

LE RETI NEURALI ARTIFICIALI IN IDRAULICA MARITTIMA

S.M. Formentin⁽¹⁾, B. Zanuttigh⁽²⁾,

- (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

1 Introduzione

Le reti neurali artificiali (*Artificial Neural Networks*, ANN) sono algoritmi di analisi dati e di modellazione numerica. Vengono dette “*data driven models*”, ossia modelli di calcolo basati sul processamento di dati – ottenuti sperimentalmente o prodotti artificialmente – al fine di testare la sensibilità di un certo fenomeno ad alcuni parametri.

Le ANN sono particolarmente utili nelle analisi di fenomeni in cui il numero di parametri in gioco è molto elevato, e le relazioni fisiche tra essi sono fortemente non lineari e molto complesse. Dal punto di vista della tipologia di modellazione, le ANN costituiscono una “*black-box*”, dunque l’algoritmo di calcolo prescinde completamente dallo studio del fenomeno fisico che sta alla base della relazione di causa-effetto tra dati di input e di output; pertanto, le ANN sono in grado di elaborare i dati sperimentali a disposizione (input) e produrre delle predizioni dei valori desiderati (output), ricostruendo artificialmente gli effetti della complessa relazione di causa-effetto incognita.

Essenziale, ai fini di una buona modellazione mediante reti neurali, è il poter disporre di un database numericamente consistente e affidabile di valori sperimentali. L’accuratezza e attendibilità dei risultati di una rete neurale dipendono proprio dalla precisione dei dati di input, che non fungono solo da punto di partenza del modello, ma costituiscono lo strumento interno di calibrazione e validazione del modello stesso.

Obiettivo di tale lavoro è esaminare la struttura caratteristica di una rete neurale e proporre alcuni esempi di ANN impiegati per la modellazione della portata di tracimazione e del coefficiente di trasmissione di strutture costiere, per sottolineare l’adeguatezza di tali strumenti all’impiego in idraulica marittima e presentarli per eventuali successivi utilizzi, quali, ad esempio, la stima del coefficiente di riflessione ondosa, ad oggi non ancora modellato accuratamente.

2 Struttura di una rete neurale

Le reti neurali sono composte da singoli elementi che operano in parallelo tra loro. La struttura e il modo di operare di tali elementi sono ispirati ai sistemi nervosi biologici: come in natura, le funzionalità di una rete sono largamente determinate dalle connessioni che si stabiliscono fra i suoi elementi. Da tale concetto, nasce l’idea di “insegnare” ad una rete neurale come simulare un determinato fenomeno fisico e come riprodurre una particolare funzione aggiustando i valori dei coefficienti di peso assegnati alle connessioni fra gli elementi.

Comunemente, le reti neurali sono “addestrate” in modo che, se sollecitate da un preciso input, siano in grado di produrre un output che corrisponda al valore atteso per quell’input.

Per comprendere meglio in che cosa consista l’astrazione di una rete neurale, si osservi la seguente rappresentazione schematica:

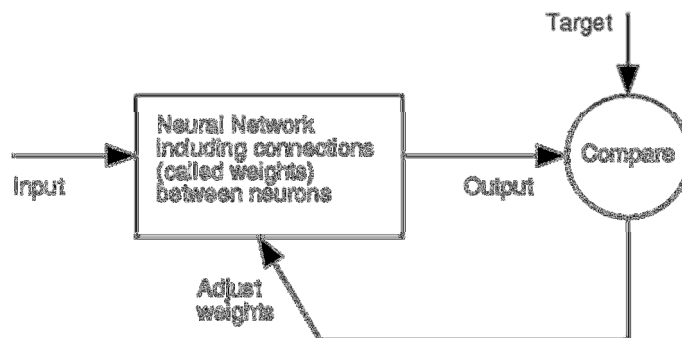


Figura 2-1 - Diagramma logico di una rete neurale

I pesi delle connessioni della rete neurale vengono modificate e corrette sulla base del confronto tra l'output da essa prodotto e il valore dell'output sperimentale (target) che segue all'input. Teoricamente, l'aggiustamento della rete continua fintantoché output e target non coincidano esattamente e, tipicamente, sono necessarie numerose coppie input-target affinché la rete possa essere addestrata adeguatamente.

Una rete neurale può essere caratterizzata da molti diversi tipi di architettura, ma i modelli più utilizzati nella pratica sono i cosiddetti "multi-layer" (ML): un ML è organizzato in layer sequenziali, di cui il primo è quello dei dati di input e l'ultimo è quello dei parametri di output del modello. I layer intermedi sono detti "hidden", e possono essere uno o più d'uno.

Ogni layer è costituito da uno o più "neuroni", gli elementi che operano in parallelo, le unità di elaborazione dei dati. Per l'input layer, ogni parametro fisico di cui si abbiano a disposizione dati sperimentali e che si presuppone abbia influenza sul fenomeno sottoposto a modellazione costituisce un neurone. Il layer di output contiene invece tanti neuroni quanti sono i parametri che ci si propone di predire con la ANN. Infine, gli hidden layer contengono un numero variabile di neuroni, che deve essere stabilito in fase di calibrazione della ANN. Non c'è una regola generale per determinare il numero di neuroni negli hidden layer: di solito, la procedura è quella di testare diverse soluzioni e scegliere quella che fornisce le predizioni migliori.




Figura 2-2 - Esempio di uno schema di rete neurale a tre layer

Una rete neurale lavora solo in una direzione, dall'input all'output. Le informazioni si propagano di layer in layer attraverso le connessioni fra i neuroni. Ogni neurone di un layer è connesso con tutti i neuroni del layer successivo: quindi, se al layer i si hanno n neuroni, e al layer $i + 1$ se ne hanno m , si generano in totale $n \cdot m$ connessioni fra i due layer.

A ciascuna connessione è attribuito un peso, al fine di rendere più o meno rilevante l'informazione trasmessa tra due neuroni. In genere, il peso è un coefficiente numerico il cui valore è massimizzato o minimizzato automaticamente da appositi algoritmi della rete neurale stessa, a seconda che, in fase di "apprendimento", la rete si "renda conto" che l'informazione associata a una connessione sia più o meno rilevante ai fini della corretta stima del parametro (o dei parametri) di output. Perciò, l'input di ciascun neurone (detto "valore di attivazione") è costituito dalla somma pesata delle informazioni provenienti da tutti i neuroni del layer precedente, cioè dalla somma pesata degli output

del *layer* precedente.

Al valore di attivazione viene quindi applicata una funzione di attivazione, e il neurone produce l'output. Quindi, è la funzione di attivazione che definisce a sua volta il valore del neurone del *layer* successivo. Di solito, la funzione di attivazione è costituita da una trasformazione non lineare per gli *hidden layer* e da una trasformazione lineare per l'*output layer*.

Un momento fondamentale della costruzione di una ANN è la calibrazione (o fase di *training* o di *learning*). L'incertezza del modello è data dalla presenza dei pesi, che possono essere intesi come parametri incogniti: sono essi l'oggetto del *training*. Per determinarli, è necessario disporre di un certo numero di dati sperimentali relativi al parametro (o ai parametri) che la rete deve predire, sulla base dei quali è possibile "fittare" gli output predetti dalla rete stessa. L'operazione di *fitting* degli output consiste nell'aggiustamento dei pesi e quindi nel *training*.

Alla fase di *training*, segue quella di *testing* (o di validazione) per il completamento della modellazione della ANN. Tale fase consiste nella valutazione delle prestazioni del modello costruito mediante l'utilizzo di un *testing set* di dati, che deve essere diverso dal *training set* usato precedentemente.

Un modello di rete neurale è quindi identificato da:

- la sua struttura (di solito di tipo ML);
- il tipo di funzioni di trasformazione che attivano e definiscono la struttura dei neuroni nei *layer* successivi a quello di input;
- l'algoritmo di "training", ossia di calibrazione, per l'ottimizzazione del modello.

3 Costruzione di una rete neurale

La costruzione di una rete neurale comincia dall'individuazione dei fattori che possono influenzare il fenomeno che si vuole studiare e dalla selezione dei parametri chiave che descrivano tali fattori. Ciascuno di questi parametri costituirà un neurone dell'*input layer*: individuare il numero e il tipo di parametri significa quindi definire l'input di una ANN.

Spesso non è possibile conoscere a priori a quali parametri il fenomeno studiato sia più sensibile, quindi persino la scelta dei neuroni dell'*input layer* è soggetta a prove di sensibilità e significatività: si rimodella più volte la ANN, cambiando il set di neuroni di input, sia in numero che in tipo, fino a che non si trova la combinazione che fornisca le prestazioni migliori.

Definiti i parametri, si passa alla selezione del database per ciascuno di essi. I dati sperimentali possono derivare da campionamenti effettuati per casistiche e in circostanze molto diverse, quindi essere estremamente eterogenei, anche in termini di errori ad essi associati.

La qualità di una ANN dipende essenzialmente dalla qualità del database di cui si dispone. Per tale motivo, è fondamentale epurare da esso tutti i valori incerti, affetti da errori sistematici o grossolani, o poco significativi. Spesso, a tal fine, si definiscono due "indici di qualità" dei dati:

- *RF*, *Reliability Factor*: indice di attendibilità del dato, che può variare da 1 (massima attendibilità) a 4 (nessuna attendibilità), a seconda che tutte le informazioni e le precauzioni necessarie alla corretta assunzione del dato siano o meno disponibili e rispettate;
- *CF*, *Complexity Factor*: indice di complessità del dato, anch'esso variabile tra 1 (minima complessità) e 4 (massima complessità).

Dalla combinazione lineare dei due fattori, si definisce poi:

$$WF \stackrel{\text{def}}{=} (4 - RF) \cdot (4 - CF),$$

Weight Factor: fattore di peso, variabile tra 0 e 4. *WF* sarà pari a 4 (massimo peso at-

tribuito al dato) quando sia RF che CF sono pari a 1, e sarà nullo quando o RF oppure CF sono pari a 4.

Grazie a tale definizione si eliminano immediatamente tutti quei dati che abbiano o minima attendibilità o massima complessità, attribuendovi coefficiente moltiplicativo di peso nullo.

Un'altra problematicità che può affliggere un database è costituita dai cosiddetti “effetti di scala”: a un modello di rete neurale si richiede solitamente di essere in grado di effettuare stime di valori variabili su range relativamente esteso ed è pertanto necessario che il database di “addestramento” contenga intervalli di dati altrettanto ampi; sorge allora il rischio che i valori più piccoli dei dati, in genere affetti da errori di misura relativamente maggiori rispetto ai valori più grandi, risultino meno significativi, e di conseguenza la rete potrebbe non stimare correttamente i valori più piccoli. Il problema è consistente, dal momento che spesso i dati provengono da misure in laboratorio, quindi in scala fortemente ridotta, ma il modello viene creato per studiare le condizioni in natura, a scala molto maggiore. Diviene perciò fondamentale rendere una ANN poco sensibile alle dimensioni dei parametri: una soluzione può essere il ricorso all'adimensionalizzazione di tutti i parametri in gioco, mediante opportune relazioni di similitudine che rispettino i fattori di scala.

3.1 Connessioni tra i neuroni

Le connessioni tra i neuroni avvengono solo in una direzione, da un *layer* al successivo, partendo da quello di input, fino a quello di output. Non esistono connessioni tra i neuroni di uno stesso *layer*, né connessioni dirette in senso inverso. Perciò, le reti neurali *multi-layer* vengono dette “*feedforward*”, e la loro schematizzazione logica e grafica è di tipo aciclica diretta.

Come anticipato, se il numero di neuroni dei *layer* di input e di output è prestabilito (quello di input corrisponde al numero di parametri che si ritengono influenzare il fenomeno analizzato, e quello di output corrisponde al numero di parametri di cui si vuole predire i valori), quello degli *hidden layer* non è noto a priori. Definire il numero ottimale dei neuroni in un *hidden layer* è un momento fondamentale della calibrazione e della realizzazione di un modello alle reti neurali.

Generalmente, aumentando il numero di neuroni, diminuiscono le differenze tra valore di output predetto e valore sperimentale, dunque cala l'errore commesso dalla ANN. Infatti, ad ogni neurone corrisponde un grado di libertà, e aumentandone il numero, si incrementa la possibilità di aggiustare parametri del modello. Tuttavia, l'incremento del numero di neuroni ha effetto benefico sulla resa di una rete fintantoché non si incappi nel problema delle “*noisy fluctuations*”: molti neuroni arrecano un disturbo alla procedura di apprendimento per la complessità crescente dell'architettura della rete, e tale effetto compensa negativamente il beneficio dovuto all'incremento di gradi di libertà, giungendo al punto che non si osservano più effettivi miglioramenti delle *performance* della ANN. Si parla allora di rete “*overtrained*”.

La procedura di selezione del numero ottimale di neuroni è pertanto basata sull'osservazione delle *performance* della rete, cominciando da un numero esiguo (solitamente uno o due) e aumentandolo finché si ottengono decrementi significativi dell'errore commesso. Solitamente, il numero di *hidden neurons* è al più pari al doppio di quello degli *input neurons*.

3.2 Valori e funzioni di attivazione, pesi e *bias* di una rete neurale

Ogni neurone riceve come input (“valore di attivazione”) la somma pesata degli output dei neuroni del *layer* precedente:

$$\sum_{i=1}^n X_i W_{ij},$$

dove X_i è il generico elemento del vettore \mathbf{X} degli output degli n neuroni del *layer* precedente e W_{ij} è il generico elemento della matrice dei pesi delle connessioni tra gli n neuroni di “monte” e gli m neuroni di “valle”.

La funzione di trasformazione input-output che ciascun neurone applica al valore di attivazione ricevuto necessita di un valore di soglia che controlli l'effettiva attivazione della funzione, ossia sia in grado di traslarla rispetto all'origine dei segnali per aggiustare il funzionamento del neurone. Il valore di attivazione del generico neurone j corretto con tale valore di soglia diventa:

$$A_j = \sum_{i=1}^n (X_i W_{ij} + B_j)$$

B_j è il valore di soglia, detto “*bias*”. Un *bias* non partecipa alla sommatoria, infatti è un'unica costante del *layer*, inizialmente pari a 1 e in seguito opportunamente pesata (con il corrispondente coefficiente di peso di *bias*); il suo effetto corrisponde semplicemente a uno “*shift*” di aggiustamento della funzione di attivazione.

In una rete neurale, un *bias* viene introdotto esattamente come un neurone: si parla di “*bias neuron*”. Viene letto dal modello esattamente come tale, ma la sua connessione e il suo peso si costruiscono separatamente da tutti gli altri. In ogni *layer*, può essere presente un *bias*, eccezion fatta per l'*output layer*, il quale non deve produrre valori di attivazione per nessun *layer* successivo, essendo l'ultimo, e quindi ovviamente non necessita del *bias*.

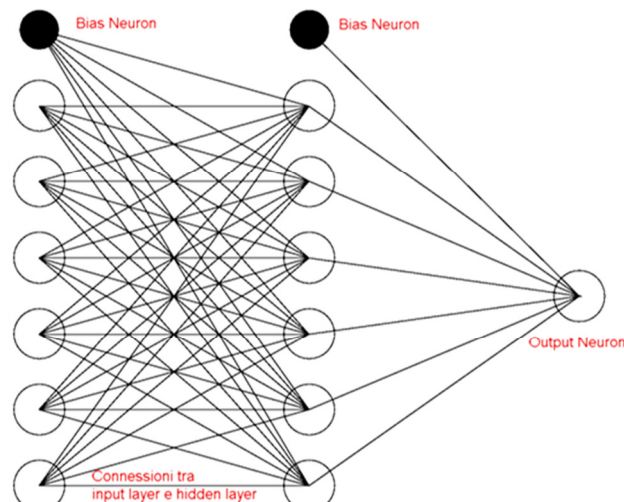


Figura 3-1 - Schema di una rete neurale formata da 3 layer (1 hidden layer) e comprensiva di bias

3.3 Training della rete neurale

La fase di *training* comprende e in parte corrisponde a quella più specifica di “*learning*”. Tali fasi vengono così denominate proprio perché la rete “impara” dai valori sperimentali degli output che deve predire come correggere i pesi ed elaborare le relazioni che legano gli input agli output. Dunque, la calibrazione delle ANN è basata sulla cosiddetta “*Error Back Propagation Rule*”:

- si sceglie una porzione di dati dell'intero database disponibile da impiegare come “*training set*”; esso deve contenere dati relativi sia ai parametri di input che a quelli di output. La restante quota parte di dati del database sarà utilizzata come “*testing set*”;
- si ipotizzano dei valori iniziali degli elementi della matrice dei pesi e dei *bias* per le connessioni tra i neuroni tra i due *layer* successivi;
- si calcola l'errore commesso nella previsione dell'output dalla rete, confrontando tale valore di output calcolato con il corrispondente valore di output sperimentale; l'errore si propaga all'interno della ANN secondo la regola di *back-propagation* (ovvero, dall'output all'indietro fino all'input);

- sulla base dell'errore, si apporta una correzione ai pesi, e si ripete il ciclo, misurando il nuovo errore commesso dalla ANN, che deve essere inferiore rispetto al primo;
- il ciclo viene ripetuto iterativamente fino a quando l'errore non si azzeri completamente, oppure (caso molto più comune nella pratica) non si ottengono più ulteriori miglioramenti (ovvero diminuzioni sensibili dell'errore).

L'aggiustamento dei valori dei coefficienti di peso, passo dopo passo, è impostato su una minimizzazione dell'errore, inteso come funzione di costo (o di performance). La funzione di costo è ciò che consente di stabilire quanto la predizione del modello è lontana dal valore sperimentale, e quindi quanto in generale il modello è lontano dalla produzione di soluzioni ottimali. Molto spesso, la minimizzazione è operata sulla radice quadrata dei quadrati delle differenze tra valore predetto e valore misurato (RMSE, “*Root Mean Square Error*”).

Particolare attenzione va posta alla scelta della *training set* e della *testing set*: la resa della ANN può essere molto influenzata da tale distinzione. Suddividere i dati fra *training* e *testing* significa stabilire quale quota parte utilizzare per “addestrare” la rete, e quale per verificare la bontà dell'addestramento. Chiaramente, se *training set* e *testing set* contengono dati fra loro disomogenei, quindi il *training* non comprende tutto il range di variazione dei parametri, le prestazioni della rete non possono che essere scadenti, dal momento che all'atto della simulazione la rete si trova a dover operare su dati che non ha mai “visto” in fase di “addestramento”.

Buona norma è variare la scelta della partizione dei dati fra i due set, in modo da effettuare anche un'analisi di sensibilità della rete ai diversi dati. A tal fine, si possono utilizzare le cosiddette “*Resampling Techniques*”, che sono utili sia come indicazione per la definizione dei due set, sia per stimare il grado di incertezza o affidabilità delle predizioni della ANN. Di solito il *training set* costituisce una porzione molto più cospicua del database rispetto al *testing set*.

3.4 *Testing e ottimizzazione della rete*

La fase di *testing* completa quella di *training*. Le predizioni del modello prodotte utilizzando i dati del *training set* vengono confrontate con quelle fornite utilizzando i dati del *testing set*: se la deviazione standard (o l'RMSE, o la generica funzione di costo scelta) tra le predizioni e i valori sperimentali del *training set* è dello stesso ordine di grandezza della deviazione standard (o l'RMSE, o la generica funzione di costo scelta) tra le predizioni e i valori sperimentali del *testing set*, si può ritenere che la rete neurale costruita sia in grado di fornire predizioni affidabili, e che possa riprodurre gli effetti del fenomeno modellato.

Il grado di affidabilità è dato dall'entità della funzione di costo utilizzata: in tal senso, quindi, una ANN non solo fornisce delle predizioni di parametri, ma associa ad esse degli intervalli di confidenza, quindi una stima della loro affidabilità. I fattori che possono influenzare il valore risultante della deviazione standard, e quindi le prestazioni del modello sono:

- numero di dati in ogni *dataset* utilizzato;
- omogeneità dei dati all'interno del *dataset* stesso;
- tipo di partizione effettuata tra *training set* e *testing set*.

La sensibilità del modello a tutti questi fattori, così come l'affidabilità stessa della rete possono essere valutate con le sopraccitate *Resampling Techniques*. Esse costituiscono uno strumento di analisi di affidabilità utilizzato comunemente nella statistica e nelle calibrazioni di modelli numerici. Come dice la parola stessa, consistono nel ripetuto utilizzo di campioni diversi del database a disposizione (ossia di *set* di dati diversi), ossia sostanzialmente nel sottoporre il modello di ANN a diverse partizioni di dati tra *training set* e *testing set*. Un modello, quindi, può essere “allenato” e “testato” più volte, con combinazioni di dati diverse, fino a trovare quella che abbia le migliori prestazioni.

Le due tecniche di *resampling* più utilizzate sono la “*jackknifing*” e la “*bootstrap*”.

ping". Quest'ultima, più di frequente adottata nelle applicazioni in idraulica marittima, consiste in una selezione casuale di un certo numero di dati dall'originale database; ad ogni selezione, vengono "reintrodotti" i dati già selezionati, in modo che ogni volta un campione possa essere scelto di nuovo o meno. La probabilità che un campione possa essere scelto per il *training set*, ad ogni *resample*, è del 63%, quindi la probabilità che non venga scelta (e allora usato per il *testing set*) è del 37%.

Si procede effettuando una serie di *resample*, il cui numero deve essere sufficientemente grande (di solito dell'ordine delle centinaia) affinché la statistica per la scelta del *sample* migliore (quindi della partizione *training set* – *testing set*) sia significativa.

Al termine delle due fasi di *training* e *testing*, eventualmente ottimizzate mediante le *resampling techniques*, la rete neurale è "allenata" e le matrici dei pesi e dei *bias* assegnate definitivamente.

4 Applicazioni delle reti neurali in idraulica marittima

Le *Artificial Neural Networks* sono strumenti potenti, capaci di interpretare con successo i dati di fenomeni empirici molto complessi. Recentemente, sono state impiegate molto di frequente per l'interpretazione e la risoluzione di problemi fisici o ingegneristici, nonostante e contemporaneamente grazie al fatto che siano *black-box* che non interpretano minimamente il problema stesso.

L'impiego di reti neurali artificiali per applicazioni oceaniche e atmosferiche è cresciuto rapidamente negli ultimi anni. Un'ampia rivisitazione dei vari aspetti di tali metodi, delle loro possibilità e limiti è stata prodotta da Cherkassky et al. nel 2006, introducendo nel *Neural Networks Journals* una sezione specifica. Un importante gruppo di applicazioni delle reti neurali nelle simulazioni oceaniche e atmosferiche è rappresentato dai cosiddetti modelli ibridi, nei quali alcune parti del codice sono rimpiazzate e sottoposte a *training* con reti neurali, consentendo stime delle quantità accurate o dei processi modellati e, in taluni casi, più efficienti di diversi ordini di grandezza.

Più specificatamente in ingegneria costiera e idraulica marittima, una delle più recenti e fondamentali applicazioni è stata realizzata nel contesto del progetto europeo CLASH, per la predizione della portata di tracimazione oltre le barriere marittime. A partire dalle analisi del progetto CLASH e dal database da esso utilizzato, altri modelli o sviluppi del modello stesso per le stime di tracimazione ondosa sono stati definiti mediante le reti neurali. Per quanto riguarda la riflessione ondosa, fenomeno complementare alla tracimazione e dipendente dagli stessi parametri, manca tuttora un modello di predizione basato sulle reti neurali.

Si riporta di seguito un breve *excursus* sulle più recenti applicazioni delle ANN in idraulica marittima, con particolare attenzione alle metodologie di costruzione dei network e soprattutto al database del progetto CLASH, costituendo esso il database originario utilizzato anche nell'ambito di altri studi.

4.1 Prime applicazioni delle ANN in idraulica marittima

Come primi esempi di applicazioni di reti neurali per strutture costiere, che si sono dimostrate una scelta vincente come alternativa di modellazione ad altre tecniche più tradizionali, si può menzionare Mase et al. (1995), Van Gent e Van den Boogard (1998), Medina (1999), Medina et al. (2002, 2003), Panizzo et al. (2003), Pozueta et al. (2004), Van Oosten e Peixo Marco (2005).

Krasnopolsky e Chevalier (2003) hanno discusso esempi di modelli ibridi, in particolare la "*Neural Network Interaction Approximation*" (NNIA; vedere anche Tolman et al., 2005), un algoritmo basato sulle reti neurali progettato per sostituire la "*Discrete Interaction Approximation*" (DIA) delle interazioni non lineari delle onde nei modelli spettrali.

Un'altra classe di approcci presenta le reti neurali applicate direttamente per la predizione di serie temporali dei parametri delle onde in un luogo di interesse (solitamente vicino a costa) a partire dalle serie temporali rilevate altrove (solitamente al largo) ad

esempio mediante misurazioni satellitari (Kalra et al., 2005), oppure da rilevazioni di segnali d'onda dalle boe (Tsai et al., 2002; Makarynsky, 2005), da risultati di modelli su larga scala (Browne et al. 2006) o dati sul vento (Deo et al. 2001; Rao e Mandal, 2005).

La tecnica a reti neurali è stata anche utilizzata per la previsione di futuri valori dei parametri delle onde in un sito determinato sulla base di valori di quei parametri misurati precedentemente (vedere ad esempio Deo e Naidu, 1999; Makarynsky, 2004; Londhe e Panchang, 2006; Makarynsky e Makarynska, 2007), per l'interpolazione di valori mancanti (Makarynsky, 2005), per studi riguardanti l'interdipendenza fra i vari parametri ondosi (Agrawal e Deo, 2004; Deo et al., 2002) e per migliorare l'accuratezza dei risultati ottenuti da modelli numerici di simulazione ondosa (Makarynsky, 2005; Zhang et al., 2006).

4.2 Progetto CLASH: ANN per la portata di tracimazione

Per la progettazione, la risistemazione e l'analisi di sicurezza delle strutture costiere sono necessarie stime affidabili della tracimazione ondosa. I parametri più utilizzati nelle formule proposte per la predizione della tracimazione sono l'altezza e il periodo d'onda, e la sporgenza della cresta dell'opera rispetto alla superficie del mare; più in generale, si trattano di parametri in grado di racchiudere e descrivere sinteticamente le peculiarità della struttura e dell'attacco ondoso. Le relazioni che legano la tracimazione ondosa a tali parametri sono fortemente non lineari, aspetto che rende il problema di predizione di difficile soluzione. A ciò si aggiunge che piccoli errori di misura, o leggere differenze nelle caratteristiche strutturali di un'opera possono avere forte influenza sul risultato. In definitiva, l'affidabilità della maggior parte delle formule non è definita, e sussistono grandi differenze nelle predizioni, a seconda delle formule utilizzate.

È da questo *background* che è nato il progetto dell'Unione Europea CLASH (“*Crest Level Assessment of coastal Structures, by full scale monitoring, neural network prediction and Hazard analysis on permissible wave overtopping*”¹), i cui principali obiettivi scientifici sono:

- analizzare gli effetti di scala per la tracimazione ondosa;
- produrre un metodo di predizione basato su modelli a reti neurali per la stima della portata di tracimazione, associando un livello di affidabilità della stima stessa.

Scopo del CLASH è anche che il metodo di predizione risulti il più possibile adattabile a diverse tipologie di opere, sia in scala di prototipo che di modello da laboratorio, in modo che sia possibile includere anche strutture dalle forme non necessariamente standard. Inoltre, il modello non deve tenere conto solamente dei principali parametri sopra descritti, ma anche degli effetti di molte altre caratteristiche dell'onda e della struttura.

Nell'ambito del progetto CLASH, sono state raccolte oltre 10000 misurazioni di portata di tracimazione, ottenute da test su modelli fisici realizzati in un grande numero di laboratori universitari e di istituti di ricerca, perlopiù partner del progetto. Tutti i dati sono stati inseriti in un unico grande database: “*the new overtopping database for coastal structures*” (Verhaeghe 2005, Van der Meer et al.), successivamente “*the overtopping database*”.

Con l'obiettivo di poter utilizzare l'*overtopping database* per molteplici applicazioni, è stato raccolto il maggior numero di informazioni possibili per ciascun dato: non sono stati rilevati semplicemente i dati essenziali (parametri ondosi, geometria e corrispondenti valori di portata tracimata), ma anche dettagli sui metodi di misurazione delle onde e delle portate e dettagli sui metodi di analisi. Ogni test di tracimazione incluso nel database è descritto da 31 parametri: 11 parametri descrivono le caratteristiche delle onde incidenti e di quelle tracimate a tergo delle barriere; 17 parametri strutturali descrivono le strutture testate; infine, 3 parametri sono relativi alle informazioni generali sulle modalità di esecuzione del test. I fattori di complessità e di affidabilità (*CF* ed *RF*) sono due di questi parametri generali; essi si riferiscono, nello specifico, al grado di appros-

¹ www.clash-eu.org

simulazione ottenuto nella descrizione di una struttura mediante i parametri strutturali, in riferimento all'affidabilità del test di tracimazione considerato. I parametri CF ed RF hanno giocato un ruolo fondamentale nella configurazione e costruzione della rete ANN. Da ultimo, il database contiene, per alcuni test, un riferimento a un report o un articolo descrittivo delle misurazioni.

La figura 4-1 rappresenta lo schema più generale possibile per la descrizione di tutti i parametri strutturali e ondosi contenuti nel database. Si precisa che nel database viene utilizzata la stessa simbologia e si fa riferimento allo stesso schema ivi riportato.




Figura 4-1 Caratteristiche strutturali e ondose utilizzate nella modellazione ad ANN per la tracimazione

Parametri relativi alle onde incidenti:

- $H_{m0,t0e}$ = altezza d'onda significativa calcolata al piede della struttura;
- $T_{m-1,0,t0e}$ = periodo d'onda significativo calcolato al piede della struttura;
- β = direzione dell'attacco ondoso (angolo di deviazione rispetto alla direzione perpendicolare, per cui si assume $\beta = 0$);
- h = profondità dell'acqua di fronte alla struttura;
- h_t = profondità dell'acqua al piede della struttura;
- h_b = profondità dell'acqua ai piedi sopra alla berma della struttura;

Parametri descrittivi la sezione trasversale della struttura (caratteristiche geometriche e strutturali):

- B_t = larghezza della protezione al piede (o berma al piede);
- B = larghezza della berma;
- γ_f = coefficiente di scabrezza/permeabilità dello strato esterno di "corazzamento" della struttura (strato di "mantellata o" "armour");
- $\cot \alpha_d$ = pendenza della parete della struttura sopra alla prima berma (protezione al piede);
- $\cot \alpha_b$ = pendenza della parete della berma;
- $\cot \alpha_u$ = pendenza della parete della struttura sopra alla seconda berma;
- R_c = sporgenza della cresta rispetto al livello del mare;
- A_c = la sporgenza della cresta dell'armour della struttura;
- G_c = larghezza in cresta della struttura.

I parametri rimanenti, oltre ai tre generali descrittivi delle modalità di esecuzione dei test, descrivono le caratteristiche delle onde e del fondale al largo rispetto all'opera, altri valori del periodo d'onda (oltre a quello significativo $T_{m-1,0,t0e}$, quello di picco T_p e quello medio T_m , sia al largo che ai piedi dell'opera), il diametro D_{n50} del materiale utilizzato per l'armour, e naturalmente il dato di portata tracimata q .

Dunque, il progetto CLASH dispone di un database con un numero di misurazioni molto maggiore e molto più completo rispetto ai casi di studio precedenti. Un modello

di ANN per la predizione dei valori di portata di tracimazione a tergo di strutture marittime poste a difesa della costa, in accordo con gli obiettivi del progetto CLASH, è stato effettivamente messo a punto nel lavoro di Van Gent, et al. (2005)².

Poiché dati erranei o fuorvianti possono intaccare seriamente le prestazioni di un modello alle reti neurali, l'iniziale database di 10000 dati è stato ridotto nel lavoro di Van Gent, Van den Boogaard, Pozueta e Medina, rimuovendo tutti i test qualificati come "non affidabili" (per i quali si aveva $RF = 4$) o i test per i quali la forma della sezione trasversale è stata ritenuta "molto complessa ($CF = 4$). Tutti i test rimanenti per i quali è stata osservata portata di tracimazione $q \neq 0 \frac{m^3}{sm}$, per un totale di 8372 dati, sono stati inseriti nell'input della rete neurale.

Sono state prese in esame alcune alternative per la definizione del *neural network*, ma non adottate. Una soluzione prevedeva la messa a punto di due reti accoppiate: una prima ANN che fosse in grado di predire per una specifica situazione se si sarebbe verificata o meno tracimazione, e una seconda che prevedesse l'effettivo valore di portata tracimata. Tale approccio avrebbe presentato il vantaggio di consentire predizioni di portata nulla nei casi in cui effettivamente non si verificava alcuna tracimazione in assoluto, mentre nell'approccio infine adottato la rete fornisce predizioni di piccoli valori di portata anche quando il dato sperimentale non presenta tracimazione.

La motivazione dello scarto della prima soluzione è dovuta alla constatazione, da parte degli autori, che la capacità di distinguere fra tracimazione o assenza di tracimazione necessitava di un numero sufficiente di test accurati che riportassero $q = 0$, mentre la proporzione di dati erranei ($RF = 4$) per $q = 0$ era nettamente più alta che quella per $q > 0$. Ciò è in qualche modo causato dalla differente definizione di $q = 0$ nei diversi programmi di test: ad esempio, in alcuni test su larga scala risulta $q = 0$, quando negli effetti si era verificato $q \leq 1 \frac{l}{s \cdot m}$, mentre in test a piccola scala $q = 0$ poteva derivare da $q \leq 0,001 \frac{l}{s \cdot m}$.

Affinché la ANN risultasse applicabile sia in condizioni di piccola scala che di prototipo, tutti i parametri di input e di output sono stati riscalandi rispetto all'altezza $H_{m0,toe}$, rispettando le regole di similitudine del numero di Froude. Il vettore di input implementato nella rete neurale da Van Gent, Van den Boogaard, Pozueta e Medina contiene i seguenti 15 parametri/neuroni:

$$[H_{m0,toe}, T_{m-1,0,toe}, \beta, h, h_t, B_t, \gamma_f, \cot \alpha_d, \cot \alpha_u, B, h_b, \tan \alpha_b, R_c, A_c, G_c].$$

Il tipo di architettura adottata da Van Gent, et al. è una *Multi-Layer Perceptron feed-forward network*, a tre layer (un *hidden layer*), con "standard error back-propagation rule" come processo di *training*, algoritmo piuttosto comune per la calibrazioni di questo tipo di ANN.




Figura 4-2 Configurazione della rete neurale del CLASH per la stima della portata di tracimazione

² "Neural network modelling of wave overtopping at coastal structures", Marcel R.A. Van Gent, Henk F.P. Van den Boogaard, Beatriz Pozueta, Josep R. Medina, *Coastal Engineering* 54 (2007), pagg. 586 – 593

Il modello di rete neurale è stato realizzato in due fasi, quella di *training/learning* e quella successiva di *testing/validazione*. L'aggiustamento dei pesi della rete durante il *training* della rete è avvenuto mediante la minimizzazione della funzione di costo della radice quadrata dello scarto quadratico medio (RMSE) delle differenze tra valori di q predetti e valori effettivi. Nella fattispecie, l'RMSE è stato calcolato considerando i logaritmi delle portate di tracimazione osservate e stimate dalla rete (in entrambi i casi, i valori sono stati scalati in similitudine di Froude e indicati con l'apice):

$$RMSE_{train} = \sqrt{\frac{1}{N_{train}} \sum_{n=1}^{N_{train}} ((\log q'_{obs})_n - (\log q'_{NN})_n)^2},$$

dove N_{train} è il numero di test considerati nel *training* della rete neurale.

Le performance della rete sono state infine valutate con un *testing set* di dati non utilizzati per il *training*.

Il numero ottimale di neuroni per l'*hidden layer* è stato stabilito sottoponendo a *training* la rete più volte, e ogni volta cambiando il numero di neuroni, annotando l'accuratezza della risposta (RMSE) della rete sul *training set* e sul *testing set*. Come si può osservare dal diagramma di figura 4-3, l'RMSE decresce rapidamente sia per il *training set* che per il *testing set* finché per un piccolo numero di neuroni, per poi iniziare a diventare più stabile per un numero crescente di unità. Sulla base di tali esperimenti, il numero di *hidden neurons* è stato stabilito come 20: un numero maggiore non avrebbe comportato una sensibile diminuzione dell'errore, complicando di contro la complessità dell'architettura di rete, aumentando il numero di connessioni.

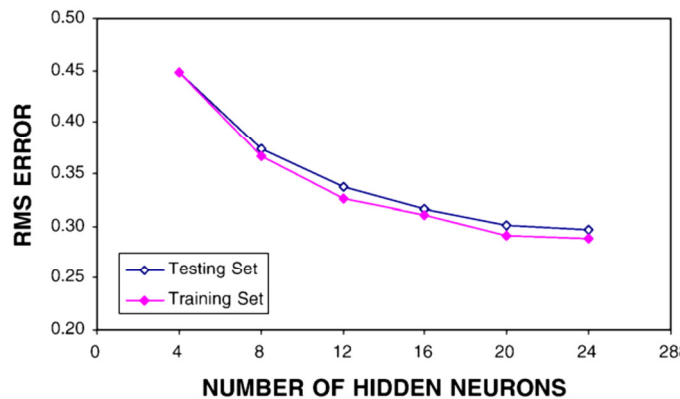


Figura 4-3 - Performance della rete all'aumentare del numero di neuroni dell'*hidden layer*

Una volta strutturata, alla ANN sono stati apportati alcuni miglioramenti, in modo che fornisca anche degli intervalli di confidenza attorno alle stime prodotte della portata di tracimazione. Ciò è stato possibile mediante l'introduzione delle tecniche di *resampling*. Il set di diversi modelli di ANN così sviluppato ha prodotto un insieme (un set di predizioni) di stime di portata tracimata. Tale insieme di valori di q ha consentito, infine, una stima dell'affidabilità delle predizioni, tramite intervalli di confidenza al 90%, oppure valori di deviazione standard o di varianza.

Quest'ultimo è un passo essenziale nell'ottimizzazione della rete, dal momento che una modellazione di tipo "*black-box*" richiede che le predizioni siano accompagnate da informazioni riguardanti la loro affidabilità.

Oltre alla media dell'insieme di reti neurali, che è stato usato come predizione del modello ($\mu = q_{NN}$), l'output del metodo di predizione includeva la deviazione standard σ (o "*spread*") e quantili di vario ordine ($q_{2,5\%}$, $q_{5\%}$, $q_{25\%}$, $q_{50\%}$, $q_{75\%}$, $q_{95\%}$, $q_{97,5\%}$). Si tenga comunque presente che l'assegnazione degli intervalli di confidenza e le stime di affidabilità delle predizioni sono comunque basate sulla dispersione dei dati sul dominio e sulla differenza di questi rispetto ai valori sperimentali misurati, quindi tutto a valle della supposizione che il database sia "corretto": le stime di affidabilità non tengono

conto, di fatto, di errori sistematici o grossolani eventualmente presenti nel database di partenza.

La rete neurale è stata sottoposta inizialmente a valori misurati di portata $q > \frac{10^{-6} m^3}{s \cdot m}$. Come si può osservare dalla figura 4-4, le predizioni della rete neurale risultano essere ragionevolmente accurate, soprattutto nel range di valori elevati di portata tracimata. Per fornire un'idea dello *spread* delle predizioni del network, sono state inserite nel grafico dell'intervallo di confidenza al 90%, all'esterno delle quali ricade, da ciascuna parte, il 5% dei punti.




Figura 4-4 - Osservazioni della portata di tracimazione confrontate con le predizioni della ANN del CLASH; in rosso, le barre indicative dell'intervallo di errore al 90%

Come indice quantitativo dell'errore commesso dalla rete neurale si è fatto riferimento – come per la fase di *training*, *testing* e di ottimizzazione del modello, all'RMSE delle differenze tra portata osservata e portata predetta. Dal modello è risultato infine:

$$RMSE = 0,29$$

La barra indicativa al 90% dell'errore commesso dalla ANN può così essere espresso:

$$\log q_{NN-90\%} = \begin{cases} 0,86 \cdot \log q_{obs} \\ 1,15 \cdot \log q_{obs} \end{cases}$$

In generale, si è perciò dimostrato che la concordanza tra valori predetti e valori misurati è ben accettabile, le predizioni sono piuttosto accurate.

Ulteriori test di applicazione della rete neurale hanno dimostrato che il modello è anche capace di valutare dai dati l'influenza di particolari parametri (angolo di incidenza dell'onda, altezza relativa della cresta R_c/H_{mo} , larghezza relativa della cresta G_c/H_{mo}) per un vasto range di tipi di strutture, fornendo anche un'indicazione dell'affidabilità e incertezza delle predizioni della ANN.

Dal progetto CLASH è infine risultato evidente che la qualità delle predizioni è in larga parte affetta dalla qualità del database stesso su cui è basato il modello.

4.3 ANN a due fasi per la portata di tracimazione

La tecnica di impiego di modelli a reti neurali a due fasi era già stata proposta da Medina (1998), per stimare l'entità del *run-up* su barriere dotate di rampe di risalita per la dissipazione dell'energia ondata.

Il modello di predizione della tracimazione ondata realizzato da Verhaeghe, De

Rouck e Van der Meer (2008)³ a due fasi è sostanzialmente uno sviluppo e miglioramento del modello a rete “singola” proposta dal CLASH presentata nel precedente paragrafo, con lo scopo principale di prevenire gli errori di sovrastima commessi da quest’ultimo nella predizione dei valori modesti di portata tracimata. Tale modello combinato è composto da due reti neurali: una prima cosiddetta “classificatrice” e una seconda “quantificatrice”. La rete neurale singola del progetto CLASH e la seconda rete “quantificatrice” del modello a due fasi ivi presentato possono essere paragonate, dal momento che entrambe sono state sottoposte a *training* con la stessa specifica combinazione di misurazioni di portata tracimata $q_{measured} > 0$.

La differenza tra la ANN del CLASH e il modello neurale a due fasi consiste nel fatto che quest’ultimo processa anche misurazioni di portata di tracimazione $q_{measured} = 0$. Ciò è possibile proprio grazie all’introduzione della rete classificatrice a monte di quella quantificatrice: essa è stata costruita al fine di poter distinguere fra valori di portata tracimata trascurabili e valori invece significativi, fungendo pertanto da filtro per la rete quantificatrice.

L’idea di associare due reti neurali in modo sequenziale per realizzare un metodo di predizione della tracimazione deriva dalla natura esponenziale delle relazioni sperimentali, presenti in letteratura, che approssimano la distribuzione dei dati di portata di tracimazione in funzione dell’altezza della cresta di una struttura (ad esempio, TAW, 2002). Se un network viene addestrato con valori di *target* di portata q non precedentemente processati, esso sarà in grado di elaborare bene soltanto i valori elevati di q ($q \approx 10^{-1} \div \frac{10^{-2}m^3}{s \cdot m}$), non potendo distinguere i valori piccoli da quelli grandi, dal momento che il le differenze tra $q_{measured}$ e q_{NN} vengono minimizzate durante il processo di *training*.

Un risultato molto migliore può allora essere ottenuto quando il valore di q viene sostituito, prima di essere introdotto nella rete, con il suo logaritmo $\log q$ e così processato in fase di *training*: in tal modo, la ANN è in grado di riconoscere i valori più piccoli di portata tracimata, con un uguale errore relativo per valori grandi e piccoli.

Come visto, tale accorgimento era già stato preso da Van Gent, Van den Boogaard, Pozueta e Medina nel loro lavoro; tuttavia, persisteva il problema dei valori nulli di portata, poiché $\log(q = 0) = -\infty$. Ciò richiedeva la soppressione dei dati con $q = 0$ dal processo di *training*, con la conseguenza che la rete (sostanzialmente, un singolo network quantificatore) non era in grado di generalizzare bene i valori di portata piccoli o nulli. Tutto ciò ha condotto alla messa a punto di un network classificatore, capace di selezionare i valori significativi di portate e filtrarli per il quantificatore.

Entrambe le reti neurali del modello a due fasi di Verhaeghe, De Rouck e Van der Meer presentano architettura MLP (*Multi-Layer Perceptrons*), con un solo *hidden layer* e un unico neurone come output. Il singolo *hidden layer* si è mostrato sufficiente per il grado di approssimazione richiesto delle funzioni considerate.

Dei 31 parametri a disposizione nel database del CLASH ne sono stati selezionati 17 (riportati nella tabella dell’immagine 4-5) per la modellazione della rete neurale. Rispetto a Van Gent et al., è stato selezionato B_h al posto dei due parametri B e $\tan \alpha_B$, dal momento che il già piccolo numero di casi di strutture con berme a superficie inclinata incluse nel database presenta, di fatto, solo alcune parti lievemente inclinate, e un parametro in più determina un sostanziale aumento della complessità dell’architettura di rete.

³ “*Combined classifier-quantifier model: A 2-phases neural model for prediction of wave overtopping at coastal structures*”, Hadewych Verhaeghe, Julien De Rouck, Jentsje Van der Meer, *Coastal Engineering* 55 (2008), pagg. 357 – 374.

Nature		Parameter		Function
Hydraulic	1	$H_{m0, toe}$ [m]	(Wave height)	Input
	2	$T_{m-1,0, toe}$ [s]	(Wave period)	Input
	3	β [°]	(Wave angle)	Input
	4	q [m ³ /s/m]	(Overtopping discharge)	Output
Structural	1	h [m]	(Water depth in front of structure)	Input
	2	h_t [m]	(Water depth on toe)	Input
	3	B_t [m]	(Width of toe)	Input
	4	γ_r [-]	(Roughness factor)	Input
	5	$\cot\alpha_d$ [-]	(Structure slope)	Input
	6	$\cot\alpha_u$ [-]	(Structure slope)	Input
	7	R_c [m]	(Crest freeboard)	Input
	8	h_b [m]	(Water depth on berm)	Input
	9	B_b [m]	(Berm width)	Input
	10	A_c [m]	(Armour freeboard)	Input
	11	G_c [m]	(Crest width)	Input
General	1	RF[-]	(Reliability factor)	Weight factor
	2	CF[-]	(Complexity factor)	Weight factor

Figura 4-5 - Parametri selezionati dal database per la creazione del metodo di predizione

Poiché la rete classificatrice ha il solo compito di distinguere tra portate $q = 0$ o portate $q > 0$, il suo output può assumere solo due valori: +1, per rappresentare le portate significative, e -1 per intendere portate nulle o trascurabili. Il limite di discernimento stabilito è di $q = \frac{10^{-6}m^3}{s \cdot m}$, ovvero gli autori del lavoro hanno valutato come insignificanti le portate inferiori a tale valore (come già deciso da Van Gent et al.).

L'input layer della rete quantificatrice, consta di 13 parametri di input scalati in similitudine di Froude, l'hidden layer di 25 neuroni, e l'output layer del solo valore $\log(q)$.

L'architettura della ANN classificatrice è simile a quella della quantificatrice (fig. 4-6); poiché è previsto che le due reti lavorino in serie, l'input layer del classificatore consiste degli stessi 13 parametri del quantificatore. Logicamente, gli output delle due reti sono diversi, dal momento che il classificatore deve produrre solo valori +1 o -1, mentre il quantificatore deve fornire le predizioni di portata trascinata. Il numero di neuroni dell'hidden layer del classificatore è stato definito come 20.




Figura 4-6 - Architettura della ANN quantificatrice

Poiché una ANN è in grado di effettuare buone predizioni soltanto all'interno dei range di dati con la quale è stata "addestrata", e poiché forzare estrapolazioni su valori

esterni a tali range può condurre a risultati privi di significato, è importante indicare i range di applicabilità tanto del quantificatore, quanto del classificatore. I range di applicabilità del quantificatore sono riassunti nella tabella di figura 4-7, suddivisi per strutture dal $\gamma_f = 1$ (barriere con paramento “smooth”, liscio impermeabile) e dal $\gamma_f < 1$ (barriere con parete scabra, generalmente permeabili). Quelli di applicabilità del classificatore sono presentati nella tabella di figura 4-8.

	$\gamma_f=1$			$\gamma_f<1$		
1	3.00	$\leq T_{m-1,0\ toe} [s] \leq$	22.00	3.00	$\leq T_{m-1,0\ toe} [s] \leq$	12.00
2	0	$\leq \beta [^\circ] \leq$	60.00	0	$\leq \beta [^\circ] \leq$	60.00
3	1.00	$\leq h [m] \leq$	20.60	1.00	$\leq h [m] \leq$	13.30
4	1.00	$\leq h_t [m] \leq$	20.50	0.65	$\leq h_t [m] \leq$	13.30
5	0	$\leq B_t [m] \leq$	11.40	0	$\leq B_t [m] \leq$	5.00
6	1.00	$\leq \gamma_f [-] \leq$	1.00	0.35	$\leq \gamma_f [-] \leq$	0.95
7	0	$\leq \cot\alpha_d [-] \leq$	7.00	0	$\leq \cot\alpha_d [-] \leq$	5.30
8	-5.00	$\leq \cot\alpha_u [-] \leq$	6.00	0	$\leq \cot\alpha_u [-] \leq$	8.00
9	0	$\leq R_c [m] \leq$	5.00	0.25	$\leq R_c [m] \leq$	2.80
10	-1.00	$\leq h_b [m] \leq$	3.60	-1.00	$\leq h_b [m] \leq$	1.20
11	0	$\leq B_h [m] \leq$	16.20	0	$\leq B_h [m] \leq$	6.20
12	0	$\leq A_c [m] \leq$	4.00	0.10	$\leq A_c [m] \leq$	2.90
13	0	$\leq G_c [m] \leq$	7.60	0	$\leq G_c [m] \leq$	5.40

Figura 4-7 - Range di applicabilità del quantificatore

	$\gamma_f=1$			$\gamma_f<1$		
1	3.00	$\leq T_{m-1,0\ toe} [s] \leq$	22.00	3.00	$\leq T_{m-1,0\ toe} [s] \leq$	12.00
2	0	$\leq \beta [^\circ] \leq$	60.00	0	$\leq \beta [^\circ] \leq$	60.00
3	1.00	$\leq h [m] \leq$	20.60	1.00	$\leq h [m] \leq$	13.30
4	1.00	$\leq h_t [m] \leq$	20.50	0.65	$\leq h_t [m] \leq$	13.30
5	0	$\leq B_t [m] \leq$	11.40	0	$\leq B_t [m] \leq$	5.00
6	1.00	$\leq \gamma_f [-] \leq$	1.00	0.35	$\leq \gamma_f [-] \leq$	0.95
7	0	$\leq \cot\alpha_d [-] \leq$	7.00	0	$\leq \cot\alpha_d [-] \leq$	5.30
8	-5.00	$\leq \cot\alpha_u [-] \leq$	6.00	0	$\leq \cot\alpha_u [-] \leq$	8.00
9	0	$\leq R_c [m] \leq$	7.50	0.25	$\leq R_c [m] \leq$	4.20
10	-1.00	$\leq h_b [m] \leq$	3.60	-1.00	$\leq h_b [m] \leq$	1.20
11	0	$\leq B_h [m] \leq$	16.20	0	$\leq B_h [m] \leq$	6.20
12	0	$\leq A_c [m] \leq$	6.00	0.10	$\leq A_c [m] \leq$	4.35
13	0	$\leq G_c [m] \leq$	11.40	0	$\leq G_c [m] \leq$	8.10

Figura 4-8 - Range di applicabilità del classificatore

La suddivisione – di tipo *random* – dei dati fra *training set* e *testing set* è stata, rispettivamente, dell’85% e del 15% per ciascuna configurazione. Mentre il *training set* è stato utilizzato per “addestrare” i vari modelli, il *testing set* è servito a confrontare le prestazioni di tali modelli sviluppati, utilizzando come funzione di performance lo scarto quadratico medio (RMSE), così definito:

$$RMSE_{test} = \sqrt{\frac{1}{N_{test}} \sum_{n=1}^{N_{test}} [(o_{test_measured})_n - (o_{test_NN})_n]^2},$$

in cui N_{test} è il numero dei dati del *testing dataset*, $o_{test_measured}$ è l’output effettivo misurato e o_{test_NN} è l’output prodotto dalla rete neurale. Minore risulta l’RMSE, migliore viene considerata l’accuratezza delle predizioni del network.

In un secondo momento, sono state introdotte le tecniche di *bootstrap resampling*, sia per stabilire le migliori configurazioni per il classificatore e il quantificatore, sia per associare alle predizioni di quest’ultimo delle stime degli intervalli di confidenza.

La figura 4-9 mostra il risultato finale dell’associazione delle due reti neurali, classificatore e quantificatore. L’errore RMSE tra i valori q_{NN} predetti dalla rete e i valori sperimentali $q_{measured}$ risulta di 0,3100.




Figura 4-9 - Predizioni dell'accoppiamento delle due ANN, classificatore-quantificatore

Il confronto tra le performance di una singola ANN adibita a puro quantificatore e di una rete neurale a due fasi con classificatore e quantificatore può essere rappresentato dalla percentuale di portate predette $q_{NN} \neq 0$ rispetto a portate misurate invece $q_{measured} = 0$, ossia alla percentuale di portate che la rete legge come significative mentre il dato andava interpretato come nullo o trascurabile.

	Single quantifier simulation	Combined classifier-quantifier simulation
	% of all zero data (3521 weighed data)	% of all data from class-1 (3710 weighed data)
(Input out of range)	(43.06)	(1.07)
$q_{NN} > 10^{-6} \text{ m}^3/\text{s}/\text{m}$ of which	54.50	18.22
$q_{NN} > 10^{-2} \text{ m}^3/\text{s}/\text{m}$	(1 wrong zero measurement: 0.09)	0
$10^{-2} \text{ m}^3/\text{s}/\text{m} \geq q_{NN} > 10^{-3} \text{ m}^3/\text{s}/\text{m}$	1.53	0.97
$10^{-3} \text{ m}^3/\text{s}/\text{m} \geq q_{NN} > 10^{-4} \text{ m}^3/\text{s}/\text{m}$	7.36	4.19
$10^{-4} \text{ m}^3/\text{s}/\text{m} \geq q_{NN} > 10^{-5} \text{ m}^3/\text{s}/\text{m}$	28.40	11.63
$10^{-5} \text{ m}^3/\text{s}/\text{m} \geq q_{NN} > 10^{-6} \text{ m}^3/\text{s}/\text{m}$	17.12	1.42
$q_{NN} \leq 10^{-6} \text{ m}^3/\text{s}/\text{m}$	2.44	0
Total	100.00	19.29

Figura 4-10 - Valori di q_{NN} per la simulazione di dati di portata misurata nulla, confronto tra i due modelli

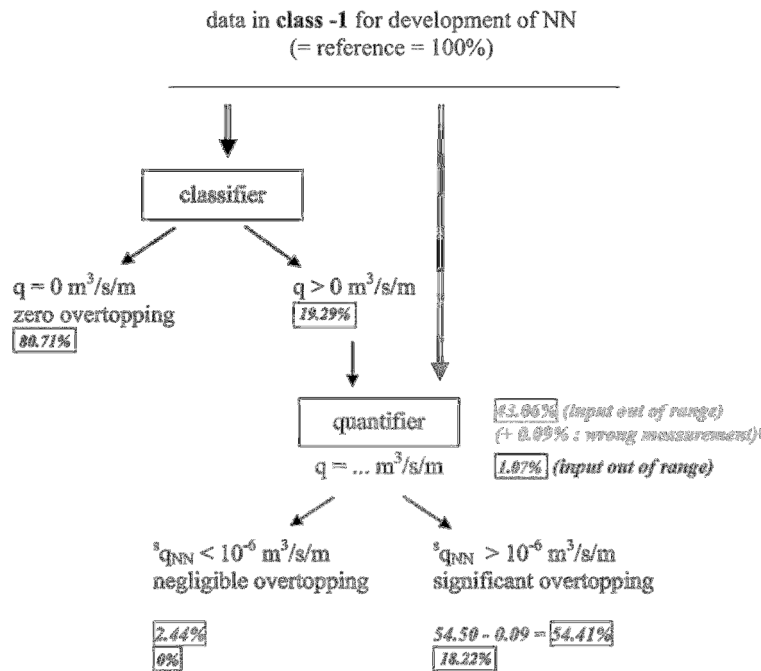


Figura 4-11 - Performance dei due modelli a confronto; in grigio le performance del singolo quantificatore, in nero quelle del classificatore-quantificatore per i dati dalla categoria -1

Contrariamente a quello che ci si poteva aspettare, la maggior parte delle simulazioni erronee di portata misurata nulla da parte del solo quantificatore (cfr. fig. 4-10) deriva da predizioni da valori relativamente alti di tracimazione (anche per valori di $q_{NN} > 10^{-3} \frac{m^3}{s \cdot m}$). Tale risultato conferma che il singolo quantificatore non è in grado di generalizzare bene per portate $q = 0 \frac{m^3}{s \cdot m}$, e che necessita di un filtro.

Rispetto al solo quantificatore, la rete a due fasi classificatore-quantificatore riduce significativamente il numero di portate sovrastimate: dal 54,41% (54,50% – 0,09% per misurazioni sbagliate) di dati erroneamente classificati come portate significative, anziché trascurabili, da parte del solo quantificatore, si passa al 18,22% (al 19,29% va sottratto un 1,07% dovuto a dati fuori range) del modello accoppiato (tale percentuale si riferisce a quella di dati a cui è stato attribuito – in modo sbagliato – l’output –1 dal classificatore). Le percentuali si riferiscono al numero totale di dati.

L’impiego di due reti neurali consecutive si è rivelato un valore aggiunto rispetto all’utilizzo di una sola: gli errori di sovrastima dei dati molto piccoli di portata – dovuti all’incapacità di una singola rete neurale di predire valori che possono spaziare da molto grandi a insignificanti – sono stati notevolmente ridotti.

4.4 Progetto CLASH: ANN per la stima del coefficiente di trasmissione

Le difficoltà nella previsione della trasmissione/tracimazione e della riflessione ondosa aumentano quando la quantificazione di tali fenomeni è relativa a strutture la cui cresta può o meno essere sommersa dalla superficie del mare a seconda delle condizioni di funzionamento. Tali particolari strutture, per le quali è corretto parlare di trasmissione piuttosto che di tracimazione ondosa, vengono dette LCS (“Low-crested structures”); sono state largamente studiate negli ultimi vent’anni, con il principale obiettivo di modellare e stimare la dissipazione energetica provocata dalla struttura, determinandone il coefficiente di trasmissione K_t .

L’approccio più comune per la progettazione di LCS è l’impiego di formule empiriche che, sempre sulla base di parametri descrittivi di opera e condizioni di attacco ondo-

so, forniscono un valore di K_t . Panizzo e Briganti (2007)⁴, partendo dall'idea "classica" del *fitting* di dati sperimentali e da alcuni risultati preliminari ottenuti da Panizzo stesso et al. nel 2003, e prendendo atto del fatto che, spesso, le formule basate sull'interpretazione dei fenomeni fisici mostrano alcuni punti deboli e notevole *scatter*, hanno messo a punto un modello numerico calibrato per la predizione del coefficiente di trasmissione per strutture a cresta bassa basate sulle reti neurali artificiali.

Una peculiarità del lavoro presentato da Panizzo e Briganti è la scelta di utilizzare dati sulle condizioni ondose calcolati al piede della struttura e non alla posizione alla quale i parametri sono misurati durante i rilievi sperimentali.

Il *dataset* utilizzato – che complessivamente consta di 2285 test – deriva in buona parte dal più grande database raccolto nell'ambito del progetto europeo DELOS, che a sua volta ha riunito dati provenienti da svariati test 2D sviluppati in studi su strutture costiere e trasmissione ondosa. Tale *dataset* è stato suddiviso in sette gruppi differenti, su ciascuno dei quali è stata tesata la ANN; ogni gruppo contiene dati omogenei per tipo di strutture LCS.

Dal momento che il dataset viene utilizzato come input per una rete neurale, la distribuzione dei parametri all'interno del database stesso gioca un ruolo cruciale: va difatti tenuto presente che una ANN può fornire predizioni ragionevoli soltanto entro i range dei parametri per i quali è stata addestrata. Ad esempio, una larga concentrazione di dati in una certa regione della distribuzione di frequenza di un parametro può influenzare le performance della rete stessa. Per questo motivo, Panizzo e Briganti hanno scelto di analizzare con istogrammi di frequenza i valori dei vari parametri per visualizzarne la distribuzione.




Figura 4-12 – Definizione dei parametri coinvolti nel processo di trasmissione ondosa

La costruzione della rete è cominciata con il "re-scaling" in un range compreso tra $[-1; +1]$ dei valori dei parametri utilizzati nel vettore di input, tenendo conto dei valori massimi e minimi di ciascuna delle variabili. Il numero di elementi del vettore di input (quindi il numero di parametri di input) è 6: $[\frac{R_c}{H_i}, \frac{H_i}{D_{n50}}, \frac{B}{H_i}, \frac{B}{L_{op}}, \xi_{op}, \frac{H_i}{h}]$; 6 sono anche i neuroni scelti per l'*hidden layer*. Un solo neurone, invece, per l'*output*: il coefficiente di trasmissione K_t . Il numero di *hidden layer* e dei relativi neuroni (rispettivamente, 1 e 3) è stato definito in fase di ottimizzazione del network. Sia nell'*input layer* che nell'*hidden layer* è presente un neurone di *bias* per l'aggiustamento delle funzioni di attivazione dei neuroni.

⁴ "Analysis of wave transmission behind low-crested breakwaters using neural networks", Andrea Panizzo, Riccardo Briganti, *Coastal Engineering* 54 (2007), pagg. 643 – 656.




Figura 4-13 - Architettura di rete utilizzata da Panizzo e Briganti per la stima di K_t

Per l'attivazione dei neuroni dell'*hidden layer* Panizzo e Briganti hanno usato una funzione di trasformazione di tipo "sigmoide": $TF(A_m) = \frac{1}{1+e^{-A_m}}$, dove $TF(A_m)$ è la funzione di attivazione del valore di attivazione A_m del neurone m ; per l'attivazione del neurone di output hanno invece impiegato una funzione lineare: $TF(A_m) = A_m$.

La funzione di errore è stata definita come $E = \frac{1}{2} \sum_{p=1}^P ||Y - K_t||^2$, dove Y è il valore predetto dalla rete del coefficiente di trasmissione, e K_t è il dato sperimentale noto; P è il numero di dati a disposizione per K_t (e quindi il numero di elementi dei vettori Y e K_t).

Per la definizione della matrice dei pesi e il vettore dei *bias*, \mathbf{W} e \mathbf{b} , e per la *training* della rete neurale, è stato usato l'algoritmo di Levenberg-Marquardt, che minimizza la funzione di errore cercando di mantenere piccolo lo step tra la "vecchia" e la "nuova" configurazione della matrice dei pesi, \mathbf{W}^{old} e \mathbf{W}^{new} (e \mathbf{b}^{old} e \mathbf{b}^{new}).

La procedura di *testing* per verificare l'applicabilità della rete neurale così creata è consistita nella suddivisione del dataset in due parti: l'80% dei dati è stata sempre impiegata nelle procedure di *learning* e *training* e il calcolo di \mathbf{W} e \mathbf{b} , mentre il restante 20% è stato utilizzato per avviare la simulazione della rete e controllare i risultati. Poiché il network ha mostrato errori tra fase di *training* e fase di *testing* sensibilmente dello stesso ordine di grandezza, Panizzo e Briganti hanno potuto concludere che la loro ANN è risultata essere uno strumento affidabile di predizione della trasmissione ondosa a tergo di strutture LCS.

I buoni risultati forniti dalla ANN sono evidenziati dal confronto delle sue performance con quelle di altri strumenti di progettazione preesistenti al loro lavoro: Panizzo e Briganti hanno scelto di confrontare gli output della *neural network* con le relazioni empiriche proposte da Van der Meer nel 2005 (VDM 2005), poiché anch'esse sono state calibrate sullo stesso set di dati.

$$\begin{cases} K_t = -0,4 \cdot \frac{R_c}{H_i} + 0,64 \left(\frac{B}{H_i}\right)^{-0,31} \cdot (1 - 0,5\xi_{op}), & \text{per } \frac{B}{H_i} < 10 \\ K_t = -0,35 \cdot \frac{R_c}{H_i} + 0,51 \left(\frac{B}{H_i}\right)^{-0,65} \cdot (1 - 0,41\xi_{op}), & \text{per } \frac{B}{H_i} > 10 \end{cases}$$

e per strutture sommerse

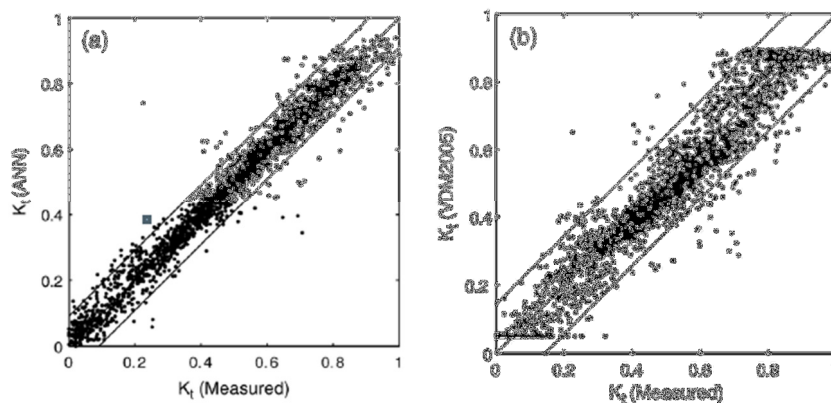


Figura 4-14 Confronto tra i risultati della ANN di Panizzo e Briganti e quelli delle formule del VDM2005

Una spiegazione della migliore accuratezza delle predizioni della ANN è sicuramente dovuta al fatto che essa impiega più parametri e più funzioni non lineari di *fitting* dei dati di quanto non facciano le formule empiriche per K_t di VDM 2005.

Un miglioramento che può essere applicato al network di Panizzo e Briganti è l'introduzione della possibilità di poter modellare strutture dalle forme più complesse di quelle standard, e probabilmente si è anche resa necessaria una campagna sperimentale per la creazione di un database omogeneo, specificatamente creato per una rete neurale.

4.5 Modellazione spettrale combinata con ANN per la variabilità delle onde

Lo studio di analisi di variabilità delle onde generate dal vento nei bacini mareali del *German Wadden Sea* (sulla costa tedesca del Mare del Nord), effettuato da Herman, Kaiser e Niemeyer, rientra nel progetto di ricerca MOSES (“*Modelling of the medium-term wave climatology at the German North Sea coast*”). Tra i fini di MOSES vi è proprio la produzione di un database a medio termine temporale (circa 40 anni) dei livelli dell'acqua, delle correnti e delle caratteristiche significative delle onde nel *German Wadden Sea*.

La conoscenza della variabilità nel breve e medio termine dell'idrodinamica delle onde e delle correnti in un bacino è un importante prerequisito per studiare diversi aspetti dei processi delle zone litoranee. Sebbene i modelli di idrodinamica costiera e delle onde marine siano in grado di riprodurre accuratamente tali processi in bacini mareali non particolarmente profondi, per ottenere una buona risoluzione spaziale e temporale la loro applicazione richiede notevoli costi computazionali.

Da tale esigenza di risparmio computazionale nasce l'idea di impiegare tecniche alternative, come ad esempio le *neural networks*. Herman, Kaiser e Niemeyer⁵ hanno utilizzato i risultati ad alta risoluzione delle simulazioni delle onde generate dal vento come punto di inizio per lo sviluppo di un sistema di modellazione basato proprio sulle reti neurali, che consente predizioni più rapide e più accurate delle distribuzioni spaziali significative di altezza ondosa (H_s), periodo d'onda ($T_e = T_{-1,0}$), direzione d'onda prevalente (ϑ_m).

La propagazione e la trasformazione delle onde da largo verso riva sono state inizialmente investigate mediante il modello spettrale di terza generazione SWAN, allo scopo di individuare fra i dati le componenti spaziali predominanti; queste ultime sono poi state rese adimensionali, in modo da risultare di più semplice ed efficiente lettura per la seconda fase della modellazione, per mezzo di rete neurale. La ANN riceveva come input i risultati dell'analisi delle principali componenti effettuata dal SWAN, con il compito di consentire una modellazione predittiva dei parametri significativi delle onde nell'intera area di studio.

⁵ “*Wind-wave variability in a shallow tidal sea – Spectral modeling combined with neural network methods*”, Agnieszka Herman, Ralf Kaiser, Hanz D. Niemeyer, *Coastal Engineering* 56 (2009), pagg. 759 – 772.

L'architettura della ANN è del tipo *multi-layer perceptron* (MLP), e consiste complessivamente di tre *layer*, quindi di un solo *hidden layer*. Perciò può essere definita una “*two-layer feed-forward network*” con procedura di *learning* di “*error gradient back-propagation*”. Alcuni dei principali parametri utilizzati nella MLP sono:

- funzione di attivazione di tangente iperbolica per l'*hidden layer*;
- funzione di attivazione lineare per l'*output layer* (la scelta più appropriata per i problemi di regressione non lineare);
- algoritmo di ottimizzazione basato sul gradiente coniugato.

Sono stati testati altri algoritmi di ottimizzazione e altre architetture di rete, ma tutti fornivano errori o prestazioni peggiori.

Il vettore di input è stato costruito con 14 elementi, rappresentanti altezza d'onda significativa, periodo energetico, direzione d'onda significativa, livello dell'acqua, componenti della velocità del vento in due direzioni e medie temporali di tali componenti. Rispettivamente:

$$\begin{aligned} & [H_{s,HIP}(\tilde{t}), T_{e,HIP}(t), \theta_{m,HIP}(t), \eta_{HIP}(\tilde{t}), u_w(t), v_w(t), \bar{u}_w(t), \bar{v}_w(t)] \\ & [H_{s,HIP}(t), T_{e,HIP}(\tilde{t}), \theta_{m,HIP}(t), \eta_{HIP}(\tilde{t}), u_w(t), v_w(t), \bar{u}_w(t), \bar{v}_w(t)] \\ & [H_{s,HIP}(t), T_{e,HIP}(t), \theta_{m,HIP}(\tilde{t}), \eta_{HIP}(\tilde{t}), u_w(t), v_w(t), \bar{u}_w(t), \bar{v}_w(t)], \end{aligned}$$

dove t denota il tempo e $\tilde{t} = [t - 3\Delta t, t - 2\Delta t, t - \Delta t]$.

Il numero di neuroni per l'*hidden layer* è stato stabilito sulla base di test di sensibilità, e alla fine è stato definito come 90.

Il vettore di output contiene invece 5 o 10 neuroni a seconda che il parametro di predizione sia la serie temporale descrittiva dell'altezza d'onda significativa $[P_{H_s,n}(t)]_{n=1,\dots,5}$ (5 neuroni), la serie temporale per il periodo energetico $[P_{T_e,n}(t)]_{n=1,\dots,5}$ (5 neuroni) o la serie temporale per la direzione d'onda significativa $[P_{\vartheta_m,n}(t)]_{n=1,\dots,10}$ (10 neuroni).

Anche in questo caso, il *dataset* è stato suddiviso tra dati di *training* e dati di *testing*.

	PC _{H,1}	PC _{H,2}	PC _{H,3}	PC _{H,4}	PC _{H,5}
Corr. coef. (%)	99.49	98.97	96.37	88.10	95.01
σ_{std} (-)	0.111	0.141	0.266	0.461	0.299
Mean difference (-)	0.007	0.000	0.001	0.025	0.006
	PC _{T,1}	PC _{T,2}	PC _{T,3}	PC _{T,4}	PC _{T,5}
Corr. coef. (%)	98.04	98.94	93.50	98.66	95.55
σ_{std} (-)	0.200	0.147	0.371	0.164	0.305
Mean difference (-)	-0.020	0.014	-0.034	-0.007	0.029
	$\theta(PC_{\vartheta,1})$	$\theta(PC_{\vartheta,2})$	$\theta(PC_{\vartheta,3})$	$\theta(PC_{\vartheta,4})$	$\theta(PC_{\vartheta,5})$
Corr. coef. (%)	99.35	98.23	97.78	98.15	96.38
σ_{std} (degr)	14.02	20.11	22.52	20.55	29.59
Mean difference (degr)	0.18	0.92	0.22	0.97	0.28

Figura 4-15 - Statistiche descrittive delle performance della ANN per H_s , T_e e ϑ_m

La figura 4-16 riporta il confronto tra valori delle serie temporali riprodotti dalla rete neurale e valori originari sperimentali: i grafici denotati da (a) si riferiscono alle serie di altezza d'onda H_s , i grafici (b) si riferiscono alle serie di periodo energetico T_e e i grafici (c) alle serie di direzione d'onda ϑ_m . La tabella di figura 4-15 riporta anch'essa, in modo sintetico, le statistiche delle performance della rete per le 3 distribuzioni temporali.




Figura 4-16 - Diagrammi di "scatter" dei valori delle serie temporale originali (ascissa) e riprodotte dalle reti neurali (ordinata)

Come si può osservare sia dalla tabella di figura 4-15 che dai diagrammi di *scatter*, il coefficiente di correlazione è piuttosto alto per le prime due serie temporali di tutti e tre i parametri altezza d'onda, ed è altrettanto accettabile per le terze serie di periodo energetico e direzione d'onda.

In definitiva, la combinazione di modellazione spettrale e neurale di onde generate dal vento si è dimostrata effettivamente un'alternativa all'approccio modellistico classico. Un importante aspetto dell'impiego di tale tecnica è la sua applicabilità ad altre regioni similari: alcuni test effettuati successivamente in altre aree della costa tedesca hanno suggerito, infatti, che la stessa struttura di rete neurale e gli stessi set di parametri di input sono ancora adatti per la simulazione di tali aree – posto che, in ogni caso, la dimensione dell'area modellata sia abbastanza piccola che le forzanti meteorologiche e mareali siano fortemente correlate spazialmente e possano essere rappresentate da serie temporali in una località prestabilita.

In generale, per rendere la tecnica di Herman, Kaiser e Niemeyer applicabile anche a regioni con maggiore non uniformità delle forzanti, è necessario implementare nel modello di ANN anche le analisi delle principali componenti delle variabili forzanti stesse.

Infine, la ANN avrebbe probabilmente restituito prestazioni migliori se fosse stato possibile utilizzare serie temporali più lunghe per il *training* e la validazione.

5 Conclusioni

È stato illustrato in cosa consista concettualmente la modellazione a reti neurali, mediante la descrizione degli elementi caratteristici e dei principi di funzionamento di tali modelli, sottolineandone la natura di "black box". È inoltre stato posto l'accento sull'essenzialità del poter disporre di un adeguato database, quale strumento fondamentale per la realizzazione, l'addestramento e la verifica delle ANN.

Circostanziando l'applicazione delle *Neural Network* all'idraulica marittima, è stato proposto per primo l'esempio del progetto CLASH per la stima della portata di tracimazione, in quanto è da esso, e dal relativo database, che è stata realizzata la maggior parte degli altri modelli. Un caso particolare di impiego successivo è quello che vede l'accoppiamento di due reti consequenziali per separare la fase di analisi e classificazione dei dati da quella di vera e propria stima dei parametri di output (a riprova dell'importanza della selezione del database).

Altre applicazioni riguardano la predizione delle grandezze caratteristiche delle onde e la stima del coefficiente di trasmissione.

Da tutti gli esempi riportati, si può dedurre una buona risposta da parte della modellazione a reti neurali ai problemi dell'idraulica marittima, pertanto si può auspicare ad ulteriori impieghi, in primis, per complementarietà dei fenomeni di interazione onda-struttura e omogeneità dei parametri in gioco, la messa a punto di un modello di ANN dedicato esclusivamente alla predizione del coefficiente di riflessione, tuttora non realizzato.

BIBLIOGRAFIA

Herman A., Kaiser R., Niemeyer H. D., "Wind-wave variability in a shallow tidal sea – Spectral modelling combined with neural network methods", *Coastal Eng.* (2009), doi:10.1016/j.coastaleng.2009.02.007

Panizzo A., Briganti R., "Analysis of wave transmission behind low-crested breakwaters using neural networks", *Coastal Eng.* (2007), doi:10.1016/j.coastaleng.2007.01.001

Van Gent M. R. A., Pozueta B., Van den Boogaard H. F. P., Medina J. R., "Prediction method. Neural network modelling of wave overtopping at coastal structures. D 42 Final report on generic prediction method", Ed. Universidad Politecnica de Valencia

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 Eng.* (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 Eng.* (2008), doi:10.1016/j.coastaleng.2007.12.002

Zanuttigh B., van der Meer J. W. , "Wave reflection from coastal structures in design conditions", *Coastal Eng.* (2008), doi:10.1016/j.coastaleng.2008.02.009