

PREVISIONI A SCALA MENSILE DELLE PRECIPITAZIONI DELLA CITTÀ DI UDINE: CONFRONTO TRA MODELLI STOCASTICI DI TIPO TARSO E MODELLI A RETI NEURALI

MARIO CESCHIA E VALENTINO PIETROBON

Dipartimento di Fisica, Università di Udine, Udine (Italy)

Abstract: In this paper a comparison between stochastic TARSO (Threshold Autoregressive Open System) and neural network models has been carried out with the aim to evaluate their ability to forecast the monthly rainfall, in particular considering the case of the town of Udine in the region of Friuli-Venezia Giulia (Italy). In a previous paper (Ceschia and Beltrame, 1994) a monthly rainfall forecasting model for both the town of Udine and its surrounding plains, by using TARSO stochastic models, has been already presented. The neural network model is based on a feedforward architecture with logistic transfer function and two hidden layers. For training the network, the "back propagation" algorithm (Rumelhart *et al.*, 1986) and the mean squared error (MSE) over the training samples (as the objective function) were used. The choice of the best architecture was based on genetic algorithms using cross-correlation technique, as to exploit all the available observational data. The following time series of monthly observational data (covering at least a period of thirty years) have been adopted: the rainfalls registered at Udine-Castello, the kinetic energy of the horizontal component of the wind at different pressure levels registered by the sounding balloon of Campofornido (a village 5 km far from Udine), the sunspot series, the Niño indices, and the NAO index. In order to contain the number of input data without wasting information, the F-test has been introduced to select the more relevant variables. By comparison, utilizing the two considered methods, it appears that the TARSO models give, at least at this stage of the development, lightly better results than those obtained from the explored neural networks in this work. Notwithstanding, by the neural networks better results for some anomalous months characterized by particularly large precipitations has been obtained. Despite its preliminary stage, both approaches represent a first useful attempt to forecast the monthly precipitations at a reasonable degree of confidence, in a range of forecasting where the involved difficulties are relevant.

Riassunto: In questo lavoro sono stati confrontati un modello stocastico di tipo TARSO (Threshold Autoregressive Open System) e un modello a rete neurale al fine di valutare l'efficacia dei modelli statistici per la previsione delle precipitazioni mensili, considerando in particolare il caso della città di Udine. In un precedente lavoro (Ceschia and Beltrame, 1994) è già stato presentato un modello TARSO di previsione delle piogge mensili per la città di Udine e le pianure circostanti. Il modello a reti neurali è basato su un'architettura *feedforward* con funzione di trasferimento logistica e due strati di nodi nascosti. Per l'apprendimento è stato usato l'algoritmo di *backpropagation* (Rumelhart *et al.*, 1986), usando come funzione obiettivo

l'errore medio quadratico sui campioni di apprendimento. La scelta della migliore architettura è effettuata mediante l'utilizzo di algoritmi genetici e l'uso della tecnica di *cross-correlation* al fine di sfruttare tutti i dati a disposizione. Sono state usate le seguenti serie di dati osservazionali mensili (relative ad un periodo di almeno trent'anni): le precipitazioni registrate a Udine-Castello, l'energia cinetica della componente orizzontale del vento registrata a diversi livelli di pressione dal pallone sonda di Campoformido (un paese a 5 km da Udine), la serie delle macchie solari, gli indici Niño e l'indice NAO. Per limitare il numero di ingressi senza perdita d'informazione è stato introdotto l'F-test come criterio di selezione delle variabili più rilevanti. Dal confronto dei due metodi risulta che i modelli TARSO forniscono risultati leggermente migliori di quelli ottenuti con le reti neurali. Ciò nonostante, con le reti neurali sono stati ottenuti risultati migliori per alcuni mesi anomali caratterizzati da valori di precipitazione molto elevati. Entrambi gli approcci rappresentano un primo concreto tentativo di prevedere le precipitazioni mensili con un ragionevole grado di attendibilità ad una scala di previsione dove le difficoltà sono notevoli.

1. Introduzione

Come è già ben noto, le piogge di una regione sono uno dei parametri principali che influenzano il clima, e in generale esse risultano molto variabili nello spazio e nel tempo. E' evidente la necessità di una previsione accurata delle precipitazioni di una data località non solo per le attività umane ma anche per la ricerca delle leggi che spiegano il fenomeno. Invero, per un dato sistema, la conoscenza delle leggi che lo governano o almeno la scoperta di forti regolarità empiriche nei dati osservazionali rappresentano lo strumento più efficace per la previsione delle piogge.

Tuttavia, a causa della complessità intrinseca del fenomeno e l'alta casualità del processo delle precipitazioni, accanto alla molteplicità e alla grande non linearità dei processi strumentali coinvolti, si possono ottenere alcuni risultati abbastanza soddisfacenti mediante l'utilizzo di metodi statistici, o usando modelli stocastici non lineari o modelli a reti neurali.

Un primo tentativo di prevedere le piogge mensili di Udine e quelle della Pianura circostante, avvalendosi della tecnica dei modelli stocastici tipo TARSO (Threshold AutoRegressive Open System), è già stato presentato in un precedente lavoro, utilizzando dapprima come processo associato l'energia cinetica della componente orizzontale del vento a 500 hPa sopra Cremona e poi quella sopra Campoformido nei pressi di Udine.

In questo lavoro è stato approfondito e perfezionato tale approccio, considerando alternativamente come processo associato sia l'energia cinetica della componente orizzontale del vento a 500 hPa che quella a 850 hPa sopra Campoformido. Inoltre, ci si è avvalsi di un modello a reti neurali artificiali di tipo *Perceptron Multilayer* per la sua maggiore elasticità e potenzialità nell'inglobare informazione (al fine di poter comprendere più compiutamente possibile i vari processi che possono influenzare il fenomeno principale). Invero, a differenza di quanto succede per i modelli TARSO, per cui è molto faticoso (dal punto di vista computazionale) inserire più di un processo associato simultaneamente o più soglie per controllare il processo principale, nei modelli a reti neurali (al di là della base concettuale differente su cui essi sono

impostati) ciò è reso possibile anche dalla maggiore elasticità e semplicità degli algoritmi coinvolti.

Ricordiamo che i modelli stocastici non lineari vennero introdotti la prima volta da Tong (Tong, 1983) per superare alcuni tipici difetti dei modelli autoregressivi lineari, quali ad esempio l'incapacità di spiegare improvvisi salti di grande ampiezza ad intervalli di tempo irregolari o fenomeni ciclici con forti asimmetrie e grande variabilità, ecc. D'altra parte, nonostante i grandi progressi compiuti in questi ultimi anni nel loro sviluppo, una formulazione del tutto soddisfacente non è stata ancora ottenuta a causa delle semplificazioni spesso introdotte nello stadio della modellizzazione, ad esempio omettendo parametri che sono sconosciuti o che non sembrano influenzare direttamente i dati osservati. Inoltre, i legami tra i parametri conosciuti ed i valori osservati possono soltanto essere ipotizzati, in quanto leggi non semplici governano il loro mutuo comportamento. Perciò, si ricorre sempre più spesso all'approccio delle reti neurali per ottenere modelli non lineari di serie temporali multivariate. Invero le reti neurali appartengono alla classe degli approcci governati dai dati (*data-driven*) in contrapposizione all'approccio governato dal modello (*model-driven*).

Il modello considerato è basato su un'architettura di tipo *feedforward* con funzione di trasferimento a sigmoide. Per addestrare la rete viene utilizzato l'algoritmo di *backpropagation* (Rumelhart *et al.*, 1986), con funzione obiettivo espressa attraverso l'errore quadratico medio (MSE) sulle configurazioni di apprendimento. La scelta della migliore architettura è effettuata mediante l'uso di algoritmi genetici e la tecnica di *cross-correlation* in modo da poter sfruttare nella fase d'apprendimento tutti i dati osservazionali disponibili.

Le serie temporali mensili utilizzate sono relative ad almeno trent'anni di dati e comprendono il processo principale ed alcuni processi strumentali globali, e cioè:

- le precipitazioni registrate a Udine-Castello all'Osservatorio "Malignani";
- l'energia cinetica della componente orizzontale del vento a diversi livelli di pressione ottenuta dalle registrazioni del pallone sonda dell'Aeronautica Militare sopra Campoformido;
- la serie delle macchie solari;
- l'indice di oscillazione australe (SOI);
- le serie delle temperature alla superficie del mare (SST) relative ad El Niño;
- l'oscillazione del Nord Atlantico (NAO).

Al fine di limitare il numero di ingressi privi di informazione rilevante o ridondanti sono stati adottati il metodo dell'F-test e talora anche l'analisi in componenti principali (PCA).

In questo lavoro è stato realizzato un primo tentativo confrontare le previsioni a scala mensile delle piogge ottenute con i modelli TARSO e quelle con i modelli a reti neurali, al fine di valutare se quest'ultimo approccio risulti più praticabile ed efficace di quello in parte già collaudato dei modelli stocastici di tipo TARSO.

Per quanto concerne lo stato attuale di sviluppo della ricerca, dal confronto dei due modelli applicati al caso particolare di Udine, risulta che in generale i modelli TARSO forniscono risultati leggermente migliori di quelli ottenuti con le reti neurali. D'altra parte, è importante osservare che le reti neurali sembrano fornire previsioni più precise per alcuni mesi particolarmente anomali e caratterizzati da valori di precipitazione molto elevati. Entrambi i modelli considerati in questo lavoro, nonostante lo stadio ancora preliminare dello studio, rappresentano comunque un primo concreto

approccio alla risoluzione del difficile problema della previsione delle precipitazioni a scala mensile con un ragionevole grado di attendibilità.

2. I modelli SETAR e i modelli TARSO

L'idea che sta alla base dei modelli a soglia consiste nell'interpretare un dato processo $\{X_t\}$ con un modello lineare, ad esempio del tipo AR, nel quale però i parametri dipendano da un numero finito di valori passati di $\{X_t\}$, o da un numero finito di valori passati di un processo associato $\{Y_t\}$.

Un'importante proprietà dei modelli a soglia è la loro capacità, sotto opportune condizioni, di interpretare fenomeni a ciclo limite. Ciò significa che questi modelli possono essere utilizzati per descrivere fenomeni ciclici senza dover ricorrere per forza ai più rigidi metodi classici, basati sulla sovrapposizione di una componente ciclica e di un residuo stazionario di tipo lineare. In particolare se la serie temporale in esame presenta un andamento ciclico caratterizzato da una forma asimmetrica (suggerendo così la mancanza della proprietà di tempo reversibilità), allora un modello non-lineare ne fornisce certamente una rappresentazione migliore.

Tra i modelli a soglia, quello più comunemente adottato assume la forma

$$X_t = a_0^{(i)} + \sum_{j=1}^{k_i} a_j^{(i)} \cdot X_{t-j} + e_t^{(i)} \quad \text{se } X_{t-d} \in R^{(i)},$$

con $i=1,2,\dots,l+1$, k_1, k_2, \dots, k_l gli ordini delle autoregressioni per le l regioni $R^{(i)}$ ed il parametro di ritardo d (*delay*) definisce l'istante di tempo passato utilizzato per confrontare il valore corrispondente con le soglie. Tale modello viene chiamato *SETAR*(l, k_1, k_2, \dots, k_l) (*Self-Exciting Threshold AutoRegressive model*).

Tong ha esteso la classe dei modelli a soglia per includere i casi in cui la scelta tra i differenti insiemi di valori dei parametri è determinata da un valore passato di un processo associato $\{Y_t\}$, piuttosto che da un valore passato di $\{X_t\}$ e compaiono nella relazione autoregressiva pure i termini riferiti al processo associato. Il modello che ne risulta è il seguente

$$X_t = a_0^{(i)} + \sum_{j=1}^{m_i} a_j^{(i)} \cdot X_{t-j} + \sum_{j=0}^{m'_i} b_j^{(i)} \cdot Y_{t-j} + e_t^{(i)} \quad \text{se } Y_{t-d} \in R^{(i)},$$

con $i=1,2,\dots,l+1$ e viene chiamato *TARSO*($l, (m_1, m'_1), \dots, (m_{l+1}, m'_{l+1})$) (*Threshold AutoRegressive System Open loop*). A volte può essere più efficace introdurre esclusivamente i termini autoregressivi del processo associato $\{Y_t\}$ e lasciare che la soglia discrimini sui valori del processo principale $\{X_t\}$.

Ricordiamo che tra i prerequisiti fondamentali per l'analisi ci sono la gaussianità e la stazionarietà delle serie osservazionali. D'altra parte, per la scelta della tipologia del modello e la sua formulazione esplicita, è indispensabile inoltre analizzare ulteriormente la struttura dei processi, al fine di cogliere altre caratteristiche importanti (quali la non linearità, il contenuto spettrale, eventuali ciclicità, tempo reversibilità, ecc.).

La verifica della bontà dei modelli avviene attraverso l'analisi dei residui (test di rumore bianco, test di normalità e verifica dei contenuti spettrali della serie osservazionale e di quelle realizzate dal modello).

3. Modello a rete neurale

La particolare rete adottata è una RNA di tipo *perceptron multistrato*, un modello gerarchico di tipo *feedforward* formato dagli strati dei nodi di ingresso e di uscita oltre che da un numero variabile di strati interni detti strati nascosti o *hidden layers*, dove le uscite dei nodi di uno strato vengono utilizzate come ingressi nello strato successivo.

Nel *perceptron* di Rosenblatt, la non derivabilità della funzione di attivazione non permetteva di introdurre per il *perceptron multistrato* una regola di apprendimento di cui si potesse dimostrare la convergenza. La difficoltà è stata superata utilizzando funzioni semilineari a soglia (derivabili ovunque) quali la funzione *sigmoide*.

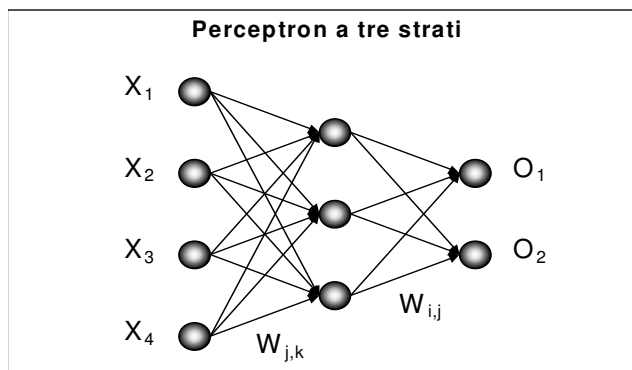


Figura 1 – Perceptron multistrato con un unico strato nascosto.

L'apprendimento avviene utilizzando quale regola per aggiornare i pesi delle connessioni un processo di propagazione all'indietro di tipo supervisionato, detto *backpropagation*. L'algoritmo relativo calcola l'errore compiuto dalla RNA sui nodi di uscita, come differenza tra i valori calcolati e i valori delle configurazioni di apprendimento e successivamente modifica i pesi, strato dopo strato fino allo strato di ingresso, in modo tale da minimizzare l'errore. Il tipo di errore considerato è l'Errore Quadratico Medio (Mean Square Error) espresso dalla formula

$$E_{MSE} = \frac{1}{2 \cdot M \cdot m^{OUT}} \cdot \sum_{P=1}^M \sum_{i=1}^{m^{OUT}} (T_i^P - o_i^P)^2,$$

dove M è il numero dei casi, m^{OUT} è il numero dei nodi di uscita, T_i^P è il valore atteso sul nodo i -esimo di uscita per il caso di apprendimento P -esimo e o_i^P è il valore corrispondente, prodotto sul nodo di uscita i -esimo.

L'algoritmo di *backpropagation* è probabilmente l'algoritmo di apprendimento più utilizzato nelle applicazioni delle RNA.

Nelle applicazioni delle reti neurali a problemi reali è indispensabile in generale conoscere sia le caratteristiche dei dati a disposizione (come la quantità di dati disponibili, il loro andamento nel tempo, la qualità dell'informazione contenuta (sua rilevanza ai fini del problema ed eventuale ridondanza), la rappresentazione numerica utilizzata, ecc.), sia quelle dei vari modelli di reti per poter scegliere tra di essi quello più adatto. L'opzione per un dato modello è determinata da molti fattori, tra cui la capacità di trattare il tipo di informazione a disposizione per risolvere il problema, l'attuale conoscenza teorica e l'esperienza già maturata da altri, l'efficacia degli algoritmi di apprendimento, l'architettura interna, ecc.

Molte volte è tuttavia indispensabile effettuare anche un ulteriore pre-filtraggio dei dati a disposizione in modo da mantenere soltanto quelli più efficaci per la risoluzione del problema, eventualmente rappresentandoli pure nel formato più conveniente. A tal fine, in questo lavoro è stato adottato per l'operazione di pre-filtraggio lo strumento statistico dell'F-test.

4. I dati

Un modello di previsione delle precipitazioni mensili di un dato sito è tipicamente basato sull'andamento delle precipitazioni passate (solitamente le precipitazioni mensili degli ultimi 30-40 anni), nonché sull'uso di alcuni processi strumentali quali il vento in quota e altri parametri che possono influenzare a scala globale le precipitazioni, quali le macchie solari, le oscillazioni quasi-biennali, le eruzioni vulcaniche, il fenomeno di El Niño, le oscillazioni del Nord Atlantico, ecc.

I modelli di previsione delle piogge mensili per la città di Udine presentati in questo lavoro utilizzano le seguenti serie temporali:

- la serie storica delle precipitazioni mensili di Udine-Castello dell'Osservatorio Malignani relativa al periodo 1964-1997;
- la serie storica delle precipitazioni mensili di Udine-Città registrata dal Servizio Idrografico Nazionale relativa al periodo 1964-1997;
- le serie storiche dell'energia cinetica della componente orizzontale del vento alle quote di 500 e 850 hPa, ottenute dalle registrazioni del pallone sonda di Campofornido dell'Aeronautica Militare relative al periodo 1964-1997;
- l'indice mensile delle macchie solari pubblicato dal SIDC (*Sunspot Index Data Center*) relativo al periodo 1954-1997;
- gli indici della temperatura alla superficie dell'Oceano Pacifico Australe relativi al fenomeno di El Niño pubblicati dal NCEP e relativi al periodo 1960-1997;
- l'indice mensile dell'Oscillazione di pressione alla superficie dell'Oceano Pacifico Australe (*Southern Oscillation Index*) pubblicati dal NCEP e relativo al periodo 1960-1997;
- l'indice mensile dell'Oscillazione di pressione alla superficie del Nord Atlantico (*North Atlantic Oscillation Index*) pubblicati dal NOAA e relativo al periodo 1960-1997.

5. I risultati

Per quanto concerne i modelli TARSO più interessanti tra quelli esaminati e con l'energia cinetica della componente orizzontale del vento al livello di 850 hPa quale processo associato, nel seguito sono riportati i valori dei loro parametri con i rispettivi errori. In particolare, nella Tabella 1 sono riportati l'ordine massimo dei rami dei modelli, il valore della soglia, il numero degli eventi interpretati dai due rami e la varianza residua totale (*pooled*).

Tabella 1 – Parametri riassuntivi dei modelli TARSO migliori con soglia applicata al processo associato dell'energia cinetica a 850 hPa (che hanno soddisfatto i test dei residui). I modelli considerati comprendono anche il parametro b_0 e sono stati ordinati rispetto all'errore RMS ottenuto sulle previsioni di orizzonte 1 negli anni 1996-1997.

Parametro di ritardo	Ordine del processo principale	Ordine del processo associato	Valore della soglia	N° dati nel 1° ramo	N° dati nel 2° ramo	Varianza Totale	Errore RMS previsioni orizzonte 1
26	11	10	3.1	63	295	43.9	62.0
12	11	10	3.0	61	311	44.5	65.7
31	11	10	4.0	119	234	42.9	66.0
3	11	10	5.5	245	128	46.7	67.8
10	11	10	6.2	285	88	44.2	68.8
7	11	10	5.4	240	133	45.3	68.8
...

Considerando quale intervallo di previsione il periodo 1996-1997, il più promettente tra quelli calcolati sembra essere il modello TARSO con coefficiente b_0 e

soglia ritardata di 26 mesi (*delay*), applicata al processo dell'energia cinetica (Tabella 2). Invero, il periodo in cui si effettua la stima delle previsioni gioca un ruolo piuttosto importante sulla bontà delle previsioni stesse. Pertanto è conveniente in generale, al fine di costruire il modello più efficace, stimare la sua bontà nei mesi più vicini a quelli della previsione reale e comunque per un periodo non troppo breve (almeno 2 anni).

Tabella 2 – Modello TARSO con b_0 e soglia con parametro di ritardo $d = 26$, applicata all'energia cinetica a 850 hPa.

	Ramo inferiore	Ramo superiore
Processo principale	$a_3^{(1)} = 0.29 \quad \pm 0.11$ $a_4^{(1)} = -0.35 \quad \pm 0.11$ $a_5^{(1)} = -0.32 \quad \pm 0.13$	$a_0^{(2)} = 18.62 \quad \pm 3.83$ $a_1^{(2)} = -0.07 \quad \pm 0.05$ $a_2^{(2)} = 0.08 \quad \pm 0.05$ $a_4^{(2)} = -0.09 \quad \pm 0.05$ $a_6^{(2)} = -0.08 \quad \pm 0.05$ $a_7^{(2)} = -0.13 \quad \pm 0.05$ $a_8^{(2)} = -0.11 \quad \pm 0.05$
Processo associato	$b_0^{(1)} = 2.82 \quad \pm 0.43$ $b_4^{(1)} = 1.34 \quad \pm 0.49$ $b_6^{(1)} = 0.10 \quad \pm 0.05$ $b_{10}^{(1)} = 1.16 \quad \pm 0.40$	$b_0^{(2)} = 1.33 \quad \pm 0.26$ $b_2^{(2)} = -0.40 \quad \pm 0.25$ $b_6^{(2)} = 0.87 \quad \pm 0.26$ $b_7^{(2)} = 0.53 \quad \pm 0.26$ $b_{10}^{(2)} = -0.95 \quad \pm 0.24$ $b_{11}^{(2)} = 0.43 \quad \pm 0.25$
Varianze	$\sigma_e^{(1)2} = 37.9$	$\sigma_e^{(2)2} = 45.1$
N° dati	63	295
Parametro di ritardo	$d = 26$	
Varianza totale	$\sigma_e^2 = 43.9$	
Valore della soglia	$r = 3.1$	

Un confronto per il periodo 1996-1997, tra i valori osservati delle precipitazioni mensili, le previsioni di orizzonte 1, le medie normali climatologiche del periodo 1964-1995, è illustrato in Figura 2.

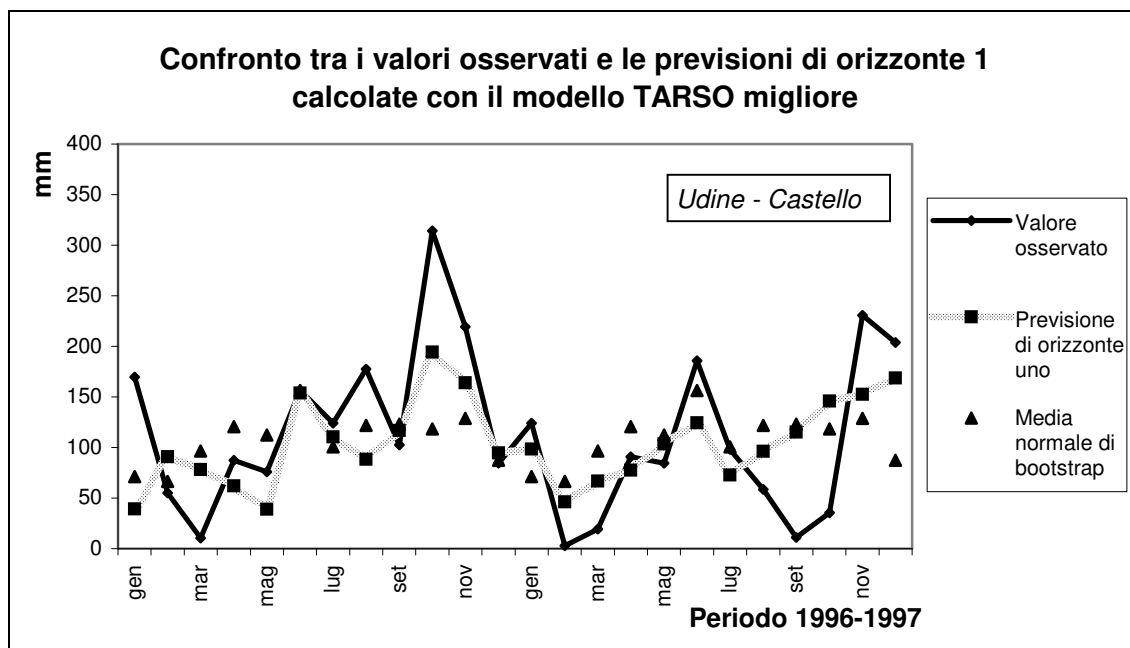


Figura 2 – Confronto tra i valori osservati delle precipitazioni mensili nel periodo 1996-1997 e le previsioni di orizzonte 1 ottenute dal modello migliore.

In conclusione, volendo confrontare diverse modalità per la determinazione della previsione migliore, in Tabella 3 sono riportati l'errore RMS (*Root Mean Square*) della media normale (relativamente ai valori osservati), quello della media delle previsioni dei modelli (che hanno superato i test di verifica di bontà), quello ottenuto da quest'ultimi scegliendo mese per mese, tra le previsioni dei differenti modelli, quella con il range di errore più piccolo ed infine quello relativo al modello migliore.

Tabella 3 – Tabella riassuntiva degli errori RMS calcolati confrontando le precipitazioni osservate con le medie normali di Bootstrap, le previsioni medie dei modelli validati, le migliori previsioni mensili di quest'ultimi e le previsioni del modello migliore. Sono considerati per confronto i due casi relativi ad errori dei parametri dei modelli fino al 100% e al 50% del loro valore.

Tipo di previsione	Errore RMS 1996-1997 taglio al 100%	Errore RMS 1996-1997 taglio al 50%
Medie normali di Bootstrap	75.5	75.5
Media dei modelli	Non calcolato	69.5
Migliore previsione valutata sulla base del range di errore dei modelli	68.5	73.0
Modello (soglia applicata al processo associato con delay = 26 e considerando il coefficiente b_0)	62.0	67.4

Per quanto riguarda le previsioni con i modelli a reti neurali, il problema più delicato affrontato nella fase di apprendimento della rete è stato quello della selezione più opportuna dell'informazione da utilizzare all'ingresso della rete. Infatti, dando in ingresso sic et simpliciter tutta l'informazione disponibile, la convergenza della rete risultava piuttosto difficile a causa dell'eccessivo rumore contenuto nei dati.

Gli ingressi utili sono stati selezionati in modo da prendere in considerazione tutti i processi analizzati, nonché scegliendo tra le variabili ritardate quelle risultate più significative all'F-test (al livello di significatività del 95%).

I dati utilizzati sono limitati al periodo che va dal 1965 al 1997 (per un totale di 396 mesi), gli altri servono per il calcolo delle variabili ritardate. Di essi, gli anni 1996 e 1997 sono stati riservati per verificare la bontà della previsione, mentre con i rimanenti 372 (utilizzando la tecnica della validazione incrociata a 12 raggruppamenti) sono stati costruiti 12 insiemi d'apprendimento e altrettanti insiemi di test con i quali poter valutare l'errore di generalizzazione. Con tali insiemi è stata effettuata una prima esplorazione per la valutazione del numero di nodi più efficace per i due strati nascosti considerati. L'esplorazione condotta su una regione di architetture, delimitata da 20 a 100 nodi per il primo strato nascosto e da 5 a 17 per il secondo, ha indicato al suo interno tre regioni significative, localizzate attorno ai punti (47, 11), (65, 11), (74, 9).

Utilizzando l'insieme di validazione relativo ai valori delle precipitazioni dei 24 mesi corrispondenti agli anni 1996-1997 con le 12 reti ottenute con il processo di ottimizzazione genetica, sono state determinate altrettante previsioni, la cui media è riportata in Figura 3. Si può notare come per alcuni mesi particolarmente anomali (caratterizzati da picchi di precipitazione molto marcati) le previsioni risultino piuttosto soddisfacenti, nonostante alcuni insuccessi in periodi con scarsa piovosità.

Lo strumento di sviluppo utilizzato è il "BrainMaker" della California Scientific Software.

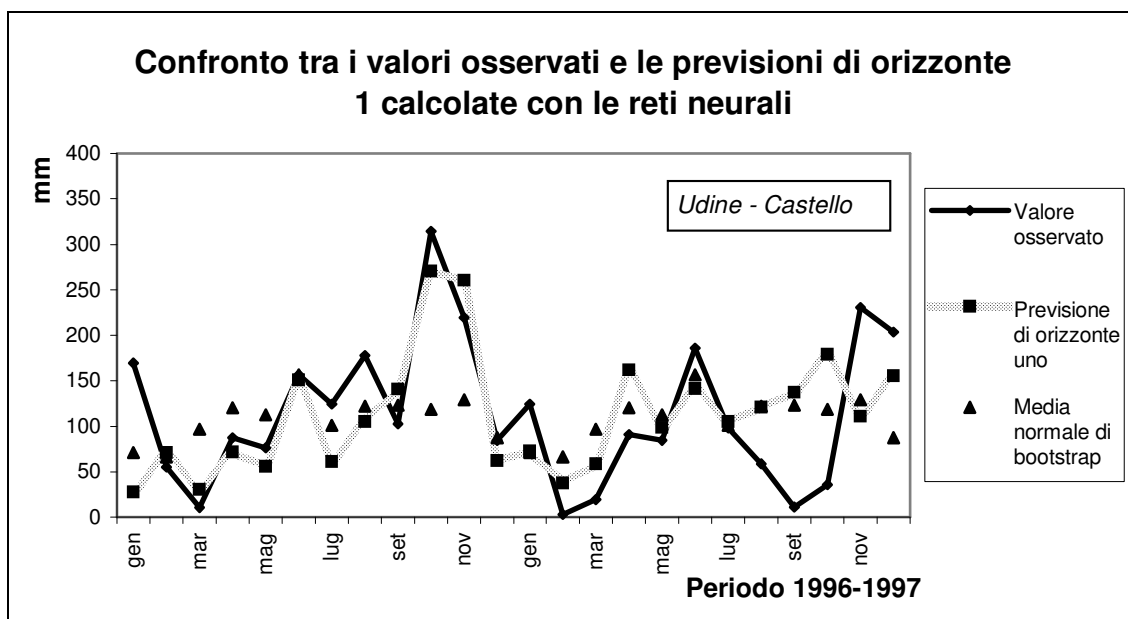


Figura 3 – Confronto tra i valori osservati delle precipitazioni negli anni 1996 e 1997, la media normale di bootstrap e la media delle previsioni di orizzonte 1 delle reti ottenute con la correlazione incrociata e l'ottimizzazione genetica.

In Tabella 4 sono riportati i RMSE corrispondenti alle previsioni basate sulle reti nonché l'errore corrispondente ai valori normali del periodo 1964-1995.

Tabella 4 – Tabella riassuntiva dei RMSE calcolati confrontando le precipitazioni osservate con le medie normali, le previsioni medie dei modelli e le migliori previsioni dei modelli.

<i>Tipo di previsione</i>	<i>RMSE 1996-1997</i>
<i>Media normale</i>	75.5
<i>Media delle reti neurali</i>	66.4

6. Conclusioni

Mentre da un lato le reti neurali (a differenza dei modelli TARSO) permettono l'utilizzo simultaneo di più processi associati (accanto a quello principale), la mancanza di un robusto supporto formale e la difficoltà nel controllo dei numerosi parametri (che le caratterizzano e ne influenzano il comportamento) rendono il loro utilizzo ai fini delle previsioni più delicato e problematico. Tuttavia, pare di intravedere nei risultati ottenuti con le reti (anche a questo stadio dello sviluppo del modello) una maggiore capacità di riprodurre certi balzi improvvisi alternati da periodi di siccità che hanno caratterizzato tipicamente l'andamento delle piogge nei 24 mesi del periodo 1996-97 preso in considerazione per effettuare le proiezioni.

Per quanto concerne in particolare la scelta dell'informazione all'ingresso della rete, è emersa l'efficacia dell'F-test (rispetto all'uso del più semplice indice di correlazione) nella selezione delle variabili più significative. Tuttavia rimane ancora molta incertezza nella definizione del livello di confidenza più conveniente per l'accettazione all'F-test. Infatti un livello di accettazione troppo selettivo può produrre una perdita di informazione fondamentale, riducendo in tal modo la capacità predittiva della rete.

Va detto alla fine che il problema della previsione delle precipitazioni mensili è un problema per sua natura molto difficile e non ancora risolto in modo del tutto soddisfacente, per cui è necessario un ulteriore approfondimento di studio sia dei metodi che delle procedure che correntemente sono a disposizione per risolvere il problema.

Bibliografia

Ceschia M. and Beltrame N. (1994), "Previsioni delle Precipitazioni mensili con Modelli stocastici a soglia e Processo associato", in *Proc. of the Intern. Meet. on 'Atmospheric Physics and Dynamics in the Analysis and Prognosis of Precipitations Fields'* Rome, 15-18 Nov. 1994, pp. 365-368.

Rumelhart D. E., Hinton G. E., Williams R. J. (1986), "Learning Internal Representations by Error Propagation," in *Parallel Distributed Processing. Exploration in the Microstructure of Cognition, Vol. 1: Foundations*, MA (USA): MIT Press.

Tong H. (1983), "Threshold Models in Non-linear Time Series Analysis", *Lecture Notes in Statistics*, Vol. 21, Springer, New York.