

PENGGUNAAN METODE MACHINE LEARNING UNTUK PENGENALAN POLA TUTUPAN LAHAN PADA CITRA SATELIT

by Febriana Santi Wahyuni

Submission date: 16-Dec-2019 10:41AM (UTC+0700)

Submission ID: 1235133693

File name: Febriana_SW_ProSIDing_AMIKOM.pdf (934.23K)

Word count: 3047

Character count: 18680

PENGUNAAN METODE MACHINE LEARNING UNTUK PENGENALAN POLA TUTUPAN LAHAN PADA CITRA SATELIT

Nursida Arif¹⁾, Febriana Santi Wahyuni²⁾

¹⁾ Geografi, Fakultas Sains dan Teknologi, Universitas Muhammadiyah Gorontalo

²⁾ T. Informatika, Institut Teknologi Nasional Malang

Email : nursida.arif@gmail.com¹⁾, vbryana@yahoo.com²⁾

Abstrak

Citra penginderaan jauh adalah sumber utama dalam deteksi liputan lahan yang dapat mencakup wilayah yang sangat luas. Pada daerah yang mempunyai tutupan lahan yang heterogen, penggunaan citra penginderaan jauh dapat digunakan untuk mengetahui jenis penggunaan lahan dalam waktu yang relatif lebih singkat dibandingkan dengan pemantauan secara terestrial. Citra yang digunakan dalam penelitian ini yaitu citra SPOT 5.

Permasalahan yang sering timbul dalam pengolahan citra penginderaan jauh adalah dimensi data yang besar sehingga sangat sulit diselesaikan dengan metode tradisional. Pendekatan machine learning menjadi pilihan alternatif metode yang dapat menangani permasalahan tersebut. Support vector machine dan artificial neural network merupakan bagian dari machine learning yang dipilih untuk digunakan dalam kasus ini karena memiliki kemampuan memahami data non linear dengan dimensi data yang lebih besar. Berdasarkan hasil klasifikasi tutupan lahan citra Pada kasus ini klasifikasi dengan SVM lebih dapat diunggulkan dengan akurasi (88,02%) dibandingkan ANN (81,78%).

Kata kunci: machine learning, support vector machine, artificial neural network

1. Pendahuluan

1.1. Latar Belakang

Perkembangan data penginderaan jauh (PJ) dari foto udara ke citra digital tidak dapat dipisahkan dari sejarah perkembangan komputer. Pengolahan data PJ yang membutuhkan interpretasi visual dengan teknik manual telah bergeser ke teknik analisis digital, sehingga pemanfaatannya semakin berkembang dengan beragam teknik untuk meningkatkan hasil akurasi. Keuntungan analisis citra komputer adalah mengurangi faktor subjektivitas penilaian manusia.

Salah satu permasalahan dalam pengenalan pola spektral data penginderaan jauh adalah resolusi citra, dimana makin tinggi resolusinya maka volume data makin besar dan algoritma untuk analisis lebih kompleks. Sehingga mulai dikembangkan beberapa algoritma untuk dapat menyimpan data dalam jumlah

yang besar, menganalisis serta memvalidasinya. Pendekatan berbasis pengetahuan kemudian mulai bergeser ke pendekatan berbasis data yang merupakan persimpangan dari ilmu statistik dan ilmu komputer yaitu machine learning.

Peningkatan penggunaan machine learning dalam penginderaan jauh karena karakteristik data citra dengan dimensi pixel yang tinggi, berbagai noise dan ketidakpastian dalam data serta sifat non-linear dan redundansi spasial^[1].

Dalam tulisan ini dilakukan klasifikasi untuk mengenali pola tutupan lahan dengan menggunakan metode Support vector machine (SVM) dan artificial neural network (ANN). Sebagai acuan akurasi, digunakan metode klasifikasi tradisional yang banyak digunakan yaitu metode parametrik maximum likelihood. Terdapat beberapa alasan yang mendasari hal tersebut yaitu karakter pembelajaran dan sebagai pengembangan ANN, serta kemampuannya untuk memecahkan masalah berbeda dalam bidang berbeda^[2]. SVM merupakan pembelajaran paling mutakhir setelah ANN dimana memiliki kemampuan dapat memahami data dengan dimensi yang lebih besar. Oleh karena itu kedua metode ini digunakan dalam klasifikasi tutupan lahan.

1.2. Rumusan Masalah

- Bagaimana mengenali pola tutupan lahan pada citra digital menggunakan metode machine learning
- Metode ANN memiliki potensi menghasilkan akurasi yang lebih tinggi dari pada non parametrik namun kurang lengkapnya bukti teoritis pendukung untuk mendapatkan hasil yang efektif sehingga membuat ANN sulit diaplikasikan

1.3. Tujuan

Membandingkan akurasi hasil klasifikasi metode SVM dan ANN dalam mengenali pola tutupan lahan.

1.4. Tinjauan Pustaka

- Karakteristik citra SPOT 5

SPOT 5 (Satellite Pour l'Observation de la Terre) adalah citra penginderaan jauh²⁾ yang merupakan satelit observasi, diluncurkan pada 4 Mei 2002 dengan tujuan untuk memastikan kelanjutan pelayanan terhadap kebutuhan informasi pencitraan untuk meningkatkan

kualitas data dan citra melalui tindakan antisipatif terhadap kebutuhan pasar.

Tabel 1. Panjang Gelombang dan Resolusi Spektral SPOT

Band	Panjang Gelombang	Resolusi Spektral
B1 (Hijau)	0,50 – 0,59 μm	10m x 10m
B2 (Merah)	0,62 – 0,68 μm	10m x 10m
B3 (NIR)	0,79 – 0,89 μm	10m x 10m
B4 (SWIR)	1,58 – 1,75 μm	20m x 20m

b. Koreksi Citra

Koreksi yang dilakukan yaitu koreksi geometrik dan radiometrik. Pertama, koreksi geometrik yang digunakan adalah *image to map* dimana koordinat acuan atau disebut pula *Ground Control Point* (GCP) bersumber dari peta Rupa Bumi Indonesia. Jumlah GCP yang digunakan bergantung pada topografi daerah kajian. Ordo yang sesuai untuk daerah kajian yang berupa perbukitan adalah orde 3, dimana membutuhkan minimal 10 GCP.

Algoritma yang digunakan dalam proses interpolasi adalah *nearest neighbour* dimana nilai piksel baru diambil kembali nilai piksel yang terdekat. Perhitungan akurasi dari proses koreksi geometrik dilakukan dengan menghitung nilai *root means square error* (RMSE). RMS dihitung berdasarkan selisih koordinat GCP dan koordinat baru hasil estimasi di sepanjang sumbu x dan y, dengan rumus sebagai berikut

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n \delta_{Ei}^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n (E - E_i)^2}$$

dan

$$\text{RMSN} = \sqrt{\frac{1}{n} \sum_{i=1}^n \delta_{Ni}^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n (N - N_i)^2}$$

Keterangan:

n : jumlah total titik kontrol lapangan (GCP)

Ei dan Ni: berturut turut, koordinat X (timur, E) dan Y (utara, N) dari GCP ke i, yang dihitung dengan fungsi Transformasi f1 dan f2 dalam rektifikasi.

E dan N : berturut turut, koordinat X (timur, E) dan Y (utara, N) dari acuan.

Berdasarkan RMSE dan RMSN dapat dihitung indikator akurasi keseluruhan dengan rumus:

$$\text{RMSEN} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\delta_{Ni}^2 + \delta_{Ei}^2)}$$

Kedua, koreksi radiometrik selain digunakan untuk memperbaiki kualitas citra, juga digunakan untuk mengubah nilai piksel menjadi nilai energi pantulan. Nilai piksel yang terekam pada citra (*Brightness Value*) belum menggambarkan kekuatan energi pantulan yang diterima oleh sensor.

Metode yang digunakan adalah dengan kalibrasi sensor. Besar radiansi spektral L_λ atau suatu nilai piksel BV pada saluran λ pada citra SPOT dirumuskan menjadi

$$L_\lambda = \frac{BV_\lambda}{\text{Gain}_\lambda}$$

Nilai L_λ pada dasarnya merupakan kombinasi nilai energi pantulan objek dan gangguan atmosfer yang diterima oleh sensor [3]. Untuk itu, perlu dilakukan kalibrasi ulang untuk mendapatkan nilai pantulan di sensor dengan menekan pengaruh atmosfer. Berdasarkan Danoedoro [3], kalibrasi tersebut dapat menggunakan rumus berikut :

$$\rho = \frac{\pi * L_\lambda(\text{maks}) * d}{E_s \cos \theta_s}$$

Keterangan:

L_λ = radiansi spektral yang tercatat di sensor (watt s⁻² sr⁻¹ μm^{-1})

E_s = irradiansi matahari di luar atmosfer

d = jarak relatif matahari dari bumi (*astronomical unit*) pada hari perekaman, dihitung dengan : d = 1 - 0,01674 cos (0,9856 (JD-4)), dengan JD merupakan *julian day* atau jumlah hari dalam setahun

θ_s = sudut zenith matahari

Nilai pantulan yang diterima sensor tersebut dapat diubah menjadi nilai pantulan objek dengan melakukan koreksi nilai L masukan dengan nilai minimal obyek air jernih.

c. Interpretasi dan Pengolahan Citra Digital

Citra digital adalah gambar hasil tangkapan cahaya oleh alat-alat seperti kamera dan pemindai (*scanner*). Citra merepresentasikan objek yang direkam sehingga mudah dilihat, diamati dan dianalisis oleh manusia. Namun seringkali citra yang dihasilkan mengandung cacat (*noise*), warnanya terlalu kontras ataupun kabur (*blurring*) sehingga sulit diinterpretasi dan informasi yang dimiliki citra menjadi berkurang.

Interpretasi secara visual/manual adalah interpretasi data penginderaan jauh yang didasarkan pada pengenalan ciri/karakteristik objek secara keruangan. Karakteristik objek dapat dikenali berdasarkan 9 unsur interpretasi yaitu bentuk, ukuran, pola, bayangan, rona/warna, tekstur, situs, asosiasi dan konvergensi bukti. [4]. Teknik interpretasi visual dilakukan tidak semata-mata kepada nilai kecerahan, tetapi juga konteks keruangan pada daerah yang dikaji juga dipertimbangkan. Hasil interpretasi sangat bergantung pada peranan interpreter dalam melakukan klasifikasi baik pada citra maupun foto udara. Citra bentuk foto yang dapat diolah lebih sederhana karena tingkat keabuan dari sensor kamera masih setara dengan kemampuan mata manusia (8 – 16 tingkat keabuan) [5]..

d. Metode Klasifikasi

Klasifikasi citra merupakan salah satu proses analisis data secara numeris bertujuan untuk identifikasi kenampakan atau pengenalan pola. Pengenalan pola obyek (*spectral pattern recognition*) adalah

mengevaluasi informasi obyek berdasarkan ciri citra penginderaan jauh sebagai dasar interpretasi citra digital. Pengenalan pola system 1 meliputi kategorisasi pixel citra dengan basis hubungan spasial antar pixel-pixel tersebut^[6].

Maximum likelihood merupakan klasifikasi parametrik yang mensyaratkan setiap kelas selama pelatihan bersifat *gaussian* atau terdistribusi normal berbeda dengan klasifikasi non parametrik dimana data pelatihan secara statistik tidak harus terdistribusi normal.

Jaringan Syaraf Tiruan (*artificial neural network*) adalah sistem yang mengolah informasi yang mempunyai karakteristik mirip dengan jaringan syaraf biologis, yaitu jaringan syaraf pada otak manusia^[7]. Jaringan syaraf tiruan berbasis spasial adalah pengolahan data spasial yang memanfaatkan teknik ANN dalam pemodelan maupun analisisnya.

Support vector machine merupakan teknik pembelajaran mesin yang digunakan untuk pengenalan pola dengan menggunakan pasangan data input dan data output berupa sasaran yang diinginkan. Pembelajaran dengan cara ini disebut dengan pembelajaran terawasi (*supervised learning*). Konsep SVM dapat dijelaskan secara sederhana sebagai usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah kelas pada *input space*. Margin adalah jarak antara *hyperplane* tersebut dengan pola terdekat dari masing-masing kelas. Pola yang paling dekat ini disebut sebagai *support vector*. Usaha untuk mencari lokasi *hyperplane* ini merupakan inti dari proses pembelajaran pada SVM^[8].

e. Uji Akurasi


Akurasi dinilai berdasarkan kebenaran hasil ekstraksi secara digital dengan data lapangan. Cara umum yang digunakan adalah dengan *error matrix* atau sering dikenal dengan *confusion matrix*.^[4]

Akurasi keseluruhan (*overall accuracy*), dihitung dengan membagi jumlah piksel benar (jumlah diagonal utama) dengan jumlah total piksel dalam matriks kesalahan Analisis Kappa merupakan suatu teknik multivariat diskrit yang digunakan dalam penilaian akurasi untuk penentuan secara statistik bahwa sebuah *error matrix* berbeda dari yang lainnya^[9].

Tabel 2. Matriks Kesalahan

Data Klasifikasi	Data Referensi				Total Baris
	D	C	AG	SB	
DC	65	4	22	24	115
C	6	81	5	8	100
AG	0	11	85	19	115
SB	4	7	3	90	104
Total Kolom	75	103	115	141	434

Overall accuracy = $(65+81+85+90)/434 = 321/434=74\%$



Gambar 1. Diagram blok klasifikasi citra


2. Pembahasan

2.1. Koreksi Citra

Beberapa permasalahan yang muncul dalam pengenalan pola spektral dari citra adalah kualitas sensor atau detektor, posisi wahana pada saat perekaman, kondisi topografi daerah yang diliput dan juga kondisi atmosfer pada saat perekaman (tutupan awan dan kabut). Untuk memperbaiki kualitas citra maka dilakukan koreksi radiometrik untuk memperbaiki informasi spektral yang terganggu karena faktor internal seperti mekanisme sensor, sedangkan koreksi geometrik dilakukan untuk memperbaiki posisi citra. Koreksi dilakukan agar citra memberikan informasi yang lebih akurat.

Koreksi geometrik dilakukan dengan memilih 60 titik kontrol (GCP) dengan nilai RMSE 0,307928 yang artinya pada kenyataan terjadi pergeseran sebesar $0,307928 \text{ pixel} \times \frac{10 \text{ meter}}{\text{pixel}} = 3,079 \text{ meter}$.

Proses koreksi radiometrik dilakukan sampai pada tahap koreksi atmosfer atas atau TOA (*Top of Atmosphere*). Koreksi radiometrik TOA dilakukan melalui dua tahap, tahap pertama adalah konversi nilai DN (*digital number*) menjadi nilai spektral radian, dan tahap kedua adalah konversi nilai spektral radian menjadi nilai spektral reflektan.



Gambar 2. (a). citra sebelum koreksi radiometrik; (b) citra setelah koreksi radiometrik

2.2. Analisis Citra


Citra yang digunakan dalam penelitian adalah citra SPOT 5 yang direkam pada 24 oktober 2014 digunakan untuk melihat tutupan lahan. Langkah awal yang dilakukan dalam klasifikasi tutupan lahan/penggunaan lahan adalah memilih area sampel (*training area*) atau *region of interest* (ROI) yang mewakili pola masing-masing kelas. Kelas area sampel yang akan menjadi data pelatihan dipilih berdasarkan pola spektral yang memiliki kenampakan cenderung homogen untuk menjaga nilai piksel murni.

Pemilihan klas penutup lahan dari 10 kelas yang disajikan dalam tabel (3).

Tabel 3. Jumlah Piksel Sampel Klas Tutupan Lahan

No	Kelas Penutup Lahan	Jumlah Piksel
1	Tubuh air	1129
2	Sawah	1748
3	Ladang pantai	1020
4	Awan	663
5	Bayangan awan	1059
6	Bangunan/permukiman	580
7	Lahan terbuka	401
8	Hutan	1316
9	Gisik pantai	778
	Total	8694

Pengenalan pola dilakukan berdasarkan kecenderungan nilai pantulan spektral serta pengetahuan lokal interpreter (*local knowledge*) terhadap lokasi liputan citra. Pada komposit 431(SWIR,NIR, Hijau), pantulan vegetasi tinggi pada saluran hijau karena dipengaruhi oleh pigmen yang terkandung di dalam daun tumbuhan. Pada sawah pantulan spektral lebih cerah dibandingkan pantulan vegetasi hutan karena perbedaan dipengaruhi oleh nilai pantulan tanah lembab.



Gambar 3. (a).awan; (b).tubuh air; (c). hutan; (d). gisik pantai; (e).lahan terbuka; (f).permukiman; (g). sawah (Sumber. Citra Spot 5 komposit 431)

Tabel 4 Akurasi Hasil Klasifikasi SVM

Kernel	Akurasi
<i>Radial basis function</i>	88,02%
<i>Linier</i>	87,65%
<i>Polynomial</i>	87,75%
<i>Sigmoid</i>	80,59%

Tabel 5. Hasil Simulasi ANN

ANN	TR	M	MSE	HL	I	OA
1	0,2	0,9	0,1	1	1000	79,17 %
2	0,2	0,9	0,1	1	1500	81,78%
3	0,2	0,9	0,1	1	2000	76,9%


Keterangan: TR=*training rate*; M= momentum, MSE=*mean square error*; HL = *hidden layer*; I= iterasi; OA= *overall accuracy*

Akurasi tertinggi klasifikasi ANN terjadi pada simulasi dengan parameter (TR=0,2; M=0,9;MSE=0,1;HL=1; I=1500). Parameter iterasi merupakan parameter yang berbeda dari ketiga simulasi diatas (tabel 5). Dapat dikatakan bahwa iterasi yang lebih banyak dapat membantu jaringan lebih optimal sehingga ANN tidak kehilangan sifat generalitasnya (*lost of generalization*). Generalitas adalah kemampuan ANN untuk memberikan jawaban yang benar atau mengenali data-data yang tidak dilatihkan^[10]. Namun, penambahan iterasi yang lebih banyak bukanlah jaminan untuk memperoleh akurasi yang lebih tinggi, karena ANN sering mengalami

fenomena *overfitting* karena *overtrained*. SVM tidak mengalami masalah ini karena training perlu dilakukan sekali saja dan akan mendapatkan solusi optimal. Dapat dilihat perbedaan akurasi yang tidak jauh berbeda pada klasifikasi SVM dengan masing-masing kernel (tabel 4). Fungsi kernel terbaik sangat bergantung pada data. Pada kasus ini, kernel terbaik adalah *radial basis function* yaitu fungsi gaussian. Kernel ini merupakan yang paling populer digunakan karena fungsi dapat secara otomatis menentukan jumlah dan lokasi dari pusat dan nilai nilai bobot ^[11].

Tabel 6. Perbandingan akurasi

	MLC	ANN	SVM
Akurasi keseluruhan	88,87 %	81,78 %	88,02 %
Koefisien kappa	0,87	0,80	0,86



Gambar 4. (a). Citra SPOT 5 komposit 431; (b). Hasil klasifikasi Maximum Likelihood; (c). Hasil klasifikasi SVM; (d). Hasil klasifikasi ANN

Berdasarkan citra hasil klasifikasi, SVM memiliki pola yang lebih mendekati hasil *training data* pada citra asli (88,02%) walaupun memiliki akurasi yang lebih rendah dari hasil klasifikasi MLC (81,78%). Hal ini disebabkan karena klasifikasi parametrik sangat dipengaruhi oleh sebaran piksel secara merata pada masing-masing pola

dan hanya dapat mengenali lebih baik pada pola yang memiliki kecenderungan sama nilai pikselnya dengan data contoh. Sedangkan non parametrik dapat memahami data walaupun memiliki *noise* (gangguan).

Akurasi klasifikasi juga sangat dipengaruhi oleh ketelitian *user* dalam menetapkan area sampel, perlu skema klasifikasi yang lebih detil dan pengujian di lapangan. Pada gambar (4) lahan terbuka terbaca sebagai ladang pantai, dan kesalahan terbesar ditunjukkan oleh pola hasil klasifikasi ANN. Pada dasarnya ANN dapat menghasilkan akurasi yang lebih baik dengan banyak data contoh dan percobaan terhadap beberapa perubahan nilai parameter (jumlah layer tersembunyi, iterasi, momentum). Beberapa penelitian mendapatkan akurasi yang tinggi dengan beragam improvisasi pada parameter jaringan dengan kesimpulan yang berbeda-beda, pada kasus tertentu dengan 1 lapisan tersembunyi (*hidden layer*) lebih baik dibandingkan 2 lapisan tersembunyi demikian pula parameter iterasi, makin banyak jumlah iterasi maka akurasi makin baik namun dititik tertentu iterasi yang banyak jenuh pada akurasi tertentu ^[12,13].

Support vector machine menawarkan kelebihan dibandingkan ANN yaitu lebih konsisten dan tidak terjebak dalam minimum lokal serta tidak ada kebutuhan untuk mengulangi pelatihan dengan *trial and error* pada setiap parameter ANN atau inisialisasi acak yang berbeda ^[14]. Namun dimensi data sangat mempengaruhi waktu komputasi dan optimasi selama pembelajaran seperti halnya pada *artificial neural network* (ANN).

3. Kesimpulan

Dari hasil pengujian yang telah dilakukan dapat diambil simpulan sebagai berikut :

1. SVM dapat diunggulkan untuk menangani pelatihan dataset kecil dengan hasil klasifikasi yang lebih tinggi dibandingkan dengan metode tradisional (MLC)
2. SVM pada kasus ini memiliki akurasi lebih tinggi dibandingkan ANN karena ANN memiliki kekurangan yang selalu terjebak dalam lokal minima dan kerumitan dalam menentukan arsitektur jaringan.
3. ANN memiliki potensi yang sama dengan SVM namun harus melakukan *trial and error* lebih banyak pada data *training* karena ANN mensyaratkan data pelatihan yang lebih banyak dan inisialisasi bobot yang tepat untuk dapat mengenali pola dengan benar.
4. Akurasi hasil klasifikasi tutupan lahan sangat dipengaruhi oleh kemampuan *user* dalam mengenali pola spektral setiap tutupan lahan.

Daftar Pustaka

- [1]. Camps-Valls,G, "Machine Learning in Remote Sensing Data Processing. Machine Learning for Signal Processing", MLSP 2009.
- [2]. Liu, Q., Wu, G., Chen, J., Zhou, G, *Interpretation Artificial Neural Network in Remote Sensing Image Classification*.IEEE, 2012.
- [3]. Danoedoro, P., 2012, *Pengantar Penginderaan Jauh Digital*. Andi.Yogyakarta, 2012.
- [4]. Lillesand, T.M., dan Kiefer, R.W., Chpman, J.W., 2007, *Remote Sensing and Image Interpretation, Sixth Edition*. John Wiley and Sons, New York
- [5]. Soenarmo, S.H, *Penginderaan Jauh dan Pengenalan Sistem Informasi Geografis untuk Bidang Ilmu Kebunian*.ITB Bandung, , 2009
- [6]. Purwadhi, S.H., Sanjoto, T.H., 2008, *Pengantar Interpretasi Citra Penginderaan Jauh*. Lembaga Penerbangan dan Antariksa Nasional dan Jurusan Geografi Universitas Negeri Semarang.
- [7]. Fausett, L, "*Fundamentals Of Neural Networks Architectures, Algorithms, and Applications*", Prentice-Hall, New Jersey, 1994
- [8]. Boswell, D, *Introduction to Support vector Machine*, 2002.
- [9]. Congalton, , R. G., Green, K., "Assessing the Accuracy of Remotely Sensed Data:Principles and Practices". CRC Press. 2009
- [10]. Purnomo,M.H., Kumiawan, A, *Supervised Neural Networks dan Aplikasinya*, Graha Ilmu, Yogyakarta. 2006
- [11]. Kumiawan, D., Supriyanto, C., "Optimasi Algoritma Support Vector Machine (SVM) Menggunakan Adaboost untuk Penilaian Resiko Kredit". *Jurnal Teknologi Informasi*, Vol. 9 Nomor 1, April, 2013.
- [12]. Arif, N., Danoedoro, P, " Study on Experiments of Artificial Neural Network Using Spatial Data" in *J. IJETAE*, Vol. 4, Issue 8,, pp. 732 – 736, August. 2014.
- [13]. Pradhan, B., Lee, S., Buchroitner, M.F., 2010," A GIS-Based Backpropagation Neural Network Model And Its Cross-Application and Validation for Landslide for Susceptibility Analyses".*Computers,Environment and Urban Systems* 34 (2010) pp. 216 – 235, 2010.
- [14]. Mountrakis, G., Im, J., Ogole, C, *Support Vector Machine in Remote Sensing: A Review*. ISPRS Journal of Photogrammetry and Remote Sensing 66:247 – 259, 2011.

Biodata Penulis

Nursida Arif ,memperoleh gelar Sarjana Teknik (S.T), Jurusan Teknik Informatika Universitas Ahmad Dahlan Yogyakarta, lulus tahun 2007. Memperoleh gelar Magister Sains (M.Sc) Program Pasca Sarjana Penginderaan Jauh, Universitas Gajah Mada Yogyakarta, lulus tahun 2011. Saat ini menjadi Dosen di Universitas Muhammadiyah Gorontalo.

Febriana Santi Wahyuni, memperoleh gelar Sarjana Komputer (S.Kom), Jurusan Teknik Informatika Institut Sains & Teknologi Palapa Malang lulus tahun 1997. Memperoleh gelar Magister Komputer (M.Kom) Program Pasca Sarjana Magister Teknik Informatika Institut Teknologi Sepuluh Nopember Surabaya, lulus tahun 2009. Saat ini menjadi Dosen di Institut Teknologi Nasional Malang.

PENGUNAAN METODE MACHINE LEARNING UNTUK PENGENALAN POLA TUTUPAN LAHAN PADA CITRA SATELIT

ORIGINALITY REPORT

4%

SIMILARITY INDEX

4%

INTERNET SOURCES

3%

PUBLICATIONS

5%

STUDENT PAPERS

PRIMARY SOURCES

1

Submitted to STIKOM Bali

Student Paper

3%

2

rimbael.blogspot.com

Internet Source

2%

Exclude quotes On

Exclude bibliography On

Exclude matches < 2%