

CAPITOLO SESTO

**RICONOSCIMENTO DELLA VEGETAZIONE SULL'IMMAGINE
QUICKBIRD****§6.1 La densità di vegetazione: l'indice NDVI**

Allo scopo di caratterizzare la distribuzione della vegetazione sulle superfici di barena si è provveduto all'elaborazione delle immagini corrette radiometricamente e geometricamente. La prima fase è consistita nella valutazione della densità vegetale mediante l'utilizzo di un indice di vegetazione. Gli indici sfruttano la differenza di riflettanza della vegetazione nel visibile (in particolare nel blu e nel rosso) e nel vicino infrarosso, e possono basarsi semplicemente su rapporti fra bande o essere espressi in formule più complesse che richiedono informazioni relative a parametri del suolo e alla composizione atmosferica. Queste analisi non consentono in generale di valutare l'abbondanza di ciascuna specie presente al suolo, ma forniscono ad ogni modo utili informazioni sullo stato fenologico della vegetazione e sulla sua densità.

L'indice di vegetazione più diffuso è l'NDVI (*Normalized Difference Vegetation Index*), che ha il vantaggio di consentire il confronto fra immagini riprese in tempi diversi. L'NDVI mette in relazione l'assorbimento spettrale della clorofilla nel rosso

con la tipica riflessione nel vicino infrarosso dove è fortemente influenzata dal tipo di struttura fogliare (Gomasca, 1997).

Il valore dell'NDVI è definito dalla relazione:

$$NDVI = \frac{\rho_{IR} - \rho_R}{\rho_{IR} + \rho_R} \quad [2]$$

Questa funzione può assumere valori dell'intervallo $[-1,+1]$ che, in genere, sono compresi tra $-0,1$ e $+0,6$.

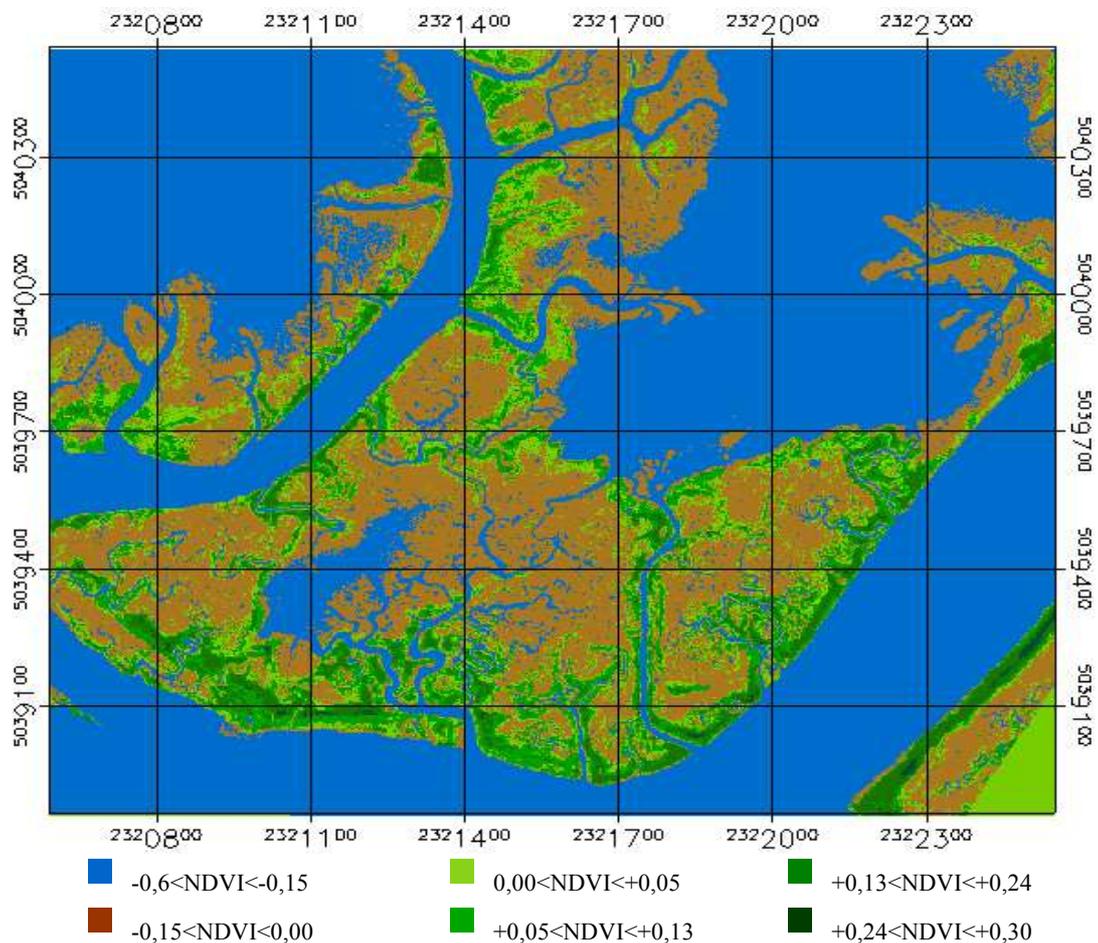


Fig. 6.1 - NDVI calcolato sui dati QuickBird relativi all'area di S.Felice.

Il risultato dell'applicazione dell'indice alle bande 3 e 4 del QuickBird è un'immagine in scala di grigi in cui i *pixel* più chiari rappresentano i valori maggiori di NDVI. Mediante una tecnica disponibile nel software ENVI che consente di suddividere in intervalli la scala continua di grigio e di assegnare a ciascuno di essi

un colore predefinito (*density slicing*), è stato possibile visualizzare l'immagine in modo che fosse più agevole apprezzare la distribuzione sulla scena delle zone a diversa densità vegetale (fig.6.1).

La scala dei valori assunti dall'indice risulta piuttosto ridotta e i valori non sono molto alti, come c'è da aspettarsi considerando che l'immagine è stata acquisita nel mese di maggio, quando ancora la vegetazione non era ancora cresciuta completamente; inoltre dall'immagine risulta evidente la notevole presenza di suolo, dovuta essenzialmente ad una condizione di marea particolarmente bassa che ha fatto emergere le zone di bassofondo e i meandri di molti ghebi e canali.

Un'ulteriore formulazione dell'NDVI è rappresentata dal *Fractional Vegetation Cover* (FVC), che normalizza l'NDVI e lo trasforma in un indice di copertura percentuale di vegetazione. Il valore di FVC è definito dalla relazione:

$$FVC = \frac{NDVI - NDVI_{\min}}{NDVI_{\max} - NDVI_{\min}} \quad [3]$$

dove, in questo caso, $NDVI_{\max} = 0,30$ ed $NDVI_{\min} = -0,6$.

La [3] ha quindi l'effetto di normalizzare l'NDVI tra i valori che rappresentano lo 0% ($NDVI_{\min}$) e il 100% di copertura vegetale ($NDVI_{\max}$).

Mediante l'applicazione della funzione *density slicing* all'immagine ottenuta, si nota che le aree relative ad acqua e suolo sono state considerate dall'indice come aree a copertura percentuale minore di 67,5%, mentre solamente per densità maggiori di questo valore l'indice riconosce la presenza di vegetazione e ne stima l'abbondanza sulla base dell'NDVI calcolato. Anche in questo caso, lo spostamento del valore minimo di copertura vegetale rilevabile dal sensore dipende essenzialmente dal periodo di acquisizione dell'immagine, rilevata a metà maggio e quindi in condizioni di vegetazione ancora in buona parte secca e non in fiore. La diversa riflettanza della vegetazione in questo stadio fenologico può quindi aver attenuato la differenza nella risposta nel rosso e nell'infrarosso vicino. Il risultato sulla mappa è che la maggior parte della copertura vegetale si assesta in media tra il 67,5% e l'87,5%, mentre solo in poche zone si raggiunge una densità di vegetazione considerevole vicina al 100% (fig.6.2). Entrambe le elaborazioni illustrano inoltre come la densità di vegetazione

risulti maggiore lungo i bordi dei ghebi e dei canali, e diminuisca invece procedendo verso le zone più interne della barena.

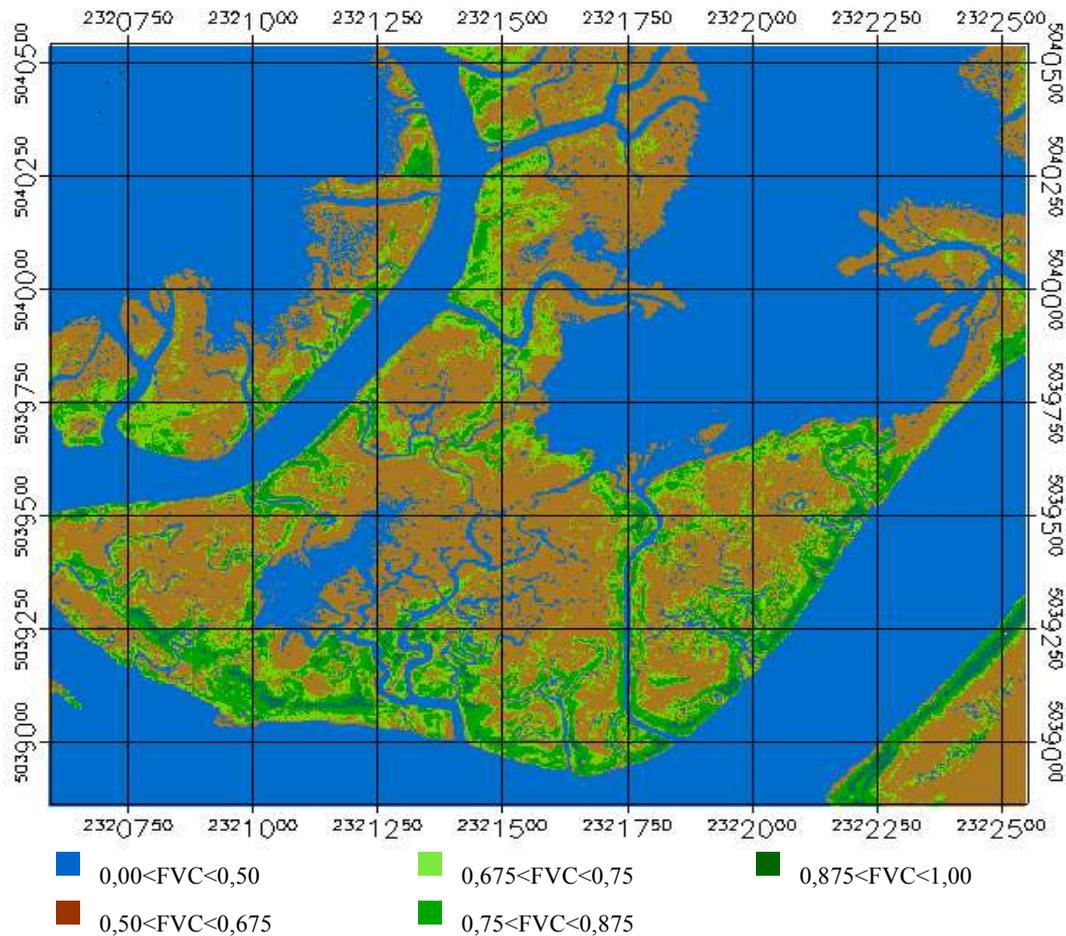


Fig.6.2 - FVC calcolato sui dati QuickBird relativi all'area di S.Felice.

§6.2 L'individuazione delle aree di verità a terra sull'immagine

Il riconoscimento della vegetazione alofila di barena sulle immagini avviene tramite la definizione a terra di aree a composizione nota e la successiva localizzazione delle stesse sull'immagine. Come già visto nel capitolo IV, nelle barene di San Felice, Pagliaga, Saline e Palude Maggiore sono stati effettuati i primi rilievi vegetazionali previsti dal progetto TIDE. Nelle uscite in campo si sono individuate più di 70 aree di vegetazione monospecifica da utilizzare per la classificazione. In fig.6.3 viene riportato un esempio di localizzazione di alcune delle aree rilevate nella zona di Spacco Tralo presso la barena di San Felice. Come si nota nel dettaglio ingrandito, i poligoni tracciati vanno a coprire più *pixel* dell'immagine

aggregandoli in categorie, o classi, con caratteristiche omogenee di copertura; in particolare nell'immagine sono indicate alcune aree di bordo rilevate lungo i ghebi o i canali principali e caratterizzate da elevata eterogeneità, e aree interne più vaste, formate da consorzi vegetali di due o tre specie al massimo. Di ogni area perimetrata è stata stimata anche la presenza percentuale di suolo nudo, in modo da poter determinare l'interferenza di questo elemento con la risposta spettrale della vegetazione e il suo effetto sulla classificazione che ne deriva.

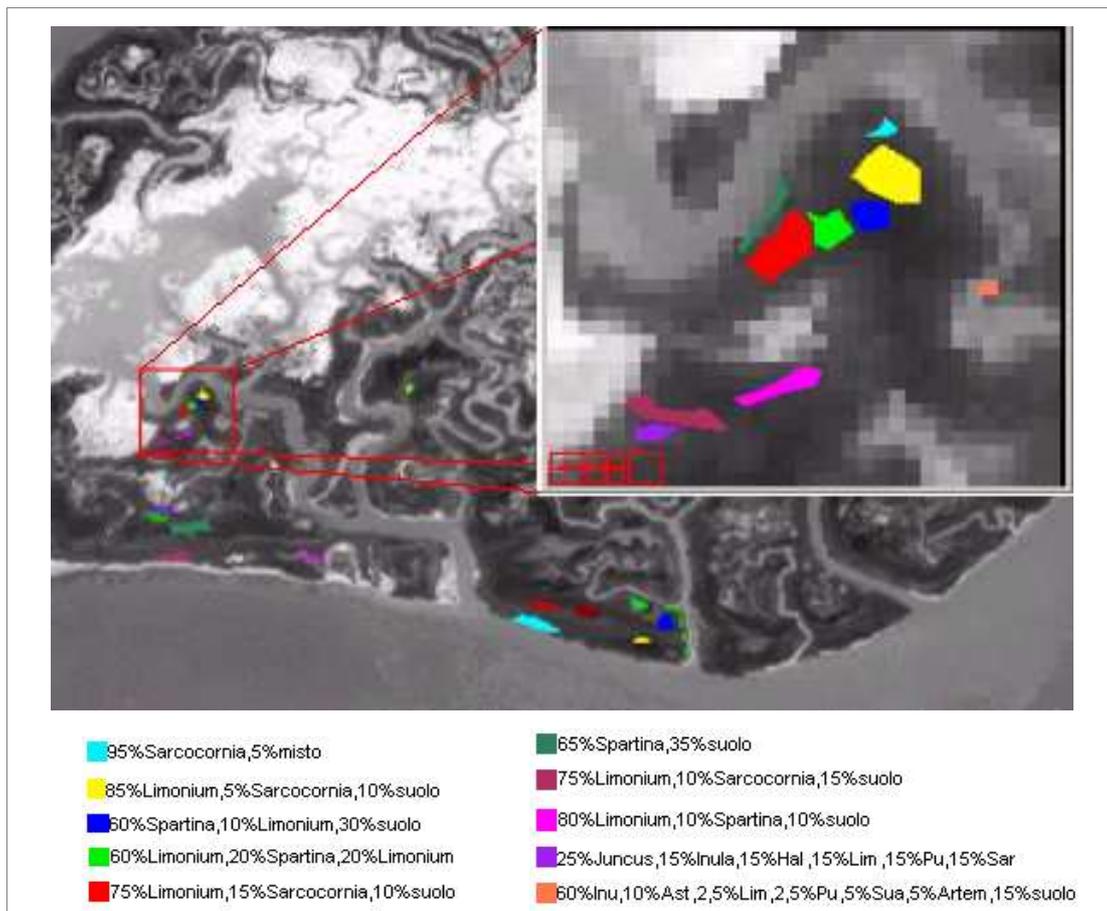
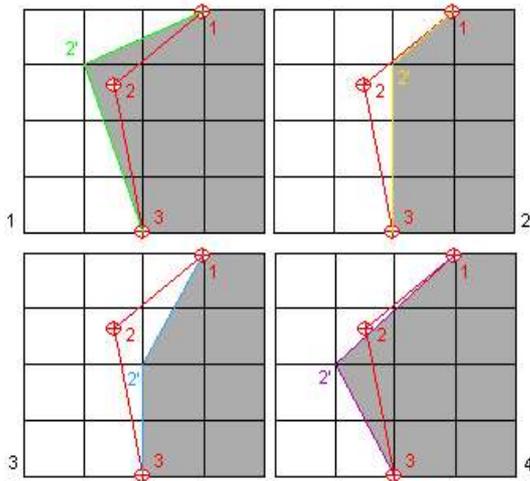


Fig.6.3 - Individuazione delle aree rilevate a San Felice sull'immagine multispettrale QuickBird (banda MSI).

Il principale problema incontrato in questa fase di elaborazione ha riguardato l'unione dei punti che definiscono le aree di vegetazione a terra per formare le ROI (*Regions Of Interest*) nell'immagine multispettrale: la congiunzione fra i GCP (*Ground Control Points*) può infatti avvenire solamente in corrispondenza dei vertici dei *pixel* (qui di lato 2,8 m), che sono le unità minime di rappresentazione della scena; come si osserva in fig.6.4, nel caso in cui le coordinate ricadano all'interno di un *pixel* (punto n°2 rosso) le superfici che si possono selezionare hanno dimensioni

molto diverse, e ciò può compromettere il grado di omogeneità dei *pixel* appartenenti ad ogni area e quindi la firma spettrale della classe individuata dalla ROI.



Il problema può essere risolto scegliendo il vertice interno all'area più vicino al vero GCP (casi 2-3) e ottenendo aree leggermente meno estese, ma a composizione più omogenea dal momento che i *pixel* di confine sono esclusi dalla ROI.

Ad ogni modo, in ENVI è presente una funzione (*Reconcile ROIs via Map*) che permette di sovrapporre ROI definite su immagini diverse a condizione che esse siano

Fig.6.4 - Modificazione dell'area delle ROI in funzione delle coordinate di vertice scelte.

state georeferenziate. Ciò ha consentito di identificare con maggior precisione le coordinate di vertice delle aree sull'immagine pancromatica, sfruttandone l'elevata risoluzione spaziale, e di ottenere poi la localizzazione delle medesime ROIs sull'immagine multispettrale utilizzata per la classificazione.

§6.3 Le tecniche di classificazione dell'immagine

Il processo di classificazione consente di identificare nell'immagine digitale i *pixel* caratterizzati da risposte spettrali molto simili e di raggrupparli in categorie che rappresentano le classi di superfici esistenti al suolo. Le tecniche di classificazione possono essere distinte in *non guidate* e *guidate*:

- la procedura non controllata, o *unsupervised*, non richiede la conoscenza degli elementi da discriminare sulla scena, ma si basa esclusivamente sui valori di radianza dei *pixel* dell'immagine, consentendo di aggregare i dati in famiglie o *cluster*. I criteri secondo cui discriminare i gruppi sono di natura statistica e vengono forniti al calcolatore come nuclei centrali con determinati attributi

spettrali, attorno a cui vengono raggruppati i *pixel* con caratteristiche simili; non è quindi necessaria alcuna informazione sulla loro corrispondenza con l'effettiva copertura del suolo;

- le tecniche controllate, o *supervised*, sfruttano invece la definizione a priori delle classi tematiche di interesse al suolo: la scelta sull'immagine di alcune aree campione rappresentative delle categorie di copertura consente di calcolare i parametri statistici relativi alle classi tematiche prescelte, in base ai valori dei *pixel* appartenenti alle aree campione.

In questo modo si ottengono gli spettri di radianza media tipici di ogni classe, con cui condurre la classificazione dell'intera scena (*training sets*), che avviene per confronto tra i *pixel* dell'immagine e le risposte spettrali delle classi di interesse secondo un criterio di somiglianza prescelto (algoritmo di classificazione).

Il risultato della procedura è in entrambi i casi un'immagine in cui i *pixel* vengono identificati, classe per classe, con toni di grigio differenti o con un colore convenzionale caratteristico per ogni categoria.

I due sistemi illustrati rispondono ad esigenze di classificazione diverse: quando è importante mettere in relazione i gruppi di *pixel* con categorie di copertura effettivamente presenti sulla scena, il metodo guidato permette di definire delle *classi informative* di estrema utilità; quando invece si devono analizzare superfici poco conosciute e scarsamente accessibili, la tecnica non guidata consente di eseguire una preliminare analisi esplorativa dell'immagine, definendo i gruppi di *pixel* in termini di *classi spettrali*, la cui relazione con le classi informative può emergere solo attraverso sopralluoghi in campo o il confronto con mappe tematiche (Mather, 1987).

Con l'aumento della risoluzione spaziale dei moderni sistemi di telerilevamento è migliorata la possibilità di discriminare tra diversi oggetti al suolo, ma è anche cresciuta la difficoltà nel riconoscimento e nell'interpretazione; infatti, con la maggior definizione aumenta anche il numero di *pixel* che rappresentano un oggetto, ed è quindi preferibile la scelta di sistemi di classificazione non più *puntuali*, che assegnano cioè ogni *pixel* ad una classe tematica in modo indipendente dai *pixel* adiacenti, ma *contestuali*, in modo che sia prevista una fase di introduzione di informazioni sulla relazione spaziale di ciascun *pixel* con quelli adiacenti (Rosselli et al., 2001).

§6.3.1 Classificazione non supervisionata: ISODATA e k-means

I due metodi di classificazione non guidata più utilizzati in remote sensing sono l'ISODATA e il k-means. Si tratta in entrambi i casi di procedure iterative: in base alla scelta di alcuni parametri iniziali definiti dall'operatore, si individuano dei cluster di confronto nei quali i vari *pixel* vengono collocati secondo un criterio di somiglianza spettrale. Ad ogni iterazione l'assegnazione dei *pixel* viene ricalcolata in base alle caratteristiche dei cluster più vicini, finché non si raggiunge un numero di ricollocazioni minore di una soglia scelta dall'operatore (es. 5%).

L'algoritmo ISODATA è simile al k-means, con l'unica differenza che il numero di cluster può variare durante l'iterazione, mentre il k-means prevede che il numero di classi sia definito a priori (Mather, 1987).

In fig.6.5 vengono riportati i risultati ottenuti da alcuni tentativi di classificazione dell'immagine QuickBird dei *target* acqua, vegetazione e suolo a San Lorenzo mediante i due algoritmi, per valutare il grado di differenza spettrale rilevabile dai due classificatori in corrispondenza dei principali elementi dell'immagine. In entrambi i casi è stata mascherata la componente "acqua" nell'immagine multispettrale¹.

Come si osserva, per valori iniziali abbastanza simili le due tecniche forniscono risultati confrontabili: in particolare, sembra che la classificazione ISODATA sottostimi la presenza di suolo nell'area sia nel multispettrale che nel pancromatico, mentre la k-means riesce a distinguere la presenza delle tre classi, nonostante l'estrazione della rete dei canali nel pancromatico non dia buoni risultati in nessuno dei due casi. Complessivamente le informazioni fornite dal sensore sono quindi sufficienti per la discriminazione delle principali caratteristiche dell'area di indagine, sebbene i tentativi di classificazione eseguiti aumentando il numero di *clusters* di partenza non consentano di ottenere risultati soddisfacenti nel riconoscimento dei diversi popolamenti vegetali.

I principali problemi che si incontrano nell'applicazione delle procedure ISODATA e k-means riguardano la scarsa riproducibilità delle classificazioni e la sensibilità dei due algoritmi alle condizioni scelte dall'operatore nella fase iniziale. Per questo motivo il riconoscimento delle aree di vegetazione di barena è avvenuto

¹ L'esclusione di una categoria di pixel dall'analisi si effettua ricorrendo all'algoritmo di classificazione supervisionata SAM che sarà illustrato in dettaglio nel paragrafo 6.3.2.

mediante l'impiego delle numerose verità a terra acquisite sull'area di studio, che hanno costituito il *training set* per le procedure di classificazione controllata.

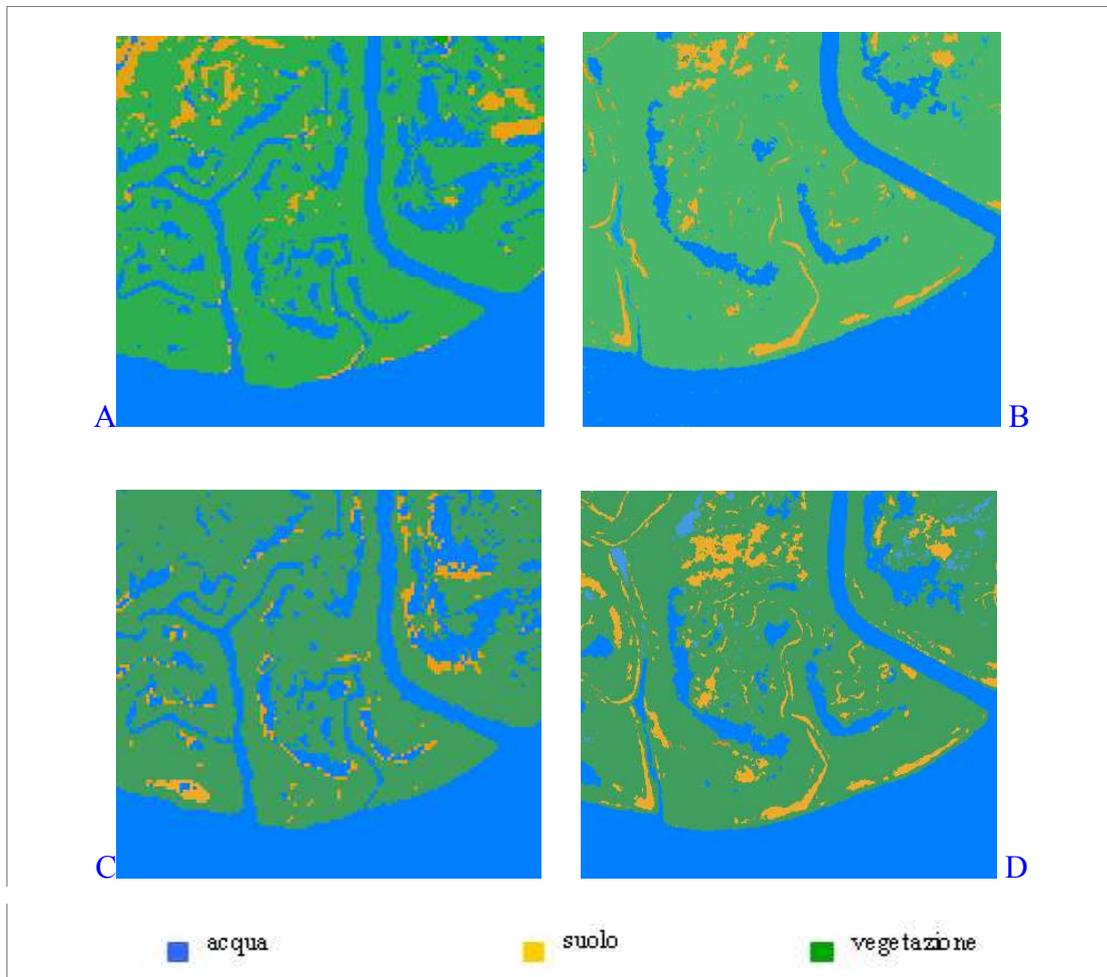


Fig.6.5 - Classificazioni ISODATA e *k-means* della porzione di immagine che comprende la barena di San Lorenzo (A: ISODATA multispettrale; 3classi; soglia 3%; B: ISODATA pancromatico; 4 classi; soglia 3%; C: *k-means* multispettrale; 4 classi; soglia 5%; D: *k-means* pancromatico; 4 classi; soglia 5%).

§6.3.2 La classificazione controllata: l'algoritmo SAM

Esistono numerosi algoritmi di classificazione guidata. Tra i principali, disponibili nel software ENVI: *Parallelepiped*, *Maximum Likelihood*, *Minimum Distance*, *Mahalanobis Distance*, *Binary Encoding*. Le diverse tecniche vengono scelte in base ai tempi di calcolo, all'accuratezza valutata in funzione dei dati di controllo disponibili per la validazione, ai costi per la raccolta delle verità a terra durante le campagne di misura.

In questo lavoro la classificazione dei popolamenti vegetali è stata effettuata applicando l'algoritmo SAM (*Spectral Angle Mapper*) (Kruse et al., 1993), che in occasione di precedenti studi condotti si è dimostrato particolarmente indicato per il riconoscimento degli elementi al suolo in aree umide (Tortato, 2001; Saccardo, 2000). In particolare il SAM ha fornito risultati molto soddisfacenti nella distinzione tra le zone vegetate di barena e quelle occupate dall'acqua.

In base al funzionamento dell'algoritmo SAM, l'operatore seleziona sull'immagine alcune regioni di interesse, o verità a terra, che vengono attribuite ai popolamenti vegetali che si vogliono identificare (*endmember*): la firma spettrale che rappresenta ogni classe è lo spettro medio calcolato sull'insieme dei *pixel* appartenenti a ciascuna ROI.

Il vettore dello spettro di riferimento così calcolato viene confrontato con lo spettro del *pixel* da classificare mediante il calcolo dell'angolo compreso tra le due curve di risposta nello spazio delle bande spettrali, e ogni *pixel* viene assegnato alla classe con cui il suo spettro forma l'angolo minore (*fig.6.6*). Il *pixel* non viene classificato se questa distanza angolare è superiore ad una soglia fissata a priori dall'operatore.

Il prodotto scalare tra due vettori ($\mathbf{s} \cdot \mathbf{p}$) è definito dalla relazione:

$$\mathbf{s} \cdot \mathbf{p} = \sum_{i=1}^n (s_i p_i) = s \cdot p \cdot \cos \alpha \quad [4]$$

dove s_i e p_i sono le componenti dei due vettori nello spazio n -dimensionale delle bande, mentre s e p sono i moduli dei vettori stessi.

Il valore dell'angolo soglia che determina l'appartenenza del *pixel* alla classe di riferimento è definito dalla seguente relazione:

$$\alpha = \arccos \left(\frac{\mathbf{s} \cdot \mathbf{p}}{s \cdot p} \right) = \arccos \left(\frac{\sum_{i=1}^n (s_i p_i)}{\sqrt{\sum_{i=1}^n s_i^2} \sqrt{\sum_{i=1}^n p_i^2}} \right) \quad [5]$$

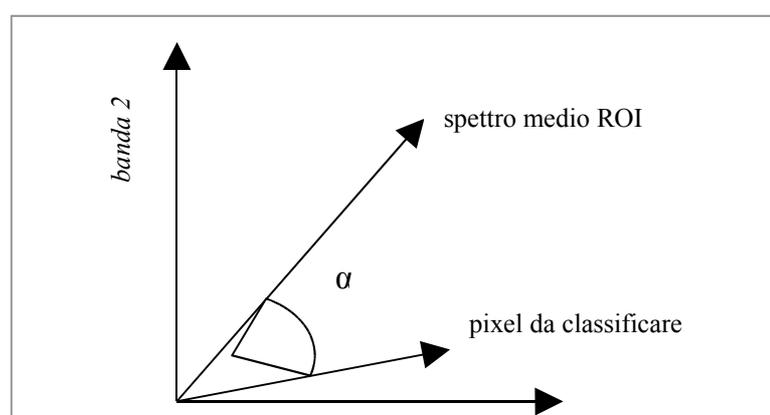


Fig.6.6 - Spazio generato da due bande spettrali: α è l'angolo che separa lo spettro di riferimento da quello del pixel da classificare.

Il vantaggio che l'uso di questo classificatore comporta risiede nell'invarianza dell'angolo di separazione fra gli spettri alle differenze di illuminazione della scena: dal momento che l'algoritmo confronta l'angolo compreso tra i vettori della classe di riferimento e del *pixel* da classificare, considerandone quindi solo la direzione e non la lunghezza, qualsiasi fattore moltiplicativo che ne modifichi il valore non influisce sulla soglia di separazione; questa caratteristica fa in modo che *pixel* appartenenti alla medesima classe ma illuminati in modo differente a causa della variabile topografia delle superfici di barena vengano considerati analoghi dal classificatore SAM (Shrestha, 2002).

L'accuratezza della mappa di vegetazione ottenuta va in seguito verificata valutando la capacità dell'algoritmo di assegnare all'esatta categoria gruppi di *pixel* di classe nota, esclusi dalla fase di calibrazione dell'immagine (*test set*).

§6.4 La selezione degli *endmember*

La scelta delle aree campione da usare come *set* di addestramento (*training set*) e *set* di verifica (*test set*) per calibrare e validare le immagini rappresenta una fase molto delicata della classificazione controllata. In particolare, i principali fattori che ne condizionano l'accuratezza possono essere così schematizzati (Foody, 2002; Muchoney e Strahler, 2002):

- **imperfetta coregistrazione delle immagini:** nel caso in cui le aree di riferimento vengano a loro volta individuate all'interno di mappe o foto telerilevate², anche di diversa risoluzione spaziale, è indispensabile che la georeferenziazione e la messa a registro delle immagini siano molto accurate, per evitare l'erronea assegnazione dei *pixel* da classificare alle categorie

² In genere, l'uso di dati acquisiti da sensori remoti come *test set* è diffuso nella validazione di mappe a bassa risoluzione che riproducono superfici estese in cui non sono possibili acquisizioni di verità a terra (Thomlinson, 1999).

riconosciute sulla scena; la selezione degli endmembers per la classificazione dell'immagine QuickBird è avvenuta mediante sopralluoghi in campo e la georeferenziazione è risultata molto buona, quindi questo fattore non è da considerarsi per ora influente, anche se diventerà importante quando si confronteranno tra loro i dati acquisiti dai diversi sensori (MIVIS, CASI e QuickBird);

- accuratezza nella **definizione degli attributi degli endmember**: i dati di riferimento usati come *training sets* sono in genere considerati una fedele rappresentazione dell'effettiva composizione della scena; in realtà le aree rilevate a terra sono a loro volta il risultato di una classificazione la cui affidabilità dipende strettamente dalla soggettività nell'interpretare le differenze fra le classi presenti al suolo (Thierry e Lowell, 2001). La stima dell'accuratezza nella classificazione si riduce quindi alla misura del suo grado di accordo con i dati rilevati a terra, più che con l'effettiva realtà (Congalton e Green, 1993). La stima delle percentuali di copertura vegetale nei siti di studio presenta in effetti una quota di soggettività, in quanto è stata effettuata da alcuni dei partecipanti alle campagne di misura mediante osservazione visiva delle aree; in realtà, per risolvere il problema, l'assegnazione definitiva delle percentuali è stata verificata mediante il confronto con le fotografie digitali acquisite su ogni area da un'altezza di 2,5m, e nelle prossime fasi dell'indagine si potranno utilizzare allo scopo anche le immagini acquisite dal pallone aerostatico, caratterizzate da una risoluzione spaziale molto elevata (da 2 a 4cm);
- la **rappresentatività** (statistica, spaziale e complessiva) delle verità a terra (Muchoney e Strahler, 2002): l'estensione delle aree campione dipende essenzialmente dal numero di variabili (bande spettrali) di cui si vogliono determinare le proprietà statistiche; Mather (1987) indica un valore di circa 30 *pixel* per ogni caratteristica da estrarre dalla classe, ma ritiene che tale dimensione minima sia valida solo in caso di indipendenza dei *pixel* dell'immagine. In realtà, *pixel* adiacenti presentano in genere caratteristiche simili (autocorrelazione spaziale), e di conseguenza, un buon *training set* dovrebbe comprendere un numero considerevole di *pixel*, di modo che le statistiche effettuate sulle classi forniscano risultati attendibili.

La rappresentatività delle verità a terra è assicurata anche dalla possibilità di definire un **disegno di campionamento**: una procedura random è indicata nell'esplorazione di aree sufficientemente vaste da garantire che tutte le classi siano adeguatamente rappresentate; nel caso delle superfici di barena, l'impraticabilità di alcune zone limita l'acquisizione delle verità a terra a determinati siti più accessibili, nei quali è possibile effettuare le misurazioni e i rilievi vegetazionali (Edwards et al., 1999).

Spesso, inoltre, il campionamento si limita alle aree più vaste ed omogenee, mentre le zone di confine o di bordo sono escluse per evitare diminuzioni nell'accuratezza della classificazione (Richards, 1996); ciò in realtà riduce la capacità del *training set* di fornire una rappresentazione completa della scena osservata e può compromettere il successo della classificazione. Durante le campagne di rilevamento TIDE sono state rilevate numerose aree di bordo, in quanto necessarie alla completa **descrizione della complessità** dell'ambiente di barena, quindi la rappresentatività delle classi di copertura al suolo può considerarsi buona;

- la corrispondenza fra la **superficie delle aree e dei pixel**: le differenze di dimensione tra le verità a terra ed i *pixel* dell'immagine possono diminuire l'accuratezza della classificazione. È necessario infatti che le aree rilevate in campo occupino una superficie confrontabile con la risoluzione geometrica dell'immagine, e che il loro grado di omogeneità garantisca la purezza della risposta spettrale di riferimento (Atkinson, 2000). Il sensore Quickbird integra il segnale di riflettanza ricevuto da una superficie di 2,8m di lato, quindi le aree di vegetazione utili per il riconoscimento sono state selezionate tra quelle di maggiori dimensioni, con l'accortezza di non compromettere l'omogeneità della copertura. Per le classificazioni si è deciso di utilizzare solo i *pixel* centrali appartenenti alle aree perimetrate in campo, per diminuire l'effetto di eventuali incertezze nella georeferenziazione e l'interferenza spettrale dei *pixel* di confine con aree adiacenti di diversa composizione;
- il grado di **separabilità degli endmember**: i classificatori risultano tanto più efficienti quanto maggiori sono le differenze tra le classi di riferimento e quanto minori sono le differenze al loro interno. La misura del grado di separabilità delle ROI consente di selezionare le aree che incrementano l'accuratezza della classificazione. Il software ENVI calcola la distanza

spettrale tra le verità a terra secondo la formula di *Jeffries-Matusita* [6] e la *Divergenza trasformata* [7]: queste due misure di distanza sembrano particolarmente indicate nell'estrazione delle caratteristiche delle immagini multispettrali (Swain e King, 1973).

La prima misura separa le classi in base alla loro firma, assumendo che siano caratterizzate da una distribuzione normale multivariata; la seconda misura la distanza statistica tra le densità di probabilità che caratterizzano la distribuzione delle classi.

La distanza di Jeffries-Matusita ha la seguente forma:

$$JM_{ij} = \sqrt{2(1 - e^{-\alpha})} \quad [6]$$

dove:

$$\alpha = \frac{1}{8}(\boldsymbol{\mu}_i - \boldsymbol{\mu}_j)^T \left(\frac{\mathbf{C}_i + \mathbf{C}_j}{2} \right)^{-1} (\boldsymbol{\mu}_i - \boldsymbol{\mu}_j) + \frac{1}{2} \ln \left[\frac{\frac{1}{2} |\mathbf{C}_i + \mathbf{C}_j|}{\sqrt{|\mathbf{C}_i| \cdot |\mathbf{C}_j|}} \right]$$

i e j indicano gli spettri da confrontare, \mathbf{C}_i è la matrice di covarianza dello spettro i , $\boldsymbol{\mu}_i$ è il vettore spettro medio i , $|\mathbf{C}_i|$ è il determinante di \mathbf{C}_i e T è la funzione trasposizione.

La Divergenza è definita invece dall'espressione:

$$TD_{ij} = 2 \left[1 - e^{\left(-\frac{D_{ij}}{8} \right)} \right] \quad [7]$$

con:

$$D_{ij} = \frac{1}{2} \text{tr} \left[(\mathbf{C}_i - \mathbf{C}_j)(\mathbf{C}_i^{-1} - \mathbf{C}_j^{-1}) \right] + \frac{1}{2} \text{tr} \left[(\mathbf{C}_i^{-1} - \mathbf{C}_j^{-1})(\boldsymbol{\mu}_i - \boldsymbol{\mu}_j)(\boldsymbol{\mu}_i - \boldsymbol{\mu}_j)^T \right]$$

dove i e j indicano gli spettri da confrontare, \mathbf{C}_i è la matrice di covarianza dello spettro i , $\boldsymbol{\mu}_i$ è il vettore spettro medio i , T è la funzione trasposizione e tr è la traccia della matrice argomento.

I valori assunti dalle due funzioni variano tra 0 e 2,0: se maggiori di 1,9 indicano buona separabilità, mentre per valori inferiori è in genere preferibile selezionare altre ROI o aggregarle in un'unica classe.

Come sarà messo in evidenza nel prossimo paragrafo, la selezione dei *set* di addestramento e di verifica per l'elaborazione dell'immagine QuickBird si è

rivelata piuttosto buona, consentendo classificazioni con elevato grado di accuratezza.

§6.5 Classificazioni dell'immagine QuickBird

Preliminarmente è stata costruita sull'immagine la maschera dell'acqua per escludere la rete dei canali e dei ghebi dalle elaborazioni successive, riducendo così il numero dei dati ed i tempi di calcolo. L'individuazione della ROI rappresentativa delle superfici d'acqua avviene nella banda dell'infrarosso vicino: la bassa riflettanza dei corpi d'acqua in tale intervallo spettrale consente infatti di distinguerli agevolmente dalle aree di vegetazione. La maschera è stata realizzata eseguendo una classificazione SAM con angolo spettrale massimo pari a 0,25 radianti e assegnando il valore 0 alla classe acqua e il valore 1 alla classe rimanente (immagine binaria).

L'applicazione della maschera consiste nella moltiplicazione dell'immagine originaria per l'immagine binaria: i *pixel* moltiplicati per 1 rimangono inalterati, mentre la moltiplicazione per 0 annulla il valore dei *pixel* corrispondenti.

La seconda fase di elaborazione è consistita nella classificazione dell'immagine sulla base di *training set* a copertura monospecifica maggiore dell'80%. L'accuratezza dei risultati è stata valutata mediante la classificazione di *test set* effettuando l'analisi della **matrice di confusione**, che confronta la classe di appartenenza osservata con la categoria di assegnazione nell'immagine classificata.

La valutazione dell'accuratezza di classificazione costituisce una fase molto delicata nella produzione di cartografia tematica ottenuta da informazioni telerilevate in quanto:

- fornisce un indice della qualità complessiva della mappa;
- effettua il confronto tra differenti algoritmi di classificazione;
- permette di identificare eventuali errori nell'elaborazione delle immagini (Hay, 1979).

Un'indagine condotta da Trodd nel 1995 ha tuttavia rivelato che su un campione di 84 classificazioni riportate in 25 articoli pubblicati sulle maggiori riviste scientifiche tra il 1994 e il 1995, l'8% dei lavori non riportava alcuna valutazione sulla qualità della classificazione; inoltre solamente il 60% dei risultati era fornito di matrice di confusione e il 44% dava due o più misure quantitative di accuratezza: in questi casi

il valore raggiunto era ad ogni modo inferiore alla soglia minima raccomandata di accuratezza dell'85% (Foody, 2002).

Tra le numerose procedure di verifica, l'uso della matrice di confusione è molto diffuso, in quanto non solo fornisce informazioni più complete della semplice stima percentuale di *pixel* correttamente classificati, ma caratterizza gli errori commessi nella procedura consentendo di migliorare la classificazione e le considerazioni che ne derivano.

Tuttavia, l'uso della matrice di confusione si basa su alcune ipotesi raramente soddisfatte dalle immagini telerilevate, tra le quali l'assunto che ogni *pixel* da classificare appartiene interamente a solo una categoria definita in un sufficientemente completo *set* di classi distinte ed esclusive (Townsend, 2000). Come sarà illustrato nel paragrafo 6.6, sistemi di classificazione *soft* sembrano poter fornire una soluzione al problema dei *pixel* misti presenti nell'immagine (Foody, 1996).

Dalla matrice di confusione derivano diverse misure di accuratezza: una delle più note è l'*overall accuracy*, A , che si ottiene per ogni categoria dividendo il numero di *pixel* correttamente classificati per il numero totale di *pixel* di quella classe:

$$A = \frac{\sum_{i=1}^r p_{ii}}{N} \quad [8]$$

dove p_{ii} sono gli elementi della diagonale della matrice, lungo cui si trovano i *pixel* classificati correttamente, i indica la classe, N è il numero complessivo di *pixel* classificati ed r rappresenta le righe della matrice (ENVI User's Guide, 2001).

Diversi autori criticano l'uso di A affermando che alcuni *pixel* possono essere assegnati casualmente alla classe corretta (Pontius, 2000) e individuano nel *coefficiente k* di Cohen l'indice standard di accuratezza della classificazione:

$$K = \frac{N \sum_{i=1}^r p_{ii} - \sum_{i=1}^r p_{iR} p_{Ci}}{N^2 - \sum_{i=1}^r p_{iR} p_{Ci}} \quad [9]$$

dove R corrisponde alle categorie a cui il classificatore assegna i *pixel* dell'immagine (righe della matrice) e C rappresenta le classi effettivamente presenti al suolo (colonne della matrice)³.

³ Il coefficiente k è utile per esprimere il grado di qualità complessivo della classificazione, in quanto rappresenta la differenza tra l'accuratezza raggiunta e quella che potrebbe essere ottenuta da una classificazione completamente casuale dell'immagine: per esempio un coefficiente k di 0,8 significa che il classificatore non ha commesso l'82% degli errori che una classificazione random avrebbe generato.

Le assegnazioni scorrette eseguite dai classificatori all'interno dell'area osservata non sono in genere casuali, ma spesso c'è una distinta distribuzione spaziale degli errori in funzione delle proprietà del sensore, delle condizioni al suolo o della presenza dei *pixel* di confine, che possono essere spazialmente autocorrelati o risentire di un'imprecisa georeferenziazione (Steele et al., 1998). Sfortunatamente la matrice di confusione non fornisce informazioni circa la distribuzione degli errori di classificazione, anche se l'impiego di tecniche geostatistiche può risultare utile nel rappresentarne la variazione spaziale.

§6.5.1 Riconoscimento di tre endmember

Con l'esecuzione delle prime classificazioni sull'immagine Quickbird si è cercato di valutare la capacità dell'algoritmo SAM di riconoscere le aree di vegetazione di barena, in modo da mettere a punto un sistema di rappresentazione della complessità della zonazione che fosse efficiente ed affidabile.

La selezione di tre endmember (acqua, suolo e vegetazione) e l'utilizzo di una soglia di separazione fra classi di tipo *multiangolo* (0,25 rad per l'acqua, 0,06 per il suolo, 0,15 per la vegetazione) ha consentito di raggiungere ottimi risultati di classificazione (con un'accuratezza complessiva A pari a 96,9% e un coefficiente k di 0,95 (fig.6.7)), com'era prevedibile date le notevoli differenze di firma spettrale dei tre *endmember* nel visibile e nel vicino infrarosso (fig.6.8). I valori riportati nella matrice di confusione indicano che la totalità dei *pixel* "suolo" è stata assegnata alla categoria corretta, mentre il 3,8% di *pixel* di vegetazione e il 4,4% dei *pixel* "acqua" sono stati classificati come suolo, probabilmente a causa di un eccessivo valore di angolo spettrale impostato nella definizione di questa categoria.



■ Suolo
■ Acqua
■ Vegetazione

A = 96,9%

k = 0,95

	Suolo	Vegetazione	Acqua	Totale
Non Classificato	0	0	0	0
Suolo	100	3,8	4,4	25,2
Vegetazione	0	96,2	0	53,5
Acqua	0	0	96,5	21,3
Totale	100	100	100	100

Fig.6.7: Classificazione SAM e matrice di confusione con la selezione di tre endmembers. Barena di San Felice.

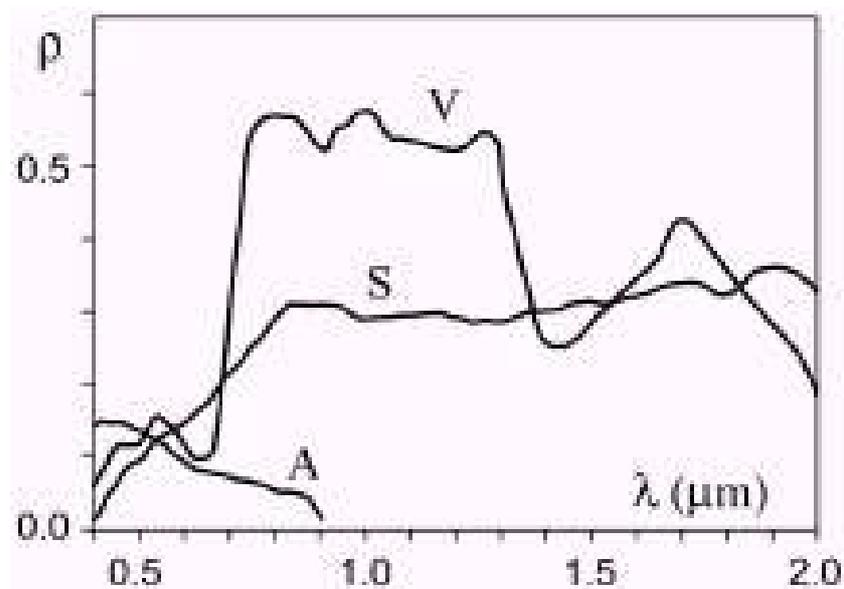


Fig.6.8: Curve spettrali di vegetazione, suolo e acqua: la diversa riflettanza delle tre categorie. Nel visibile e nel vicino infrarosso ne consente la distinzione nell'immagine multispettrale.

§6.5.2 Riconoscimento di quattro endmember



$A = 85\%$

$k = 0,8008$

	Sarcocornia	Spartina	Suolo	Limonium	Totale
Non classificato	0	0	0	2,86	0,93
Sarcocornia	78,13	0	0	11,43	27,1
Spartina	21,88	100	0	8,57	24,3
Suolo	0	0	100	2,86	23,36
Limonium	0	0	0	74,29	24,3
Totale	100	100	100	100	100

Fig.6.9: Classificazione SAM e matrice di confusione con la selezione di quattro endmember. Barena di San Felice.

In fig.6.9 sono riportati i risultati della classificazione eseguita con quattro *endmember* (suolo e aree di vegetazione a copertura omogenea maggiore dell'80%) e angolo spettrale di 15°, sull'immagine mascherata dall'acqua. L'incertezza nella classificazione delle aree test selezionate a terra in termini di accuratezza A e coefficiente k risulta aumentata (pari a 85% e 0,8 rispettivamente), ma si mantiene ancora a livelli piuttosto buoni secondo le soglie indicate da Foody (2002). L'accuratezza minore si nota nella stima di *Limonium* sp., che in buona parte viene classificato come *Sarcocornia* e *Spartina* spp., sebbene l'incertezza maggiore riguardi la categoria *Sarcocornia* sp., che viene attribuita alla classe *Spartina* sp. per il 21,8%

dei *pixel*. Suolo e *Spartina* sp. risultano invece perfettamente distinguibili dalle altre classi (accuratezza del 100%). Sembra quindi esistere una certa difficoltà nella distinzione delle aree a *Limonium* sp. da parte del sensore, che non ne discrimina nettamente la firma spettrale, confondendola con quella di *Sarcocornia* sp. Tale circostanza è probabilmente da ricondursi al periodo di acquisizione dell'immagine (metà maggio), quando ancora le piante di *Limonium narbonense* non sono fiorite e sono riconoscibili solo dalla tipica rosetta basale, e alla vicinanza spaziale che in genere caratterizza la presenza di queste due specie sulle barene. La stima della separabilità fra le classi e la loro curva spettrale media (fig.6.10 e 6.11) confermano i risultati ottenuti: sebbene la differenza tra le categorie *Limonium* e *Sarcocornia* sia molto bassa, il *training set* scelto è comunque in grado di garantire una buona classificazione anche di aree test che non sono perfettamente distinguibili tra loro, come dimostrano i bassi valori di separabilità riportati in tabella.

	Jeffries Matusita	Transf. Diverg.
Sarcocornia e Limonium	1,227	1,662
Spartina e Limonium	1,988	2,000
Sarcocornia e Spartina	1,989	1,997
Sarcocornia e suolo	2,000	2,000
Suolo e Spartina	2,000	2,000
Suolo e Limonium	2,000	2,000

Fig.6.10: Misure di distanza fra le classi e spettri medi delle ROIs –training set

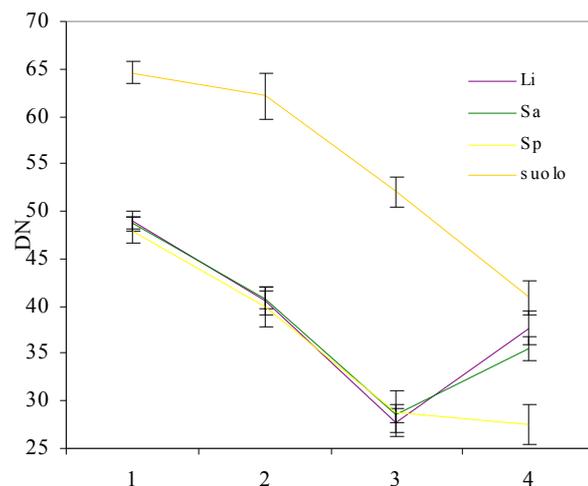
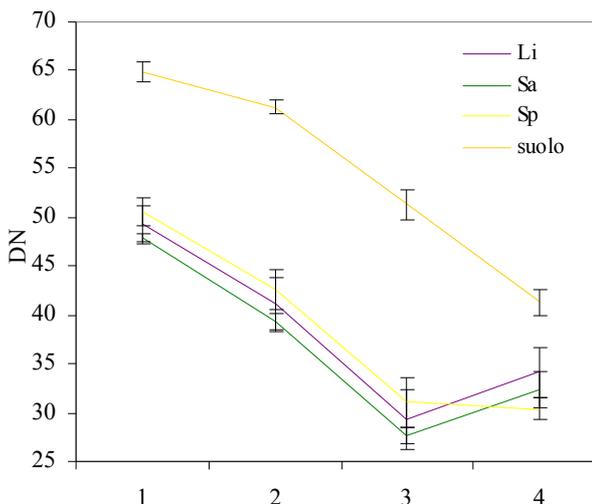


Fig.6.11: Misure di distanza fra le classi e spettri medi delle ROIs –test ses

	Jeffries Matusita	Tran Dive
Spartina e Limonium	1,266	1,77
Sarcocornia e Limonium	1,401	1,97
Sarcocornia e Spartina	1,823	1,99
Suolo e Limonium	2,000	2,00
Sarcocornia e suolo	2,000	2,00
Suolo e Spartina	2,000	2,00

§6.5.3 Riconoscimento di cinque endmember



La selezione di un quinto

endmember (*Juncus* sp.) ha leggermente diminuito la qualità della classificazione, che si abbassa all'83,7%, ma il coefficiente k non presenta sostanziali differenze rispetto al valore stimato per quattro *endmember* (0,8). Anche in questo caso le aree a *Spartina* sp. e il suolo nudo sono riconosciute molto bene dal classificatore, e ciò avviene anche per la specie *Juncus maritimus*, che compare soprattutto al confine fra le zone vegetate e il suolo emerso e lungo i bordi di alcuni ghebi e canali. Il riconoscimento di *Sarcocornia* sp. è invece meno accurato, e soggetto alle medesime incertezze riscontrate nella classificazione a quattro *endmember*; infine, le coperture di *Spartina*, *Juncus* e *Sarcocornia* spp. risultano sovrastimate a causa dell'attribuzione di *pixel* "Limonium" alle tre classi, e continua quindi ad essere l'*endmember* meno riconoscibile nell'immagine.

	Sarcocornia	Spartina	Giunco	Limonium	Suolo	Totale
Non classificato	0	0	0	3,45	0	0,85
Sarcocornia	75	0	0	13,79	0	23,93
Spartina	12,5	100	0	3,45	0	17,95
Giunco	12,5	0	100	13,79	0	20,51
Limonium	0	0	0	62,07	0	15,38
Suolo	0	0	0	3,45	100	21,37
Totale	100	100	100	100	100	100

Fig.6.12: Classificazione SAM e matrice di confusione: selezione di cinque endmember. Barena di San Felice.

La tabella di separabilità delle ROI di *training* e gli spettri medi riportati nelle

Acqua	Giunco
Spartina	Limonium
suolo	Sarcocornia

A = 83,7%

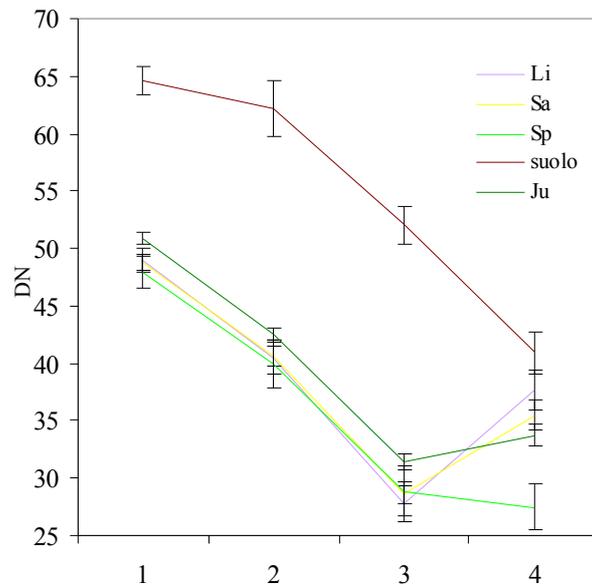
K = 0,8

figg.6.13 e 6.14 mostrano che la distinzione fra *Juncus* sp. e gli altri *endmember* è netta in tutte le bande, e in particolare nel vicino infrarosso. Nel complesso le risposte

spettrali degli *endmember* scelti a terra sembrano essere sufficientemente separate fra loro, ad eccezione delle classi “*Limonium*” e “*Sarcocornia*” che, presentando bassi valori di divergenza, non sono adeguatamente classificate nell’immagine. Anche l’assegnazione dei *pixel Limonium* alla categoria *Giunco* è dovuta alla scarsa separabilità dei due *endmember* di *training*, mentre l’incertezza nella classificazione di *Sarcocornia* sp. dipende dalla limitata divergenza spettrale tra le aree *test*.

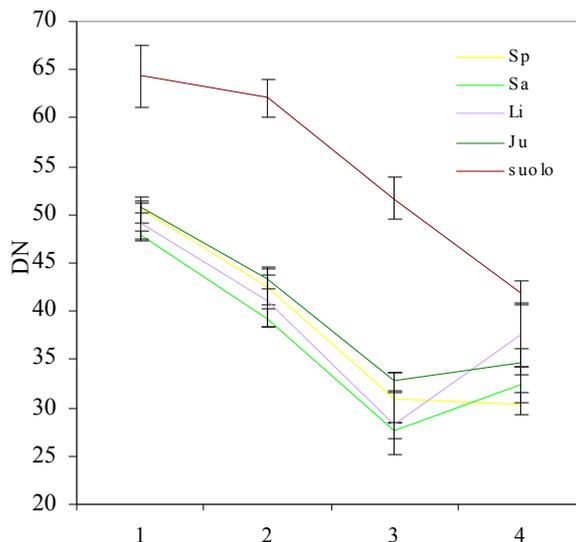
	Jeffries Matusita	Transf. Diverg.
Sarcocornia e Limonium	1,227	1,662
Giunco e Limonium	1,877	2,000
Spartina e Giunco	1,912	1,971
Sarcocornia e Giunco	1,965	2,000
Spartina e Limonium	1,988	2,000
Sarcocornia e Spartina	1,989	1,997
Sarcocornia e suolo	2,000	2,000
Suolo e Spartina	2,000	2,000
Suolo e Limonium	2,000	2,000
Suolo e Giunco	2,000	2,000

Fig.6.13: Misure di distanza fra le classi e spettri medi delle ROIs –training set

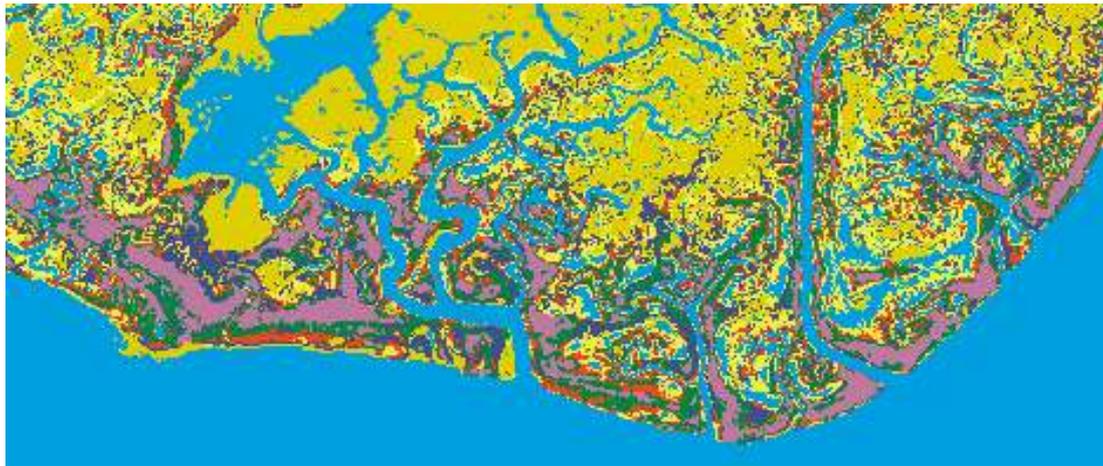


	Jeffries Matusita	Transf. Diverg.
Giunco e Limonium	1,626	2,000
Spartina e Limonium	1,659	1,995
Sarcocornia e Limonium	1,816	1,995
Sarcocornia e Spartina	1,823	1,999
Spartina e Giunco	1,866	1,983
Sarcocornia e Giunco	1,866	1,983
Suolo e Limonium	2,000	2,000
Suolo e Spartina	2,000	2,000
Sarcocornia e suolo	2,000	2,000
Suolo e Giunco	2,000	2,000

Fig.6.14: Misure di distanza fra le classi e spettri medi delle ROIs –test set



§6.5.4 Riconoscimento di sei endmember



$$A = 72,0670\%$$

$$K = 0,6504$$

	Sarcocornia	Spartina	Giunco	Suolo	Limonium	Misto Sa-Li	Totale
Non classif.	0	0	0	0	2,88	0	0,56
Sarcocornia	53,13	0	0	0	5,71	30,36	20,11
Spartina	3,13	87,5	0	0	2,86	1,79	9,5
Giunco	0	0	75	0	5,71	3,57	8,94
Suolo	0	0	0	100	2,86	0	13,97
Limonium	0	0	0	0	74,29	0	14,53
Misto Sa-Li	43,75	12,75	25	0	5,71	64,29	32,4
Totale	100	100	100	100	100	100	100

Fig.6.15: Classificazione SAM e matrice di confusione: selezione di sei endmember. Barena di San Felice.

Nella classificazione a sei endmember si è introdotta nel *set* di addestramento un'area a copertura mista (50% *Limonium* sp., 50% *Sarcocornia* sp.) in primo luogo per risolvere il problema di classificazione dei *pixel* a *Limonium*, e inoltre per valutare la capacità di discriminazione del classificatore in presenza di endmember non omogenei. La vegetazione di barena ha infatti la caratteristica di disporsi in consorzi o macchie formate da diverse specie, e solo raramente è possibile individuare in campo aree a copertura monospecifica di estensione sufficientemente ampia per la classificazione dell'immagine. L'accuratezza della procedura risulta molto inferiore a quella rilevata nei casi precedenti; dalla matrice di confusione si può osservare che i *pixel* di *Sarcocornia* e *Sarcocornia* mista a *Limonium* vengono confusi dal classificatore in percentuali piuttosto rilevanti (>30% in entrambi i casi), mentre ben

il 74% dei *pixel* Limonium viene assegnato correttamente. Le classi *Giunco* e *Spartina* mostrano in questo caso una cospicua diminuzione di accuratezza: una rilevante percentuale di *pixel* viene infatti assegnata alla nuova categoria introdotta, che come si osserva nelle *figg. 6.16* e *6.17* presenta una firma spettrale intermedia tra quella dei due endmember. La stima della separabilità tra le ROI conferma i risultati ottenuti in quanto le aree test presentano una divergenza molto bassa e il classificatore non è in grado di determinarne con precisione la classe di appartenenza.

	Jeffries Matusita	Transf.D iverg.
Sarcocornia e Limonium	1,227	1,662
Giunco e Limonium	1,877	2,000
Spartina e Giunco	1,912	1,971
Sarcocornia e Giunco	1,965	2,000
Spartina e Limonium	1,988	2,000
Sarcocornia e Spartina	1,989	1,997
Misto Sa-Li e Spartina	1,997	1,958
Misto Sa-Li e Sarcocornia	1,999	1,960
Misto Sa-Li e Giunco	1,999	1,955
Misto Sa-Li e Limonium	1,999	2,000
Suolo e Limonium	2,000	2,000
Suolo e Spartina	2,000	2,000
Sarcocornia e suolo	2,000	2,000
Suolo e Giunco	2,000	2,000
Misto Sa-Li e suolo	2,000	2,000

Fig.6.16: Misure di distanza fra le classi e spettri medi delle ROI -training set

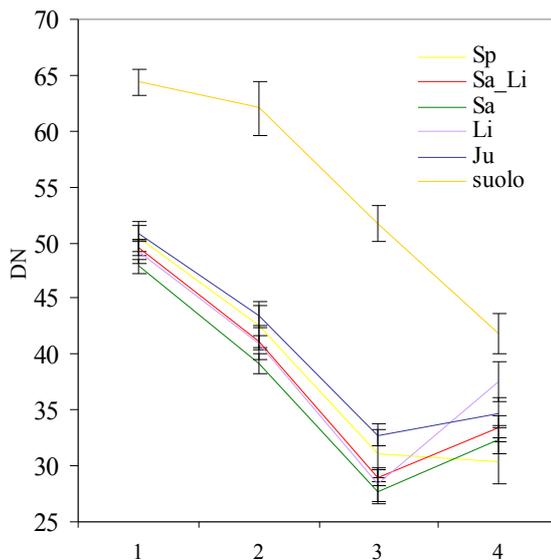
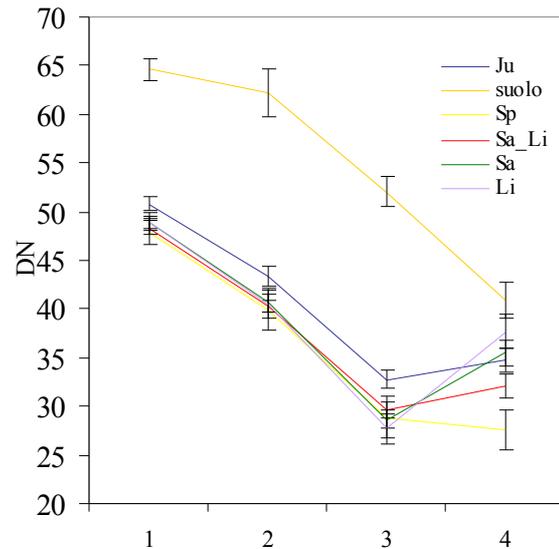


Fig.6.17: Misure di distanza fra le classi e spettri medi delle ROI -test set

	Jeffries Matusita	Transf.D iverg.
Misto Sa-Li e Sarcocornia	1,276	1,887
Misto Sa-Li e Limonium	1,277	1,805
Misto Sa-Li e Spartina	1,613	1,706
Giunco e Limonium	1,626	2,000
Spartina e Limonium	1,659	1,995
Misto Sa-Li e Giunco	1,772	1,963
Sarcocornia e Limonium	1,816	1,995
Sarcocornia e Spartina	1,823	1,999
Spartina e Giunco	1,866	1,983
Sarcocornia e Giunco	1,999	2,000
Suolo e Limonium	2,000	2,000
Suolo e Spartina	2,000	2,000
Sarcocornia e suolo	2,000	2,000
Suolo e Giunco	2,000	2,000
Misto Sa-Li e suolo	2,000	2,000

§6.6 Il problema dei *pixel* misti

Nonostante abbiano in genere fornito risultati soddisfacenti, le prime analisi dell'immagine hanno evidenziato la necessità di mettere a punto un sistema di classificazione che riesca a discriminare non solo le aree di vegetazione omogenee, per le quali gli algoritmi supervisionati tradizionali consentono di ottenere buoni risultati, ma

soprattutto le aree miste di vegetazione, corrispondenti sull'immagine a *pixel* non puri⁴. La necessità di distinguere le informazioni spettrali provenienti dal singolo *pixel* e di mantenerle nelle proporzioni dei singoli componenti diventa tanto più importante se si considera che in ogni area omogenea i popolamenti sono composti da più specie vegetali, la cui presenza e abbondanza possono variare da punto a punto.

Recenti studi sul riconoscimento della vegetazione di barena (Silvestri, 2000; Tassarollo, 2002) hanno dimostrato l'efficacia di modelli lineari come l'*Unmixing* per la stima delle componenti all'interno dei *pixel*; tuttavia, il modello si dimostra applicabile solo nel caso in cui il numero di *endmember* sia inferiore o uguale al numero di bande dell'immagine e la loro natura sia nota. Data la notevole complessità della composizione vegetale che si intende studiare, le quattro bande QuickBird a disposizione non consentono l'applicazione del modello, e per questo motivo si stanno sperimentando metodi alternativi di analisi lineare. In particolare, la tecnica di *Matched Filtering*, implementata in ENVI, sembra essere maggiormente adeguata allo scopo, corrispondendo ad un *Unmixing* parziale in cui non è richiesta la conoscenza di tutti gli *endmember* della scena.

Un'altra procedura di classificazione che sta diventando di largo uso negli ultimi anni si basa sulla teoria dei *Fuzzy Sets*: in questa rappresentazione, i *pixel* sono definiti come elementi a cui è permessa l'appartenenza parziale a più categorie contemporaneamente, e rappresenta quindi un valido strumento matematico per la rappresentazione di grandezze continue, come l'abbondanza di copertura vegetale, per

⁴ Le classificazioni soft si contrappongono alle classificazioni rigide, che utilizzano informazioni derivate da mediazioni di valori e determinano l'appartenenza di ogni *pixel* ad un'esclusiva categoria (Lechi, 1998).

le quali l'imposizione di classi discrete ed esclusive non è soddisfacente (Gomasca, 1997; Townsend, 2000).

Fra i metodi non lineari, si è intrapreso lo studio di reti neurali⁵, con cui ci si attende di poter migliorare i risultati, in quanto rappresentano una tecnica veloce, indipendente dalla conoscenza a priori della distribuzione statistica dei dati e robusta agli errori. L'applicazione del metodo alle immagini acquisite è ad ogni modo ancora nella fase iniziale di progettazione dell'architettura neurale.

⁵ Le reti sono costituite da insiemi di unità elementari (neuroni), totalmente o parzialmente interconnessi. L'architettura delle reti dipende dal tipo di modello considerato e varia a seconda del problema applicativo analizzato.