

STIMA DEL COEFFICIENTE DI RIFLESSIONE ONDOSA MEDIANTE MODELLAZIONE ALLE RETI NEURALI

S. M. Formentin¹, B. Zanuttigh² & R. Briganti³

- (1) Dipartimento di Ingegneria Civile, Ambientale e dei Materiali, Università di Bologna, Italia, e-mail: saramizar.formentin2@unibo.it
(2) Dipartimento di Ingegneria Civile, Ambientale e dei Materiali, Università di Bologna, Italia, e-mail: barbara.zanuttigh@unibo.it
(3) Faculty of Engineering, University of Nottingham, UK, e-mail: riccardo.briganti@nottingham.ac.uk

SOMMARIO

Viene presentata la messa a punto di un modello alle reti neurali finalizzato alla stima del coefficiente di riflessione ondosa relativo a strutture costiere e portuali. Per la realizzazione del modello è stato utilizzato un ampio insieme di dati che racchiude oltre 5000 prove sperimentali a diversa scala. La rete neurale è in grado di elaborare stime predittive del coefficiente di riflessione per svariate tipologie di strutture, caratterizzate da diversa permeabilità e sommergezza, e per molteplici condizioni di attacco ondoso. I risultati della rete riportano errori inferiori a quelli associati alle formule sperimentali che sono state prese a riferimento per un'analisi di sensitività del modello ai parametri idraulici e strutturali in esso introdotti.

1 INTRODUZIONE

L'analisi dell'interazione tra le onde e le strutture costiere e la valutazione della vulnerabilità e resilienza degli argini a mare sono uno strumento fondamentale per la progettazione delle opere e la messa in sicurezza delle zone di battigia o portuali. In particolare, lo studio della riflessione ondosa nasce dall'esigenza pratica di prevenire e risolvere i problemi dell'agitazione ondosa generata all'imbocco di porti e dell'erosione al piede delle strutture che può degenerare nella loro destabilizzazione.

Il parametro di riferimento per la quantificazione dell'energia ondosa riflessa è il coefficiente di riflessione K_r , rapporto tra altezza dell'onda riflessa e altezza dell'onda incidente. Le formule in letteratura che forniscono una stima di K_r sono tutte di derivazione empirica e tendenzialmente affette dal problema di mancanza di generalizzazione a più tipologie di opere e condizioni di attacco ondoso. Un elemento comune ad esse è la dipendenza di K_r dal parametro di frangimento ξ_0 (Battjes, 1974; Seeling & Ahrens, 1981; Postma, 1989; Allsop e Hiettrarchi, 1989; Zanuttigh & Van der Meer, 2006):

$$\xi_0 = \frac{\tan \alpha}{\sqrt{\frac{2\pi H_{m0,t}}{g T_{m-1,0}^2}}}, \quad (1)$$

ove $T_{m-1,0} = m_{-1}/m_0$ è il periodo spettrale d'onda alla base della struttura, $H_{m0,t}$ è l'altezza d'onda significativa al piede della struttura e $\tan \alpha$ rappresenta l'inclinazione della parete a mare della struttura, su cui incide l'onda.

Per ottenere stime di K_r che siano attendibili per intervalli dei valori dei parametri più ampi, può rivelarsi utile l'impiego di metodologie alternative, quale la modellazione alle reti neurali, uno strumento risultato efficace per la rappresentazione della trasmissione e tracimazione (Eurotop 2007).

Con il presente lavoro verrà illustrato proprio un modello alle reti neurali per la stima di K_r : la procedura di messa a punto e il modello stesso (sezione 2), i risultati ottenuti (sezione 3), la validazione e calibrazione del modello, e l'analisi di sensitività ai parametri utilizzati (sezione 4).

2 LA RETE NEURALE PER LA RIFLESSIONE ONDOSA

Tre sono le motivazioni che hanno indotto alla realizzazione di una rete neurale per la modellazione di K_r : la bontà dei risultati ottenuti con la stima della portata di tracimazione e del coefficiente di trasmissione, la necessità di completare tale descrizione dei fenomeni di interazione onda-struttura, eventualmente sintetizzando tutto in un unico modello, e la consapevolezza che le Reti Neurali Artificiali (RNA) sono particolarmente adatte alle analisi di fenomeni dipendenti da molti parametri.

Per la costruzione dell'architettura di rete è stato utilizzato il *software* Matlab.

2.1 Funzionamento concettuale del modello di rete neurale

Una RNA è una "black box" che computa dati sperimentali di *input* e di *output* e apprende, senza conoscere la fisica che sottintende al processo, le relazioni fra essi. Una volta sottoposta ai dati di *input*, la RNA elabora delle connessioni artificiali *input-output*, in base alle quali produce degli *output* predittivi, confronta questi ultimi con i dati di *output* sperimentali e computa l'errore commesso; iterativamente, modifica ad ogni *step* le relazioni assegnate tra *input* e *output* in modo tale che la funzione di errore venga continuamente minimizzata. Il procedimento si arresta quando l'errore commesso nelle previsioni scende sotto una certa tolleranza impostata dall'utente.

La modalità con cui vengono appresi i legami *input-output* è stabilita dai cosiddetti algoritmi di *training* e *learning*, in sostanza le procedure di minimizzazione della funzione di errore. Lo strumento di modifica è costituito dai coefficienti di peso assegnati dal modello stesso alle connessioni fra i neuroni (di *input* e di *output*): variando ad ogni iterazione il valore di tali coefficienti, la rete può predire *output* che risultino sempre più prossimi ai valori sperimentali.

La *black-box* essenzialmente si compone di: *input layer*, che contiene come neuroni gli elementi del vettore di *input*, *output layer* che ha come neurone il parametro (o i parametri) che si desidera stimare (nella fattispecie, K_r), *hidden layer* costituito da neuroni esclusivamente propedeutici al *training* della rete, il cui numero non è definibile se non a valle di operazioni di calibrazione.

2.2 Dati sperimentali per *training* e *learning* della rete

La rete neurale deve soddisfare a due requisiti: da un lato, essere il più possibile versatile per operare con diversi tipi di strutture; dall'altro, fornire stime affidabili di K_r .

Il primo requisito richiede un *database* di "training" vasto ed eterogeneo: per questo

motivo si è partiti dal *database* di riflessione messo a punto da Zanuttigh & Van der Meer (2006) contenente all'incirca 5000 dati. Fig. 1 Le grandezze fondamentali impiegate nella definizione dei parametri di *input* della RNA sono state mutuare dai 34 parametri del *database* di riflessione (illustrati sinteticamente nello schema di Fig. 1); tali grandezze sono di seguito descritte:

- h_f : altezza del fondale ai piedi dell'opera, [m];
- $H_{m0,t}$, $T_{m-1,0}$: altezza d'onda significativa [m] e periodo spettrale [s], calcolati ai piedi dell'opera (le stesse utilizzate per la definizione di ξ_0 (cfr. Eq. 1));
- γ_f : coefficiente di scabrezza del materiale costituente la mantellata, [-];
- $D_{n,50}$: diametro significativo nominale del masso della mantellata esterna, [m]; per le strutture impermeabili lisce, tale valore è stato imposto idealmente 0;
- $\cot \alpha_d$: pendenza della paramento lato mare dell'opera, su cui incide l'onda, [-];
- R_c : sporgenza totale della cresta (comprensiva di eventuale muro paraonde) rispetto al livello del mare, [m];
- RF , CF : “reliability factor” e “complexity factor”, indici di affidabilità e complessità del dato; parametri descrittivi del grado di precisione con cui è stata effettuata la misurazione e della complessità geometrica della sezione trasversale;
- K_r : coefficiente di riflessione, [-].

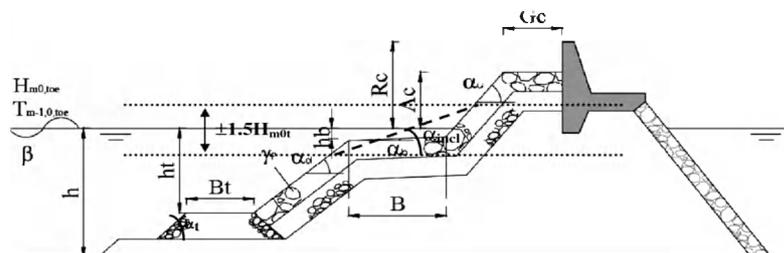


Figura 1 - Parametri strutturali del *database* di riflessione (Zanuttigh & Van der Meer, 2006)

Il secondo requisito della RNA, al contrario, richiede un insieme di dati omogeneo e accurato. Da qui, si pone il problema della selezione dei dati a disposizione, operazione che è stata attuata in due fasi. Si sono eliminate a priori tutte le strutture con sezione trasversale diversa dalla comune sezione trapezia, eventualmente corredata di protezione al piede e strutture composte da elementi particolari come gli *Acquareefs* (oltre 1000 dati), per l'anomalia costituita dalla modalità di dissipazione dell'energia ondosa – legata all'induzione del frangimento delle onde determinata dalla brusca riduzione della profondità del fondale e contestuale aumento della tensione di attrito al fondo. Una seconda selezione dei 2480 dati rimasti è stata quindi effettuata mediante le operazioni di calibrazione della RNA, eliminando alcuni dati individuati come causa di dispersione anomala dei risultati del modello, per un totale complessivo di 2378 dati.

2.3 Parametri di *input*

I parametri di *input* della RNA devono proporre una sintesi delle grandezze meteorologiche e strutturali che governano al fenomeno della riflessione ondosa. La definizione del *set* di parametri di *input* ha avuto come punto di riferimento due tra le più recenti formule di riflessione a disposizione in letteratura: Zanuttigh & Van der Meer, 2006,

$$K_r = \tanh(a \cdot \xi_0^b), \quad (2)$$

ove i coefficienti a e b sono correlati al coefficiente di scabrezza γ_f

$$a = 0.167 \cdot [1 - \exp(-3.2 \cdot \gamma_f)], \quad b = 1.49 \cdot (\gamma_f - 0.38)^2 + 0.86 \quad (3)$$

e Muttray et al., 2006,

$$K_r = \frac{1}{1.3 + 3h \frac{2\pi}{L_{m-1,0,t}}}, \quad (4)$$

applicata a frangiflutto emerso con berma e rivestito di accropodi. Le relazioni (2) e (3) accoppiate forniscono previsioni accurate di K_r , tuttavia esse sono valide solamente nell'ambito delle condizioni di progetto: modesta trasmissione ondosa: $R_c/H_{m0,t} \geq 0.5$; onde incidenti non troppo basse: $H_{m0,t}/D_{n,50} \geq 1.0$; onde incidenti non troppo lunghe: $s_0 \geq 0.01$ (dove s_0 è la ripidità dell'onda relativa al periodo $T_{m-1,0}$).

La (2) e la (4) mostrano dipendenza da grandezze molto diverse, ma elemento comune è la presenza di $L_{m-1,0,t}$ e $T_{m-1,0}^2$, entrambi a “doppio” denominatore (dunque, a numeratore), poiché in acque alte $L_0 \propto T_0^2$. Sulla base di tali relazioni, è stato dunque definito un vettore di *input* a 6 parametri adimensionali, elencati di seguito (fra parentesi quadre, gli intervalli di variazione di ciascun parametro):

- $p_1 = \frac{H_{m0,t}}{L_{m-1,0,t}} = [6.0261 \cdot 10^{-4}; 0.1208]$;
- $p_2 = \frac{h}{L_{m-1,0,t}} = [0.0080; 1.8924]$;
- $p_3 = \frac{R_c}{H_{m0,t}} = [-8.0870; 62.3900]$;
- $p_4 = \tan \alpha = [0.1667; 1.2195]$;
- $p_5 = \gamma_f = [0.3500; 1.0000]$;
- $p_6 = \frac{D_{n,50}}{H_{m0,t}} = [0.0000; 6.5369]$.

2.4 Architettura di rete

La definizione risolutiva dell'architettura della RNA deriva da una serie di prove mirate alla valutazione delle prestazioni, con operazioni di validazione di varia tipologia (descritte nella sezione 4); essa è caratterizzata dalle seguenti strutture fondamentali:

- rete *multilayer* di tipo statica (non sono presenti “*delay*” o “*feedback*”);
- numero di *layer*: 3, di cui un solo *hidden layer*;
- algoritmo di apprendimento di tipo “*feed-forward backpropagation*”;
- numero di neuroni di *input*: 6 (corrispondono ai 6 elementi del vettore di *input*);
- numero di neuroni di *output*: 1, il coefficiente di riflessione K_r ;
- numero di neuroni per l'*hidden layer*: 12 (definito con operazioni di calibrazione);
- funzione di trasformazione per l'*hidden layer*: *tansig*, funzione sigmoide differenziabile che trasforma tutti i dati di *input*, i cui valori numerici possono distribuirsi fra meno e più infinito, in un vettore di valori compresi tra -1 e +1;
- funzione di trasformazione per l'*output layer*: *purelin*, approssimazione lineare degli *output* dell'*hidden layer*, che consente di re-distribuire i valori tra meno e più

- infinito predisponendoli per l'output definitivo;
- algoritmo di *training*: *trainlm* (algoritmo di *Levenberg-Marquardt* (*Levenberg*, 1944 & *Marquardt*, 1963), che sviluppa una velocità di *training* del secondo ordine senza calcolare la matrice Hessiana della funzione di errore);
- algoritmo di *learning*: *learnngdm*;
- modalità di *training*: “*batch training*”, l'aggiornamento dei pesi avviene solo al termine di ciascuna iterazione, dopo che tutti gli *input* sono stati “letti” dalla rete.

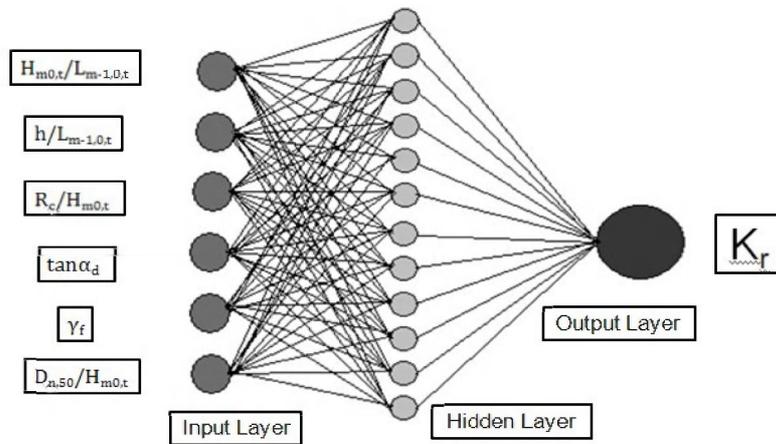


Figura 2. Schema concettuale della RNA di riflessione

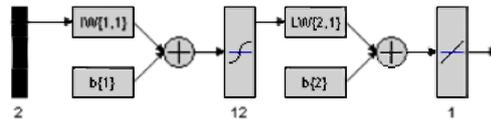


Figura 3. Schema logico sintetico dell'architettura della rete neurale.

3 RISULTATI DELLA RETE NEURALE

In tale sezione vengono riportati e commentati i risultati ottenuti con la rete neurale, in termini di confronto fra i valori di K_r da essa predetti (vettore \mathbf{K}_{rNN}) e valori di K_r sperimentali (vettore \mathbf{K}_{r_s}). L'errore viene computato sia come vettore differenza

$$\mathbf{e} \stackrel{\text{def}}{=} \mathbf{K}_{r_s} - \mathbf{K}_{rNN}, \quad (5)$$

sia come scarto quadratico medio (“*root mean square error, rmse*”) delle medesime differenze fra K_{r_s} sperimentale e K_{rNN} predetto:

$$\text{rmse} \stackrel{\text{def}}{=} \sqrt{\frac{1}{N} \sum_{i=1}^N \left((K_{r_s})_i - (K_{rNN})_i \right)^2}. \quad (6)$$

Un esempio dei risultati in termini di confronto tra \mathbf{K}_{r_s} e \mathbf{K}_{rNN} e di errore \mathbf{e} viene mostrato in Fig. 4. Il valore esatto di *rmse* varia ad ogni simulazione del modello a

seconda delle modalità con cui è stata eseguita la procedura di *training*, oggetto di aleatorietà; in ogni caso, esso risulta mediamente pari a 0.038 e sempre ≤ 0.04 . Tale risultato è particolarmente buono, specialmente se confrontato con quelli delle precedenti formule di riflessione, che forniscono valori di *rmse* di fatto sempre superiori a 0.037 ma sono associate a tipologie di strutture ben definite, e quindi a insiemi di dati più ristretti (Zanuttigh & Van der Meer, 2008).

Parimenti, il valore dell'indice di Willmott (1981) è più che soddisfacente, mantenendosi molto prossimo a 1 e mediamente pari a 0.98: l'errore, pertanto, non è soltanto basso, ma è anche "simmetrico", come del resto sottolineano i due grafici relativi alla distribuzione dell'errore stesso (Figg. 4, destra e 5). Solamente una decina di previsioni differiscono dai dati sperimentali di più del 20% e nessuna più del 25%, in valore assoluto.

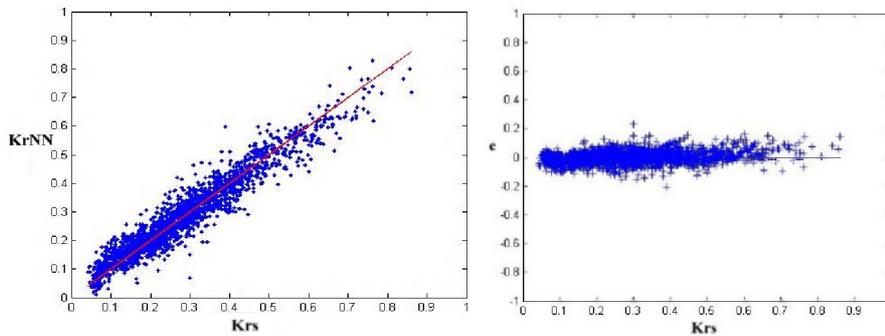


Figura 4. Sinistra: valori sperimentali di K_{rs} (ascissa) e corrispondenti K_{rNN} predetti dalla rete (ordinata); destra: scarto $e \stackrel{\text{def}}{=} K_{rs} - K_{rNN}$ (ordinata) per ciascun K_{rs} (ascissa).

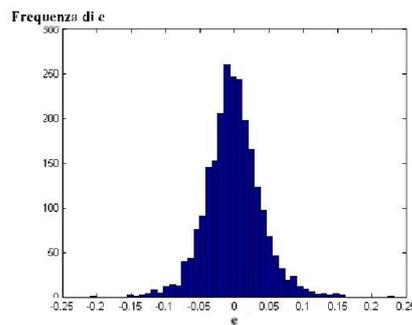


Figura 5. Distribuzione di frequenza dell'errore $e \stackrel{\text{def}}{=} K_{rs} - K_{rNN}$ commesso dalla rete neurale.

Si sottolinea la capacità della rete di fornire tali risultati per opere completamente diverse l'una dall'altra; si rileva, tuttavia, un'incertezza residua nel modello a simulare valori elevati di K_r riconducibili al caso di strutture lisce impermeabili, incertezza responsabile degli errori percentuali maggiori del 20% e dell'asimmetria che affligge il grafico dell'errore agli estremi superiori (Fig. 4, destra).

4 VALIDAZIONE E CALIBRAZIONE DELLA RETE NEURALE E ANALISI DI SENSITIVITÀ

Tanto il *set* di *input* quanto i parametri “interni” caratteristici del modello sono stati definiti e ottimizzati grazie a un’operazione di calibrazione. Per il vettore di *input* sono state sottoposte a prova complessivamente 12 combinazioni (cfr. Tabella 1), con un numero crescente di parametri, da 1 a 5. La combinazione definitiva a 6 parametri (presentata nella sottosezione 2.3, in termini di vettore di *input*, e nella sezione 3, per quanto concerne i risultati ad essa associati) è stata scelta a valle dei risultati ottenuti proprio con tali prove.

Le funzioni e i parametri caratteristici della RNA sottoposti a calibrazione sono riassunti in Tabella 2; il risultato di tali operazioni di calibrazione ha reso possibile la definizione ultima dell’architettura di rete quale mostrata nella sottosezione 2.4.

4.1 Definizione del vettore di *input*

Dalle combinazioni a 2 parametri (cfr. Tabella 1) risulta evidente la maggiore sensibilità a $R_c/H_{m0,t}$ rispetto agli altri parametri, e, al secondo posto, a γ_f rispetto a $\tan \alpha$. Successivamente, a 3 e 4 parametri, la rete sembra leggermente più sensibile a $h/L_{m-1,0,t}$ rispetto a $H_{m,0,t}/L_{m-1,0,t}$. Le simulazioni a 5 parametri confermano quanto già evidenziato. Dunque, i parametri che si ritengono ben definiti sono $R_c/H_{m0,t}$; $\tan \alpha$; γ_f .

Combinazione parametri di <i>input</i>	Errore <i>rmse</i>
$\frac{h}{L_{m-1,0,t}}$	0.12
$\frac{h}{L_{m-1,0,t}}, \tan \alpha$	0.11
$\frac{h}{L_{m-1,0,t}}, \gamma_f$	0.10
$\frac{h}{L_{m-1,0,t}}, \frac{R_c}{H_{m0,t}}$	0.09
$\frac{H_{m,0,t}}{L_{m-1,0,t}}, \gamma_f, \tan \alpha$	0.08
$\frac{h}{L_{m-1,0,t}}, \tan \alpha, \frac{R_c}{H_{m0,t}}$	0.07
$\frac{h}{L_{m-1,0,t}}, \gamma_f, \tan \alpha$	0.07
$\frac{H_{m,0,t}}{L_{m-1,0,t}}, \gamma_f, \tan \alpha, \frac{R_c}{H_{m0,t}}$	0.055
$\frac{h}{L_{m-1,0,t}}, \gamma_f, \tan \alpha, \frac{R_c}{H_{m0,t}}$	0.05
$\frac{H_{m,0,t}}{L_{m-1,0,t}}, \gamma_f, \tan \alpha, \frac{R_c}{H_{m0,t}}, \frac{D_{n,50}}{H_{m,0,t}}$	0.05
$\frac{h}{L_{m-1,0,t}}, \gamma_f, \tan \alpha, \frac{R_c}{H_{m0,t}}, \frac{D_{n,50}}{H_{m,0,t}}$	0.048
$\frac{h}{L_{m-1,0,t}}, \gamma_f, \tan \alpha, \frac{R_c}{H_{m0,t}}, \frac{H_{m,0,t}}{L_{m-1,0,t}}$	0.048

Tabella 1. Combinazioni dei parametri di *input* della RNA e *rmse* associato.

Per $H_{m,0,t}/L_{m-1,0,t}$ e $h/L_{m-1,0,t}$ si rende opportuna una analisi mirata alla loro ridefinizione, valutando sia l’opportunità di sostituire il termine $H_{m,0,t}$ da $H_{m,0,t}/L_{m-1,0,t}$,

dal momento che è già presente sottoforma di altri parametri (R_c/H_{m0r} , $D_{n,50}/H_{m,0,r}$), sia l'effettiva rilevanza della grandezza h per la bontà dei risultati.

Infine, sebbene rimanga indubbia l'essenzialità di $D_{n,50}/H_{m,0,r}$, tale parametro genera alcune problematiche legate alle strutture lisce e impermeabili nel *database*, per le quali la definizione del diametro rappresentativo del materiale è priva di senso. A questo proposito, è stata valutata l'ipotesi di costruire due reti neurali distinte per opere permeabili e impermeabili, come proposto nella sottosezione 4.2 seguente.

4.2 Le opere impermeabili

I risultati ottenuti con la simulazione senza opere impermeabili, che ha comportato l'eliminazione di 275 dati, con una riduzione a 1903 prove residue, dimostrano un miglioramento delle prestazioni della rete sia in termini di *rmse*, mediamente pari a 0.035, sia in termini di simmetria dello scarto e (Fig. 6). Tuttavia, il decremento dell'errore (circa il 10%) non è così rilevante da giustificare la perdita di capacità da parte della rete di simulare anche le strutture lisce e impermeabili. Si è perciò giunti alla conclusione di mantenere il *database* completo e utilizzare come unico il modello originale già presentato della RNA.

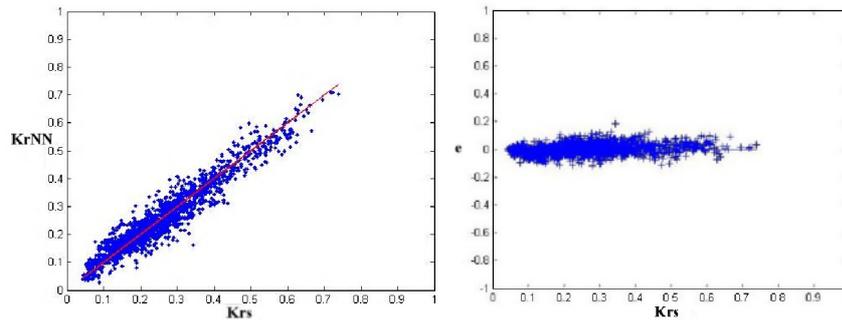


Figura 6. Sinistra: valori sperimentali di K_{rs} (ascissa) e corrispondenti K_{rNN} predetti (ordinata); destra: scarto e (ordinata) per ciascun K_{rs} (ascissa), simulazione senza opere impermeabili lisce.

4.3 Definizione dei parametri interni alla rete neurale

L'ultima fase della calibrazione è consistita nella messa a punto dei parametri intrinseci al modello; essendo la RNA una *black-box*, non è possibile conoscere a priori il valore ottimale da assegnare a tali parametri o la funzione migliore da utilizzare, perciò l'unico strumento a disposizione per la loro definizione è un'analisi dei risultati prodotti al loro variare.

Un momento fondamentale della calibrazione è stato quello relativo alla definizione del numero di *hidden neurons*. Osservando il grafico di Fig. 7 si può dedurre che l'errore decresce in modo esponenziale all'aumentare del numero di neuroni, assestandosi asintoticamente intorno a $rmse \approx 0.04$ per 12 neuroni. Il decremento successivo non diviene più rilevante, perciò si è ritenuto che 12 sia il numero ideale di neuroni dell'*hidden layer*, anche per evitare di complicare eccessivamente l'architettura di rete, creando un numero troppo grande di connessioni. Per tutti gli altri parametri sottoposti a calibrazione è stata effettuata un'analisi del decremento di *rmse* del tutto analoga, di cui si riporta una sintesi in Tabella 2.

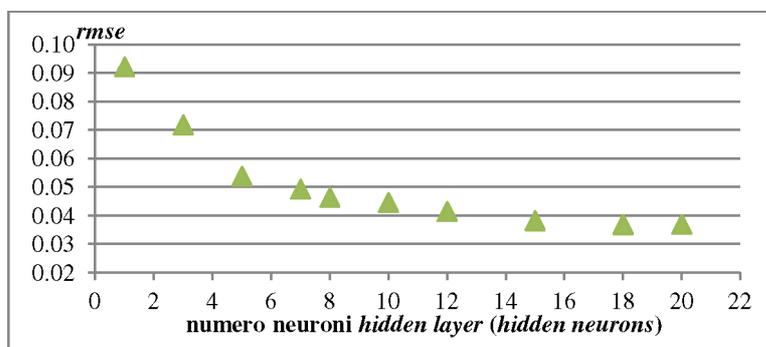


Figura 7. Grafico dell'errore *rmse* (ordinata) in funzione del numero di *hidden neurons* (ascissa).

Parametro	Nr prove effettuate	Valore definitivo assegnato al parametro
Vettore di <i>input</i>	12	$\frac{H_{m,0,t}}{L_{m-1,0,t}}, \frac{h}{L_{m-1,0,t}}, \frac{R_c}{H_{m,0,t}}, \tan\alpha_d, \gamma_P, \frac{D_{n,50}}{H_{m,0,t}}$
Nr. neuroni hidden layer	20	
Algoritmo di <i>training</i>	6 (<i>traingd, traingda, traingdm, trainrp, trainscg, trainlm</i>)	<i>trainlm</i>
Algoritmo di <i>learning</i>	2 (<i>learngd, learngdm</i>)	<i>learngdm</i>
<i>Learning rate</i>	$0.001 \leq lr \leq 1$	0.007
Funzione di trasformazione <i>hidden layer</i>	4 (<i>purelin, logsig, tansig, softmax</i>)	<i>tansig</i>
Funzione di trasformazione <i>output layer</i>	3 (<i>purelin, logsig, tansig</i>)	<i>purelin</i>
Funzione di errore	2 (<i>mse, msereg</i>)	<i>mse</i>

Tabella 2. Parametri del modello di RNA sottoposti a calibrazione

5 CONCLUSIONI

È stato presentato un modello alle reti neurali per la stima predittiva del coefficiente di riflessione ondosa. La architettura della RNA è stata ottimizzata attraverso analisi di sensitività e nella sua veste finale utilizza 6 parametri di ingresso caratteristici della struttura e delle condizioni ondose incidenti, fisicamente basati.

I risultati ottenuti sulla base di quasi 2500 dati sperimentali sono caratterizzati da valori dell'indice di Willmott e di *rmse* rispettivamente pari in media a 0.98 e 0.04. Tali valori denotano una buona accuratezza della RNA anche nei confronti delle formule di letteratura, e rivelano la buona capacità della rete nel rappresentare il comportamento di svariate tipologie di opere permeabili e impermeabili.

Obiettivo di futura ricerca sarà la messa a punto di un procedura di *resampling* dei dati sperimentali (“*bootstrapping*”) per l’introduzione dei coefficienti di peso nel modello, in modo tale da assegnare maggiore rilevanza alle prove a cui è associato un migliore indice di affidabilità.

Il modello può essere esteso alla rappresentazione di strutture dalla sezione trasversale più complessa ed eventualmente associato ad altri modelli alle reti neurali per la stima del coefficiente di trasmissione, per ottenere un metodo predittivo completo della risposta idraulica di una struttura nei termini di interazione con il moto ondoso.

Ringraziamenti. Gli autori ringraziano il supporto della Comunità Europea mediante il progetto THESEUS “Innovative Technologies for safer European coasts in a changing climate” finanziato nell’ambito dell’FP7.ENV2009-1 con contratto 244104, www.theseusproject.eu.

BIBLIOGRAFIA

- Allsop, N.W.H., Hettiarachi, S.S.L. Wave reflections in harbours; the design, construction and performance of wave absorbing structures, Report OD 89. Hydraulics Research, Wallingford, 1989.
- Battjes, J.A. Surf similarity. Proc. XIV Int. Conf. Coastal Eng. ASCE, pp. 466–480, 1974.
- Herman A., Kaiser R., Niemeier H. D. Wind-wave variability in a shallow tidal sea – Spectral modelling combined with neural network methods, Coastal Engineering, 2009. doi:10.1016/j.coastaleng.2009.02.007
- Levenberg K. A method for the solution of certain non-linear problems in least squares, quarterly of applied mathematics 2: 164–168, 1944.
- Marquardt D. An algorithm for least-squares estimation of nonlinear parameters, SIAM Journal on Applied Mathematics 11 (2): 431–441, 1963. doi:10.1137/0111030.
- Muttray M., Oumeraci H., ten Oever E. Wave reflection and wave run-up at rubble mound breakwaters, International Conference of Coastal Engineering, 2006, San Diego.
- Overtopping Manual, In: Pullen, T., Allsop, N. W. H., Bruce, T., Kortenhaus, A., Schüttrumpf, H., van der Meer, J. W. (Eds.). Wave overtopping of sea defences and related structures – Assessment Manual, 2007. www.overtopping-manual.com.
- Panizzo, A., Briganti, R. Analysis of wave transmission behind lowcrested breakwaters using neural networks, Coastal Engineering, 2007, 54 (9), 643–656. doi:10.1016/j.coastaleng.2007.01.001
- Postma, G.M. Wave reflection from rock slopes under random wave attacks, PhD thesis, Delft University of Technology, 1989.
- Seelig, W.N., Ahrens, J.P. Estimation of wave reflection and energy dissipation coefficients for beaches, revetments and breakwaters. CERC Technical paper 81-1, Fort Belvoir, U.S.A.C.E. MS, 1981, Vicksburg.
- Van Gent M. R. A., Pozueta B., Van den Boogaard H. F. P., Medina J. R. Neural network modelling of wave overtopping at coastal structures, Coastal Engineering, 2007. doi:10.1016/j.coastaleng.2006.12.001
- Verhaeghe H., De Rouck J., van der Meer J. Combined classifier-quantifier model: A 2-phases neural model for prediction of wave overtopping at coastal structures, Coastal Engineering, 2008. doi:10.1016/j.coastaleng.2007.12.002
- Willmott, C. J. On the validation of models. *Physical Geography* 2, 1981: 184-194.
- Zanuttigh B., van der Meer J. W. Wave reflection from coastal structures in design conditions, Coastal Engineering, 2008. doi:10.1016/j.coastaleng.2008.02.009