

ΠΡΟΣΟΜΟΙΩΣΗ ΧΡΟΝΟΣΕΙΡΑΣ ΜΗΝΙΑΙΟΥ ΥΨΟΥΣ ΒΡΟΧΗΣ ΤΟΥ ΒΡΟΧΟΜΕΤΡΙΚΟΥ ΣΤΑΘΜΟΥ ΝΕΣΤΟΡΙΟΥ ΚΑΣΤΟΡΙΑΣ ΜΕ ΤΗ ΧΡΗΣΗ ΑΝΑΤΡΟΦΟΔΟΤΟΥΜΕΝΟΥ (RECURRENT) ΜΟΝΤΕΛΟΥ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Κοτοπούλη Μ.*, Ψιλοβίκος Αρ.*, Γκιτσάκης Ν.*, Σαπουντζής Μ.*, Δήμος Γ.***

* Τμήμα Γεωπονίας Ιχθυολογίας & Υδάτινου Περιβάλλοντος, Σχολή Γεωπονικών Επιστημών, Πανεπιστήμιο Θεσσαλίας, Οδός Φυτόκου, 38446, Ν. Ιωνία Μαγνησίας, psiloviko@apae.uth.gr

**Εργαστήριο Διευθέτησης Ορεινών Υδάτων, Σχολή Δασολογίας & Φυσικού Περιβάλλοντος, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης, 54124, Θεσσαλονίκη

ΠΕΡΙΛΗΨΗ

Στην παρούσα εργασία, εφαρμόζεται ένα μοντέλο προσομοίωσης χρονοσειράς βασισμένο σε δομές Τεχνητών Νευρωνικών δικτύων (ΤΝΔ). Τα ΤΝΔ, τα οποία είναι μοντέλα «μαύρου κουτιού», χρησιμοποιούνται αφενός επειδή μπορούν να εφαρμοστούν σε συστήματα οι διεργασίες των οποίων χαρακτηρίζονται από υψηλό βαθμό πολυπλοκότητας και αφετέρου λόγω της σημαντικής απλότητας που τα χαρακτηρίζει. Η χρονοσειρά στην οποία εφαρμόζονται, προέρχεται από τα δεδομένα 41 ετών μηνιαίων παρατηρήσεων (1962 – 2003) των βροχοπτώσεων του βροχομετρικού σταθμού Νεστορίου – Καστοριάς. Το τελικό προτεινόμενο μοντέλο που διαμορφώνεται είναι ένα (12,5,3,1) επανατροφοδοτούμενο δίκτυο (recurrent network) το οποίο αποτελείται από 12 κόμβους εισόδου (βροχόπτωση κατά τους 12 προηγούμενους μήνες), δύο κρυφά επίπεδα 5 και 3 κόμβων αντίστοιχα και 1 κόμβο εξόδου (βροχόπτωση του μήνα αναφοράς). Το μοντέλο εμφανίζει καλή προσαρμογή στα δεδομένα λόγω της σύγκλισης των τιμών σφάλματος των δεδομένων εκπαίδευσης και των δεδομένων δοκιμής. Το τελικό εκτιμώμενο σφάλμα (RMSE) είναι ίσο με 0,94, είναι της τάξης του ενός χιλιοστού βροχής και κρίνεται πολύ ικανοποιητικό. Η πλατφόρμα λογισμικού που χρησιμοποιήθηκε για την ανάπτυξη του μοντέλου ήταν το Neurosolution της εταιρείας Neurodimension (<http://www.nd.com>).

TIME SERIES ANALYSIS OF RAINFALL DATA OF NESTORIO – KASTORIA – GAUGE STATION USING A RECURRENT NEURAL NETWORK MODEL

Kotopouli M.*, Psilovikos Ar.*, Gitsakis N.*, Sapountzis M.*, Dimos G.***

* Department of Agriculture Ichthyology & Aquatic Environment, School of Agricultural Sciences, University of Thessaly, Fytoko St., 38446, N. Ionia Magnisias, psiloviko@apae.uth.gr

**Laboratory of Mountainous Water Management and Control, School of Forestry & Natural Environment, Aristotle University of Thessaloniki, 54124, Thessaloniki

ΠΕΡΙΛΗΨΗ

In the present study, a time series model is applied based on Artificial Neural Network algorithms. Neural Networks are applied because, as “black box” models, they can simulate systems which are characterized by very complicated natural processes and moreover it is easy to be applied. The time series in which the Neural Network is applied, is the monthly rainfall data of Nestorio – Kastoria – rainfall gauge for a period

of 41 years (1962 – 2003). The final proposed model that is formulated, is a **(12,5,3,1)** recurrent network, which consists of 12 nodes of the input layer, two hidden layers of 5 and 3 nodes respectively and 1 node of the output layer. The model reveal good fitting in the raw data because of the convergence between the training and validation errors. The final RMSE value is equal to 0,94 and is correspond to one mm of rainfall, so the method obtain very satisfactory results. The software package which has been used for the development of the model is Neurosolution of Neurodimension Company (<http://www.nd.com>).

1. ΕΙΣΑΓΩΓΗ

Τα Νευρωνικά Δίκτυα, αποτελούν μορφές μη ρητών αλγεβρικών συναρτήσεων επεξεργασίας πληροφοριών που έχουν την ικανότητα μάθησης. Τα κύρια χαρακτηριστικά τους είναι τα εξής :

- Λειτουργούν ως «μαύρα κουτιά» (Black Box), δεν είναι δηλαδή γνωστές οι αλγεβρικές μορφές των συναρτήσεων που περιγράφουν
- Δεν απαιτούν ειδική γνώση του προβλήματος το οποίο μελετάμε
- Το εκπαιδευμένο νευρωνικό δίκτυο αποτελεί το τελικό μοντέλο προσομοίωσης

Τα ΤΝΔ χρησιμοποιούνται είτε αυτόνομα είτε σε συνδυασμό με άλλες τεχνικές ως εναλλακτικός τρόπος επίλυσης πολλών προβλημάτων. Τέτοια προβλήματα είναι η βελτιστοποίηση διαδικασιών (optimisation), η αναγνώριση προτύπων (pattern recognition), η επεξεργασία σήματος (signal processing), το προσαρμοστικό φιλτράρισμα (adaptive filtering), η συμπίεση δεδομένων (data compression), η αναγνώριση και επεξεργασία της ανθρώπινης φωνής, η επεξεργασία εικόνας κ.α.

Τα ΤΝΔ είναι δομές οι οποίες χαρακτηρίζονται από τη δυνατότητα επίλυσης μιας μεγάλης κατηγορίας προβλημάτων που περιλαμβάνουν τη δημιουργία μοντέλων για τα πάσης φύσεως δυναμικά συστήματα, το χαρακτηρισμό και την πρόβλεψη χρονοσειρών και την αναγνώριση προτύπων. Υπάρχουν πολλοί λόγοι που συνηγορούν στη χρήση ΤΝΔ και οι πιο σημαντικοί από αυτούς είναι οι ακόλουθοι:

- Χαρακτηρίζονται από επιτυχή δυνατότητα περιγραφής ενός συστήματος σύμφωνα με τις αρχές της **πολυωνυμικής προσέγγισης (polynomial approximation)**. Χρησιμοποιώντας αυτή την μεθοδολογία, μπορούμε να προσεγγίσουμε κάθε συνάρτηση με την βοήθεια ενός πολυωνύμου, οι συντελεστές του οποίου υπολογίζονται από την διαδικασία ελαχιστοποίησης του σφάλματος προσέγγισης (approximation error). Το βασικό μειονέκτημα αυτής της μεθόδου, καθώς και πολλών άλλων που στηρίζονται σε αυτή, είναι η εξαιρετική ευαισθησία της στην επιλογή των μονωνύμων βάσης (monomials), τους συντελεστές των οποίων επιθυμούμε να υπολογίσουμε. Τα ΤΝΔ δίκτυα ωστόσο δεν υφίστανται αυτόν τον περιορισμό, καθώς οι συντελεστές του πολυωνύμου υπολογίζονται δυναμικά κατά την διάρκεια της εκπαίδευσής τους και υπό αυτή την έννοια είναι περισσότερο αποτελεσματικά όσον αφορά την μοντελοποίηση των μη γραμμικών συστημάτων, σε σχέση με την αυθεντική μέθοδο της πολυωνυμικής προσέγγισης
- Η ιδιότητά που εμφανίζουν σε **προσομοίωση μη – γραμμικών δυναμικών συστημάτων**, να προσεγγίζουν την κατάσταση ελαχίστου σφάλματος κατά την διάρκεια της εκπαίδευσής τους, ακολουθώντας πολλούς διαφορετικούς τρόπους δυναμικής συμπεριφοράς. Το γεγονός αυτό τα καθιστά ένα πολύτιμο εργαλείο για την μελέτη των μη γραμμικών συστημάτων, καθώς μπορούν να χρησιμοποιηθούν για να μελετηθεί και να προσομοιωθεί μια μεγάλη ποικιλία δυναμικών συστημάτων, με διαφορετική γενικά συμπεριφορά το καθένα. Τέλος τα δίκτυα αυτού του είδους χαρακτηρίζονται όπως είναι γνωστό από την ιδιότητα της

γενίκευσης (generalization), που συνίσταται στη δυνατότητα υπολογισμού εξόδου από το δίκτυο, ακόμη και εάν αυτή αντιστοιχεί σε κάποια είσοδο, η οποία δεν είναι γνωστή.

- Η χρήση τους ως εργαλεία για την ανάλυση και τον χαρακτηρισμό των συστημάτων που παρουσιάζουν **χαοτικό τρόπο εξέλιξης στον χρόνο**. Η πιο κλασική από τις εφαρμογές αυτού του είδους, συνίσταται στην πρόβλεψη της τρέχουσας τιμής κάποιας χρονοσειράς, με βάση τις προγενέστερες τιμές, και δια της χρήσης δομών νευρωνικών δικτύων (Patterson et al., 1993 & Dorffner, 1996). Σε άλλες πάλι περιπτώσεις τα νευρωνικά δίκτυα χρησιμοποιούνται για τον υπολογισμό χαρακτηριστικών παραμέτρων των χαοτικών συστημάτων, όπως είναι οι ελκυστές Lorenz, οι εκθέτες Lyapunov (Μάργαρης, 2003; Margaritis et al., 2001) και πάσης φύσεως κλασματικές διαστάσεις που περιγράφουν ένα χαοτικό ελκυστή. Τέλος τα νευρωνικά δίκτυα βρίσκουν ευρεία εφαρμογή σε μια μεγάλη κατηγορία πρακτικών προβλημάτων που σχετίζονται με χαοτικά συστήματα, με κλασικό παράδειγμα τον έλεγχο και τον συγχρονισμό τους (Alsing et al., 1994; Bakker et al., 1996; Iplikci & Denizhan, 2003).

Από την άλλη πλευρά τα ίδια τα νευρωνικά δίκτυα ως μη γραμμικά συστήματα, παρουσιάζουν και αυτά χαοτικά χαρακτηριστικά, η μελέτη των οποίων αποτελεί αντικείμενο συστηματικής ερευνητικής δραστηριότητας τα τελευταία χρόνια (Hendin et al., 1991; Albers et al., 1998). Τυπική κατηγορία δικτύων τα οποία εμφανίζουν χαοτική συμπεριφορά, είναι τα επανατροφοδοτούμενα δίκτυα (recurrent networks) (Pasemann, 1997), ενώ ανάλογα χαρακτηριστικά περιγράφουν και πολλούς άλλους τύπους νευρωνικών δικτύων. Η μελέτη των εν λόγω δικτύων από αυτή την οπτική γωνία, συνίσταται στην ταυτοποίηση και καταμέτρηση των δεικτών χαοτικής συμπεριφοράς, στη μελέτη του μηχανισμού μετάβασης αυτών των μοντέλων στη χαοτική περιοχή και γενικότερα, στην ανάλυση των χαοτικών τους χαρακτηριστικών.


Παρακάτω, ακολουθούν εφαρμογές των Τεχνητών Νευρωνικών Δικτύων (ANN) και παραδείγματα τόσο από την Ελλάδα, όσο και από το εξωτερικό, κυρίως από Μεσογειακές χώρες, που υποφέρουν από ξηρασία. Οι Aksoy & Dahamsheh (2009), εφάρμοσαν ένα μοντέλο Τεχνητών Νευρωνικών Δικτύων για την πρόβλεψη των μηνιαίων κατακρημνισμάτων σε ξηρές και ημίξηρες περιοχές. Ως περιοχή μελέτης επιλέχθηκε η Ιορδανία, χώρα της Μέσης Ανατολής με έκταση 90.000 km² και με έντονα φαινόμενα ανομβρίας, λειψυδρίας και ανισοκατανομής των κατακρημνισμάτων στο χώρο και το χρόνο. Οι Diamantopoulou et al. (2006) εφάρμοσαν τρία μοντέλα Τεχνητών Νευρωνικών Δικτύων με χρονοκαθυστέρηση (TDANN), με σκοπό την πρόβλεψη της ημερήσιας παροχής κατάντη του ΥΗΣ Ιλαρίωνα στον ποταμό Αλιάκμονα, υπολεκάνη του οποίου αφορά και την παρούσα εργασία για τα δεδομένα του Βροχομετρικού Σταθμού Νεστορίου. Οι Kostopoulou et al. (2007) εφάρμοσαν ένα μοντέλο προσομοίωσης των μέγιστων και ελάχιστων τιμών της θερμοκρασίας στην ελληνική επικράτεια. Εφαρμόστηκε για τις τέσσερις συμβατικές εποχές του έτους και χρησιμοποιήθηκαν τρεις αλγόριθμοι καταβιβασμού και συγκεκριμένα α) η πολλαπλή γραμμική παλινδρόμηση με τη χρήση της προσέγγισης τύπου «circulation», β) η κανονική ανάλυση συσχέτισης, γ) τα Τεχνητά Νευρωνικά Δίκτυα (ANN). Οι Tolika et al. (2007) ανέπτυξαν μία τεχνική καταβιβασμού βασισμένη σε Τεχνητά Νευρωνικά Δίκτυα (ANN) με σκοπό την εκτίμηση των τοπικών μεταβολών στις εποχιακές διακυμάνσεις των κατακρημνισμάτων και των ημερών βροχόπτωσης σε επιλεγμένους σταθμούς από την ελληνική επικράτεια. Οι Koutsoyiannis et al. (2008), σύγκριναν στοχαστικές και ντετερμινιστικές μεθόδους για να προβλέψουν την παροχή στον ποταμό Νείλο. Οι παρατηρήσεις που χρησιμοποιήθηκαν χαρακτηρίζονται ως επαρκείς για την κατανόηση των υδρολογικής του διαίτας, λόγω των πολλών ετών καταγραφής. Από τις ντετερμινιστικές μεθόδους, χρησιμοποιήθηκαν α) ένα τοπικό μη

γραμμικό χαστικό μοντέλο και β) ένα μοντέλο Τεχνητών Νευρωνικών Δικτύων (ANN). Τέλος οι Kourakos & Mantoglou (2009) εφάρμοσαν έναν επαναστατικό αλγόριθμο κατά τον οποίο αριθμός νευρωνικών υποδικτύων εφαρμόστηκε για την βελτιστοποίηση της άντλησης σε παράκτιο υδροφορέα. Αυτός ο διαχωρισμός σε πολλά υποδίκτυα έγινε για να αντιμετωπιστεί το πλήθος των μεταβλητών απόφασης οι οποίες δημιουργούν πολυπλοκότητα και δυσκολία στην εκπαίδευση του δικτύου.

2. ΤΟ ΜΑΘΗΜΑΤΙΚΟ ΜΟΝΤΕΛΟ

2.1 Γενικά

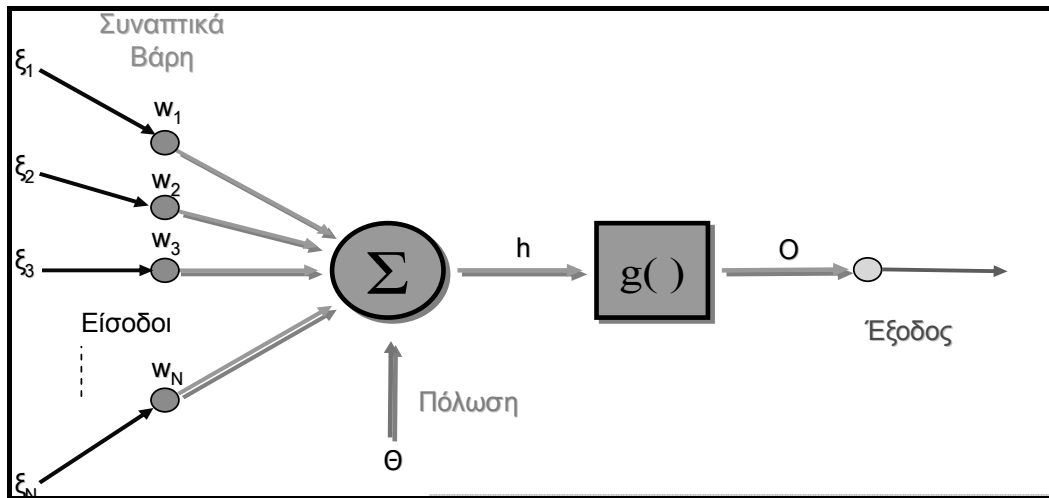
Από την επιστήμη της Βιολογίας είναι γνωστό πως βασική μονάδα του ανθρώπινου εγκεφάλου είναι ένας ειδικός τύπος κυττάρου που ονομάζεται νευρώνας (neuron). Αυτό το κύτταρο θεωρείται ως βασικό στοιχείο επεξεργασίας της πληροφορίας και η κεντρική του λειτουργία συνίσταται στη λήψη της κατάλληλα διαμορφωμένης εισόδου (σε μορφή ηλεκτρικού παλμού) και στην εκπομπή της εξόδου του, διαδικασία η οποία λαμβάνει χώρα, όταν η συνολική είσοδος του νευρώνα ξεπεράσει κάποια οριακή τιμή που λέγεται τιμή κατωφλίου (threshold value). Αυτή η έξοδος που εκπέμπεται από τον κάθε νευρώνα διαβιβάζεται ως είσοδος στους γειτονικούς νευρώνες, δια μέσου ειδικών αγωγών επικοινωνίας οι οποίοι ονομάζονται συνάψεις (synapses) (Σχήμα 1). Οι νευρώνες δε λειτουργούν από μόνοι τους αλλά συμμετέχουν σε μεγαλύτερες ομάδες νευρώνων οι οποίες είναι γνωστές με το όνομα Νευρωνικά Δίκτυα (Neural Networks), (Haykin, 1994).



Σχήμα 1 Τυπικό σχήμα ενός Βιολογικού Νευρωνικού Δικτύου (Κοτοπούλη, 2007)

Λόγω της εξαιρετικής σπουδαιότητας που παρουσιάζουν οι δομές νευρωνικών δικτύων, έχουν αποτελέσει αντικείμενο εντατικής ερευνητικής δραστηριότητας κατά την διάρκεια των τελευταίων δεκαετιών. Ωστόσο, λόγω της εξαιρετικής πολυπλοκότητας που τα χαρακτηρίζει, η μελέτη τους λαμβάνει χώρα δια της χρήσης ειδικών δομών οι οποίες προσομοιώνουν την λειτουργία των βιολογικών νευρωνικών δικτύων και οι οποίες ονομάζονται Τεχνητά Νευρωνικά Δίκτυα – ΤΝΔ (Artificial Neural Networks – ANNs). Η δομική μονάδα αυτών των δομών προσομοίωσης είναι


αντίστοιχα ο τεχνητός νευρώνας, η βασική δομή του οποίου παρουσιάζεται στο Σχήμα 2.



Σχήμα 2 Είσοδοι και έξοδος ενός τεχνητού νευρώνα (Κοτοπούλη, 2007)

Από το Σχήμα 2, διαπιστώνεται πως η βασική λειτουργία του τεχνητού νευρώνα περιλαμβάνει τη λήψη N εισόδων ξ_i , τον πολλαπλασιασμό τους με αντίστοιχα βάρη w_i , την επεξεργασία τους σύμφωνα με το μοντέλο που θα παρουσιαστεί στην συνέχεια και την απόδοση μίας και μοναδικής εξόδου με τη βοήθεια της συνάρτησης ενεργοποίησης g . Σε όλες σχεδόν τις περιπτώσεις ο νευρώνας δεν λειτουργεί από μόνος του, αλλά συμμετέχει σε ένα μεγαλύτερο νευρωνικό δίκτυο και συνεργάζεται με άλλους νευρώνες. Αυτό σημαίνει πως οι N εισοδοί που διαβιβάζονται στο νευρώνα, $\xi_1, \xi_2, \dots, \xi_N$, αποτελούν την έξοδο κάποιων άλλων νευρώνων, με την ανταλλαγή πληροφορίας ανάμεσα στους νευρώνες να γίνεται δια του μηχανισμού των συνάψεων. Με τον ίδιο ακριβώς τρόπο, η τιμή που υπολογίζεται στην έξοδο του νευρώνα, αποτελεί τιμή εισόδου για άλλους νευρώνες οι οποίοι βρίσκονται στην άμεση γειτονιά του.

Στις πιο συνηθισμένες περιπτώσεις ΤΝΔ οι νευρώνες είναι οργανωμένοι σε επίπεδα, εκ των οποίων το πρώτο το οποίο δέχεται την πληροφορία εισόδου είναι γνωστό ως επίπεδο εισόδου (input layer), το τελευταίο το οποίο επιστρέφει την έξοδο του δικτύου στο εξωτερικό περιβάλλον είναι γνωστό ως επίπεδο εξόδου (output layer), ενώ υπάρχει και ένας αριθμός ενδιάμεσων επιπέδων που ονομάζονται κρυφά επίπεδα (hidden layers) και άγουν την πληροφορία που κινείται μέσα στο δίκτυο, από το επίπεδο εισόδου προς το επίπεδο εξόδου. Στις πιο πολλές περιπτώσεις, το πλήθος των νευρώνων που θα τοποθετηθούν στα επίπεδα εισόδου και εξόδου, καθορίζεται μονοσήμαντα από τη φύση και τη διαμόρφωση των δεδομένων που θα χρησιμοποιηθούν κατά την διάρκεια της εκπαίδευσης του δικτύου. Ωστόσο το πλήθος και η δομή των κρυφών επιπέδων δεν υπαγορεύονται από κάποιους κανόνες, αλλά αποτελούν αντικείμενο πειραματικής μελέτης και εξαρτώνται άμεσα από την φύση του προβλήματος. Στο Σχήμα 3, παρουσιάζεται μία τυπική πολυεπίπεδη δομή νευρωνικού δικτύου, με συνάψεις των νευρώνων να κατευθύνονται από το επίπεδο εισόδου προς το επίπεδο εξόδου, χωρίς να επιστρέφουν προς τα πίσω. Τα δίκτυα αυτού του τύπου, ονομάζονται δίκτυα εμπρόσθιας διάδοσης (feedforward neural networks).



Σχήμα 3. Η οργάνωση των νευρώνων σε επίπεδα, όπου κάθε νευρώνας του ενός επιπέδου, συνδέεται με όλους τους νευρώνες του άλλου επιπέδου (full connections)

Όπως φαίνεται από τα Σχήματα 2 και 3, στην γενική περίπτωση ο νευρώνας δέχεται N εισόδους και παράγει πάντοτε μία έξοδο. Θεωρώντας πως ο νευρώνας ανήκει σε κάποιο από τα ενδιάμεσα στρώματα του δικτύου, είναι προφανές πως αυτές οι εισοδοί προέρχονται από τους νευρώνες των προηγούμενων επιπέδων, οι οποίοι συνδέονται με αυτό τον νευρώνα δια μέσου των συνάψεων. Σε κάθε μία από τις N εισόδους ξ_i – ή ισοδύναμα σε κάθε σύναψη – αντιστοιχεί ένα βάρος (weight) w_i που εκφράζει το ποσοστό κατά το οποίο η εν λόγω είσοδος συνεισφέρει στη ολική είσοδο του νευρώνα. Αυτό σημαίνει πως η συνολική είσοδος που διαβιβάζεται σε αυτό τον νευρώνα, θα είναι ίση με το εσωτερικό γινόμενο:

$$\vec{\xi} \cdot \vec{w} = \sum_{i=1}^N \xi_i w_i \quad (1)$$

όπου

$i = 1, \dots, N$ είναι ο αριθμός των εισόδων

$\vec{\xi} = \{\xi_1, \xi_2, \dots, \xi_N\}$ είναι το διάνυσμα των εισόδων και

$\vec{w} = \{w_1, w_2, \dots, w_N\}$ είναι το αντίστοιχο διάνυσμα των βαρών.

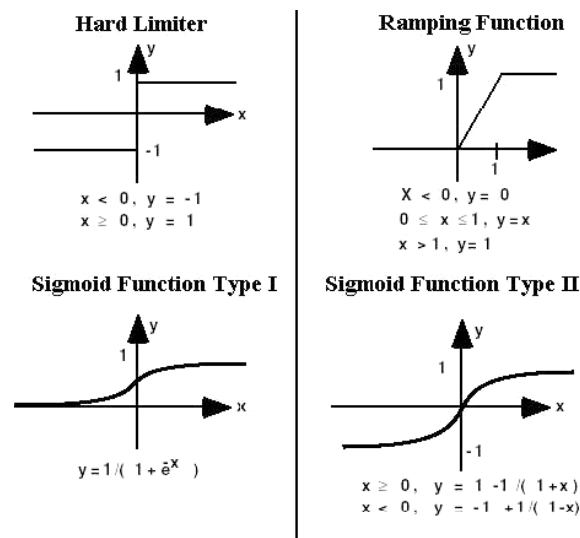
Από αυτή την συνολική τιμή εισόδου, θα πρέπει στη συνέχεια να αφαιρεθεί η τιμή του κατωφλίου (threshold value) θ , η οποία σε πλήρη αναλογία με το βιολογικό νευρώνα, επιτρέπει την ενεργοποίησή του (δηλαδή την παραγωγή της εξόδου από αυτόν), μόνο όταν ισχύει η ανισότητα:

$$h = \vec{\xi} \cdot \vec{w} - \theta > 0 \quad (2)$$

Τέλος, η πραγματική έξοδος του νευρώνα, προκύπτει διαβιβάζοντας την τιμή της μεταβλητής h σε μία συνάρτηση ενεργοποίησης (activation function) $g = g(h)$, η οποία, ανάλογα με την εφαρμογή μας μπορεί να είναι γραμμική ή μη γραμμική. Επομένως η πραγματική έξοδος του νευρώνα σε συνάρτηση με τις τιμές των εισόδων και των βαρών των συνάψεων που συσχετίζονται με αυτόν, θα δίδεται από τη σχέση:

$$\text{Output} = g\left(\sum_{i=1}^N \xi_i w_i - \theta\right) \quad (3)$$

Όσον αφορά την συνάρτηση ενεργοποίησης, $g(h)$, αυτή μπορεί να επιλεγεί μέσα από μια μεγάλη οικογένεια συναρτήσεων, όπως είναι η συνάρτηση βήματος, η ταυτοτική συνάρτηση, η σιγμοειδής και η συνάρτηση της υπερβολικής εφαπτομένης. Από αυτές τις συναρτήσεις, εκείνη που χρησιμοποιείται στην πλειοψηφία των περιπτώσεων, είναι η σιγμοειδής καμπύλη, της οποίας η έξοδος, ανάλογα με τον τύπο της συνάρτησης που έχει επιλεγεί, ανήκει στο διάστημα $[0,1]$ ή στην περιοχή τιμών $[-1,1]$. Οι γραφικές παραστάσεις τυπικών συναρτήσεων ενεργοποίησης των τεχνητών νευρώνων, παρουσιάζονται στο Σχήμα 4 (Anderson & McNeil, 1992).




Σχήμα 4 Τυπικές συναρτήσεις ενεργοποίησης τεχνητών νευρώνων

2.2 Τα επανατροφοδοτούμενα (recurrent) νευρωνικά δίκτυα

Προχωρώντας στα Επανατροφοδοτούμενα Νευρωνικά Δίκτυα (Recurrent Neural Network), σκόπιμο είναι να αναλυθούν κάποια απλά κατασκευαστικά κομμάτια. Το πρώτο είναι το κομμάτι καθυστέρησης (Delay Block), το οποίο εικονίζεται στο Σχήμα 5. Η έξοδος καθυστέρησης $a(t)$ υπολογίζεται από την είσοδο $u(t)$ σύμφωνα με τη σχέση:

$$a(t) = u(t-1) \quad (4)$$

Έτσι η έξοδος, είναι η είσοδος καθυστερημένη κατά ένα χρονικό βήμα. Αυτό προϋποθέτει ότι ο χρόνος είναι εκσυγχρονισμένος σε διακριτά βήματα και παίρνει μόνο ακέραιες τιμές). Η συνάρτηση (4) απαιτεί η έξοδος αρχικά να είναι σε χρόνο $t = 0$. Αυτή η πρώτη συνθήκη φαίνεται στο Σχήμα 5 από το εισερχόμενο βέλος στην βάση του κομματιού καθυστέρησης. Ένα άλλο κατασκευαστικό κομμάτι, το οποίο χρησιμοποιείται για τα συνεχούς χρόνου ανατροφοδοτούμενα δίκτυα, είναι το ενοποιημένο (the integrator block) το οποίο φαίνεται στο Σχήμα 6.



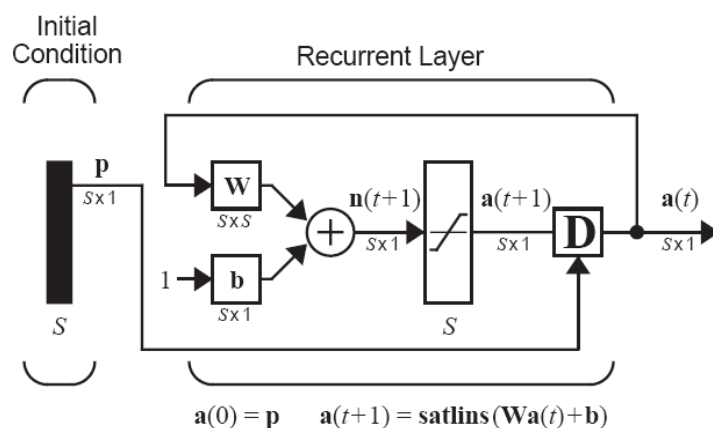
Σχήμα 5 Κομμάτι καθυστέρησης Delay Block (Demuth & Beale, 2002)

Σχήμα 6 Ολοκληρωμένο κομμάτι Integrated Block (Demuth & Beale, 2002)

Η ενοποιημένη έξοδος $a(t)$ υπολογίζεται από την είσοδο $u(t)$ σύμφωνα με την εξίσωση:

$$a(t) = \int_0^t u(t)dt + a(0) \tag{5}$$

Η αρχική συνθήκη $a(0)$ εικονίζεται με το βέλος να εισέρχεται στην βάση του Integrator Block. Με βάση τα παραπάνω, προκύπτει ότι βασικό χαρακτηριστικό των επανατροφοδοτούμενων δικτύων είναι η μεταβολή της κατάστασής τους σε συνάρτηση με τον χρόνο, η οποία ανάλογα με τις τιμές των παραμέτρων του προβλήματος μπορεί να είναι συγκλίνουσα, περιοδική ή χαοτική. Κάποιες από τις εξόδους του δικτύου αυτού, είναι συνδεδεμένες με τις εισόδους του. Αυτή είναι και η ειδοποιός διαφορά σε σχέση με τα αυστηρά εμπρός τροφοδοτούμενα δίκτυα χωρίς προς τα πίσω συνδέσεις. Ένας τύπος διακριτού χρόνου ανατροφοδοτούμενου δικτύου (discrete time recurrent network) απεικονίζεται στο Σχήμα 7.



Σχήμα 7 Recurrent Network (Demuth & Beale, 2002)

Στο δίκτυο αυτό, ο παράγοντας p τροφοδοτεί τις αρχικές συνθήκες $a(0) = p$. Στην συνέχεια μελλοντικές έξοδοι του δικτύου υπολογίζονται από προηγούμενες εξόδους:

$$a(1) = \text{satlins} \{Wa(0) + b\}, a(2) = \text{satlins} \{Wa(1) + b\}, \dots, \kappa.ο.κ.$$

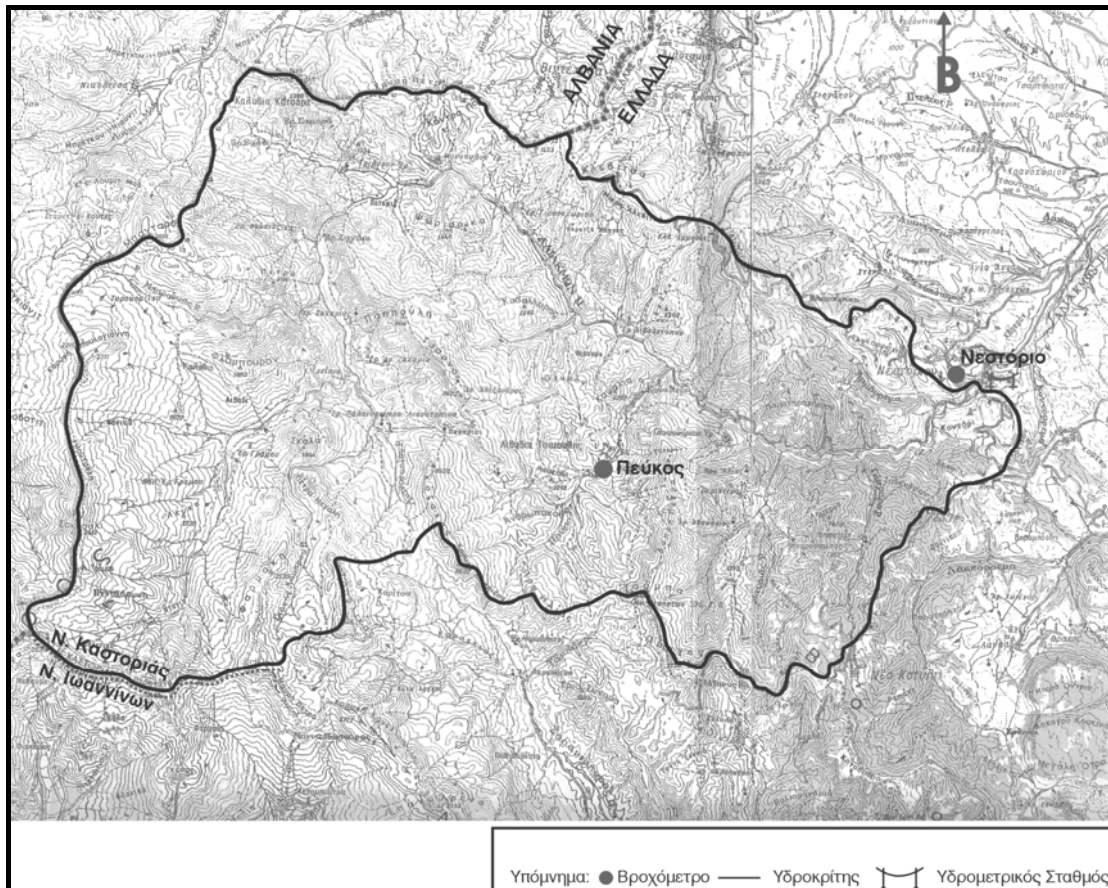
όπου η λέξη «satlins», είναι η συντομογραφία των λέξεων Saturating Linear Transfer Function. Τα Επανατροφοδοτούμενα Δίκτυα είναι εν δυνάμει πιο αποτελεσματικά από τα Εμπρός Τροφοδοτούμενα Δίκτυα.

3. ΠΕΡΙΟΧΗ ΜΕΛΕΤΗΣ – ΕΦΑΡΜΟΓΗ

Το ανατροφοδοτούμενο νευρωνικό δίκτυο εφαρμόστηκε σε μία χρονοσειρά κατακρημνισμάτων, του βροχομετρικού σταθμού Νεστορίου Καστοριάς και για 41 έτη (1962 – 2003) συνεχών μηνιαίων παρατηρήσεων. Τα δεδομένα αυτά ελήφθησαν από μελέτη που χρηματοτήθηκε από την Νομαρχιακή Αυτοδιοίκηση Καστοριάς (Μαυρονικολάου κ.α., 2004). Ο σταθμός αυτός βρίσκεται στη λεκάνη απορροής του ποταμού Αλιάκμονα στην θέση Νεστόριο του Νομού Καστοριάς και σε υψόμετρο 850 m. Στη συγκεκριμένη αυτή θέση, πρόκειται να κατασκευαστεί φράγμα από τη ΔΕΗ. Η λεκάνη απορροής του φράγματος, είναι υπολεκάνη του δυτικού κλάδου του ποταμού Αλιάκμονα και βρίσκεται στο δυτικότερο άκρο της Μακεδονίας, στην ανατολική πλευρά του όρους Γράμμου και σε γεωγραφική θέση του κέντρου βάρους της 20°53' Α.Γ.Μ. & 40°25' Β.Γ.Π. περίπου. Έχει σχήμα τραπεζοειδές, με την μεγάλη βάση στο δυτικό άκρο της, κατά μήκος των Ελληνοαλβανικών συνόρων, την μικρή δε βάση στο ανατολικό άκρο της, νοτίως του Νεστορίου όπου βρίσκεται και το στόμιο της λεκάνης σε υψόμετρο περίπου 850 m. Στη θέση αυτή υπάρχει υδρομετρικός σταθμός της ΔΕΗ, εξοπλισμένος με σταθμήμετρα, σταθμηγράφο και μόνιμη εγκατάσταση για την μέτρηση της παροχής.

Από το σημείο αυτό ξεκινά ο υδροκρίτης ο οποίος διανύμενος με φορά δεξιόστροφη, ανεβαίνει προς το Βόιο όρος στα Νότια μέχρι το υψόμετρο (+1500 μ.) περίπου παρά την Νέα Κοτύλη, ακολουθώντας περίπου το ίχνος της οδού που την συνδέει με το Νεστόριο. Από εκεί στρέφεται προς Δυσμάς και περνά από τα υψώματα Πύργος (+1758 μ.), Τούμπα (+1644 μ.) και Κορυφή Μπαρίκου (+1632 μ.). Από το σημείο αυτό, συνεχίζοντας την προς Δυσμάς πορεία του, ο υδροκρίτης ανεβαίνει σε ακόμα μεγαλύτερα υψόμετρα (Σουφλίκας +2146 μ., Περήφανο +2442 μ.), μέχρι να συναντήσει την κορυφογραμμή του Γράμμου στο +2520 μ. που είναι και το μεγαλύτερο υψόμετρο της λεκάνης. Συνεχίζοντας με προσανατολισμό Βόρειο, ο υδροκρίτης ακολουθεί τα σύνορα σε υψόμετρα πάνω από +2100 μ., μέχρι την Κορυφή Μπουλογιάννη (+2251 μ.). Από εκεί αλλάζει διεύθυνση σε ΒΑ μέχρι τα Καλύβια Κατσάρα (+1495 μ.) όπου στρέφεται προς τα ανατολικά, συνέχεια πάνω στη συνοριακή γραμμή. Στο ύψωμα Χελώνα (+1423 μ.) ο υδροκρίτης στρεφόμενος προς τα ΝΑ εγκαταλείπει τη συνοριακή γραμμή και περνώντας από τα υψώματα Αλεβίτσα (+1585 μ.), Αμμούδα (+1546 μ.), Καλλιθέα (+1200 μ.) και Δίδυμο (+1120 μ.), κατηφορίζει προς το στόμιο της λεκάνης (Μαυρονικολάου κ.α., 2004).

Η συνολική λεκάνη που φαίνεται στο χάρτη (Σχήμα 8) έχει έκταση 255,3 km² και μέσο υψόμετρο 1398 m. Το υδρογραφικό δίκτυο είναι πολύ αναπτυγμένο, 6^{ης} τάξεως και πυκνό σε όλη την λεκάνη. Το μήκος του κύριου κλάδου είναι περίπου 41,9 km από το στόμιο της λεκάνης μέχρι το απώτατο σημείο του υδροκρίτη. Η μέση κλίση του κυρίως ρεύματος (μετρημένη ανάμεσα στο 10% και στο 85% του μήκους του) είναι ίση προς 2,23 %.



Σχήμα 8 Χάρτης απεικόνισης της συνολικής λεκάνης απορροής (Μαυρονικολάου κ.α., 2004, τροποποιημένο από Κοτοπούλη, 2007)

Στην ευρύτερη περιοχή μελέτης, το βροχομετρικό δίκτυο είναι επαρκές. Πληροφορίες περί των σταθμών που συγκροτούν το βροχομετρικό δίκτυο αναφορικά με την περίοδο λειτουργίας τους, το είδος των οργάνων, το υψόμετρο τοποθέτησής τους και τέλος, τον Φορέα κτήσης δίνονται στον πίνακα που ακολουθεί.

Πίνακας 1 Χαρακτηριστικά των βροχομετρικών σταθμών


Όνομα/θέση σταθμού	Είδος οργάνου	Περίοδος λειτουργίας	Υψόμετρο (m)	Φορέας
Πεύκος	Βγ	1965 – 1978	980	ΔΕΗ
	ΟΒΧμ	1978 – σήμερα		
Νεστόριο	Βγ	1951 – σήμερα	850	ΙΔΕ, ΔΕΗ
Δαμασκησιά	Βγ	1962 – σήμερα	990	ΔΕΗ
Μεσοποταμία	Βγ	1962 – σήμερα	695	ΔΕΗ
Άργος Ορεστικό	Βγ	1962 – 1994	650	ΔΕΗ
	Βμ	1995 – σήμερα		
Δροσοπηγή	Βγ	1980 - σήμερα	1055	ΔΕΗ

Όπου: Βγ→ βροχογράφος, ΟΒΧμ→ ομβροχιονόμετρο, Βμ→βροχόμετρο

Η συγκεκριμένη χρονοσειρά που χρησιμοποιήθηκε, επιλέχθηκε γιατί αποτελείται από ένα σύνολο από συνεχείς μετρήσεις με σημαντικό χρονικό μήκος κατάλληλο για την ανάπτυξη μοντέλων χρονικών σειρών. Τα πλήρη δεδομένα της σειράς δίνονται στον Πίνακα 2, ενώ στο Σχήμα 9, δίνεται η γραφική παράσταση της σειράς.

Πίνακας 2. Μηνιαία ύψη βροχής βροχομετρικού σταθμού Νεστορίου Καστοριάς

Υδρ. Έτος	ΟΚΤ	ΝΟΕ	ΔΕΚ	ΙΑΝ	ΦΕΒ	ΜΑΡ	ΑΠΡ	ΜΑΙ	ΙΟΥΝ	ΙΟΥΛ	ΑΥΓ	ΣΕΠ	ΕΤΟΣ
62-63	91,0	114,0	58,0	75,0	122,0	96,0	62,0	107,0	60,0	42,0	22,0	22,0	871,0
63-64	131,0	53,0	134,0	23,0	24,0	48,0	17,0	88,0	63,0	42,0	12,0	31,0	666,0
64-65	34,0	164,0	118,0	56,0	80,0	58,0	60,0	28,0	9,0	14,0	7,0	4,0	632,0
65-66	2,0	70,0	96,0	83,0	39,0	62,0	38,0	23,0	25,0	9,0	15,0	82,0	544,0
66-67	76,0	216,0	130,0	97,0	19,0	25,0	40,0	58,0	27,0	117,0	29,0	46,0	880,0
67-68	44,0	57,0	135,0	26,0	26,0	44,0	24,0	87,0	46,0	0,0	30,0	38,0	557,0
68-69	40,0	41,0	80,0	108,0	73,0	78,0	34,0	15,0	2,0	9,0	15,0	62,0	557,0
69-70	3,0	49,0	246,0	77,0	80,0	82,0	63,0	47,0	37,0	44,0	5,0	16,0	749,0
70-71	11,0	31,0	81,0	71,0	64,0	115,0	37,0	31,0	57,0	67,0	36,0	110,0	711,0
71-72	38,0	76,0	78,0	125,0	72,0	54,0	118,0	45,0	8,0	121,0	90,0	27,0	852,0
72-73	172,0	0,0	5,0	34,0	97,0	108,0	14,0	30,0	36,0	95,0	19,0	61,0	671,0
73-74	73,0	50,0	74,0	58,0	130,0	41,0	101,0	32,0	40,0	28,0	17,0	41,0	685,0
74-75	115,0	114,0	47,0	14,0	79,0	80,0	51,0	83,0	103,0	34,0	19,0	12,0	751,0
75-76	92,0	59,0	71,0	28,4	67,0	35,5	68,0	68,5	83,5	22,6	43,2	13,5	652,2
76-77	43,8	98,3	122,0	43,7	62,1	12,3	28,8	32,6	38,9	0,0	63,2	57,0	602,7
77-78	21,2	105,0	61,8	104,0	47,2	75,9	117,0	41,5	17,8	2,5	7,0	88,4	689,3
78-79	78,6	41,7	110,0	168,0	69,6	34,5	125,0	86,4	35,6	3,3	41,8	7,3	801,8
79-80	107,0	269,0	126,0	92,4	43,6	81,1	44,2	116,0	39,9	2,7	30,7	33,0	985,6
80-81	181,0	111,0	156,0	107,0	66,0	41,1	69,5	58,9	6,9	23,3	103,0	76,5	1000,2
81-82	130,0	98,6	152,0	25,8	50,2	107,0	151,0	77,4	10,6	14,5	104,0	71,8	992,9
82-83	96,3	138,0	117,0	35,5	63,0	50,5	27,3	112,0	104,0	54,1	39,5	79,0	916,2
83-84	37,2	109,0	231,0	97,6	132,0	70,2	95,5	15,6	17,5	1,1	34,5	25,8	867,0
84-85	20,0	62,0	47,0	124,0	40,5	75,5	116,0	73,5	6,0	5,0	0,0	10,0	579,5
85-86	47,0	198,0	40,0	94,0	171,0	54,5	36,5	171,0	101,0	30,0	9,0	13,0	965,0
86-87	66,0	84,0	60,7	131,0	97,0	149,0	47,5	44,0	16,5	34,0	30,5	22,0	782,2
87-88	126,0	112,0	49,0	42,5	48,0	60,0	48,0	14,1	26,0	4,0	9,6	36,4	575,6
88-89	46,0	152,0	108,0	1,8	59,0	46,0	15,5	87,0	15,5	117,0	27,5	18,5	693,8
89-90	97,0	100,5	116,0	0,3	25,5	6,0	55,0	95,0	10,0	17,5	40,0	22,0	584,8
90-91	36,5	144,0	184,5	38,0	136,5	34,0	176,0	85,0	13,0	38,5	53,0	24,0	963,0
91-92	34,0	118,0	30,0	19,5	5,5	15,0	128,5	74,0	87,0	83,5	1,5	21,0	617,5
92-93	131,0	49,5	105,0	89,0	70,0	95,0	44,0	41,0	40,0	0,0	46,0	21,0	731,5
93-94	61,0	188,0	88,0	126,0	159,0	33,0	77,0	26,0	8,0	89,0	15,0	8,0	878,0
94-95	84,0	63,0	103,0	167,0	58,5	107,5	39,0	89,0	13,0	81,0	122,0	45,5	972,5
95-96	0,0	82,5	164,0	65,0	105,0	89,0	28,0	68,0	13,0	57,0	33,0	100,0	804,5
96-97	77,3	85,5	149,1	48,3	27,6	57,4	83,2	7,3	18,2	20,6	24,8	5,9	605,2
97-98	200,8	86,8	118,1	38,2	72,3	43,5	27,3	131,6	24,5	10,6	27,0	116,9	897,6
98-99	75,7	224,3	98,4	87,1	117,2	120,2	44,9	8,9	14,3	76,8	23,3	43,3	934,4
99-00	37,0	215,9	120,0	52,7	126,1	68,6	21,6	78,5	18,1	11,2	5,4	16,2	771,3
00-01	58,4	46,5	31,3	102,7	43,5	10,0	76,0	21,4	16,8	45,3	27,4	30,4	509,7
01-02	14,8	59,2	153,6	31,5	31,5	137,8	118,3	65,2	36,0	87,2	46,1	197,2	978,4
02-03	70,1	26,7	291,2	158,1	110,0	21,1	60,4	44,7	34,2	3,6	55,7	53,6	929,4



Σχήμα 9 Γραφική απεικόνιση των τιμών της χρονοσειράς των υψών βροχής.

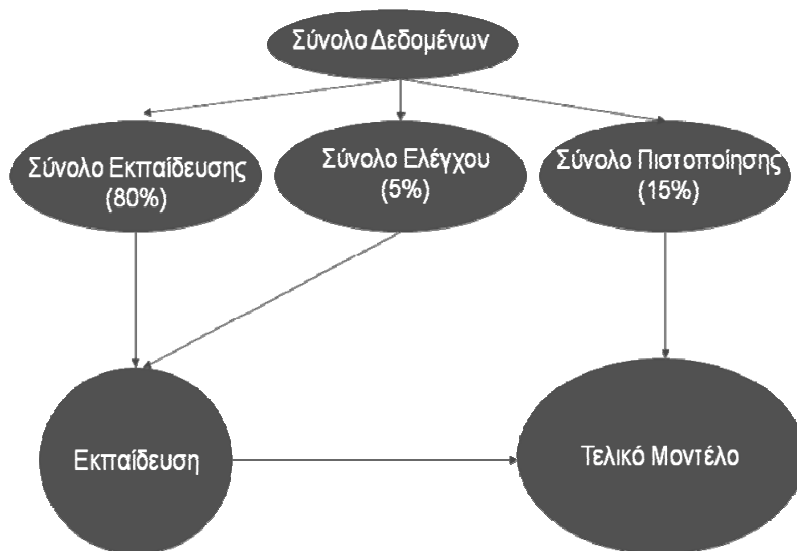
Το τελικό προτεινόμενο μοντέλο, το οποίο είναι αποτέλεσμα μιας σειράς δοκιμών, υιοθετήθηκε γιατί μας έδωσε την καλύτερη προσαρμογή στα δεδομένα (μικρότερο τυπικό σφάλμα). Συγκεκριμένα, η τελική τοπολογία που διαμορφώθηκε ήταν ένα (12,5,3,1) επανατροφοδοτούμενο δίκτυο το οποίο περιελάμβανε 12 κόμβους εισόδου που αποτελούν τους 12 προηγούμενους μήνες της βροχόπτωσης, ένα κόμβο εξόδου που αποτελεί τη βροχόπτωση του μήνα αναφοράς και δύο κρυφά επίπεδα 5 και 3 κόμβων αντίστοιχα.

Σε ότι αφορά το χωρισμό του συνολικού δείγματος μετρήσεων – παρατηρήσεων, αυτός έγινε σε τρία υποσύνολα, ως εξής:

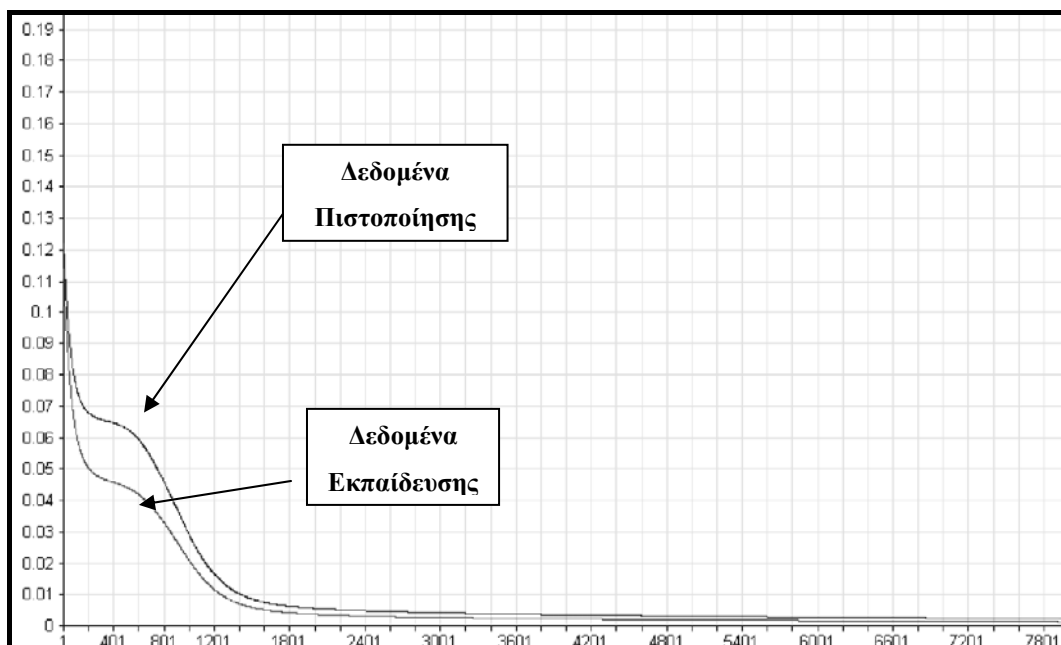
- 1) Το πρώτο υποσύνολο, αποτελεί το 80% του συνολικού δείγματος και είναι το δείγμα εκπαίδευσης (training sample) το οποίο περιελάμβανε και ακραίες τιμές για την εκτίμηση της βαρύτητας των κόμβων με τη μεγαλύτερη δυνατή γενίκευση,
- 2) Το δεύτερο υποσύνολο, αποτελεί το 5% του συνολικού δείγματος και είναι το δείγμα ελέγχου (testing sample) με το οποίο ελέγχεται η δυνατότητα του μοντέλου να προσομοιώνει τη χρονοσειρά της βροχόπτωσης πέρα από την περίοδο εκπαίδευσης και
- 3) Το τρίτο υποσύνολο, αποτελεί το 15% του συνολικού δείγματος (validation sample) Στην παρούσα εφαρμογή, το δεύτερο υποσύνολο, δηλαδή το δείγμα ελέγχου, αποτελεί τμήμα της διαδικασίας εκπαίδευσης (Σχήμα 10).

Σε ότι αφορά τα κριτήρια που διασφαλίζουν τη γενίκευση (μη υπερπροσαρμογή στο δείγμα εκπαίδευσης) και τη σύγκλιση του δικτύου (π.χ. αριθμός βαρών < πλήθος δεδομένων εκπαίδευσης, αρχικές τιμές βαρών, ρυθμός εκπαίδευσης (learning rate), μετάδοση ορμής (momentum transfer) < 1), παρουσιάζονται αναλυτικά στη βιβλιογραφία από τους Maier & Dandy (1998) και Dawson & Wilby (2001).

Το διάγραμμα εκπαίδευσης με το πλήθος των εποχών του μοντέλου δίνεται στο Σχήμα 11.




Σχήμα 10 Χωρισμός του συνολικού δείγματος παρατηρήσεων σε τρία υποσύνολα



Σχήμα 11 Διαδικασία εκπαίδευσης του τελικού δικτύου. Η προβλεπτική ικανότητα πιστοποιείται από τη σύγκλιση των δεδομένων εκπαίδευσης (training) και των δεδομένων πιστοποίησης (validation)

Στο Σχήμα 11, φαίνεται επίσης η δυνατότητα καλής προσαρμογής του μοντέλου στα δεδομένα λόγω της σύγκλισης των τιμών σφάλματος των δεδομένων εκπαίδευσης και των δεδομένων πιστοποίησης πράγμα που δηλώνει πως η ακρίβεια του μοντέλου θα είναι ίδια με την εκτιμώμενη όταν χρησιμοποιηθεί για πρόβλεψη σε νέες τιμές.

Το τελικό εκτιμώμενο σφάλμα RMSE, είναι ίσο με 0,94 και δίνει απόκλιση από τις μετρημένες τιμές της τάξης του ενός χιλιοστού βροχής, ενώ ο συντελεστής συσχέτισης R^2 είναι ίσος με 0,97. Η πλατφόρμα λογισμικού που χρησιμοποιήθηκε για την ανάπτυξη του μοντέλου ήταν το Neurosolution της εταιρείας Neurodimension (<http://www.nd.com>) το οποίο δίνει την δυνατότητα σύνθεσης ανατροφοδοτούμενων Νευρωνικών Μοντέλων. Στο Σχήμα 12, δίνονται από κοινού οι πραγματικές και οι προβλεπόμενες τιμές της χρονοσειράς των υψών βροχής και με βάση το σφάλμα και το συντελεστή συσχέτισης, κρίνονται πολύ ικανοποιητικές.



Σχήμα 12 Πραγματικές και προβλεπόμενες τιμές της χρονοσειράς των υψών βροχής για το τελικό μοντέλο του νευρωνικού δικτύου

4. ΑΠΟΤΕΛΕΣΜΑΤΑ – ΣΥΜΠΕΡΑΣΜΑΤΑ

Στην παρούσα εργασία παρουσιάστηκε η εφαρμογή ενός μοντέλου προσομοίωσης, βασισμένο στη δημιουργία και εκπαίδευση Ανατροφοδοτούμενων Τεχνητών Νευρωνικών Δικτύων – ΑΤΝΔ, με όσο το δυνατόν μικρότερη τιμή σφάλματος προσομοίωσης.

Ο περιορισμός της έρευνας συνίσταται, στην στενή θεματική περιοχή των μη γραμμικών συστημάτων. Η επιλογή αυτή δικαιολογείται από το γεγονός ότι, το ΤΝΔ στηρίχθηκε πάνω σε χρονοσειρές που προκύπτουν από τις καταγραφές υψών βροχής και οι οποίες χαρακτηρίζονται από πολύπλοκες φυσικές διεργασίες, επομένως ο πειραματικός χαρακτηρισμός τους εμπίπτει σε αυτόν τον χώρο.

Η χρονοσειρά επιλέχθηκε από τον χώρο της τεχνικής υδρολογίας και συγκεκριμένα από την υδρολογική μελέτη κατασκευής φράγματος, στο Νεστόριο του νομού Καστοριάς (Μαυρονικολάου κ.α., 2004).

Μετά από την ολοκλήρωση αυτής της αναζήτησής πάνω στα υδρολογικά δεδομένα της περιοχής μελέτης, κρίθηκε ως κατάλληλη χρονοσειρά για την εφαρμογή ενός μοντέλου με χρήση Τεχνητών Νευρωνικών Δικτύων, αυτή του βροχομετρικού σταθμού Νεστορίου που βρίσκεται σε υψόμετρο 850 m και μας δίνει καταγραφές μηνιαίων υψών βροχής για τα έτη από 1962 έως 2003. Η επιλογή αυτή στηρίχθηκε στο γεγονός ότι η χρονοσειρά αποτελείται από ένα σύνολο συνεχών μετρήσεων με σημαντικό χρονικό μήκος κατάλληλο για την ανάπτυξη μοντέλων χρονικών σειρών.

Το λογισμικό που χρησιμοποιήθηκε για την ανάπτυξη του μοντέλου ήταν το Neurosolution της εταιρίας Neurodimension (<http://www.nd.com>). Μετά από μια σειρά δοκιμών προέκυψε το τελικό μας προτεινόμενο μοντέλο, το οποίο είναι ένα επανατροφοδορούμενο δίκτυο (recurrent network) 12–5–3–1, αποτελούμενο δηλαδή από 12 κόμβους εισόδου, 1 κόμβο εξόδου και δύο κρυφά επίπεδα των 5 και 3 κόμβων αντίστοιχα και υιοθετήθηκε γιατί έδωσε το μικρότερο τυπικό σφάλμα (RMSE = 0,94) της τάξης του ενός χιλιοστού βροχής και συντελεστή συσχέτισης ($R^2 = 0,97$) και κρίνεται πολύ ικανοποιητικό.

Καταλήγοντας, μπορούν να σημειωθούν τα εξής:

- Το επιλεγμένο ΤΝΔ, προσομοιώνει την χρονοσειρά με αρκούντως ικανοποιητικό τρόπο.
- Η ανάπτυξη του μοντέλου είναι ανεξάρτητη από ενδεχόμενη ύπαρξη τάσης ή παραδοχές στασιμότητας.
- Το τελικό μοντέλο είναι μη ρητό και απαιτεί την υποστήριξη από κατάλληλο υπολογιστικό σύστημα.

Πρέπει να τονιστεί επίσης πως η προβλεπτική ικανότητα του μοντέλου είναι βραχεία και εκπορεύεται από τα δεδομένα εκπαίδευσης. Αυτό σημαίνει πως η αξιοπιστία του μοντέλου εξαντλείται σε ένα ή δύο χρονικά βήματα στο μέλλον. Κάθε φορά που μια νέα μέτρηση πραγματοποιείται το δίκτυο πρέπει να επανεκπαιδεύεται και να επαναπροσδιορίζονται οι τιμές των βαρών του w_i , ώστε να είναι αξιοποιήσιμο για νέα πρόβλεψη.

BIBΛΙΟΓΡΑΦΙΑ

- Albers D., Sprott J. & Dechert W., 1998. Routes to Chaos in Neural Networks with Random Weights, *International Journal of Bifurcation and Chaos*, Vol. 8, No.7, pp. 3017 – 3026.
- Anderson D. & Mc Neil G., 1992. Artificial Neural Networks Technology – a DACS State of the Art Report, On Line Paper, URL: <http://www.dacs.dtic.mil/techs/neural/>
- Alsing P, Gavrielides A, & Kovanis V, 1994. Using Neural Networks for Controlling Chaos, *Physical Review E*, Vol. 49, No. 2, pp. 1225–1231.
- Aksoy H. & Dahamsheh A., 2009. Artificial neural network models for forecasting monthly precipitation in Jordan. *Stochastic Environmental Research and Risk Assessment*. Vol. 23, No 7, pp. 917 – 931.
- Bakker R., Schouten J., Giles C., Takens F. & Van Den Bleek C., 2000. Learning Chaotic Attractors by Neural Networks Source. *Neural Computation*, Vol. 12, No 10, pp. 2355 – 2383.
- Dawson C. & Wilby R., 2001. Hydrological modeling using artificial neural networks, *Prog. Phys. Geog.*, Vol **25**, No 1, pp. 80–108.
- Demuth H. & Beale M., 2002. *Neural Network Toolbox for use with MATLAB. User's Guide*, Ver. 4, the Mathworks.
- Diamantopoulou M., Georgiou P. & Papamichail D., 2006. A Time Delay Artificial Neural Network approach for Flow Routing in a River System. *Hydrology and Earth System Sciences Discussions*, Vol. 3, pp. 2735 – 2756.
- Dorffner G., 1996. Neural Networks for Time Series Processing, *Neural Network World* 4/96, pp. 447 – 468.
- Haykin S, 1994. *Neural Networks – A comprehensive foundation*, Prentice Hall, ISBN 0-02-352761-7.
- Hendin O, Horn D & Usher M, 1991. Chaotic Behavior of a Neural Network with Dynamical Thresholds, *International Journal of Neural Systems*, Vol. 1, pp. 327–335.
- Iplikci S. & Denizhan Y., 2003. An improved Neural Network Based Targeting Method for chaotic dynamics, *Chaos, Solitons and Fractals*, Vol 17, No.2, pp 523–529(7).
- Kostopoulou E., Giannakopoulos C., Anagnostopoulou C., Tolika K., Maheras P., Vafiadis M. & Founda D., 2007. Simulation maximum and minimum temperature over Greece: a comparison of three downscaling techniques. *Theoretical and Applied Climatology*, Vol. 90, pp. 65 – 82.
- Κοτοπούλη Μ., 2007. Η χρήση των Νευρωνικών Δικτύων στην ανάλυση χρονοσειρών της βροχόπτωσης του βροχομετρικού σταθμού Νεστορίου. *Μεταπτυχιακή Διατριβή*,

- Εργαστήριο Πληροφορικής, Τμήμα Γεωπονίας Ιχθυολογίας & Υδάτινου Περιβάλλοντος, σελ. 180, Βόλος.
- Kourakos G. & Mantoglou A., 2009. Pumping Optimization of Coastal Aquifers Based on Evolutionary Algorithms and Surrogate Modular Neural Network Models, *Advances in Water Resources*, Vol. 32, pp. 507 – 521.
- Koutsoyiannis D., Yao H. & Georgakakos A., 2008. Medium – range flow prediction for the Nile: a comparison of stochastic and deterministic methods. *Hydrological Sciences – Journal des Sciences Hydrologiques*, Vol 53, Issue 1, pp. 142 – 164.
- Maier H. & Dandy G., 1998. The effect of internal parameters and geometry on the performance of back–propagation neural networks: an empirical study, *Environmental Modelling & Software*, Vol 13, No 2, 193–209.
- Margaris A., Roumeliotis M., & Adamopoulos M., 2001. Development of Neural Models for the Logistic Equation and Study of the Neural Based Trajectories in the Convergence, Periodic and Chaotic Regions, *Neural, Parallel & Scientific Computations*, Vol. 9, pp. 221-230.
- Μάργαρης Α., 2003. Νευρωνικά δίκτυα και χάος. Μελέτη και Προσομοίωση χαοτικών ελκυστών δια της χρήσεως Νευρωνικών Δικτύων. Διδακτορική Διατριβή, Τμήμα Εφαρμοσμένης Πληροφορικής, Πανεπιστήμιο Μακεδονίας, σελ. 470.
- Μαυρονικολάου Ν., Κάρκας Δ. & Συνεργάτες «ΥΔΡΕΤΜΕ», Σούλης Ν., Ζαΐμης Κ., Καφετζής Γ., Τυπάλδης Γ., Διακοσταυριανός Σ. & Θεοδωρόπουλος Π., 2004. Μελέτη κατασκευής φράγματος Νεστορίου Ν. Καστοριάς – Υδρολογική Μελέτη. 1. Βροχοπτώσεις και πλημμύρες σχεδιασμού. Νομαρχιακή Αυτοδιοίκηση Καστοριάς, Δ/ση Τεχνικών Υπηρεσιών.
- Pacemann F., 1997. A simple chaotic neuron, *Physica D.*, 104, 205 – 211.
- Patterson D., Chan K. & Tan C., 1993. Time series forecasting with Neural Nets: a comparative study in *Proceedings of the International Conference on Neural Networks Applications to Signal Processing, NNASP*, Singapore, pp. 269 – 274.
- Tolika K., Maheras P., Vafiadis M., Flocas H & Arseni–Papadimitriou A., 2007. Simulation of seasonal precipitation and raindays over Greece: a statistical downscaling technique based on artificial neural networks (ANNs). *International Journal of Climatology*, Vol 27, pp. 861 – 881.