

Applicazione delle reti neurali alla valutazione della produzione primaria e della biomassa fitoplanctonica.

Michele Scardi

Dipartimento di Zoologia, Università di Bari, Via Orabona 4/A, 70125 Bari

email: mcardi@mclink.it

URL: <http://www.mare-net.com/mcardi>

Sommario.

In questo contributo sono sintetizzate alcune applicazioni delle reti neurali a problematiche legate al telerilevamento della biomassa fitoplanctonica ed alla modellizzazione della produzione primaria fitoplanctonica. In particolare, vengono presentate applicazioni di reti neurali di tipo feedforward a 3 strati, addestrate mediante un classico algoritmo di error back-propagation. Questa soluzione non è certamente d'avanguardia nel campo delle reti neurali, ma fornisce comunque prestazioni di enorme interesse in rapporto a quanto è possibile ottenere mediante un approccio convenzionale.

Generalità sulle reti neurali.

Le reti neurali (o, più correttamente, le reti neurali artificiali) sono strumenti di calcolo molto potenti e flessibili, che possono essere utilizzati per le più svariate applicazioni, fra cui, ad esempio, la classificazione, il riconoscimento di patterns, l'approssimazione di funzioni o la modellizzazione empirica.

In generale, le reti neurali possono essere "addestrate" a fornire un output corretto di tipo binario, fuzzy o quantitativo, a condizione che sia disponibile una quantità di dati sufficientemente grande e, soprattutto, rappresentativa del problema da affrontare. Da un punto di vista computazionale tutti i diversi tipi di rete neurale possono essere considerati come dei sistemi composti da un certo numero di unità di calcolo elementari che operano in parallelo. Il ruolo di ciascuna di tali unità ai fini del funzionamento della rete è determinato dalla struttura di quest'ultima, dell'intensità delle connessioni fra le unità di calcolo elementari e dal tipo di trasformazione che viene operato al loro interno sul flusso dei dati.

Alcune tipologie di rete neurale sono particolarmente adatte a ricostruire relazioni complesse fra insiemi di variabili, anche in termini quantitativi, e quindi possono essere utilizzate con successo come modelli empirici. Ciò le rende particolarmente utili in tutti i casi in cui si debbano effettuare delle stime di grandezze derivate da dati rilevati strumentalmente e soprattutto nei casi in cui non è possibile definire su base teorica una formulazione analitica dei processi che devono essere considerati ai fini della stima delle grandezze derivate. E' evidente che questo contesto applicativo è quello tipico del telerilevamento e, in particolare, della stima della biomassa fitoplanctonica in funzione del colore delle acque marine e della stima della produzione primaria fitoplanctonica sulla base di quest'ultima.

Una rete neurale di tipo Multilayer Perceptron (MLP) è costituita da diversi strati di nodi (o neuroni, per analogia con i sistemi biologici a cui si richiama): uno strato di input (**i**), un numero variabile di strati nascosti (**h**) ed uno strato di output (**o**). Da un

punto di vista computazionale una rete neuronale MLP può essere considerata come una funzione più o meno complessa che ha come argomenti i valori immessi ai nodi di input e che restituisce i suoi risultati ai nodi di output. Al suo interno la rete combina i diversi inputs attraverso una serie più o meno complessa di combinazioni lineari e di funzioni non lineari, fino ad ottenere i valori di output.

Nella figura 1 è mostrato un modello di rete neuronale MLP con tre strati e, quindi, con un solo strato nascosto. La struttura di questo tipo di rete può essere sintetizzata dal numero dei nodi nei diversi strati. Ad esempio, quella mostrata è di tipo 5-7-1, cioè ha 5 nodi nello strato di input, 7 in quello nascosto e 1 in quello di output. In realtà, sia nello strato di input, sia nello strato nascosto, si può notare un ulteriore nodo, contraddistinto da un "1" al suo interno. Questi nodi, forniscono un valore costante (generalmente, per l'appunto, 1) e sono noti come nodi di *bias*. Il loro ruolo in una rete neuronale MLP è analogo a quello del termine costante in una regressione, poichè essi permettono di traslare l'origine dell'iperspazio definito dall'insieme dei dati relativi alle variabili di input.

Questo tipo di rete neuronale è di gran lunga il più comune in svariati settori applicativi, sia come classificatore che come approssimatore. A questo proposito, in particolare, è utile ricordare che è stato dimostrato che una rete neuronale MLP con uno solo strato nascosto può essere considerata come un approssimatore universale a condizione che abbia un numero sufficiente di nodi nello strato nascosto (Hornik et al., 1989). Due semplici esempi di applicazione di reti neurali MLP utilizzati a scopi dimostrativi sono quelli relativi alla ricostruzione di una porta logica di tipo XOR ed all'approssimazione di funzioni di seno e di coseno. In entrambi i casi reti estremamente semplici sono in grado di assicurare risultati molto accurati, a testimonianza della flessibilità e della potenza di questo tipo di strumento. Per ciò che riguarda il suo funzionamento interno, una rete neuronale MLP è caratterizzata dal fatto che ogni nodo degli strati successivi a quello di input riceve una combinazione lineare degli output dei nodi dello strato precedente. Le connessioni fra i nodi sono modulate da pesi (detti a volte sinaptici, sempre per analogia con il modello biologico) che vengono definiti mediante una apposita procedura di addestramento (o *training*).

Inoltre, ogni nodo degli strati successivi a quello di input è associato ad una funzione di attivazione, che riceve la combinazione di input del nodo e ne restituisce l'output (fig. 2). La funzione di attivazione può essere di diversi tipi, ma deve comunque essere una funzione differenziabile della combinazione lineare degli inputs che il nodo riceve e che costituisce, quindi, il suo argomento. Fra le funzioni di attivazione più comuni possono essere senz'altro citate quelle di tipo sigmoide, come, ad esempio:

$$f(a) = \frac{1}{1 + e^{-a}}$$

Ritornando sul concetto di rete neuronale MLP come approssimatore universale, oltre ad un numero sufficiente di nodi nello strato nascosto, è necessario che una rete con queste caratteristiche abbia anche delle funzioni di attivazione non lineari nello strato nascosto. E' dunque l'interazione fra un elevato numero di combinazioni lineari e le funzioni di attivazione non lineari a consentire alla rete neuronale una grande flessibilità e la capacità di adattarsi ai più disparati problemi.

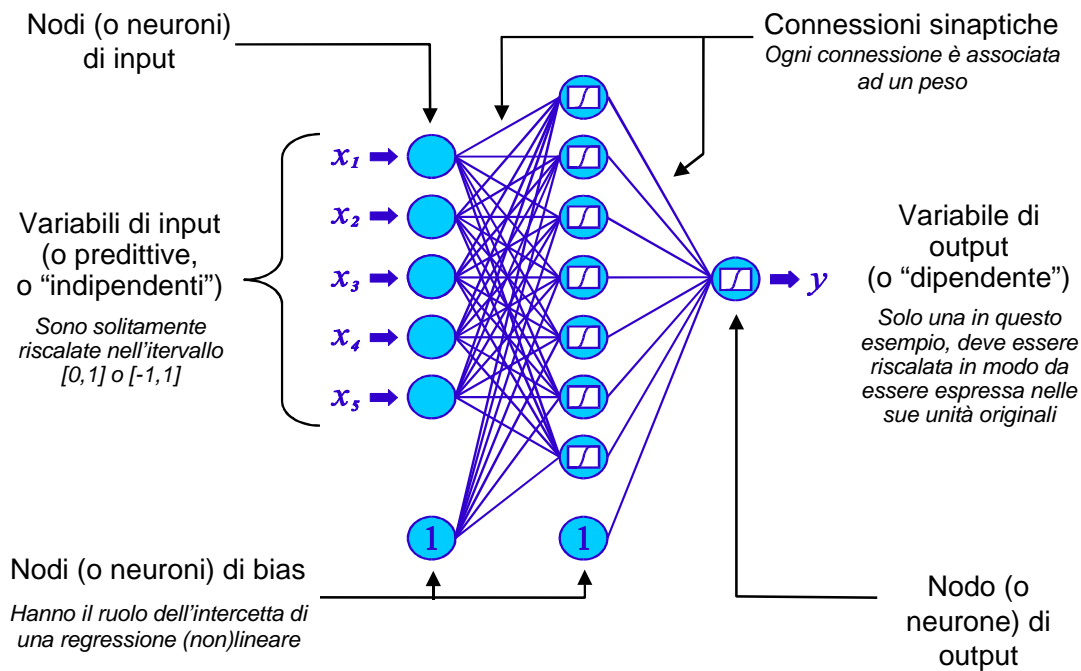


Fig. 1. La struttura di una rete neuronale di tipo Multilayer Perceptron (MLP).

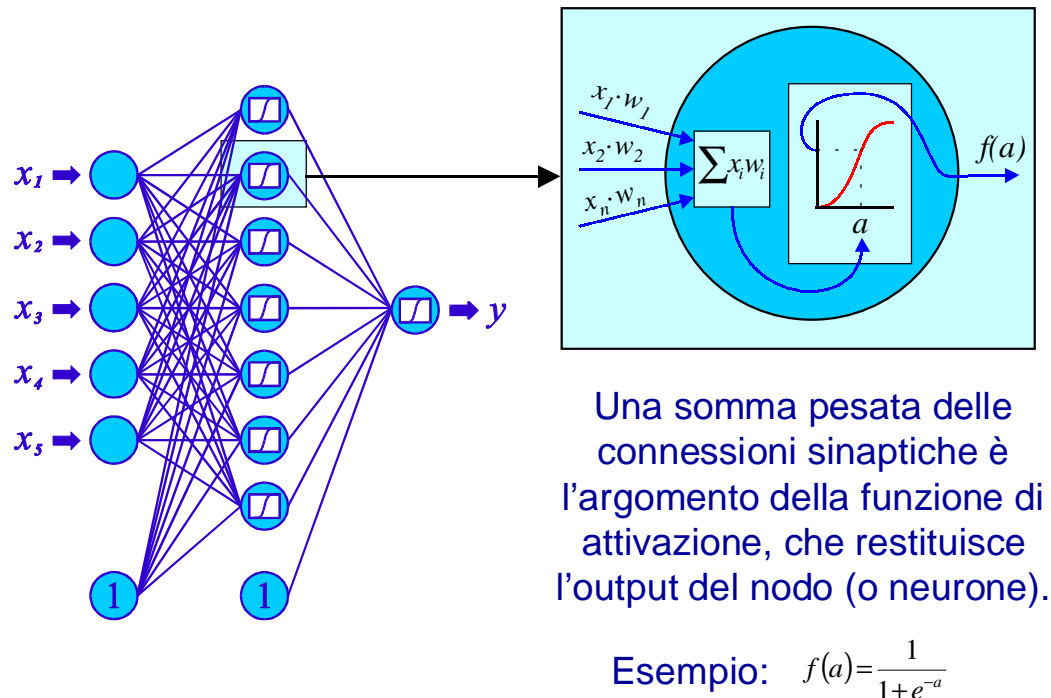


Fig. 2. La funzione di attivazione in un rete neuronale di tipo Multilayer Perceptron (MLP).

Una volta che la struttura di una rete neuronale MLP è stata definita, il suo funzionamento dipende esclusivamente dai pesi sinaptici. Esistono diversi algoritmi mediante i quali possono essere ottimizzati tali pesi, ma quello che ha consentito alle reti neurali MLP di diventare degli strumenti effettivamente applicabili è quello noto come error back-propagation o EBP (Rumelhart et al., 1986). In seguito sono stati messi a punto altri algoritmi, molti dei quali costituiscono delle evoluzioni dell'EBP. Alcuni di questi offrono effettivamente dei vantaggi rispetto all'algoritmo originale, che non è esente da difetti e limitazioni. Tuttavia, per un uso non particolarmente spinto e nei casi in cui i problemi di generalizzazione della rete neuronale sono più rilevanti dell'efficienza dell'apprendimento, anche l'algoritmo EBP rimane una scelta più che valida.

L'algoritmo EBP può essere suddiviso in quattro steps principali: (1) la rete neuronale è inizializzata assegnando valori casuali ai pesi sinaptici; (2) un *training pattern* (cioè un vettore di dati di input associato ad uno o più output noti) viene sottoposto alla rete e propagato attraverso di essa in modo tale da calcolare un valore per ogni nodo di output; (3) i valori di output così ottenuti vengono comparati con quelli attesi, cioè con quelli noti; (4) la struttura della rete viene idealmente percorsa all'indietro (back-propagation), variando i pesi sinaptici sulla base dello scarto osservato fra output calcolati e valori noti. Le fasi da 2 a 4 vengono iterate per ogni pattern del training set e quindi viene controllato il funzionamento della rete, solitamente in base al calcolo dell'errore quadratico medio su un insieme di dati di validazione indipendente. Se l'accordo fra gli outputs della rete ed i valori attesi è soddisfacente la procedura viene interrotta, altrimenti si ripete l'intera procedura dal punto 2.

Il primo step della fase di apprendimento prevede che i pesi vengano inizializzati con valori casuali, che generalmente sono assegnati in modo da essere abbastanza piccoli in valore assoluto. Una regola empirica frequentemente utilizzata per determinare i pesi iniziali tiene anche conto della struttura della rete, assegnando i pesi iniziali in un intervallo tanto più limitato quanto maggiore è il numero di nodi nello strato da cui partono le connessioni sinaptiche. Ad esempio, si può utilizzare un'inizializzazione tale che sia:

$$-\frac{1}{\sqrt{n_i}} \leq w_{jk} \leq \frac{1}{\sqrt{n_i}} \quad (j = 1, \dots, n_i; k = 1, \dots, n_h)$$

$$-\frac{1}{\sqrt{n_h}} \leq z_{kl} \leq \frac{1}{\sqrt{n_h}} \quad (k = 1, \dots, n_h; l = 1, \dots, n_o)$$

dove w_{jk} sono i pesi delle connessioni fra gli n_i nodi dello strato di input e gli n_h nodi di quello nascosto e z_{kl} sono quelli delle connessioni fra gli n_h nodi di quello nascosto e gli n_o nodi dello strato di output.

Il secondo step dell'algoritmo EBP prevede la propagazione in avanti dei valori di input ed il calcolo degli outputs della rete. Questa operazione, più in generale, è quella che si compie ogni qualvolta è necessario utilizzare la rete per determinarne gli outputs, dato un vettore (o pattern) di input, e quindi anche nell'uso della rete stessa una volta terminata la fase di apprendimento. Il primo passo per la propagazione in avanti dei valori di input è quello con cui si calcolano gli inputs h_k dei nodi dello strato nascosto:

$$h_k = \sum_{j=1}^{n_i+1} i_j w_{jk} \quad (k = 1, \dots, n_h)$$

dove i_j sono gli output dello strato di input (cioè i valori degli input della rete ed un valore unitario per il nodo di bias) e w_{jk} sono i pesi delle connessioni fra lo strato di input e quello nascosto. Gli inputs dello strato nascosto vengono trasformati nei valori di output di questo stesso strato passandoli come argomento alla funzione di attivazione. Fa eccezione il nodo di bias, il cui output è costante e pari a 1:

$$\begin{aligned} h_k &= f(h_k) \\ h_{n_h+1} &= 1 \end{aligned}$$

Gli outputs della rete vengono poi calcolati ripetendo la stessa procedura fra lo strato nascosto e quello di output:

$$\begin{aligned} o_l &= \sum_{k=1}^{n_h+1} h_k z_{kl} \quad (l = 1, \dots, n_o) \\ o_l &= f(o_l) \end{aligned}$$

A questo punto la propagazione in avanti dei valori di input è terminata e gli outputs della rete neuronale sono disponibili. Durante la fase di apprendimento, il terzo step è quello in cui gli outputs ottenuti (o_l) vengono comparati con i valori attesi (y_l) e viene calcolato uno scarto quadratico medio degli outputs:

$$E = \frac{1}{n_o} \sum_{l=1}^{n_o} (y_l - o_l)^2$$

Il quarto ed ultimo step della fase di apprendimento è quello propriamente detto di propagazione all'indietro dell'errore, cioè di error back-propagation, da cui prende il nome l'algoritmo. In questo step tutti i pesi sinaptici vengono fatti variare in modo tale da assicurare una discesa ottimale dei gradienti della superficie che descrive l'errore. In pratica, per i pesi z_{kl} delle connessioni fra lo strato di output e quello nascosto, ciò si attua come segue:

$$z_{kl} = z_{kl} + \eta \delta_l^o h_k \quad (k = 1, \dots, n_h + 1; l = 1, \dots, n_o)$$

dove η è una costante (tasso di apprendimento) e:

$$\delta_l^o = (y_l - o_l) \cdot f'(o_l) = (y_l - o_l) \cdot o_l(1 - o_l)$$

Come si può notare è molto importante ai fini pratici che la derivata della funzione di attivazione sia semplice da calcolare. I pesi w_{jk} delle connessioni fra lo strato nascosto e quello di input vengono anch'essi aggiornati di conseguenza:

$$w_{jk} = w_{jk} + \eta \delta_k^h i_j \quad (k = 1, \dots, n_h + 1; j = 1, \dots, n_i + 1)$$

dove i δ_k^h vengono calcolati come:

$$\delta_k^h = f'(h_k) \cdot \sum_{l=1}^{n_o} \delta_l^o z_{kl} = h_k(1-h_k) \cdot \sum_{l=1}^{n_o} \delta_l^o z_{kl}$$

La fase di apprendimento prosegue poi iterando questi 4 steps ed ha termine quando vengono raggiunte delle condizioni prefissate, che in generale implicano la minimizzazione dell'errore quadratico medio sull'insieme dei dati utilizzati per la validazione della rete, che dovrebbe essere indipendente da quello da cui vengono estratti i patterns forniti alla rete durante l'apprendimento.

Va sottolineato il fatto che questa procedura non converge sempre e comunque verso un unico set di pesi sinaptici, poichè in essa sono implicati anche fattori non deterministici (es. valori iniziali dei pesi sinaptici) ed è possibile che l'apprendimento si arresti in un punto che corrisponde ad un minimo locale della superficie d'errore. Esistono molte variazioni della procedura EBPed innumerevoli affinamenti possibili, per i quali si rimanda alla letteratura specializzata.

Ad esempio, un'introduzione alla materia compatta ed efficace è stata fornita da Abdi (1994), ma è anche possibile attingere alle numerose risorse disponibili in rete. Per un orientamento preliminare si consiglia di consultare la FAQ mantenuta da Warren Sarle dell'SAS Institute (<ftp://ftp.sas.com/pub/neural/FAQ.html>) o la pagina Web sulle reti neurali dell'Autore (<http://www.mare-net.com/mscardi/work/nn/nn.htm>).

Da un punto di vista del codice di calcolo sono disponibili moltissimi pacchetti, sia commerciali, sia shareware, sia di pubblico dominio. Comunque, chi fosse interessato può anche richiedere il codice Fortran o Basic di un'implementazione di base di una rete neurale EBP all'Autore di questo testo.

Stima della biomassa fitoplanctonica.

La biomassa fitoplanctonica è stata oggetto di telerilevamento da svariate piattaforme, anche se quelle su cui è stata basata la gran parte delle applicazioni sono sostanzialmente due, entrambe di tipo satellitare: il Coastal Zone Color Scanner (CZCS), operativo dal 1978 al 1986, ed il Sea-viewing Wide Field-of-view Sensor (SeaWiFS), operativo da circa due anni. In particolare, il secondo sensore rappresenta un'estensione ed un affinamento del primo ed entrambi sono stati progettati e gestiti dalla NASA. I dati prodotti sono facilmente accessibili alla collettività scientifica per usi non commerciali e, soprattutto per quanto riguarda i dati CZCS, sono disponibili direttamente attraverso degli appositi server Web ed FTP. I dati sono anche disponibili in formati compositi, cioè ottenuti elaborando più immagini per ottenere immagini mediate nel tempo e nello spazio (e quindi a risoluzione inferiore a quella massima).

La stima della biomassa fitoplanctonica si basa in generale sul colore delle acque marine, che viene analizzato utilizzando l'informazione relativa alle radianze rilevate dai sensori per alcune lunghezze d'onda particolari. Esistono diverse formulazioni empiriche possibili della relazione fra radianze e biomassa, alcune molto semplici, di tipo lineare, ed altre più complesse ed arricchite da correzioni atmosferiche di vario genere.

Un esempio di algoritmo di tipo tradizionale relativamente complesso è fornito dall'algoritmo OC2 (O'Reilly and Maritorena, 1998), sviluppato per l'analisi dei dati SeaWiFS. La stima della biomassa fitoplanctonica, espressa come concentrazione della clorofilla, si ottiene come segue:

$$Chl = -0.040 + 10^{0.341 - 3.001x + 2.811x^2 - 2.041x^3}$$

dove

$$x = \log_{10}[R_{rs}(490)/R_{rs}(555)]$$

Questo algoritmo utilizza dunque l'informazione contenuta nei dati relativi a due sole radianze ed in particolare nel loro rapporto. Le stime ottenute mediante l'algoritmo OC2 sono abbastanza accurate e comunque tali da superare altri algoritmi di formulazione più semplificata, come ben illustrato nella fig. 3.

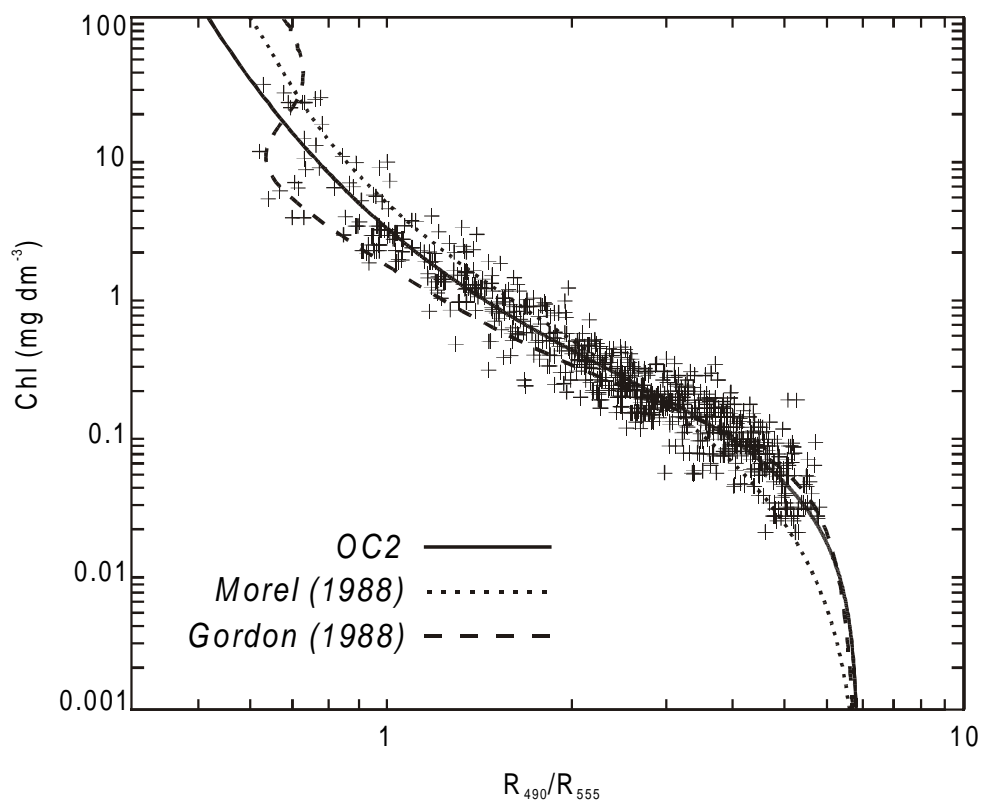


Fig. 3. Confronto fra l'algoritmo OC2 ed altri algoritmi convenzionali per la stima della biomassa fitoplanctonica.

E' evidente, comunque, che l'idea di poter derivare una stima della biomassa fitoplanctonica dal rapporto fra due radianze appare abbastanza debole da un punto di vista concettuale, così come la scelta di una formulazione tanto complessa quanto non supportata da un background teorico. E' evidente, inoltre, che immediatamente al di fuori dei limiti del data set utilizzato per la taratura, l'algoritmo fornisce stime assolutamente non realistiche ed è quindi carente in termini di capacità di estrapolazione.

L'approccio basato sulle reti neurali costituisce un'alternativa di grande interesse pratico, perchè la mancanza di una ipotesi *a priori* sulle relazioni causali che sottendono l'interpretazione dei dati telerilevati non ne limita la validità in alcun

modo, a condizione che siano state soddisfatte tutte le condizioni necessarie ad una buona generalizzazione della rete neuronale stessa.

Inoltre, la robustezza di questo tipo di approccio nei confronti dell'informazione ridondante consente di utilizzare tutte le radianze disponibili, anche se il loro ruolo resta da chiarire. Sarà la procedura di training della rete a determinare il loro ruolo in rapporto ai dati disponibili.

Una struttura di rete neuronale esemplificativa per questo tipo di applicazione è quella mostrata nella fig. 4, in cui si può osservare come ben cinque diverse lunghezze d'onda siano state prese in considerazione e, fra queste, quelle utilizzate dall'algoritmo OC2. Il risultato dell'applicazione della rete neuronale alla stima delle biomasse fitoplanctoniche è stato confrontato con quello dell'algoritmo OC2, come mostrato nella fig. 5. I risultati ottenuti sono apparentemente abbastanza simili, ma si può notare come l'errore dell'algoritmo OC2 per i valori più bassi di biomassa sia ben superiore a quello della rete neuronale, come mostra la maggior dispersione di punti nell'angolo in basso a sinistra.

Da un punto di vista complessivo la differenza fra i due approcci in termini di errore quadratico medio (MSE) della stima è percepibile, anche se non estremo. La rete neuronale ha un MSE pari a 2.47, cioè inferiore a quello dell'algoritmo OC2, che arriva a 2.92. La varianza spiegata dal modello è nel primo caso pari al 68.1% e nel secondo al 62.2%). In entrambi i casi la distribuzione degli scarti fra valori stimati e valori osservati è centrata sullo zero e non troppo lontana dalla normalità (fig. 6). Nel caso dell'OC2, si nota comunque una quantità non trascurabile di casi di forte sovrastima (cioè di scarti maggiori di $0.8 \mu\text{g Chl dm}^{-3}$).

Ciò che rende sostanzialmente differenti i due approcci, tuttavia, è la possibilità di migliorare ulteriormente quello basato sulla rete neuronale, arricchendo l'insieme delle grandezze predittive di informazioni accessorie facilmente disponibili e correlate con particolari condizioni di tipo geografico (es. latitudine) o stagionale (es. giorno dell'anno), che ben difficilmente potrebbero essere integrate in un approccio tradizionale (si pensi, ad esempio, ai problemi che si incontrano per le latitudini estreme).




Fig. 4. Struttura di una rete neuronale MLP per la stima della biomassa fitoplanctonica. In input sono utilizzati i dati di radianza relativi a 5 lunghezze d'onda.

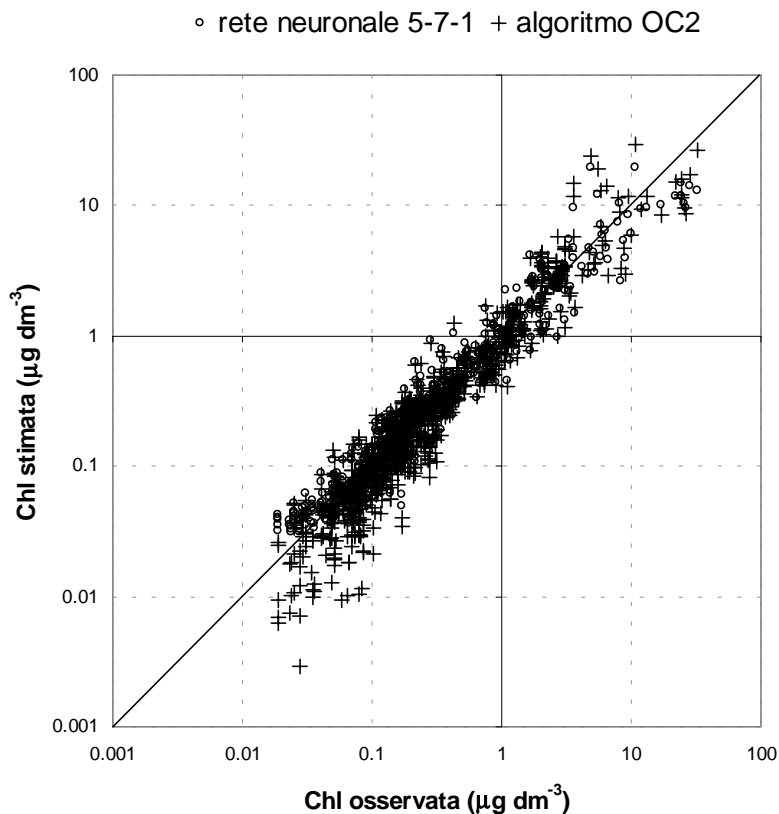


Fig. 5. Biomassa fitoplanctonica stimata ed osservata, espressa come concentrazione di clorofilla a, per l'algoritmo OC2 (croci) e la rete neuronale 5-7-1 (cerchi).

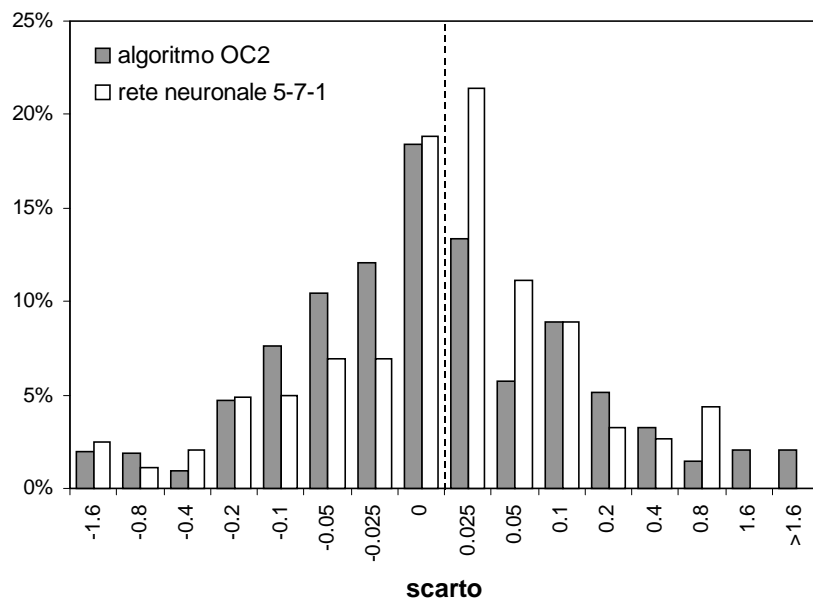


Fig. 6. Scarti fra valori stimati ed osservati di biomassa fitoplanctonica per l'algoritmo OC2 (in grigio) e la rete neuronale 5-7-1 (in bianco), espressi come $\mu\text{g Chl dm}^{-3}$.

Stima della produzione primaria fitoplanctonica.

Il dato relativo alla biomassa fitoplanctonica è di per sé estremamente interessante ed è utile per l'analisi di una vasta gamma di problemi oceanografici. Tuttavia, se si vuole approssimare lo studio della dinamica del comparto pelagico, non si può prescindere dal mettere in relazione la biomassa fitoplanctonica con ciò che la determina e, al tempo stesso, ne consegue, cioè con la produzione primaria fitoplanctonica.

Questa grandezza viene stimata per via diretta mediante la misura dell'assimilazione di carbonio radiattivo o dell'ossigeno liberato durante la fotosintesi, sia *in situ*, sia in condizioni simulate di luce e temperatura. In generale, la produzione primaria è strettamente dipendente dalla biomassa fotosinteticamente attiva, dal suo stato fisiologico, dalla temperatura dell'acqua e dalla quantità di luce disponibile e ciò favorisce un approccio indiretto alla sua stima, basato su modelli empirici.

Come nel caso della stima della biomassa da dati telerilevati, sono disponibili diversi algoritmi empirici che consentono di stimare la produzione primaria sulla base delle grandezze predittive appena citate ed alcuni di essi hanno fornito risultati certamente interessanti. Tuttavia, molto spesso la validità di questi algoritmi è strettamente legata ad un particolare insieme di dati e, quindi, ad un particolare contesto spazio-temporale.

L'applicazione delle reti neurali è anche in questo caso particolarmente efficace e consente di migliorare con facilità le stime ottenibili con un approccio di tipo convenzionale.

Un esempio assai semplificato, ma concettualmente utile per introdurre un approccio basato sulle reti neurali, è quello mostrato nella fig. 7. Nonostante l'estrema semplificazione dell'insieme di variabili predittive, una rete neurale di questo tipo è in grado di superare senza problemi gran parte dei modelli convenzionali, indipendentemente dalla loro complessità.




Fig. 7. Una semplice rete neurale per la stima della produzione primaria fitoplanctonica integrata su tutta la colonna d'acqua.

Volendo considerare un'espressione più ampia delle potenzialità di una rete neurale, può essere utile confrontarne una strutturalmente un po' più complessa con un algoritmo tradizionale. Il confronto presentato è relativo ad un modello globale basato su una rete neurale appena più complessa di quella appena mostrata ed al modello VGPM di Behrenfeld e Falkowski (1997).

La rete neurale prende in considerazione dati rilevati in superficie per la biomassa fitoplanctonica, la temperatura e l'irradianza (come in fig. 7), oltre alla data, espressa mediante una coppia di funzioni di seno e coseno, e quindi mappata su una circonferenza, ed alle coordinate geografiche. Il modello VGPM oltre alle prime tre grandezze utilizzate per la rete neurale, utilizza il fotoperiodo o, se questo non è disponibile, la data e la latitudine. L'unica differenza fra i due approcci, dunque, sta nel fatto che la rete neurale in questione utilizza anche la longitudine del punto in cui deve essere stimata la produzione. Per quanto riguarda il modello VGPM, si rimanda alla descrizione dell'algoritmo disponibile in Behrenfeld e Falkowski (1997). Nella figura 8 sono mostrati i risultati ottenuti con i due modelli, visualizzati mediante grafici in cui il valore predetto (in ordinata) è plottato contro il valore osservato (in ascissa). Come si può notare, la dispersione dei punti è minore per la rete neurale (fig. 8a), che aveva una struttura di tipo 7-7-1, cioè basata su sette nodi nello strato nascosto, ad eccezione che per i più bassi valori di produzione primaria. Il modello VGPM mostra una maggiore dispersione dei punti su tutta la gamma dei valori e l'errore per i valori di produzione più bassi è comunque elevato (fig. 8b). Se si fa riferimento alla linea diagonale che indica un accordo perfetto fra dati stimati ed osservati, si può notare che per il modello VGPM la nube dei punti si colloca prevalentemente al di sopra della linea stessa, cioè in un'area che indica una tendenza a sovrastimare i valori di produzione.

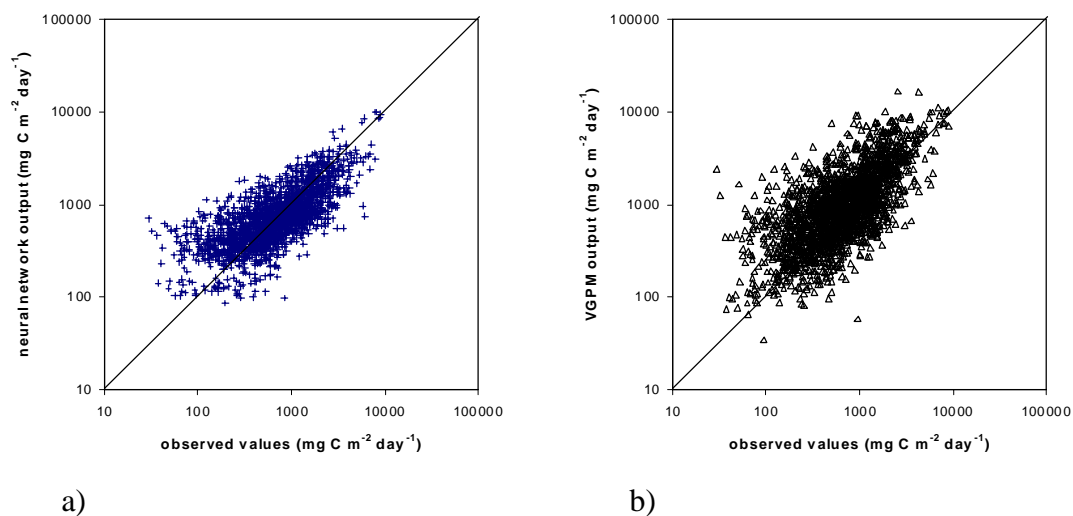


Fig. 8. Confronto fra valori di produzione primaria fitoplanctonica stimati ed attesi per la rete neurale 7-7-1, a sinistra (a), ed il modello VGPM di Behrenfeld e Falkowski (1997), a destra (b).

Da un punto di vista dell'errore quadratico medio questo risultato può essere sintetizzato nel fatto che esso è pari a 0.389 per la rete neurale e ad 1.583, cioè quattro volte superiore, per il modello VGPM. In termini di errore medio semplice, cioè di tendenza allo scarto sistematico, la rete neurale risulta quasi del tutto esente da tale tendenza (errore medio pari a 0.054 g C m⁻² giorno⁻¹), mentre il modello VGPM, come già accennato, sovrastima sistematicamente la produzione primaria, con un errore medio pari a 0.490 g C m⁻² giorno⁻¹, cioè quasi nello stesso ordine di grandezza dei valori medi di produzione osservati.

Tutto ciò trova ovviamente riscontro nella distribuzione degli errori, mostrata nella fig. 9. La distribuzione è leptocurtica, centrata sullo zero (cfr. linea tratteggiata verticale) e simmetrica nel caso della rete neuronale, mentre è evidentemente spostata verso i valori positivi e leggermente più platicurtica nel caso del modello VGPM.

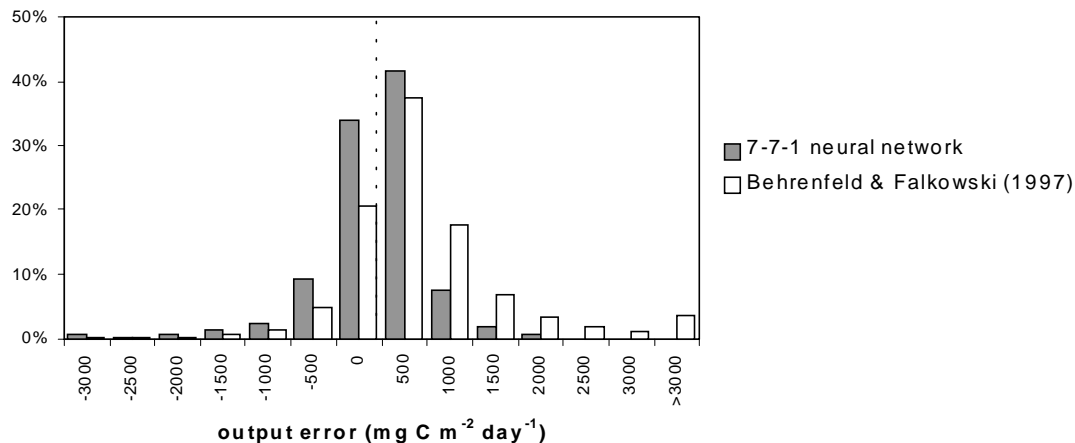


Fig. 9. Scarti fra stime di produzione primaria e valori osservati per la rete neuronale 7-7-1, in grigio, ed il modello VGPM di Behrenfeld e Falkowski (1997), in bianco.

Conclusioni.

La superiorità di un approccio connessionistico, cioè basato su reti neurali di tipo EBP o affini, all'interpretazione dei dati telerilevati per la stima della biomassa e della produzione fitoplanctonica emerge con chiarezza da tutte le esperienze disponibili. Anche prescindendo dal problema specifico dell'uso dei dati telerilevati, è stato ampiamente dimostrato che la modellizzazione empirica della produzione primaria fitoplanctonica mediante reti neurali fornisce risultati molto accurati e superiori a quelli che possono essere ottenuti mediante l'uso di modelli convenzionali (Scardi, 1996; Scardi e Harding, 1999).

La possibilità di estendere facilmente l'insieme delle grandezze predittive e di creare modelli svincolati dalle scelte strutturali del modellista rende l'uso delle reti neurali molto promettente, soprattutto in rapporto al miglior sfruttamento dell'informazione disponibile ed all'uso in aree più estese rispetto a quelle, generalmente ristrette, in cui la gran parte degli algoritmi tradizionali è stata calibrata.

La condizione essenziale per un uso corretto delle reti neurali per la stima della biomassa e della produzione fitoplanctonica, così come per qualsiasi altra applicazione di tipo modellistico, è quella di raggiungere un grado ottimale di generalizzazione del modello. Ciò implica che la rete non sia addestrata al punto da comportarsi come una "memoria", associando ad ogni vettore di input un determinato output, ma piuttosto fornisca una risposta coerente anche in termini di capacità di interpolazione ed estrapolazione. Svariate tecniche sono disponibili per il raggiungimento di questo obiettivo, ma la loro trattazione esula dagli obiettivi di questo testo.

In conclusione, si può affermare che le reti neurali possono costituire uno strumento di grande importanza nel panorama delle tecniche di trattamento dei dati telerilevati. Come in altri contesti, tuttavia, la condizione essenziale per un loro uso corretto è

costituita dalla capacità del modellista di adattare lo strumento, in sé tanto potente quanto complesso da governare appieno, alla natura dell'applicazione specifica.

Bibliografia.

- Abdi H (1994) A neural network primer. *Journal of Biological Systems* 2(3): 247-283.
- Behrenfeld MJ, Falkowski PG (1997) Photosynthetic rates derived from satellite-based chlorophyll concentration. *Limnol Oceanogr* 42 (1): 1-20
- Hornik K, Stinchcombe M, White H (1989) Multilayer feedforward networks are universal approximators. *Neural Networks* 2: 359-366
- O'Reilly JE, Maritorena S, Mitchell BG, Siegel DA, Carder KL, Garver SA, Kahru M, McClain C (1998) Ocean color chlorophyll algorithms for SeaWiFS. *Journal of Geophysical Research-Oceans*, 103(C11): 24937-24953.
- Rumelhart DE, Hinton GE, Williams GE (1986) Learning representations by back-propagating errors. *Nature* 323: 533-536
- Scardi M (1996) Artificial neural networks as empirical models of phytoplankton production. *Mar Ecol Prog Ser* 139: 289-299
- Scardi M, Harding LW (1999) Developing an empirical model of phytoplankton primary production: a neural network case study. *Ecol Modell* 120: 213-223