

Διαχείριση παράκτιων υδροφορέων με χρήση τεχνητών νευρωνικών δικτύων

ΧΡΙΣΤΙΝΑ ΚΑΡΑΜΠΕΡΙΔΟΥ

ΜΑΡΓΑΡΙΤΗΣ ΒΑΦΕΙΑΛΗΣ

ΚΩΝΣΤΑΝΤΙΝΟΣ

ΚΑΤΣΙΦΑΡΑΚΗΣ

Πολιτικός Μηχανικός, Υπ.Δρ ΑΠΘ

Αναπλ. Καθηγητής ΑΠΘ

Καθηγητής ΑΠΘ

Περίληψη

Η υφαλμύριση αποτελεί σημαντικό πρόβλημα των παράκτιων υδροφορέων με επιπτώσεις στην ποιότητα των υδάτων ύδρευσης και άρδευσης. Στην παρούσα εργασία ένα τεχνητό νευρωνικό δίκτυο υπολογίζει τον συνολικό όγκο υφάλμυρου νερού, που αντλείται από πηγάδια σε παράκτιο υδροφόρα της Ανατολικής Μακεδονίας.

Πρόκειται για τεχνητό νευρωνικό δίκτυο ανάδρασης με νευρώνες εισόδου που αντιστοιχούν στις παροχές άντλησης των πηγαδιών και έναν νευρώνα εξόδου που αντιστοιχεί στη συνολική παροχή θαλασσινού νερού, που αντλείται από αυτά. Για την εκπαίδευσή του χρησιμοποιούνται αποτελέσματα αριθμητικής προσομοίωσης της ροής με τη μέθοδο των οριακών στοιχείων.

Η συσχέτιση των τιμών, που εκτιμά το νευρωνικό δίκτυο, με αυτές που υπολογίζονται από τον κώδικα οριακών στοιχείων, ενθαρρύνει την περαιτέρω διερεύνηση και επέκταση της εφαρμογής με την εκπαίδευση και τον έλεγχο του νευρωνικού δικτύου με δεδομένα μετρήσεων πεδίου. Ένα καλά εκπαιδευμένο δίκτυο, λόγω της απλότητας της εφαρμογής του -καθώς δεν απαιτεί από τον χρήστη εξειδικευμένες γνώσεις πάνω στο φαινόμενο που πραγματεύεται- μπορεί να αποδειχθεί χρήσιμο εργαλείο στον τομέα της διαχείρισης υδατικών πόρων σε επίπεδο λεκάνης απορροής.

1. ΕΙΣΑΓΩΓΗ

Τα τεχνητά νευρωνικά δίκτυα (artificial neural networks-ANN) προσομοιώνουν με απλοποιημένο τρόπο τη λειτουργία του ανθρώπινου εγκεφάλου. Στηρίζονται στην ιδέα ότι ορισμένες χαρακτηριστικές ιδιότητες των βιολογικών νευρώνων μπορούν να απομονωθούν και να χρησιμοποιηθούν για τη δημιουργία ενός απλοποιημένου «εγκεφάλου» που μιμείται κάποιες ικανότητες του αντίστοιχου ανθρώπινου, ιδιαίτερα την αναγνώριση προτύπων και τη συνειρμική λογική.

Με τα νευρωνικά δίκτυα δεν επιχειρείται μαθηματική προσομοίωση των εξεταζόμενων φαινομένων, αλλά εξαγωγή ποσοτικών συμπερασμάτων για συγκεκριμένα δεδομένα, με βάση ανάλογες περιπτώσεις. Επομένως τα νευρωνικά δίκτυα είναι ιδιαίτερα χρήσιμα όταν: α) η μαθηματική προσο-

μοίωση του φυσικού προβλήματος δεν είναι δυνατή ή είναι ιδιαίτερα πολύπλοκη και β) όταν δεν έχουν προσδιοριστεί με επαρκή ακρίβεια απαραίτητες παράμετροι (π.χ. η υδραυλική αγωγιμότητα ενός υδροφορέα).

Λόγω της προαναφερθείσας ικανότητάς τους για αναγνώριση προτύπων, αλλά και για αναπαραγωγή σειρών δεδομένων που αφορούν καθαρά στοχαστικά φαινόμενα, τα νευρωνικά δίκτυα έχουν χρησιμοποιηθεί επιτυχώς, ιδίως από τις αρχές της δεκαετίας του 1990, σε διάφορους τομείς της υδρολογίας όπως η πρόβλεψη βροχοπτώσεων [1] [2] [3], η σύνθεση και ανάλυση χρονοσειρών υδρολογικών δεδομένων [4], η προσομοίωση της σχέσης βροχόπτωσης-απορροής [5][6][7][8][9] και η πρόβλεψη της χειμαρρικής παροχής [10][11][12][13].

Ακόμη τα νευρωνικά δίκτυα έχουν χρησιμοποιηθεί σε θέματα ποιότητας υδατικών πόρων [14] [15] [16], λειτουργίας ταμιευτήρων [17], υπολογισμού των παραμέτρων υδροφορέων [18] και πρόβλεψης της στάθμης τους [19][20], πρόβλεψης της κίνησης ρύπων σε υπόγεια νερά [21][22], βελτιστοποίησης της διαχείρισης υδροφορέων [23][24] κ.ά.

Στην παρούσα εργασία διερευνάται η δυνατότητα ενός τεχνητού νευρωνικού δικτύου ανάδρασης (back-propagation feedforward neural network) να προσδιορίσει την ποσότητα υφάλμυρου νερού που αντλείται σε παράκτιο υδροφόρα, χρησιμοποιώντας ως στοιχεία εισόδου τις παροχές γεωτρήσεων.


Ως δεδομένα για την εκπαίδευση του δικτύου χρησιμοποιήθηκαν αποτελέσματα μαθηματικού μοντέλου, που προσομοιώνει την κίνηση του θαλασσινού νερού στον υδροφόρα και επιλύεται αριθμητικά με τη μέθοδο των οριακών στοιχείων. Ουσιαστικός στόχος είναι η διερεύνηση της ικανότητας ενός νευρωνικού δικτύου να προβλέψει τον κίνδυνο υφαλμύρισης σε παράκτιο υδροφόρα, του οποίου η ακριβής μαθηματική προσομοίωση δεν είναι εφικτή (π.χ. λόγω ανομοιογένειας, ύπαρξης ρηγμάτων ή καρστικών φαινομένων).

2. ΠΕΡΙΟΧΗ ΜΕΛΕΤΗΣ-ΚΩΔΙΚΑΣ ΠΡΟΣΟΜΟΙΩΣΗΣ

Η εφαρμογή του νευρωνικού δικτύου πραγματοποιήθηκε στη λεκάνη Ελευθερών Καβάλας, η οποία ανήκει στην υδρολογική λεκάνη Γυαλοχωριών του υδατικού διαμερισματος Ανατολικής Μακεδονίας. Για τη μελέτη του φαινομένου της υφαλμύρισης επιλέχθηκαν 21 γεωτρήσεις (10 ερευνητικές και 11 αρδευτικές), των οποίων οι αποστάσεις από την ακτή είναι γνωστές με ακρίβεια [25].

Αντί για δεδομένα μετρήσεων, χρησιμοποιήθηκαν αποτελέσματα αριθμητικής επίλυσης μιας «ισοδύναμης» διδιάστατης ροής με τη μέθοδο των οριακών στοιχείων. Η μέθοδος αυτή παρουσιάζει τα ακόλουθα πλεονεκτήματα: α) Δεν απαιτεί κατασκευή κανάβου στο πεδίο ροής, αλλά βασίζεται σε διακριτοποίηση των ορίων του και υπολογίζει απευθείας τις κάθετες ταχύτητες στα όρια αυτά.

Έτσι προκύπτει άμεσα η παροχή θαλασσινού νερού, που εισρέει στον υδροφορέα β) Η επιρροή της παροχής κάθε γεώτρησης λαμβάνεται υπ' όψιν με ακρίβεια (ως μεμονωμένο φορτίο, δηλαδή χωρίς κατανομή της σε κάποιο στοιχείο κανάβου) και γ) Ο υπολογισμός των ταχυτήτων σε εσωτερικά σημεία του πεδίου ροής είναι απλός, οπότε συνδυάζεται αποτελεσματικά με τη μέθοδο των κινουμένων σημείων, η οποία χρησιμοποιείται για την παρακολούθηση της κίνησης του εισρέοντος θαλάσσιου νερού προς τις γεωτρήσεις.



Σχήμα 1: Διακριτοποίηση των ορίων του υδροφορέα

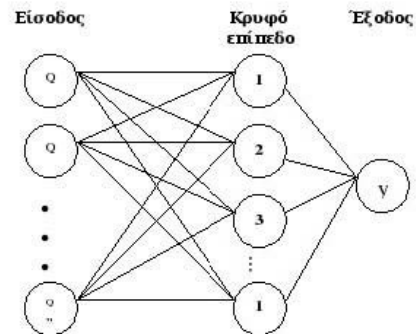
Για την εφαρμογή του κώδικα οριακών στοιχείων το όριο του υδροφορέα απλοποιήθηκε και διακριτοποιήθηκε σε 57 ευθύγραμμα οριακά στοιχεία μήκους 500m το καθένα, όπως φαίνεται στο σχήμα 1.

Κάθε κόμβος τοποθετήθηκε στο μέσον του αντίστοιχου οριακού στοιχείου. Για τους παράκτιους κόμβους (κόμβοι 1 έως 20) ισχύει οριακή συνθήκη σταθερού φορτίου, ενώ για τους υπόλοιπους θεωρείται οριακή συνθήκη γνωστής παροχής, η οποία είναι μηδενική για όσους κόμβους βρίσκονται σε αδιαπέρατο όριο.

3. ΤΟ ΤΕΧΝΗΤΟ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ

3.1 Γενικά

Όπως αναφέρθηκε, ένα τεχνητό νευρωνικό δίκτυο είναι ένας αλγόριθμος που μιμείται τον τρόπο επεξεργασίας πληροφοριών από τον ανθρώπινο εγκέφαλο. Αποτελείται από τις μονάδες επεξεργασίας ή νευρώνες και τις μεταξύ τους συνδέσεις. Οι νευρώνες, που στο σχήμα 2 παριστάνονται με κύκλους, είναι κατά κανόνα διαταγμένοι σε 3 τουλάχιστον στρώματα. Ένα στρώμα εισόδου, μέσω του οποίου εισάγονται τα δεδομένα, ένα ή περισσότερα ενδιάμεσα στρώματα (που αποκαλούνται και κρυφά), και ένα στρώμα εξόδου, το οποίο δίνει τα αποτελέσματα. Οι συνδέσεις μεταξύ των νευρώνων, που παριστάνονται με ευθύγραμμα τμήματα στο σχήμα 2, συνοδεύονται από συντελεστές, που αποκαλούνται βάρη και δείχνουν την ένταση της επίδρασης του ανάντη (ως προς τη ροή της πληροφορίας) νευρώνα στον κατάντη. Τα κρυφά στρώματα εισάγουν μη-γραμμικότητα στη διαδικασία υπολογισμού της εξόδου του δικτύου.



Σχήμα 2: Τεχνητό Νευρωνικό Δίκτυο

Τα τρία βασικά χαρακτηριστικά ενός τεχνητού νευρωνικού δικτύου είναι η αρχιτεκτονική του (architecture), δηλαδή ο τρόπος διασύνδεσης των νευρώνων, ο αλγόριθμος εκμάθησης (learning algorithm), η μέθοδος δηλαδή που ακολουθείται για την προσαρμογή του βάρους κάθε σύνδεσης στο εξεταζόμενο πρόβλημα και η συνάρτηση ενεργοποίησης (activation function), με την οποία υπολογίζεται η έξοδος κάθε νευρώνα για δεδομένο άθροισμα εισόδων (και μπορεί να είναι διαφορετική για κάθε επίπεδο) [26].

Για ένα νευρωνικό δίκτυο με ένα κρυφό επίπεδο (όπως αυτό που χρησιμοποιήθηκε στο παρόν πρόβλημα), η γενική εξίσωση που δίνει την έξοδο του δικτύου είναι:

$$y = h_2 \left(\sum_{j=1}^k w_j h_1 \left(\sum_{i=1}^n w_{ji} Q_i \right) \right) \quad (3.1)$$

όπου, y η έξοδος του δικτύου, k ο αριθμός των κρυφών

νευρώνων, n ο αριθμός των εισόδων, w_{ji} τα βάρη που συνδέουν τους νευρώνες εισόδου με τους κρυφούς νευρώνες, w_j τα βάρη που συνδέουν τους κρυφούς νευρώνες με την έξοδο, Q_i τα στοιχεία εισόδου, και h_1, h_2 οι συναρτήσεις ενεργοποίησης για το κρυφό επίπεδο και το επίπεδο εξόδου, αντιστοίχως.

Η συνάρτηση ενεργοποίησης πρέπει να έχει ορισμένες μαθηματικές ιδιότητες, όπως συνέχεια και ομαλότητα. Η επιλογή της εξαρτάται από τη φύση των δεδομένων και την υποθεθείσα κατανομή των μεταβλητών εξόδου. Έτσι, για ένα κλασικό πρόβλημα γραμμικής παλινδρόμησης, η συνάρτηση ενεργοποίησης είναι ταυτοτική, ούτως ώστε από την εξίσωση (3.1) να προκύπτει μία γραμμική σχέση της εξόδου y με τις εισόδους Q_i . Σε συνθετότερα προβλήματα χρησιμοποιείται πολύ συχνά η σιγμοειδής συνάρτηση ή συνάρτηση υπερβολικής εφαπτομένης. Στην παρούσα εργασία χρησιμοποιείται σιγμοειδής συνάρτηση ενεργοποίησης στο κρυφό επίπεδο (για να εισαγάγει τη μη-γραμμικότητα), και γραμμική συνάρτηση στο επίπεδο εξόδου (για να δώσει το ζητούμενο αποτέλεσμα παροχής).

3.2 Ο αλγόριθμος Quickprop

Η συνήθης μορφή νευρωνικών δικτύων, που χρησιμοποιείται στα προβλήματα υδρολογίας, είναι τα δίκτυα με ανάδραση (back-propagation). Για την προσαρμογή του βάρους των συνδέσεων χρησιμοποιούν την τυπική μέθοδο εκπαίδευσης με επίβλεψη. Δίνονται δηλαδή στο δίκτυο σειρές δεδομένων (είσοδοι) και τα αντίστοιχα επιθυμητά αποτελέσματα, τα οποία συγκρίνονται με τα αποτελέσματα (εξόδους) που παράγει το δίκτυο. Το υπολογιζόμενο σφάλμα χρησιμοποιείται για την αναπροσαρμογή των βαρών στις συνδέσεις των νευρώνων. Κριτήριο επιτυχίας της προσέγγισης σε κάθε κύκλο εκπαίδευσης αποτελεί το μέσο τετραγωνικό σφάλμα (εξ. 3.2), όπου $d^{(p)}$ το διάνυσμα επιθυμητών εξόδων και $y^{(p)}$ το διάνυσμα των εξόδων του δικτύου.

$$J = \frac{1}{P} \sum_{p=1}^P \|d^{(p)} - y^{(p)}\|^2 \quad (3.2)$$

Ο κλασικός αλγόριθμος ανάδρασης υπολογίζει την πρώτη μερική παράγωγο του συνολικού σφάλματος ως προς το αντίστοιχο βάρος, δηλαδή την κλίση της επιφάνειας σφάλματος, για την ελαχιστοποίηση του οποίου χρησιμοποιεί τη μέθοδο της πιο απότομης καθόδου (steepest descent). Η μέθοδος αυτή έχει κάποιους περιορισμούς, που οφείλονται στο ότι χρησιμοποιεί τοπική πληροφορία μόνο, γι' αυτό μπορεί να οδηγήσει σε μεγάλους χρόνους εκπαίδευσης.

Για την επιτάχυνση της διαδικασίας στον αλγόριθμο Quickprop προτιμήθηκε η προσέγγιση του Fahlman [27], που επιτρέπει μεγαλύτερα βήματα και χρησιμοποιεί την εξίσωση (3.3) για τον υπολογισμό της μεταβολής του βάρους, στην οποία $\Delta^{t+1}w_{ij}$ η πραγματική μεταβολή βάρους, S^{t+1} η

μερική παράγωγος της συνάρτησης σφάλματος ως προς το βάρος w_{ij} και S^t η προηγούμενη μερική παράγωγος.

$$\Delta^{t+1}w_{ij} = \frac{S^{t+1}}{S^t - S^{t+1}} \Delta^t w_{ij} \quad (3.3)$$

Το πόσες σειρές δεδομένων θα χρησιμοποιηθούν στην εκπαίδευση ενός νευρωνικού δικτύου, εξαρτάται από τη φύση του εξεταζόμενου προβλήματος και την αρχιτεκτονική του δικτύου (ο απαιτούμενος αριθμός αυξάνει με το πλήθος των συνδέσεων).

3.3 Εφαρμογή στον παράκτιο υδροφορέα


Για τη μελέτη του φαινομένου της υφαλμύρισης στον εξεταζόμενο υδροφορέα επιλέχθηκε ένα δίκτυο ανάδρασης που περιλαμβάνει 21 νευρώνες εισόδου, ο καθένας από τους οποίους αντιστοιχεί στην παροχή άντλησης μιας γεώτρησης, ένα κρυφό στρώμα και το στρώμα εξόδου που αποτελείται από έναν νευρώνα, ο οποίος δίνει τη συνολική παροχή θαλασσινού νερού Q_s στον υδροφορέα. Το πλήθος των κρυφών νευρώνων καθορίστηκε με δοκιμές. Η σύνδεση μεταξύ των στρωμάτων είναι πλήρης, δηλαδή κάθε νευρώνας του ενός στρώματος συνδέεται με όλους τους νευρώνες του επομένου. Δίνουμε δηλαδή σε όλα τα δεδομένα εισόδου την ίδια δυνατότητα επηρεασμού του τελικού αποτελέσματος. Επιπλέον εξετάστηκε και η επίδραση της προσθήκης απευθείας συνδέσεων μεταξύ του στρώματος εισόδου και του νευρώνα εξόδου. Για την εκπαίδευση του δικτύου χρησιμοποιήθηκε ο αλγόριθμος Quickprop, που σκιαγραφήθηκε στο υποκεφάλαιο 3.2.

4. ΕΚΠΑΙΔΕΥΣΗ ΤΟΥ ΔΙΚΤΥΟΥ ΚΑΙ ΑΠΟΤΕΛΕΣΜΑΤΑ


Σημαντικότερο ρόλο στην απόδοση ενός νευρωνικού δικτύου έχει η επιλογή των δεδομένων εκπαίδευσης. Στο σχήμα 3 παρουσιάζεται η συσχέτιση των αποτελεσμάτων του νευρωνικού δικτύου με τα αναμενόμενα, όταν η εκπαίδευση του δικτύου γίνεται με σειρές δεδομένων (πρότυπα), των οποίων το εύρος τιμών (δηλαδή των παροχών άντλησης από τις γεωτρήσεις), συμπίπτει με αυτό των προτύπων ελέγχου. Παρατηρείται εμμονή των εξόδων γύρω από την τιμή $Q_s = 0.69$, ωστόσο αυτές ακολουθούν τις διακυμάνσεις των αναμενόμενων και, μάλιστα, αντιδρούν στην ακραία τιμή 0, διαφοροποιούμενες σημαντικά. Η αύξηση του εύρους τιμών των προτύπων εκπαίδευσης πέραν αυτού των προτύπων ελέγχου οδηγεί σε σημαντική βελτίωση του συντελεστή συσχέτισης μεταξύ των αναμενόμενων τιμών και αυτών που υπολογίσθηκαν από 0.56 σε 0.77, όπως φαίνεται στο σχήμα 4. Περαιτέρω διεύρυνση των προτύπων εκπαίδευσης βελτιώνει ακόμη περισσότερο τον συντελεστή συσχέτισης

σε 0.92, όπως φαίνεται στο σχήμα 5.


Παρατηρήθηκε, ωστόσο, πως ακόμη μεγαλύτερη διεύρυνση οδηγεί σε αντίθετα αποτελέσματα και πτώση της συσχέτισης. Τα αντίστοιχα συγκριτικά αποτελέσματα παρουσιάζονται στο σχήμα 6.




Σχήμα 3: Εκπαίδευση & έλεγχος με το ίδιο εύρος τιμών



Σχήμα 4: Εκπαίδευση με αυξημένο εύρος τιμών



Σχήμα 5: Διεύρυνση τιμών εκπαίδευσης




Σχήμα 6: Συγκριτικά αποτελέσματα


Λόγω της σημασίας για το φυσικό φαινόμενο της απόστασης κάθε γεώτρησης από το όριο της θάλασσας, επιχειρήθηκε στη συνέχεια η «ενσωμάτωση» μιας πρόσθετης πληροφορίας στα πρότυπα εκπαίδευσης. Είναι γνωστό ότι σε μόνιμη ροή, η πτώση στάθμης που προκαλεί η άντληση παροχής Q από μία γεώτρηση μειώνεται με τον λογάριθμο της απόστασης από τη γεώτρηση. Για τον λόγο αυτό, η υφαλμύριση παράκτιων υδροφορέων εξαρτάται άμεσα από την απόσταση μεταξύ των γεωτρήσεων και της ακτογραμμής. Έτσι το δίκτυο εκπαίδευτηκε με δεδομένα το πηλίκο της παροχής κάθε γεώτρησης με το λογάριθμο της απόστασής της από τη θάλασσα. Από τα αποτελέσματα συνάγεται, πως, όταν το εύρος τιμών εκπαίδευσης είναι μεγάλο, η συσχέτιση βελτιώνεται σημαντικά (σχήμα 7).

Τέλος, τροποποιήθηκε η δομή του δικτύου με προσθήκη περισσότερων νευρώνων στο κρυφό επίπεδο, και, κατόπιν, με προσθήκη νέων απευθείας συνδέσεων μεταξύ του επιπέδου εισόδου και του επιπέδου εξόδου.

Το παράδειγμα που παρουσιάζεται στο σχήμα 8, αφορά στην τροποποίηση της δοκιμής που περιγράφεται από το σχήμα 5. Στη νέα δοκιμή προστέθηκαν δέκα επιπλέον νευρώνες στο κρυφό επίπεδο (πρόκειται δηλαδή για δομή 21-20-1). Η απόδοση βελτιώθηκε και ο συντελεστής συσχέτισης ανήλθε στην τιμή 0.9449.



Σχήμα 7: Ενσωμάτωση επιπλέον πληροφορίας



Σχήμα 8: Τροποποίηση δομής δικτύου

Σε επόμενη δοκιμή διατηρήθηκε η δομή 21-20-1, αλλά προστέθηκαν απευθείας συνδέσεις μεταξύ επιπέδου εισόδου και επιπέδου εξόδου. Η απόδοση του δικτύου βελτιώθηκε και ο συντελεστής συσχέτισης έφθασε σε πολύ καλοπονητικό επίπεδο (96.9%). Οι δύο δοκιμές απεικονίζονται στο σχήμα 8.

5. ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΣΥΖΗΤΗΣΗ

Το πρώτο βήμα για την εξακρίβωση της ικανότητας των τεχνητών νευρωνικών δικτύων να προβλέψουν την εξέλιξη ενός φυσικού φαινομένου είναι η διερεύνηση της ικανότητάς τους να υποκαθιστούν τη λειτουργία των κλασικών μοντέλων που χρησιμοποιούνται για τον σκοπό αυτό. Σ' αυτό το πλαίσιο, η απόδοση του νευρωνικού δικτύου μπορεί στην καλύτερη περίπτωση να προσεγγίσει την απόδοση του υποκαθιστώμενου κλασικού μοντέλου, που χρησιμοποιήθηκε και για την εκπαίδευσή του. Από την έρευνά μας προέκυψε ότι το συγκεκριμένο νευρωνικό δίκτυο μπορεί να υποκαταστήσει ικανοποιητικά το μοντέλο των οριακών στοιχείων, εφόσον εκπαιδευθεί κατάλληλα.

Βέβαια, σε αυτές τις περιπτώσεις δεν αναμένεται ουσιαστικό όφελος σε υπολογιστικό χρόνο. Αυτό συμπεραίνεται τόσο από τη διεθνή βιβλιογραφία, όσο και από την παρούσα εργασία. Πράγματι, αν και χρησιμοποιήθηκε η εναλλακτική μέθοδος εκπαίδευσης με ανάδραση που εισήγαγε ο Fahlman, και η οποία θεωρείται ταχύτερη, για ένα τόσο απλό από άποψη υπολογιστικών απαιτήσεων πρόβλημα το νευρωνικό δίκτυο δεν είναι ταχύτερο από τον κώδικα των οριακών στοιχείων.

Μάλιστα, όταν αυξάνεται το πλήθος των κύκλων εκπαίδευσης του δικτύου (από 1000 σε 2000 ή 5000 κύκλους) καθυστερεί σε κάποιο βαθμό η εξαγωγή αποτελεσμάτων, χωρίς, ταυτόχρονα, να σημειώνεται σημαντικό κέρδος ως προς την ακρίβειά τους. Εκτιμάται πως ουσιαστική συνεισφορά στην ταχύτητα προσφέρουν τα νευρωνικά δίκτυα στην περίπτωση που συνεργάζονται ή υποκαθιστούν μοντέλα της μεθόδου Monte-Carlo, τα οποία απαιτούν μεγάλο αριθμό πραγματοποιήσεων για τη σύνθεση χρονοσειρών [28], καθώς και όταν υποκαθιστούν τα μοντέλα προσομοίωσης της ροής στη συνάρτηση αποτίμησης Γενετικών Αλγορίθμων. Στις περιπτώσεις αυτές το νευρωνικό δίκτυο χρησιμοποιείται πολλές φορές με διαφορετικά δεδομένα μετά από μία εκπαίδευση μόνο.

Συγκρίνοντας τις απαιτήσεις του κώδικα οριακών στοιχείων με αυτές του νευρωνικού δικτύου, είναι σαφές πως το νευρωνικό δίκτυο είναι απλούστερο στην κατασκευή του και δεν προϋποθέτει παραδοχές, όπως η απλοποίηση των ορίων του πεδίου, που είναι απαραίτητες για την εφαρμογή του κώδικα των οριακών στοιχείων. Για τον λόγο αυτό είναι πιθανό να επιτευχθεί μεγαλύτερη ακρίβεια με το νευρωνικό δίκτυο, αν η εκπαίδευσή του γίνει με δεδομένα από μετρήσεις πεδίου.

Ουσιαστικά η χρήση των νευρωνικών δικτύων στην υδραυλική και την υδρολογία προσβλέπει στη μίμηση των υποκείμενων υδρολογικών διεργασιών, τις οποίες η επιστήμη δεν κατανοεί πλήρως ή δεν μπορεί να εκφράσει με τις συνήθεις μαθηματικές διατυπώσεις. Ωστόσο, πρέπει να σημειωθεί πως, λόγω της ίδιας της φύσης της δομής και της λειτουργίας τους, τα νευρωνικά δίκτυα γενικώς δεν προσφέρουν καλύτερη κατανόηση των υδρολογικών διεργασιών και

των φυσικών φαινομένων, καθώς απλοποιούν τη φυσική και την «εκφυλίζουν» σε βάρη και τιμές καταφλοιού [29]. Έτσι και στην περίπτωση του φαινομένου της υφαλμύρισης πρέπει κανείς να κατανοεί το φυσικό φαινόμενο για να κάνει ορθή επιλογή της δομής του δικτύου και του κατάλληλου αλγόριθμου εκπαίδευσης που πρέπει να εφαρμοστεί.

Επιπλέον, δεν μπορεί να τεκμηριωθεί η ορθή επιλογή αρχιτεκτονικής δικτύου, συναρτήσεων ενεργοποίησης και μεθόδων εκμάθησης, παρά μόνο μέσα από μια διαδικασία δοκιμών και ελέγχου. Το ίδιο ισχύει και για την ορθή επιλογή δεδομένων εκπαίδευσης, των οποίων είναι απαραίτητη η κατάλληλη προετοιμασία και κανονικοποίηση. Έτσι και στην παρούσα εργασία ενώ θα περίμενε κανείς η απόδοση του δικτύου να είναι βέλτιστη, όταν οι τιμές εκπαίδευσης και ελέγχου κινούνται στο ίδιο διάστημα, κάτι τέτοιο δεν συμβαίνει, ίσως λόγω της μικρής διακύμανσης των τιμών του πραγματικού φαινομένου.

Αυτή η αδυναμία εξήγησης της συμπεριφοράς του δικτύου μπορεί να φαντάζει μη αποδεκτή για τον μηχανικό, αλλά δεν πρέπει να ξεχνά κανείς πως, όταν κινείται στα ασαφή πλαίσια των στοχαστικών φαινομένων και, ιδιαίτερα, της τεχνητής νοημοσύνης, αυτό, όχι μόνο μπορεί να είναι αποδεκτό, αλλά, ίσως είναι και το ζητούμενο. Με άλλα λόγια, είναι ζητούμενο να παρέχεται μέσω της δομής και λειτουργίας του στο δίκτυο η δυνατότητα να «αυτονομείται» από τον εκπαιδευτή του, ώστε να επιτύχει την ιδέα της «νοούσης μηχανής». Από την άλλη, αν βρεθεί κάποιος τρόπος να εξαχθούν συμπεράσματα από τα βάρη και τα κατώφλια για τη συσχέτιση υδρολογικών μεταβλητών, η οποία έως τώρα δεν έχει εντοπιστεί, τα νευρωνικά δίκτυα είναι ικανά να βοηθήσουν σημαντικά, π.χ. στην επέκταση και την ανάλυση χρονοσειρών.

Πάντως, σε ένα πλαίσιο διαχείρισης υδατικών πόρων σε τοπικό επίπεδο, λόγω του φιλικού προς τον χρήστη χαρακτήρα των νευρωνικών δικτύων, αυτά μπορούν να εφαρμόζονται σε πραγματικό χρόνο από μη ειδικούς, καθώς μετά τη φάση της εκπαίδευσής τους δεν απαιτούνται γνώσεις πάνω στο φαινόμενο για την διερεύνηση διάφορων σεναρίων.

ΒΙΒΛΙΟΓΡΑΦΙΑ

1. S. Tohma & S. Igata, "Rainfall estimation from GMS imagery data using neural network.", *Hydraulic engineering software* Volume 1, W.R. Blain and K.L. Katsifarakis eds., *Computational Mechanics Publications*, 1994, Southampton, U.K., pp 123-130
2. H. Navone & H. Ceccatto, "Predicting Indian monsoon rainfall: a neural network approach", *Climate Dyn.* 10, 1994, pp.305-312
3. A. Barros & R. Kuligowski, "Experiments in short-term precipitation forecasting using artificial neural networks", *Stochastic and statistical methods on hydrology and environmental engineering time series analysis in hydrology and environmental engineering* 3. K.W. Hipel, et al., eds., 1998, *Kluwer*, Dordrecht, The Netherlands, pp.229-242

4. H. Raman & N. Sunilkumar, "Multi-variate modeling of water resources time series using artificial neural networks", *Hydrological Sci.* 40, 1995, pp.145-163
5. A. Halff & A. H. M. Azmoodeh, "Predicting runoff from rainfall using neural networks", *Proc. Engrg. Hydrol., ASCE*, New York, 1993 pp. 760-765.
6. A. Hjelmfelt & M. Wang, "Runoff hydrograph estimation using artificial neural networks", *Proc., ASAE Conference*, 1993, American Society of Civil Engineers, St. Joshep, Mich.
7. M. Zhu, M. Fujita & N. Hashimoto, "Application of neural networks to runoff prediction.", *Stochastic and statistical methods in hydrology anf environmental engineering 3*. K.W. Hipel et al., eds, *Kluwer*, 1994, Drordrecht, The Netherlands, pp. 205-216.
8. J. Smith & R. Eli, "Neural-network models of rainfall-runoff process", *J. Water Resour. Plng. and Mgmt.*, *ASCE 121(6)*, 1995, pp. 499-508.
9. P. Carriere, S. Mohagheh & R. Gaskari "Performance of a virtual runoff hydrograph system.", *J. Water Resour. Plng. and Mgmt.*, *ASCE 122(6)*, 1996, pp.421-427.
10. K.W. Kang, J.H. Kim, C.H. Park & K.J. Ham, "Evaluation of hydrological forecasting system based on neural network model", *Proc., 25th Congress of Int. Assoc. For Hydr. Res., International Association of Hydraulic Research*, 1993, Delft, The Netherlands, pp. 257-264.
11. N. Karunanithi, W.J. Grenney, D. Whitley & K. Bovee, "Neural networks for river flow prediction", *J. Comp. In Civ. Engrg.*, *ASCE 8(2)*, 1994,, pp.201-220.
12. M. Markus, J.D. Salas, H.K. Shin & R. Grande, "Predicting streamflows based on neural networks", *Proc., 1st Int. Conf. On Water Resour. Engrg.*, *ASCE*, 1995, New York, pp. 1641-1646.
13. M. Tawfic, A. Ibrahim & H. Fahmy, "Hysteresis sensitive neural network for modeling rating curves", *J. Comp. In Civ. Engrg.*, *ASCE 11(3)*, 1997, pp.206-211.
14. H. Maier & G. Dandy, "The use of artificial neural networks for the prediction of water quality parameters", *Water Resour. Res.* 32(4), 1996, pp.1013-1022.
15. N. Sandhu & R. Finch, "Emulation of DWRDSM using artificial neural networks and estimation of Sacramento River flow from salinity", *Proc., North Am. Water and Envir. Conf.*, *ASCE*, 1996, New York, pp.4335-4340.
16. P. Hutton, et al., "Predicting THM formation with artificial neural networks", *Proc., North Am. Water and Envir. Conf.*, *ASCE*, 1996, New York.
17. H. Raman & V. Chandramouli., "Deriving a general operating policy for reservoirs using neural networks", *J. Water resour. Plng and Mgmt.*, *ASCE 122 (5)*, 1996, pp.342-347
18. A. Aziz & K. Wong., "Neural network approach to the determination of aquifers parameters", *Ground Water 30(2)*, 1992, pp. 164-166.
19. P. Nayak, Y.R.S. Rao & K.P. Sudheer, "Groundwater level forecasting in a shallow aquifer using artificial neural network approach", *Water Resources Management 20*, 2006, pp.77-90
20. C. Yang, S.O. Prasher & R. Lacroix, "Application of artificial neural networks to simulate water-table depth under subirrigation", *Can. Water Resour. J., Lethbridge, Canada 21(1)*, 1996, pp.27-44
21. S. Starrett, Y.M. Najjar & J.C. Hill, "Neural networks predict pesticide leaching", *Proc., Am. Water and Envir. Conf.*, *ASCE*, 1996, New York, pp. 1693-1698
22. C. Ray & K. Klindworth, "Use of artificial neural networks for agricultural chemical assessment of rural private wells", *Proc., North Am. Water and Envir. Conf.*, *ASCE*, 1996, New York, pp.1687-1692.
23. L. Rogers & F. Dowla, "Optimization of groundwater remediation using artificial neural networks with parallel solute transport model", *Water Resour. Res.* 30(2), 1994, pp. 457-481
24. S.V.N. Rao, B.S. Thandaveswara, S.M. Bhallamudi & V. Srinivasulu, "Optimal Groundwater Management in Deltaic Regions using Simulated Annealing and Neural Networks", *Water Resources Management 17(6)*, 2003, pp. 409-428
25. C. Karamperidou, E. Karamperidou & K.L. Katsifarakis "Seawater intrusion into the aquifer of Eleftherae-N. Peramos, Kavala, Greece", *Proc. Int. Conf. River Basin Management IV*, 2007, pp. 3-10, Kos, Greece.
26. E. El-Sebakhy, "Artificial Neural Networks, Probabilistic Networks, Support Vector Machines, Adaptive-Neuro Fuzzy Systems and Functional Networks". Elsevier Science, 2006
27. S.E. Fahlman, "An Empirical Study of Learning Speed in Back-Propagation Networks", Technical report CMU_CS-88-162, 1988
28. A. Minns & M. Hall, "Artificial neural networks as rainfall-runoff models", *Hydrologic Sci.* 41(3), 1996, pp. 399-417.
29. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, "Artificial Neural Networks in hydrology, II: Hydrologic Applications", *Journal of Hydrologic Engineering 5:2*, 2000

Χριστίνα Καραμπερίδου

Πολιτικός Μηχανικός, Υπ. Δρ ΑΠΘ

Τμήμα Πολιτικών Μηχανικών, Τομέας Υδραυλικής και Τεχνικής Περιβάλλοντος, ΑΠΘ 54124, Θεσσαλονίκη

Μαργαρίτης Βαφειάδης

Αναπληρωτής Καθηγητής ΑΠΘ

Τμήμα Πολιτικών Μηχανικών, Τομέας Υδραυλικής και Τεχνικής Περιβάλλοντος, ΑΠΘ 54124, Θεσσαλονίκη

Κωνσταντίνος Α. Κατσιφαράκης

Καθηγητής ΑΠΘ

Τμήμα Πολιτικών Μηχανικών, Τομέας Υδραυλικής και Τεχνικής Περιβάλλοντος, ΑΠΘ 54124, Θεσσαλονίκη

Extended Summary

Optimization of groundwater resources management by means of artificial neural networks

**CHRISTINA
KARAMPERIDOU**

Civil Engineer, Ph.D. student,
A.U.Th.

MARGARITIS VAFEIADIS

Associate Professor A.U.Th.

**KONSTANTINOS L.
KATSIFARAKIS**

Professor A.U.Th.

Abstract

Seawater intrusion into coastal aquifers is an important problem worldwide, since it renders groundwater unusable for drinking or irrigation. For this reason, the respective scientific literature is very rich. The present paper addresses the issue of training an artificial neural network (ANN) in order to estimate the total volume of salt water that is pumped from a coastal aquifer in Eastern Macedonia, Greece.

The ANN used consists of input neurons that represent the wells' pumping rate, one hidden layer and a single output neuron that represents the volume of seawater that is pumped from the wells. The network uses the Quickprop Algorithm, a method of speeding back-propagation style training that was developed by Fahlman; the training patterns are derived from numerical flow simulations, by means of a Boundary Element Code.

The correlation achieved between expected and estimated values of seawater intrusion, although highly dependent on the training data, encourages further investigation that should include training the ANN with actual field data. The final product, namely a well trained ANN, could be easily used, even by non-specialists, in the study of basin-scale water resource management problems.

hydraulics and hydrology, owing to their capacity for pattern recognition and reconstruction of time series. Since the 1990s, ANNs have been used successfully for rainfall-runoff modeling, stream flow prediction, groundwater modeling, water resource management, precipitation forecasting, hydrological time series analysis and reconstruction and reservoir network operation. Articles addressing the flow of pollutants in groundwater tables, as well as optimization of groundwater resource management in coastal aquifers by means of artificial neural networks, are also available in the international literature.

This paper is an attempt to assess the ability of a back-propagation artificial neural network to estimate the total volume of salt water that is pumped from a coastal aquifer, using pumping rates as input variables. Training patterns are produced through the implementation of a numerical model that combines a boundary element code with a particle tracking scheme.

1. INTRODUCTION

Artificial neural networks (ANNs) are based on the idea that certain properties of biological neurons can be isolated and used for the creation of a simplified "brain" which imitates to an extent the computational capacity of a human brain.

ANNs do not use mathematical simulations of the phenomena. They try instead to achieve quantitative results, based on similar known cases. Thus, they are particularly useful when mathematical simulation of the physical phenomena is either impossible or too complicated.

ANNs have been used extensively to address problems in

Submitted: May 12, 2008 Accepted: Sep. 18, 2008

2. AREA OF STUDY

The aquifer of Eleftherae, Kavala is situated in the region of Eastern Macedonia, Greece. Pumping from twenty-one existing wells (10 research wells and 11 irrigation wells) was taken into account.

The aquifer's boundary was simplified and divided into fifty-seven linear boundary elements, each 500m long, as shown in fig.1. A boundary condition of constant hydraulic head $h=0$ was considered for nodes 1 to 20, which lie on the coastline, while the nodal flow rates were set equal to zero for nodes that lie on the impermeable boundary. Finally, known constant inflow rates were considered for the remaining nodes.

3. ARTIFICIAL NEURAL NETWORK

ANNs consist of simple interconnected processing units (neurons) that present complex parallel behavior; the latter is determined by the properties of their connections. ANNs use learning algorithms that alter the strength (weights) of these connections, in order to achieve optimal results.

Back-propagation ANNs in particular, use supervised learning algorithms, namely they are provided both with input patterns and desired output patterns. Then they calculate the error between estimated and expected output values, and adjust their weights in order to minimize this error. Learning is completed when the Root Mean Squared Error (RMSE) is minimized (eq. 3.2). Commonly used back-propagation networks minimize RMSE by using a gradient descent technique. In this article, the network uses the Quickprop algorithm proposed by Fahlman, which encompasses training speeding techniques.

The network used in our case consists of an input layer with 21 neurons, which represent the 21 well pumping rates, one hidden layer, and an output layer with one neuron representing the total pumping rate of salt water. The number of hidden neurons was determined by trial and error. Neurons in different layers were fully connected, as shown in fig. 2. In addition, the result of introducing additional cross-cut connections between the input and output layer was investigated.

4. TRAINING AND RESULTS

Sets with different ranges of input values were used in the training process. As shown in figures 3 to 6, ANN performance improved, up to a certain point, when the range of input values used in the training sets exceeded that of the control sets. Moreover, as shown in fig. 7, performance definitely improved when well flow-rate values used for training were divided by the logarithm of each well's distance from the coastline, since in this case the ANN was fed additional important information.

Finally, as shown in fig. 8, the network achieved very

good correlation (96.9%) between calculated and expected results when a more complex architecture was used, including a 21-20-1 structure and cross-cut connections between the input and the output layer.

5. DISCUSSION

The first step in determining the ability of ANNs to forecast values in hydrological processes is to determine whether they can efficiently replace the respective simulation models. Of course, a network trained with patterns produced by a classical model cannot exceed its performance. This is the case of the ANN described in this paper, which achieved a satisfactory performance.

ANNs are particularly useful in dealing with complex processes that cannot be described adequately by typical simulation models. In our case, the ANN could probably achieve better results if trained with measured field data.

Regarding the gain in computational speed and burden, it is negligible in straightforward and simple -in terms of computational requirements- problems. However, ANNs may offer faster responses when multiple realizations that increase computational burden are required, e.g. in time series reconstruction using the Monte Carlo method, or for flow simulations included in the evaluation function of genetic algorithm models.

It should be mentioned that, due to their structure and way of function, ANNs generally do not offer a better understanding of the underlying natural processes, since they reduce physics to a set of optimal weights and threshold values. Moreover, their capacity for self-organizing and autonomous function may lead to fallacious results and conclusions; thus, controlling the ANN's output with classical methods is suggested, when applicable. Accordingly, in the case of salt water intrusion, one has to understand the physical phenomenon in order to evaluate training data, choose appropriate network architecture and training algorithms, and decide on the value of the network's output. After proper training, though, an ANN can be considered a robust, fast, and user-friendly tool that can be easily operated by non-specialists in basin-scale water resource management problems.

Christina Karamperidou

Civil Engineer, Ph.D. Cand. A.U.Th.

Department of Civil Engineering, Division of Hydraulics and Environmental Engineering, GR 54124, Thessaloniki, Greece

Margaritis Vafeiadis

Associate Professor A.U.Th.

Department of Civil Engineering, Division of Hydraulics and Environmental Engineering, GR 54124, Thessaloniki, Greece

Konstantinos L. Katsifarakis

Professor A.U.Th.

Department of Civil Engineering, Division of Hydraulics and Environmental Engineering, GR 54124, Thessaloniki, Greece