

## RETI NEURALI PER MODELLISTICA DI INCIDENTE

*Marzio Marseguerra, Enrico Zio, Cristina Modica*  
Dipartimento di Ingegneria Nucleare del Politecnico di Milano  
Via Ponzio 34/3, 20133 Milano, Italia  
marzio.marseguerra@polimi.it

*F. Parozzi*

CESI - Power Generation Processes, Via Reggio Emilia, 39, 20090 Segrate - Milano, Italia

### SOMMARIO

In questo lavoro viene studiata l'opportunità di utilizzare le reti neurali artificiali (RNA) per descrivere l'evoluzione dinamica di incidenti di impianto. Le reti neurali sono in grado di fornire efficaci mappature non-lineari input/output tra spazi di ingresso e di uscita multidimensionali, senza la necessità di dover esplicitamente identificare e rappresentare le relazioni tra le variabili con modelli analitici. Grazie a queste proprietà, le reti neurali possono essere efficacemente impiegate nella modellazione di complesse e non-lineari dinamiche di incidente. In questo lavoro viene considerato il problema della fuoriuscita, in atmosfera o nella geosfera, di materiale nocivo da impianti di processo. In particolare, vengono qui dettagliatamente analizzati scenari incidentali di perdita di refrigerante (piccoli e medi LOCA) tipici dei reattori nucleari ad acqua in pressione (PWR).

### 1. INTRODUZIONE

Spesso, la complessità dei fenomeni che governano l'evoluzione fisica degli incidenti e la numerosità delle variabili in gioco rendono praticamente impossibile una trattazione analitica classica della loro descrizione modellistica. In questi casi, può essere vantaggioso ricorrere ad algoritmi empirici, quali quelli neurali, in grado di ricostruire le relazioni tra i parametri in gioco attraverso la conoscenza di esempi di input e corrispondenti output raccolti sull'impianto.

In questo lavoro viene studiata l'opportunità di utilizzare le reti neurali artificiali (RNA) per descrivere l'evoluzione dinamica di incidenti di impianto. Le reti neurali sono algoritmi di calcolo ispirati al comportamento del cervello umano. Il tipo di rete neurale qui considerato elabora l'informazione attraverso un sistema di elementi di processamento non lineari, detti *nodi*, collegati tra loro da connessioni pesate, dette sinapsi. Ciascun nodo elabora l'informazione indipendentemente da tutti gli altri, così da permettere alla rete di operare efficacemente in parallelo. I pesi delle connessioni del sistema neurale costituiscono i parametri del modello neurale. Le reti neurali sono in grado di fornire efficaci mappature non-lineari input/output tra spazi di ingresso e di uscita multidimensionali, senza la necessità di dover esplicitamente identificare e rappresentare le relazioni tra le variabili con modelli analitici. Mediante una fase di addestramento supervisionato, durante il quale vengono ripetutamente forniti alla rete diversi esempi di valori di input e corrispondenti valori di output, vengono calibrati i numerosi parametri del modello neurale, ovvero i pesi delle connessioni tra nodi. Al termine dell'addestramento, in corrispondenza di nuovi valori di ingresso la rete è in grado di richiamare l'informazione immagazzinata al suo interno e di produrre un valore di uscita coerente con la rappresentazione multiparametrica interna della mappatura input/output di interesse.

Grazie a queste proprietà, le reti neurali possono essere efficacemente impiegate nella modellazione di complesse e non-lineari dinamiche di incidente. In questo lavoro viene considerato il problema della fuoriuscita, in atmosfera o nella geosfera, di materiale nocivo da impianti di processo. In particolare, vengono qui dettagliatamente analizzati scenari incidentali di perdita di refrigerante (piccoli e medi LOCA, Loss Of Cool Accident) tipici dei reattori nucleari ad acqua in pressione (PWR).

L'interesse specifico è legato all'estensione del PSA (Probabilistic Safety Assessment - Analisi Probabilistica di Sicurezza) classico a quello dinamico, con l'obiettivo di eseguire un'analisi di sicurezza più realistica prendendo in considerazione non solo i guasti stocastici, ma anche l'evoluzione deterministica delle variabili di processo. Un approccio formale per tenere conto del comportamento dinamico nell'analisi di rischio è quello della Dinamica Probabilistica [1], dal quale sono derivati, negli ultimi dieci anni, vari metodi quantitativi [2, 3, 4, 5, 6, 7]. L'analisi dinamica richiede la soluzione di modelli matematici che descrivono il comportamento dell'impianto. Le corrispondenti equazioni devono essere integrate con passi di tempo relativi all'evoluzione temporale dei processi fisici, e quindi molto minori dei tempi di guasto stocastici caratteristici di un'analisi PSA. Questo comporta, in generale, tempi di calcolo molto elevati; pertanto, molte

ricerche attuali in questo ambito riguardano lo studio di nuove tecniche veloci ed efficienti per la soluzione approssimata delle equazioni fisiche che descrivono l'evoluzione delle variabili di processo di un impianto.

Il presente lavoro utilizza le Reti Neurali Artificiali (RNA) multistrato, supervisionate, con elaborazione dell'informazione "in avanti", addestrate con l'algoritmo di retro-propagazione dell'errore [8], per la simulazione di un caso studio riguardante l'evoluzione all'interno del contenitore di un incidente severo in un reattore nucleare (PSA di Livello 2).

Il calcolo del trasporto di radionuclidi durante un incidente con danneggiamento severo delle barre di combustibile, richiede una valutazione appropriata delle condizioni termo-idrauliche che influenzano sia gli equilibri chimici fra le varie specie coinvolte, sia i fenomeni di ritenzione dei radionuclidi. Inoltre, il cammino seguito dal flusso radioattivo attraverso le varie barriere ingegneristiche di sicurezza, prima di essere rilasciato all'ambiente, deve essere simulato con attenzione. In questo contesto, il presente lavoro si limita ad un caso studio focalizzato sull'evoluzione del termine di sorgente governata dai fenomeni di trasporto e deposizione di aerosol e vapori, con ipotesi semplificate per quanto riguarda gli aspetti chimici e termo-idraulici. Tramite il codice meccanicistico ECART [9], che riflette lo stato dell'arte ed è stato da noi utilizzato come modello di riferimento, è stato ottenuto un insieme di evoluzioni delle concentrazioni di radionuclidi nel contenitore in diversi incidenti di fusione del nocciolo, fino a 72 ore dall'inizio dell'incidente. I valori così raccolti costituiscono i pattern di input/output in seguito utilizzati per l'addestramento delle reti neurali.

Nel paragrafo successivo, si fornisce una breve descrizione dei fenomeni e dei processi fisici che caratterizzano l'evoluzione dell'incidente, con particolare attenzione al trasporto e deposizione di aerosol e vapori nel contenitore; inoltre si presenta dettagliatamente il caso studio oggetto dell'applicazione del metodo delle reti neurali artificiali. Nel paragrafo 3, si fornisce un breve cenno sulle basi del calcolo neurale. Nel paragrafo 4, viene presentato il modello neurale da noi sviluppato per la simulazione veloce, sebbene approssimata, dell'evoluzione del sistema alle condizioni di input dell'incidente specificato. Nel paragrafo 5, si mostra la capacità delle reti neurali addestrate di fornire direttamente i valori di concentrazione dei radionuclidi a tempi assegnati, a partire da assegnate condizioni di ingresso, consentendo così la ricostruzione dell'evoluzione del termine di sorgente nel contenitore per diverse condizioni iniziali. Infine, nel paragrafo 6 si traggono alcune conclusioni sull'approccio studiato, evidenziandone vantaggi e svantaggi.

## **2. LA FISICA DEL PROBLEMA**

La principale preoccupazione legata al funzionamento delle centrali nucleari è il potenziale rilascio, in caso di incidente, di prodotti di fissione all'ambiente circostante. Lo scopo di questo lavoro è la valutazione, tramite un appropriato set di reti neurali, delle concentrazioni aeriformi di gruppi rappresentativi di elementi radioattivi nell'atmosfera del contenitore (termine di sorgente del contenitore), durante l'evoluzione di un incidente severo tipico di un reattore PWR di 1000 MWe, escludendo comunque la possibilità di cedimento del contenitore.

Aerosol, vapori e gas vengono rilasciati dal nocciolo di reattori ad acqua leggera (LWR) come conseguenza di incidenti severi. Si possono distinguere due fasi di rilascio: la prima, dal surriscaldamento del nocciolo fino alla perforazione del vessel (fase in-vessel); la seconda, successiva alla perforazione del recipiente in pressione, inizia quando i frammenti del nocciolo attaccano il calcestruzzo del basamento (fase ex-vessel). Possono presentarsi vari tipi di interazione fra gli aerosol e vapori dei prodotti di fissione e l'ambiente circostante; i fenomeni di trasporto di maggior interesse sono i seguenti: condensazione / evaporazione dei vapori sulle superfici strutturali o sulle particelle in sospensione, chemio-assorbimento dei vapori sulle superfici, crescita del particolato dovuta ad agglomerazione del particolato sospeso ed a condensazione di vapori radioattivi e di vapor d'acqua, risospensione a secco (dry resuspension) di particelle dalle superfici, abbattimento per gorgogliamento (pool scrubbing) di aerosol.

Il tipo di sequenze incidentali considerate è rappresentativo di sequenze aventi come eventi iniziatori piccoli-medi LOCA (Loss Of Coolant Accident) che potrebbero verificarsi in PWR di grossa taglia. La tipica sequenza di rilascio considerata nel caso studio è semplificata, ed è caratterizzata dalle due suddette distinte fasi di rilascio nel contenitore: la fase in-vessel e la fase ex-vessel (Figura 1).

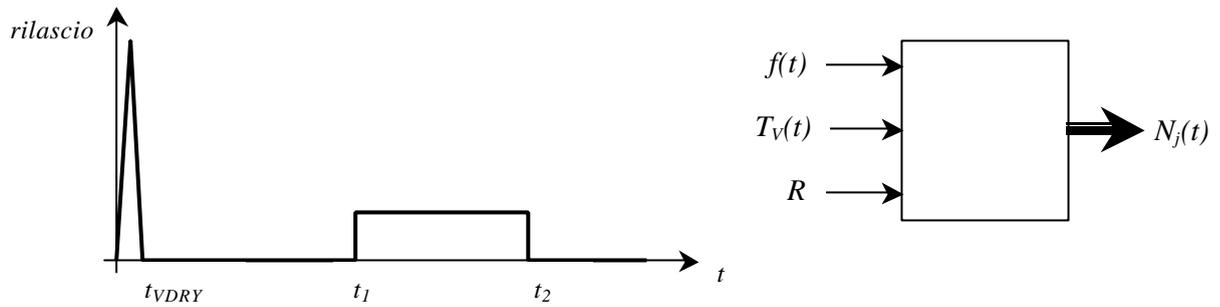


Figura 1: Tipica sequenza di rilascio nel contenitore considerata per il caso studio.

Ogni sequenza è caratterizzata da diversi valori delle seguenti variabili di input:

- $f(t)$  rateo di rilascio dei radionuclidi [kg/s]. I tempi incidentali rilevanti sono  $t = \{t_{VDRY}, t_1, t_2\}$ , ovvero i tempi ai quali, rispettivamente, il vessel si è completamente asciugato, inizia l'interazione fra nocciolo fuso e calcestruzzo, finisce la suddetta interazione;
- $T_V(t)$  temperatura dell'atmosfera nel contenitore, ai tempi  $t = \{t_{VDRY}, 12h, 24h, 48h, 72h\}$ ;  $T_V \in [330K, 410K]$  (il limite superiore è preso in modo da evitare il cedimento del contenitore dovuto alla pressione di aria e vapore);
- $R$  fattore di rilascio per la fase in-vessel: a seconda della sequenza incidentale, la frazione  $(1 - R)$  del potenziale rilascio in-vessel è trattenuta nel circuito primario e non fuoriesce nel contenitore;  $R \in [0.1, 0.8]$ : il limite inferiore è rappresentativo di alta ritenzione nel sistema di raffreddamento del reattore (RCS, Reactor Cooling System), mentre quello superiore rappresenta la situazione di un grande LOCA.

Le variabili di output del sistema considerate sono le seguenti:

- $N_j(t)$  concentrazioni nel contenitore [kg/m<sup>3</sup>] di radionuclidi e di materiali strutturali  $j = \{CsI, CsOH, Te_2, SrO, RuO_2, La_2O_3, \text{Materiali Strutturali (SM)}\}$  ai tempi  $t = \{6h, 12h, 24h, 36h, 48h, 60h, 72h\}$ .

Infine, il contenitore considerato è di tipo duale in calcestruzzo con volume  $V = 73000 \text{ m}^3$ ; il basamento è di calcestruzzo basaltico; i fenomeni incidentali non considerano l'esplosione di vapore, il cedimento del contenitore, il pool scrubbing di aerosol e la risospensione di aerosol; gli aerosol sono supposti sferici con diametro aerodinamico di massa distribuito secondo una log-normale con mediana pari a  $3 \mu\text{m}$  e deviazione standard geometrica di  $2.5 \mu\text{m}$  e porosità degli ossidi di 0.5; l'inventario degli elementi radioattivi è quello risultante da un calcolo con il codice ORIGEN-2 per un tipico PWR da 1000 MWe, con un bruciamento di  $1.13 \cdot 10^6 \text{ MWd}$  a 3 ore dopo lo spegnimento [9]; i ratei di rilascio delle fasi in-vessel ed ex-vessel sono stimati a partire dai pochi dati sperimentali disponibili in letteratura [9, 10, 11].

E' qui importante segnalare che fra tutte le suddette ipotesi, quelle riguardanti le caratteristiche degli aerosol sono di gran lunga le più restrittive, nel senso che i risultati della simulazione dipendono fortemente dalla distribuzione dei diametri aerodinamici.

### 3. LE RETI NEURALI

Le reti neurali artificiali (RNA) sono algoritmi di calcolo che simulano un sistema computazionale parallelo costituito da un certo numero di unità elementari di processamento dell'informazione (*nodi*) operanti in maniera indipendente le une dalle altre e che si trasmettono l'informazione attraverso una rete di connessioni (*sinapsi*) pesate [12, 13, 14]. Le connessioni tra i nodi possono avere peso sia positivo che negativo [15].

Le principali caratteristiche di una RNA sono:

- la sua architettura (*topologia*), che descrive il sistema di interconnessione tra i nodi;
- le *funzioni di attivazione* (o *funzioni di trasferimento*) dei singoli nodi;
- l'*algoritmo di addestramento*.

Le reti più comunemente usate sono del tipo multi-strato unidirezionale, nelle quali l'informazione viene trasmessa esclusivamente nella direzione ingresso-uscita. Nella loro struttura più semplice, esse consistono di tre strati di nodi: lo strato di input, quello nascosto e quello di output, con un numero di nodi  $n_i$ ,  $n_h$ , e  $n_o$

rispettivamente (Figura 2). Ogni nodo riceve in ingresso una combinazione lineare dei valori degli output, pesati dai valori delle connessioni, di tutti i nodi dello strato precedente, elabora tale informazione attraverso una funzione, tipicamente sigmoideale  $f(x) = (1 + e^{-x})^{-1}$ , detta *funzione di attivazione*, ed invia il risultato a tutti i nodi dello strato successivo.

Nel presente lavoro è stato adoperato questo tipo di rete a tre strati poiché è dimostrato che tali reti sono “approssimanti universali”, cioè atte ad approssimare una qualsiasi funzione e le sue derivate con un grado di precisione comunque elevato [16, 17]. Sia lo strato di input che quello nascosto hanno un nodo addizionale (*nodo di bias*), che funge da valore di soglia per l’argomento della funzione di attivazione e che ha la caratteristica di fornire in uscita sempre un valore unitario.

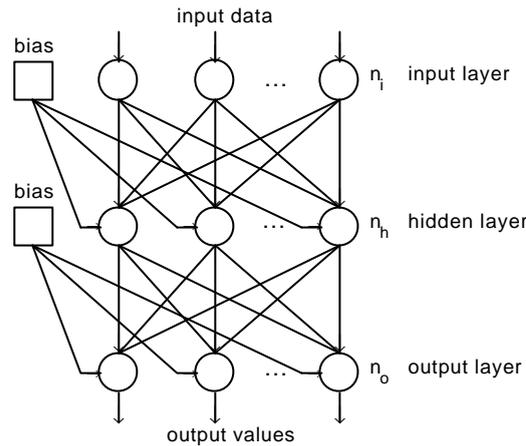


Figura 2: Schema di una rete neurale unidirezionale a tre strati.

La taratura dei pesi delle connessioni, che costituiscono i parametri del modello neurale, avviene mediante una *procedura di addestramento* che consiste in un aggiornamento iterativo dei pesi a partire da valori iniziali arbitrari. Per eseguire l’addestramento occorre disporre di un training-set, cioè un insieme di esempi (patterns), ciascuno costituito dagli  $n_i$  valori di input e dai corrispondenti  $n_o$  valori di output. La procedura consiste nel presentare alla rete gruppi di  $n_p$  patterns e nell’aggiustare i valori delle connessioni minimizzando l’errore compiuto dalla rete nel calcolo dell’output, secondo una predefinita misura di errore.

In questo lavoro abbiamo adottato l’algoritmo di propagazione a ritroso dell’errore (*Error Back Propagation, EBP*) che deriva dal più generale metodo del gradiente [12]. Si presentano alla rete, ripetutamente,  $n_p$  patterns di input/output presi a caso tra tutti quelli disponibili e i valori delle connessioni vengono modificati in modo da minimizzare la *funzione Energia*, definita come

$$D = \frac{1}{2n_p n_o} \sum_{p=1}^{n_p} \sum_{l=1}^{n_o} (t_{pl} - u_{pl})^2 \quad (1)$$

dove  $t_{pl}$  e  $u_{pl}$  sono i valori veri e i valori calcolati dalla rete al nodo  $l$ -esimo di output, per il  $p$ -esimo pattern presentato,  $l = 1, 2, \dots, n_o, p = 1, 2, \dots, n_p$ .

Mediante questa procedura di addestramento, la rete è in grado di tarare i pesi, ossia i parametri del modello neurale interno che descrive la mappatura input/output del processo in esame.

Al termine dell’addestramento i valori dei pesi delle sinapsi sono fissati. Nuovi patterns di input possono a questo punto essere presentati alla rete la quale è in grado di richiamare l’informazione contenuta nei pesi e di produrre gli output corrispondenti, in accordo con la rappresentazione neurale interna del legame esistente tra input e output. Si osservi che la non linearità della funzione sigmoideale di attivazione dei nodi consente di costruire mappature neurali di legami input/output non lineari.

Inoltre, la già citata proprietà di processamento in parallelo del segnale consente di ottenere una tolleranza intrinseca a valori non ottimali di alcune connessioni e una notevole capacità di generalizzazione a nuove combinazioni di valori di input.

#### 4. IL MODELLO NEURALE

Come detto in precedenza, lo scopo del presente lavoro è quello di sviluppare un modello di simulazione neurale per l'evoluzione del processo incidentale illustrato nel precedente paragrafo. Il volume di input è lo spazio a 9 dimensioni delle variabili  $\{t_{VDRY}, t_1, t_2, T_V(t_{VDRY}), T_V(12h), T_V(24h), T_V(48h), T_V(72h), R\}$ ; il volume di output è lo spazio a 49 dimensioni delle concentrazioni  $\{N_j(t)\}, j = \{CsI, CsOH, \dots, SM\}, t = \{6h, 12h, \dots, 72h\}$ . Tramite ECART, sono stati ottenuti un gran numero di pattern input/output per l'addestramento delle reti, in maniera da coprire uniformemente il volume d'interesse. Il sistema di simulazione di reti neurali deve quindi assolvere al difficile compito di mappare uno spazio 9-D in uno spazio 49-D.

Data la struttura del problema, si potrebbe cercare di addestrare una sola RNA, avente come ingresso  $n_i = 9$  nodi e come uscita  $n_o = 49$  nodi. Questo tipo di approccio si è rivelato subito difficoltoso, a causa delle grandi dimensioni dei volumi di input e di output (quest'ultimo si estende su circa 8 ordini di grandezza). Sorge quindi spontanea la necessità di suddividere il compito di modellare la dinamica del processo in più parti, mediante specifiche sotto-reti con strutture più semplici. Per procedere alla suddivisione, è stata effettuata un'analisi preliminare dei dati. Il successivo addestramento delle reti, su volumi ridotti dello spazio di input/output, è stato eseguito con il programma NEST (Neural Network Simulation Tool), sviluppato dal gruppo LASAR al Dipartimento di Ingegneria Nucleare del Politecnico di Milano ([www.cesnef.polimi.it/lasar.htm](http://www.cesnef.polimi.it/lasar.htm)).

##### 4.1 Analisi preliminare dei dati

La Figura 3 mostra un tipico andamento dell'evoluzione temporale delle concentrazioni dei radionuclidi che fuoriescono dal recipiente in pressione, in seguito ad un incidente durante il quale al tempo  $t_{VDRY} = 1h\ 38'$  il vessel si è completamente svuotato, al tempo  $t_1 = 34h\ 44'$  inizia la fase ex-vessel, ed al tempo  $t_2 = 59h$  finisce la fase ex-vessel. La rappresentazione è limitata ai valori considerati in corrispondenza dei sette punti temporali  $\{6h, 12h, 24h, 36h, 48h, 60h, 72h\}$  che rappresentano gli output di concentrazione di interesse. Si può notare che durante la fase in-vessel ( $t \leq 24h$ ) i sette elementi presentano lo stesso andamento qualitativo, differenziandosi solo per un fattore di scala; invece, durante la fase ex-vessel, essi mostrano un comportamento abbastanza diverso l'uno dall'altro, che dipende dai valori dei ratei di rilascio di ciascun elemento durante le due fasi. In particolare, la massa rilasciata durante la fase in-vessel è responsabile della diversa concentrazione dei vari elementi in questa fase. In realtà, gli elementi potrebbero presentare un comportamento differente l'uno dall'altro se per alcuni di essi si verificasse un cambiamento di fase: tuttavia, alle basse temperature considerate nel caso studio [330K, 410K] tutti gli elementi si trovano in fase condensata (aerosol solidi con tensione di vapore trascurabile). Per quel che riguarda la fase ex-vessel, se durante tale fase la quantità rilasciata nel contenitore è abbondante rispetto a quella rilasciata durante la fase in-vessel, si può riscontrare un netto incremento delle concentrazioni, come per esempio nel caso di  $Te_2$ ,  $SrO$ ,  $La_2O_3$  e Materiali Strutturali. Al contrario, per  $CsI$  e  $CsOH$  il rilascio ex-vessel è sufficiente soltanto a compensare la diminuzione di concentrazione dovuta ai meccanismi di deposizione, e quindi le corrispondenti concentrazioni tendono a stabilizzarsi. Infine, il rateo di rilascio ex-vessel è talmente ridotto per il  $RuO_2$  che riesce solo a frenare la diminuzione, dovuta alla deposizione, della sua concentrazione.

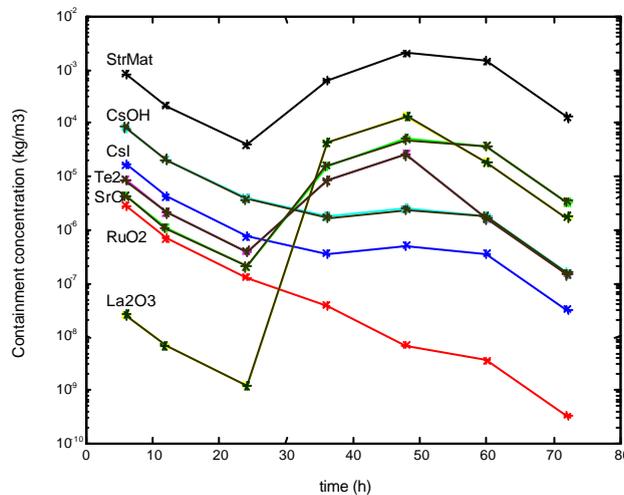


Figura 3: Concentrazione dei 7 elementi, per tempi incidentali  $t_{VDRY} = 1h\ 38'$ ,  $t_1 = 34h\ 44'$ ,  $t_2 = 59h$ .

## 4.2 Il “Neural Network Manager”

Diverse soluzioni sono state esplorate, alla ricerca dell’appropriata configurazione di modello neurale. In un primo tempo, sono state considerate sette RNA, ognuna addestrata a predire i valori di concentrazione di tutti gli elementi in corrispondenza di uno dei sette punti temporali considerati. Alla luce dei risultati poco soddisfacenti ottenuti, e delle osservazioni derivanti dall’analisi preliminare dei dati, si è suddiviso il problema in due parti, sulla base dell’esistenza o meno della fase ex-vessel al tempo considerato per la predizione delle concentrazioni. Quindi, per ognuno dei sette tempi considerati, sono state addestrate due reti per predire le concentrazioni: una rete “WITHOUT” per i casi in cui la fase ex-vessel non fosse ancora iniziata, ed una rete “WITH” per i casi in cui la fase ex-vessel fosse già iniziata, per un totale di 14 reti. I risultati così ottenuti sono soddisfacenti, specialmente per le reti “WITHOUT” (Figure 4-a e 4-b). Per le reti “WITH”, invece, si ha ancora una certa imprecisione di stima, dovuta soprattutto al fatto che i valori di output sono ancora dispersi su vari ordini di grandezza, come si nota nelle Figure 4-c e 4-d. I dati riportati in Figura 4 si riferiscono per semplicità grafica al solo radionuclide CsI all’unico tempo  $t = 72h$ : i dati relativi agli altri radionuclidi e agli altri tempi presentano andamenti analoghi e non vengono, per questo motivo, qui riportati.

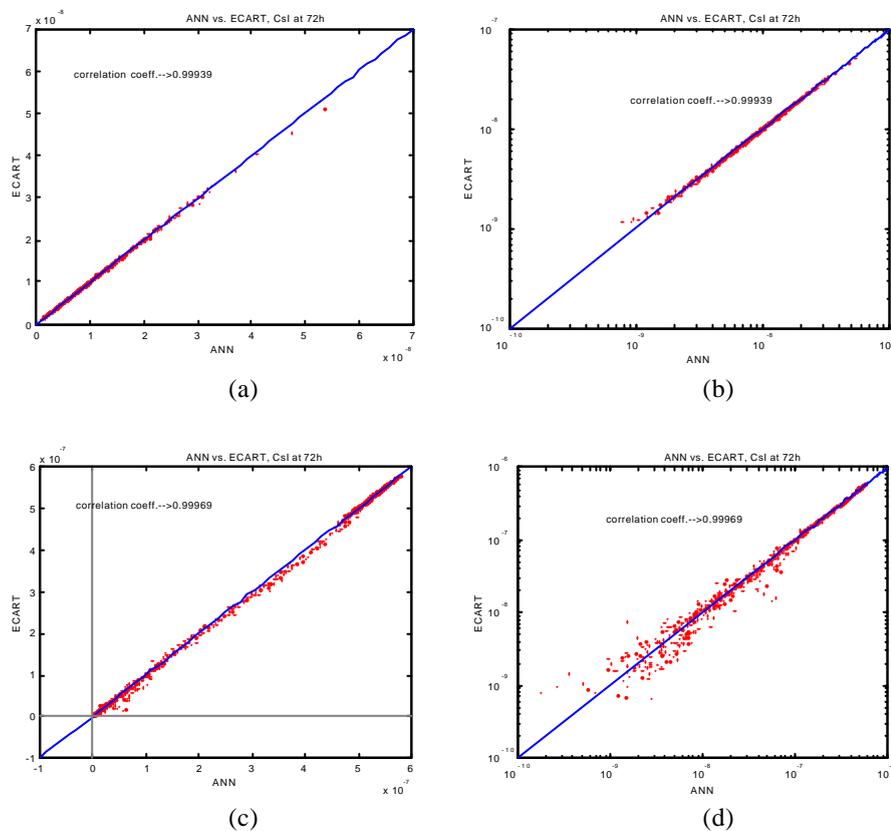


Figura 4: Confronto degli output ‘veri’ di ECART e degli output predetti dalle reti, per i valori del CsI a 72 ore ( $t = 72h$ ,  $j = CsI$ ); sopra: RNA senza fase ex-vessel (“WITHOUT”), rappresentazione in scala lineare (a) e logaritmica (b); sotto: RNA con fase ex-vessel (“WITH”), rappresentazione in scala lineare (c) e logaritmica (d).

Al fine di migliorare la precisione delle previsioni riguardanti scenari che presentano la fase ex-vessel, è stato addestrato un terzo tipo di rete che fornisce in output il logaritmo delle concentrazioni  $\tilde{N}_j(\mathbf{t}) = \log N_j(\mathbf{t})$ . Tale tipo di rete, qui di seguito chiamata rete “WITH\_LN”, consente una migliore accuratezza per quel che riguarda la predizione degli output con piccoli valori.

In totale, è stato sviluppato un insieme di 19 reti neurali per la predizione, con soddisfacente precisione, delle concentrazioni di interesse. Questo insieme è idealmente composto, per ognuno dei sette tempi considerati, da tre RNA (Figura 5): una rete “WITHOUT”, per i pattern di input relativi a scenari senza la fase ex-vessel; una rete “WITH”, per i pattern di input relativi a scenari con la fase ex-vessel e aventi come output

le concentrazioni  $N_j(\mathbf{t})$  dei vari elementi; una rete “*WITH\_LN*”, per i pattern di input relativi a scenari con la fase *ex-vessel* e output logaritmici  $\tilde{N}_j(\mathbf{t})$ . In realtà, per i primi due tempi, ovvero  $\mathbf{t} = 6\text{h}$  e  $\mathbf{t} = 12\text{h}$ , le reti “*WITH*” hanno fornito in ogni caso risultati sufficientemente precisi, cosicché non è stato necessario addestrare le corrispondenti reti “*WITH\_LN*”. L’insieme di reti necessarie a simulare il problema del caso studio in esame è quindi composto da 7 reti “*WITHOUT*”, 7 reti “*WITH*” e 5 reti “*WITH\_LN*”. Ognuna di esse è stata addestrata con circa 1000 pattern di input/output, e validata su un analogo numero di pattern mai visti durante l’addestramento. Durante la procedura, per un dato pattern di input, i valori predetti dalle due reti “*WITH*” e “*WITH\_LN*”,  $o_{lin} = N_j(\mathbf{t})$  e  $o_{log} = \exp \tilde{N}_j(\mathbf{t})$  rispettivamente, vengono messi a confronto con un valore di soglia predefinito: se  $o_{lin}$  è maggiore del valore di soglia, questi è accettato come previsione, altrimenti si accetta  $o_{log}$ . In questo lavoro, i valori di soglia per le diverse situazioni sono stati definiti sulla base delle prestazioni delle diverse reti rispetto ai dati di addestramento.

Al termine dell’addestramento, i pesi delle connessioni di ogni rete rimangono fissati, e le reti possono venire utilizzate per ottenere i valori di concentrazione degli elementi considerati in corrispondenza di nuovi pattern di input. A tal fine, è stato sviluppato un “*Neural Network Manager*” per gestire il flusso di informazioni (Figura 6): partendo dagli input di una data sequenza incidentale, questi sceglie automaticamente la rete, fra le 19 addestrate, che fornisce la previsione di concentrazione più accurata.

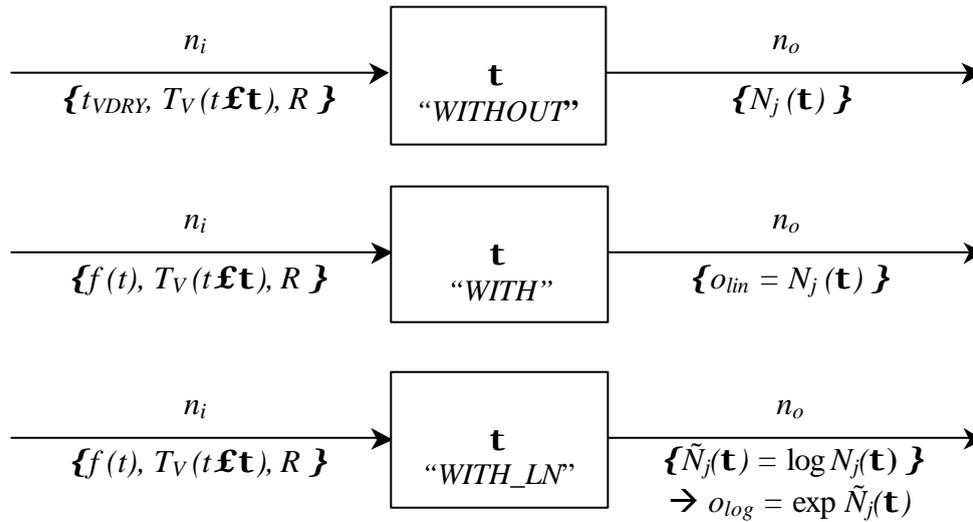


Figura 5: Schema delle RNA addestrate.

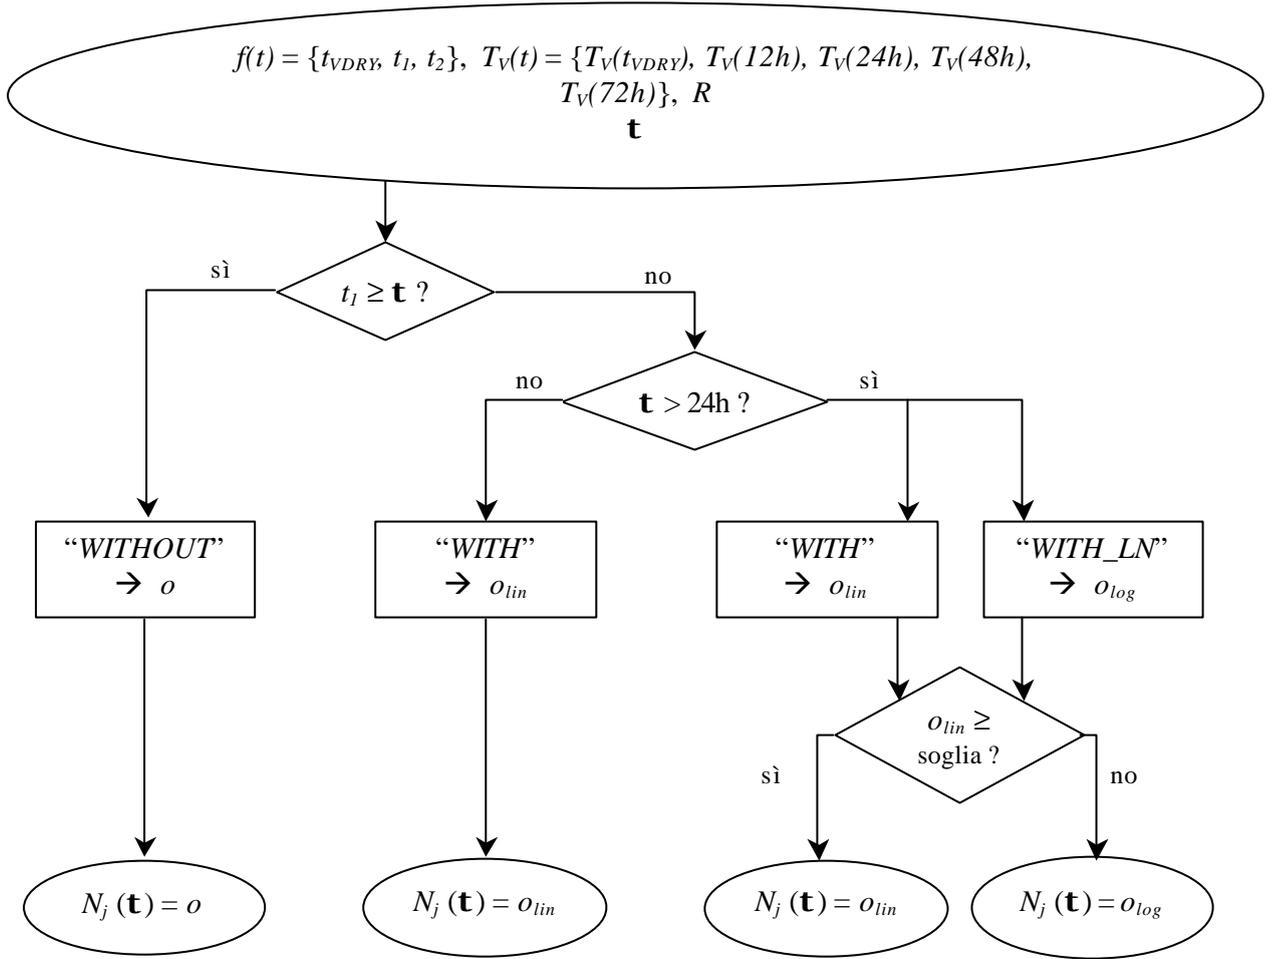


Figura 6: Schema del *Neural Network Manager*.

## 5. RISULTATI

La figura di merito considerata per misurare la precisione dei valori di output  $u$  calcolati con le reti neurali, rispetto ai “veri” valori  $t$ , calcolati con il codice ECART, è l’errore relativo medio  $E$ :

$$E = \frac{1}{n_p n_o} \sum_{p=1}^{n_p} \sum_{l=1}^{n_o} \frac{|u_{pl} - t_{pl}|}{t_{pl}} \quad (2)$$

ove  $t_{pl}$  e  $u_{pl}$  sono rispettivamente i valori veri e calcolati tramite le reti neurali in corrispondenza dell’  $l$ -esimo nodo di output (essendo  $n_o$  il numero di nodi di output) quando il  $p$ -esimo pattern viene presentato alla rete (essendo  $n_p$  il numero di pattern totali presentati).

In Tabella 1 si riportano gli errori compiuti dalle varie reti su circa un migliaio di pattern di test. Degli output forniti dalle reti “WITH” e “WITH\_LN”, solo uno viene accettato dal *Manager* (  in Tabella 1), col procedimento di Figura 6 basato sulla grandezza del valore di output delle reti lineari,  $o_{lin}$ . E’ evidente in Tabella l’efficienza del *Manager* nella selezione degli output forniti dalle reti “WITH\_LN” invece di quelli forniti dalle reti “WITH”, per i valori al di sotto del valore di soglia. Infatti, nel caso delle reti “WITH”, che considerano situazioni in cui si verifica la fase ex-vessel,  $t \geq 24h$  e per valori di output delle reti lineari  $o_{lin}$  inferiori alla soglia (colonne 3 e 4 di Tabella 1), il *Neural Network Manager* scarta gli output delle reti “WITH” lineari (colonna 3) e considera solo quelli delle reti con uscite logaritmiche “WITH\_LN” che sono più accurati (colonna 4); viceversa, nel caso di output delle reti lineari  $o_{lin}$  superiori alla soglia (colonne 5 e 6 di Tabella 1) il *Manager* scarta le uscite delle reti logaritmiche “WITH\_LN” (colonna 6) e accetta quelle più accurate fornite dalle reti lineari “WITH” (colonna 5).

Nel caso delle reti “WITHOUT”, cioè per gli scenari in cui esiste solo la fase in-vessel, i processi fisici dei quali le reti devono costruirsi una rappresentazione interna sono piuttosto semplici e sono comuni a tutti gli elementi, avendo come unica differenza un fattore di scala, come visto nell’analisi preliminare dei dati di cui al paragrafo 4.1. I risultati delle predizioni così ottenute sono per questo molto precisi (colonna 2 in Tabella 1). Per le reti che si occupano di entrambe le fasi di rilascio (reti “WITH”), si può osservare che l’errore relativo medio  $E$  è sempre maggiore di quello delle reti “WITHOUT”, e tende a crescere con il tempo di predizione  $t$ . Ciò è dovuto al fatto che più la fase ex-vessel è importante, più i dati sono dispersi e l’addestramento delle reti diventa difficoltoso. Per quel che riguarda le reti “WITH\_LN”, si nota che esse presentano gli errori relativi maggiori, poiché trattano con valori molto piccoli di output.

| $t$ | Errore $E$ |         | Errore $E$ sotto la soglia |        | Errore $E$ sopra la soglia |  |
|-----|------------|---------|----------------------------|--------|----------------------------|--|
|     | “WITHOUT”  | “WITH”  | “WITH_LN”                  | “WITH” | “WITH_LN”                  |  |
| 6h  | 0.60 %     | 1.54 %  | -                          | 1.54 % | -                          |  |
| 12h | 0.44 %     | 0.89 %  | -                          | 0.89 % | -                          |  |
| 24h | 0.63 %     | 6.69 %  | 4.19 %                     | 1.56 % | 3.66 %                     |  |
| 36h | 1.12 %     | 28.39 % | 13.25 %                    | 1.70 % | 3.6 %                      |  |
| 48h | 1.02 %     | 179.9 % | 24.05 %                    | 2.10 % | 5.18 %                     |  |
| 60h | 1.88 %     | 2288 %  | 12.36 %                    | 2.48 % | 4.70 %                     |  |
| 72h | 1.82 %     | 11848 % | 14.23 %                    | 2.95 % | 7.17 %                     |  |

Tabella 1. Reti “WITHOUT”: errore relativo medio  $E$  su test. Reti “WITH” e “WITH\_LN”: errore relativo medio  $E$  su test, calcolato su output al di sotto ed al di sopra del valore di soglia. Le caselle evidenziate corrispondono all’errore calcolato su valori di output accettati dal Manager, le altre corrispondono all’errore calcolato su valori non accettati.

In Figura 7 si confronta un esempio del comportamento temporale della concentrazione di CsI calcolato con ECART con il corrispondente simulato dal sistema di RNA: si osserva l’elevato livello di precisione raggiunto. L’errore relativo globale sui pattern di test presentati riferito al *Neural Network Manager* nel suo insieme, composto degli errori relativi commessi dalle singole reti nelle diverse situazioni, è infatti pari al 2,62%.

Infine, dal punto di vista del tempo di calcolo richiesto, il simulatore di RNA è più veloce del simulatore meccanicistico ECART di circa due ordini di grandezza: su un Pentium 166MHz, il tempo di processo richiesto dal *Manager* per una singola simulazione è inferiore ai 3 secondi, mentre quello richiesto da ECART è di circa 400 secondi (Figura 8). Questa rapidità di calcolo, associata alla accuratezza delle approssimazioni fornite, dimostra la potenzialità dell’uso delle reti neurali artificiali per una simulazione accurata, robusta ed affidabile di dinamiche incidentali complesse.

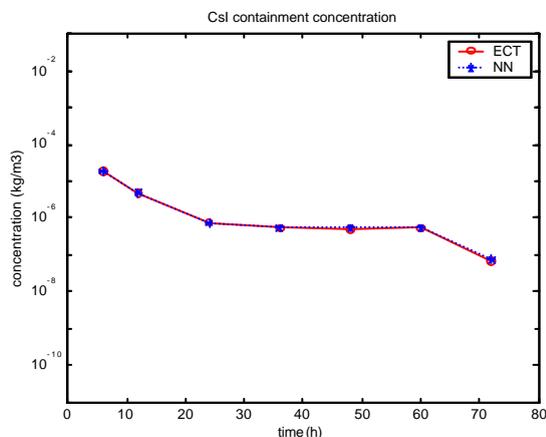


Figura 7: Confronto tra i risultati del “Neural Network Manager” e di ECART: evoluzione della concentrazione di CsI nel contenitore.

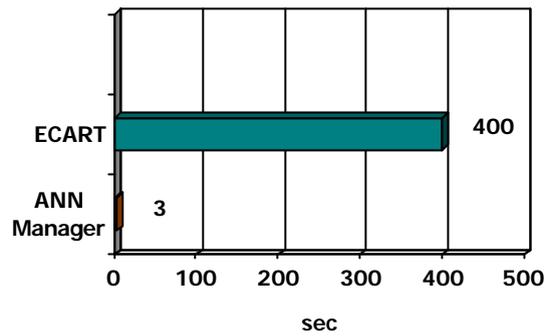


Figura 8. Confronto dei tempi di calcolo.

## 6. CONCLUSIONI

In questo lavoro viene studiata l'opportunità di utilizzare le reti neurali artificiali (RNA) per descrivere l'evoluzione dinamica di incidenti di impianto. In particolare, il caso studio considerato ha riguardato la possibilità di utilizzare le Reti Neurali Artificiali multistrato, supervisionate per fornire la mappatura fisica che descrive la dinamica del termine di sorgente nel contenitore di un impianto nucleare. A tale scopo è stato messo a punto un set di 19 reti neurali, addestrate a riprodurre le relazioni di input/output per varie sequenze incidentali di interesse. Dopo il completamento dell'addestramento, le reti sono risultate in grado di fornire i risultati desiderati per le nuove condizioni incidentali, con un livello ragionevole di approssimazione.

I risultati ottenuti sono stati soddisfacenti non solo dal punto di vista della precisione raggiunta, ma anche da quello dei tempi di simulazione: il simulatore di RNA è più veloce del simulatore meccanicistico ECART di circa due ordini di grandezza. Ciò prova la potenzialità dell'uso delle reti neurali artificiali per una simulazione dinamica accurata ed affidabile.

I risultati soddisfacenti raggiunti sono derivati da uno sforzo modellistico mirato a determinare un insieme di reti appropriato alla rappresentazione dell'evoluzione degli scenari incidentali di interesse. Tale modello in nessun modo rappresenta l'ottimo e pertanto si ritiene che possano essere sviluppati altri modelli neurali altrettanto validi, se non migliori.

Infine, in generale, la metodologia neurale proposta con applicazione nell'ambito della sicurezza nucleare presenta notevoli potenzialità di esportazione in ambiti affini.

## 7. ELENCO DEI SIMBOLI

|                  |   |
|------------------|---|
| $D$              | funzione Energia                                    |
| $E$              | errore relativo medio                               |
| $f(t)$           | rateo di rilascio [kg/s]                            |
| $j$              | indice dell'elemento                                |
| $l$              | indice del nodo di output                           |
| $N_j(t)$         | concentrazione nel contenitore [kg/m <sup>3</sup> ] |
| $\tilde{N}_j(t)$ | logaritmo della concentrazione nel contenitore      |
| $n_h$            | numero di nodi dello strato nascosto                |
| $n_i$            | numero di nodi di input                             |
| $n_o$            | numero di nodi di output                            |
| $n_p$            | numero di pattern                                   |
| $o_{lin}$        | output della rete "WITH"                            |
| $o_{log}$        | output della rete "WITH_LN"                         |
| $p$              | indice del pattern                                  |
| $R$              | fattore di rilascio per la fase in-vessel           |
| $t$              | tempo [s]   |
| $t_v(t)$         | temperatura dell'atmosfera nel contenitore [K]      |
| $t_{VDRY}$       | tempo di fine della fase in-vessel                  |
| $t_I$            | tempo di inizio della fase ex-vessel                |

|          |   |
|----------|---|
| $t_2$    | <i>tempo di fine della fase ex-vessel</i> |
| $t_{pl}$ | <i>valore calcolato tramite ECART</i>     |
| $u_{pl}$ | <i>valore calcolato tramite le RNA</i>    |
| $t$      | <i>istante temporale considerato</i>      |

## 8. BIBLIOGRAFIA

- [1] Devooght J. and Smidts C. (1992). Probabilistic Reactor Dynamics I. The Theory of Continuous Event Trees. *Nucl. Sci. and Eng.* **111:3**, 229-240.
- [2] Cojazzi G., Izquierdo J.M., Melendez E., Sanchez-Perea M. (1992). The Reliability and Safety Assessment of Protection Systems by the Use of Dynamic Event Trees (DET). The DYLAM-TRETA package. *Proc. XVIII Annual Meeting Spanish Nuclear Society*. October 28-30, 1992.
- [3] Aldemir T., Siu N., Mosleh A., Cacciabue P.C., Goktepe B.G. (1994). Eds.: Reliability and Safety Assessment of Dynamic Process System. *NATO-ASI Series F 120*, Springer-Verlag, Berlin.
- [4] Siu N. (1994). Risk assessment for dynamic systems: an overview. *Reliability Engineering and System Safety* 43.
- [5] Izquierdo J.M., Hortal J., Sanchez-Perea M., Melendez E. (1994). Automatic Generation of dynamic Event Trees: A Tool for Integrated Safety Assessment (ISA). *Reliability and Safety Assessment of Dynamic Process System NATO-ASI Series F 120*, Springer-Verlag, Berlin.
- [6] Labeau P.E. (1996). Probabilistic Dynamics: Estimation of Generalized Unreliability Through Efficient Monte Carlo Simulation. *Annals of Nuclear Energy* **23:17**, 1355-1369.
- [7] Marseguerra M. and Zio E. (1996). Monte Carlo approach to PSA for Dynamic Process Systems. *Reliability Engineering and System Safety*, **52**, 227-241.
- [8] Rumelhart D.E. and McClelland J.L. (1986). *Parallel Distributed Processing*, **1**, MIT Press, Cambridge, MA.
- [9] Parozzi F. et al. (1997). *ECART User's Manual*, ENEL-EDF.
- [10] Borioli E., Mariotti G., Parozzi F., Sandrelli G., Valisi M. (December 1997). PHEBUS-FP Scoping Calculations Phase A: Italian Source Term Studies for PWR Plants. *Rapporto Contratto ENEL-CEE n. 3210-87-07 EL ISP I*.
- [11] Parozzi F. (1999). Evaluation of Radioactive Releases under Accident Conditions in Westinghouse EP1000 Design. *ENEL Ricerca Area Generazione Unità Diagnostica di Processo*.
- [12] Muller B. e Reinhardt J., *Neural Networks – An introduction*, Springer- Verlag, New York, 1991.
- [13] Jain L.C. e Martin N.M. eds., *Fusion of Neural Networks, Fuzzy Sets and Genetic Algorithms*, CRC Press 1999.
- [14] Uhrig R.U. e Tsoukalas L.H., *Soft Computing Technologies in Nuclear Engineering Applications, Progress in Nuclear Energy*, vol. 34, No 1, pp. 13 – 75, 1999.
- [15] Eberhart R.C. e Dobbins R.W., *Neural Network PC Tools: a Practical Guide*, Academic Press 1990.
- [16] White H., *Connectionist Nonparametric Regression: Multilayer Feedforward Networks Can Learn Arbitrary Mappings*, *Neural Networks*, Vol. 3, p 535, 1990.
- [17] Hornik K. e Stinchcombe M. e White H., *Universal Approximation of an unknown Mapping and Its Derivatives Using Multilayer Feedforward Networks*, *Neural Networks*, Vol. 3, p 551, 1990.