characterized by surface scattering (alpha values less than 42.5°) with low entropy, while forest area is characterized by volume scattering (alpha values near 45°) with high entropy ($H > 0.9$). Bare soils and fields are both characterized relatively by medium entropy and low alpha values, and may cause low separability between these two classes. Anisotropy A does not provide sufficient sensitivity for the separation of the different land-cover types, however, may be used for separation of the bare soil class and field class. We then use these features as input for neural network classifier module. The classification result for 7x7 speckle-filtered data is shown in Fig. 8-a. Overall accuracy 83.48% is obtained, with some misclassification between forest, fields, and bare soils are occurred evidently. It can also be observed that water class at river areas can not be accurately identified. However, when we combine these features with textural features, the classification accuracy is

significantly improved more than 15%. Results for each speckle-filtered data are shown in Fig. 9. It was found that for each case, the classification accuracy was improved by 13% ~ 25%.

In order to point out the improvements that can be obtained with the classification module defined in our method, we compared the results of the neural network classifier with those obtained when classifying the combined features dataset with maximum likelihood classifier. In all trials, we observed that the accuracies exhibited by the neural network are always higher (3%~11%) than by maximum likelihood classifier (shown in Fig. 9). These results can also be confirmed in Fig. 7-d and Fig. 8-d, which some misclassification between forest, fields, and bare soils are occurred evidently, and water class at river areas can not be accurately identified by maximum likelihood classifier.

VI. Conclusion

A method for supervised classification of polarimetric-SAR data has been proposed. The method was designed by integrating the combined features extracted from two

scattering models (i.e., Freeman decomposition model and Cloude decomposition model) and textural analysis (based on GLCM) with distribution-free neural network classifier.

The proposed method has been tested on a fully polarimetric, single look complex E-SAR (L-Band) data acquired on the area of Penajam, East Kalimantan, Indonesia. From an analysis of the results of all the experiments carried out using this method, we can conclude that the scattering model features alone can discriminate different land-cover types with reasonable accuracy while adding textural features can help to further improve the classification performance. In detail investigation, we verified that: 1) the accuracy improvement for combined features of cloude decomposition model and textural analysis is higher than for combined features of Freeman decomposition model and textural analysis; and 2) distribution-free neural network classifiers are very effective classification methodology that allows to exploit the information in the two above combined features (3%~11% better than maximum likelihood classifiers).

In future work, we intend to extend the scope of the method to include another aspect, such as polarimetric discriminators (Woodhouse, 2006) or features extracted from other frequency-SAR, and test the method on more complex area or land-cover types.

Acknowledgement

The authors would like to thank The Ministry of Forestry Republic of Indonesia for providing the E-SAR polarimetric data. The used polarimetric

data set was acquired through INDREX-II experiment (Indonesian Airborne Radar Experiment) supported by the European Space Agency.

References

- Acqua, F.D. and P. Gamba. 2003. Multitemporal and/or polarimetric SAR characterization of urban areas, in *Proceedings of the Workshop on POLINSAR - Applications of SAR Polarimetry and Polarimetric Interferometry*.
- Bruzzone, L., M. Marconcini, U. Wegmuller, and A. Wiesmann. 2004. An Advanced method for the automatic classification of multitemporal SAR images, *IEEE Trans. Geosci. Remote Sensing*, vol. 42, no. 6, pp. 1321-1334, Jun. 2004.
- Canty, M.J. 2006. *Image Analysis, Classification and Change Detection in Remote Sensing*, CRC Press.
- Clausi, D.A. and M.E. Jernigan. 1998. A fast method to determine co-occurrence texture features, *IEEE Trans. Geosci. Remote Sensing*, vol. 36, no. 1, pp. 298-300, Jan. 1998.
- Cloude, S.R. and E. Pottier. 1997. An entropy based classification scheme for land applications of polarimetric SAR, *IEEE Trans. Geosci. Remote Sensing*, vol. 35, no. 1, pp. 68-78, Jan 1997.
- Deng, H. and D. Clausi. 2005. Unsupervised segmentation of SAR sea ice imagery, *IEEE Trans. Geosci. Remote Sensing*, vol. 43, no. 3, pp. 528-538, Mar. 2005.
- Ferro-Famil, L., E. Pottier, H. Skriver, P. Lumsdon, R. Moshammer, and K. Papathanassiou. 2005. Forest mapping and classification using L-Band Polinsar data, in *Proceedings of the Workshop on POLINSAR - Applications of SAR*

Polarimetry and Polarimetric Interferometry.

- Freeman, A. and S.L. Durden. 1998. A three-component scattering model for polarimetric SAR data, *IEEE Trans. Geosci. Remote Sensing*, vol. 36, no. 3, pp. 963-973, May 1998.
- Karathanassi, V. and M. Dabboor. 2004. Land cover classification using E-SAR polarimetric data, in *Proceedings of the XXth ISPRS Congress*.
- Lee, J.S., M.R. Grunes, T.L. Ainsworth, L.J. Du, D.L. Schuler, and S.R. Cloude. 1999. Unsupervised classification using polarimetric decomposition and the complex Wishart classifier, *IEEE Trans. Geosci. Remote Sensing*, vol. 37, no. 5, pp. 2249-2258, Sep. 1999-a.
- Lee, J.S., M.R. Grunes, and G. D. Grandi. 1999. Polarimetric SAR speckle filtering and its impact on terrain classification, *IEEE Trans. Geosci. Remote Sensing*, vol. 37, no. 5, pp. 2363-2373, Sep. 1999-b.
- Lee, J.S., M.R. Grunes, T.L. Ainsworth, I.Hajnsek, T. Mette, and K.P. Papathanassiou. 2005. Forest classification based-on L-band polarimetric and interferometric SAR data, in *Proceedings of the Workshop on POLINSAR - Applications of SAR Polarimetry and Polarimetric Interferometry*.
- Lee, J.S., M.R. Grunes, D.L. Schuler, E. Pottier, and L. Ferro-Famil. 2005. Scattering-model-based speckle filtering of polarimetric SAR data, *IEEE Trans. Geosci. Remote Sensing*, vol. 44, no. 1, pp. 176-187, Jan. 2006.
- Lumsdon, P. 2003. Land cover classification and height estimation in polarimetric SAR interferometry", in *Proceedings of the Workshop on POLINSAR - Applications of SAR Polarimetry and Polarimetric Interferometry*.
- Scheuchl, B., R. Caves, I. Cumming, and G. Staples. 2001. H/A/ α -based classification of sea ice using SAR polarimetry, in *Proceedings of the 23rd Canadian Symposium on Remote Sensing*.
- Tso, B. and P.M. Mather. 2001. *Classification Methods for Remotely Sensed Data*, Taylor & Francis Inc.
- Woodhouse, I. 2006. *Introduction to Microwave Remote Sensing*, CRC Press.
- Yamaguchi, Y., T. Moriyama, M. Ishido, and H. Yamada. 2005. Four-Component scattering model for polarimetric SAR image decomposition", *IEEE Trans. Geosci. Remote Sensing*, vol. 43, no. 8, pp. 1699-1706, Aug. 2005.