

5. ABBONDANZA DELLE SPECIE ALOFILE DA DATI IPERSPETTRALI

Esistono principalmente tre approcci che permettono di riconoscere le varie tipologie di vegetazione e la loro abbondanza a partire da dati remoti: a) il primo utilizza indici di vegetazione; b) il secondo classifica i pixel come elementi di mappe tematiche; c) il terzo usa tecniche di analisi spettrale mista (*unmixing*).

Gli indici di vegetazione e le tradizionali tecniche di classificazione sono stati principalmente utilizzati per tracciare le mappe della vegetazione in aree agricole o forestali, dove la scena è dominata da un'unica tipologia di copertura o dove sono presenti delle regioni ben distinte caratterizzate da una copertura relativamente omogenea.

In ogni caso, tali procedure sono uno strumento imperfetto per lo studio della vegetazione di barena e principalmente per due motivi:

- esiste un'elevata variabilità spaziale della copertura vegetale: l'estensione areale di una popolazione "omogenea" può variare da qualche decimetro ad una decina di m² al massimo;
- popolazioni vegetali caratterizzate dalla stessa tipologia di specie presentano un'elevata variabilità nella loro composizione in termini di copertura percentuale, dando di conseguenza una diversa risposta spettrale.

Nel nostro caso quindi, la radiazione riflessa da un pixel, difficilmente potrà essere attribuita ad un'area omogenea ma il valore di radianza misurato dal sensore per ciascuna unità a terra (alla quota di volo utilizzata a Venezia la risoluzione spaziale MIVIS era di 3m×3m), risulterà dalla combinazione delle firme spettrali delle specie vegetali presenti nel pixel. Il problema principale quindi consiste nello stimare le proporzioni delle diverse componenti dei pixel "misti".

In questo senso, le tecniche di *unmixing* sono lo strumento più promettente rispetto ai metodi di classificazione basati sul criterio di associare un pixel ad una classe e rispetto a quelli basati sugli indici di vegetazione.

5.1 Indici di vegetazione

Gli indici di vegetazione misurano la biomassa presente in un pixel sfruttando la marcata differenza tra la bassa riflettanza della vegetazione nel visibile, ed in particolare nel rosso e nel blu, e l'alta risposta nel vicino infrarosso (bande spettrali di assorbimento e riflessione tipiche della vegetazione). In modo sintetico gli indici possono essere suddivisi in tre categorie (Eastwood et al., 1997; Gomasca, 1997):

- indici intrinseci, come il semplice rapporto tra bande e l'NDVI (*Normalised Difference Vegetation Index*), basati solo sulla riflettanza spettrale misurata, i quali però sono altamente sensibili alla naturale variazione di riflettanza del suolo ed alla visibilità atmosferica;
- indici che introducono l'uso di parametri legati al suolo, come il PVI (*Perpendicular Vegetation Index*), il SAVI (*Soil Adjusted Vegetation Index*) ed il suo derivato MSAVI (*Modified Soil Adjusted Vegetation Index*);
- indici con correzioni atmosferiche, come l'ARVI (*Atmospherically Resistant Vegetation Index*) e il più complesso GEMI (*Global Environmental Monitoring Index*) il quale riduce simultaneamente la sensibilità alla visibilità atmosferica e alla riflettanza del suolo e massimizza la sensibilità alla copertura vegetale.

In generale gli indici di vegetazione non permettono di inferire in modo quantitativo l'abbondanza di ciascuna specie presente al suolo (obiettivo del presente lavoro), ma forniscono comunque una prima e importante indicazione sulla distribuzione spaziale della vegetazione e sulla sua densità. Una prima analisi dei dati è stata quindi condotta calcolando l'NDVI (uno degli indici più utilizzati) sull'immagine relativa alla barena S.Lorenzo.

Il valore dell'NDVI è definito come:

$$\text{NDVI} = \frac{\rho_{\text{IR}} - \rho_{\text{R}}}{\rho_{\text{IR}} + \rho_{\text{R}}} \quad (5.1)$$

dove ρ_{IR} è la riflettanza nell'infrarosso vicino e ρ_{R} è la riflettanza nel rosso. Questa funzione varia nell'intervallo tra -1 e $+1$ e assume valori tanto maggiori quanto più densa è la copertura vegetale.

Nel caso attuale, l'NDVI è stato calcolato utilizzando le riflettanza nelle seguenti bande: rosso (banda MIVIS n°12 tra 0,65 e 0,672 μm), infrarosso vicino (banda MIVIS n°18 tra 0,772 e 0,792 μm).

Il risultato è un'immagine in scala di grigi in cui i pixel più chiari rappresentano i maggiori valori di NDVI. Mediante una tecnica (*Density slicing*) che consente di suddividere la scala continua dei toni di grigio in intervalli e di assegnare a ciascuno di essi un particolare colore, è stato possibile visualizzare l'immagine in modo che fosse più facile per l'occhio separare zone caratterizzate da diversa densità vegetativa (*Fig.5.1*).

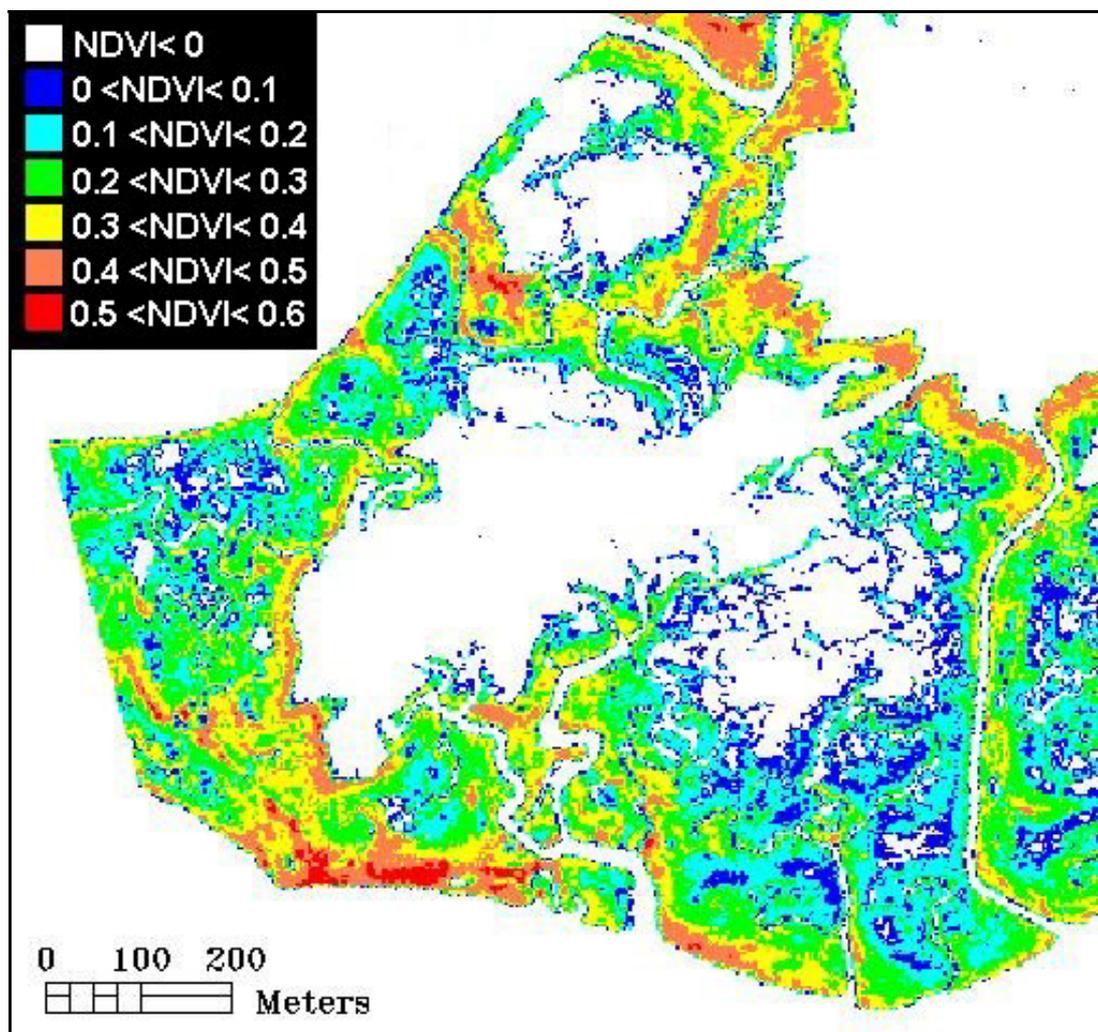


Fig.5.1 – NDVI calcolato sui dati MIVIS relativi alla barena S.Lorenzo.

Come si può notare la densità di vegetazione risulta maggiore lungo i bordi dei canali e dei ghebi (classi rossa, arancione e gialla) e diminuisce procedendo verso le zone più interne della barena. I valori negativi di NDVI sono raffigurati con il colore bianco e rappresentano le

superfici d'acqua dei canali, dei ghebi e dei chiari. L'acqua, infatti, assorbe tutta l'energia incidente nel vicino e medio infrarosso ($\rho_{IR} - \rho_R < 0$) e questo caratterizza in modo univoco la sua risposta spettrale rispetto ad altri elementi, ed in particolare suolo e vegetazione.

5.2 Classificazione “rigida”

La classificazione permette di individuare nell'immagine digitale le classi di superfici esistenti al suolo. Le tecniche tradizionali utilizzano degli algoritmi che definiscono in modo molto rigido la classe di appartenenza del pixel nell'immagine: ciascun pixel è assegnato in modo esclusivo ed inequivocabile ad un'unica categoria. Per questo si parla di classificazione “rigida” o *hard classification*.

Le tecniche tradizionali di classificazione sono divise in due categorie: senza controlli (*unsupervised*) e con controlli a terra (*supervised*), a seconda che il metodo preveda o meno una fase preliminare in cui è richiesto l'intervento umano di indirizzo.

- Classificazione non controllata

Si tratta di una classificazione che prescinde dalla conoscenza di aree campione del suolo in esame. In generale si tratta di analizzare lo spazio dei dati in modo da raggrupparli in famiglie (*cluster*). L'assegnazione ad un *cluster* è regolata da una legge (diversa, a seconda dell'algoritmo utilizzato) che sfrutta unicamente i valori di radianza dei vari pixel. Ogni *cluster* sarà quindi caratterizzato dall'essere formato da pixel spettralmente simili e pertanto, molto probabilmente, appartenenti ad un'unica classe.

L'impiego della tecnica *unsupervised* è particolarmente utile quando si devono analizzare superfici poco conosciute e difficilmente accessibili ma può risultare appropriata anche per eseguire un'analisi esplorativa dell'immagine.

- Classificazione controllata

Questa classificazione si basa sulla conoscenza al suolo di alcune aree campione rappresentative delle classi di superfici della futura mappa tematica, note e ben localizzate sulle immagini. La procedura consiste in più fasi:

1. si definiscono le classi tematiche;

2. si localizzano sulle immagini da classificare le aree campione (ROI, *Region Of Interest*) per ogni classe da distinguere;
3. si scelgono fra tutte le bande disponibili quelle meno correlate fra loro, relativamente alle classi tematiche prescelte;
4. si determinano i parametri statistici (media, covarianza, minimi e massimi) delle classi tematiche prescelte, calcolandoli in base ai valori dei pixel appartenenti alle aree campione, in modo da ottenere dei valori tipici di radianza per ogni classe, relativamente ad ogni banda prescelta;
5. si sceglie infine l'algoritmo di classificazione che consente di stabilire il criterio di assegnazione di ogni singolo pixel ad una determinata classe. I classificatori più utilizzati e conosciuti sono: l'algoritmo della minima distanza spettrale (*Minimum Distance*), quello del parallelepipedo iperspettrale (*Parallelepiped*), quello della massima verosimiglianza (*Maximum Likelihood*) e dell'angolo spettrale (*Spectral Angle Mapper*);
6. il risultato è una matrice delle stesse dimensioni di quella di partenza, ed i nuovi pixel vengono descritti, classe per classe, o con un tono di grigio o con un colore, diverso per ogni classe.

Nel presente lavoro, per quanto detto in precedenza, non si è fatto uso di questi classificatori per lo studio della vegetazione ma si è deciso di utilizzare uno di essi per distinguere le zone vegetate di barena da quelle occupate dall'acqua (canali, ghebi, chiari e laghi). A tal fine è stato adottato un algoritmo di classificazione (*supervised*) denominato SAM (*Spectral Angle Mapper*) che, tra i metodi classici, sembra quello che restituisce i risultati migliori in aree umide (Saccardo, 2000).

Il principio di funzionamento di tale tecnica, è molto semplice. Si consideri ad esempio di dover classificare un'immagine mediante l'utilizzo delle informazioni spettrali contenute solo in due bande. Ogni pixel dell'immagine potrà essere rappresentato come un punto in un diagramma cartesiano, in cui gli assi esprimono i valori di radianza per ogni banda; le coordinate del punto caratterizzano il pixel nello spazio delle bande.

Il SAM prende in considerazione gli spettri medi di ogni ROI (*Region Of Interest*) (ciascuna ROI comprende un piccolo numero di pixel il cui spettro medio rappresenta lo spettro di riferimento per una data categoria al suolo) e calcola il vettore corrispondente nello spazio delle bande. Il SAM calcola l'angolo spettrale del pixel da classificare rispetto ai vettori

rappresentativi delle ROI scelte, per poi attribuire il pixel alla ROI con cui esso forma l'angolo spettrale minore. Il pixel rimarrà non classificato se questa distanza angolare è superiore ad una soglia fissata a priori dall'operatore. In Fig.5.2 è possibile visualizzare l'angolo in questione nel caso di due bande spettrali. Nel caso di n bande, i vettori sono n -dimensionali.

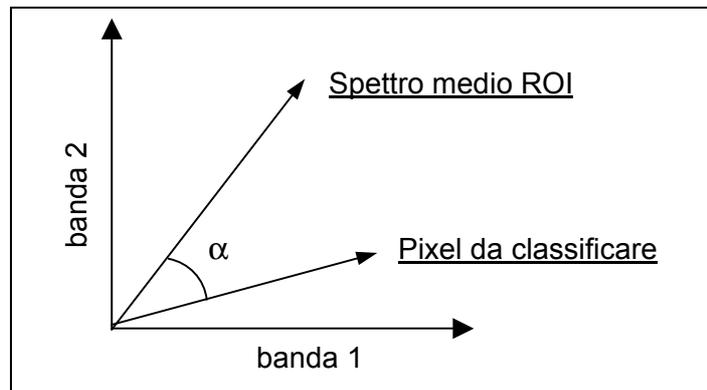


Fig.5.2 – Spazio generato da due bande spettrali. α è l'angolo spettrale tra lo spettro medio di una ROI e quello del pixel da classificare.

Il prodotto scalare tra due vettori ($\mathbf{u} \cdot \mathbf{v}$) è definito come:

$$\mathbf{u} \cdot \mathbf{v} = \sum_{i=1}^n (u_i v_i) = uv \cdot \cos \alpha \quad (5.2)$$

dove u_i e v_i sono le componenti dei due vettori nell'iperspazio delle bande, mentre u e v sono i moduli dei vettori stessi e n è il numero di bande. Dalla (5.2) si arriva facilmente al valore dell'angolo α ricercato:

$$\alpha = \arccos \frac{\mathbf{u} \cdot \mathbf{v}}{u \cdot v} = \arccos \left(\frac{\sum_{i=1}^n (u_i v_i)}{\sqrt{\sum_{i=1}^n u_i^2} \sqrt{\sum_{i=1}^n v_i^2}} \right) \quad (5.3)$$

L'individuazione della ROI rappresentativa delle superfici d'acqua, è stata facilitata visualizzando l'immagine nella banda dell'infrarosso vicino: la riflettanza dei corpi d'acqua in corrispondenza di tale intervallo spettrale è molto bassa a differenza dei valori assunti dalle aree

vegetate. La soglia massima fissata per l'angolo spettrale è stata di 35° (Saccardo, 2000). Le superfici d'acqua classificate sono state successivamente mascherate (escluse). La maschera (immagine binaria) è stata definita sull'immagine classificata, assegnando il valore zero alla classe acqua e il valore uno alla classe rimanente. La maschera così ottenuta è stata applicata all'immagine originale. Applicare una maschera significa moltiplicare pixel per pixel l'immagine di partenza per l'immagine binaria: i pixel moltiplicati per uno rimangono inalterati mentre la moltiplicazione per zero manda i pixel corrispondenti a zero (Fig.5.4).

Questo procedimento, esclude dalle successive elaborazioni i pixel che non appartengono alla vegetazione da esaminare, riducendo così la dimensione spaziale dei dati e di conseguenza i tempi di calcolo.

5.3 Linear Mixture Model

In quest'ultimo decennio grazie anche all'esperienza acquisita nel settore e alle nuove possibilità offerte dalla tecnologia, si stanno sviluppando diverse procedure, che hanno la capacità di non “mescolare” le informazioni spettrali provenienti dal singolo pixel ma di mantenerle nelle proporzioni dei singoli componenti. In questo caso si parla di *soft classification*. Questo tipo di approccio consente una maggiore accuratezza, ma soprattutto permette di lavorare sulle informazioni tal quali e non più su informazioni derivate da mediazioni di valori come nelle classificazioni “rigide” (Lechi, 1998).

Nel presente lavoro si è fatto uso di un modello chiamato *Linear Mixture Model* (LMM). L'assunzione fisica che sta alla base di questo modello è che all'interno del pixel siano trascurabili effetti di *scattering* multiplo. Si assume cioè che ciascun fotone in arrivo al sensore abbia interagito con il bersaglio solo una volta. Allora la totalità dei fotoni riflessi da un singolo pixel, può essere descritta in termini di un semplice modello lineare in cui la riflettanza misurata dal sensore è data dalla combinazione lineare degli spettri di ciascuna componente, pesata per la sua abbondanza relativa.

Nella maggioranza dei casi la distribuzione spaziale delle componenti al suolo, è tale da produrre una risposta non lineare. Tuttavia, in molte applicazioni, si è visto che l'approccio lineare ha un'accuratezza sufficiente per stabilire l'abbondanza della vegetazione (Bajjouk et al., 1998; Smith et al., 1990).

Il *Linear Mixture Model* ha la forma seguente:

$$r_i = \sum_{j=1}^n (a_{ij} \cdot f_j) + e_i \quad \text{e} \quad \sum f_j = 1 \quad \text{con } i = 1, 2, \dots, m \quad (5.4)$$

dove:

r_i = riflettanza del pixel misurata dal sensore nella banda i -esima,
 n = numero delle componenti (*endmembers*) presenti all'interno del pixel;
 a_{ij} = riflettanza dell'*endmember* j -esimo nella banda i -esima;
 f_j = frazione di copertura dell'*endmember* j -esimo;
 m = numero di bande spettrali;
 e_i = errore per la banda spettrale i -esima (differenza tra la riflettanza r_i osservata e quella calcolata dal modello).

cosicché se si indica con \mathbf{A} la matrice (a_{ij}) e con \mathbf{f} , \mathbf{r} ed \mathbf{e} i vettori $\{f_j\}$, $\{r_i\}$, $\{e_i\}$, si ottiene la forma vettoriale:

$$\mathbf{r} = \mathbf{A} \cdot \mathbf{f} + \mathbf{e} \quad (5.5)$$

La soluzione del problema consiste nel ricercare i valori di abbondanza $\{f_j\}$, che minimizzano il modulo di \mathbf{e} . La soluzione è unica solo quando gli *endmembers* selezionati sono distinguibili ed il loro numero è uguale o minore del numero di bande utilizzate ($n \leq m$).

Solo allora la soluzione esiste, infatti:

1. se $m < n$ il numero di incognite f_j , è maggiore del numero di equazioni ed il sistema è "indeterminato";
2. se $m = n$ e la matrice \mathbf{A} è invertibile, il sistema è "determinato" ed ha una e una sola soluzione.
3. se $m > n$, il sistema è "sovradeterminato" ed il calcolo dei coefficienti f_j si ottiene minimizzando la somma dei quadrati degli errori mediante il calcolo della matrice "pseudoinversa" di \mathbf{A} .

Le colonne della matrice \mathbf{A} , contengono i valori di riflettanza degli *endmembers* e, quando sono correlate, la matrice diventa singolare. Maggiore è il grado di interdipendenza delle colonne (e cioè delle firme spettrali dei diversi *endmembers*) e più probabile è che l'errore introdotto nei calcoli sia grande. Questo accade più facilmente quando il numero di bande è limitato, come nel caso di dati multispettrali, mentre è meno frequente con dati iperspettrali come quelli MIVIS. Naturalmente, problemi analoghi si hanno anche quando una colonna di \mathbf{A} è

la combinazione lineare di altre colonne perché anche allora la matrice è singolare, e non è invertibile.

Esistono due tipologie di *unmixing*: condizionato (*constrained*) e non (*unconstrained*) (Metternicht et Fermont, 1998; Mather, 1999).

L'algoritmo incondizionato permette alle abbondanze (f_j) di ciascun elemento nell'immagine di assumere qualsiasi valore, inclusi i valori negativi indipendentemente dal fatto che essi siano privi di significato fisico.

Nella versione condizionata l'algoritmo utilizzato introduce il vincolo che il valore di f_j sia compreso nell'intervallo [0-1].

In generale si preferisce utilizzare, come in questo lavoro, l'algoritmo incondizionato poiché l'imposizione dei vincoli appena descritti, può condurre a risultati errati (Elmore et al., 2000). Un LMM corretto dovrebbe, infatti, restituire valori di abbondanza (f_j) compresi tra zero e uno, senza imporre alcun vincolo e, lasciando alle f_j la possibilità di assumere qualsiasi valore, si ottengono delle informazioni sull'accuratezza del risultato e quindi sulla validità della selezione degli endmembers.

A differenza delle tecniche standard di classificazione, il metodo del LMM produce tante immagini quante sono le componenti selezionate, e ogni pixel di tali immagini, dette mappe delle proporzioni (*fraction maps*), rappresenta la percentuale di superficie occupata da ciascuna categoria all'interno del pixel stesso. Inoltre viene prodotta un'immagine dell'errore quadratico medio (*RMS image*).

L'RMS viene calcolato come radice quadrata della somma dei quadrati di tutti gli errori residui per un dato pixel, diviso per il numero di bande spettrali:

$$RMS = \sqrt{\frac{\sum_{i=1}^m e_i^2}{m}} \quad (5.6)$$

L'errore RMS è calcolato per tutti i pixel dell'immagine ed è riscalato nell'intervallo 0-255 al fine di creare un'immagine dell'errore. Quest'ultimo indica quanto la variabilità spettrale è spiegata dagli *endmembers* selezionati ed è quindi utilizzato per valutare l'accuratezza con cui sono state determinate le abbondanze delle varie componenti.

In generale il risultato dell'*unmixing* è considerato valido quando i valori di abbondanza all'interno dell'immagine sono per la maggior parte compresi nell'intervallo (0-1), l'errore

medio è basso e l'immagine dell'errore mostra una bassa correlazione spaziale degli errori.

Il risultato del LMM può essere affetto da errori più o meno importanti per i seguenti motivi (Mather, 1999):

- i pixel che rappresentano le componenti possono essere stati scelti in modo poco accurato. Essi dovrebbero essere “puri”, composti cioè dalle singole tipologie di copertura, che determinano le caratteristiche di tutti gli altri pixel dell'immagine. Si può pensare ad una situazione in cui la selezione degli *endmembers* è molto semplice, per esempio un terreno pianeggiante composto da una densa foresta, da suolo nudo e da uno specchio profondo di acqua dolce. Queste tre componenti possono essere pensate come i vertici di un triangolo all'interno del quale cadono tutti i pixel dell'immagine. Se il pixel che rappresenta la foresta è scelto malamente, e quindi in realtà rappresenta un'area in cui solo l'80% è occupata da foresta, allora ogni pixel con una copertura a foresta maggiore dell'80% avrà un valore maggiore di uno.
- delle componenti possono essere state omesse. Il problema si presenta quando il paesaggio è complesso.
- l'assunzione che ciascun fotone raccolto dal sensore abbia interagito con un solo oggetto sulla terra, può non essere soddisfatta ed in questo caso sarebbe necessario applicare un modello non lineare.

Questi inconvenienti possono essere eliminati o ridotti sia riducendo l'area d'interesse in modo da considerare solo le superfici rappresentate dagli *endmembers*, o evitando l'inserimento di *endmembers* non presenti nella scena o modificando la scelta degli stessi (Metternicht et Fermont, 1998; Elmore et al., 2000).

5.4 Applicazione del *Linear Mixture Model* ai dati MIVIS

Una delle fasi più delicate e più importanti affinché l'*unmixing* possa avere successo, è la selezione appropriata degli *endmembers*. Essi devono descrivere un set coerente di spettri rappresentativi delle componenti al suolo, ma devono anche rappresentare la variabilità spettrale della scena.

Esistono diverse procedure per selezionare gli *endmembers* (Metternicht et Fermont, 1998; Elmore et al., 2000; McGwire et al., 2000):

- direttamente dall'immagine;
- attraverso misure radiometriche a terra;
- mediante la consultazione di librerie spettrali di pubblico dominio.

Purtroppo nel caso della vegetazione alofila non esistono librerie spettrali. Per questo, in concomitanza al volo MIVIS del 1998, sono state effettuate delle misure in campo con un radiometro portatile allo scopo di raccogliere le firme spettrali delle comunità vegetali più caratteristiche dell'ambiente di barena. Dapprima si è utilizzato il valore medio degli spettri misurati a terra per ciascuna comunità vegetale monospecifica, come *endmembers* per l'applicazione del LMM e ci si è resi conto, dall'analisi delle immagini e della relativa statistica, che l'applicazione aveva restituito dei risultati scadenti soprattutto perché gli spettri presi a terra contenevano componenti non visibili al MIVIS a causa della diversa risoluzione delle immagini.

Si è quindi deciso di selezionare gli *endmembers* direttamente dall'immagine utilizzando una procedura che in altri casi (Kruse et al., 1997; McGwire et al., 2000) ha fornito dei buoni risultati.

La procedura è articolata in tre fasi (ENVI Tutorials et ENVI User's Guide, 1997):

- compressione spettrale dei dati e riduzione del rumore mediante una trasformazione denominata *Maximum Noise Fraction* (MNF);
- individuazione dei pixel spettralmente "puri" mediante una funzione denominata *Pixel Purity Index* (PPI);
- definizione degli *endmembers* attraverso un metodo geometrico (*n-Dimensional Visualization*).

Purtroppo il metodo non ha permesso l'effettiva individuazione degli *endmembers* e la selezione delle varie componenti è avvenuta per riconoscimento diretto. Per facilitare l'operazione, l'immagine è stata visualizzata considerando sempre la combinazione di bande diverse, al fine di enfatizzare le differenze tra le varie tipologie di piante e si è fatto riferimento ai rilievi in campo eseguiti in barena S.Lorenzo.

Poiché la percentuale di riuscita del *Linear Mixture Model* aumenta al diminuire della correlazione tra bande (Bajjouk et al., 1998), si è applicato il LMM al nuovo set di dati trasformato mediante la MNF.

Le immagini telerilevate multispettrali, e soprattutto quelle iperspettrali, presentano un elevato grado di correlazione tra bande, e ciò dipende dalla natura fisica degli oggetti osservati, dalla larghezza della banda e dal rumore presente nei dati (Lechi, 1998). Anche le venti bande MIVIS sono risultate altamente correlate presentando un indice di correlazione costantemente

maggiore di 0.7. Questo problema può essere superato costruendo bande sintetiche meno correlate di quelle originali. Al fine di ridurre la dimensione spettrale dei dati è stata utilizzata la MNF (Green et al., 1988) che ridistribuisce l'informazione contenuta nei dati nelle nuove componenti in modo che sia riunita per la maggior parte nelle prime (dove il rapporto segnale/rumore è maggiore) ed in quantità sempre minore mano a mano che si passa alle componenti successive.

In altri termini si assume che la riflettanza r_i di un pixel ($i = 1, \dots, m$; $m =$ numero delle bande), sia la somma di un segnale s_i e di un rumore n_i non correlati tra loro, relazione che in forma vettoriale si può scrivere:

$$\mathbf{r} = \mathbf{s} + \mathbf{n} \quad (5.7)$$

Si definisce la “frazione di rumore” della i -esima banda del pixel considerato, come il rapporto tra la varianza del rumore e la varianza totale per quella banda:

$$\text{Var} \{n_i\} / \text{Var} \{r_i\}$$

L'MNF sceglie una trasformazione lineare del tipo:

$$\mathbf{y} = \mathbf{M} \cdot \mathbf{r} \quad (5.9)$$

che massimizzare la frazione di rumore per y_i (con $i = 1, \dots, m$). Green et al. (1988) hanno mostrato che gli autovalori μ_i della matrice \mathbf{M} sono uguali alla “frazione di rumore” di y_i e, quindi, ordinando gli autovalori in modo che $\mu_1 \geq \mu_2 \geq \dots \geq \mu_m$, si ottiene che la qualità delle immagini aumenta passando dalla prima all'ultima banda, ovvero invertendo l'ordine delle immagini, si ha una diminuzione di qualità dell'immagine all'aumentare dell'ordine della componente.

Il nuovo set di dati MIVIS trasformato (in un nuovo spazio a 20 componenti) ha il vantaggio di presentare una bassissima correlazione tra le componenti. Un esempio è riportato in Fig.5.3 dove viene mostrata la correlazione tra le bande 3 e 7 prima e dopo aver effettuato la trasformazione.

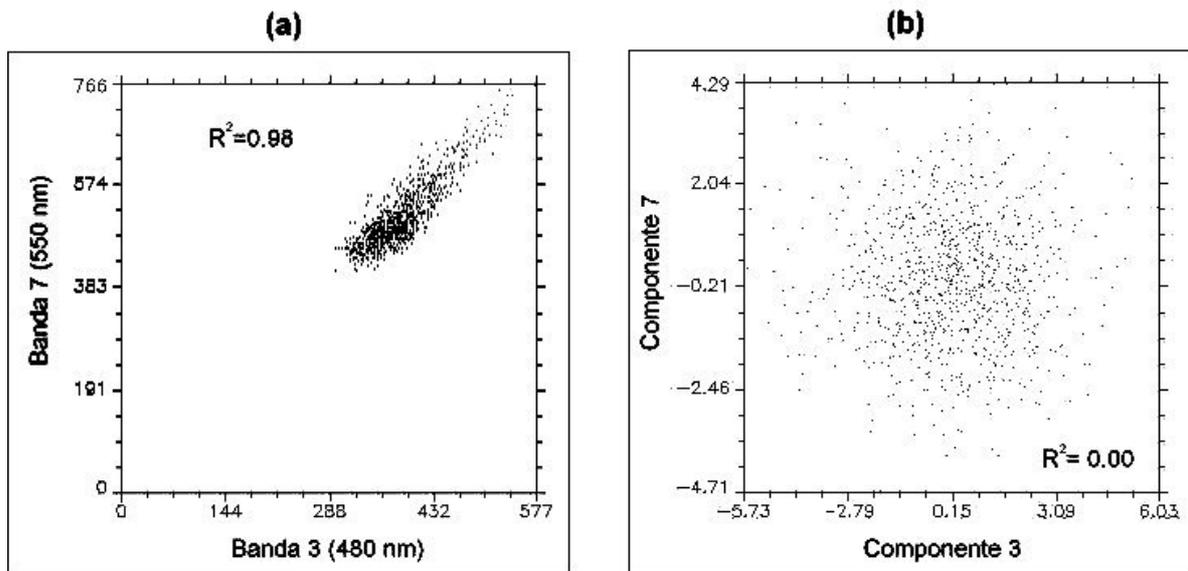


Fig.5.3 – Correlazione tra le bande 3 e 7 del MIVIS (a) prima e (b) dopo aver effettuato la trasformazione MNF.

Dopo aver selezionato gli *endmembers* il LMM è stato quindi applicato all'immagine trasformata per tutta la barena S.Lorenzo.

Questa procedura si è rivelata più efficace rispetto agli altri metodi, ma ha comunque prodotto un RMS elevato. Per tentare di diminuire l'errore si è quindi ridotta l'area di lavoro (Metternicht et Fermont, 1998; Elmore et al., 2000) ad una piccola porzione della barena S.Lorenzo (Fig.5.4), sulla quale era stato effettuato un numero elevato di rilievi in campo.

Gli *endmembers* selezionati sono stati quattro: tre relativi alle specie *Spartina maritima*, *Limonium narbonense* e *Sarcocornia fruticosa* (le uniche specie presenti nelle aree interne alla barena) ed uno corrispondente alla vegetazione di bordo. Sulle gengive dei canali e dei ghebi cresce infatti una vegetazione mista che comprende *Inula crithmoides*, *Puccinellia palustris* e *Suaeda maritima*. Poiché queste tre specie crescono sempre in associazione, non è stato possibile riconoscere sull'immagine MIVIS aree in cui esse fossero presenti al 100%, e quindi l'associazione delle tre specie è stata considerata come un unico *endmember*. Inoltre in questa zona della barena S.Lorenzo non sono state riconosciute porzioni di suolo nudo, e pertanto esso non ha costituito un *endmember* per l'*unmixing*. Gli spettri dei quattro *endmembers* sono rappresentati in Fig.5.5.

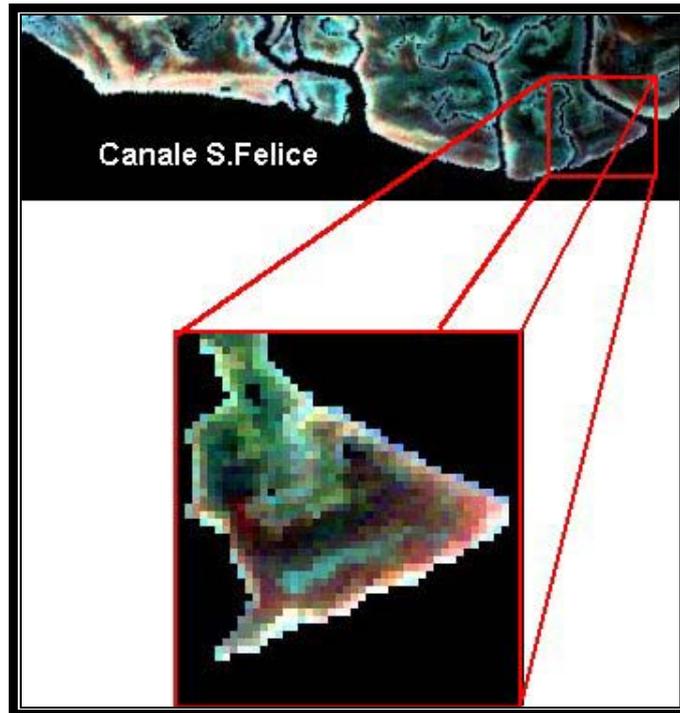


Fig.5.4 – Porzione della barena S.Lorenzo sulla quale è stato applicato il Linear Mixture Model. (le zone raffigurate con il colore nero rappresentano le superfici d'acqua dopo l'applicazione della maschera).

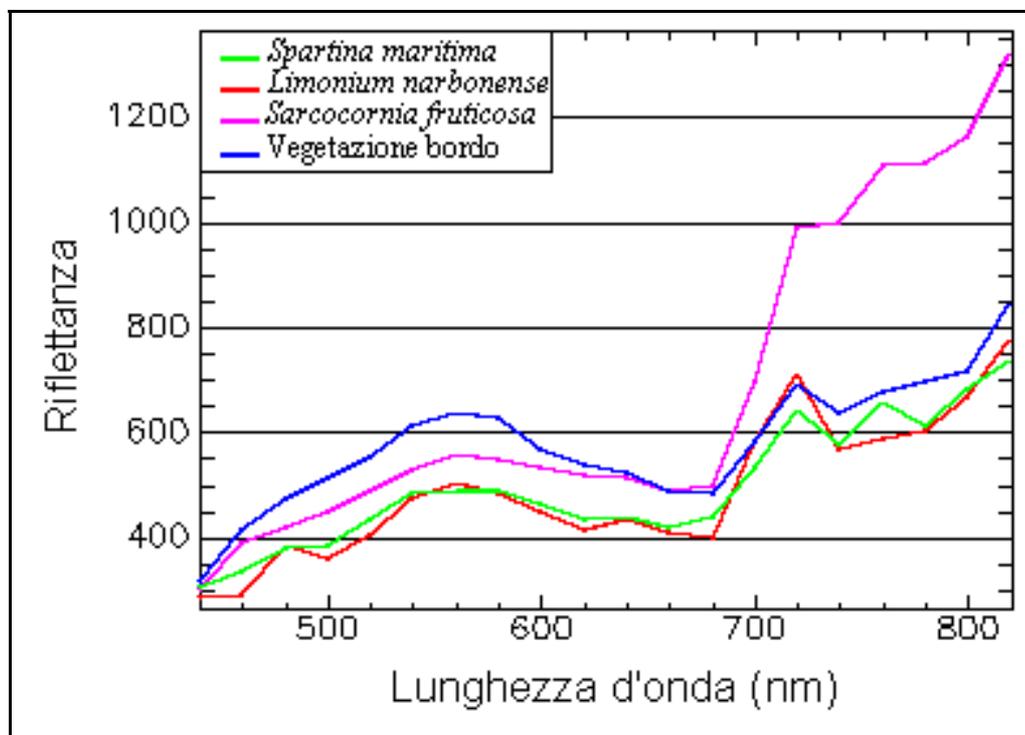


Fig.5.5 - Spettri di riflettanza (risalata tra 0 e 10^4) dei quattro endmembers selezionati.

Il risultato dell'unmixing è riportato in scala di grigi nella *Fig.5.6*: l'immagine (A) rappresenta l'abbondanza della *Spartina*, l'immagine (B) raffigura l'abbondanza del *Limonium*, la (C) quella di *Sarcocornia* ed infine la (D) raffigura l'abbondanza della vegetazione di bordo. I pixel più chiari rappresentano le zone con abbondanza maggiore.

Procedendo dall'alto verso il basso si distinguono tre fasce pressoché parallele in cui predomina rispettivamente la *Spartina* (che occupa le zone più interne), il *Limonium* e la *Sarcocornia*, mentre la vegetazione di bordo è ristretta in una sottile fascia lungo i margini del canale e dei ghebi.

L'immagine (E) (*RMS image*) presenta una bassa correlazione spaziale dell'errore e il suo valore medio è pari a 1,38. Per avere un'idea della dimensione dell'errore questo è stato confrontato con l'intervallo di variabilità dei dati dell'immagine MIVIS trasformata (valori che non sono più delle riflettanza). In *Tab.5.I* sono elencati, per ciascuna delle venti bande, il valore minimo, medio, massimo e la deviazione standard dei dati dell'immagine MIVIS trasformata. La deviazione standard mediata ($\bar{\sigma}$) sulle venti componenti è risultata di 1,48.

Prendendo come misura della dispersione dei dati attorno alla media il valore $\pm 2\bar{\sigma}$, intervallo entro il quale ricade il 95% circa dei valori, e confrontandolo con il valore medio dell'RMS ($\overline{\text{RMS}} = 1,38$), si ottiene l'errore commesso dal modello LMM che è risultato pari al 23,3% ($\overline{\text{RMS}}/4\bar{\sigma} * 100$).

Un secondo modo per valutare l'accuratezza del risultato è quello di considerare la percentuale di pixel che presenta valori di abbondanza minori di zero o maggiori di uno. In *Tab.5.II*, si osserva che tale percentuale è elevata sia per l'immagine relativa a *Spartina maritima* che per quella relativa a *Sarcocornia fruticosa* mentre assume il valore più basso per *Limonium narbonense*.

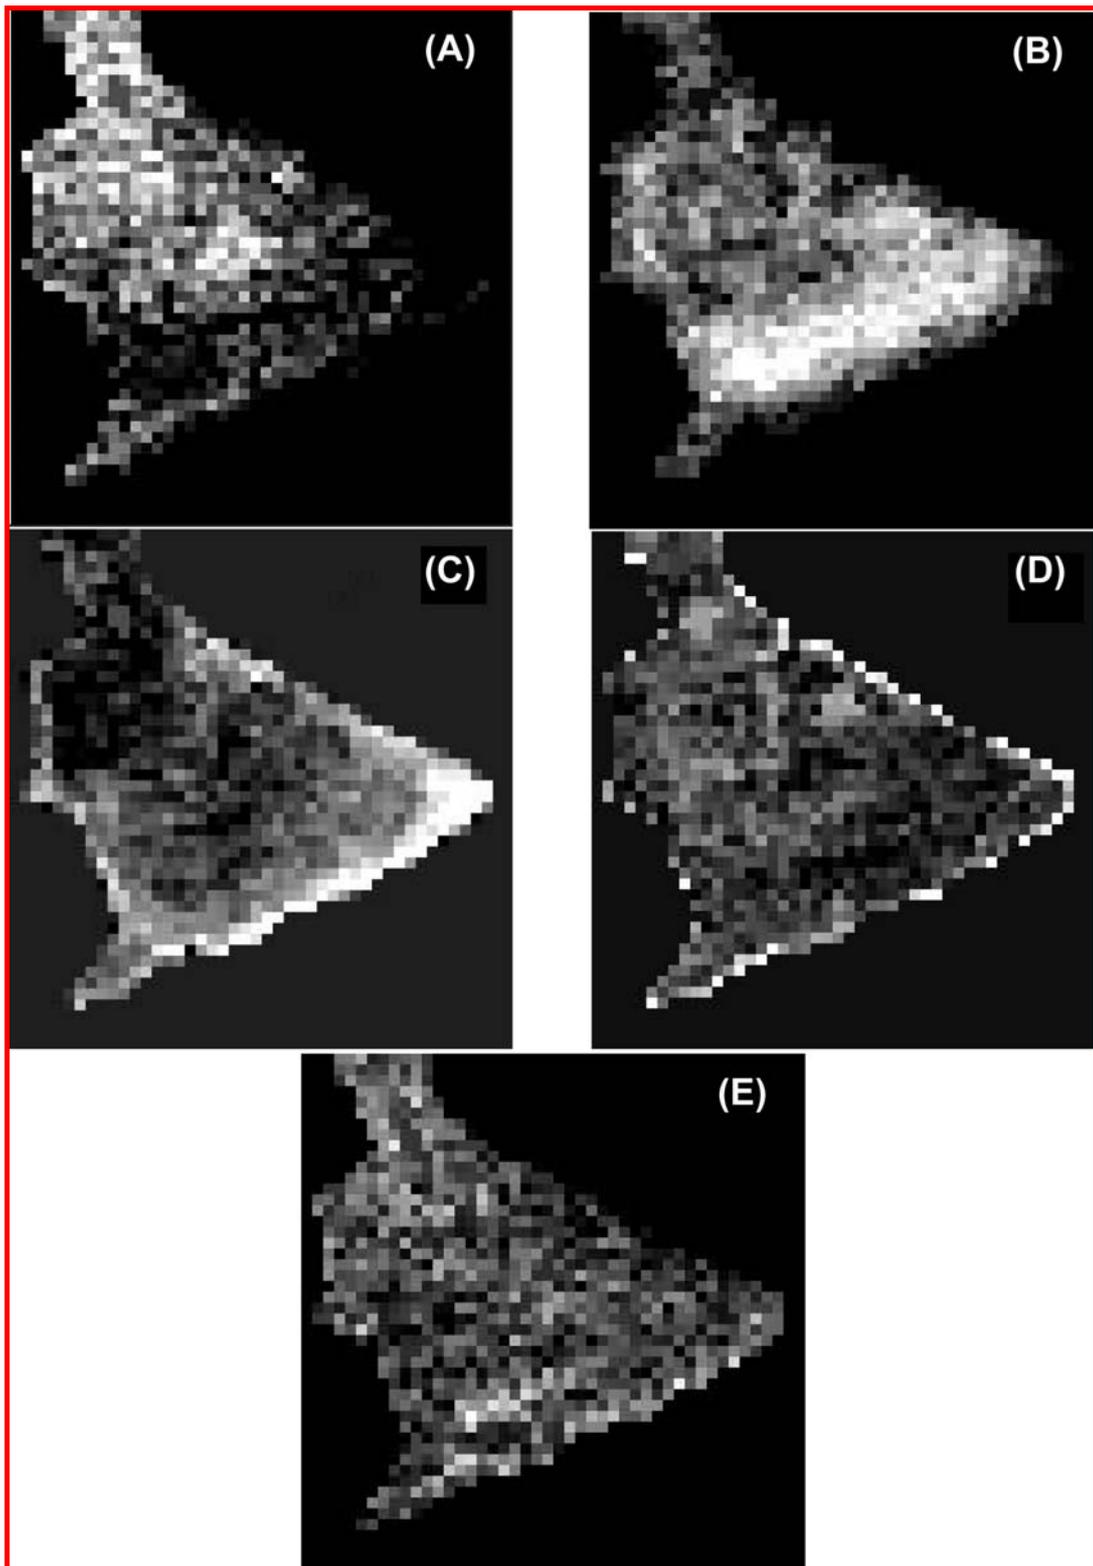


Fig.5.6 – Risultato del Linear Mixture Model (immagini in scala di grigi): (A) *Spartina maritima*, (B) *Limonium narbonense*, (C) *Sarcocornia fruticosa*, (D) vegetazione di bordo (i pixel più chiari rappresentano i valori di abbondanza maggiori).

Tab.5.I – Valori minimi, massimi, medi e deviazione standard relativi alle 20 bande MIVIS trasformate. Si calcola inoltre la deviazione standard media ($\bar{\sigma}$).

Banda <i>i</i> -esima	Minimo	Massimo	Media	σ
1	-7,51	9,94	0	3,03
2	-6,64	6,52	0	2,55
3	-5,73	6,03	0	1,91
4	-5,81	5,45	0	1,55
5	-5,36	5,27	0	1,43
6	-4,69	5,19	0	1,40
7	-4,71	4,29	0	1,38
8	-4,07	4,37	0	1,37
9	-5,53	4,34	0	1,35
10	-4,56	3,92	0	1,33
11	-4,72	4,81	0	1,32
12	-4,50	4,22	0	1,29
13	-4,42	4,60	0	1,27
14	-3,85	4,74	0	1,25
15	-3,88	3,89	0	1,25
16	-3,46	4,08	0	1,24
17	-3,88	4,11	0	1,23
18	-3,61	3,89	0	1,20
19	-3,73	3,12	0	1,18
20	-3,18	5,32	0	1,09

Tab.5.II – Percentuale di pixel (per ogni mappa delle proporzioni) che presenta valori di abbondanza al di fuori dell'intervallo [0,1].

<i>Fraction maps</i>	% pixel \notin [0, 1]
<i>Spartina maritima</i> (A)	20,5
<i>Limonium narbonense</i> (B)	7,2
<i>Sarcocornia fruticosa</i> (C)	19,9
Vegetazione di bordo (D)	12,5