

MAPPE TEMATICHE DA DATI SATELLITARI: INTEGRAZIONE TRA METODOLOGIE NEURALI E AD OGGETTI

Alessandro BURINI(*), Cosimo PUTIGNANO (*), Fabio DEL FRATE(**), Giorgio LICCIARDI (**), Daniela IASILLO (***), Guido SIGNORILE (***)

(*) Geo-K S.r.l., spin-off of Tor Vergata University, Via del Politecnico 1, 00133 Rome - Italy,
tel, +39 0694188571, *e-mail*:cosimo.putignano@geok.it

(**) Dipartimento di Informatica Sistemi e Produzione, Via del Politecnico, 1 - 00133 Rome ITALY,
tel, +39 0672597734, *e-mail*: delfrate@disp.uniroma2.it

(***) Planetek Italia, Via Massaua, 12 - 70123 Bari ITALY,
tel, +39 0809644200, *e-mail*: iasillo@planetek.it

Introduzione: Il progetto GSE LAND

Il progetto GSE (GMES Service Element) LAND, finanziato dall’Agenzia Spaziale Europea (ESA), risponde all’esigenza di supportare i paesi europei nel recepire e rendere operative le direttive in tema di gestione del territorio. Il progetto mette insieme le esperienze di 3 precedenti progetti dedicati nello specifico al monitoraggio dell’inquinamento delle acque e al calcolo di indicatori agro-ambientali (SAGE), alla gestione degli ambiti urbani (GUS) e alla gestione delle fasce costiere (COASTWATCH).

Obiettivo di LAND è, quindi, la realizzazione di una serie di servizi per la gestione ed il monitoraggio dell’ambiente basati sull’integrazione di dati satellitari con dati ancillari.

Il progetto coinvolge circa 60 partners tra fornitori dei servizi, utenti ed enti di ricerca distribuiti a livello europeo.

In questo ambito Planetek Italia è un fornitore del servizio “Urban Atlas” che consiste nella realizzazione di mappe tematiche di uso del suolo su aree urbane. Le mappe sono realizzate a partire da dati ad altissima risoluzione SPOT 5 con l’ausilio di mappe topografiche e degli stradari. La metodologia di estrazione delle informazioni tematiche si basa su tecniche object oriented.

In questo contesto si inserisce la collaborazione con l’Università di Tor Vergata che sta sperimentando l’integrazione con classificatori NN al fine di migliorare la qualità complessiva del prodotto finale.

L’algoritmo neurale

Le reti neurali sono modellate sull’architettura del cervello umano e consistono di numerose semplici unità fortemente interconnesse. Il primo modello di neurone artificiale fu proposto nel 1943 da Warren Mc-Culloch e Walter Pitts (Mc-Culloch e Pitts, 1943). Essi proposero per primi un modello di elaborazione dell’informazione in cui la singola unità processante, o neurone, calcolava una somma pesata dei suoi ingressi provenienti da altre unità, e dava in uscita il valore binario di 1 o 0 a secondo o meno che il valore di tale somma fosse superiore o inferiore ad una certa soglia. Negli anni ’50 e ’60 si arrivò allo sviluppo delle prime reti neurali artificiali con la capacità di apprendere (Rosenblatt, 1962). Le unità di processing erano simili al neurone di Mc-Culloch e Pitts, ma le sinapsi erano costituite da connessioni di diverso peso, che poteva essere cambiato durante il processo d’apprendimento. Lo spirito della regola di addestramento era abbastanza semplice: si trattava di presentare degli esempi alla rete e di modificare i pesi delle connessioni per ottenere un miglioramento del risultato, così da avvicinarsi alle uscite desiderate. L’entusiasmo iniziale fu però spento qualche anno più tardi, quando si cominciarono a trovare le prime importanti limitazioni a tali modelli. Il più grande difetto riscontrato fu la caratteristica di avere un solo strato di connessioni

adattative. Minsky e Papert (Minsky and Papert, 1969) mostrarono che tali reti erano in grado di separare solo linearmente gli input. Questo significava, ad esempio, che non erano in grado di "imparare" la funzione booleana dell'or esclusivo (XOR). Minsky e Papert mostrarono comunque che queste limitazioni potevano essere superate introducendo, nello schema del Perceptrone Semplice, uno strato intermedio (o hidden) di neuroni. Si otteneva in tal modo una rete neurale multistrato. A quel tempo, comunque, nessuna regola d'apprendimento sembrava efficiente per le reti neurali con strati intermedi, così la ricerca su tali versanti andò progressivamente diminuendo. Fu nel 1985 che numerosi schemi d'apprendimento per le reti neurali multistrato cominciarono ad emergere dagli ambienti di ricerca, riportando in auge le reti neurali. Grande successo ebbe, per facilità d'apprendimento e semplicità d'implementazione, la *delta-rule* generalizzata, introdotta da Rumelhart nel 1986 (Rumelhart et al., 1986). L'applicazione di tale regola richiedeva due fasi specifiche. Nella prima fase, l'input è propagato avanti nella rete verso le unità d'output. Nella seconda fase, l'errore è propagato all'indietro attraverso la rete ed è utilizzato per aggiornare i pesi delle connessioni interne. E' dalla caratteristica di questa seconda fase che tale procedura è conosciuta con il nome di Backpropagation. Dal quel momento numerosi ricercatori hanno cominciato ad applicare le reti neurali per la risoluzione di vari problemi di inversione e classificazione. In particolare le reti neurali hanno dimostrato interessanti potenzialità nel campo dell'Osservazione della Terra e per il processamento automatico delle immagini (Del Frate et al., 2007).

La rete neurale utilizzata per il nostro studio è una classica rete perceptron feedforward con uno strato interno (vedi figura 1) dove, per ciascun neurone, è stata scelta la funzione di attivazione logistica, definita come segue (Bishop, 1995):

$$f(x) = \frac{1}{1 + e^{-x}} [1]$$




Figura 1- Tipologia feedforward di una rete neurale

La rete è stata addestrata basandosi su algoritmi SCG (*Scaled Coniugate Gradient*), che rappresentano un'alternativa significativamente più veloce rispetto all'algoritmo standard di "*Backpropagation*" (Møller, 1993). La simulazione software è stata eseguita dal simulatore denominato SNNS (Stuttgart Neural Network Simulator), sviluppato presso l'Università di

Stoccarda (Zell et al., 1995). Tale simulatore si è dimostrato avere un soddisfacente livello di affidabilità e flessibilità. I tempi di calcolo necessari per l'addestramento sono sempre stati contenuti entro poche ore di una CPU di media velocità.

Poiché la classificazione dell'immagine è stata effettuata su base pixel, gli insiemi di addestramento e di validazione sono stati ottenuti considerando in ingresso il vettore di features caratterizzanti il pixel e in uscita un vettore con numero di componenti pari al numero di classi di copertura considerate. È stato poi assegnato il valore 1 alla componente del vettore corrispondente alla classe di appartenenza del pixel esaminato e il valore 0 alle altre componenti.

È stata poi effettuata una compressione dei dati di ingresso fino a considerare per questi ultimi un dominio limitato all'intervallo in cui la funzione sigmoideale ha una caratteristica quasi lineare. Ciò risulta vantaggioso per due motivi. Permette di evitare fenomeni di saturazione in ingresso e rende omogenei gli intervalli in cui variano i valori delle componenti il vettore di ingresso della rete.

Metodologia e risultati

Per la produzione di cartografia tematica da dati satellitari SPOT finalizzata alla realizzazione di mappe di uso del suolo, la metodologia consolidata si basa una classificazione ad oggetti basata sul software eCognition, considerato, ad oggi, uno degli strumenti più efficienti per l'elaborazione automatica delle immagini. D'altro canto, gli algoritmi di classificazione mediante reti neurali possono inserirsi nell'attuale metodologia ottimizzandone alcune fasi.

Di seguito saranno mostrati i risultati relativi a tre differenti classificazioni. Per queste elaborazioni è stata considerato come dato di input il solo dato satellitare (non sono stati utilizzati altri dati vettoriali ancillari). Tutti i pixel delle classificazioni ottenute sono stati confrontati con quelli relativi ad un'immagine di verità a terra ottenuta per fotointerpretazione tramite dati satellitari, ortofoto, e dati vettoriali.

L'immagine considerata per la classificazione ha una dimensione di 1924x1352 pixel e corrisponde ad un'area situata nei pressi della città di Padova (vedi figura 2). Nell'area sono presenti diversi tematismi classificabili in accordo al primo livello della legenda utilizzata per GSE (GMES Service Element) LAND; considerando la stessa terminologia inglese usata nel progetto le classi sono: *Settlement*, *Cropland*, *Forest*, *SBWG* (Shrubs & Bushes, other Wooded land and Grassland) e *Water*, nelle figure rispettivamente in rosso, giallo, verde e azzurro.




Figura 2- a) Immagine satellitare utilizzata come input per la classificazione e b) Ground Truth utilizzato per il calcolo delle matrici di confusione

Per la prima classificazione è stato utilizzato il software e-Cognition. La metodologia di elaborazione prevede più fasi. La prima consiste nella segmentazione dell'immagine. Mediante opportuni parametri e diversi pesi assegnati alle bande costituenti l'input (quattro bande multispettrali con risoluzione di 10 m e una banda pancromatica con risoluzione di 2.5 m) sono stati creati gli oggetti sfruttando la funzione di *Multiresolution Segmentation*. Per gli oggetti sono state calcolate le *features* più indicate alla classificazione in modo da ottimizzarne il numero senza

eccessiva perdita di informazione. Per la classificazione sono stati quindi utilizzati, oltre alle bande costituenti l'immagine satellitari, 4 parametri di forma e 5 parametri di tessitura. Il risultato ottenuto è mostrato in figura 3, mentre le relative matrici di confusione, relative alla totalità dei pixel, sono mostrate nella tabella 1. Si osserva che l'accuratezza totale è quasi del 70%.




Figura 3- Risultato della classificazione mediante e-Cognition

Overall Accuracy = (1810664/2601248) 69.6%					
Kappa Coefficient = 0.5407					
Class	Settlement	Cropland	Forest & SBWG	Water	Total
Settlement	349777	457059	54649	1022	862507
Cropland	44167	786827	149649	291	980934
Forest & SBWG	11758	68821	665138	2082	747799
Water	25	1061	0	8922	10008
Total	405727	1313768	869436	12317	2601248

Tab. 1- Matrice di confusione relativa alla classificazione mediante e-Cognition

Per la seconda classificazione è stato utilizzato un algoritmo utilizzando le reti neurali. Il risultato è mostrato in figura 4 ed è stato ottenuto mediante una tipologia di rete a due strati interni di 25 unità, utilizzando come dato di ingresso le sole bande dell'immagine satellitare. La matrice di confusione relativa a questa classificazione è schematizzata in tabella 2. Possiamo notare un miglioramento rispetto al risultato precedente con un'accuratezza totale di circa il 75%.




Figura 4- Risultato della classificazione mediante reti neurali

Overall Accuracy = (1963312/2601248) 75.5%					
Kappa Coefficient = 0.6086					
Class	Settlement	Cropland	Forest & SBWG	Water	Total
Settlement	343826	275366	23699	813	643704
Cropland	53312	1004859	242477	135	1300783
Forest & SBWG	6940	29950	603260	2	640152
Water	1649	3593	0	11367	16609
Total	405727	1313768	869436	12317	2601248

Tab. 2 - Matrice di confusione relativa alla classificazione mediante reti neurali.

Per l'ultima classificazione è stata utilizzata una nuova rete neurale. Come *layers* di ingresso sono state utilizzate sia le bande dell'immagine satellitare, sia i *layers* ottenuti durante la fase di ottimizzazione in e-Cognition. In totale, in ingresso alla rete, sono stati presentati 14 *layers*. È stata tuttavia mantenuta la stessa dimensione per gli strati interni di processamento. I risultati di questo tipo di elaborazione sono mostrati in Figura 5, mentre le matrici di confusione in tabella 3. L'accuratezza ottenuta in questo caso è quella migliore ed è superiore all'80%.




Figura. 5- Risultato della classificazione ibrida eCognition- Reti Neurali.

Overall Accuracy = (2095820/2601248) 80.6% Kappa Coefficient = 0.6912					
Class	Settlement	Cropland	Forest & SBWG	Water	Total
Settlement	344598	185388	24082	474	554542
Cropland	44791	1016491	120619	358	1182259
Forest & SBWG	15264	102116	723246	0	840626
Water	1074	9773	1489	11485	23821
Total	405727	1313768	869436	12317	2601248

Tab. 3 Matrice di confusione relativa alla classificazione mista e-Cognition, Reti Neurali.

Conclusioni

L'elaborazioni effettuate in questo studio hanno confermato le potenzialità dell'utilizzo delle reti neurali nella la classificazione automatica di dati satellitari. Esse, quando utilizzate nella modalità stand-alone forniscono risultati del tutto comparabili con quelli ottenuti mediante i migliori software di classificazione attualmente esistenti. La loro versatilità, inoltre, le rende molto adatte ad elaborazioni ibride, nelle quali metodologie *object-oriented* e *pixel-oriented* possono essere utilizzate in maniera sinergica.

Riferimenti bibliografici

Bishop C. M. (1995), *Neural Networks for Pattern Recognition*, pp 232--234. Oxford.

Del Frate F., Pacifici F., G. Schiavon G., Solimini C. (2007), "Use of neural networks for automatic classification from high resolution imagery," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, n. 4, pp. 800-809, April 2007.

Møller M. (1993), A scaled conjugate gradient algorithm for fast supervised learning, *Neural Networks*, vol. 6, 1993, pp. 525-533.

McCulloth W. S. e Pitts W.(1943), A logical calculus of ideas immanent in nervous activity, *Bulletin of Mathematical Biophysics*, 5, pp 115-133. Reprinted in Anderson and Rosenfeld (1988).

Rosenblatt F.(1962), *Principles of Neurodynamics*, New York: Spartan.

Minsky M. L. e Papert S. A.(1969). *Perceptrons*. Cambridge: MIT Press

Rumelhart D.E., Hinton G.E., Williams R.J. (1986). Learning Internal Representations by Error Propagation. In D.E. Rumelhart, J.L. McClelland and the PDP Research Group, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Vol. 1: Foundations*, Cambridge: MIT Press.

Zell A. et al. (1995), *Stuttgart Neural Network Simulator User Manual*, Version 4.2