

Confronto di procedure automatiche di classificazione con elevato numero di classi da immagini a bassa risoluzione.

Gianluigi ROSSI(*), Flavio LUPIA(*), Paolo CASTRACANE(**)

(*) ENEA C.R. Casaccia, Via Anguillarese, 301, 06 30483431, 06 30486038, gianluigi.rossi@casaccia.enea.it

(*) ENEA C.R. Casaccia, Via Anguillarese, 301, 06 30486046, 06 30486038, flavio.lupia@casaccia.enea.it

(**) ACS S.p.A, Via della Bufalotta, 378, 06 87090921, 06 87201502, p.castracane@acsys.it

1. Introduzione

Questo lavoro si colloca all'interno di un progetto finanziato dall'ESA nell'ambito del programma DUE ("Data User Element of the Earth Observation Envelope Programme"). L'obiettivo del Progetto, chiamato *DesertWatch*, è lo sviluppo di un sistema operativo di informazione che sfrutti tecniche di telerilevamento satellitare per la valutazione ed il monitoraggio della desertificazione. Dal punto di vista metodologico il progetto sfrutterà i risultati consolidati delle ricerche scientifiche e dei progetti applicativi finanziati negli ultimi anni da EC, ESA e R&D programmi nazionali (per esempio, *TESEO-Desertification*, *DIMED*, *LADAMER*, *DESERTLINKS*, *MEDALUS*, *DEMON*, *RIADE*, *MEDRAO*, etc.). Il team vede l'*Advanced Computer Systems* S.p.A (ACS) primo contraente e coinvolge partners nazionali ed internazionali di consolidata esperienza nel settore tra cui l'ENEA. Nell'ambito della fase di progettazione preliminare del sistema il gruppo di ricerca coinvolto (ACS S.p.A. - ENEA) ha eseguito un'analisi delle procedure di classificazione al fine di individuare quelle più adatte al tipo di dato da elaborare (immagini Landsat). L'obiettivo è la definizione di una procedura automatica per la classificazione di dati Landsat e MERIS per:

- Aggiornare dinamicamente il *Vegetation Quality Index* e (parzialmente) *Management Quality Index* per le mappe di suscettibilità alla desertificazione.
- Calcolare alcuni indicatori (Aree forestali, sviluppo urbano, aree irrigue, aree incendiate) richiesti dal sistema *DesertWatch*

Il progetto si avvale inoltre dei dati *CORINE Land cover* (CLC) i quali sono disponibili per due date di riferimento: 1990 e 2000.

Abstract

In the context of DesertWatch project (ESA DUE program) has been carried out an analysis of classification methodologies suitable for Landsat images. After a preliminary phase of Landsat images classification techniques, it has been selected two different approaches: maximum likelihood and Object Oriented classification algorithm. Before testing the performances of mentioned above algorithm the dataset has been preprocessed by an hybrid segmentation approach based on "region-based" and "edge-based" technique and a Multiresolution Segmentation tool implemented in Definiens eCognition 4.0. Training areas has been selected (in the three period of analysis: 1984, 1994 and 2004) by an iterative fuzzy classification procedure using CLC maps, verifying a satisfactory radiometric class separability.

2 Metodologia

A valle di una fase preliminare di studio dello stato dell'arte delle tecniche di classificazione, si sono valutate le prestazioni di metodologie distinte su alcune aree di *test*. Le immagini Landsat multispettrali sono state segmentate utilizzando una metodologia che combina sia un approccio "region-based" sia un criterio "edge-based" [1] [2]. Le aree di training vengono estrapolate alle date richieste dal progetto (1984, 1994, 2004) con una procedura iterativa di classificazioni a massima verosimiglianza che parte dalle CLC e consente di ottenere una adeguata separabilità radiometrica delle classi [3]. Stabilito un approccio automatico supervisionato, si è valutata l'accuratezza dei risultati tra un classificatore di Massima Verosimiglianza ed uno basato su un classificatore *Object Oriented*.

2.1 Dati di input e pre-processamento

Sono state selezionate tre aree di *test*, due in Basilicata ed una in Sicilia. Per ogni area erano disponibili due immagini Landsat (primavera e tarda estate/autunno), dalle quali si è esclusa la banda termica; il DEM da cui si derivano *slope* e *aspect* e la carta *Corine Land Cover* (CLC1990 e CLC2000). In seguito ad una fase di test sulla separabilità spettrale delle classi selezionate, sono state selezionate nove classi rappresentate nella *Tabella 1* a cui va aggiunta la classe relativa ai corpi idrici per un totale di 10 classi che rappresentano la legenda per la classificazione delle aree di interesse del progetto.

DESERTWATCH land cover legend	CORINE 3 rd level legend
A+B Mixed Mediterranean maquis and Coniferous forest	3.1.3, 3.2.3, 3.2.4, 3.2.2, 3.1.2
C Deciduous forest	2.4.4, 3.1.1
D Grassland	2.3.1, 3.2.1
E Permanent tree crops and heterogeneous agriculture areas	2.2.1, 2.2.2, 2.2.3, 2.4.1, 2.4.2, 2.4.3
F Non-irrigated arable land	2.1.1
G Irrigated land	2.1.2, 2.1.3
H Bare land	3.3.1, 3.3.2, 3.3.3
I Artificial areas	1.1.1, 1.1.2, 1.2.1, 1.2.2, 1.2.3, 1.2.4, 1.3.1, 1.3.2, 1.3.3, 1.4.1, 1.4.2
N Wetlands	4.1.1, 4.1.2, 4.2.1, 4.2.2, 4.2.3

Tabella 1- Classi DesertWatch e aggregazioni delle classi CLC corrispondenti (i colori rappresentano la legenda relativa alle classificazioni di Figura 1 e fig2)

Le immagini multispettrali sono state segmentate utilizzando un algoritmo sviluppato da ACS basato su un metodo di aggregazione iterativo multiscala sviluppato da Sharon et al., 2000 [1]. Dalle bande segmentate - in cui ogni poligono è rappresentato dal valor medio, sulla banda, dei pixels appartenenti al poligono stesso - una trasformazione nelle componenti principali riduce lo spazio delle configurazioni da 12 bande (6 per ogni immagine) a 5 bande, alle quali si sono aggiunte 3 bande relative al DEM (DEM, *slope*, e *aspect*). Chiameremo semplicemente *input* l'immagine risultante a 12 bande.

2.2 Ottimizzazione del Training

I dati CLC disponibili non possono essere utilizzati *tout court* nel *training* dei classificatori, per due motivazioni:

- Le *land cover* possono essere cambiate in quanto le date del CLC disponibili non corrispondono a quelle delle immagini satellitari richieste al progetto.
- I dati CLC stimati con celle di risoluzione minime di 25 ettari, possono risultare inadeguati nel confronto con le risoluzioni del Landsat.

L'approccio di ottimizzazione seguito si basa sull'assunzione che per ogni classe almeno la metà dei pixel del CLC sono ben classificati. La procedura è sinteticamente riportata nei seguenti passi [2], il risultato è rappresentato nella *Figura 1*:

- i. Inizialmente l'*input* viene classificato con un classificatore a massima verosimiglianza utilizzando tutto il CLC aggregato come in *Tabella 1*
- ii. L'uscita della classificazione viene generata mantenendo, per ogni *pixel*, l'informazione di probabilità di appartenenza a quella determinata classe (logica *fuzzy*)
- iii. Dopo la prima iterazione i *pixel* con confidenze inferiori al 25 percentile vengono esclusi e la classificazione viene rieseguita considerando come training soltanto i *pixel* rimanenti.
- iv. La confidenza sulla classificazione viene calcolata iterativamente mantenendo come training soltanto i *pixel* con probabilità superiori al 50%
- v. Il processo iterativo tende rapidamente a stabilizzarsi (un numero sempre inferiore di *pixel* viene scartato). Tipicamente 5 iterazioni sono sufficienti all'ottimizzazione del *training*.




Figura 1- CLC (sinistra) e training ottimizzato (destra)

2.3 Approccio di Change Detection con classificatore ML

La metodologia proposta si basa sulla combinazione delle classificazioni ottenute da un classificatore a massima verosimiglianza allenato con un training purificato ottenuto con la procedura descritta nel paragrafo precedente. I concetti base sono:

- Si generano tre classificazioni, quella relativa ai dati primaverili, quella relativa ai dati autunnali, e quella che comprende tutte e due le immagini Landsat – rispettivamente C10, C11 e Clall
- La land cover finale è ottenuta con un criterio di maggioranza tra le classificazioni e che include la CLC anche in input.

L'algoritmo prevede il passaggio ad un criterio basato su una tabella della verità a tre input qualora non venga soddisfatto un requisito di accuratezza stimato *versus* il CLC per la singola classe per ogni classificazione. Può accadere che per un poligono (regioni definite dalla segmentazione) non venga definita una classe maggioritaria. Questo corrisponde, per esempio, al caso in cui tutti gli elementi (Classificazioni e CLC) associno un dato segmento ad una classe differente. Questo può accadere per quei segmenti difficili in cui sia il contesto spaziale che l'informazioni spettrale non garantiscono un sufficiente potere discriminante. L'assegnazione di questi segmenti avviene contando il numero di *pixel* che appartengono a ciascuna classe per le tre classificazioni e per il CLC. La classe più votata è eletta rappresentante di quel segmento.

La classificazione finale viene processata al fine di eliminare regioni isolate con una popolazione di *pixel* al di sotto di una soglia determinata e per ottenere una risoluzione spaziale compatibile con i requisiti del progetto.

2.4 Pre-processamento Object Oriented

A valle della procedura di acquisizione dei dati multispettrali e parallelamente alla fase di segmentazione eseguita con l'algoritmo sviluppato da ACS, il gruppo di lavoro ENEA ha effettuato la segmentazione delle immagini attraverso il *Tool Multiresolution Segmentation* del software eCognition 4.0. L'algoritmo di segmentazione è basato su una procedura di *region-merging* il quale aggrega i *pixels* dell'immagine secondo due criteri: ogni poligono è rappresentato dal momento del secondo ordine; i poligoni vengono aggregati tenendo conto anche della loro forma. Sull'immagine segmentata si è effettuato il calcolo delle componenti principali (PCA). Una trasformazione nelle componenti principali riduce lo spazio delle configurazioni da 12 bande (6 per ogni immagine) a 5 bande, alle quali si sono aggiunte 3 bande relative al DEM (DEM, *slope*, e *aspect*).

2.5 Classificazione Object Oriented

A differenza della metodologia standard di classificazione per pixel, la classificazione *Object Oriented* si basa sul concetto di immagine come insieme di oggetti. L'immagine è interpretata come un insieme di oggetti di differente forma e differente risposta spettrale e, a seconda del criterio di assegnazione scelto, questi saranno attribuiti ad una particolare classe della legenda DW. L'oggetto-poligono viene classificato secondo una serie di criteri intrinseci, topologici e contestuali. Nel presente lavoro, per esigenze di sviluppo di requisiti del progetto, si è utilizzato il software Definiens eCognition 4.0 il quale implementa una metodologia di classificazione *Object Oriented*. L'algoritmo di classificazione utilizzato in eCognition 4.0 è lo *Standard Nearest Neighbor* (SNN) e si compone di differenti criteri definiti *Membership Functions* (MF). Le MF consistono in un insieme di criteri intrinseci, topologici e contestuali che possono essere combinati per definire un unico criterio di classificazione dell'immagine. Una volta scelta la combinazione di MF adatte si assegna un valore di soglia al criterio SNN definito dal parametro *slope*, affinché ogni poligono venga correttamente assegnato ad una determinata classe.

2.6 Risultati per l'approccio di Massima Verosimiglianza

Una serie di *test* hanno portato alla definizione di una procedura che soddisfi i seguenti requisiti.

- Sia basata sulla disponibilità di due immagini per anno (selezione in primavera e fine estate/autunno)
- Sia completamente automatica
- Consideri le classi definite nella *Tabella 1*
- Abbia un'accuratezza compresa tra l'80 ed il 90 %

L'obiettivo appare molto ambizioso in quanto non sono presenti in letteratura algoritmi completamente automatici che garantiscano classificazioni di un numero così alto di classi con le accuratezze richieste dalle specifiche del progetto. I seguenti aspetti hanno portato i miglioramenti più significativi:

- Ottimizzazione del *training*
- Approccio *Region-based* (segmentazione delle immagini)
- Strategia *Change-Detection*
- Post-classificazione con aggregazione alla minima unità spaziale

I risultati dei *test*, calcolati per le aree di *test* versus il CLC2000 sono riportati nella *Tabella 2*. La classificazione per l'area di *test* Basilicata_1 è riportata nella *Figura 2* (a sinistra).

Test Site	Basilicata_1	Basilicata_2	Trapani
Overall Accuracy %	80.11	80.41	88.95

Tabella 2- Accuratezza stimata versus il CLC per le tre aree di test.

2.7 Risultati per l'approccio Object Oriented

Una serie di *test* hanno portato alla definizione di una procedura che soddisfi i seguenti requisiti.

- Sia basata sulla disponibilità di due immagini per anno (selezione in primavera e fine estate/autunno)
- Si possa basare su di un protocollo di classificazione implementabile con eCognition 4.0 e che sia completamente automatica
- Consideri le classi definite nella *Tabella 1*
- Abbia un'accuratezza compresa tra l'80 ed il 90 %

L'obiettivo appare anche in questo caso molto ambizioso in quanto non sono presenti in letteratura protocolli completamente automatici implementati per questo tipo di software e che garantiscano classificazioni di un numero così alto di classi con le accuratezze richieste dalle specifiche del progetto. I seguenti aspetti hanno portato i miglioramenti più significativi:

- Ottimizzazione del *training*
- Approccio *Region-merging* (segmentazione delle immagini)
- Approccio *Membership Functions* attraverso criteri intrinseci, topologici e contestuali
- Post-classificazione con aggregazione alla minima unità spaziale

I risultati dei *test*, calcolati per le aree di *test* versus il CLC2000 sono riportati nella *Tabella 3*. La classificazione per l'area di *test* Basilicata_1 è riportata nella *Figura 2* (a destra).

Test Site	Basilicata_1	Basilicata_2	Trapani
eCognition 4.0-Overall Accuracy %	75.10	75.40	84.78

Tabella 3- Accuratezza stimata versus il CLC per le tre aree di test.




Figura 2- Classificazione ML (a sinistra) e Classificazione Object Oriented SNN(a destra) per l'area di test Basilicata_1.

3 Conclusioni

Per il progetto *DesertWatch* diverse strategie sono state studiate per realizzare classificazioni automatiche:

- Approccio di *Change Detection* con classificatore ML
- Classificazione Object Oriented

Le analisi effettuate mostrano come sia difficoltoso definire una procedura automatica o un protocollo automatico di classificazione con elevata accuratezza volendo discriminare un elevato numero di classi (*target* di progetto 12 classi) con bassa separabilità spettrale. L'utilizzo combinato di una tecnica di segmentazione delle immagini e di una procedura di ottimizzazione del *training set* consente di ottenere una adeguata separabilità radiometrica delle classi. L'approccio di *Change detection* con classificatore ML risulta fornire, dai nostri *test*, le accuratezze - in termini di *Overall Accuracy* e *K-Coefficient* più alte (80-89 %) rispetto all'approccio *Object Oriented* (75-84 %) con l'uso del software Definiens eCognition 4.0. Ciò non toglie il fatto che l'analisi svolta con eCognition 4.0 ha evidenziato una flessibilità e una potenzialità del software che può certamente migliorare in futuro i risultati finora raggiunti nel presente lavoro. In conclusione, il progetto *DesertWatch* utilizzerà la strategia di *Change Detection* con classificatore ML per generare i prodotti e gli indicatori richiesti.

4 Bibliografia

- [1] Sharon E., Brandt A., Basri R. "Fast Multiscale Image Segmentation" *CVPR*, 1:70-77, 2000
- [2] Baatz, M.A.S.(2000), "Multiresolution segmentation - an optimization approach for high quality multi-scale image segmentation", *Angewandte Geographische Informationsverarbeitung XI. Beiträge zum AGITSymposium Salzburg 1999*. Karlsruhe, Herbert Wichmann Verlag.
- [3] Arcuri G., Chirici G., Romanelli S., e Maselli F., "Procedura semiautomatica per l'aggiornamento di carte di uso del suolo tramite immagini telerilevate".
- [4] Blaschke, T.(2005), "A framework for change detection based on image objects", In: *Erasmí, S., Cyffka, B., Kappas, M. (Eds.) Göttinger Geographische Abhandlungen*, Vol. 113, Göttingen, 1-9.
- [5] Blaschke, T., Lang S. and Möller M.S.(2005), "Object-based analysis of remote sensing data for landscape monitoring", *Recent developments. Anais xii simpósio brasileiro de sensoriamento remoto, goiânia, brasil, 16-21 abril 2005*, inpe, p. 2879-2885.
- [6] Chen, Y., T. Fung, Lin W. and Wang J. (2005), "An image fusion method based on object-oriented image classification", In: *proceedings of the igarss 2005 symposium*. Seoul, korea. July 25-29.
- [7] Greiwe, A. and Ehlers M.(2005), "Combined analysis of hyperspectral and high resolution image data in an object oriented classification approach", In: *proceedings of the isprs wg vii/1 "human settlements and impact analysis" 3rd international symposium remote sensing and data fusion over urban areas (urban 2005) and 5th international symposium remote sensing of urban areas (urs 2005)*. Tempe, Az, Usa. March 14 - 16 2005.
- [8] Hájek, F.(2005), "Object-oriented classification of remote sensing data for the identification of tree species composition", *Proceedings of ForestSat 2005 conference*, May 31 - June 3, 2005, Borås, Sweden.