



ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ  
ΠΕΡΙΒΑΛΛΟΝΤΟΣ

Διπλωματική εργασία με τίτλο:

***«Προσομοίωση της στάθμης του υδροφορέα  
Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών  
αλγόριθμων εκπαίδευσης»***

Πάντου Θέτις

Εξεταστική επιτροπή:

Καρατζάς Γεώργιος (επιβλέπων)

Νικολαΐδης Νικόλαος

Δόκου Ζωή

Χανιά 2014

## Ευχαριστίες

Ολοκληρώνοντας την παρούσα διπλωματική εργασία, θα ήθελα κατ' αρχάς να ευχαριστήσω τον επιβλέποντα καθηγητή της διπλωματικής μου, κ. Καρατζά Γεώργιο, για την ευκαιρία που μου έδωσε αλλά και την εμπιστοσύνη που μου έδειξε ώστε να ασχοληθώ με το θέμα της παρούσας διπλωματικής.

Ευχαριστώ επίσης θερμά τον καθηγητή Νικόλαο Νικολαΐδη καθώς και την μεταδιδακτορική ερευνήτρια της Σχολής Μηχανικών Περιβάλλοντος, Ζωή Δόκου για το χρόνο που αφιέρωσαν στην ανάγνωση της διπλωματικής μου εργασίας καθώς και τη συμμετοχή στην τριμελή επιτροπή.

Επιπλέον, θα ήθελα να ευχαριστήσω τον Ιωάννη Τριχάκη για τη βοήθεια του στην αρχή της εργασίας.

Ένα ευχαριστώ δεν θα ήταν αρκετό για την Ευδοκία Ταπόγλου, η καθοδήγηση και η βοήθεια της οποίας ήταν καθοριστική για να έρθει εις πέρας η παρούσα εργασία.

Εν κατακλείδι, θα ήθελα να ευχαριστήσω του γονείς μου για την υποστήριξη τους όλα αυτά τα χρόνια καθώς και του φίλους μου που με άντεξαν και μοιράστηκαν μαζί μου τόσες υπέροχες στιγμές.

## Πίνακας περιεχομένων

Ευχαριστίες.....	i
Περίληψη.....	vi
Abstract .....	vii
Κεφάλαιο 1 : Εισαγωγή .....	1
1.1 Υπόγεια ύδατα.....	1
1.2 Υπερεκμετάλλευση υπογείων υδάτων .....	2
1.3 Ορισμός του προβλήματος .....	3
1.4 Παλιότερες εργασίες.....	3
Κεφάλαιο 2 : Θεωρητικό υπόβαθρο .....	4
2.1 Βιολογικά νευρωνικά δίκτυα .....	4
2.2 Ιστορική αναδρομή ΤΝΔ.....	5
2.3 Τεχνητά νευρωνικά δίκτυα.....	6
2.4 Συνάρτηση ενεργοποίησης .....	8
2.5 Κατηγορίες Νευρωνικών Δικτύων βάσει τρόπου διάδοσης.....	11
2.6 Κατηγορίες Μάθησης.....	12
2.7 Κανόνας εκμάθησης Perceptron.....	12
2.8 Η συνάρτηση XOR.....	15
2.9 Κανόνας Δέλτα .....	17
2.11 Δίκτυα πολλαπλών επιπέδων .....	19
2.12 Ο Γενικευμένος Κανόνας Δέλτα .....	20
2.13 Αλγόριθμος οπισθοδιάδοσης σφάλματος .....	22
Κεφάλαιο 3 : Περιοχή μελέτης.....	23
3.1 Η κοιλάδα της Μεσσαράς .....	23
3.2 Κλιματολογικά και υδρολογικά στοιχεία .....	24
3.3 Γεωλογικό υπόβαθρο .....	24
Κεφάλαιο 4 : Μεθοδολογία .....	25
4.1 Υδατικό ισοζύγιο .....	25
4.2 Επεξεργασία χρονοσειρών .....	27
4.3 Δομή και εκπαίδευση νευρωνικού δικτύου.....	28
4.4 Χρονική υστέρηση .....	29
4.5 Matlab και τεχνητά νευρωνικά δίκτυα .....	32

4.6 Εκπαίδευση δικτύου .....	38
Κεφάλαιο 5 : Αποτελέσματα .....	39
5.1 Βελτίωση σφαλμάτων .....	39
5.2 Μέθοδος Monte Carlo.....	44
5.3 Προσομοίωση διαφοράς στάθμης.....	50
5.4 Πρόβλεψη υδραυλικού ύψους .....	54
5.5 Μεσοπρόθεσμη πρόβλεψη υδραυλικού ύψους.....	57
Κεφάλαιο 6 : Συμπεράσματα-Προτάσεις.....	61
Κεφάλαιο 7 : Βιβλιογραφία.....	62
ΠΑΡΑΡΤΗΜΑ I: Ορισμοί .....	64
ΠΑΡΑΡΤΗΜΑ II: Συνολικοί πίνακες .....	66
ΠΑΡΑΡΤΗΜΑ III: Συγκριτικά διαγράμματα .....	68
ΠΑΡΑΡΤΗΜΑ IV: Εργαλείο προσαρμογής νευρωνικών δικτύων-nftool .....	69

## Κατάλογος εικόνων

Εικόνα 2-1 Σχηματική απεικόνιση φυσικού νευρώνα (Αργυράκης,2011, p.47).....	4
Εικόνα 2-2 Αναπαράσταση κόμβου νευρωνικού δικτύου .....	7
Εικόνα 2-3 Συνάρτηση κατωφλίου (Haykin,1994 p.11) .....	9
Εικόνα 2-4 Τμηματικά γραμμική συνάρτηση (Haykin,1994, p.11) .....	10
Εικόνα 2-5 Σιγμοειδής συνάρτηση (Haykin,1994, p.11) .....	11
Εικόνα 2-6 Γεωμετρική αναπαράσταση της διαχωριστικής συνάρτησης και των βαρών (Kröse&der Smagt, 1996. p.24).....	14
Εικόνα 2-7 Γεωμετρική αναπαράσταση συνάρτησης XOR (Ταπόγλου, 2011, p.24).....	16
Εικόνα 2-8 Επίλυση προβλήματος XOR βαρών (Kröse & der Smagt,1996 p.30).....	17
Εικόνα 2-9 Αναπαράσταση πολυεπίπεδου νευρωνικού δικτύου.....	19
Εικόνα 3-1 Περιοχή μελέτης-Πεδιάδα Μεσσαράς, Κρήτη.....	24

## Κατάλογος διαγραμμάτων

Διάγραμμα 5-1 Μέση τιμή μέσου τετραγωνικού σφάλματος για 1 κρυφό επίπεδο (trainlm)	39
Διάγραμμα 5-2 Μέσο τετραγωνικό σφάλμα εκπαίδευσης για 1 κρυφό επίπεδο (trainlm)...	40
Διάγραμμα 5-3 Μέσο τετραγωνικό σφάλμα ελέγχου για 1 κρυφό επίπεδο (trainlm).....	40
Διάγραμμα 5-4 Μέση τιμή μέσου τετραγωνικού σφάλματος για 2 κρυφά επίπεδα (trainlm)	41
Διάγραμμα 5-5 Μέσο τετραγωνικό σφάλμα εκπαίδευσης για 2 κρυφά επίπεδα(trainlm) ...	41
Διάγραμμα 5-6 Μέσο τετραγωνικό σφάλμα ελέγχου για 2 κρυφά επίπεδα (trainlm) .....	42
Διάγραμμα 5-7 Κατανομή σφαλμάτων για 1000 επαναλήψεις .....	45
Διάγραμμα 5-8 Ιστόγραμμα σφαλμάτων εκπαίδευσης για 1000 επαναλήψεις (trainlm) .....	46
Διάγραμμα 5-9 Ιστόγραμμα σφαλμάτων επαλήθευσης για 1000 επαναλήψεις (trainlm)....	47
Διάγραμμα 5-10 Ιστόγραμμα σφαλμάτων ελέγχου για 1000 επαναλήψεις (trainlm) .....	47
Διάγραμμα 5-11 Ιστόγραμμα σφαλμάτων εκπαίδευσης για 1000 επαναλήψεις (trainbr)....	48
Διάγραμμα 5-12 Ιστόγραμμα σφαλμάτων επαλήθευσης για 1000 επαναλήψεις (trainbr)...	49
Διάγραμμα 5-13 Ιστόγραμμα σφαλμάτων ελέγχου για 1000 επαναλήψεις (trainbr).....	49
Διάγραμμα 5-14 Προσομοιωμένη διαφορά στάθμης συναρτήσει πραγματικής διαφοράς στάθμης (trainlm).....	51
Διάγραμμα 5-15 Προσομοιωμένη και πραγματική διαφορά στάθμης ως προς το χρόνο (trainlm).....	51
Διάγραμμα 5-16 Προσομοιωμένη διαφορά στάθμης συναρτήσει πραγματικής διαφοράς στάθμης (trainbr) .....	53
Διάγραμμα 5-17 Προσομοιωμένη και πραγματική διαφορά στάθμης ως προς το χρόνο (trainbr) .....	53
Διάγραμμα 5-18 Προσομοιωμένο υδραυλικό ύψος συναρτήσει πραγματικού υδραυλικού ύψους (trainlm) .....	54
Διάγραμμα 5-19 Προσομοιωμένο υδραυλικό ύψος και πραγματικό υδραυλικό ύψος ως προς το χρόνο (trainlm).....	55
Διάγραμμα 5-20 Προσομοιωμένο υδραυλικό ύψος συναρτήσει πραγματικού υδραυλικού ύψους (trainbr).....	56
Διάγραμμα 5-21 Προσομοιωμένο υδραυλικό ύψος και πραγματικό υδραυλικό ύψος ως προς το χρόνο (trainbr) .....	56
Διάγραμμα 5-22 Προσομοιωμένο υδραυλικό ύψος συναρτήσει πραγματικού υδραυλικού ύψους - μεσοπρόθεσμη πρόβλεψη (trainlm) .....	58
Διάγραμμα 5-23 Προσομοιωμένο υδραυλικό ύψος και πραγματικό υδραυλικό ύψος ως προς το χρόνο-μεσοπρόθεσμη πρόβλεψη (trainlm).....	58
Διάγραμμα 5-24 Προσομοιωμένο υδραυλικό ύψος συναρτήσει πραγματικού υδραυλικού ύψους - μεσοπρόθεσμη πρόβλεψη (trainbr).....	59
Διάγραμμα 5-25 Προσομοιωμένο υδραυλικό ύψος και πραγματικό υδραυλικό ύψος ως προς το χρόνο-μεσοπρόθεσμη πρόβλεψη (trainbr) .....	60

## Κατάλογος πινάκων

Πίνακας 2-1 Συνάρτηση XOR.....	15
Πίνακας 4-1 Στατιστική ανάλυση δεδομένων χρονοσειρών βροχόπτωσης .....	27
Πίνακας 4-2 Στατιστική ανάλυση χρονοσειρών μετεωρολογικών δεδομένων .....	28
Πίνακας 4-3 Στατιστική ανάλυση χρονοσειρών μετεωρολογικών δεδομένων .....	28
Πίνακας 4-4 Τιμές συντελεστή χρονικής υστέρησης βροχοπτώσεων-διαφοράς υδραυλικού ύψους .....	31
Πίνακας 4-5 Τιμές συντελεστή χρονικής υστέρησης χείμαρρων-διαφοράς υδραυλικού ύψους .....	31
Πίνακας 4-6 Αλγόριθμοι εκπαίδευσης νευρωνικού δικτύου .....	34
Πίνακας 5-1 Βέλτιστο σφάλμα (trainlm) .....	42
Πίνακας 5-2 Ελάχιστα σφάλματα διαφορετικών αλγορίθμων εκπαίδευσης .....	43
Πίνακας 5-3 Βέλτιστο σφάλμα (trainbr).....	43
Πίνακας 5-4 Στατιστική ανάλυση σφαλμάτων για 1000 επαναλήψεις (trainlm) .....	44
Πίνακας 5-5 Στατιστική ανάλυση σφαλμάτων για 1000 επαναλήψεις (trainbr).....	44
Πίνακας 5-6 Όρια εμπιστοσύνης για διάστημα εμπιστοσύνης 95% .....	50

## Περίληψη

Η παρούσα διπλωματική αποσκοπεί στην προσομοίωση της διαφοράς στάθμης σε ένα πηγάδι παρατήρησης στην περιοχή της Μεσσαράς, Κρήτης με τη χρήση τεχνητών νευρωνικών δικτύων.

Τα τεχνικά νευρωνικά δίκτυα αποτελούν μια σχετικά νέα μέθοδο τεχνητής νοημοσύνης η οποία βασίζεται στον τρόπο λειτουργίας του ανθρώπινου εγκεφάλου. Για τη χρήση τους απαιτείται πρώτα η διαδικασία της εκπαίδευσης. Στόχος της εκπαίδευσης του δικτύου ήταν η όσο το δυνατόν καλύτερη προσομοίωση των δεδομένων πεδίου και ο υπολογισμός της απόκλισης των πραγματικών τιμών από τις προσομοιωμένες από το μοντέλο. Για την εκπαίδευση του δικτύου χρησιμοποιήθηκαν ημερήσιες μετρήσεις υδρολογικών δεδομένων από την περιοχή μελέτης ενώ βρέθηκε και η βέλτιστη χρονική υστέρηση μεταξύ βροχοπτώσεων και χειμάρρων και του υπόγειου υδροφορέα. Η χρονική υστέρηση βρέθηκε μέσω των συντελεστών συσχέτισης μεταξύ της διαφοράς στάθμης και της βροχόπτωσης ή της στάθμης των χειμάρρων. Στόχος της εκπαίδευσης του δικτύου ήταν η όσο το δυνατόν καλύτερη προσομοίωση των δεδομένων πεδίου και ο υπολογισμός της απόκλισης πραγματικών τιμών και τιμών που προέκυψαν από το μοντέλο.

Το δίκτυο εκπαιδεύτηκε για τέσσερις διαφορετικούς αλγόριθμους εκπαίδευσης οπισθοδιάδοσης σφάλματος με εμπρόσθια τροφοδότηση στοχεύοντας στην εύρεση εκείνου για τον οποίο σημειώνονται τα μικρότερα σφάλματα. Εκ των τεσσάρων επιλέχθηκαν οι δύο μεταξύ των όποιων έγινε σύγκριση και πραγματοποιήθηκαν 1000 επαναλήψεις έτσι ώστε να αξιολογηθεί η κατανομή των σφαλμάτων.

Κατόπιν, για το εκπαιδευόμενο δίκτυο σύμφωνα με τους δύο καλύτερους, ως προς τα ελάχιστα σφάλματα, αλγόριθμους αξιολογήθηκε κατά πόσο συγκλίνει η πραγματική με την προσομοιωμένη διαφορά στάθμης ενώ βάσει των διαφορών στάθμης υπολογίστηκαν τα προσομοιωμένα υδραυλικά ύψη και έγινε και σύγκριση με τα παρατηρούμενα από το πεδίο. Έπειτα, σύγκριση έγινε και με τη μεσοπρόθεσμη πρόβλεψη του υδραυλικού ύψους, η οποία υπολογίστηκε κάνοντας χρήση μόνο του αρχικού υδραυλικού ύψους και των διαφορών στάθμης που προέκυψαν από το μοντέλο.

## **Abstract**

The present diploma thesis aims at the simulation of the hydraulic head change at an observation well in Messara valley in Crete using artificial neural networks.

Artificial Neural Networks (ANNs) provide a relative new methodology of artificial intelligence based on the function of human brain. Their use requires first a training process. The goal of the training process is to achieve the best possible simulation of the field data and the calculation of the deviation of actual values from the ones simulated by the model. In order to train the network, time series of hydrological measurements of the study area were used as inputs. Additionally, the optimal time lag for parameters such as precipitation and steam water level, where their effect is not instant, were calculated using the correlation coefficient between hydraulic head change and the parameter examined. The networks' training goal is to achieve the best possible simulation of the hydraulic head change.

The network was trained using four different backpropagation feedforward algorithms, aiming to find the combination which accounts for minimum errors. Two algorithms were selected out of the four and their performances were compared. A total of 1000 iterations were made for each one in order to assess the error distribution.

Moreover, for the trained network according to the chosen algorithms was evaluated in order to examine the agreement between the observed and simulated hydraulic head changes. Furthermore, simulated hydraulic head change was converted into hydraulic head by adding the simulated hydraulic head change to field hydraulic head of the previous day and then compared to the field data in order to examine the efficiency of the simulation. The same procedure was followed also for the mid-term prediction of hydraulic head, which was computed using only the observed hydraulic head of the first day of the simulation and then adding the simulated hydraulic head change values for the current day.



## Κεφάλαιο 1 : Εισαγωγή

### 1.1 Υπόγεια ύδατα

Η κυκλοφορία του νερού πάνω και κάτω από την επιφάνεια της Γης πραγματοποιείται μέσω του υδρολογικού κύκλου. Ο υδρολογικός κύκλος είναι αέναος και κατά τη διάρκεια του το νερό αλλάζει συνεχώς τις μορφές του (υγρή, στερεή, αέρια).

Το νερό σε παγκόσμιο επίπεδο κατανέμεται κατά περίπου 3% σε γλυκό και 97% σε αλμυρό. Το υπόγειο νερό αποτελεί το 30,1% του γλυκού νερού και το 1,7% της συνολικής ποσότητας του νερού.

Το υπόγειο νερό δημιουργείται όταν νερό που πέφτει ως βροχή και χιόνι αλλά και τμήμα του επιφανειακού νερού διηθείται στο έδαφος. Ένα τμήμα του νερού που διηθείται και μένει κοντά στην επιφάνεια ενδέχεται να καταλήξει σε κάποιο υδατόρευμα, ενώ τμήμα του νερού που εισρέει βαθύτερα μπορεί να τροφοδοτήσει τους υπόγειους υδροφορείς (USGS, 2014).

Κατά τη διήθηση του νερού στο έδαφος σχηματίζονται δύο ζώνες, η κορεσμένη και η ακόρεστη. Η ακόρεστη ζώνη έχοντας ως υψηλότερο σημείο της την επιφάνεια του εδάφους χαρακτηρίζεται από την ύπαρξη τόσο ύδατος όσο και αέρα στους πόρους του εδάφους. Κάτω από την ακόρεστη βρίσκεται η κορεσμένη ζώνη η ανώτερη επιφάνεια της οποίας είναι ο υδροφόρος ορίζοντας και όπου οι πόροι του εδάφους είναι πλήρως κορεσμένοι σε νερό. Στη ζώνη αυτή ρέει το υπόγειο νερό το οποίο αποθηκεύεται σε ειδικούς γεωλογικούς σχηματισμούς, τους υδροφορείς (Καρατζάς, 2003; Longwood university, The importance of groundwater, n.d.).

Η ροή του υπογείου νερού μπορεί να γίνει είτε κάθετα είτε οριζόντια διαμέσου υπεδάφινων σχηματισμών που περιέχουν σημαντικές ποσότητες διαπερατών υλικών κορεσμένων με ύδωρ, των υδροφορέων. (Καρατζάς, 2003) Η ταχύτητα της ροής εξαρτάται από τη βαρύτητα και τους γεωλογικούς σχηματισμούς. Το υπόγειο νερό μπορεί να παραμείνει αποθηκευμένο στους υδροφορείς από ένα μικρό χρονικό διάστημα μερικώς ημερών έως και πολλούς αιώνες (Longwood university, The importance of groundwater, n.d.).

Οι χρήσεις του υπόγειου νερού μπορούν να χωριστούν σε δύο κατηγορίες. Η πρώτη αφορά τη φυσική σημασία του υπόγειου νερού ενώ η δεύτερη ιδιότητα του ως πηγή ύδρευσης και άρδευσης για την εξυπηρέτηση των ανθρώπινων αναγκών.

Στη φύση το υπόγειο νερό αποτελεί βασικό παράγοντα σε πολλές γεωλογικές διαδικασίες. Τα συστατικά του συμβάλουν στη διατήρηση του εμπλουτισμού των πηγών και στη βασική ροή ποταμών, διάφορων τύπων λιμνών και υγροτόπων. Επιπλέον, συμβάλει στη μεταφορά διαλυμένης μάζας διαμέσου του εδάφους, στη βιωσιμότητα οικοτόπων και χρησιμεύει ως γεωτεχνικός παράγοντας σε σχέση με την εδαφική συμπεριφορά και τη συμπεριφορά των πετρωμάτων.

Όσον αφορά την ιδιότητα του ως πηγή ύδρευσης για την εξυπηρέτηση των ανθρώπινων αναγκών, το υπόγειο νερό αποτελεί κύρια πηγή για αστική και αγροτική χρήση και αποτελεί ένα σημαντικό κοινωνικά πόρο για την ανάπτυξη της άρδευσης και των καλλιεργειών καθώς και μια αξιόπιστη πηγή βιομηχανικής χρήσης.

Σε κατοικημένες περιοχές όπου οι βροχοπτώσεις είναι σπάνιες, το υπόγειο νερό μπορεί να αποτελέσει την κύρια πηγή πόσιμου νερού, καθώς είναι εύκολα προσβάσιμο και η άντληση του αποτελεί μια σχετικά φτηνή διαδικασία (Custodio, 2002).

## 1.2 Υπερεκμετάλλευση υπογείων υδάτων

Η υπερεκμετάλλευση των υπόγειων υδάτων ως απόρροια της ολοένα αυξανόμενης ανάγκης σε νερό για αγροτικούς και βιομηχανικούς σκοπούς αλλά και για δημόσια χρήση έχει αναδειχθεί σε πανευρωπαϊκό πρόβλημα. Συγκεκριμένα, στις ημι-άνυδρες περιοχές της Μεσογείου που χαρακτηρίζονται από την απουσία πολλών βροχοπτώσεων και χρόνιων ποταμών εμφανίζεται επιτακτική η ανάγκη για υπόγειους υδάτινους πόρους, οι οποίοι υφίστανται υπερεκμετάλλευση για την κάλυψη αρδευτικών αναγκών.

Η διεύρυνση της εκμετάλλευσης των υπογείων υδάτων έχει ήδη προκαλέσει σοβαρές οικονομικές, περιβαλλοντικές και κοινωνικές συνέπειες, γεγονός που έχει οδηγήσει με τη σειρά του την ανάπτυξη οικονομικών, κοινωνικών και πολιτικών πιέσεων για την επίλυση του ζητήματος διάθεσης του υπόγειου νερού.

Πληθώρα ευρωπαϊκών ερευνητικών προγραμμάτων έχουν ασχοληθεί με τη μελέτη της αλληλεπίδρασης των διάφορων φυσικών και δημοσιονομικών διαδικασιών σε αντιπροσωπευτικές λεκάνες απορροής για την ανάπτυξη μεθόδων και δεικτών για την αναγνώριση της υπερεκμετάλλευσης και τη δημιουργία των απαραίτητων μοντέλων για την ανάπτυξη και την αξιολόγηση εναλλακτικών σχεδίων διαχείρισης των υδάτινων πόρων. Μοντέλα για τη μελέτη υπόγειων νερών έχουν βαθμονομηθεί και εφαρμοστεί σε πλήθος λεκανών απορροής για τη μελέτη των επιλεχθέντων

σεναρίων διαχείρισης. Μέσω των αποτελεσμάτων από την εφαρμογή αυτών των μοντέλων έγιναν εμφανείς οι αρνητικές συνέπειες της εντατική χρήσης των υδάτινων πόρων (Balabanis, 1999).

### 1.3 Ορισμός του προβλήματος

Η εγκατάσταση ενός εκτενούς δικτύου αντλιοστασίων στην περιοχή της Μεσσαράς από το 1984, το οποίο έχει μεταμορφώσει τις ξηρές καλλιέργειες ελαιόδεντρων σε στάγδην-αρδευόμενες καλλιέργειες, συνέβαλε στην αύξηση της παραγωγής ενώ παράλληλα οδήγησε στην πτώση της στάθμης του υδροφορέα κατά 20 μέτρα (Croke et al., 2000). Ως εκ τούτου, ο εμπλουτισμός του υδροφορέα πραγματοποιείται τους χειμερινούς μήνες ενόσω η άντληση λαμβάνει χώρα για την πραγματοποίηση στάγδην-άρδευσης των ελαιοδέντρων τους ξηρούς θερινούς μήνες (Vardavas et al., 1997). Τα επίπεδα του υπόγειο νερού είναι μέγιστα κατά το Μάρτιο ή τον Απρίλιο, με μεγάλες υφέσεις, κατά την διάρκεια του υδρολογικού έτους. Στις αρχές της δεκαετίας του 70' τα υδροφόρα στρώματα ήταν μεγάλης παραγωγικότητας σημειώνοντας ρυθμούς άντλησης μέχρι και 300 m<sup>3</sup>/hour. Οι σημερινές τιμές έχουν μειωθεί περίπου στο ένα δέκατο (Croke et al., 2000).


### 1.4 Παλιότερες εργασίες

Τα τεχνητά νευρωνικά δίκτυα αποτελούν ένα χρήσιμο εργαλείο για τον προσδιορισμό της υδραυλικής στάθμης χωρίς την προϋπόθεση της γνώσης του φυσικού συστήματος που καλούνται να μοντελοποιήσουν. Ως εκ τούτου, σε αντίθεση με άλλα αριθμητικά μοντέλα, έχουν το πλεονέκτημα της χρήσης μόνο των υδρολογικών δεδομένων της περιοχής μελέτης ως δεδομένα εισόδου χωρίς την αναγκαιότητα γνώσης του γεωλογικού υποστρώματος. Ιδιαίτερα σε περιοχές που η γεωλογία είναι περίπλοκη είτε άγνωστη, όπως τα καρστικά πετρώματα, μπορούν να αποδειχθούν ιδιαίτερα αποτελεσματικά. Η χρήση τεχνητών νευρωνικών δικτύων βρίσκει αντίκρισμα σε εφαρμογές πολλών τομέων. Όσον αφορά τον τομέα της Υδρολογίας που εξετάζουμε, εκτεταμένες μελέτες έχουν γίνει ως προς τον προσδιορισμό των παραμέτρων του υδροφορέα (Fong Lin et al., 2006 ; Samani et al., 2007) ενώ υπάρχει και μια σειρά εργασιών που αφορά την προσομοίωση του υδραυλικού ύψους του υδροφορέα (Daliakopoulos et al., 2004; Adamowski and Chan, 2011) καθώς και περιορισμένες σε αριθμό εργασίες του προσδιορισμού της διαφοράς του υδραυλικού ύψους σε καρστικούς υδροφορείς (Trichakis et al., 2009; Trichakis et al., 2011).

## Κεφάλαιο 2 : Θεωρητικό υπόβαθρο

### 2.1 Βιολογικά νευρωνικά δίκτυα

Ο ανθρώπινος εγκέφαλος αποτελεί τη μονάδα του ανθρώπινου σώματος που έχει τη δυνατότητα της σκέψης και της αντίληψης καθώς και της ανάπτυξης συναισθημάτων. Δομικά συστατικά του εγκέφαλου αποτελούν οι νευρώνες, ο αριθμός των οποίων υπολογίζεται να είναι περίπου ίσος με  $10^{10}$  ( $10^9$ - $10^{11}$  νευρώνες). Κάθε νευρώνας απαρτίζεται από το κυρίως σώμα, τον άξονα και τους δενδρίτες, ενώ η διασύνδεση με άλλους νευρώνες γίνεται μέσω των συνάψεων. Στο κυρίως σώμα βρίσκεται ο πυρήνας του κυττάρου, όπου υπάρχει όλο το γενετικό υλικό (Αργυράκης, 2011). Οι άξονες είναι γραμμές μεταφοράς του σήματος λείας επιφάνειας και μεγάλου μήκους ενώ οι δενδρίτες αποτελούν τις δεκτικές ζώνες με μορφολογία πολλών διακλαδώσεων (Haykin, 1994). Η σχηματική απεικόνιση ενός φυσικού νευρώνα φαίνεται στην εικόνα 2-1.



Εικόνα 2-1 Σχηματική απεικόνιση φυσικού νευρώνα (Αργυράκης, 2011, p.47)

Ένα πλήθος νευρώνων μαζί με τις διασυνδέσεις τους αποτελούν ένα νευρωνικό δίκτυο. Το σύνολο των νευρωνικών δικτύων στον ανθρώπινο οργανισμό αποτελεί το Κεντρικό Νευρικό σύστημα (Αργυράκης, 2011).


## 2.2 Ιστορική αναδρομή ΤΝΔ

Οι απαρχές των τεχνητών νευρωνικών δικτύων τοποθετούνται το 1943, όπου οι McCulloch και Pitts εισήγαγαν ένα απλοποιημένο μαθηματικό μοντέλο του νευρώνα εμπνευσμένο από τους βιολογικούς νευρώνες, γνωστό και ως 'McCulloch-Pitts neuron' (Golden, 2001). Το μοντέλο αυτό αποτέλεσε βασικό συστατικό κυκλωμάτων πραγματοποίησης υπολογισμών (Kröse & der Smagt, 1996). Το επόμενο σημαντικό βήμα για την ανάπτυξη των νευρωνικών δικτύων έγινε το 1949 με το μοντέλο μάθησης του Hebb. Σύμφωνα με αυτό κάθε φορά που ενεργοποιείται μια σύναψη, αυτή ενισχύεται και έτσι το δίκτυο υφίσταται μια διαδικασία ανάπτυξης στην εκμάθηση του προτύπου που του παρουσιάζεται. Αργότερα, το 1958 ο Rosenblatt έδωσε μια νέα προοπτική στο πρόβλημα αναγνώρισης προτύπων με την εισαγωγή του μοντέλου perceptron (απλός αισθητήρας). Αποτέλεσμα του μοντέλου perceptron ήταν ο κανόνας εκμάθησης, γνωστός ως θεώρημα σύγκλισης απλού αισθητήρα, (perceptron convergence theorem) βάσει του οποίου αν για ένα πρόβλημα ταξινόμησης υπάρχει έστω μια αρχιτεκτονική δικτύου που να δίνει λύση, τότε το θεώρημα σύγκλισης απλού αισθητήρα συνίσταται για την εύρεση λύσης μετά από μια διάθεση ενός επαρκώς μεγάλου αριθμού δειγμάτων εκπαίδευσης (Golden, 2001). Το ενδιαφέρον για τα νευρωνικά δίκτυα μειώθηκε αισθητά από τα τέλη του 1960 μέχρι τις αρχές του 1980, μετά τη μαθηματική απόδειξη, από τους Minsky και Papert, ότι τα τεχνητά νευρωνικά δίκτυα ενός επιπέδου δε μπορούν να λύσουν συγκεκριμένα προβλήματα (Haykin, 1994). Μόνο λίγοι ερευνητές συνέχισαν την έρευνα του πάνω στον τομέα μέχρι το 1986 όπου αναπτύχθηκε ο αλγόριθμος οπισθοδιάδοσης σφάλματος από τον Rumelhart και του συνεργάτες του. Σήμερα τα τεχνητά νευρωνικά δίκτυα θεωρούνται ένα εργαλείο μεγάλης σημαντικότητας με μια πληθώρα εφαρμογών σε πολλούς διαφορετικούς τομείς (ψυχολογία, ιατρική, επιστήμες πληροφορικής, βιολογία κ.α.) (Haykin, 1994).

## 2.3 Τεχνητά νευρωνικά δίκτυα

Τα τεχνητά νευρωνικά δίκτυα (Artificial Neural Networks) αποτελούν ένα μοντέλο προσομοίωσης του τρόπου λειτουργίας του εγκεφάλου κατά την πραγματοποίηση συγκεκριμένων δραστηριοτήτων (Haykin, 1994). Η λειτουργία των ANN είναι μια προσπάθεια συνδυασμού τρόπου σκέψης του ανθρώπινου εγκεφάλου και μαθηματικής ανάλυσης (Αργυράκης, 2001). Όπως και στον εγκέφαλο έτσι και στα ANNs βασικό δομικό στοιχείο είναι ο νευρώνας  $k$ , ο οποίος αποτελεί τη μονάδα επεξεργασίας πληροφοριών (Haykin, 1994). Το νευρωνικό μοντέλο αποτελείται από μια σειρά συνάψεων μεταφοράς σημάτων  $x_j$  που χαρακτηρίζονται μέσω των συναπτικών βαρών  $w_{kj}$ . Τα συναπτικά βάρη παίρνουν θετικές τιμές στην περίπτωση που η συνδεόμενη σύναψη είναι διεγερτική και αρνητικές τιμές στην περίπτωση που η συνδεόμενη σύναψη είναι ανασταλτική (Haykin, 1994), ενώ αναλόγως με την τιμή του βάρους γίνεται εμφανές το πόσο σημαντικό είναι το συγκριμένο σήμα στη διαμόρφωση της δομής του δικτύου. Όταν η τιμή του συνοπτικού βάρους είναι μεγάλη τότε είναι μεγάλη και η συνεισφορά του σήματος και το αντίθετο όταν η τιμή είναι μικρή (Αργυράκης, 2001). Ένα επιπλέον στοιχείο του νευρωνικού μοντέλου είναι ο παράγοντας πρόσθεσης των εισερχόμενων σημάτων πολλαπλασιαζόμενα ανάλογα με τις αντίστοιχες συνάψεις, η διαδικασία αυτή ονομάζεται γραμμικά συνδυαστική έξοδος. Ένα ακόμη βασικό στοιχείο είναι η συνάρτηση ενεργοποίησης (activation function),  $F(\cdot)$  η οποία περιορίζει το σήμα εξόδου μέσα σε ένα συγκεκριμένο εύρος τιμών. Τέλος, το νευρωνικό μοντέλο εμπεριέχει έναν εξωτερικό παράγοντα εισόδου που μπορεί να είναι είτε το κατώφλι (threshold),  $\theta_k$  ή η πόλωση (bias),  $b_k$ . Σκοπός του κατωφλίου ως παράγοντα εισόδου είναι η μείωση της εισόδου της συνάρτησης ενεργοποίησης ενώ στην αντίθετη περίπτωση η είσοδος της συνάρτησης ενεργοποίησης αυξάνεται μέσω της πόλωσης (Haykin, 1994).

Η σχηματική αναπαράσταση των διεργασιών του νευρωνικού μοντέλου δίνεται στην  
εικόνα 2-2.



Εικόνα 2-2 Αναπαράσταση κόμβου νευρωνικού δικτύου

Η μαθηματική περιγραφή ενός νευρώνα  $k$ , μπορεί να εκφραστεί μέσω των  
εξισώσεων 2.1 και 2.2.

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad (2.1)$$

$$y_k = F(u_k + b_k) \quad (2.2)$$

Όπου:

$x_1, x_2, x_3, \dots, x_n$ : τα δεδομένα εισόδου

$w_{k1}, w_{k2}, w_{k3}, \dots, w_{kn}$ : τα συναπτικά βάρη

$u_k$ : η γραμμικά συνδυαστική έξοδος

$y_k$ : η έξοδος του δικτύου

$b_k$ : η πόλωση του κόμβου  $k$  (η αρνητική τιμή της οποίας ισούται με το κατώφλι  $\theta_k$ )

## 2.4 Συνάρτηση ενεργοποίησης

Η συνάρτηση ενεργοποίησης  $F(u)$  ορίζει την έξοδο του νευρώνα συναρτήσει της εισόδου,  $u$ . Η συνάρτηση ενεργοποίησης μπορεί να διαχωριστεί σε τρεις διαφορετικούς τύπους, όπως εκφράζονται παρακάτω (Haykin, 1994):

### 1. Συνάρτηση κατωφλίου

Για τη συνάρτηση αυτού του τύπου ισχύει η εξίσωση 2.3:

$$F(u) = \begin{cases} 1, & \text{αν } u \geq 0 \\ 0, & \text{αν } u < 0 \end{cases} \quad (2.3)$$

Ως εκ τούτου, η έξοδος του κόμβου  $k$  δίνεται από την εξίσωση 2.4:


$$y_k = \begin{cases} 1, & \text{αν } u_k \geq 0 \\ 0, & \text{αν } u_k < 0 \end{cases} \quad (2.4)$$

Και έτσι η γραμμικά συνδυαστική έξοδος  $u_k$  δίνεται από την εξίσωση 2.5:

$$u_k = \sum_{j=1}^n w_{kj} - x_j + b_k \quad (2.5)$$



Η συνάρτηση κατωφλίου μπορεί να αναπαρασταθεί γραφικά σύμφωνα με την  
εικόνα 2-3:



Εικόνα 2-3 Συνάρτηση κατωφλίου (Haykin, 1994 p.11)


Ο κόμβος συνάρτησης τέτοιου τύπου αναφέρεται στη βιβλιογραφία ως μοντέλο  
McCulloch&Pitts.

## 2. Τμηματικά γραμμική συνάρτηση

Για τη συνάρτηση αυτού του τύπου ισχύει η εξίσωση 2.6:

$$F(u) = \begin{cases} 1, & u \geq \frac{1}{2} \\ u, & \frac{1}{2} > u > -\frac{1}{2} \\ 0, & u \leq -\frac{1}{2} \end{cases} \quad (2.6)$$

Η μορφή της συνάρτησης απεικονίζεται στην εικόνα 2-4:




Εικόνα 2-4 Τμηματικά γραμμική συνάρτηση (Haykin,1994, p.11)

### 3. Σιγμοειδής συνάρτηση

Αποτελεί την πιο ευρέως χρησιμοποιούμενη συνάρτηση ενεργοποίησης για την κατασκευή νευρωνικών δικτύων. Ορίζεται ως αυστηρά αύξουσα συνάρτηση, η οποία παρουσιάζει ομαλότητα και ασυμπτωτικές ιδιότητες. Ένα παράδειγμα σιγμοειδούς συνάρτησης είναι η λογιστική συνάρτηση που εκφράζεται βάσει της σχέσης 2.7:

$$F(u) = \frac{1}{1+\exp(-au)} \quad (2.7)$$

Όπου,  $a$  συντελεστής κλίσης της σιγμοειδούς συνάρτησης. Με την αλλαγή αυτού του παράγοντα αλλάζει και η κλίση της σιγμοειδούς συνάρτησης όπως είναι εμφανές στην εικόνα 2-5.



Εικόνα 2-5 Σιγμοειδής συνάρτηση (Haykin,1994, p.11)

## 2.5 Κατηγορίες Νευρωνικών Δικτύων βάσει τρόπου διάδοσης

Τα νευρωνικά δίκτυα διαχωρίζονται σε κατηγορίες ανάλογα με τη συνδεσμολογία των κόμβων αλλά και τη διάδοση του σήματος. Ο διαχωρισμός αυτός γίνεται στις παρακάτω δύο κατηγορίες (Kröse & der Smagt, 1996):

- **Δίκτυα εμπρός τροφοδότησης:** Η διάδοση των δεδομένων εισόδου γίνεται αποκλειστικά προς τα εμπρός. Η επεξεργασία των δεδομένων μπορεί να γίνει μέσω πολλαπλών κόμβων, ενώ δεν είναι δυνατή η σύνδεση από τις εξόδους των κόμβων στις εισόδους τους είτε στο ίδιο είτε σε προηγούμενα επίπεδα.
- **Δίκτυα με ανατροφοδότηση:** Είναι δυνατή η μετάδοση του σήματος από τις εξόδους στις εισόδους των κόμβων του ίδιου ή προηγούμενων επιπέδων.

## 2.6 Κατηγορίες Μάθησης

Ως μάθηση ορίζεται η διαδικασία κατά την οποία οι ελεύθερες παράμετροι ενός νευρωνικού δικτύου προσαρμόζονται μέσω μιας συνεχούς διεργασίας προσομοίωσης από το περιβάλλον στο οποίο το δίκτυο είναι ενσωματωμένο. Ο τύπος της μάθησης καθορίζεται από τον τρόπο βάσει του οποίου γίνονται οι αλλαγές των παραμέτρων (Haykin, 1994).

Οι κυριότερες διαδικασίες μάθησης του νευρωνικού δικτύου είναι δύο. Η επιβλεπόμενη μάθηση και η μη-επιβλεπόμενη μάθηση.

Στην **επιβλεπόμενη μάθηση** παρέχονται στο δίκτυο τα δεδομένα εισόδου καθώς και οι στόχοι που επιδιώκουμε να προσεγγίσει. Αυτά τα ζεύγη εισόδων-εξόδων δίνονται στο δίκτυο μέσω ενός εξωτερικού δασκάλου ή μέσω του συστήματος. Οι παράμετροι του δικτύου προσαρμόζονται ανάλογα με το διάνυσμα εκπαίδευσης αλλά και το σήμα του σφάλματος, το οποίο προσδιορίζεται ως η διαφορά της απόκρισης του δικτύου από την επιθυμητή που έχει τεθεί μέσω των στόχων (Kröse & der Smagt, 1996; Haykin, 1994).

Κατά τη **μη επιβλεπόμενη μάθηση** παρέχονται στο δίκτυο μόνο δεδομένα εισόδου. Επομένως, η εκπαίδευση γίνεται με τέτοιο τρόπο ώστε το δίκτυο πραγματοποιεί έναν εσωτερικό έλεγχο όπου αναζητά κάποιες τάσεις ή κανονικότητα στα σήματα εισόδου, στοχεύοντας στην ύπαρξη κοινών ιδιοτήτων εισόδων και εξόδων. Τα βάρη δεν προσαρμόζονται βάσει κάποιας εξωτερικής παραμέτρου, αλλά η εκπαίδευση σταματά όταν ο στόχος, της όσο το δυνατόν μικρότερης τιμής στα σφάλματα εξόδου, έχει επιτευχθεί (Αργυράκης, 2001).

## 2.7 Κανόνες εκμάθησης Perceptron

Ο απλός αισθητήρας (perceptron) προτάθηκε το 1958 από τον Rosenblatt και αποτελεί την απλούστερη μορφή ενός νευρωνικού δικτύου. Αποτελείται από ένα μόνο νευρώνα με προσαρμοζόμενα συναπτικά βάρη και πολώσεις (Haykin, 1994) και συνιστά το πιο απλό, αυτοδύναμο σύστημα που υπάρχει και επιτελεί μια ορισμένη διεργασία (Αργυράκης, 2001).

Η είσοδος του δικτύου είναι το άθροισμα των δεδομένων εισόδου πολλαπλασιαζόμενα με το αντίστοιχο βάρος. Η έξοδος του δικτύου είναι συνάρτηση της εισόδου και δίνεται από τη σχέση 2.8 (Kröse & der Smagt, 1996):

$$\mathbf{y} = \mathbf{F}(\sum_{i=1}^n \mathbf{w}_i \mathbf{x}_i + \mathbf{b}) \quad (2.8)$$


Η συνάρτηση ενεργοποίησης εκφράζεται από τη συνάρτηση κατωφλίου και δίνεται από την εξίσωση 2.9:

$$\mathbf{F}(\mathbf{u}) = \begin{cases} +1, & \text{αν } \mathbf{u} > 0 \\ -1, & \text{αν } \mathbf{u} \leq 0 \end{cases} \quad (2.9)$$

Σύμφωνα με την εξίσωση 2.9 παραπάνω, η έξοδος του δικτύου μπορεί να πάρει τις τιμές +1 και -1. Ως εκ τούτου, το δίκτυο είναι ικανό ταξινομήσει τις εισόδους σε μία από τις δύο κατηγορίες. Όταν η είσοδος είναι θετική τότε ταξινομείται στην πρώτη κατηγορία ενώ σε διαφορετική περίπτωση στη δεύτερη. Ο διαχωρισμός μεταξύ των δύο κατηγοριών αναπαριστά μια ευθεία γραμμή. Για λόγους απλοποίησης, θεωρούμε την πιο απλή μορφή δικτύου με μόνο δύο εισόδους, έτσι παίρνουμε την εξίσωση 2.10 (Kröse & der Smagt, 1996).

$$\mathbf{w}_1 \mathbf{x}_1 + \mathbf{w}_2 \mathbf{x}_2 + \mathbf{b} = 0 \Rightarrow \mathbf{x}_2 = -\frac{\mathbf{w}_1 \mathbf{x}_1}{\mathbf{w}_2} - \frac{\mathbf{b}}{\mathbf{w}_2} \quad (2.10)$$

Η εικόνα 2-6 αποτελεί τη γεωμετρική αναπαράσταση της εξίσωσης 2.10. Όπως είναι εμφανές τα βάρη καθορίζουν την κλίση της ευθείας, ενώ η πόλωση την απόσταση από την αρχή των αξόνων.



Εικόνα 2-6 Γεωμετρική αναπαράσταση της διαχωριστικής συνάρτησης και των βαρών (Kröse&der Smagt, 1996. p.24)

Η αλλαγή στα βάρη και τις πολώσεις πραγματοποιείται προσθέτοντας έναν όρο διόρθωσης στην προηγούμενη τιμή τους δημιουργώντας με αυτόν τον τρόπο την καινούρια τιμή. Η διαδικασία αυτή εκφράζεται μέσω των σχέσεων 2.11 και 2.12 (Kröse & der Smagt,1996):

$$\mathbf{w}_i(\mathbf{t} + 1) = \mathbf{w}_i(\mathbf{t}) + \Delta \mathbf{w}(\mathbf{t}) \quad (2.11)$$

$$\mathbf{b}(\mathbf{t} + 1) = \mathbf{b}(\mathbf{t}) + \Delta \mathbf{b}(\mathbf{t}) \quad (2.12)$$

Όπου  $\Delta w(t)$  και  $\Delta b(t)$  οι οροί διόρθωσης για τα βάρη και τις πολώσεις αντίστοιχα.

Για τη διόρθωση συναπτικών βαρών και πολώσεων εφαρμόζεται μια επαναληπτική διαδικασία. Αρχικά, θεωρώντας ένα σύνολο δεδομένων αποτελούμενων από το διάνυσμα εισόδου  $x$  και την επιθυμητή έξοδο  $d(x)$ , ο κανόνας εκμάθησης perceptron ακολουθεί τα παρακάτω βήματα (Kröse & der Smagt,1996):

- 1.Εισάγονται τυχαίες τιμές των συναπτικών βαρών.
2. Επιλέγεται ένα διάνυσμα  $x$  από το σύνολο των σημάτων εκπαίδευσης.
3. Αν  $y \neq d(x)$ , τροποποιούνται όλα τα βάρη σύμφωνα με τη σχέση:

$$\Delta w_i = d(x)x_i.$$

4. Επιστροφή στο βήμα 2.

Με την αλλαγή των βαρών πρέπει να γίνει και αλλαγή της πόλωσης,  $b$ . Η πόλωση, ισοδυναμεί με το συναπτικό βάρος  $w_0$  μεταξύ του κόμβου εξόδου και της θεωρητικής υποστηρικτικής μονάδας η οποία ισούται με  $x_0=1$ . Συνεπώς, σύμφωνα με την κανόνα εκμάθησης perceptron, η πόλωση τροποποιείται σύμφωνα με τη σχέση 2.13 (Kröse & der Smagt, 1996):

$$\Delta b = \begin{cases} 0, & \text{για σωστή απόκριση του perceptron} \\ dx, & \text{αλλιώς} \end{cases} \quad (2.13)$$

## 2.8 Η συνάρτηση XOR

Το μοντέλο perceptron αν και έχει αρκετές δυνατότητες δε διαθέτει την ικανότητα ταξινόμησης μη γραμμικώς διαχωρίσιμων συναρτήσεων. Μια τέτοιου τύπου συνάρτηση είναι η XOR (Exclusive-OR) (Haykin, 1994). Ο πίνακας 2-1 αναπαριστά τα προσδοκώμενα αποτελέσματα των κόμβων εισόδου και εξόδου της συνάρτησης XOR (Kröse & der Smagt, 1996).

Πίνακας 2-1 Συνάρτηση XOR


$x_0$	$x_1$	$d$
-1	-1	-1
-1	1	1
1	-1	1
1	1	-1

Όπως είναι εμφανές και από τον πίνακα 2-1, αν οι τιμές εισόδου έχουν την ίδια τιμή η τιμή εξόδου είναι ίση με -1 ενώ αν είναι διαφορετικές παίρνει την τιμή +1. (Ταπόγλου, 2011)

Στην περίπτωση του απλού perceptron, για δύο τιμές εισόδου και μία έξοδο, η είσοδος εκφράζεται μέσω της εξίσωσης 2.14 (Kröse & der Smagt, 1996):

$$u = w_1x_1 + w_2x_2 + b \quad (2.14)$$

Με βάση την εξίσωση 1.8, όταν η τιμή του  $u$  είναι αρνητική, η έξοδος του perceptron γίνεται μηδενική ενώ στην περίπτωση που είναι θετική, ισούται με τη μονάδα. Η γεωμετρική αναπαράσταση της παραπάνω εξίσωσης περιγράφεται από την εικόνα 2-7:



Εικόνα 2-7 Γεωμετρική αναπαράσταση συνάρτησης XOR (Ταπόγλου, 2011, p.24)

Για μια σταθερά  $b$ , η έξοδος του perceptron είναι ίση με 1 στο ένα άκρο της διαχωριστικής ευθείας γραμμής και ίση με 0 στο άλλο. Η εξίσωση αυτής της ευθείας δίνεται από τη σχέση 2.15 (Kröse & der Smagt, 1996):


$$\mathbf{w}_1\mathbf{x}_1 + \mathbf{w}_2\mathbf{x}_2 = -\mathbf{b} \quad (2.15)$$

Τόσο η κατεύθυνση όσο και ο προσανατολισμός της ευθείας γραμμής καθορίζονται από τα συναπτικά βάρη αλλά και την πόλωση. Από την εικόνα 2-7 γίνεται σαφές ότι τα σημεία  $(-1,-1)$  και  $(1,1)$  δε μπορούν να διαχωριστούν από τα σημεία  $(-1,1)$  και  $(1,-1)$  μέσω μιας ευθείας γραμμής, όπως θα ήταν θεμιτό ώστε να υπάρξει λύση στο πρόβλημα, επομένως ένας απλός perceptron δε μπορεί να λύσει ένα πρόβλημα XOR (Kröse & der Smagt, 1996).

Ένα πρόβλημα XOR μπορεί να επιλυθεί με την εισαγωγή κρυφών επιπέδων, επεκτείνοντας με αυτόν τον τρόπο τον απλό perceptron σε ένα πολύ επίπεδο νευρωνικό δίκτυο. Σύμφωνα με την εικόνα 2-8 τα τέσσερα σημεία του προβλήματος μπορούν να αναπαρασταθούν σαν κορυφές ενός τετράεδρου στον τρισδιάστατο χώρο, το οποίο ορίζεται από τις δύο εισόδους με την προσθήκη ενός κρυφού



επιπέδου. Έτσι, τα τέσσερα σημεία μπορούν να διαχωριστούν σε δυο ομάδες μέσω ενός υπερεπίπεδου (Kröse & der Smagt, 1996).



Εικόνα 2-8 Επίλυση προβλήματος XOR βαρών (Kröse & der Smagt, 1996 p.30)

## 2.9 Κανόνας Δέλτα

Ο κανόνας Δέλτα παρουσιάστηκε πρώτη φορά από τους Widrow και Hoff ως ένας κανόνας εκμάθησης του ελάχιστου τετραγωνικού σφάλματος (least mean square error-LMS). Αποτελεί μια γενίκευση του αλγορίθμου εκπαίδευσης perceptron, ενώ η βασικά λειτουργική διαφορά τους εντοπίζεται στον τρόπο που ο κανόνας εκμάθησης χρησιμοποιεί την έξοδο του δικτύου. Ο κανόνας εκμάθησης perceptron χρησιμοποιεί την έξοδο της συνάρτησης κατωφλίου (-1 ή 1) για τη μάθηση του δικτύου. Από την άλλη μεριά, ο κανόνας Δέλτα χρησιμοποιεί την έξοδο χωρίς περεταίρω αντιστοιχία με τιμές εξόδου -1 ή 1.

Για ένα νευρωνικό δίκτυο ενός επιπέδου με γραμμική συνάρτηση ενεργοποίησης η έξοδος δίνεται από την εξίσωση 2.16:

$$y = \sum_{j=1} w_j x_j + b \quad (2.16)$$

Το δίκτυο διαθέτει ένα πλήθος αισθητήρων οι οποίοι παράγουν μια σειρά σημάτων εισόδου,  $x^p$  σύμφωνα με το πρότυπο  $p$ . Αυτά τα σήματα πολλαπλασιάζονται με ένα

σύνολο συναπτικών βαρών  $w^p$  και τα σήματα που προκύπτουν αθροίζονται στη συνέχεια για να παράγουν την τελική απόκριση του δικτύου, τις εξόδους,  $y^p$ . Σκοπός της διαδικασίας είναι η βελτιστοποίηση των συναπτικών βαρών έτσι ώστε η διαφορά ανάμεσα στις εξόδους του δικτύου,  $y^p$  και τους προσδοκώμενους στόχους,  $d^p$  να είναι όσο το δυνατόν μικρότερη (Haykin, 1994). Αυτή τη διαφορά χρησιμοποιείται από τον κανόνα δέλτα για το μετασχηματισμό των βαρών. Η εξίσωση σφάλματος 2.17 δίνεται παρακάτω:

$$E = \sum_p E^p = \frac{1}{2} (d^p - y^p)^2 \quad (2.17)$$

Όπου,  $E$  το ολικό μέσο τετραγωνικό σφάλμα και  $E^p$  το τετραγωνικό σφάλμα του προτύπου  $p$ .

Στη συνέχεια, ο αλγόριθμος χρησιμοποιεί τη μέθοδο κλίσης καθόδου για τον υπολογισμό των τιμών των βαρών που συνεισφέρουν στην ελαχιστοποίηση του σφάλματος. Ο μετασχηματισμός των βαρών είναι ανάλογος της αρνητικής παραγώγου της συνάρτησης σφάλματος, για τα υπάρχοντα δεδομένα εισόδου, συναρτήσει κάθε συναπτικού βάρους. Αυτό φαίνεται στην εξίσωση 2.18:

$$\Delta_p w_j = -\gamma \frac{\partial E^p}{\partial w_j} \quad (2.18)$$

Όπου  $\gamma$ , ένας συντελεστής απόδοσης.

Η παράγωγος της παραπάνω εξίσωσης υπολογίζεται από την εξίσωση 2.19:

$$\frac{\partial E^p}{\partial w_j} = \frac{\partial E^p}{\partial y^p} \frac{\partial y^p}{\partial w_j} \quad (2.19)$$

Όμως σύμφωνα με την εξίσωση 2.16 προκύπτει η σχέση 2.20 και κατόπιν η 2.21:

$$\frac{\partial y^p}{\partial w_j} = x_j \quad (2.20)$$

$$\frac{\partial E^p}{\partial y^p} = -(d^p - y^p) \quad (2.21)$$

Έτσι με βάση τις σχέσεις 2.18, 2.20, 2.21 προκύπτει η εξίσωση 2.22:


$$\Delta_p w_j = \gamma \delta^p x_j \quad (2.22)$$

(Kröse & der Smagt, 1996)

## 2.11 Δίκτυα πολλαπλών επιπέδων

Ένα απλό νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης απαρτίζεται από δύο επίπεδα, το επίπεδο αυτό που εμπεριέχει τους κόμβους εισόδου και εκείνο που εμπεριέχει τους κόμβους εξόδου (υπολογιστικοί κόμβοι) όπου συνδέονται μεταξύ τους μέσω των παραγόντων βάρους. Ένα πολύ-επίπεδο νευρωνικό δίκτυο μπορεί να έχει ένα ή περισσότερα κρυφά επίπεδα (hidden layers) να παρεμβάλλονται των επιπέδων εισόδου και εξόδου. Οι υπολογιστικές μονάδες των κρυφών επιπέδων καλούνται κρυφοί κόμβοι (hidden nodes). Σε ένα δίκτυο με αυτή την αρχιτεκτονική οι κόμβοι κάθε επίπεδου που ακολουθεί λαμβάνουν το σήμα εισόδου τους από τους κόμβους του αμέσως προηγούμενου επιπέδου. Το σύνολο των σημάτων εξόδου στο επίπεδο εξόδου αποτελεί την τελική απόκριση του δικτύου (Haykin, 1994).

Η γραφική αναπαράσταση ενός δικτύου πολλαπλών επιπέδων δίνεται στην εικόνα 2-9:



Εικόνα 2-9 Αναπαράσταση πολυεπίπεδου νευρωνικού δικτύου

## 2.12 Ο Γενικευμένος Κανόνας Δέλτα

Ο κανόνας Δέλτα όπως αναπτύχθηκε στο υποκεφάλαιο 2.10 αφορά γραμμικές συναρτήσεις ενεργοποίησης. Ως εκ τούτου, για την εφαρμογή μη γραμμικών συναρτήσεων πρέπει να γίνει μια γενίκευση του κανόνα.

Η συνάρτηση ενεργοποίησης είναι μια διαφορίσιμη συνάρτηση του συνόλου των εισόδων και δίνεται από την εξίσωση 2.23:

$$y_k^p = F(u_k^p) \quad (2.23)$$

Όπου ο παράγοντας  $u_k^p$ , υπολογίζεται από την εξίσωση 2.24:

$$u_k^p = \sum_j w_{jk} y_j^p + b_k \quad (2.24)$$

Και γενικεύοντας τη σχέση 2.18, παίρνουμε τη 2.25:

$$\Delta_P w_{jk} = -\gamma \frac{\partial E^P}{\partial w_{jk}} \quad (2.25)$$

Το ολικό τετραγωνικό σφάλμα του προτύπου,  $E^P$ , στους κόμβους εξόδου, υπολογίζεται από τη σχέση 2.26:

$$E^P = \frac{1}{2} \sum_{k=1}^{N_o} (d_k^p - y_k^p)^2 \quad (2.26)$$

Στη συνέχεια, το μέσο τετραγωνικό σφάλμα τίθεται ίσο με  $E = \sum_P E^P$  και έτσι προκύπτει η εξίσωση 2.27:

$$\frac{\partial E^P}{\partial w_{jk}} = \frac{\partial E^P}{\partial u_k^p} \frac{\partial y^p}{\partial w_{jk}} \quad (2.27)$$

Παραγωγίζοντας την εξίσωση 2.24 προκύπτει η σχέση 2.28:

$$\frac{\partial s_k^p}{\partial w_{jk}} = y_j^p \quad (2.28)$$

Έπειτα η τοπική κλίση,  $\delta_k^p$ , ορίζεται από τη σχέση 2.29:

$$\delta_k^p = -\frac{\partial E^P}{\partial u_k^p} \quad (2.29)$$

Η μεταβολή των βαρών γίνεται σύμφωνα με την εξίσωση 2.30, όπως δείχνεται παρακάτω. Με τον τρόπο αυτό εφαρμόζεται η μέθοδος της κλίσης καθόδου στην επιφάνεια των βαρών.

$$\Delta_p \mathbf{w}_{jk} = \gamma \delta_k^p \mathbf{y}_j^p \quad (2.30)$$

Η διαδικασία αυτή αποσκοπεί στον σωστό υπολογισμό των  $\delta_k^p$  για κάθε κόμβο. Ο υπολογισμός αυτός πραγματοποιείται αναδρομικά με την διάδοση των σημάτων προς τα πίσω, δηλαδή από την έξοδο προς την είσοδο του δικτύου.

Το  $\delta_k^p$  υπολογίζεται ως γινόμενο δύο παραγώγων, όπου η μία εκφράζει τη μεταβολή των συναπτικών βαρών σε συνάρτηση της εξόδου του δικτύου, ενώ η δεύτερη εκφράζει τη μεταβολή της εξόδου συναρτήσει της μεταβολής της εισόδου (Kroße & der Smagt, 1996; Αργυράκης, 2001). Έτσι προκύπτει η εξίσωση 2.31:

$$\delta_k^p = -\frac{\partial E^p}{\partial u_k^p} = -\frac{\partial E^p}{\partial y_k^p} \frac{\partial y_k^p}{\partial u_k^p} \quad (2.31)$$

Παραγωγίζοντας την εξίσωση 2.23 προκύπτει ότι η παράγωγος της συνάρτησης ενεργοποίησης, όπως δίνεται από τη σχέση 2.32, ισούται με το δεύτερο παράγοντα της εξίσωσης 2.31:

$$\frac{\partial y_k^p}{\partial u_k^p} = \mathbf{F}'(\mathbf{u}_k^p) \quad (2.32)$$

Σχετικά με τον πρώτο παράγοντα της εξίσωσης 2.31 θεωρούμε δύο περιπτώσεις. Η πρώτη αφορά, την περίπτωση που ο κόμβος  $k$  είναι κόμβος εξόδου του δικτύου (με συμβολισμό  $k=o$ ), ενώ η δεύτερη να είναι κόμβος κρυφού επιπέδου του δικτύου (με συμβολισμό  $k=h$ ).

➤ Αν  $k$ , κόμβος εξόδου:

Στην περίπτωση αυτή ισχύει ο συνήθης κανόνας δέλτα. Έτσι ισχύει η εξίσωση 2.33:

$$\frac{\partial E^p}{\partial y^p} = -(\mathbf{d}_o^p - \mathbf{y}_o^p) \quad (2.33)$$

Και η τοπική κλίση,  $\delta_o^p$ , υπολογίζεται σύμφωνα με τη σχέση 2.34:

$$\delta_o^p = (\mathbf{d}_o^p - \mathbf{y}_o^p) \mathbf{F}'_o(\mathbf{u}_o^p) \quad (2.34)$$

➤ Αν  $k$ , κόμβος κρυφού επιπέδου:

Σε αυτήν την περίπτωση δεν είναι γνωστό το πώς συμβάλει ο κρυφός κόμβος στην έξοδο του δικτύου, (Kröse & der Smagt, 1996) καθώς δεν έχουμε τιμές για στόχους (Αργυράκης, 2001). Επομένως, εφαρμόζεται ο κανόνας αλυσίδας για τον υπολογισμό του σφάλματος όπως δίνεται από τη σχέση 2.35:

$$\frac{\partial EP}{\partial y_h^p} = \sum_{o=1}^{N_o} \frac{\partial EP}{\partial u_o^p} \frac{\partial u_o^p}{\partial y_h^p} = \sum_{o=1}^{N_o} \frac{\partial EP}{\partial u_o^p} \frac{\partial}{\partial y_h^p} \sum_{j=1}^{N_h} w_{ko} y_j^p = \sum_{o=1}^{N_o} \frac{\partial EP}{\partial u_o^p} w_{ho} = - \sum_{o=1}^{N_o} \delta_o^p w_{ho} \quad (2.35)$$

Αντικαθιστώντας τη σχέση 2.35 στη σχέση 3.31, παίρνουμε την σχέση 2.36:

$$\delta_h^p = F'(u_h^p) \sum_{o=1}^n \delta_o^p w_{ho} \quad (2.36)$$

Όπου:

$N_o$ : ο αριθμός των κόμβων εξόδου

$N_h$ : ο αριθμός των κρυφών κόμβων

$w_{ko}$ : το συναπτικό βάρος μεταξύ του κόμβου  $k$  και του κόμβου εξόδου

$w_{ho}$ : το συναπτικό βάρος μεταξύ των κρυφών κόμβων και των κόμβων εξόδου.

(Kröse & der Smagt, 1996)

## 2.13 Αλγόριθμος οπισθοδιάδοσης σφάλματος

Η εφαρμογή των πολυεπίπεδων νευρωνικών δικτύων έχει συμβάλει καθαριστικά στην επίλυση πληθώρας προβλημάτων (Haykin, 1994). Ο αλγόριθμος οπισθοδιάδοσης του σφάλματος είναι ο κανόνας που χρησιμοποιείται κατά κύριο λόγο στη μεταβολή των βαρών στα πολυεπίπεδα νευρωνικά δίκτυα.

Ο αλγόριθμος οπισθοδιάδοσης του σφάλματος εφαρμόζεται σε δύο βήματα. Στο πρώτο, το δίκτυο δέχεται τα σήματα εισόδου, τα οποία διαδίδονται μέσω των συνάψεων του δικτύου και παράγουν τις τιμές εξόδου κάθε κόμβου. Η τιμή αυτή συγκρίνεται με την τιμή των στόχων που έχουμε ορίσει και υπολογίζεται η μεταξύ τους απόκλιση, η οποία δίνει και το σφάλμα για κάθε κόμβο εξόδου. Στο δεύτερο στάδιο το σήμα μεταδίδεται στο δίκτυο κατά την αντίστροφη πορεία, δηλαδή από πίσω προς τα εμπρός. Κατά την πορεία αυτή το σήμα του σφάλματος μεταδίδεται στους κόμβους του δικτύου και υπολογίζονται οι απαιτούμενες αλλαγές στα συναπτικά βάρη.

Η διαδικασία μάθησης, ή αλλιώς μάθηση οπισθοδιάδοσης, προϋποθέτει οι αλλαγές στα συναπτικά βάρη να γίνονται αναλογικά με  $\partial E^p / \partial w$ . Η αλλαγή των βαρών γίνεται σύμφωνα με τη σχέση 2.37:

$$\Delta w_{jk}(t+1) = \gamma \delta_k^p y_j^p + a \Delta w_{jk}(t) \quad (2.37)$$


Για την αποφυγή ταλάντωσης σε περίπτωση που ο συντελεστής απόδοσης,  $\gamma$ , είναι υπερβολικά μεγάλος έχει προστεθεί ένας σταθερός συντελεστής ορμής  $a$ , ο οποίος συμβάλει στην μεταβολή των βαρών σε εξάρτηση με τις προηγούμενες μεταβολές τους. Ως  $t$  ορίζεται ο αριθμός την επανάληψης.

Η σημαντικότητα του συντελεστή ορμής έγκειται στην ιδιότητα του να βοηθάει στον εντοπισμό του ελαχίστου με μεγαλύτερη ταχύτητα από εκείνη η οποία επιτυγχάνεται χωρίς αυτόν. Χωρίς το συντελεστή ορμής και με μικρό συντελεστή απόδοσης, η διαδικασία εντοπισμού του ελαχίστου διαρκεί πολύ περισσότερο ενώ σε περίπτωση μεγάλου συντελεστή απόδοσης ενδέχεται να μην εντοπιστεί ποτέ λόγω ταλαντώσεων (Kröse & der Smagt, 1996).

## Κεφάλαιο 3 : Περιοχή μελέτης

### 3.1 Η κοιλάδα της Μεσσαράς

Η κοιλάδα της Μεσσαράς εκτείνεται σε μια περιοχή 398 km<sup>2</sup> και βρίσκεται στο κεντρικό-νότιο τμήμα της Κρήτης, σε μια απόσταση περίπου 50 km από την πόλη του Ηρακλείου. Αποτελεί την πιο σημαντική περιοχή αγροτικών δραστηριοτήτων σε ολόκληρη την Κρήτη, ενώ εκεί βρίσκονται το Μινωικό παλάτι της Φαιστού και η Ρωμαϊκή πόλη, Γκόρτης. Τα 250 περίπου εκ των 398 km<sup>2</sup> είναι καλλιεργημένα, με κύριες καλλιέργειες να αποτελούν τα ελαιόδεντρα (175 km<sup>2</sup>) και οι αμπελώνες (40 km<sup>2</sup>), ενώ οι υπόλοιπες καλλιεργήσιμες εκτάσεις αποτελούνται από λαχανικά, φρούτα και δημητριακά. Οι κάτοικοι στην κοιλάδα της Μεσσαράς υπολογίζονται περίπου στα 40000 άτομα. Η κύρια πηγή νερού άρδευσης προέρχεται από τα υπόγεια ύδατα ως αποτέλεσμα της έλλειψης επαρκούς ποσότητας επιφανειακών υδάτων εξαιρουμένων των χειμερινών μηνών (Croke et al., 2000).



Εικόνα 3-1 Περιοχή μελέτης-Πεδιάδα Μεσσαράς, Κρήτη

\*source: cascade-project.eu

### 3.2 Κλιματολογικά και υδρολογικά στοιχεία

Το κλίμα της περιοχής, όπως και ολόκληρης της Κρήτης, είναι ξηρή υπό-υγρό Μεσογειακό με ήπιους χειμώνες και ξηρά, ζεστά καλοκαίρια. Η μέση θερμοκρασία τους χειμερινούς μήνες κυμαίνεται στους 12°C, ενώ τους θερινούς στους 28°C. Το ποσοστό σχετικής υγρασίας κυμαίνεται σε πολύ μεγάλα ποσοστά, αφού το χειμώνα είναι περίπου 70% ενώ το καλοκαίρι 60%. Ο υδρολογικός κύκλος χωρίζεται σε υγρή και ξηρή περίοδο, ενώ εκτιμάται ότι το 40% της ολικής βροχόπτωσης σημειώνεται το Δεκέμβριο και Ιανουάριο ενώ από τον Ιούνιο μέχρι και τον Αύγουστο η βροχόπτωση που παρουσιάζεται είναι σχεδόν μηδαμινή. Παρόλο που η κοιλάδα της Μεσσαράς λαμβάνει (μεσοπρόθεσμα) ετήσια βροχόπτωση 600 mm κατά μέσο όρο, εκτιμάται ότι το 65% περίπου χάνεται λόγω εξατμισοδιαπνοής, 10% εκρέει προς τη θάλασσα και μόνο ένα ποσοστό 25% πηγαίνει για τον εμπλουτισμό της αποθήκης υπόγειου νερού (Vardavas et al., 1997).

### 3.3 Γεωλογικό υπόβαθρο

Η κοιλάδα της Μεσσαράς καλύπτεται κυρίως από τεταρτογενείς αλλούβιες αποθέσεις αργίλου, ιλύος, άμμου και κροκάλων πάχους από λίγα μέτρα έως και περισσότερα από 100. Η ανομοιογένεια των αποθέσεων της κοιλάδας υπήρξε η αιτία για μεγάλες παραλλαγές υδρογεωλογικών συνθηκών ακόμα και σε μικρές



αποστάσεις. Οι βόρειες πλαγιές αποτελούνται κυρίως από μαργαϊκούς νεογενείς σχηματισμούς ενώ οι πιο νότιες πλαγιές συνίστανται κυρίως από σχιστολιθικούς και ασβεστολιθικούς σχηματισμούς της μεσοζωικής περιόδου (Croke et al., 2000).

## Κεφάλαιο 4 : Μεθοδολογία

### 4.1 Υδατικό ισοζύγιο

Για τη δημιουργία του νευρωνικού δικτύου πρέπει αρχικά να προσδιοριστούν οι παράμετροι εισόδου και εξόδου, οι οποίες συνδέονται με το υδατικό ισοζύγιο το οποίο προσπαθεί να προσομοιώσει το νευρωνικό δίκτυο.

Το υδατικό ισοζύγιο εκφράζεται από την εξίσωση 4.1, όπως περιγράφεται παρακάτω:

$$\Delta S = I - O + P \pm EPT \pm Q \quad (4.1)$$

Όπου,

$\Delta S$ : η μεταβολή στο ρυθμό αποθήκευσης του υδροφορέα

$I$ : οι εισροές στη λεκάνη απορροής

$O$ : οι εκροές από τη λεκάνη απορροής σε άλλες υδατικές μορφές

$P$ : οι βροχοπτώσεις στη λεκάνη απορροής

$EPT$ : η εξατμισοδιαπνοή που λαμβάνει χώρα στη λεκάνη απορροής

$Q$ : ο ρυθμός άντλησης/εμπλουτισμού (Trichakis et al., 2009)

Οι εισροές ( $I$ ) στη μελετώμενη λεκάνη απορροής μπορούν να γίνουν επιφανειακά ή υπόγεια και εκφράζονται μέσω μετρήσεων παροχής υδάτων που εισέρχονται από άλλες λεκάνες απορροής. Ομοίως, οι εκροές ( $O$ ) χωρίζονται σε επιφανειακές και υπόγειες και εκφράζονται με την παροχή στο σημείο εκροής. Στην παρούσα διπλωματική διαθέτουμε ως δεδομένα εισόδου τους χείμαρρους οι οποίοι αποτελούν επιφανειακά νερά και εντάσσονται στις εισροές αν εισέρχονται στη λεκάνη απορροής και στις εκροές αν εξέρχονται από τη λεκάνη απορροής.

Όσον αφορά την εξατμισοδιαπνοή (EPT), μπορεί να οφείλεται είτε στην εξάτμιση του νερού είτε στη διαπνοή μέσω των φυτών. Διαθέσιμα δεδομένα υπάρχουν για τις τιμές της εξάτμισης καθώς και παραμέτρων που σχετίζονται με αυτή, όπως η ηλιοφάνεια και η μέγιστη και ελάχιστη θερμοκρασία σε ημερήσια βάση. Ωστόσο, παραλείπονται παράμετροι όπως η ταχύτητα του ανέμου και η σχετική υγρασία που όμως κρίνεται ότι δεν είναι ιδιαίτερα σημαντικές ώστε να επηρεάσουν σημαντικά το μοντέλο.

Ο ρυθμός άντλησης ή εμπλουτισμού (Q) είναι λογικό να επηρεάζει τη διαφορά στάθμης. Παρ' όλα αυτά, η μέτρηση του μπορεί να γίνει αποκλειστικά σε κάθε πηγάδι που υπάρχει στη περιοχή, γεγονός που καθιστά πολύ δύσκολη την καταγραφή όλων των απαραίτητων μετρήσεων και για το λόγο αυτό δεν υπάρχουν τα απαραίτητα δεδομένα. Συνεπώς, είναι φυσικό λόγω έλλειψης δεδομένων άντλησης ή εμπλουτισμού από τα γειτονικά πηγάδια το μοντέλο να μη μπορεί κάποιες μέρες να προσημειώσει τη μεταβολή της στάθμης.

Η μεταβολή του ρυθμού αποθήκευσης του υδροφορέα(ΔS) εκφράζεται μέσω της μεταβολής του υδραυλικού ύψους στη γεώτρηση(διαφορά παρατηρούμενης στάθμης μιας ημέρας μείον την παρατηρούμενη στάθμη της προηγούμενης ημέρας), η οποία στη μελέτη αυτή αποτελεί την παράμετρο εξόδου του νευρωνικού δικτύου.

Σε πληθώρα παλαιότερων εργασιών(Daliakopoulos et al., 2004; Adamowski et al., 2011) ήταν σύνηθες να χρησιμοποιείται εκτός από παράμετρος εισόδου και ως παράμετρος εξόδου το υδραυλικό ύψος αντί για τη διαφορά του υδραυλικού ύψους. Ωστόσο, κάτι τέτοιο δεν ενδείκνυται διότι οι δυο αυτές παράμετροι έχουν πολύ υψηλό βαθμό συσχέτισης, με το συντελεστή συσχέτισης να ξεπερνά το 0,998. Το γεγονός αυτό οδηγεί το νευρωνικό δίκτυο σε μια προκατάληψη που ως αποτέλεσμα έχει την υποτίμηση των υπόλοιπων παραμέτρων εισόδου, δημιουργώντας αυξημένα συνοπτικά βάρη για αυτές τις παραμέτρους εισόδου του υδραυλικού ύψους συγκριτικά με τις υπόλοιπες, πράγμα το οποίο πιθανότατα να καταστήσει το νευρωνικό ανίκανο στην ακριβή επίδραση των άλλων παραμέτρων στην παράμετρο εξόδου. Βάσει των παραπάνω, κρίνεται ως ιδανικότερη μεταβλητή εξόδου η διαφορά του υδραυλικού ύψους αντί για το ίδιο το υδραυλικό ύψος. (Trichakis et al., 2009)

## 4.2 Επεξεργασία χρονοσειρών

Τα δεδομένα που διατίθενται για την εφαρμογή του μοντέλου στην πεδιάδα της Μεσσαράς αποτελούνται από χρονοσειρές που περιέχουν μετρήσεις για βροχοπτώσεις (από επτά διαφορετικούς σταθμούς), εξάτμιση (από τέσσερις διαφορετικούς σταθμούς), ηλιοφάνεια (από ένα σταθμό), τη μέγιστη και ελάχιστη θερμοκρασία (από δύο σταθμούς) καθώς και τη στάθμη της γεώτρησης. Οι μετρήσεις λήφθηκαν για το χρονικό διάστημα από 6/9/2001 έως 31/3/2004. Το μοντέλο εφαρμόστηκε επίσης και για μετρήσεις δύο χρονοσειρών χείμαρρων για το χρονικό διάστημα 6/9/2001 έως 31/7/2002 και από 1/9/2002 έως 31/8/2003.

Στη συνέχεια, πραγματοποιήθηκε στατιστική ανάλυση κάθε χρονοσειράς μέσω της εύρεσης:

- της ελάχιστης τιμής
- της μέγιστης τιμής
- της μέσης τιμής
- της τυπικής απόκλισης
- της διασποράς
- της ασυμμετρίας
- της κύρτωσης

Η ανάλυση των μετρήσεων των χρονοσειρών με τα κριτήρια όπως αναλύθηκαν παραπάνω παρουσιάζεται στους πίνακες 4-1,4-2,4-3.

Πίνακας 4-1 Στατιστική ανάλυση δεδομένων χρονοσειρών βροχόπτωσης

	Βροχόπτωση (mm)						
	Μορόνι	Πόμπια	Βαγιωνιά	Άγιος Κύριλλος	Ασήμι	Καπετανιανά	Πραιτώρια
Ελάχιστο	0	0	0	0	0	0	0
Μέγιστο	132,2	124	175	130,8	200,5	180,4	147
Μέση τιμή	2,97	2,31	2,22	2,24	2,46	2,79	2,10
Τυπική απόκλιση	9,72	8,29	9,21	7,29	9,55	10,68	7,46
Διασπορά	94,56	68,78	84,76	53,17	91,19	114,13	55,73
Ασυμμετρία	6,15	6,70	9,53	8,08	11,37	7,85	9,79
Κύρτωση	57,80	68,84	145,11	113,62	206,71	98,79	160,50

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης

Πίνακας 4-2 Στατιστική ανάλυση χρονοσειρών μετεωρολογικών δεδομένων

	Εξάτμιση (mm)				Max ημερήσια θερμοκρασία (°C)	Min ημερήσια θερμοκρασία (°C)	Max ημερήσια θερμοκρασία (°C)	Min ημερήσια θερμοκρασία (°C)
	Αγία Βαρβάρα	Πόμπια	Ασήμι	Πραιτώρια	Πόμπια	Πόμπια	Πραιτώρια	Πραιτώρια
Ελάχιστο	0	0	0	0	1	-2	0,2	-5
Μέγιστο	20	18,8	11,92	15,1	42	27	41,5	17
Μέση τιμή	4,00	4,72	3,29	3,81	23,06	13,01	22,79	10,39
Τυπική απόκλιση	3,41	3,30	2,57	3,03	8,21	6,20	7,68	4,17
Διασπορά	11,64	10,92	6,60	9,20	67,42	38,43	58,98	17,39
Ασυμμετρία	1,02	0,71	0,75	0,68	0,22	0,15	0,08	-1,11
Κύρτωση	3,78	2,65	2,42	2,35	2,02	2,08	2,05	3,90

Πίνακας 4-3 Στατιστική ανάλυση χρονοσειρών μετεωρολογικών δεδομένων

	Χείμαρρος (m <sup>3</sup> /sec)		Ηλιοφάνεια (h)	Στάθμη Πηγαδιού (m)
	Ληθαίος	Φαιστός	Πραιτώρια	
Ελάχιστο	0	0	0	7,03
Μέγιστο	3,685	21,766	12,5	41,5
Μέση τιμή	0,31	0,54	6,73	21,89
Τυπική απόκλιση	0,51	1,79	3,59	10,71
Διασπορά	0,26	3,21	12,90	114,78
Ασυμμετρία	2,66	6,73	-0,36	0,13
Κύρτωση	10,99	62,73	1,97	1,49

### 4.3 Δομή και εκπαίδευση νευρωνικού δικτύου

Στην παρούσα εργασία χρησιμοποιήθηκε ένα πολυεπίπεδο νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης (multilayer feedforward network) με επιβλεπόμενη μάθηση (supervised learning) με οπισθοδιάδοση σφάλματος (backpropagation).

Η αρχιτεκτονική του δικτύου μεταβλήθηκε μέσω της μεθόδου δοκιμής και σφάλματος, έτσι ώστε να βρεθεί η καταλληλότερη για την ύπαρξη του μικρότερου δυνατού σφάλματος. Παράλληλα, πραγματοποιήθηκαν και άλλου είδους μεταβολές ως προς τον τρόπο μάθησης και τα δεδομένα εισόδου.

Συνολικά οι μεταβολές που πραγματοποιήθηκαν είναι οι εξής:

- Ως προς τη χρήση ή όχι των χείμαρρων ως παραμέτρους εισόδου.
- Ως προς την ύπαρξη ενός ή δύο κρυφών επιπέδων στο δίκτυο.
- Ως προς τον αριθμό των κρυφών κόμβων σε κάθε κρυφό επίπεδο.
- Ως προς τον αλγόριθμο εκπαίδευσης.
- Ως προς τη χρήση της καλύτερης ή των δύο καλύτερων τιμών χρονικής υστέρησης (αναλυτικότερα θα περιγραφεί στο επόμενο κεφάλαιο).

Κατόπιν της εισαγωγής των διαθέσιμων δεδομένων στο δίκτυο πραγματοποιείται η διαδικασία της εκπαίδευσης, έτσι ώστε το νευρωνικό να μπορέσει να προσομοιώσει τις τιμές της διαφοράς του υδραυλικού ύψους. Η πρακτική που ακολουθείται είναι ο διαχωρισμός των δεδομένων σε τρία υποσύνολα. Το πρώτο αφορά την εκπαίδευση του νευρωνικού δικτύου (training set) και υπολογίζει την κλίση του, ενώ παράλληλα πραγματοποιεί την ενημέρωση του δικτύου, των βαρών (weights) και των πολώσεων (biases). Σχετικά με το δεύτερο υποσύνολο, αυτό της επαλήθευσης (validation set), υπολογίζει την ικανότητα του δικτύου να γενικεύει. Το σφάλμα επαλήθευσης ελέγχεται κατά τη διάρκεια της εκπαίδευσης και ακολουθεί την πορεία μείωσης του σφάλματος εκπαίδευσης. Όταν αυτό σταματήσει να συμβαίνει και η γενίκευση παύει να υφίσταται βελτίωση σημαίνει ότι το δίκτυο αρχίζει την υπερπροσαρμογή των δεδομένων (overfitting) και το σφάλμα επαλήθευσης αρχίζει να αυξάνεται. Τα βάρη και οι πολώσεις αποθηκεύονται στην ελάχιστη τιμή του σφάλματος επαλήθευσης. Τέλος, η τρίτη υποκατηγορία αφορά το σφάλμα ελέγχου (test set error) το οποίο δε χρησιμοποιείται κατά την εκπαίδευση, αλλά δημιουργεί μια αυτόνομη μέτρηση της επίδοσης του δικτύου πριν και μετά την εκπαίδευση αυτού. Στην περίπτωση που υπολογίζεται ένα σφάλμα ελέγχου με μεγάλη απόκλιση από το σφάλμα επαλήθευσης, αυτό πιθανόν υποδεικνύει κακό διαχωρισμό των δεδομένων. (Neural Network Toolbox-User's guide, R2013b) Τα δεδομένα εισόδου διαχωρίστηκαν τυχαία στα τρία υποσύνολα, training set, validation set και test set σε εκατοστιαία ποσοστά 80-10-10 αντιστοίχως.

#### 4.4 Χρονική υστέρηση

Τόσο το νερό της βροχής που πέφτει στο έδαφος όσο και των χείμαρρων που ρέουν, χρειάζεται κάποιο χρόνο για να φτάσει στον υπόγειο υδροφορέα. Ως χρονική υστέρηση (time lag) ορίζουμε το χρονικό διάστημα που μεσολαβεί από τη στιγμή που θα παρατηρηθεί η βροχόπτωση ή το νερό των χείμαρρων στο έδαφος μέχρι τη στιγμή που θα φτάσει στον υδροφορέα. Η χρονική υστέρηση εξαρτάται από την

απόσταση του σημείου μέτρησης από την γεώτρηση καθώς και από το γεωλογικό υπόβαθρο της περιοχής.

Για τον εντοπισμό της ημέρας όπου η βροχόπτωση ή οι χείμαρροι ασκούν μεγαλύτερη επιρροή στη στάθμη της γεώτρησης χρησιμοποιήθηκε ο συντελεστής συσχέτισης (correlation coefficient) για τις χρονοσειρές της βροχόπτωσης, των χείμαρρων και εκείνη της διαφορά στάθμης. (Trichakis et al., 2009). Η εξίσωση που εκφράζει το συντελεστή συσχέτισης μεταξύ δύο χρονοσειρών A,B δίνεται από την εξίσωση 4.2.

$$\text{Correl}(A, B) = \frac{\sum(a-\bar{a})*(b-\bar{b})}{\sqrt{\sum(a-\bar{a})^2 * \sum(b-\bar{b})^2}} \quad (4.2)$$

Ο συντελεστής συσχέτισης για κάθε χρονοσειρά σε σχέση με τη χρονοσειρά της διαφοράς στάθμης υπολογίστηκε στη Matlab μέσω της εντολής “corr”. Λόγω της θετικής επίδρασης των βροχοπτώσεων και των χείμαρρων στη μεταβολή της στάθμης, καλύτερη τιμή χρονικής υστέρησης θεωρείται εκείνη με το μεγαλύτερο θετικό συντελεστή συσχέτισης.

Στην παρούσα εργασία οι χρονοσειρές διαμορφώθηκαν ανάλογα με την καλύτερη τιμή χρονικής υστέρησης, αλλά και με τις δύο καλύτερες τιμές όσον αφορά τη βροχόπτωση, ενώ για τους χείμαρρους διαμορφώθηκαν ανάλογα με τη βέλτιστη τιμή. Το μήκος των χρονοσειρών εισόδου και εξόδου διαμορφώθηκε (μειώθηκε) έτσι ώστε η χρονική υστέρηση να ανταποκρίνεται στην ανάλογη μέρα.

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης

Οι τιμές του συντελεστή συσχέτισης για διάφορες χρονικές υστερήσεις παρουσιάζονται στους πίνακες 4-4, 4-5:

✓ Βροχόπτωση:

Πίνακας 4-4 Τιμές συντελεστή χρονικής υστέρησης βροχοπτώσεων-διαφοράς υδραυλικού ύψους

Χρονική υστέρηση (d)	Μορόνι	Πόμπια	Βαγιωνία	Άγιος Κύριλλος	Ασήμι	Καπετανιανά	Πραιτώρια
0	0,078	0,141	0,160	0,057	0,172	0,129	<b>0,166</b>
1	0,165	0,145	0,114	<b>0,234</b>	0,125	0,093	0,097
2	0,118	0,067	0,064	0,070	0,080	0,092	0,072
3	0,089	<b>0,186</b>	0,168	0,037	0,159	0,129	0,152
4	0,164	0,052	0,067	<b>0,183</b>	0,062	0,031	0,051
5	0,056	0,045	0,040	0,068	0,098	0,063	0,069
6	0,074	0,174	<b>0,180</b>	0,056	<b>0,177</b>	<b>0,161</b>	0,163
7	<b>0,206</b>	0,105	0,070	0,169	0,116	0,088	0,085
8	0,090	0,064	0,065	0,092	0,070	0,067	0,060
9	0,084	0,157	0,145	0,076	0,148	0,131	0,157
10	0,133	0,110	0,098	0,168	0,099	0,036	0,075
11	0,111	0,144	0,165	0,092	0,164	<b>0,181</b>	0,132
12	0,158	0,116	0,116	0,151	0,111	0,068	0,123
13	0,088	0,101	0,097	0,084	0,144	0,096	0,117
14	0,127	0,097	0,092	0,147	0,133	0,126	0,127
15	0,093	0,121	0,117	0,083	0,098	0,108	0,099
16	0,110	0,127	0,104	0,074	0,108	0,073	0,089
17	0,127	0,043	0,049	0,125	0,051	0,024	0,034
18	0,051	0,065	0,022	0,061	0,067	0,093	0,064
19	0,069	<b>0,211</b>	<b>0,237</b>	0,041	<b>0,197</b>	0,162	<b>0,184</b>
20	<b>0,208</b>	0,086	0,082	0,202	0,102	0,080	0,070
21	0,104	0,083	0,066	0,106	0,064	0,070	0,067
22	0,079	0,138	0,143	0,073	0,159	0,132	0,146
23	0,122	0,109	0,098	0,122	0,172	0,090	0,097
24	0,152	0,159	0,123	0,158	0,108	0,132	0,148
25	0,115	0,073	0,086	0,088	0,169	0,058	0,094
26	0,081	0,111	0,109	0,157	0,074	0,113	0,140
27	0,128	0,115	0,106	0,095	0,115	0,074	0,073
28	0,123	0,078	0,057	0,083	0,085	0,059	0,065
29	0,075	0,058	0,030	0,056	0,069	0,015	0,052
30	0,092	0,132	0,104	0,103	0,079	0,135	0,109

• Χείμαρροι:

Πίνακας 4-5 Τιμές συντελεστή χρονικής υστέρησης χείμαρρων-διαφοράς υδραυλικού ύψους

Χρονική υστέρηση (d)	Ληθαίος	Φαιστός
0	0,254	<b>0,238</b>
1	<b>0,287</b>	0,203
2	0,225	0,153
3	0,223	0,210
4	0,260	0,169

#### 4.5 Matlab και τεχνητά νευρωνικά δίκτυα

Η Matlab (από τις λέξεις Matrix Laboratory) αποτελεί μια υψηλού επιπέδου γλώσσα, τέταρτης γενιάς, καθώς και ένα διαδραστικό περιβάλλον επεξεργασίας πινάκων και συναρτήσεων, ψηφιακού υπολογισμού και γραφικής παρουσίασης. Με τη χρήση της γίνεται δυνατή η ανάλυση δεδομένων, η ανάπτυξη αλγόριθμων όπως επίσης και η δημιουργία μοντέλων και εφαρμογών (Mathworks).

Η Matlab λειτουργεί ως διερμηνέας εντολών (command interpreter) και μέσω του παράθυρου εντολών (command window) δίνει εντολές ποικίλου τύπου, όπως:

- Ορισμούς μεταβλητών και πράξεις.
- Κλήση ενσωματωμένων συναρτήσεων της Matlab και των εγκατεστημένων εργαλειοθηκών της (toolboxes).
- Κλήση συναρτήσεων (functions), ή αρχείων εντολών της Matlab (scripts) που κατασκευάζονται από του χρήστες σε μορφή M-file (Αρναουτάκης, 2002).

Οι εργαλειοθήκες (toolboxes) της Matlab περιέχουν μια σειρά από συναρτήσεις σχετικά με ένα συγκεκριμένο αντικείμενο. Για το σχεδιασμό, την εκπαίδευση, τη γραφική απεικόνιση και την προσομοίωση νευρωνικών δικτύων υπάρχει η ανάλογη εργαλειοθήκη (Neural Network Toolbox). Η εργαλειοθήκη νευρωνικών δικτύων υποστηρίζει μια πληθώρα αρχιτεκτονικών με έναν απεριόριστο αριθμό νευρώνων και δυνατότητες διασύνδεσης (Λυμπεροπούλου, 2006). Η εν λόγω εργαλειοθήκη υποστηρίζει την επιβλεπόμενη μάθηση (supervised learning) δικτύων εμπρόσθιας τροφοδότησης (feedforward), ακτινικής συνάρτησης βάσης (radial basis) όπως και δυναμικών δικτύων (dynamic networks). Επιπλέον, υποστηρίζει και τη μη επιβλεπόμενη μάθηση (unsupervised learning) με αυτό-ρυθμιζόμενους χάρτες (self-organizing maps) και ανταγωνιστικά επίπεδα (competitive layers) (Mathworks).

Τα τεχνητά νευρωνικά δίκτυα έχουν την ικανότητα προσαρμογής συναρτήσεων. Αυτό μπορεί να πραγματοποιηθεί με το εργαλείο προσαρμογής νευρωνικών δικτύων της Matlab, nftool (neural network fitting tool) (Mathworks). Το εργαλείο αυτό δίνει τη δυνατότητα της παραγωγής ενός νευρωνικού δικτύου ενός κρυφού επιπέδου με σιγμοειδή συνάρτηση ενεργοποίησης στο κρυφό επίπεδο και γραμμική στο επίπεδο εξόδου. Στο nftool μπορούν να εισαχθεί ο πίνακας με τα δεδομένα εισόδου και εκείνος με τις προσδοκώμενες εξόδους. Στη συνέχεια, ορίζονται τα ποσοστά διαχωρισμού των δεδομένων εισόδου στα σετ εκπαίδευσης, επαλήθευσης και ελέγχου, ενώ ακολούθως ορίζεται ο αριθμός κρυφών κόμβων. Μετά την εισαγωγή όλων των δεδομένων, λαμβάνει χώρα η διαδικασία της εκπαίδευσης και υπολογίζονται τα μέσα τετραγωνικά σφάλματα για κάθε σετ. Το nftool δίνει τη



δυνατότητα επανεκπαίδευσης του δικτύου, σε περίπτωση που τα αποτελέσματα δεν είναι ικανοποιητικά, είτε ως έχει, είτε αλλάζοντας το μέγεθος του δικτύου. Τέλος, μπορεί να παραχθεί ένα M-File με τις συναρτήσεις που χρησιμοποιήθηκαν, έτσι ώστε ο χρήστης να έχει μεγαλύτερη ευελιξία στη διαμόρφωση της δομής του δικτύου. (ΠΑΡΑΡΤΗΜΑ IV)

Καταρχάς, για να ξεκινήσει η εκπαίδευση του δικτύου απαραίτητη είναι η δημιουργία της οντότητας του δικτύου (network object), αυτό συμβαίνει με την κλήση μιας εκ των τυποποιημένων συναρτήσεων της Matlab. (Σκιτζί, 2010) Στη συγκεκριμένη περίπτωση χρησιμοποιείται η συνάρτηση *"newfit"*, μέσω της οποίας δημιουργείται ένα Νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης (feedforward) που εκπαιδεύει με βάση τον αλγόριθμο οπισθοδιάδοσης σφάλματος (backpropagation). Στη συνέχεια, γίνεται χρήση των συναρτήσεων επεξεργασίας (processing function) για την ομαλοποίηση των δεδομένων εισόδου και εξόδου. Χρησιμοποιήθηκε η συνάρτηση *"tarmminmax"* για την κανονικοποίηση εισόδων/στόχων ώστε να είναι μέσα στο εύρος [-1,1] καθώς και η συνάρτηση *"remove constant rows"* για τη αφαίρεση εισόδων/στόχων που παραμένουν σταθεροί. Ο διαχωρισμός των δεδομένων εισόδου στα υποσύνολα εκπαίδευσης, επαλήθευσης και ελέγχου γίνεται μέσω της συνάρτησης *"dividerand"*, όπου πραγματοποιείται τυχαίος διαχωρισμός (Neural Network Toolbox-User's guide, R2013b).

Η διαδικασία εκπαίδευσης του δικτύου περιλαμβάνει την προσαρμογή της τιμής συναπτικών βαρών και πολώσεων για τη βελτιστοποίηση της απόδοσης του δικτύου όπως ορίζεται από τη συνάρτηση σφάλματος (performance function), *"net.performFcn"*. Η προεπιλεγμένη συνάρτηση σφάλματος για δίκτυα εμπρόσθιας τροφοδότησης είναι το μέσο τετραγωνικό σφάλμα (mse) μεταξύ των εξόδων που προκύπτουν από το δίκτυο και των στόχων που έχουν τεθεί. Η σχέση του mse εκφράζεται από την εξίσωση 4.3 (Neural Network Toolbox-User's guide, R2013b).

$$mse = \frac{1}{n} \sum_{i=1}^n (e_i)^2 = \frac{1}{n} \sum_{i=1}^n (d_i - y_i)^2, \quad (4.3)$$

Όπου,

n: ο συνολικός αριθμός των εκπαιδευμένων μεταβλητών

e: το συνολικό σφάλμα

y: οι έξοδοι του δικτύου

d: οι στόχοι του δικτύου

Η εργαλειοθήκη των νευρωνικών δικτύων της Matlab υποστηρίζει μια πληθώρα αλγορίθμων που μπορούν να επιλεγθούν για την εκπαίδευση του δικτύου. Οι

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης

αλγόριθμοι εκπαίδευσης είναι μαθηματικές διαδικασίες μέσω των οποίων επιτυγχάνεται η αυτόματη προσαρμογή των βαρών και των πολώσεων (Mathworks).

Οι υποστηριζόμενοι αυτοί αλγόριθμοι παρουσιάζονται στον παρακάτω πίνακα:

Πίνακας 4-6 Αλγόριθμοι εκπαίδευσης νευρωνικού δικτύου

<b>trainlm</b>	Levenberg-Marquardt ανάδραση
<b>trainb</b>	Εκπαίδευση σε δεσμίδες δεδομένων με κανόνες εκμάθησης των συναπτικών βαρών και πολώσεων (Batch training with weights and bias learning rule)
<b>trainbfg</b>	BFGS quasi Newton συνάρτηση οπισθοδιάδοσης σφάλματος
<b>trainbr</b>	Μπαεσιανή κανονικοποίηση
<b>trainbuwb</b>	Εκπαίδευση σε δεσμίδες δεδομένων με μη επιβλεπόμενη μάθηση συναπτικών βαρών/πολώσεων (Batch unsupervised weights/bias training)
<b>trainc</b>	Κυκλικής διαδοχής αυξητική ενημέρωση (Cyclical order incremental update)
<b>traincgb</b>	Συζυγής κλίση με επανεκκινήσεις Powell-Beale
<b>traincgf</b>	Συζυγής κλίση με ενημέρωση Fletcher-Powell
<b>traincgp</b>	Συζυγής κλίση με ενημέρωση Polak-Ribiere
<b>traingd</b>	Συζυγής κλίση
<b>traingda</b>	Συζυγής κλίση με προσαρμόσιμο ρυθμό εκμάθησης και ανάδραση
<b>traingdm</b>	Συζυγής κλίση με ορμή
<b>traingdx</b>	Συζυγής κλίση με ορμή και προσαρμόσιμη γραμμική ανάδραση
<b>trainoss</b>	Αντιστρόφου συνημίτονου με μοναδιαίο βήμα ανάδραση
<b>trainr</b>	Τυχαίας σειράς αυξητικής ενημέρωσης
<b>trainrp</b>	Ελαστική ανάδραση (Resilient backpropagation-Rprop)
<b>trains</b>	Διαδοχικής σειράς πρόσθετης εκπαίδευση/μάθηση (Sequential order incremental training w/learning)
<b>trainscg</b>	Κλίση κλιμακωτής σύζευξης (Scale conjugate gradient)

(Σκιτζί, 2010; Neural Network Toolbox-User's guide, R2013b; Ρεφενίδης, 2011)

Δεν υπάρχει προκαθορισμένα καλύτερος αλγόριθμος εκπαίδευσης, η καταλληλότητα του αλγορίθμου εξαρτάται από το είδος του προβλήματος που μελετάμε καθώς και από το μέγεθος του δικτύου. Στην παρούσα διπλωματική αρχικά χρησιμοποιήθηκε ο προκαθορισμένος από τη Matlab αλγόριθμος Levenberg-Marquardt (`trainlm`). Στη συνέχεια, για τη δομή του δικτύου που παρουσίασε τα μικρότερα σφάλματα κατά την `trainlm` έγινε εκπαίδευση για όλες τους διαθέσιμους αλγόριθμους, από τους οποίους επιλέχθηκαν οι τρεις που έδιναν τα καλύτερα αποτελέσματα όσον αφορά τα σφάλματα εκπαίδευσης, επαλήθευσης και ελέγχου καθώς και το μέσο όρο τους. Οι επιλεγόμενοι αλγόριθμοι είναι: Μπαεσιανής κανονικοποίησης (`trainbr`), συζυγούς κλίσης με ορμή και προσαρμόσιμη γραμμική ανάδραση (`traingdx`) και ελαστικής ανάδρασης (`trainrp`). Οι επιλεγμένοι αλγόριθμοι ανήκουν όλου στους αλγορίθμους οπισθοδιάδοσης σφάλματος και διαφέρουν μεταξύ τους κυρίως στον τρόπο ενημέρωσης των βαρών.

Πιο αναλυτικά οι αλγόριθμοι που εξετάζονται περιγράφονται παρακάτω:

- Μέθοδος Levenberg-Marquardt (`trainlm`): Ανήκει στην κατηγορία αλγορίθμων συζυγών κλίσεων (*conjugate gradient algorithms*), μια κατηγορία αλγορίθμων όπου σε κάθε βήμα εκτελείται τοπική αναζήτηση για την εύρεση της βέλτιστης τιμής αλλά και της βέλτιστης κατεύθυνσης μεταβολής των βαρών. Ο τρόπος λειτουργίας της είναι με το υπολογισμό πρώτων παραγόντων και την αριθμητική προσέγγιση δεύτερων παραγόντων (Ρεφενίδης, 2011). Πιο αναλυτικά, αποτελεί μια παραλλαγή του κλασσικού αλγορίθμου κατά Newton, όπου σκοπός είναι να βρεθεί η βέλτιστη λύση ενός προβλήματος ελαχιστοποίησης. Γίνεται προσεγγιστική χρήση του Εσσιανού πίνακα (*Hessian matrix*) όπως φαίνεται στην εξίσωση 4.4 της μεθόδου τύπου-Newton ενημέρωσης βάρους.

$$\mathbf{w}_{k+1} = \mathbf{w}_k - [\mathbf{J}^T \mathbf{J} + \mu \mathbf{I}]^{-1} \mathbf{J}^T \mathbf{e} \quad (4.4)$$

Όπου:

$\mathbf{w}$ : το βάρος του νευρωνικού δικτύου

$\mathbf{I}$ : ο μοναδιαίος πίνακας

$\mathbf{J}$ : ο Ιακωβιανός πίνακας, με στοιχεία τις πρώτες παραγώγους των σφαλμάτων του κάθε νευρώνα ως προς τα βάρη και τα κατώφλια του ίδιου επιπέδου

$\mu$ : η βαθμίδα ελέγχου της διαδικασίας εκμάθησης

$\mathbf{e}$ : διάνυσμα σφαλμάτων δικτύου για τα δεδομένα εκπαίδευσης

Όταν η βαθμίδα  $\mu$  ισούται με μηδέν, η εναπομένουσα εξίσωση είναι η μέθοδος Newton με χρήση του προσεγγιστικού Εσσιανού πίνακα. Σκοπός της μεθόδου αυτής είναι να στραφεί όσο το δυνατόν γρηγορότερα στη μέθοδο Newton καθώς είναι γρηγορότερη και πιο ακριβής στην εύρεση ενός ελαχίστου σφάλματος. Όσο η τιμή της βαθμίδας  $\mu$  είναι μεγάλη δημιουργείται κλίση καθόδου με βήμα μικρού μεγέθους (Samani et al., 2007). Το μειονέκτημα αυτής της μεθόδου είναι ότι καθώς έχει μεγάλες απαιτήσεις υπολογισμού και μνήμης μπορεί να χρησιμοποιηθεί μόνο σε μικρού μεγέθους δίκτυα (Daliakopoulos et al., 2004).

- Μέθοδος Μπαεσιανής (Bayesian) κανονικοποίησης (trainbr): Αποτελεί μια μέθοδο προσέγγισης της αυτόματης διαδικασίας καθορισμού παραμέτρων κανονικοποίησης κατά το πρότυπο πιθανότητας Bayesian. Κατά τη μέθοδο αυτή συναπτικά βάρη και πολώσεις του δικτύου ορίζονται σαν τυχαίες μεταβλητές με καθορισμένες κατανομές ενώ οι παράμετροι κανονικοποίησης του δικτύου σχετίζονται με τις διακυμάνσεις αυτών των πιθανοτήτων. Οι εν λόγω παράμετροι κανονικοποίησης εκτιμώνται μέσα από στατιστικές τεχνικές. Κατά την κατανομή Bayesian ελαχιστοποιείται ένας γραμμικός συνδυασμός των τετραγωνικών σφαλμάτων και των συνοπτικών βαρών, όπου κατά την εκπαίδευση η ελαχιστοποίηση του γραμμικού αυτού συνδυασμού πραγματοποιείται με τέτοιο τρόπο, ώστε μετά το πέρας της εκπαίδευσης το δίκτυο να εξάγει κανονικοποιημένα αποτελέσματα στη φάση της γενίκευσης. Η κανονικοποίηση αυτή γίνεται μέσω του αλγορίθμου Levenberg-Marquardt, καθώς ο αλγόριθμός Μπαεσιανής κανονικοποίησης αποτελεί μια παραλλαγή του. Ένα βασικό πλεονέκτημα του αλγορίθμου trainbr, είναι ότι μπορεί να παρέχει ένα μέτρο για το πόσες παράμετροι (συναπτικά βάρη και πολώσεις) μπορούν να χρησιμοποιηθούν με αποτελεσματικότητα από το δίκτυο, πράγμα που σημαίνει ότι ο αριθμός τους μπορεί να παραμείνει σταθερός ανεξάρτητα από το πόσο μπορεί να αυξηθεί το μέγεθος του δικτύου (Πάνου, 2003). Η συνάρτηση σφάλματος τροποποιείται αυτόματα κάθε φορά με σκοπό της επίτευξης της όσο το δυνατόν καλύτερης γενίκευσης. Η τυπική συνάρτηση σφάλματος τροποποιείται στην περίπτωση αυτή με την προσθήκη ενός όρου που αποτελείται από το μέσο άθροισμα των τετραγώνων των συναπτικών βαρών και των πολώσεων του δικτύου, όπως δίδεται από τη σχέση 4.5 (Parasuraman and Elshorbagy, 2007).

$$mse = \gamma \frac{1}{n} \sum_{i=1}^n (e_i)^2 + (1 - \gamma) \sum_{i=1}^n \mathbf{w}_k^2 = \gamma \frac{1}{n} \sum_{i=1}^n (\mathbf{d}_i - \mathbf{y}_i)^2 + (1 - \gamma) \sum_{i=1}^n \mathbf{w}_k^2 \quad (4.5)$$

όπου,

n: ο συνολικός αριθμός των συναπτικών βαρών και πολώσεων

γ: το ποσοστό απόδοσης (performance ratio)

- Μέθοδος συζυγούς κλίσης με ορμή και προσαρμόσιμη γραμμική ανάδραση (traingdx): Αποτελεί ένα συνδυασμό του μεταβλητού ρυθμού μάθησης και της ορμής. Όπου με τον όρο ορμή (momentum) εννοούμε την επίδραση που έχει η προηγούμενη μεταβολή βάρους στην επόμενη. Αυτός ο αλγόριθμος χρησιμοποιείται για ομαδική εκπαίδευση (batch training) και βοηθά στην αποφυγή μικρών τοπικών ελαχίστων. Όσον αφορά τον μεταβλητό ρυθμό μάθησης, είναι ένα χρήσιμο εργαλείο αφού προσαρμόζεται ανάλογα, χρησιμοποιώντας κάποιο κριτήριο, ώστε να αποφεύγεται η καθυστέρηση στη σύγκλιση που πραγματοποιείται από ένα μικρό ρυθμό μάθησης αλλά και η αδυναμία σταθεροποίησης στη λύση που προκαλείται από ένα μεγάλο ρυθμό μάθησης. Η χρησιμότητα του μεταβλητού ρυθμού μάθησης βρίσκεται στο γεγονός ότι στην περίπτωση που μετά από μια εποχή εκπαίδευσης το συνολικό σφάλμα έχει μεγαλύτερη τιμή από το σφάλμα της προηγούμενης εποχής κατά ένα ποσοστό, ο ρυθμός μάθησης μειώνεται, ενώ στην αντίθετη περίπτωση έχουμε αύξηση του ρυθμού μάθησης (Ρεφενίδης, 2011). Η μέθοδος αυτή είναι ικανή να εκπαιδεύσει οποιοδήποτε δίκτυο όσο η σχέση που προκύπτει μεταξύ των συναπτικών βαρών, της εισόδου του δικτύου και των συναρτήσεων είναι παραγωγίσιμη. Η ανάδραση συνίσταται στον υπολογισμό της παραγώγου της συνάρτησης σφάλματος ως προς τα συναπτικά βάρη και τις πολώσεις (Πάνου,2003).
- Μέθοδος ελαστικής ανάδρασης-Resilient backpropagation-Rprop(trainrp): Αποτελεί μια παραλλαγή του μεταβλητού ρυθμού μάθησης με τη διαφορά ότι δε λαμβάνει υπόψη την παράγωγο της συνάρτησης αλλά μόνο το πρόσημο του σφάλματος (Ρεφενίδης, 2011). Η μεταβολή του βάρους καθορίζεται από μια διαφορετική τιμή ενημέρωσης βάρους (update weight value). Όταν η παράγωγος της συνάρτησης σφάλματος συναρτήσει του βάρους διατηρεί το ίδιο πρόσημο για δύο διαδοχικές επαναλήψεις η τιμή ενημέρωσης βάρους για κάθε συναπτικό βάρος και πόλωση αυξάνεται κατά ένα παράγοντα. Στην αντίθετη περίπτωση όπου η παράγωγος της συνάρτησης σφάλματος συναρτήσει του βάρους αλλάζει πρόσημο από την προηγούμενη επανάληψη η τιμή ενημέρωσης βάρους μειώνεται κατά ένα παράγοντα. Στην περίπτωση που η παράγωγος είναι μηδενική, η τιμή αυτή παραμένει ίδια. Όταν υπάρχει ταλάντωση των βαρών η μεταβολή τους

μειώνεται ενώ αν τα βάρη συνεχίζουν να αλλάζουν προς την ίδια κατεύθυνση για πληθώρα επαναλήψεων το μέγεθος αλλαγής των βαρών αυξάνεται (Παντελή, 2012).

#### 4.6 Εκπαίδευση δικτύου

Η βέλτιστη εκπαίδευση του δικτύου επιλέχθηκε με τη μέθοδο δοκιμής και σφάλματος (trial and error) αρχικά για διαφορετικές δομές και στη συνέχεια και για διαφορετικούς αλγόριθμους εκπαίδευσης. Η εργασία αυτή ως σκοπό είχε την εύρεση του βέλτιστου σεναρίου, δηλαδή αυτού για το οποίο παρουσιάζονται μικρότερα σφάλματα. Ως εκ τούτου, αρχικά το δίκτυο εκπαιδεύτηκε για τον προκαθορισμένο από τη Matlab αλγόριθμο `trainlm` με χρήση χείμαρρων αλλά και χωρίς την ύπαρξη αυτών για τη μία και τις δύο τιμές χρονική υστέρησης της βροχόπτωσης και στις δύο περιπτώσεις. Ύστερα έγινε εκπαίδευση του δικτύου για ένα κρυφό επίπεδο για 5,10,15,20 κρυφούς κόμβους ενώ ακολούθησε εκπαίδευση για δύο κρυφά επίπεδα για αριθμό κόμβων  $[i,j]$  όπου  $i$  και  $j$  έπαιρναν τις τιμές 5,10,15,20 σε όλου τους συνδυασμούς τους. Για το συνδυασμό που έδινε τις μικρότερες τιμές σφάλματος, τόσο όσον αφορά το μέσο σφάλμα όσο και τα σφάλματα εκπαίδευσης και έλεγχου, εφαρμόστηκε η μέθοδος Monte Carlo για χίλιες επαναλήψεις, κατά την οποία εκτυλίσσεται η ίδια διαδικασία για την εκπαίδευση του δικτύου αλλά με διαφορετική επιλογή των δεδομένων εκπαίδευσης, επαλήθευσης και δοκιμής, αλλά και των τιμών αρχικοποίησης των βαρών (διαφορετικό τυχαίο seed). Με αυτόν τον τρόπο γίνεται πιο σφαιρική παρακολούθηση της κατανομής των σφαλμάτων, αλλά και για τον προσδιορισμό της ασάφειας που προκύπτει από τις τυχαίες αυτές αρχικές επιλογές. Στη συνέχεια, η ίδια διαδικασία πραγματοποιήθηκε για τρεις ακόμα αλγόριθμους εκπαίδευσης (`trainbr`, `traingdx`, `trainrp`) άλλα χωρίς χρήση χείμαρρων καθώς εξήγαγαν χειρότερα αποτελέσματα. Για τον `trainbr` που έδινε τα καλύτερα αποτελέσματα εκ των τριών βρέθηκε το καλύτερο σενάριο ως προς την αρχιτεκτονική του και ως προς αυτό εφαρμόστηκε η μέθοδος Monte Carlo για χίλιες επαναλήψεις. Αξίζει να σημειωθεί το γεγονός ότι σε όλες τις περιπτώσεις ο αρχικός διαχωρισμός των δεδομένων στα υποσύνολα εκπαίδευσης, επαλήθευσης και ελέγχου ήταν ο ίδιος σε όλες τις περιπτώσεις (ίδιο seed), επομένως τα αποτελέσματα είναι συγκρίσιμα μεταξύ τους.


## Κεφάλαιο 5 : Αποτελέσματα

### 5.1 Βελτίωση σφαλμάτων

Όπως αναφέρθηκε στο προηγούμενο κεφάλαιο, για να βρεθεί η καλύτερη αρχιτεκτονική, δηλαδή εκείνη για την οποία το δίκτυο παρουσιάζει τα μικρότερα σφάλματα (εκπαίδευσης, επαλήθευσης και ελέγχου) το δίκτυο εκπαιδεύτηκε για διαφορετικούς συνδυασμούς.


Στα διαγράμματα 5-1 έως και 5-6 παρουσιάζονται τα σφάλματα όπως τα εξήγαγε το δίκτυο με τη χρήση ή μη των χείμαρρων για μια και δύο τιμές χρονικής υστέρησης και με αριθμό κόμβων στα κρυφά επίπεδα,  $[i,j]$ ,  $i=5,10,15,20$  και  $j=5,10,15,20$ . Για να είναι συγκρίσιμα τα αποτελέσματα έγινε αντιπαράθεση με το μέσο σφάλμα, το σφάλμα εκπαίδευσης και το σφάλμα ελέγχου για ένα και δύο κρυφά επίπεδα. Τα αποτελέσματα αφορούν το αλγόριθμο εκπαίδευσης `trainlm`.

- Για ένα κρυφό επίπεδο:




Διάγραμμα 5-1 Μέση τιμή μέσου τετραγωνικού σφάλματος για 1 κρυφό επίπεδο (`trainlm`)

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγορίθμων εκπαίδευσης



Διάγραμμα 5-2 Μέσο τετραγωνικό σφάλμα εκπαίδευσης για 1 κρυφό επίπεδο (trainIm)




Διάγραμμα 5-3 Μέσο τετραγωνικό σφάλμα ελέγχου για 1 κρυφό επίπεδο (trainIm)




Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης


➤ Για δύο κρυφά επίπεδα



Διάγραμμα 5-4 Μέση τιμή μέσου τετραγωνικού σφάλματος για 2 κρυφά επίπεδα (trainlm)



Διάγραμμα 5-5 Μέσο τετραγωνικό σφάλμα εκπαίδευσης για 2 κρυφά επίπεδα(trainlm)



Διάγραμμα 5-6 Μέσο τετραγωνικό σφάλμα ελέγχου για 2 κρυφά επίπεδα (trainlm)

Όπως γίνεται αντιληπτό από τα διαγράμματα 5-1, 5-2, 5-3, η πορεία των σφαλμάτων είναι πολύ πιο ομαλή όταν δε χρησιμοποιούνται σα δεδομένα εισόδου οι χείμαρροι, πράγμα που μπορεί να εξηγηθεί από την ύπαρξη πολλών μηδενικών στις χρονοσειρές των χείμαρρων αλλά και στο μικρότερο μέγεθος του δικτύου, ενώ πιο ομαλή πορεία ακολουθείται για τη χρήση και των δύο καλύτερων τιμών χρονικής υστέρησης.

Όσον αφορά το βέλτιστο συνδυασμό προκύπτει από την αρχιτεκτονική που αποτελείται από 2 κρυφά επίπεδα χωρίς την ύπαρξη χείμαρρων και με 10 και 15 κόμβους στο πρώτο και δεύτερο κουφό επίπεδο αντίστοιχα. Στον πίνακα 5-1 παρουσιάζονται τα αποτελέσματα των σφαλμάτων για το βέλτιστο σενάριο.

Πίνακας 5-1 Βέλτιστο σφάλμα (trainlm)

	mse (m)
Training error	$2,72 \cdot 10^{-2}$
Validation error	$2,29 \cdot 10^{-2}$
Test error	$1,74 \cdot 10^{-2}$
Average error	$2,25 \cdot 10^{-2}$

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγορίθμων εκπαίδευσης

Στα πλαίσια προσπάθειας ελαχιστοποίησης των σφαλμάτων έγινε δοκιμή εκπαίδευσης του δικτύου για τρεις ακόμη αλγόριθμους, τον trainbr, τον traingdx και τον trainrp. Η εκπαίδευση έγινε για μία και δύο τιμές χρονικής υστέρησης χωρίς χείμαρρους για ένα και δύο κρυφά επίπεδα. Τα βέλτιστα αποτελέσματα για το σύνολο των αλγορίθμων που χρησιμοποιήθηκε δίνεται στον πίνακα 5-2:

Πίνακας 5-2 Ελάχιστα σφάλματα διαφορετικών αλγορίθμων εκπαίδευσης

	trainlm	trainbr	traingdx	trainrp
Training error	$2,72 \cdot 10^{-2}$	$3,15 \cdot 10^{-2}$	$3,29 \cdot 10^{-2}$	$3,52 \cdot 10^{-2}$
Validation error	$2,29 \cdot 10^{-2}$	$1,81 \cdot 10^{-2}$	$1,98 \cdot 10^{-2}$	$1,02 \cdot 10^{-2}$
Test error	$1,74 \cdot 10^{-2}$	$1,5 \cdot 10^{-2}$	$1,87 \cdot 10^{-2}$	$2,44 \cdot 10^{-2}$
Average error	$2,25 \cdot 10^{-2}$	$2,15 \cdot 10^{-2}$	$2,38 \cdot 10^{-2}$	$2,33 \cdot 10^{-2}$

Σύμφωνα με τον Πίνακα 5-2, γίνεται εμφανές ότι τα βέλτιστα σενάρια και των τεσσάρων αλγορίθμων δεν παρουσιάζουν υπερβολικά μεγάλες διαφορές στα σφάλματα. Ωστόσο, συνολικά καλύτερα αποτελέσματα από την trainlm είχε η trainbr που όμως στο βέλτιστο σενάριο έδωσε μεγαλύτερη τιμή σφάλματος εκπαίδευσης αλλά εμφανώς μικρότερες τιμές σφαλμάτων επαλήθευσης και ελέγχου και επομένως και καλύτερη μέση τιμή σφάλματος. Για τους παραπάνω λόγους η σύγκριση αποτελεσμάτων πραγματοποιήθηκε μεταξύ των αλγορίθμων trainlm και trainbr.

Η βέλτιστη αρχιτεκτονική για εκπαίδευση με τον αλγόριθμο Μπαεσινής κατανομής (trainbr) αποτελούνταν από 20 κόμβους στο πρώτο κρυφό επίπεδο και 10 στο δεύτερο, ενώ χρησιμοποιήθηκε η βέλτιστη τιμή χρονικής υστέρησης. Τα αποτελέσματα δίνονται στον πίνακα 5-3:

Πίνακας 5-3 Βέλτιστο σφάλμα (trainbr)

	mse
Train error	$3,15 \cdot 10^{-2}$
Validation error	$1,81 \cdot 10^{-2}$
Test error	$1,5 \cdot 10^{-2}$
Average error	$2,15 \cdot 10^{-2}$

## 5.2 Μέθοδος Monte Carlo

Για τη βέλτιστη αρχιτεκτονική, τόσο για το αλγόριθμο Levenberg-Marquardt όσο και για τον αλγόριθμο Μπαεσιανής κανονικοποίησης, οι οποίοι είχαν τα καλύτερα αποτελέσματα, πραγματοποιήθηκαν 1000 επαναλήψεις έτσι ώστε να μπορέσει να πραγματοποιηθεί μια κατανομή των σφαλμάτων αλλά και να εξεταστεί κατά πόσο αυτή ακολουθεί το πρότυπο της κανονικής κατανομής. Αξίζει να σημειωθεί ότι ο χρόνος που χρειάστηκε για την εκπαίδευση δίκτυο για 1000 επαναλήψεις με τον αλγόριθμο `trainbr` ήταν περίπου τρεις φορές περισσότερος από τον χρόνο που χρειάστηκε σύμφωνα με τον αλγόριθμο `trainlm`.

Μετά το πέρας των χιλίων επαναλήψεων έγινε στατιστική επεξεργασία των σφαλμάτων που παρουσιάστηκαν και βρέθηκε η ελάχιστη, η μέγιστη και η μέση τιμή των σφαλμάτων που παρουσιάστηκαν καθώς και η τυπική απόκλιση, η διασπορά, η ασυμμετρία και η κύρτωση τους (πίνακες 5-4 και 5-5).

- Για τον αλγόριθμο εκπαίδευσης `trainlm`

Πίνακας 5-4 Στατιστική ανάλυση σφαλμάτων για 1000 επαναλήψεις (`trainlm`)

	training error	validation error	test error
Ελάχιστο	0,015	0,011	0,013
Μέγιστο	0,063	0,078	0,163
Μέση τιμή	0,027	0,035	0,037
Τυπική απόκλιση	0,004	0,09	0,012
Διασπορά	$1,90 \cdot 10^{-5}$	$8,87 \cdot 10^{-5}$	$1,52 \cdot 10^{-4}$
Ασυμμετρία	1,386	0,419	2,556
Κύρτωση	10,084	3,544	21,492


- Για τον αλγόριθμο εκπαίδευσης `trainbr`:

Πίνακας 5-5 Στατιστική ανάλυση σφαλμάτων για 1000 επαναλήψεις (`trainbr`)

	training error	validation error	test error
Ελάχιστο	0,024	0,006	0,011
Μέγιστο	0,039	0,062	0,063
Μέση τιμή	0,029	0,030	0,030
Τυπική απόκλιση	0,002	0,009	0,008
Διασπορά	$5,21 \cdot 10^{-6}$	$7,21 \cdot 10^{-5}$	$7,05 \cdot 10^{-5}$
Ασυμμετρία	0,872	0,315	0,377
Κύρτωση	4,065	3,209	3,147

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης

Στη συνέχεια, στο διάγραμμα 5-7 δίνεται το εύρος των τιμών που παρουσίασαν τα σφάλματα για τους δύο αλγόριθμους εκπαίδευσης.




Διάγραμμα 5-7 Κατανομή σφαλμάτων για 1000 επαναλήψεις

Είναι εμφανές σύμφωνα με το διάγραμμα 5-7, ότι οι διακυμάνσεις των σφαλμάτων είναι αρκετά μεγαλύτερες στο υποσύνολο ελέγχου όσον αφορά κυρίως τον αλγόριθμο trainlm. Αυτό, πιθανώς να οφείλεται στο γεγονός ότι αυτό το υποσύνολο δε χρησιμοποιείται κατά την εκπαίδευση του δικτύου. Οι τιμές των σφαλμάτων του αλγόριθμου trainbr είναι εμφανές πως κυμαίνονται σε μικρότερο εύρος από εκείνες των τιμών για τον αλγόριθμο trainlm ιδίως όσον αφορά τα σφάλματα εκπαίδευσης όπου τιμές κυμαίνονται γύρω από τη μέση τιμή, γεγονός που μπορεί να γίνει εμφανές από τον πίνακα όπου η μέση τιμή σφάλματος είναι 0,029 η ελάχιστη 0,024 και η μέγιστη 0,039.

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης


Για να ελέγξουμε πιο αποδοτικά το κατά πόσο οι τιμές των σφαλμάτων κατανέμονται γύρω από μια μέση τιμή δημιουργήθηκαν τα ιστογράμματα των σφαλμάτων (error histograms):

- Για τον αλγόριθμο εκπαίδευσης trainlm




Διάγραμμα 5-8 Ιστόγραμμα σφαλμάτων εκπαίδευσης για 1000 επαναλήψεις (trainlm)

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης




Διάγραμμα 5-9 Ιστόγραμμα σφαλμάτων επαλήθευσης για 1000 επαναλήψεις (trainIm)



Διάγραμμα 5-10 Ιστόγραμμα σφαλμάτων ελέγχου για 1000 επαναλήψεις (trainIm)

Μέσω των ιστογραμμάτων εξετάστηκε κατά πόσο τα σφάλματα κατανέμονταν με τέτοιο τρόπο ώστε να έχουμε κανονική κατανομή. Κάτι τέτοιο δεν επετεύχθη για κανένα υποσύνολο, ωστόσο είναι εμφανές ότι πιο κοντά στην κανονική κατανομή βρίσκονται τα σφάλματα του υποσυνόλου επαλήθευσης.


- Για τον αλγόριθμο εκπαίδευσης trainbr:




Διάγραμμα 5-11 Ιστόγραμμα σφαλμάτων εκπαίδευσης για 1000 επαναλήψεις (trainbr)



Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης



Διάγραμμα 5-12 Ιστόγραμμα σφαλμάτων επαλήθευσης για 1000 επαναλήψεις (trainbr)



Διάγραμμα 5-13 Ιστόγραμμα σφαλμάτων ελέγχου για 1000 επαναλήψεις (trainbr)

Η επίτευξη της κανονικής κατανομής δεν πραγματοποιήθηκε ούτε στην περίπτωση του αλγορίθμου *trainbr*. Συγκρίνοντας όμως τους δύο αλγορίθμους γίνεται αντιληπτό ότι η προσέγγιση κανονικής κατανομής γίνεται πολύ καλύτερα από τον αλγόριθμο Μπαεσιανής κανονικοποίησης. Ειδικότερα στην περίπτωση του σφάλματος ελέγχου το ιστόγραμμα σχεδόν προσεγγίζει την κανονική καμπύλη.

Εφόσον η κανονική κατανομή δεν επετεύχθη, για τον υπολογισμό των διαστημάτων εμπιστοσύνης της τάξεως του 95% βρέθηκαν αρχικά τα όρια εμπιστοσύνης στην 26<sup>η</sup> και στην 975<sup>η</sup> επανάληψη και δίνονται στον πίνακα 5-6:

Πίνακας 5-6 όρια εμπιστοσύνης για διάστημα εμπιστοσύνης 95%


	trainlm			trainbr		
Όρια Εμπιστοσύνης	εκπαίδευσης	επαλήθευσης	ελέγχου	εκπαίδευσης	επαλήθευσης	ελέγχου
Άνω όριο	0,02	0,0185	0,0189	0,0256	0,0145	0,0149
Κάτω όριο	0,0357	0,0545	0,0638	0,0347	0,047	0,0488

### 5.3 Προσομοίωση διαφοράς στάθμης


Για την αρχιτεκτονική που παρουσιάστηκε το μικρότερο σφάλμα για τους αλγορίθμους εκπαίδευσης Levenberg-Marquardt και Μπαεσιανής κανονικοποίησης το νευρωνικό δίκτυο πραγματοποίησε την προσομοίωση της διαφοράς στάθμης. Στα διαγράμματα που ακολουθούν πραγματοποιείται σύγκριση της πραγματικής τιμής της διαφοράς στάθμης με την προσομοιωμένη.

Σύμφωνα με τον αλγόριθμο εκπαίδευσης Levenberg-Marquardt προέκυψαν τα διαγράμματα 5-14, 5-15 όπως αναλύονται παρακάτω.

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγορίθμων εκπαίδευσης



Διάγραμμα 5-14 Προσομοιωμένη διαφορά στάθμης συναρτήσει πραγματικής διαφοράς στάθμης (trainlm)




Διάγραμμα 5-15 Προσομοιωμένη και πραγματική διαφορά στάθμης ως προς το χρόνο (trainlm)

Σύμφωνα με το διάγραμμα προσομοιωμένων προς πραγματικών τιμών διαφορών στάθμης, 5-14, το νευρωνικό δίκτυο αδυνατεί να προσομοιώσει τις πραγματικές τιμές των διαφορών στάθμης με ακρίβεια. Το γεγονός αυτό πιθανόν να οφείλεται στο γεγονός ότι η καταγραφή των υδραυλικών υψών δεν έχει γίνει με την απαιτούμενη ακρίβεια αλλά και στην ύπαρξη πολλών σε σειρά ημερών με μηδενική διαφορά στάθμης, που δε μπορούν να περιγραφούν επαρκώς από το μοντέλο.


Ωστόσο, βάσει του διαγράμματος 5-15, σε γενικές γραμμές η τάση του συστήματος περιγράφεται αρκετά καλά. Οι απότομες πτώσεις τις ημέρες 439 και 449 οφείλονται στις ξαφνικές πολύ μεγάλες τιμές βροχοπτώσεις μετά από μία ή περισσότερες ημέρες ανυδρίας. Το νευρωνικό ωστόσο τείνει να υπερεκτιμάει κάποιες τιμές της διαφορές υδραυλικού ύψους και να υποεκτιμάει άλλες. Αυτό οφείλεται στην αδυναμία του δικτύου να προσομοιάζει τοπικά και μεταβατικά φαινόμενα που μπορεί να προκληθούν από κάποια άντληση ή από μη ορθώς καταγεγραμμένες βροχοπτώσεις.

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης

Αντίστοιχα, τα αποτελέσματα της προσομοίωσης σύμφωνα με τον αλγόριθμο εκπαίδευσης Μπαεσιανής κανονικοποίησης δίνονται από τα διαγράμματα 5-16 και 5-17:



Διάγραμμα 5-16 Προσομοιωμένη διαφορά στάθμης συναρτήσει πραγματικής διαφοράς στάθμης (trainbr)



Διάγραμμα 5-17 Προσομοιωμένη και πραγματική διαφορά στάθμης ως προς το χρόνο (trainbr)


Ομοίως με τον `trainlm`, και κατά την εκπαίδευση με τον `trainbr` όπως προκύπτει από το πρώτο διάγραμμα (5-16), το δίκτυο αδυνατεί να προσομοιώσει επαρκώς τις πραγματικές τιμές υδραυλικού ύψους και μάλιστα σε μεγαλύτερο ποσοστό από την περίπτωση του αλγορίθμου Levenberg-Marquardt, αφού η εξίσωση που προκύπτει απέχει ακόμα περισσότερο από το ιδανικό  $y=x$  των αξόνων. Επίσης και σε αυτή την περίπτωση η ύπαρξη μεγάλου πλήθους μηδενικής διαφοράς στάθμης παρεμποδίζει την ικανότητα προσομοίωσης του δικτύου.

Όσον αφορά το διάγραμμα 5-17, παρατηρείται ότι το δίκτυο περιγράφει με μεγάλη ακρίβεια την τάση των δεδομένων με ελάχιστες εξαιρέσεις τα σημεία που έχουμε απότομες μεταβολές από θετικές σε αρνητικές τιμές διαφοράς στάθμης και το αντίθετο. Ωστόσο, συγκρίνοντας το με το αντίστοιχο διάγραμμα που προέκυψε βάσει της εκπαίδευσης με τον `trainlm` το δίκτυο υπερεκτιμάει και υποεκτιμάει τα δεδομένα σε πολύ μεγαλύτερο ποσοστό, γεγονός που δεν είναι θεμιτό.

## 5.4 Πρόβλεψη υδραυλικού ύψους


Για τις ίδιες περιπτώσεις υπολογίστηκε στη συνέχεια το προσομοιωμένο υδραυλικό ύψος, με την πρόσθεση στην προσομοιωμένης διαφοράς στάθμης την πραγματική στάθμη της προηγούμενης ημέρας. Έτσι προέκυψαν τα διαγράμματα:

- Για τον αλγόριθμο `trainlm`:



Διάγραμμα 5-18 Προσομοιωμένο υδραυλικό ύψος συναρτήσει πραγματικού υδραυλικού ύψους (`trainlm`)


Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης




Διάγραμμα 5-19 Προσομοιωμένο υδραυλικό ύψος και πραγματικό υδραυλικό ύψος ως προς το χρόνο (trainlm)

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης

➤ Για τον αλγόριθμο trainbr:



Διάγραμμα 5-20 Προσομοιωμένο υδραυλικό ύψος συναρτήσει πραγματικού υδραυλικού ύψους (trainbr)



Διάγραμμα 5-21 Προσομοιωμένο υδραυλικό ύψος και πραγματικό υδραυλικό ύψος ως προς το χρόνο (trainbr)



Τα προσομοιωμένα με τα πραγματικά υδραυλικά ύψη παρουσιάζουν μικρές αποκλίσεις, τόσο για τα αποτελέσματα από τον αλγόριθμο εκπαίδευσης trainlm όσο και τον trainbr, και όπως φαίνεται από τα διαγράμματα (5-19,5-21) οι τιμές τους σχεδόν ταυτίζονται. Το γεγονός αυτό μαρτυρά την ύπαρξη σωστών τιμών των συναπτικών βαρών (Μούτζουρης, 2010). Μέγιστη απόκλιση όσον αφορά την εκπαίδευση κατά Levenberg-Marquart σημειώνεται την ημέρα 247 ίση με


-0,671m. Ενώ η μέση τιμή της απόκλιση ισούται με 0,00338. Για τον αλγόριθμο κατά τη Μπαεσιανή κανονικοποίηση, μέγιστη διαφορά μεταξύ πραγματικής και προσομοιωμένης διαφοράς στάθμης παρατηρείται την ημέρα 617 και είναι ίση με -0,782 ενώ η μέση τιμή της διαφοράς ισούται με 0,0716.

## 5.5 Μεσοπρόθεσμη πρόβλεψη υδραυλικού ύψους


Στην προσπάθεια μιας πιο ρεαλιστικής σύγκρισης του προσομοιωμένου υδραυλικού ύψους με το πραγματικό υπολογίστηκε η μεσοπρόθεσμη προσομοιωμένη στάθμη όπως προέκυψε έχοντας ως αρχικό δεδομένο μόνο την τιμή της πρώτης μέρας της πραγματικής στάθμης. Η προσομοιωμένη στάθμη υπολογίστηκε προσθέτοντας στην προηγούμενη τιμή προσομοιωμένου υδραυλικού ύψους την αντίστοιχη προσομοιωμένη διαφορά στάθμης. Με τον τρόπο αυτό εξετάζεται κατά πόσο το δίκτυο μπορεί να προβλέψει τα υδραυλικά ύψη για περισσότερες της μιας ημέρες (Ταπόγλου,2011).Τα αποτελέσματα δίνονται στα διαγράμματα 5-22 έως 5-25:

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης

- Αρχικά για τον αλγόριθμο trainlm:




Διάγραμμα 5-22 Προσομοιωμένο υδραυλικό ύψος συναρτήσει πραγματικού υδραυλικού ύψους - μεσοπρόθεσμη πρόβλεψη (trainlm)



Διάγραμμα 5-23 Προσομοιωμένο υδραυλικό ύψος και πραγματικό υδραυλικό ύψος ως προς το χρόνο- μεσοπρόθεσμη πρόβλεψη (trainlm)


Η εικόνα παρουσιάζεται στα διαγράμματα 5-22,5-23 είναι σαφώς χειρότερη από εκείνη στα διαγράμματα 5-18,5-19, γεγονός αναμενόμενο αφού έχουμε ως δεδομένο το υδραυλικό ύψος μόνο της πρώτης μέρας ενώ τα υπόλοιπα προβλέπονται από το δίκτυο. Το νευρωνικό δίκτυο μέχρι την ημέρα 440 τείνει να υπερεκτιμά τη στάθμη και στη συνέχεια να την υποεκτιμά. Η μέγιστη διαφορά της πραγματικής και προσομοιωμένης στάθμης παρουσιάζεται την ημέρα 762 και ισούται με 5,927 m ενώ η ελάχιστη εντοπίζεται την ημέρα 2 και ισούται με 0,092m. Η μέση διαφορά είναι 1,24m.

➤ Έπειτα για τον αλγόριθμο trainbr:



Διάγραμμα 5-24 Προσομοιωμένο υδραυλικό ύψος συναρτήσει πραγματικού υδραυλικού ύψους - μεσοπρόθεσμη πρόβλεψη (trainbr)

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης



Διάγραμμα 5-15 Προσομοιωμένο υδραυλικό ύψος και πραγματικό υδραυλικό ύψος ως προς το χρόνο-μεσοπρόθεσμη πρόβλεψη (trainbr)

Συγκρίνοντας τα διαγράμματα, στην περίπτωση του trainbr παρατηρούνται χειρότερα αποτελέσματα συγκριτικά με τον trainlm ως προς τη δυνατότητα μεσοπρόθεσμης πρόβλεψης του υδραυλικού ύψους. Το νευρωνικό δίκτυο τείνει να υπερεκτιμά και να υποεκτιμά την πραγματική στάθμη σε μεγαλύτερο ποσοστό, με τη μέγιστη διαφορά του προσομοιωμένου από το πραγματικό υδραυλικό ύψος να ισούται με 8,91 την ημέρα 775 και η μέση τιμή της διαφοράς να είναι ίση με 1,9 m.

Παρόλα αυτά, ιδιαίτερα στην περίπτωση εκπαίδευσης κατά τον trainlm, το δίκτυο προσομοιώνει με αρκετή ακρίβεια την πραγματική στάθμη. Επομένως, το μοντέλο μπορεί να χρησιμοποιηθεί για τη μελλοντική πρόβλεψη της στάθμης για μεταβολή των υδρολογικών δεδομένων ή των κλιματολογικών συνθηκών.

## Κεφάλαιο 6 : Συμπεράσματα-Προτάσεις

Στην παρούσα διπλωματική εργασία τα τεχνητά νευρωνικά δίκτυα, μέσω της αντίστοιχης εργαλειοθήκης της Matlab, χρησιμοποιήθηκαν για την προσομοίωση της διαφοράς στάθμης του υδροφορέα με δεδομένα που λήφθηκαν από μια γεώτρηση παρατήρησης στην τοποθεσία της Μεσσαράς στην Κρήτη. Τα τεχνητά νευρωνικά δίκτυα αποδείχτηκαν ένα πολύ χρήσιμο εργαλείο προσομοίωσης του υδραυλικού ύψους.

Για την εύρεση της δομής του δικτύου που θα παρουσίαζε τα μικρότερα σφάλματα πραγματοποιήθηκε μια πληθώρα δοκιμών. Βάσει αυτών των δοκιμών για τον αλγόριθμο εκπαίδευσης Levenberg-Marquardt (`trainlm`) βρέθηκε το βέλτιστο σενάριο δομής του δικτύου, ενώ παράλληλα αποδείχθηκε ότι η χρήση των χείμαρρων σαν εισόδους του δικτύου δίνει μεγαλύτερα σφάλματα, έτσι απορρίφθηκαν στην εξέταση των μετέπειτα αλλαγών. Πέραν του `trainlm`, εξετάστηκαν άλλοι τρεις αλγόριθμοι εκπαίδευσης (`trainbr`, `traingdx`, `trainrp`) όπου ανταγωνιστικά στον `trainlm` αποτελέσματα εξήχθησαν μόνο από την εκπαίδευση κατά τον `trainbr`.

Αρχικά για τα βέλτιστα σενάρια δομής του δικτύου και για τους δύο επιλεχθέντες αλγόριθμους έγινε σύγκριση της διαφοράς του προσομοιωμένου και του πραγματικού υδραυλικού ύψους τόσο μεταξύ τους όσο και σε σχέση με το χρόνο. Η τάση του δικτύου περιγράφηκε αρκετά καλά και από τους δύο αλγόριθμους. Ωστόσο, ο αλγόριθμος Levenberg-Marquardt αποδείχθηκε καλύτερος αφού ο αλγόριθμος Μπαεσιανής κανονικοποίησης έτεινε να υποεκτιμά και να υπερεκτιμά σε πολύ μεγαλύτερο βαθμό τις πραγματικές μετρήσεις. Το ίδιο δε φαίνεται να συμβαίνει στη διαδικασία προσομοίωσης των πραγματικών τιμών της διαφοράς στάθμης, γεγονός που εξηγείται από την ύπαρξη πολλών στη σειρά μετρήσεων με μηδενική διαφορά στάθμης. Παρ' όλα αυτά, και σε αυτή την περίπτωση ο αλγόριθμός Levenberg-Marquardt τείνει να δίνει καλύτερα αποτελέσματα από τον αλγόριθμο Μπαεσιανής κανονικοποίησης.

Όσον αφορά την προσεγγιστική πρόβλεψη του υδραυλικού ύψους, βραχυπρόθεσμα, προσθέτοντας στην προσομοιωμένη διαφορά στάθμης την πραγματική στάθμη της προηγούμενης ημέρας αλλά και μεσοπρόθεσμα, έχοντας ως αρχικό δεδομένο μόνο την τιμή της πρώτης μέρας της πραγματικής στάθμης και προσθέτοντας στην προηγούμενη τιμή προσομοιωμένου υδραυλικού ύψους την αντίστοιχη προσομοιωμένη διαφορά στάθμης, το δίκτυο κατάφερε να το προσομοιάσει με πολύ μεγάλη επάρκεια. Συνεπώς, η πρώτη περίπτωση, αποδεικνύει ότι τα συναπτικά βάρη προσαρμόστηκαν ορθώς, ενώ η δεύτερη τη δυνατότητα του δικτύου να προβλέπει τα υδραυλικά ύψη για περισσότερες από μία ημέρες.

Ως προς τις δυνατότητες μελλοντικής έρευνας, μια εποικοδομητική πλην δύσκολη σε υλοποίηση λύση θα ήταν η εισαγωγή χρονοσειρών άντλησης στο μοντέλο, που όμως δεν είναι εύκολο να ληφθούν. Εν συνεχεία, θα μπορούσε να πραγματοποιηθεί ο συνδυασμός ή σύγκριση τεχνητών νευρωνικών δικτύων με άλλες μεθόδους με στόχο τον συνδυασμό εκείνο που δίνει τα καλύτερα δυνατά αποτελέσματα. Ακόμη, θα ήταν χρήσιμο γίνεται αξιολόγηση των καταγεγραμμένων δεδομένων των χρονοσειρών, μιας και κάποιες από τις καταγεγραμμένες τιμές εμφανίζεται να μην ανταποκρίνονται στην πραγματικότητα είτε λόγω λανθασμένης μέτρησης είτε απουσίας μέτρησης. Τέλος, θα μπορούσε να γίνουν επιπλέον δοκιμές στον αριθμό των κόμβων στα κρυφά επίπεδα.

## Κεφάλαιο 7 : Βιβλιογραφία

Adamowski J., Chan H.F. «A wavelet neural network conjunction model for groundwater level forecasting.» *Journal of Hydrology*, 28 June 2011: 28-40.

Balabanis, Panagiotis. «Water in Eutrope.» *Afers Internacionals*, 1999: 59-78.

Croke B., Cleridou N., Kolovos A., Vardava I., Papamastorakis J. «Water resources in the desertification-threatened Messara Valley of Crete: estimation of annual water budget using rainfall-runoff model.» *Environmental Modelling&Software*, 2000: 387-402.

Custodio, Emilio. «Aquifer overexploitation: what does it mean?» *Hydrogeology Journal*, 2002: 254-277.

Elshorbagy, Kamran Parasuraman and Amin. «Cluster-Based Hydrologic Prediction Using Genetic Algorithm-Trained Neural Networks.» *Journal of Hydrologic Engineering*, January/February 2007: 52-62.

«Engineering statistics handbook.»  
<http://www.itl.nist.gov/div898/handbook/eda/section3/eda35b.htm>.

*Engineering statistics handbook*. 2003.  
(<http://www.itl.nist.gov/div898/handbook/eda/section3/eda35b.htm>).

Fong Lin G., Rong Chen G. «An improved neural network approach to the determination of aquifers parameters.» *Journal of Hydrology*, 2006: 281-289.

Golden, R.M. «Artificial Neural Networks: Neurocomputation.» *International Encyclopedia of the Social & Behavioral Sciences*, 2001: 806-811.

Haykin, Simon. *Neural networks: A Comprehensive foundation*. Macmillan, 1994.

Ioannis C. Trichakis, Ioannis K. Nikolos, and George P. Karatzas. «Optimal selection of artificial neural networks parameters for the prediction of carstic aquifer's response.» *Hydrological processes*, 25 August 2009: 2956-2969.

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και  
διαφορετικών αλγόριθμων εκπαίδευσης

Ioannis N. Daliakopoulos, Paulin Coulibaly, Ioannis K. Tsanis. «Groundwater Level Forecasting using Artificial Neural Networks.» *Journal of Hydrology*, 1 December 2004: 229-240.

Kröse Ben and van der Smagt Patrick. *An introduction to Neural Networks*. 8th. University of Amsterdam , 1996.

Mark Hudson Beale, Martin T. Hagan, Howard B. Demuth. *Neural Network Toolbox-User's guide*.

«Mathworks.» [www.mathworks.com](http://www.mathworks.com).

Samani N., Gohari-Moghadam M., Safavi A.A. «A Simple Neural Network Model for the Determination of Aquifer Parameters.» *Journal of Hydrology*, 17 March 2007: 1-11.

«The importance of groundwater.» Longwood University.

*USGS-Science of a changing world* . <http://water.usgs.gov/edu/watercyclegreek.html#global>.

Vardavas IM., Papamastorakis J., Fountoulakis A., Manousakis M. «Water resources in of desertification-threatened Messsara Valley of Crete: estimation of potential lake evaporation.» *Ecological Modelling*, 1997: 363-374.

Αγγελίδης, Τιμόθεος. «Διαστήματα εμπιστοσύνης.»

Αργυράκης, Π. «Νευρωνικά Δίκτυα και Εφαρμογές.» 2001.

Αρναουτάκης, Νεκτάριος. «Συνοπτικός Οδηγός Matlab-Simulink.» Τμήμα Μηχανικών Παραγωγής και διοίκησης, Πολυτεχνείο Κρήτης, 2002.

Καρατζάς, Γ. «Ροή Υπογείων Υδάτων και Μεταφοράς Ρύπων, Πανεπιστημιακές σημειώσεις.» Πολυτεχνείο Κρήτης, Τμήμα Μηχανικών Περιβάλλοντος, 2003.

Λυμπεροπούλου, Κυριακή. «Χρήση Νευρωνικών Δικτύων για την πρόγνωση της συγκέντρωσης τροποσφαιρικού όζοντος σε αστικό περιβάλλον.» Πάτρα, 2006.

Μούτζουρης-Σιδέρης, Ιωάννης. «Προσομοίωση Στάθμης Γεώτρησης σε Καρστικό Υδροφορέα με χρήση Νευρωνικών Δικτύων.» Χανιά, 2010.

Πάνου, Ελένη Γ. «Υλοποίηση Αλγορίθμου Πρόβλεψης Ζήτησης με Χρήση Τεχνητών Νευρωνικών Δικτύων.» Αθήνα, 2003.

Παντελή, Αντρέας. «Υπολογιστική νοημοσύνη στην οικονομία για την προβλεψη της νομισματικής ισοτιμίας μεταξύ δολαρίου και ευρώ.» 2012.

Ρεφενίδης, Γιάννης. «Νευρωνικά Δίκτυα.» 2011.

Σκιτζί, Ειρήνη. «Προσομοίωση Παροχών Καρστικών Πηγών με Χρήση Νευρωνικών Δικτύων.» Χανιά, 2010.

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης

Ταπόγλου, Ευδοκία. «Χρήση αλγορίθμου βελτιστοποίησης σμήνου σωματιδίων για την εκπαίδευση τεχνητού νευρωνικού δικτύου. Εφαρμογή σε υπόγεια ύδατα.» Χανιά, 2011.



## ΠΑΡΑΡΤΗΜΑ Ι: Ορισμοί

**Τυπική απόκλιση:** η θετική τετραγωνική ρίζα της διασποράς

**Διασπορά:** ο αριθμητικός μέσος όρος των τετραγώνων, των διαφορών που προκύπτουν, αν αφαιρέσουμε τη μέση τιμή μιας μεταβλητής, από τις τιμές της.

**Ασυμμετρία:** το μέτρο της συμμετρίας, ή ακριβέστερα, η απουσία αυτής. Αφορά το κατά πόσο ένα σύνολο δεδομένων φαίνεται το ίδιο προς τα αριστερά και δεξιά του κεντρικού σημείου.

**Κύρτωση:** μέτρο του κατά πόσο τα δεδομένα είναι κορυφωμένα ή επίπεδα σε σχέση με την κανονική κατανομή. Που σημαίνει πως σύνολα δεδομένων με υψηλή κύρτωση τείνουν να έχουν μια διακριτή κορυφή κοντά στην μέση τιμή, μειώνονται μάλλον γρήγορα. Ενώ σύνολα δεδομένων με χαμηλή κύρτωση, τείνουν να έχουν μια επίπεδη κορυφή κοντά στην μέση και όχι μία απότομη κορυφή. Μια ομοιόμορφη κατανομή θα είναι η ακραία περίπτωση.

(Engineering statistics handbook, 2003)

**Διάστημα εμπιστοσύνης:** Ένα διάστημα βασιζόμενο στις παρατηρήσεις ενός δείγματος, το οποίο είναι καθορισμένο με τέτοιο τρόπο ώστε να υπάρχει μια συγκεκριμένη πιθανότητα να περιέχει μια άγνωστη πραγματική τιμή μιας παραμέτρου.

(Αγγελίδης, n.d)

## ΠΑΡΑΡΤΗΜΑ II: Συνολικοί πίνακες

ΠΙΝΑΚΑΣ i Αποτελέσματα μεθόδου δοκιμής και σφάλματος (trainbr)

		Χωρίς χείμαρρους 2 lag				Χωρίς χείμαρρους 1 lag			
		5	10	15	20	5	10	15	20
training	5	0,0268	0,0318	0,035	0,0274	0,0302	0,0284	0,0284	0,0299
validation	5	0,0457	0,0204	0,0276	0,0296	0,0218	0,0231	0,0287	0,0229
test	5	0,0289	0,0206	0,0186	0,0363	0,0472	0,0377	0,045	0,0533
average	5	0,0338	0,0243	0,0271	0,0311	0,0331	0,0297	0,0340	0,0354
training	10	0,0242	0,027	0,0274	0,032	0,028	0,0339	0,027	0,0315
validation	10	0,0537	0,0347	0,028	0,0356	0,0307	0,009	0,0259	0,0181
test	10	0,0344	0,0301	0,0467	0,0419	0,0329	0,0242	0,0341	0,015
average	10	0,0374	0,0306	0,0340	0,0365	0,0305	0,0224	0,0290	0,0215
training	15	0,0299	0,0337	0,0315	0,0268	0,026	0,0279	0,0298	0,0297
validation	15	0,0356	0,0226	0,0142	0,032	0,0362	0,0295	0,0265	0,0292
test	15	0,0283	0,0165	0,043	0,0396	0,036	0,0448	0,0342	0,0194
average	15	0,0313	0,0243	0,0296	0,0328	0,0327	0,0341	0,0302	0,0261
training	20	0,0287	0,0299	0,0276	0,027	0,0288	0,0286	0,0313	0,0271
validation	20	0,0324	0,0275	0,0247	0,0312	0,0199	0,0303	0,0155	0,0357
test	20	0,0378	0,0302	0,0475	0,0362	0,0287	0,0226	0,032	0,0277
average	20	0,0330	0,0292	0,0333	0,0315	0,0258	0,0272	0,0263	0,0302

ΠΙΝΑΚΑΣ ii Αποτελέσματα μεθόδου δοκιμής και σφάλματος (trainbxd)


		Χωρίς χείμαρρους 2 lag				Χωρίς χείμαρρους 1 lag			
		5	10	15	20	5	10	15	20
training	5	0,0284	0,0334	0,0443	0,0316	0,0297	0,0297	0,0352	0,0297
validation	5	0,0473	0,0211	0,0344	0,0283	0,0250	0,0247	0,0434	0,0214
test	5	0,0315	0,0225	0,0255	0,0391	0,0445	0,0408	0,0575	0,0563
average	5	0,0357	0,0257	0,0347	0,0330	0,0331	0,0317	0,0454	0,0358
training	10	0,1347	0,0295	0,0649	0,0518	0,0306	0,0550	0,0324	0,0329
validation	10	0,1811	0,0367	0,0767	0,0502	0,0318	0,0224	0,0283	0,0198
test	10	0,2004	0,0331	0,0666	0,0612	0,0316	0,0354	0,0345	0,0187
average	10	0,1721	0,0331	0,0694	0,0544	0,0313	0,0376	0,0317	0,0238
training	15	0,0521	0,0332	0,0304	0,0288	0,0321	0,0307	0,0298	0,0316
validation	15	0,0569	0,0258	0,0160	0,0317	0,0411	0,0343	0,0269	0,0288
test	15	0,0411	0,0164	0,0434	0,0422	0,0424	0,0468	0,0343	0,0199
average	15	0,0500	0,0251	0,0299	0,0342	0,0385	0,0373	0,0303	0,0268
training	20	0,0456	0,0300	0,0297	0,1573	0,0341	0,0315	0,0328	0,0295
validation	20	0,0437	0,0302	0,0275	0,1576	0,0216	0,0307	0,0197	0,0376
test	20	0,0435	0,0311	0,0501	0,1441	0,0274	0,0259	0,0390	0,0315
average	20	0,0443	0,0304	0,0358	0,1530	0,0277	0,0294	0,0305	0,0329

Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και  
διαφορετικών αλγόριθμων εκπαίδευσης


ΠΙΝΑΚΑΣ iii Αποτελέσματα μεθόδου δοκιμής και σφάλματος (trainrp)

		Χωρίς χείμαρρους 2 lag				Χωρίς χείμαρρους 1 lag			
		5	10	15	20	5	10	15	20
training	5	0,0279	0,0333	0,0359	0,0298	0,0298	0,0296	0,0293	0,0316
validation	5	0,0449	0,0192	0,0264	0,0283	0,0225	0,0238	0,0307	0,0238
test	5	0,0288	0,0217	0,018	0,0381	0,0457	0,0383	0,0472	0,0727
average	5	0,0339	0,0247	0,0268	0,0321	0,0327	0,0306	0,0357	0,0427
training	10	0,0254	0,0276	0,026	0,0287	0,03	0,0352	0,0282	0,0355
validation	10	0,0542	0,0364	0,0267	0,0303	0,0311	0,0102	0,0272	0,0232
test	10	0,036	0,0308	0,0498	0,0366	0,0312	0,0244	0,0323	0,0169
average	10	0,0385	0,0316	0,0342	0,0319	0,0308	0,0233	0,0292	0,0252
training	15	0,0606	0,0306	0,0318	0,0308	0,0314	0,0279	0,0283	0,0317
validation	15	0,0615	0,0274	0,0165	0,0297	0,0418	0,0348	0,0272	0,0276
test	15	0,0445	0,0189	0,0434	0,039	0,0414	0,0487	0,0338	0,028
average	15	0,0555	0,0256	0,0306	0,0332	0,0382	0,0371	0,0298	0,0291
training	20	0,028	0,029	0,0277	0,0272	0,0338	0,0292	0,0286	0,0272
validation	20	0,0319	0,0274	0,0266	0,0337	0,0226	0,0365	0,0174	0,0381
test	20	0,0385	0,0316	0,0486	0,0366	0,0278	0,0267	0,033	0,0258
average	20	0,0328	0,0293	0,0343	0,0325	0,0281	0,0308	0,0263	0,0304

### ΠΑΡΑΡΤΗΜΑ ΙΙΙ: Συγκριτικά διαγράμματα




ΔΙΑΓΡΑΜΜΑ i Πραγματική και προσομοιωμένη διαφορά στάθμης ως προς το χρόνο



ΔΙΑΓΡΑΜΜΑ ii Πραγματικό και Προσομοιωμένο υδραυλικό ύψος ως προς το χρόνο

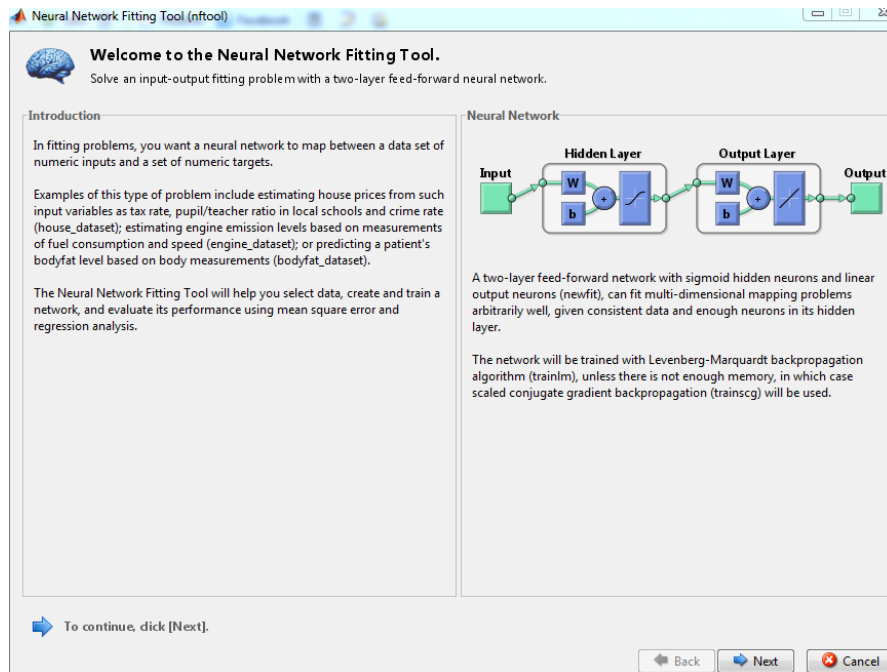
## Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης



ΔΙΑΓΡΑΜΜΑ iii Πραγματικό και Προσομοιωμένο υδραυλικό ύψος ως προς το χρόνο-μεσοπρόθεσμη πρόβλεψη

## ΠΑΡΑΡΤΗΜΑ IV: Εργαλείο προσαρμογής νευρωνικών δικτύων-nftool

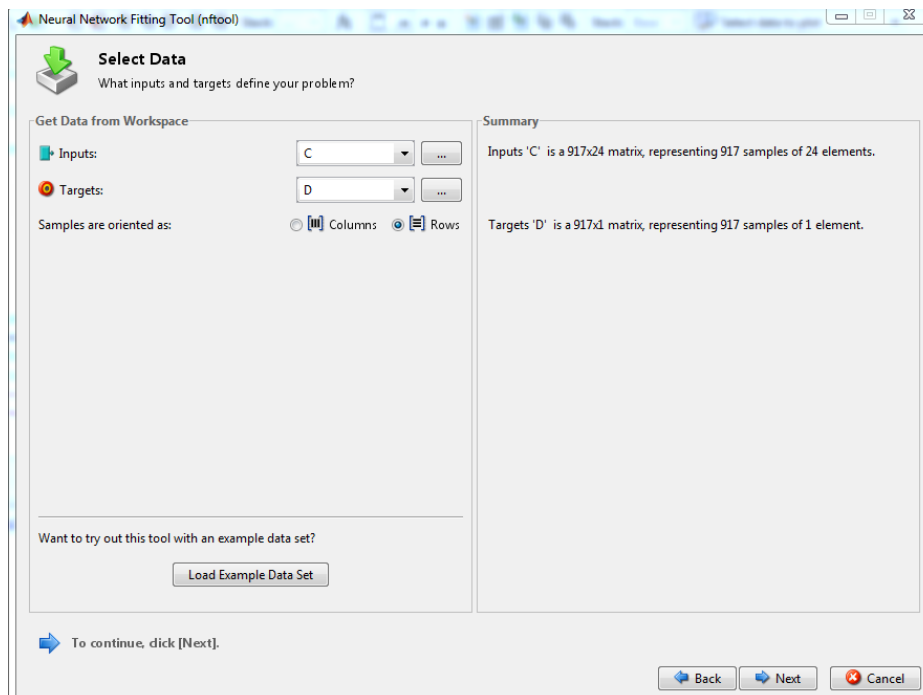
### ➤ Αρχικό παράθυρο nftool



ΕΙΚΟΝΑ i αρχικό παράθυρο nftool

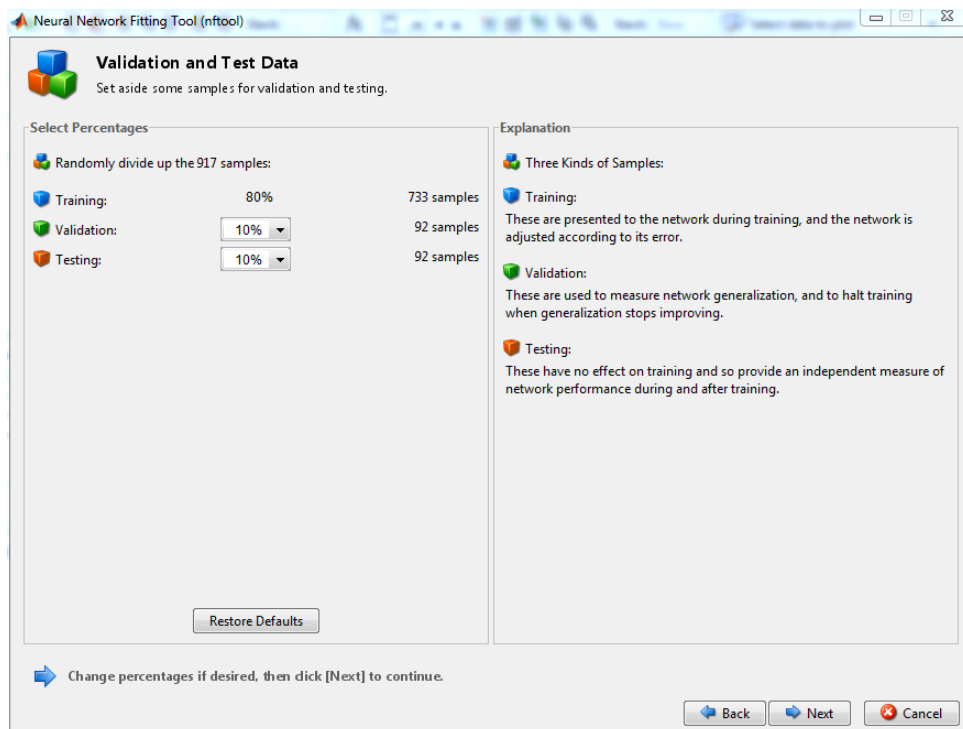
## Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης

- Εισαγωγή πινάκων εισόδων (C) και στόχων (D)



ΕΙΚΟΝΑ ii Παράθυρο nftool εισαγωγής εισόδων και στόχων

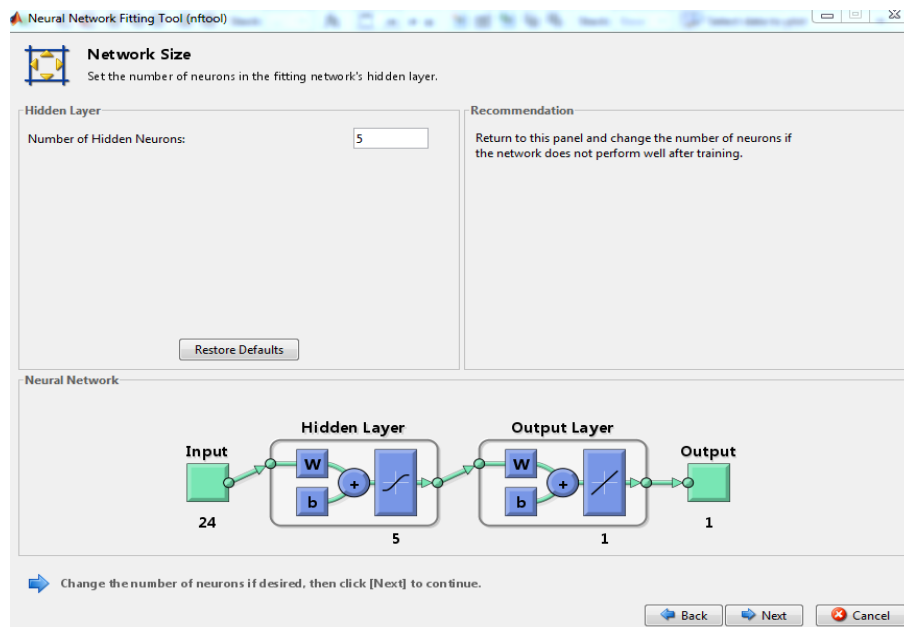
- Διαχωρισμός δεδομένων εισόδου στα σετ εκπαίδευσης, επαλήθευσης και ελέγχου(80-10-10)



ΕΙΚΟΝΑ iii Διαχωρισμός εισόδων σε σετ

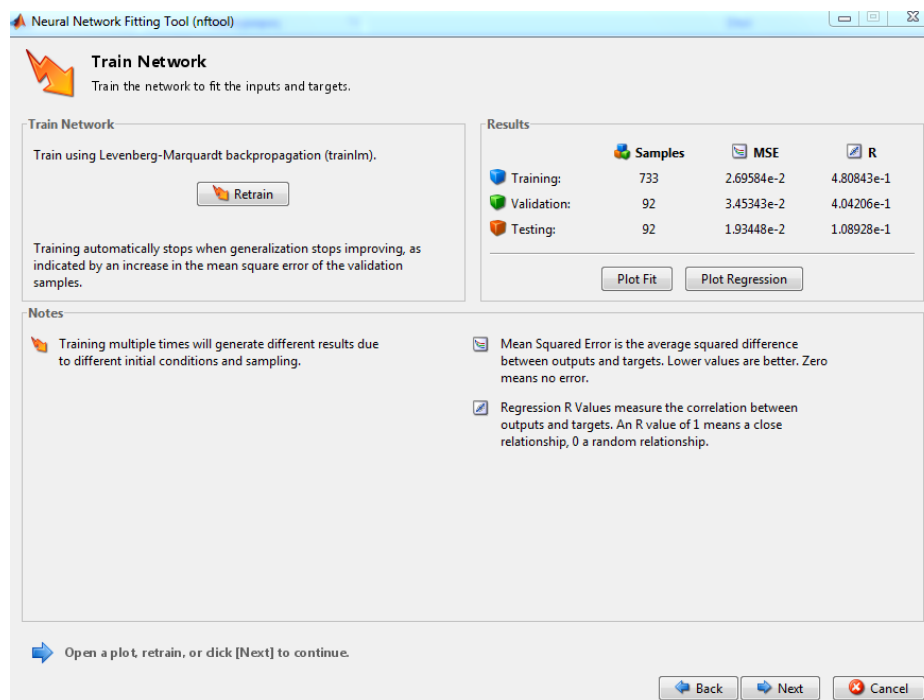
## Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης

- Ορισμός αριθμού κρυφών κόμβων( π.χ 5).



ΕΙΚΟΝΑ iv Παράθυρο nftool εισαγωγής αριθμού κρυφών κόμβων

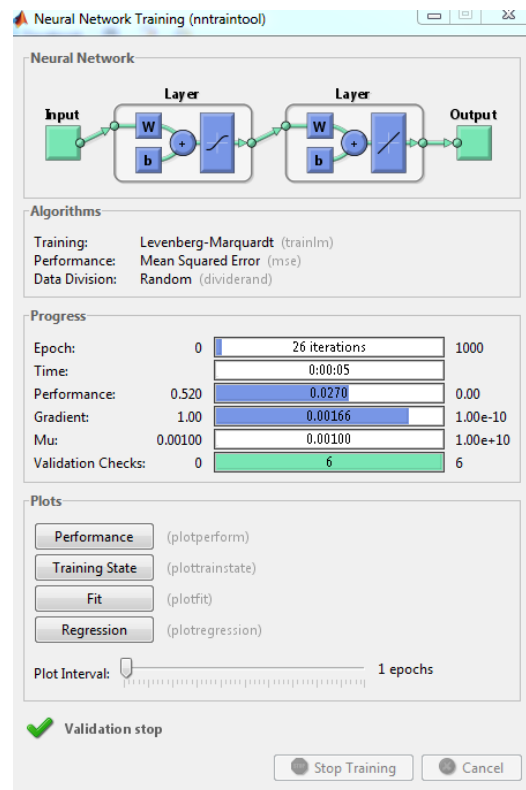
- Διαδικασία εκπαίδευσης και υπολογισμός τετραγωνικών σφαλμάτων



ΕΙΚΟΝΑ v Παράθυρο nftool για εκπαίδευση του δικτύου και υπολογισμό τετραγωνικών σφαλμάτων

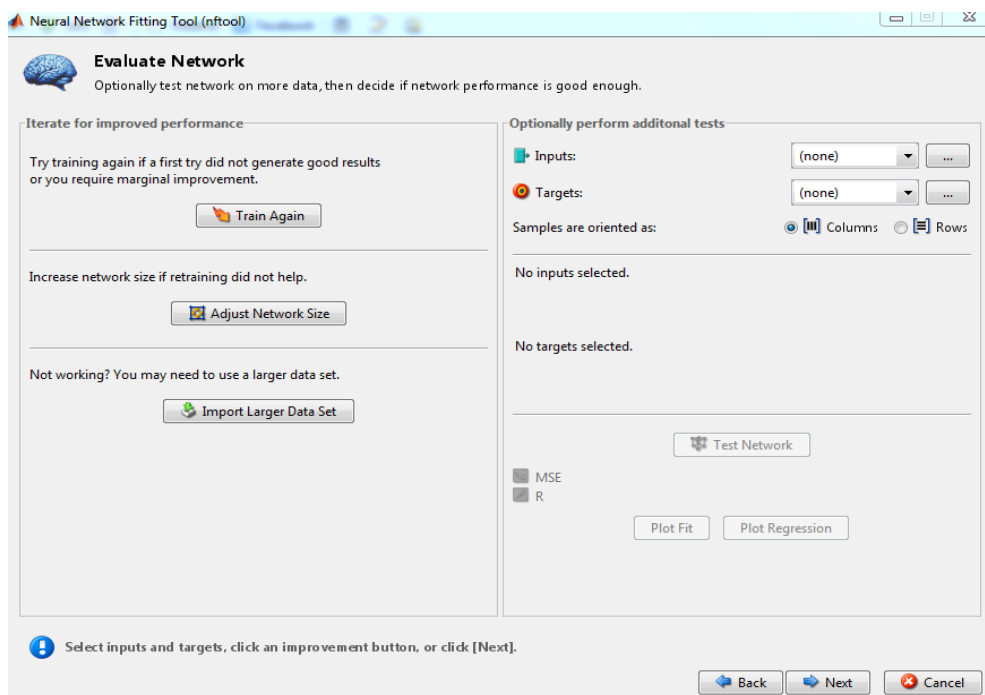
## Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης

### ➤ Παράθυρο εκπαίδευσης



ΕΙΚΟΝΑ vi Εκπαίδευση δικτύου

### ➤ Παράθυρο επέκτασης-επανεκπαίδευσης δικτύου

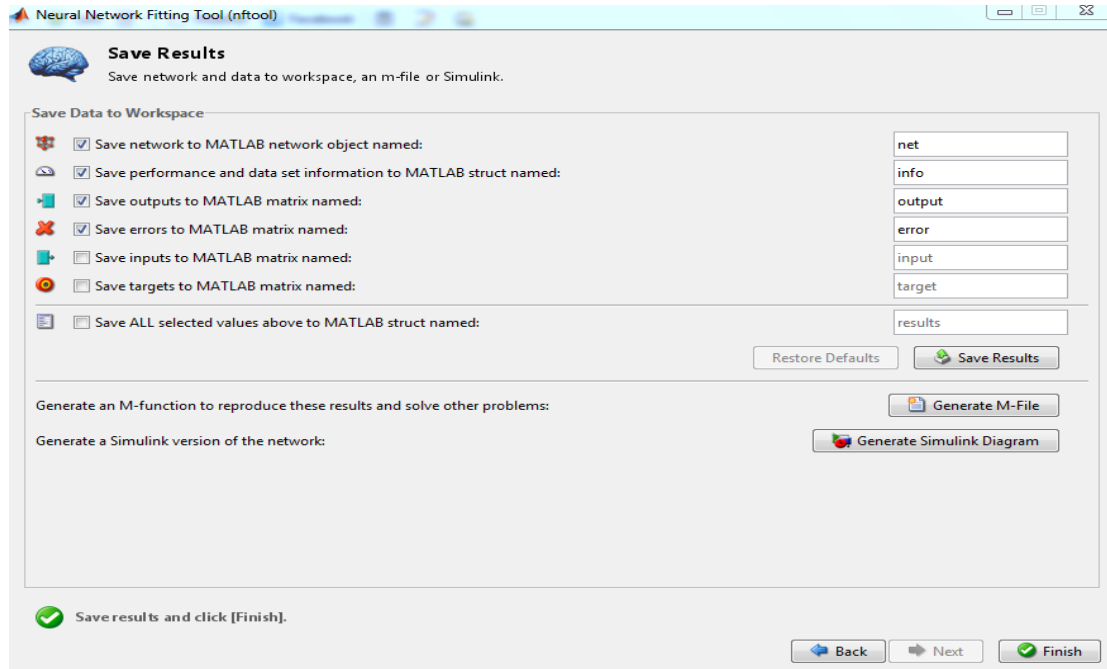


ΕΙΚΟΝΑ vii Παράθυρο nftool για επέκταση-επανεκπαίδευση δικτύου



## Προσομοίωση της στάθμης του υδροφορέα Μεσσαράς Κρήτης με χρήση ANN και διαφορετικών αλγόριθμων εκπαίδευσης

- Παράθυρο αποθήκευσης αποτελεσμάτων και δημιουργίας M-file



ΕΙΚΟΝΑ viii Παράθυρο nftool για αποθήκευση αποτελεσμάτων