

Model *Tree-Structured Markov Random Fields (TS-MRF)* pada Segmentasi Terawasi Data Citra Multispektral

Murinto¹, Agus Harjoko², Sri Hartati³

¹ Program Studi Teknik Informatika Universitas Ahmad Dahlan / Mahasiswa S3 Ilmu Komputer UGM

^{2,3} Program Studi S3 Ilmu Komputer FMIPA UGM Yogyakarta

Email : aryacettakusno1306@gmail.com¹

Abstrak

Segmentasi merupakan suatu proses yang penting untuk proses berikutnya dalam analisis citra. Segmentasi citra mempunyai peranan penting dalam analisis citra dengan tujuan membagi citra ke dalam beberapa bagian citra yang didasarkan pada fitur-fitur citra. Tujuan dari penelitian ini adalah mengimplementasikan model untuk permasalahan segmentasi citra satelit yang seringkali kompleks. Segmentasi menggunakan model *tree-structured Markov random field (TS-MRF)* untuk menangkap struktur alamiah citra. Pemrosesan segmentasi citra menggunakan model terawasi. Dalam segmentasi terawasi baik jumlah kelas ataupun properti statistik lainnya diketahui untuk implementasi model dalam data satelit Alos Avnir-2 Kota Yogyakarta tahun 2009. Teknik yang digunakan dalam penelitian ini menghasilkan suatu keluaran yang baik untuk segmentasi citra penginderaan jauh.

Kata kunci : *Alos Avnir-2, Penutup Lahan, Tree-Structured Markov Random Field (TS-MRF), Segmentasi Terawasi*

Abstract

Segmentation is a very important process to the next process in image analysis. Image segmentation is a key tool in image analysis that aims to divide image into several subregions based-on its features. This research aims to implement model to solve problems of satellite image segmentation that is usually complicated. Segmentation uses a Markov model that divides image into several regions feature spectral homogeneity. The focus of his research is the use of models of Tree - Structured Markov random field (TS - MRF) to capture natural structure of image . The Processing image segmentation using supervised models. In supervised segmentansi both classes and statistical property are known for implementation segmentation model of the satellite data using TS - MRF models used Alos Avnir - 2 image of the city of Yogyakarta in 2009. Techniques used in producing a good output for a remote sensing image segmentation

Key Words : *Alos Avnir-2, Land Cover, Supervised Segmentation, Tree-Structured Markov Random Field (TS-MRF)*

I. PENDAHULUAN

Terdapat beberapa pendekatan yang dianjurkan dalam literatur untuk segmentasi citra dengan menggunakan kerangka pemodelan *MRF*, seringkali didasarkan pada pasangan potensial *clique-clique* dan suatu pemilihan ketetangaan yang sesuai (4-ketetangaan dan 8-ketetangaan). Suatu pendekatan yang penting dikemukakan oleh D'Ellia et al (2003), menggunakan segmentasi binary rekursif untuk menyelesaikan permasalahan K-kelas, diinspirasi oleh Model Ising sebagai lawan dari model Potts [1]. Dalam suatu teknik unsupervised, dimana parameter model dan peta segmentasi (segmentation map) tidak diketahui (*unknown*) dan memerlukan pengestimasi secara simultan. Solusinya adalah

penggantian antara langkah estimasi parameter dan inference sampai tercapai konvergensi. Ketika permasalahan lain muncul yakni jumlah kelas-kelas tidak diketahui, maka dibutuhkan suatu estimasi yang baik. D'Ellia et al (2003) mengusulkan suatu penyelesaian melalui pendefinisian *split gain*, rasio dari ketidaknormalan posterior yang didapatkan melalui dua hipotesis, struktur pohon sebelum dan sesudah pemisahan dari suatu node. Suatu uji seperti ini memungkinkan untuk memutuskan representasi mana yang lebih cocok bagi data dan *split* potensial di sini dapat diterima atau ditolak. Meskipun ini ide yang baik dalam kerangka tak terawasi (*unsupervised*), akan tetapi perlu dicatat bahwa kelas didasarkan hirarki secara fisik, selanjutnya ada kemungkinan tidak sesuai untuk

himpunan data tertentu. Sedangkan dalam teknik terawasi (*supervised*) baik jumlah kelas dan karakteristik statistiknya diketahui.

II. METODE PENELITIAN

Suatu *random field* X didefinisikan pada *lattice* S dikatakan sebagai *Markov random field (MRF)* yang sesuai dengan sistem ketetanggaan N yang diberikan jika mempunyai sifat *Markovian* untuk tiap site sebagai berikut [2]:

$$p(x_s | x - x_s) = p(x_s | x_{N(s)}) \tag{2.1}$$

Dimana $N(s)$ merupakan tetangga dari s. Distribusi dari *MRF* positif dapat dibuktikan mempunyai bentuk Gibss sebagai berikut (Li, 2001) :

$$p(x) = \frac{1}{Z} \exp(-U(x)) \tag{2.2}$$

$$p(x) = \frac{1}{Z} \exp\left(-\sum_{c \in C} V_c(x_c)\right) \tag{2.3}$$

Dimana $V_c(.)$ dinamakan dengan fungsi potensial, $U(x)$ menotasikan energi, Z adalah konstanta normalisasi dan c merupakan suatu *clique* dari citra yang merupakan himpunan ketetanggaan site-site. Tiap potensial V_c hanya tergantung pada nilai yang berasal dari site-site *clique* $x_c = \{x_s, s \in c\}$, dan hanya tergantung pada interaksi lokal saja. Sebagai konsekuensinya ketergantungan lokal dalam X dapat dengan mudah dimodelkan melalui pendefinisian potensial-potensial $V_c(.)$ yang sesuai.

2.1 Model Ising

Representasi secara khusus dari pemodelan MRF adalah *Generalized Potts Model (GPM)* yang berasal dari teorema Hammersley-Clifford. Potensial dicirikan melalui parameter sederhana. Model potensial yang terkenal adalah Model Ising. Pertama kali model ini digunakan untuk kasus MRF biner. Sedangkan perluasan dari model ini adalah model Potts. Model Ising dapat didefinisikan pada sistem ketetanggaan N^1 dan N^2 , akan tetapi biasanya lebih sering didefinisikan pada N^2 . Pada tiap *clique* potensial didefinisikan sebagai berikut [3]:

$$V_c(x_c) = \begin{cases} \beta, & \text{jika } x_p \neq x_q, \quad p, q \in c \\ 0, & \text{untuk yang lain} \end{cases} \tag{2.4}$$

Dimana $\beta > 0$ merupakan parameter '*edge-penalty*'. Sedangkan distribusi global $p(x)$ secara lengkap didefinisikan, karakteristik lokal $p(x_s | x_{N(s)})$ dituliskan sebagai :

$$p(x_s = k | x_{N(s)}) \propto \exp[\beta N_k] \alpha \exp[-\beta N_{\bar{k}}] \tag{2.5}$$

dimana $N_k(N_{\bar{k}})$ adalah jumlah tetangga dari s dengan label k (berbeda dari bentuk k). Generalisasi dari model ini dinamakan dengan *Generalized Potts Model* yang menghilangkan konstrein dari ekuivalensi diantara *clique-clique* tak homogen citra dan substitusi parameter β

dengan himpunan dari $\frac{1}{2}K(K-1)$ parameter-

parameter β_{hk} , satu untuk tiap label dari pasangan berbeda dengan *clique* dari map $(h, k \in \Lambda)$ dan $h \neq k$, dengan $\beta_{hk} = \beta_{kh}$. Bentuk persamaannya adalah :

$$V_c(x_c) = V_c(x_p, x_q) = \begin{cases} \beta_{hk} > 0, & \text{jika } x_p = h \neq k = x_q, p, q \in c \\ 0, & \text{yang lain} \end{cases} \tag{2.6}$$

sedangkan karakteristik lokalnya dapat dituliskan sebagai :

$$p(x_s = k | x_{N_s}) = \frac{1}{Z} \exp\left[-\sum_{h \neq k} \beta_{hk} N_h\right] \tag{2.7}$$

dimana Z adalah konstanta normalisasi.

2.2 Metode Optimisasi

Permasalahan segmentasi dapat dituliskan sebagai maksimasi dari hasil $p(x)p(y | x)$ atas x. Nilai x bersesuaian dengan memaksimalkan posteriori probabilitas (\hat{x}), sebagai peta segmentasi. Posterior distribusi dapat dituliskan dalam bentuk Gibss-MRF. Untuk melakukan maksimisasi, diperlukan juga term likelihood $p(y^t | x^t, x^{\omega(t)})$ untuk tiap node t, di mana Y^t merupakan himpunan pasangan data dengan X^t [4]. Disini diasumsikan data tak bergantung bersyarat, sehingga hanya membutuhkan pendefinisian term $p(y_s^t | x_s^t, x_s^{\omega(t)})$, dimana x_s^t sama antara yang kiri l(t) dan kanan r(t) anak

(child) dari t. Ketika suatu anak (child) merupakan node terminal, likelihood yang bersesuaian dikenal sebagai priori dan diasumsikan sebagai Gaussian dengan parameter yang diketahui. Dalam situasi ini, didefinisikan term *likelihood* sebagai Gaussian terbaik di antara semua daun-daun secara menurun, yang dapat dituliskan sebagai :

$$p(y_s^t | x_s^t, x_s^{\omega(t)}) = \max_{k \in \gamma(x_s^t)} p(y_s | x_s = k) \quad (2.8)$$

Dimana $\gamma(t)$ merupakan himpunan daun-daun secara menurun dari t, sedangkan $x_s^t \in \{l(t), r(t)\}$. Dengan kata lain, untuk memutuskan jika site saat itu akan berada di node kiri atau kanan, ditentukan terlebih dulu distribusi Gaussian terbaik dari dua distribusi yang ada bersesuaian dengan kelas-kelasnya, menurun kanan $\gamma(r(t))$ atau menurun kiri $\gamma(l(t))$. Dengan cara ini, struktur pohon hanya melibatkan bagian prior MRF di mana tidak ada konstrain struktur yang ditransfer pada term *likelihood* $p(y|x)$.

Tiap node t dalam pohon, diberikan oleh X^t dan $X^{\omega(t)}$ masing-masing menyatakan *field* yang berada pada bagian pohon (*subtree*) sebelah kiri berasal dari t dan *field* yang berada pada bagian pohon sebelah kanan, dimana masing-masing adalah tak tergantung (*independent*). Dapat dituliskan sebagai persamaan berikut:

$$p(x^t) \prod_{t \in T} p(x^t | x^{\omega(t)}) \quad (2.9)$$

Juga untuk tiap node internal t, diberikan *ancestor field* $X^{\omega(t)}$, *field* dibangun pada bagian pohon di *root* t, field binary terminal X^t (diasosiasikan dengan *terminal split*) merupakan Model MRF Ising, yang dituliskan dalam bentuk persamaan :

$$p(x^t | x^{\omega(t)}) = \frac{1}{(Z(x^{\omega(t)}))} \exp(-\beta^t N^t) \quad (2.10)$$

Dengan catatan bahwa tidak semua *term* pada persamaan (2.10) berdistribusi Ising. Namun, untuk menemukan suatu estimasi MAP dari segmentasi probabilitas prior *TS-MRF*, dapat secara rekursif memaksimalkan term dalam persamaan (2.9), bersamaan dengan bagian *likelihood*, dimulai dari *root* dan menurun sampai semua daun tercapai. Tiap *term* hanya tergantung

pada suatu *field binary* X^t *ancestor field* $x^{\omega(t)}$ yang diberikan, dan ini berbentuk Ising, serta dapat dimaksimalkan dengan menggunakan *Iterated Conditional Mode (ICM)*, *Simulated Annealing (SA)* dan lain sebagainya.

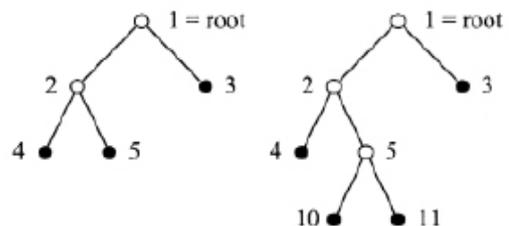
2.3 Estimasi Parameter

Segmentasi dicirikan melalui sejumlah parameter penting seperti jumlah kelas/label K pada suatu citra, parameter kelas μ_k dan Σ_k berelasi dengan *term likelihood* $p(y|x)$ dan parameter β_{hk} dari prior Gibbs $p(x)$. Dalam kasus paling sederhana di mana semua parameter ini ada nilainya (*known*), seperti pada kasus supervised, maka ICM digunakan untuk menemukan peta segmentasi. Pada kasus unsupervised, diestimasi dari data secara bersamaan melalui segmentasi \hat{x} itu sendiri. Dua prosedur di sini digunakan yakni : Parameter-parameter model diestimasi dari observed data, melalui pendekatan ML dan MAP segmentasi menggunakan nilai-nilai parameter yang diestimasi. Sejumlah teknik dapat digunakan untuk melakukan estimasi parameter ML antara lain algoritma Expectation-Maximum atau ICE.

2.4 Model Segmentasi Terawasi Didasarkan Pada Tree-Structured Markov Random Field (TS-MRF)

Model TS-MRF mendeskripsikan suatu *K-array label field* melalui mean barisan MRF biner, di mana masing-masing bersesuaian dengan suatu node t dalam pohon T. Suatu pohon biner T, diidentifikasi melalui node-node dan hubungan mutual diantara mereka. Kecuali untuk *root*, tiap node t mempunyai satu *parent* $u(t)$, dan tiap internal node mempunyai 2 *children* $l(t)$ dan $r(t)$.

Himpunan node-node terminal atau daun tidak mempunyai children (●) dan internal node (*the rest of node*) (o). Contoh sederhana model TS-MRF diperlihatkan dalam Gambar 1.



Gambar 1 Struktur Pohon Biner (a). Setelah 2 Pemisahan (*Split*) (b). Hasil dari Suatu Penambahan *Split*

Algoritma secara garis besarnya didasarkan pada pengestimasiian secara iteratif parameter *edge penalty* β dari klasifikasi sebelumnya ω^k dan membangun realisasi baru dari ω^{k+1} didasarkan pada parameter yang diestimasi. Proses iteratif ini secara sekuensial ditampilkan pada tiap kelompok piksel-piksel yang dihubungkan dengan suatu node internal dari pohon (yakni suatu node yang mempunyai node-node *child*) secara hirarki pergeserannya, seperti digambarkan dalam gambar 1. Suatu cara untuk estimasi parameter *penalty* adalah dari klasifikasi sebelumnya ω^k menggunakan maximum *pseudo-likelihood estimation* (MPLE).

Dan secara umum algoritma optimisasi rekursif TS-MRF dituliskan sebagai [5]:

Algoritma 1: Optimisasi rekursif atas TS-MRF

Node $t = 1$, inialisasi S^t , himpunan dari lokalisasi diklasifikasi sebagai kelas yang berkorespondensi ke node t, sebagai S yang merupakan citra asli.

1) Estimasi:

$\forall s \in S^t$, hitung $p(y_s | x_s^t = l(t))$ dan $p(y_s | x_s^t = r(t))$, dengan $l(t)$ dan $r(t)$ adalah child kiri dan kanan dari t, menggunakan *Maximum Likelihood Estimation* (MLE).

2) Optimisasi :

Mencari estimasi x^t dan β^t melalui persamaan :

$$(x^t, \beta^t) = \arg \max_{(x^t, \beta^t)} p(x^t | \beta^t) p(y | x^t) \quad (2.11)$$

secara iteratif melalui β^t yang pasti saat menghitung x^t dan sebaliknya sampai konvergen, dimulai dari $\beta^t = 0$.

3) Segmentasi :

$S^{l(t)}$ merupakan himpunan dari lokasi yang diklasifikasi sebagai $l(t)$, $S^{r(t)}$ merupakan himpunan dari lokasi yang diklasifikasi sebagai $r(t)$, jika $t < K - 1$, maka $t = t + 1$ dan berikutnya ke langkah 2, jika tidak maka keluar.

Pada saat melakukan segmentasi terawasi (*supervised segmentation*) maka beberapa asumsi dikenali sebagai priori : Jumlah kelas K, himpunan parameter mean dan kovariansi $\{\mu_k, \Sigma_k\}$ dimana $k=1,2,\dots,K$, yang mendefinisikan komponen Gaussian likelihood, serta suatu K-1 daun struktur pohon biner (binary tree-structure T) yang

mempunyai K-1 internal node yang diindeks melalui $\bar{T} = \{1,2,\dots,K-1\}$ sedemikian hingga $t > n$ jika $n \in \omega(t)$. Segmentasi citra $x = \{x^t\}_{t \in \bar{T}}$ dari data y, kemudian dengan estimasi dari himpunan parameter prior $\beta = \{\beta^t\}_{t \in \bar{T}}$ kemudian ditampilkan melalui algoritma seperti dalam algoritma 1.

2.5 Akurasi Assesment Method (Akurasi Metode Penilaian)

Melalui penggunaan *ground truth/ROI*, akurasi penggunaan metode pengklasifikasian TS-MRF lama dan baru berdasarkan pada Matrik Konfusi (*confusion matrix*). Masukan baris ke i dan kolom ke j matriks ini merupakan jumlah piksel-piksel sampel dari ke ke j yang diklasifikasikan termasuk pada kelas ke i.

Berbagai indikator diturunkan dari matriks. Pertama, Penilaian dua error dapat dihitung untuk tiap kelas; keakuratan user kelas i didefinisikan sebagai a_{ii} / a_{i+} , di mana a_{i+} merupakan baris marjinal ke i (sum of row entries); sebaliknya prosedur akurasi kelas ini didefinisikan sebagai a_{ii} / a_{+i} , di mana a_{+i} merupakan kolom marjinal ke i.

Di samping, dua parameter berdasarkan kelas, tiga indikator kualitas global juga dihitung. Akurasi keseluruhan metode didefinisikan sebagai :

$$\tau = \sum_i a_{ii} / N \quad (2.12)$$

merupakan prosentase pixel sampel yang diklasifikasikan dengan baik. Indikator umum lainnya dinamakan dengan parameter Kappa, didefinisikan sebagai :

$$K = \frac{(N \sum_i a_{ii} - \sum_i a_{i+} a_{+i})}{(N^2 - \sum_i a_{i+} a_{+i})} \quad (2.13)$$

III. HASIL DAN PEMBAHASAN

Algoritma TS-MRF segmentasi terawasi diaplikasikan untuk citra satellite Alos Avnir-2. Citra satelit berukuran 4157 x 3132 pixel 4 band (R,G,B,N) dengan panjang gelombang yang berbeda-beda dalam spektrum tampak. Tujuan akhir dari penelitian ini adalah menentukan penutup lahan dari area ini. Gambar 2 menunjukkan citra kota Yogyakarta pada bulan Juni tahun 2009. Dalam penelitian ini kemudian dibuat daftar dengan menentukan lima kelas

klasifikasi yang meliputi : tubuh air, vegetasi, tanah, aspal dan penutup atap. Kemudian dilakukan pelatihan yang menghasilkan suatu himpunan pelatihan (*learning set*) yang digunakan untuk mengestimasi mean spektral respon dan matrik kovariansi masing-masing kategori, dimana selanjutnya akan digunakan untuk uji sampel untuk mendapatkan akurasi dari teknik klasifikasi yang digunakan.

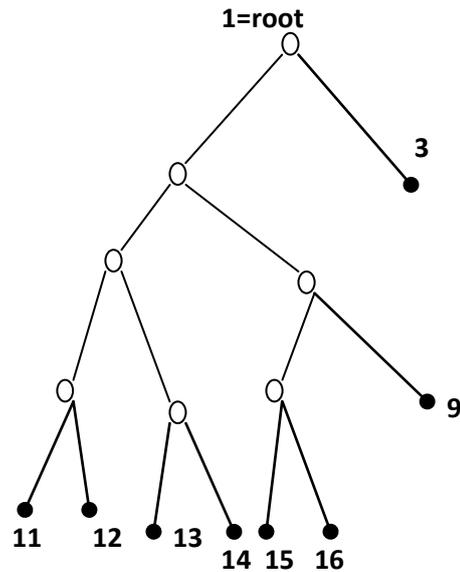


Gambar 2 Citra Satelit Alos Avnir-2 Kota Yogyakarta

Model TS-MRF biner yang digunakan di sini dibangun dengan model Potts sederhana lokal field pada tiap node dari pohon (tree), di mana split tunggal ditampilkan melalui pengkombinasian suatu prosedur ICM dengan MLE untuk estimasi dari parameter prior [6]. Segmentasi citra yang digunakan disini adalah segmentasi terawasi (*supervised segmentation*), di mana jumlah kelas dan properti statistiknya di ketahui terlebih dahulu. Dalam penelitian ini kelas-kelas dari penutup lahan sebanyak 8 kelas yaitu : Tubuh Air (TA), Vegetasi Daun Kayu (VG1), Vegetasi Daun Tak Berkayu (VG2), Atap Seng (A1), Atap Genteng (A2), Tanah Kering (TK), Tanah Basah (TB) dan Aspal (AS). Adapun properti statistik yaitu mean dan variansi diperlihatkan dalam Tabel 1.

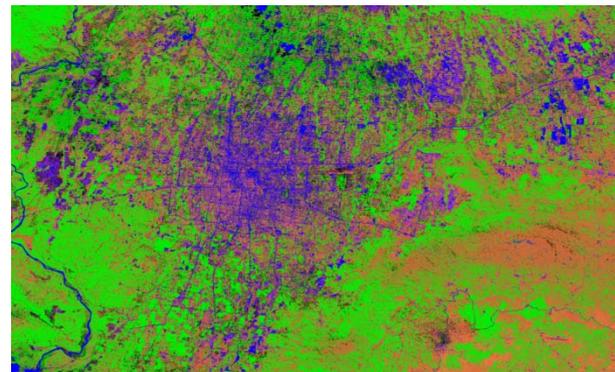
Struktur pohon dari model TS-MRF Segmentasi Terawasi adalah seperti yang terlihat dalam Gambar 2. Selanjutnya, suatu segmentasi gabungan dari dua citra ditampilkan pada keseluruhan himpunan data. Akurasi keseluruhan τ yang merepresentasikan prosentase dari sampel-sampel pixel yang secara benar

diklasifikasi adalah 83,97 % sedangkan parameter Kappa 80 %.



Gambar 3 Struktur Pohon dan Kelas TA(3),VG1(11), VG2(12), AS(9),A1(13), A2(14), TK(15),TB(16).

Sedangkan hasil segmentasi menggunakan model terawasi TS-MRF diperlihatkan dalam Gambar 4.



- Tubuh Air
- Vegetasi Daun Berkayu
- Vegetasi Daun Tak Berkayu
- Tanah Terbuka Kering
- Tanah Terbuka Basah
- Aspal
- Atap Genteng Orange
- Atap Seng dan Asbes

Gambar 4 Peta Segmentasi Terawasi Menggunakan TS-MRF

TABEL 1
MEAN DAN STANDAR DEVIASI
UNTUK TIAP BAND

	TA	VG1	VG2	A1	A2	TK	TB	AS
μ	90.8	79.2	83.0	96.4	86.48	136.8	89.2	90.6
	69.1	55.2	61.0	80.6	69.88	124.4	68.8	69.9
	57.8	36.2	71.1	76.9	78.50	121.7	56.9	59.1
	53.7	65.5	76.6	57.0	77.97	56.6	44.1	58.6
σ	5.0	2.03	2.5	5.33	3.15	18.9	3.7	15.3
	7.0	3.08	2.9	8.60	3.98	20.3	4.7	18.3
	9.1	2.98	3.9	1.99	6.01	20.9	6.7	21.0
	11.9	9.85	8.5	6.02	10.64	7.4	6.4	12.5

IV. KESIMPULAN

Dalam penelitian ini telah diimplementasikan segmentasi citra terawasi dengan menggunakan model TS-MRF untuk klasifikasi penutup lahan. Suatu prosedur yang sederhana diterapkan untuk membangun struktur pohon sedemikian hingga mengikuti struktur citra secara statistik. Prosedur didasarkan pada ukuran probabilitik. Nilai akurasi keseluruhan yang didapatkan adalah 83,97% sedangkan parameter Kappa sebesar 80%. Teknik yang dipakai menghasilkan keluaran yang bagus, untuk segmentasi suatu citra penginderaan jauh.

DAFTAR PUSTAKA

- [1] D'Ellia, C., Poggi, G., Scarpa, G., "A Tree Structured Markov Random Field Model for Bayesian Image Segmentation", *IEEE Trans. on Image Proce.*, Vol.12, no.10, pp.1259 – 1273, Oct.2003.
- [2] Li, S.Z., "Markov Random Field Modelling, in Image Analysis", Springer-Verlag, 2001.
- [3] Gaetano, R., Scarpa, G., Poggi, G., Zerubia, J., 2008, "Unsupervised Hierarchical Image Segmentation Based on The TS-MRF Model and Fast Mean Shift Clustering", *Proc. European Signal Processing Conference, EUSIPCO 2008*.
- [4] Scarpa, G., Poggi, G., Zerubia, J, *A Binary Tree-Structured MRF Model for Multispectral Satellite Image Segmentation*, Proje Ariana, Universita di Napoli 'Federico II', 2003.
- [5] Thoonen, G, *Contextual classification of hyperspectral remote sensing images: Application in vegetation monitoring*, Thesis Ph.D, Univesiteit Antwerpen, 2012
- [6] Besag, J., 1986, "On the Statistical Analysis of Dirty Pictures", *Journal of the Royal Stat.Soc.*, Series B, Vol. 48, pp. 259-302.