

Metodi di elaborazione di immagini SAR: un'applicazione di Support Vector Machines

Introduzione

In quest'articolo, presenteremo un nuovo approccio alla classificazione di immagini SAR, basato sulle cosiddette *Multi-class Support Vector Machines* (M-SVMs)¹. Le Support Vector Machines (SVMs) sono state introdotte all'interno della Statistical Learning Theory^{2,3}.

Uno dei più grandi risultati della Statistical Learning Theory è dato dal fatto che l'errore di probabilità di un classificatore è limitato superiormente da una quantità dipendente non soltanto dal tasso d'errore raggiunto sul training set, ma anche da un'intrinseca proprietà del classificatore, la quale è una misura della "ricchezza" dell'insieme delle funzioni decisionali che si possono implementare: questa va sotto il nome di "capacità" o dimensione di Vapnik-Chervonenkis.

Più l'insieme delle funzioni decisionali è ricco, più alta è la capacità del classificatore, e il limite superiore sull'errore di probabilità può essere aumentato per valori crescenti della capacità. Questo risultato ha suggerito un diverso approccio per il training del classificatore, basato sulla cosiddetto principio Structural Risk Minimisation (SRM).

Il suo scopo è di raggiungere il minimo valore per il limite superiore dell'errore di probabilità di un classificatore tramite un trade-off fra le performance sul training set e la capacità. L'applicazione dell'SRM ha condotto alla tecnica delle Support Vector Machines⁴.



Fig. 1 - Immagine ERS-1 SAR usata per il test

Le M-SVM sono una estensione della teoria delle SVM; esse permettono di trattare i problemi di classificazione nei quali sono coinvolti più di due classi di elementi. Per quanto riguarda i principi teorici delle M-SVM rimandiamo al lavoro di Hsu e Lin¹. Nella sezione 2, pertanto, passeremo subito a mostrare un test applicativo utilizzando le M-SVM e l'immagine in Fig. 1⁶. Infine, nella sezione 3, illustreremo le nostre conclusioni.

Test Applicativo di M-SVM

Come già brevemente descritto all'interno dell'introduzione a quest'articolo, abbiamo scelto di applicare le M-SVM all'immagine presentata in Fig. 1. In essa possono essere isolate tre grandi classi di elementi: *Terra*, *Petrolio* e *Mare*.

La predilezione per l'immagine sopra presentata è giustificata dall'applicazione del remote sensing al monitoraggio ambientale. Attraverso, infatti, un'attenta disamina delle sue varie parti, è possibile applicare il nostro algoritmo di riconoscimento immagini al controllo da satellite di eventuali presenze in mare di chiazze di petrolio fuoriuscite da petroliere o da piattaforme di estrazione.

Il problema, pertanto, si risolve in una ricerca di riconoscimento pattern all'interno dell'immagine considerata, che richiede la costruzione di classificatori adeguati utilizzando, nel nostro caso, per l'appunto le M-SVM.

I classificatori sono stati creati attraverso una fase di training. Il database di input è una matrice 4x4965 (la sua costruzione è presentata successivamente); il database di output, invece, è stato creato utilizzando la codifica presentata in Tab. 1:

TABELLA 1

CODIFICA USATA PER CREARE IL DATABASE DI OUTPUT

Classe	Etichetta assegnata
Mare	1
Petrolio	2
Terra	3

Nell'ambito del remote-sensing, notevoli sviluppi si sono avuti dal momento in cui tecniche non lineari proprie dell'Intelligenza Artificiale sono state impiegate nel campo della cosiddetta land cover classification. In quest'ambito, è stato pensato di implementare un algoritmo di riconoscimento immagini tramite l'applicazione di una nuova tecnica di riconoscimento pattern alla classificazione di immagini SAR. Tale tecnica è stata recentemente introdotta all'interno della cosiddetta Statistical Learning Theory sviluppata da V. Vapnik e al., e viene indicata sotto il nome di Support Vector Machines (SVMs).

Poiché, però, le SVMs sono propriamente dei classificatori binari, è stata utilizzata una loro estensione, definita come Multi-class Support Vector Machines (M-SVMs). Queste sono state implementate da Hsu and Lin al fine di applicare la teoria di Vapnik anche alle applicazioni nelle quali sono coinvolte più di due classi di elementi. La tecnica proposta ha portato a risultati molto interessanti, con un grado di affidabilità stimabile attorno ad un 94% circa. Essa, pertanto, potrebbe essere a ragion veduta applicata ad applicazioni di monitoraggio ambientale e rilevazione di cambiamenti di sorta nel contesto di singole zone oggetto di telerilevamento da aereo e/o da satellite.

Implementazione del database di input

Per la costruzione del database di input abbiamo utilizzato i seguenti quattro parametri statistici: media, deviazione standard, skewness e curtosi. Ognuna è stata calcolata per ogni subzona considerata all'interno dell'immagine SAR di partenza.

Infatti, per ogni classe, abbiamo considerato alcuni boxplot di campioni caratteristici della medesima classe. Ogni boxplot è un quadrato di lato 1.

Per costruire il database dei pattern è stato implementato il seguente algoritmo:

indichiamo con S il cosiddetto *step coefficient*, inizialmente settato ad un valore di default pari a 4; all'interno di ogni boxplot, abbiamo considerato tutti i sub-boxplot quadrati di lato $S \times S$ ed abbiamo calcolato i loro valori statistici;

lo *step coefficient* è stato moltiplicato per un fattore 2, ed abbiamo ripetuto l'algoritmo fintantochè $S \leq 1$.

Questa procedura è stata usata per ogni boxplot selezionato (Fig. 2).




Fig. 2 - Boxplot usati per il database di input: a) Classe Mare; b) Classe Petrolio; c) Classe Terra

In Tab. 2 sono riportati i range di variazione dei parametri statistici.

TABELLA 2

RANGE DI VARIAZIONE DEI PARAMETRI STATISTICI

Parametri Statistici	Mare	Petrolio	Terra
Media	[33.125 205.94]	[0 26.688]	[31.125 186.19]
Deviazione Standard	[6.8105 49.681]	[0 24.752]	[3.304 96.339]
Skewness	[-2.637 1.99]	[0.20254 15.843]	[-2.2735 1.9365]
Curtosi	[1.2626 15.235]	[1.3457 317.36]	[1 8.3151]

Performance del classificatore

Come descritto in [1], le SVM (e conseguentemente le M-SVM) sono caratterizzate da una funzione di decisione utilizzata durante la fase di training e chiamata *Kernel*. Brevemente, il kernel è usato per cercare gli iperpiani di separazione fra le varie classi. Noi abbiamo analizzato le performance delle M-SVM con un kernel polinomiale, in quanto ha consentito di ottenere performance degne di nota unitamente ad una bassa complessità computazionale e ad un relativamente breve tempo di calcolo.

Il kernel polinomiale si presenta nella forma

$$K(x_i, x_j) = (\gamma \|x_i - x_j\| + \mu)^2, \gamma > 0$$

e nel nostro caso abbiamo assegnato ai vari parametri i seguenti valori:

$$\lambda = 7; C = 100; \gamma = 1; \mu = 0.$$

Teniamo a precisare che C un parametro scelto dall'utente; esso definisce la sensibilità della macchina agli errori: utilizzare un relativamente grande valore per C significa penalizzare fortemente gli errori. Pertanto esso può essere interpretato come un parametro di regolarizzazione.

Il test effettuato sul classificatore ha restituito la seguente *Matrice di confusione*:

0.9066	0.0934	0
0.1534	0.8466	0
0	0	1.0000

Come è possibile notare, l'identificazione della zona *Petrolio* è nominalmente ottimale, mentre i valori della prima e della seconda ri-

ga della *Matrice di confusione* mostrano come il classificatore ha una seppure piccola possibilità di confondere la classe *Mare* con *Terra* e viceversa. Alla fine di questa sottosezione, presentiamo l'ammontare dei support vector per ogni classe (Tab. 3).

TABELLA 3

NO. DI SUPPORT VECTOR PER IL CLASSIFICATORE M-SVM

Mare	Petrolio	Terra
627	3	628

Un test di classificazione

Considerando la tecnica di creazione del classificatore M-SVM, basato sui valori di media, deviazione standard, skewness e curtosi, sarebbe illogico considerare ciascun pixel avulso dal contesto dell'intera immagine. Pertanto, ogni pixel è analizzato inserendolo in una finestra di opportune dimensioni. Per

ottenere un'accurata stima concernente il pixel in questione è necessario avere una finestra abbastanza ampia⁸; però, più grande è l'ampiezza di tale finestra, più alta è la probabilità di recepire delle disomogeneità dentro la stessa finestra, che potrebbero inficiare la stima stessa. Pertanto la scelta di una finestra di 5x5 pixel ci è sembrata abbastanza opportuna. Quindi, abbiamo classificato l'immagine di Fig. 1 pixel per pixel, considerando ognuno di questi in una finestra contestuale di dimensioni 5x5, dove possibile. Infatti, per i pixel in prossimità dei bordi, per i quali non è possibile ottenere un contorno di dimensioni 5x5, abbiamo esaminato finestre più piccole.

Il classificatore restituisce una nuova immagine in output, nella quale:

il colore bianco mostra che il pixel è stato classificato come *Mare*;

il colore nero indica che il pixel è stato classificato come *Petrolio*;

il colore grigio corrisponde alla classificazione del pixel come zona *Terra*.

CONCLUSIONI

Come una prima analisi visiva suggerisce, è possibile stimare il valore medio percentuale di affidabilità delle M-SVM ad un 94% circa, con prestazioni degne di nota per quanto concerne la zona *Petrolio* in primis e la zona *Terra* in secundis. La nostra ricerca, pertanto, ha consentito di pervenire alla costruzione di un classificatore notevolmente performante che sia in grado di poter rintracciare all'interno di un'immagine telerilevata presenza di eventuali chiazze petrolifere.

Ecco, quindi, che la rappresentazione grafica avvalora quanto inizialmente indicato dalla *Matrice di confusione*, tenendo anche in opportuna considerazione che le percentuali di affidabilità indicate nelle varie righe della medesima rappresentano dei valori nominali e quindi suscettibili di lievi modifiche in

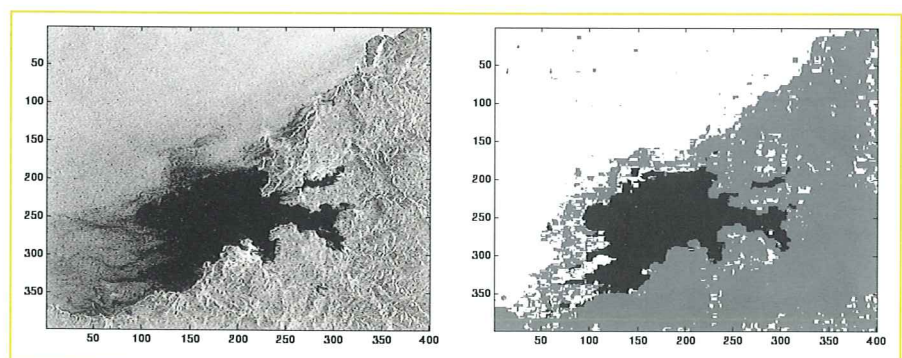


Fig. 3 - a) immagine originale in toni di grigio; b) immagine classificata utilizzando il classificatore con kernel polinomiale

fase di reale utilizzo del classificatore. Ad ogni buon conto, a nostro avviso questo si presenta essere un buon risultato, soprattutto se si considera che l'immagine utilizzata non è stata pulita con un qualsivoglia filtro (per esempio un filtro adattativo non coerente basato sulla trasformata wavelet), e quindi è ancora affetta da rumori derivanti dai fenomeni di speckle e fading. Tutto ciò conferma la validità di un classificatore M-SVM in qualità di strumento non lineare di riconoscimento di pattern, grazie alla sua abilità di "generalizzare bene" a partire da un rappresentativo insieme di elementi di ogni classe, selezionati all'interno dell'intero "dominio universo" che, nel nostro caso, è rappresentato dall'immagine di Fig. 1.

Note

[1] C. W. Hsu, C.-J. Lin, "A comparison of methods for Multi-class Support Vector Machines", Department of Computer Science and Informaion Engineering, National Taiwan University

[2] V.N. Vapnik, "The Nature of Statistical Learning theory", Springer Verlag, New York, 1995

[3] V.N. Vapnik, "Statistical Learning theory", Wiley, New York, 1998

[4] C. Cortes, V.N. Vapnik, "Support vector networks", Machine Learning 20, pp. 273-297, 1995

[5] F. Roli, G. Fumera, "Support Vector Machines for Remote-Sensing Image Classification", Dept. of Electrical and Electronic Eng., University of Cagliari, Italy

[6] J. Lichtenegger, "Using ERS-1 SAR images for oil spill surveillance",

<http://esapub.esrin.esa.it/eqq/eqq44/lichten.htm>

[7] J. Ma, Y. Zhao, S. Ahalt, Matlab toolbox OSU-SVM 3.0, http://www.eleceng.ohio-state.edu/~maj/osu_svm/


[8] S. Barbarossa, L. Parodi, "SAR Image Classification by Wavelets", IEEE International Radar Conference, 1995, pp. 462-467

Autori

G. Angiulli*, V. Barrile*, M. Cacciola

* DIMET – Dipartimento di Informatica, Matematica, Elettronica e Trasporti
Università degli Studi "Mediterranea"
di Reggio Calabria
89100 Reggio Calabria – Italy

Long Range 3D Laser Scanner MENSIS GS100



Il laser scanner GS100 è una soluzione eccezionalmente versatile per l'acquisizione di grandi quantità di dati. La sua straordinaria efficienza è proprio nel poter acquisire un elevato numero di informazioni su ampie zone in tempi significativamente ridotti.

È lo strumento ideale per il rilievo di ponti, tunnel, edifici, monumenti, insediamenti industriali o archeologici.

Caratteristiche principali:

- Portata fino a 100 mt.
- Precisione 3-6 mm (standard mode)
- Area di scansione 360°x60°
- Sensore CCD per acquisizione dell'immagine
- Dimensioni: 32x42x28
- Peso: 13 Kg

GS100

GEO TOP
Positioning Instruments



GEOTOP srl
Via Brece Bianche, 152 - 60131 ANCONA
Tel. 071.21325.1 - Fax 071.21325.282
E-mail: info@geotop.it

www.geotop.it