

# ACTIVE LEARNING FOR ONE-CLASS CLASSIFICATION USING SVDD

## Candidato:

Mirco Furlani

## Relatore:

Prof. Lorenzo Bruzzone (Università degli Studi di Trento, Remote Sensing Laboratory, Italia)

## Correlatori:

Dr. Devis Tuia (Ecole Polytechnique Fédérale de Lausanne, Laboratory of GIS, Svizzera)

Prof. Gustavo Camps-Valls (Universidad de Valencia, Image Processing Laboratory, Spagna)

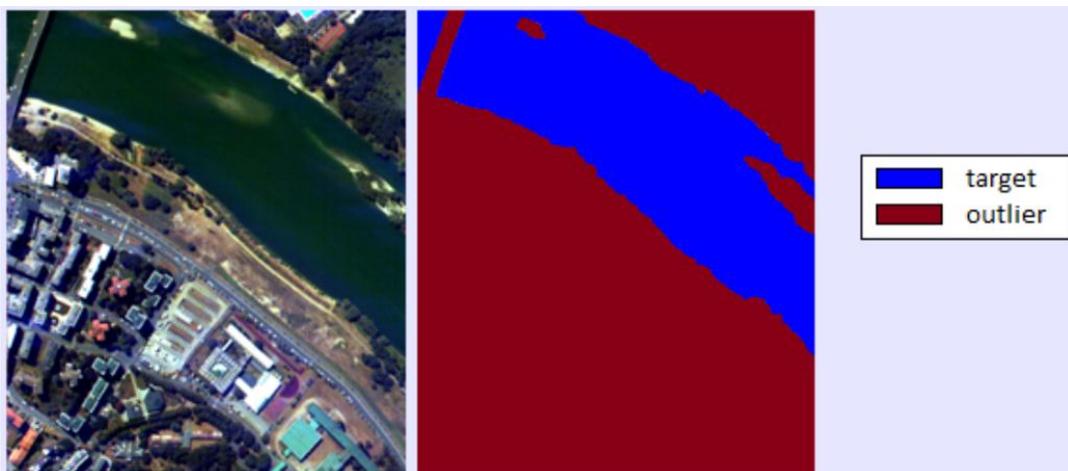
Dr. Jordi Muñoz-Mari (Universidad de Valencia, Image Processing Laboratory, Spagna)

Dr. Francesca Bovolo (Università degli Studi di Trento, Remote Sensing Laboratory, Italia)

## Abstract

### Introduzione generale al problema

Nell'ambito della classificazione di immagini telerilevate vi sono un gran numero di applicazioni in cui l'interesse si focalizza su di una specifica classe di copertura del suolo senza considerare in alcun modo le altre classi[1] (Fig. 1).



**Fig.1. Classificazione a singola classe di immagine telerilevata. La classe target è rappresentata dall'acqua.**

In tutti questi casi, l'utilizzo delle convenzionali tecniche di classificazione supervisionata multi-classe può essere inappropriata e portare ad un inutile dispendio di risorse in termini di costi e tempi. Al contrario, la classificazione a singola classe (OCC, One-Class Classification) è appropriata, perché il train del classificatore può essere fatto con campioni della classe di interesse (i.e. classe target) senza che sia richiesto alcun campione per le altre classi (i.e. classi outlier). Tuttavia la complessità del problema deriva dal fatto che è spesso difficile costruire un training set in modo efficiente, tale per cui la classe target sia rappresentata in modo completo e accurato. Nella presente trattazione viene presentato un efficace ed innovativo metodo di Active Learning (AL)

adatto per OCC basato sul classificatore Support Vector Data Description (SVDD)[2]. Il classificatore SVDD è inizializzato con un piccolo numero di campioni di train; ad esempio, per applicazioni al problema del Change Detection essi sono ottenuti in modo non supervisionato grazie alla tecnica di Change Vector Analysis (CVA) [3]. Viene poi richiesto ad un esperto di etichettare campioni di train supplementari, scelti a partire da un insieme di campioni non etichettati e selezionando solo quei campioni che sono in grado di incrementare il più possibile l'accuratezza del modello (i.e. apportare la maggiore quantità di informazione possibile). In particolare, il nuovo criterio di AL introdotto permette di accentuare la diversità dei campioni selezionati per l'etichettatura e sfrutta un metodo che permette una ricerca "aggressiva" che espande velocemente la frontiera di decisione. I campioni scelti vengono quindi etichettati dall'utente esperto e inclusi nel training set solo se classificati come appartenenti alla classe target. Tale procedura di selezione ed etichettatura si ripete in modo iterativo fino ad ottenere un modello di classificazione che soddisfi determinati parametri di accuratezza di classificazione (Fig. 2).

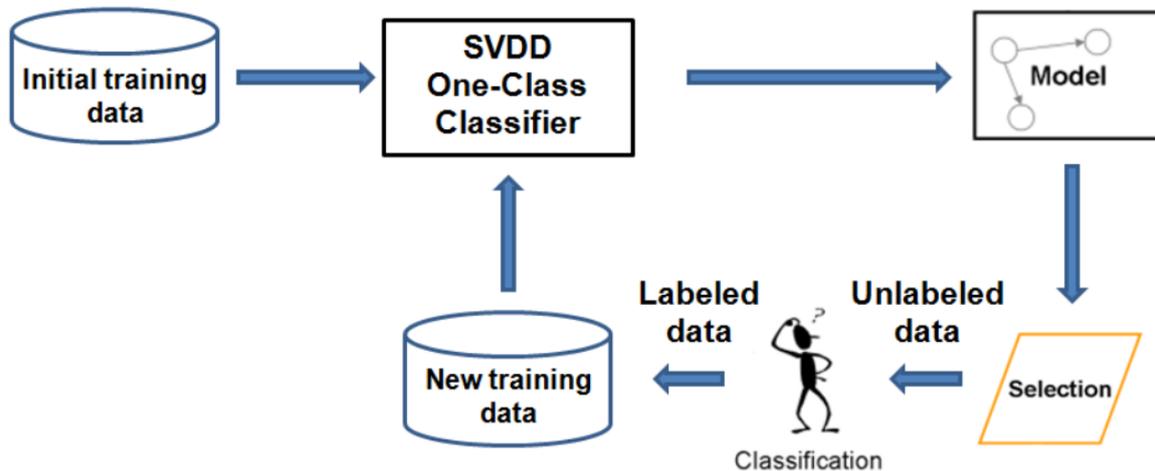
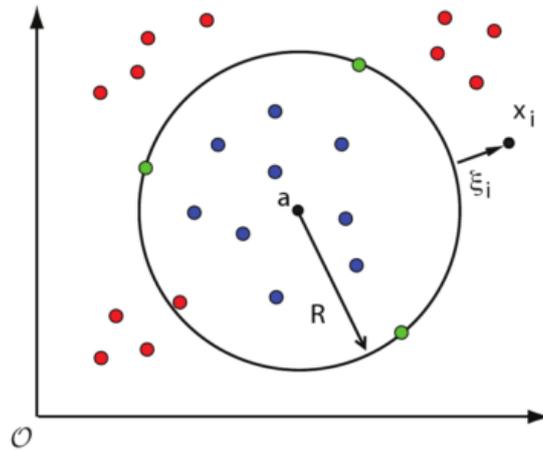


Fig.2. Schema del processo di active learning con SVDD.

### 1. Support Vector Data Description

In questa tesi è stato preso in considerazione il classificatore SVDD (Support Vector Data Description) (Fig. 3). Ispirato al Support Vector Machine, calcola una frontiera di decisione iperferica con minimo volume attorno alla classe dei campioni target (in blu •), resa eventualmente flessibile grazie all'utilizzo delle funzioni kernel. Tutti gli outliers (in rosso •) vengono lasciati all'esterno, ammettendo l'eventuale presenza di errori (in nero •,  $\xi_i$ ), mentre i vettori di supporto (in verde •) sono sulla superficie dell'ipersfera stessa. Tuttavia, per ottenere elevate accuratezze di classificazione, il classificatore SVDD ha bisogno di un gran numero di campioni etichettati. Soprattutto in problemi di classificazione di immagini telerilevate, fornire tali campioni è molto dispendioso sia in termini di costi che di tempo richiesto.



**Fig.3. Il classificatore SVDD.**

## 2. Active Learning

La procedura di AL è quindi necessaria al fine di etichettare solo i campioni più utili. AL sfrutta l'interazione uomo-macchina per migliorare in modo iterativo le performance del modello minimizzando il numero di campioni di train. Selezionando opportunamente i campioni da proporre ad un esperto per l'etichettatura, questa procedura permette dunque di ridurre drasticamente i costi computazionali e di etichettatura [4]. Un intuitivo criterio di selezione dei campioni per SVDD è quello di scegliere campioni vicini all'ipersfera poiché sono i campioni più incerti relativamente alla loro classe di appartenenza. Dato un insieme di campioni non etichettati  $U$ , la funzione di decisione dell'SVDD attuale  $f(\cdot)$  e il raggio attuale  $R$ , il campione selezionato  $x^*$  sarà il seguente:

$$x^* = \min_{x \in U} |f(x) - R|$$

Tale criterio risulta essere molto efficiente per problemi di classificazione a 2 classi o multi classi, ma si adatta meno bene per problemi di OCC.

Il metodo di AL per OCC proposto in questa tesi sfrutta la diversità dei campioni e la ricerca "aggressiva", che verranno ora mostrate.

### 2.1 Diversità

La tecnica introdotta in questa tesi seleziona ad ogni iterazione campioni spettralmente diversi, vale a dire campioni distanti tra di loro nello spazio ipersferico, evitando la selezione di campioni ridondanti (i.e. campioni che portano informazioni molto simili tra di loro). E' stato qui adottato il criterio Angle Based Diversity (ABD) [5] per la selezione di campioni:

$$x^* = \min_{x_i \in I/B} \left\{ \lambda \underbrace{\left( f^D(x) - R \right)}_{\text{uncertainty}} + (1 - \lambda) \underbrace{\left( \max_{x_j \in B} K^*(x_i, x_j) \right)}_{\text{diversity}} \right\}$$

dove il parametro  $\lambda$  regola il trade-off tra incertezza e diversità mentre  $K(x, x_i)$  è una misura del kernel. Tale criterio ci permette nel caso del classificatore SVDD una selezione dei campioni per settori. L'incertezza e la diversità dei campioni assicurano una costante espansione dell'ipersfera, ma la crescita risulta essere piuttosto lenta. Si rende quindi necessaria anche l'adozione di un metodo di ricerca che esplori regioni che non siano necessariamente vicine alla frontiera di decisione.

## 2.2 La ricerca "aggressiva"

La ricerca cosiddetta "aggressiva" è stata pensata appositamente per problemi di OCC. Essa seleziona due insiemi di campioni:

- campioni vicini alla frontiera di decisione e classificati all'ultima iterazione del processo di AL come appartenenti alla classe target
- campioni lontani dalla frontiera di decisione e classificati all'ultima iterazione del processo di AL come appartenenti alla classe outlier

Le due aree di interesse vengono quindi definite sulla base di due anelli circolari: uno interno all'ipersfera (molto stretto) ed uno esterno (molto più ampio) (Fig. 4).

Sulla base di tali considerazioni, anche la diversità è stata trattata in modo da tenere presente questa configurazione, definendo un modello di diversità a 3 livelli:

- internamente all'anello circolare interno
- internamente all'anello circolare esterno
- reciprocamente tra l'anello circolare interno e quello esterno

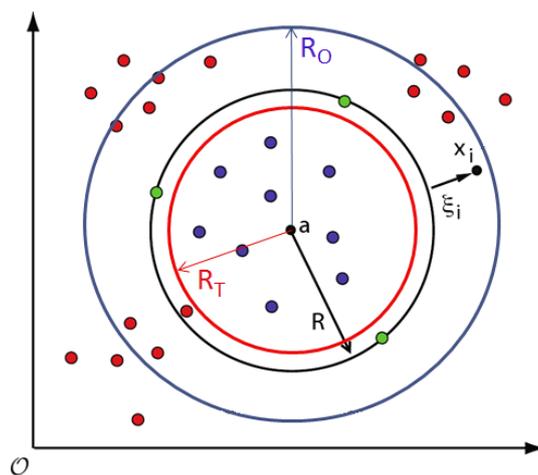
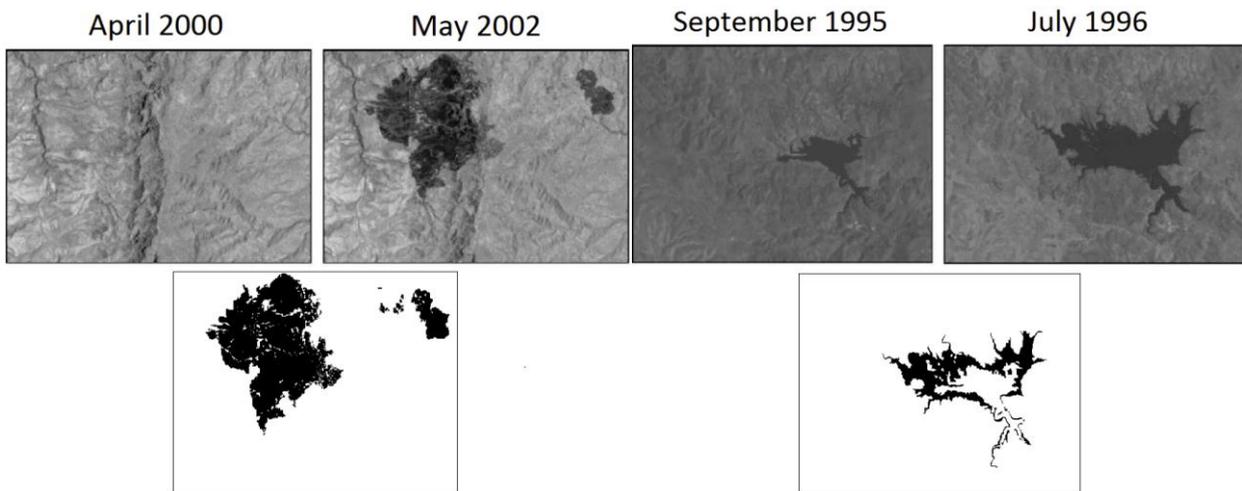


Fig.4. SVDD e anelli circolari.

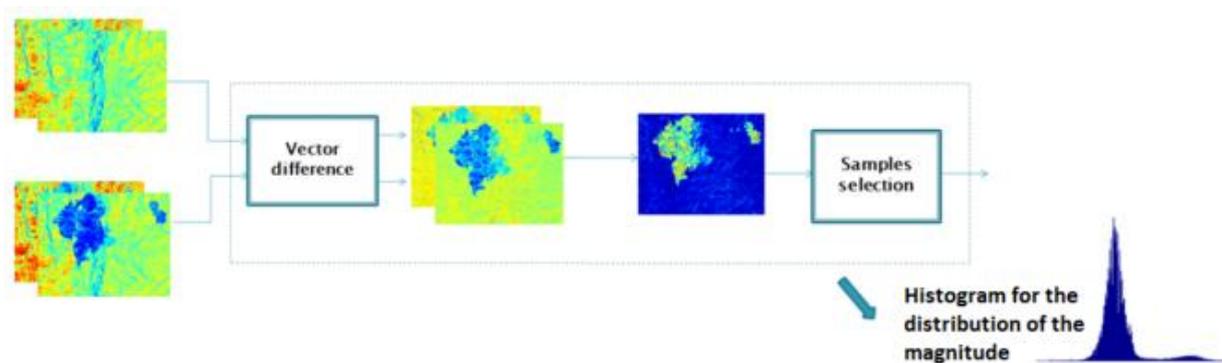
## 3. Risultati sperimentali

Il problema del Change Detection è un classico problema di OCC. Vengono presi in considerazione due differenti Dataset (Fig. 5) con immagini multispettrali acquisite in tempi differenti e si vuole ricavare l'area associato al cambiamento intercorso tra le due date di acquisizione.



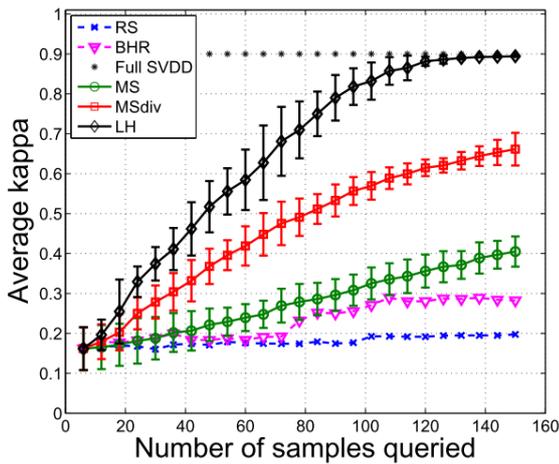
**Fig.5. Dataset: incendio area boschiva del Messico (sinistra) e allargamento Lago Mulargia in Sardegna (destra). Satellite Landsat-5, sensore TM, Channel 4. Le immagini in basso sono le mappe di riferimento.**

Iniziamo con pochi campioni selezionati grazie alla tecnica CVA per la definizione del training set iniziale, come mostrato in Fig. 6.



**Fig.6. Tecnica CVA per la definizione del training set iniziale**

In seguito vengono selezionati campioni non etichettati aggiuntivi ed aggiunti al training set solo se appartenenti alla classe target. I risultati numerici mostrano che la tecnica proposta (LH, in **nero**) permette di raggiungere, fissato un certo numero di campioni, un livello di accuratezza di classificazione nettamente superiore rispetto a tecniche di Random Sampling (in **blu** e **viola**) o rispetto a metodi tipicamente utilizzate in problemi di classificazione a due classi o multi classe, quali la tecnica di Marginal Sampling e Marginal Sampling con diversità (in **verde** e **rosso**) (Fig. 7).



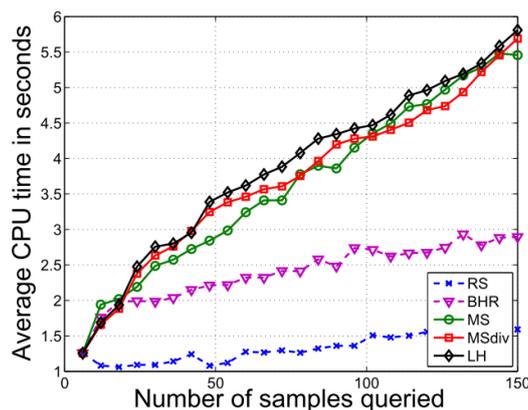
| AL techniques | Number of samples (target kappa accuracy 0,4) |
|---------------|-----------------------------------------------|
| RS            | 540                                           |
| BHR           | 232                                           |
| MS            | 148                                           |
| MSdiv         | 55                                            |
| LH            | 34                                            |

| AL techniques | Number of samples (target kappa accuracy 0,6) |
|---------------|-----------------------------------------------|
| RS            | 952                                           |
| BHR           | 398                                           |
| MS            | 261                                           |
| MSdiv         | 114                                           |
| LH            | 62                                            |

| AL techniques | Number of samples (target kappa accuracy 0,8) |
|---------------|-----------------------------------------------|
| RS            | 1321                                          |
| BHR           | 572                                           |
| MS            | 374                                           |
| MSdiv         | 176                                           |
| LH            | 91                                            |

**Fig.6. Accuratezza di classificazione (Kappa di Cohen) mediata su 10 ripetizioni per la tecnica proposta (in nero), Marginal Sampling con diversità (in rosso), Marginal Sampling (in verde), Half Random Sampling (in viola), Random Sampling (in blu) su dataset relativo a un area boschiva del Messico.**

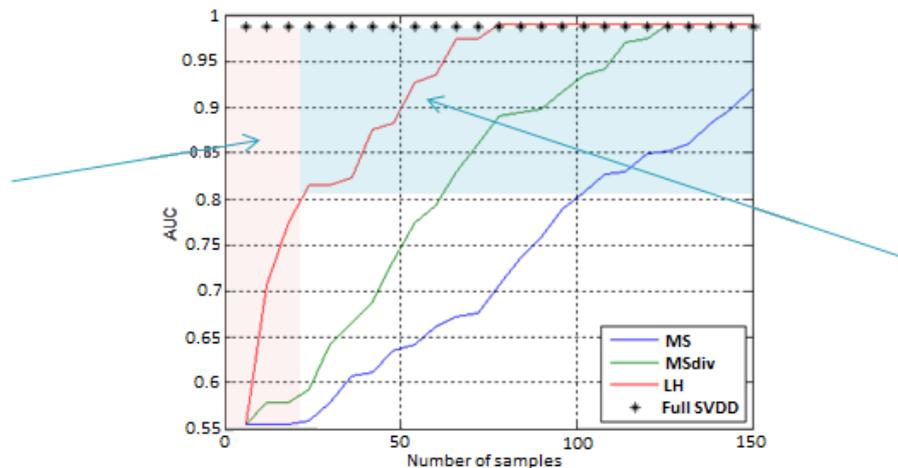
Si noti inoltre che i tempi di esecuzione e di CPU (Fig. 7) della tecnica LH sono assolutamente comparabili rispetto alle tecnica di Marginal Sampling. Come ci si poteva aspettare le tecniche di Random Sampling raggiungono le prestazioni migliori in termini di tempi di esecuzione, ma sono anche le peggiori in termini di accuratezza di classificazione.



**Fig.7. Tempo medio di CPU (in secondi) in funzione del numero di campioni selezionati**

Risultati analoghi che confermano le prestazioni dall' algoritmo sono stati ottenuti sul dataset relativo al Lago Mulargia in Sardegna. Per tale dataset viene infine mostrato (Fig. 8) come la tecnica LH (in rosso) sia in grado inizialmente di espandere molto velocemente l'ipersfera grazie ai campioni selezionati lontani dall'ipersfera (parte di curva evidenziata in rosa), mentre in una

seconda fase è in grado di raffinare l'ipersfera grazie ai campioni selezionati in prossimità della frontiera di decisione.



**Fig.8. Accuratezza di classificazione (Area Under Curve) per una singola iterazione utilizzando la tecnica proposta (in rosso), Marginal Sampling con diversità (in verde), Marginal Sampling (in blu) su dataset relativo al lago Mulargia in Sardegna.**

#### 4. Risultati sperimentali

Abbiamo proposto un metodo di AL ottimizzato per problemi di OCC, mostrando come i metodi di AL tipicamente utilizzati per problemi a più classi non sono i migliori per OCC. Abbiamo mostrato come nel OCC con SVDD esistano due fasi: una fase di espansione dell'ipersfera e una successiva fase di raffinamento. Nel OCC tuttavia è molto più importante inizialmente espandere il più possibile l'ipersfera. Infine la tecnica proposta ha fornito il miglior trade-off tra accuratezza di classificazione e complessità computazionale.

#### Bibliografia

- [1] Sanchez-Hernandez, C. Boyd, D.S. ; Foody, G.M. "One-Class Classification for Mapping a Specific Land-Cover Class: SVDD Classification of Fenland", IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING 45(4), 1061 – 1073 (2007).
- [2] David M. J. Tax, Robert P. W. Duin: "Support vector domain description". Pattern Recognition Letters 20(11-13): 1191-1199 (1999).
- [3] F. Bovolo, G. Camps-valls, L. Bruzzone, "A Support Vector Domain Method for Change Detection in Multitemporal Images" in PATTERN RECOGNITION LETTERS, v. vol. 31, n. no. 10 (2010), p. 1148-1154.
- [4] Tuia, Volpi, Copa, Kanevski Munoz-Mari, "A survey of active learning algorithms for supervised remote sensing image classification", IEEE J. Sel. Topics Signal Proc., 2011, 5, 606-617.
- [5] Demir, B., Persello, C., Bruzzone, L., "Batch mode active learning methods for the interactive classification of remote sensing images", IEEE Trans. Geosci. Remote Sens., 2011, 49, 1014-1032