



ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ
ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ ΠΕΡΙΒΑΛΛΟΝΤΟΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**Πρόβλεψη της χωρικής κατανομής υδραυλικού ύψους
υδροφορέα με τη χρήση νευρωνικού δικτύου Ακτινικών
Συναρτήσεων Βάσης**

Βασίλης Τσαπάρας

Εξεταστική Επιτροπή:

Καρατζάς Γεώργιος (Επιβλέπων)

Νικολός Ιωάννης

Βαρουχάκης Εμμανουήλ

Χανιά 2018

ΕΥΧΑΡΙΣΤΙΕΣ

Θα ήθελα αρχικά να ευχαριστήσω τον επιβλέποντα καθηγητή μου Δρ. Γεώργιο Καρατζά που μου έδωσε την ευκαιρία να επιλέξω αυτό το απαιτητικό αλλά πολύ ενδιαφέρον θέμα.

Ιδιαίτερα, θα ήθελα να ευχαριστήσω θερμά τον καθηγητή Δρ. Ιωάννη Νικολό από την Σχολή Μηχανικών Παραγωγής και Διοίκησης για τον πολύ χρόνο και την προσπάθεια που αφιέρωσε καθ όλη την διάρκεια αυτής της χρονοβόρας εργασίας, ώστε να με καθοδηγήσει και να μου παράσχει ότι βοήθεια και υλικό χρειαζόταν.

Επίσης θα ήθελα να ευχαριστήσω πολύ την Παναγιώτα Θεοδωρίδου για την παροχή των δεδομένων στα οποία βασίστηκε αυτή η διπλωματική καθώς και για την πολύτιμη βοήθεια, τις λεπτομέρειες και το υλικό που μου έδωσε για αυτά.

Επιπλέον θα ήθελα να ευχαριστήσω τον Δρ. Εμμανουήλ Βαρουχάκη για την συμμετοχή του στην εξεταστική επιτροπή.

ΠΕΡΙΛΗΨΗ

Σκοπός αυτής της εργασίας είναι η χωρική εκτίμηση του υδραυλικού ύψους ενός υδροφορέα στον νομό Δράμας με την χρήση ενός είδους τεχνητού νευρωνικού δικτύου που λέγεται δίκτυο ακτινικών συναρτήσεων βάσης (RBFN–RadialBasisFunctionNetwork).

Οι συμβατικές τεχνικές μοντελοποίησης συχνά είναι χρονοβόρες και δαπανηρές και έχουν περιορισμούς σε δεδομένα και γνώση. Τα τεχνητά νευρωνικά δίκτυα παρέχουν μια εναλλακτική απέναντι σε αυτά τα εμπόδια, καθώς μπορούν να παρέχουν λύσεις χωρίς να καθορίσουν τη σχέση μεταξύ των δεδομένων και των αποτελεσμάτων, με το να εκπαιδεύονται από δεδομένα και να γενικεύουν. Η λειτουργία τους βασίζεται στην βιολογία του ανθρώπινου εγκεφάλου και αποτελούν ένα είδος τεχνητής νοημοσύνης.

Τα τεχνητά νευρωνικά δίκτυα εκπαιδεύονται τροποποιώντας τις ενδονευρωνικές δυνάμεις σύνδεσης γνωστές ως συναπτικά βάρη μεταξύ των τεχνητών τους νευρώνων. Αυτό γίνεται τροφοδοτώντας το δίκτυο με παραδείγματα εισόδου-εξόδου, ώστε να τους παρέχεται μια επιθυμητή απάντηση σε δεδομένα εισόδου και έτσι να τροποποιήσουν κατάλληλα τα συναπτικά τους βάρη, ανάλογα με έναν κανόνα μάθησης. Μετά από ένα μεγάλο αριθμό επαναλήψεων το τεχνητό νευρωνικό δίκτυο έχει κατασκευάσει μια χαρτογράφηση εισόδου- εξόδου και έχει προσαρμοστεί στο πρόβλημα.

Στην περιοχή μελέτης έχουμε δεδομένα από 250 σημεία από πηγάδια παρατήρησης. Για κάθε σημείο έχουμε συντεταγμένες x , y και μετρήσεις υδραυλικού ύψους. Το νευρωνικό δίκτυο εκπαιδεύτηκε στην πλειοψηφία των δεδομένων και δοκιμάστηκε η ακρίβεια του σε έναν μικρό αριθμό του συνόλου δεδομένων. Πραγματοποιήθηκαν επίσης δοκιμές χωρίζοντας το σύνολο δεδομένων σε υποσύνολα και εκπαιδεύοντας το νευρωνικό δίκτυο σε αυτά, καθώς και δοκιμές σε τυχαία δεδομένα. Εξετάστηκε η ακρίβεια του νευρωνικού δικτύου σε κάθε περίπτωση και έγινε γραφική αναπαράσταση των αποτελεσμάτων και της απόκλισης από τις τιμές μέτρησης.

ABSTRACT

The purpose of this work is to estimate the hydraulic head of an aquifer in the regional unit of Drama using an artificial neural network called RBFN (Radial Basis Function Network).

Conventional modeling techniques are often time-consuming and costly and have limitations in data and knowledge. Artificial neural networks provide an alternative to these obstacles, as they can provide solutions without defining the relationship between the data and the results, by being trained by data and generalizing. Their function is based on the biology of the human brain and is a form of artificial intelligence.

Artificial neural networks are trained by modifying the interneuronconnection strengths, known as synaptic weights, between their artificial neurons. This is done by feeding the network with input-output examples, to give them a desired response to input data and, thus, to modify their synaptic weights according to a learning rule. After a large number of iterations, the artificial neural network has constructed an input-output mapping and has adapted to the problem.

In the study area we have data from 250 points from observation wells. For each point we have coordinates x , y and hydraulic head measurements. The neural network was trained on the majority of data and its accuracy was tested on a small number of testing data. Tests were performed by dividing the data set into subsets and training the neural network with each of them, as well as tests with random data. The accuracy of the neural network was examined in each case and graphical representations of the results and deviations from the measurement values were made.

ΠΕΡΙΕΧΟΜΕΝΑ

ΕΥΧΑΡΙΣΤΙΕΣ	i
ΠΕΡΙΛΗΨΗ	ii
ABSTRACT.....	iii
ΠΕΡΙΕΧΟΜΕΝΑ	iv
1. ΕΙΣΑΓΩΓΗ	1
1.1 ΥΠΟΓΕΙΑ ΥΔΑΤΑ	1
1.2 ΤΕΧΝΙΚΕΣ ΜΟΝΤΕΛΟΠΟΙΗΣΗΣ	2
1. 3 ΤΟ ΠΡΟΒΛΗΜΑ	5
2. ΥΠΟΒΑΘΡΟ ΚΑΙ ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ	8
2.1 ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ (ANN)	8
2.1.1 Ορισμός	8
2.1.2 Ανθρώπινος εγκέφαλος και τεχνητά νευρωνικά δίκτυα (ANN)	9
2.1.3 Θεμελιώδη στοιχεία τεχνητών νευρωνικών δικτύων (ANN)	10
2.1.4 Συνάρτηση ενεργοποίησης.....	11
2.1.5 Αρχιτεκτονικές τεχνητών νευρωνικών δικτύων (ANN)	14
2.1.6 Είδη μάθησης	15
2.1.7 Ιστορία ANN	16
2.1.8 Πλεονεκτήματα των τεχνητών νευρωνικών δικτύων (ANN)	17
2.1.9 Πολυστρωματικά δίκτυα perceptron (MLP)	19
2.1.10 Δίκτυα ακτινικών συναρτήσεων βάσης (RBFN)	21
2.1.11 Σύγκριση MLP και RBFN	23
2.2 ΠΑΛΑΙΟΤΕΡΕΣ ΕΡΓΑΣΙΕΣ	24
2.2.1 Χρήσεις MLPγια χωρικές προβλέψεις	24
2.2.2 Χρήσεις RBFN για χωρικές προβλέψεις	26
3. ΜΕΘΟΔΟΣ ΚΑΙ ΕΦΑΡΜΟΓΗ	35

3.1 Ο ΑΛΓΟΡΙΘΜΟΣ ΤΟΥ ANN	35
3.1.1 Χαρακτηριστικά	35
3.1.2 Δομή των αρχείων εισόδου	36
3.1.3 Δομή των αρχείων εξόδου	40
3.2 ΔΟΚΙΜΗ ΤΟΥ ΑΛΓΟΡΙΘΜΟΥ RBFN	42
3.2.1 Δοκιμές με ολόκληρο το σύνολο δεδομένων	42
3.2.2 Δοκιμές σε υποσύνολα των δεδομένων	45
3.2.3 Χάρτες Ισοϋψών	53
3.2.4 Δοκιμή με τυχαία δεδομένα	57
3.2.5 Παρατηρήσεις	60
4. ΣΥΜΠΕΡΑΣΜΑΤΑ	61
ΒΙΒΛΙΟΓΡΑΦΙΑ	62

ΚΕΦΑΛΑΙΟ 1 : ΕΙΣΑΓΩΓΗ

1.1 ΥΠΟΓΕΙΑ ΥΔΑΤΑ

Τα υπόγεια ύδατα είναι ύδατα που υπάρχουν σε πορώδεις σχηματισμούς και σε ρήγματα σε πετρώματα και ιζήματα κάτω από την επιφάνεια της Γης. Προέρχονται από βροχή ή χιόνι και στη συνέχεια μετακινούνται μέσω του εδάφους στο σύστημα υπογείων υδάτων, όπου τελικά επιστρέφουν στις επιφανειακές ροές, τις λίμνες ή τους ωκεανούς. Αν και τα υπόγεια ύδατα αποτελούν μόνο το 1% του νερού στη γη (καθώς το μεγαλύτερο μέρος τους βρίσκεται στους ωκεανούς), συνιστούν 35 φορές την ποσότητα νερού σε λίμνες και επιφανειακές υδάτινες ροές (Nelson, 2015). Σε παγκόσμιο επίπεδο, περισσότερο από το ένα τρίτο του συνόλου των υδάτων που χρησιμοποιούνται από τον άνθρωπο προέρχεται από υπόγεια ύδατα. Στις αγροτικές περιοχές το ποσοστό είναι ακόμη υψηλότερο, με περισσότερο από το ήμισυ του συνόλου του πόσιμου νερού να παρέχεται από τα υπόγεια ύδατα.


Οι γεωλογικοί σχηματισμοί, από τους οποίους μπορούν να αντληθούν σημαντικές ποσότητες υπογείων υδάτων για οικιακές, δημοτικές ή γεωργικές χρήσεις, είναι γνωστοί ως υδροφορείς. Μερικές φορές οι υδροφορείς χωρίζονται κάθετα μεταξύ τους από γεωλογικούς σχηματισμούς, που επιτρέπουν ελάχιστο ή καθόλου νερό να ρέει μέσα ή έξω. Αν είναι πολύ λιγότερο διαπερατό από έναν κοντινό υδροφόρο, αλλά εξακολουθεί να επιτρέπει περιορισμένη ροή (π.χ. αμμώδης πηλός), ένας τέτοιος σχηματισμός, επιβραδυντικός της ροής, ονομάζεται *aquitard*. Όταν το φράγμα νερού είναι σχεδόν αδιαπέραστο (π.χ. πηλός) και σχηματίζει έτσι ένα τεράστιο φράγμα ροής μεταξύ των υδροφορέων, ονομάζεται *aquiclude* (Harter, 2003). Υπάρχουν δύο τύποι υδροφορέων:

Ελεύθερος υδροφορέας: Αυτός είναι ο πιο κοινός τύπος υδροφορέα, όπου ο υδροφόρος ορίζοντας εκτίθεται στην ατμόσφαιρα της γης μέσω της ζώνης αερισμού.

Περιορισμένος (αρτεσιανός) υδροφορέας: Είναι ουδροφορέας που περιορίζεται ανάμεσα σε στρώματα αδιαπέραστων σχηματισμών (*aquitards*).

Όταν η βροχή πέφτει στην επιφάνεια, εισχωρεί μέσα από το έδαφος και φθάνει σε μια ζώνη που ονομάζεται ακόρεστη ζώνη, όπου οι περισσότεροι πόροι είναι γεμάτοι με αέρα. Καθώς διεισδύει βαθύτερα, εισέρχεται τελικά σε μια ζώνη όπου όλοι οι χώροι των πόρων και τα ρήγματα είναι γεμάτοι με νερό. Αυτή η ζώνη είναι η κορεσμένη ζώνη. Η ζώνη κάτω από αυτήν, όπου όλοι οι κενοί χώροι των πετρωμάτων είναι πλήρεις ύδατος, ονομάζεται υδροφόρος ορίζοντας.

Ο υδροφόρος ορίζων υπάρχει παντού κάτω από τη Γη, ακόμη και σε ερημώδεις περιοχές, αλλά σπάνια διατέμνει την επιφάνεια. Σε πιο υγρές περιοχές φτάνει στην επιφάνεια υπό μορφήν επιφανειακών ροών, ή λιμνών και γενικά ακολουθεί την τοπογραφία της επιφάνειας. Το βάθος του νερού αλλάζει ανάλογα με την ποσότητα νερού που ρέει μέσα και έξω από την κορεσμένη ζώνη. Για παράδειγμα, κατά τη διάρκεια ξηρών εποχών, το βάθος του υδροφόρου ορίζοντα αυξάνεται, ενώ κατά τη διάρκεια υγρών εποχών το βάθος του μειώνεται (Nelson, 2015).



Εικόνα 1.1: Διάγραμμα υδροφόρου ορίζοντα (USGS, 2016) .

Τα υπόγεια ύδατα μετακινούνται από μεγαλύτερα υψόμετρα σε χαμηλότερα υψόμετρα και από θέσεις υψηλότερης πίεσης σε θέσεις χαμηλότερης πίεσης. Τυπικά, αυτή η κίνηση είναι αρκετά αργή, επειδή το νερό πρέπει να περάσει ανάμεσα από τους ελεύθερους χώρους των βράχων. Στην υδραυλική των υπογείων υδάτων η επιφάνεια πίεσης νερού και η ανύψωση του υδροφόρου ορίζοντα αναφέρονται ως υδραυλικό ύψος. Το υδραυλικό ύψος είναι η κινητήρια δύναμη πίσω από την μεταφορά των υπόγειων υδάτων, καθώς η ροή πραγματοποιείται πάντα προς την κάτω κατεύθυνση της κλίσης του υδραυλικού ύψους. Εάν δεν υπάρχει κλίση του υδραυλικού ύψους, δεν υπάρχει ροή (Harter, 2003).

Για να προσπελαστεί ο υδροφόρος ορίζοντας πρέπει να κατασκευαστεί ένα πηγάδι. Πηγάδι είναι μια εκσκαφή που μπορεί να χρησιμοποιηθεί ως πηγή υπογείων υδάτων. Εάν εξορύξουμε διαμέσω του ορίζοντα, το νερό θα γεμίσει τον εξορυχθέντα χώρο έως το επίπεδο του υδροφόρου ορίζοντα και μπορεί να αντληθεί με ένα κουβά ή μηχανικά (Nelson, 2015). Το ύψος των υπόγειων υδάτων μπορεί επίσης να μετρηθεί μέσω των πηγαδιών, κάτι που είναι σημαντικό για αυτήν την εργασία. Ένα πηγάδι επιτήρησης υπογείων υδάτων είναι ένα είδος πηγαδιού κατασκευασμένο για τον συγκεκριμένο αυτόν σκοπό.

1.2 ΤΕΧΝΙΚΕΣ ΜΟΝΤΕΛΟΠΟΙΗΣΗΣ

Οι συμβατικές τεχνικές μοντελοποίησης είναι συνήθως μαθηματικές-αναλυτικές μέθοδοι για ακριβή μοντελοποίηση των διεργασιών, διεξάγοντας λεπτομερείς μελέτες των φυσικών, χημικών και άλλων παραμέτρων. Αυτή είναι μια διαδικασία χρονοβόρα και δαπανηρή, η οποία απαιτεί μεγάλη προσαρμογή του μοντέλου. Σε πολλές περιπτώσεις αυτή η προσέγγιση δεν είναι πραγματικά εφαρμόσιμη, λόγω περιορισμένων δεδομένων και γνώσης.

Στις υδρολογικές διεργασίες, οι συμβατικές τεχνικές μοντελοποίησης περιλαμβάνουν στατιστικά μοντέλα και φυσικά υδρολογικά μοντέλα.

Στατιστικά μοντέλα: Τα υδρολογικά φαινόμενα είναι εγγενώς τυχαία και πολύπλοκα από τη φύση τους, καθιστώντας δύσκολη την ανάπτυξη αιτιοκρατικών μαθηματικών μοντέλων που θα περιέγραφαν τις φυσικές διεργασίες τους (Grimaldi et al., 2011). Ως εκ τούτου, έχουν χρησιμοποιηθεί στατιστικές προσεγγίσεις για την παροχή επαρκών αναλύσεων. Οι στατιστικές μέθοδοι εξαρτώνται από τη διαθεσιμότητα και την ποιότητα των δεδομένων, επομένως επηρεάζονται έντονα από τις συνθήκες του διαθέσιμου συνόλου δεδομένων. Η προσομοίωση, η πρόβλεψη, η ανάλυση αβεβαιότητας, η ανάλυση επικινδυνότητας και η χωρική παρεμβολή είναι κάποια από τα πιο σημαντικά στατιστικά μοντέλα (Grimaldi et al., 2011).

Υδρολογική μοντελοποίηση βασισμένη στη φυσική: Η προσέγγιση αυτή βασίζεται στην κατανόηση της φυσικής των υδρολογικών διεργασιών και των φυσικών εξισώσεων που περιγράφουν αυτές τις διεργασίες (Seth, 2009). Αφού προσδιοριστούν οι δεσμοί μεταξύ των συνιστωσών του μοντέλου, μπορεί να βρεθεί λύση μέσω αριθμητικών μεθόδων. Δεδομένου ότι τα δεδομένα εισροών και οι υπολογιστικές απαιτήσεις είναι τεράστιες, η χρήση τους δεν είναι πρακτική για την πρόβλεψη σε πραγματικό χρόνο (Seth, 2009). Παραδείγματα περιλαμβάνουν μοντέλα απορροής με βάση τις εξισώσεις St. Venant, μοντέλα διήθησης βασισμένα σε θεωρία ροής δύο φάσεων σε πορώδες μέσον και μοντέλα εξάτμισης με βάση τις θεωρίες της τυρβώδους ροής και της διάχυσης (Xu, 2002).

Κοινά λογισμικά υδρολογικής μοντελοποίησης είναι μεταξύ άλλων, τα MODFLOW και SWAT. Το MODFLOW προέρχεται από την Γεωλογική Υπηρεσία των Η.Π.Α. και χρησιμοποιείται εκτενώς παγκοσμίως για τη διαχείριση των υπόγειων υδάτινων πόρων (Akram et al., 2012). Πρόκειται για ένα τριδιάστατο περιβάλλον μοντελοποίησης ροής υπόγειων υδάτων, που μπορεί να χρησιμοποιηθεί για πρακτικές εφαρμογές και προσομοίωση μεταφοράς ρύπων. Λειτουργεί με την επίλυση ενός συστήματος εξισώσεων, που περιγράφει τη κύρια ροή, χρησιμοποιώντας μεθόδους πεπερασμένων διαφορών (Akram et al., 2012). Το SWAT είναι ένας συνεχής ημικατανεμημένος προσομοιωτής λεκάνης απορροής, που λειτουργεί σε ημερήσιο βήμα. Οι συνιστώσες του είναι η υδρολογία, ο καιρός, η διάβρωση, η ανάπτυξη των φυτών, τα θρεπτικά συστατικά, τα φυτοφάρμακα, η διαχείριση της γης και η δρομολόγηση των ρευμάτων (Arnold et al., 1998). Το ArcSWAT είναι μια διεπιδραστική έκδοση του SWAT, που είναι ενσωματωμένη στο ArcGIS.

Οι πολυπαραγοντικές προσεγγίσεις (multivariate approaches) είναι μέθοδοι που εξετάζουν διαφορετικούς παράγοντες επιρροής και τις σχέσεις τους και επιτρέπουν μια ορισμένη γενίκευση (Noack et al., 2014). Πολύ συνηθισμένες πολυπαραγοντικές προσεγγίσεις περιλαμβάνουν ανάλυση παραγόντων, ανάλυση διακρίσεων και ανάλυση συμπλέγματος.

Ανάλυση Παραγόντων (Factor Analysis): Αυτή η τεχνική χρησιμοποιείται όταν υπάρχουν πολλές μεταβλητές σε ένα ερευνητικό σχέδιο και η μείωση τους σε ένα μικρότερο σύνολο παραγόντων είναι απαραίτητη (Richarme, 2002). Δεν υπάρχει

εξαρτώμενη μεταβλητή και ο ερευνητής αναζητά την υποκείμενη δομή του πίνακα δεδομένων. Λειτουργεί βέλτιστα όταν οι ανεξάρτητες μεταβλητές είναι κανονικές και συνεχείς, με τουλάχιστον 3 έως 5 μεταβλητές για κάθε παράγοντα (Richarme, 2002).

Διακριτική ανάλυση (Discriminantanalysis): Αυτή η προσέγγιση χρησιμοποιείται για να περιγράψει χαρακτηριστικά που είναι ειδικά για ξεχωριστές ομάδες και να ταξινομήσει περιπτώσεις σε προϋπάρχουσες ομάδες με βάση τις ομοιότητες μεταξύ της κατάστασης και της άλλης κατάστασης που ανήκει στις ομάδες. Μαθηματικά αυτό σημαίνει ότι ο στόχος είναι να σταθμίσουμε και να συνδυάσουμε γραμμικά τις πληροφορίες από ένα σύνολο εξαρτημένων μεταβλητών p έτσι ώστε οι ομάδες k να είναι όσο το δυνατόν πιο διακριτές (Brown et al., 2000). Ο στόχος είναι συνήθως η εξεύρεση μιας εξίσωσης πρόβλεψης για την ταξινόμηση νέων καταστάσεων ή για την ερμηνεία της εξίσωσης πρόβλεψης, με σκοπό την καλύτερη κατανόηση των σχέσεων μεταξύ των μεταβλητών (Richarme, 2002).

Ανάλυση συμπλέγματος (ClusterAnalysis): Ο σκοπός αυτής της μεθόδου είναι να διαιρέσει μεγάλα σύνολα δεδομένων σε υποομάδες, που έχουν μεγαλύτερη σημασία (Richarme, 2002). Η διαίρεση αυτή γίνεται με βάση την ομοιότητα των αντικειμένων σχετικά με ορισμένα χαρακτηριστικά. Οι αποκλίσεις μπορεί να είναι ένα πρόβλημα και μπορεί να προκληθούν από πάρα πολλές μη σχετικές μεταβλητές. Είναι καλύτερα το δείγμα να είναι αντιπροσωπευτικό του πληθυσμού (Richarme, 2002).

Σε σύγκριση με την ακριβή μαθηματική-αναλυτική-αριθμητική μοντελοποίηση, οι πολυπαραγοντικές προσεγγίσεις προσφέρουν αρκετά πλεονεκτήματα (Noacketal., 2014):

- Ισχύουν ακόμη και αν οι σχέσεις μεταξύ της εξαρτώμενης μεταβλητής και των παραγόντων επηρεασμού δεν είναι πραγματικά γνωστές.
- Λαμβάνουν υπόψη πολλούς παράγοντες επιρροής.
- Εργάζονται με τα διαθέσιμα δεδομένα.
- Είναι συγκριτικά γρήγορες και εύκολες στη χρήση.

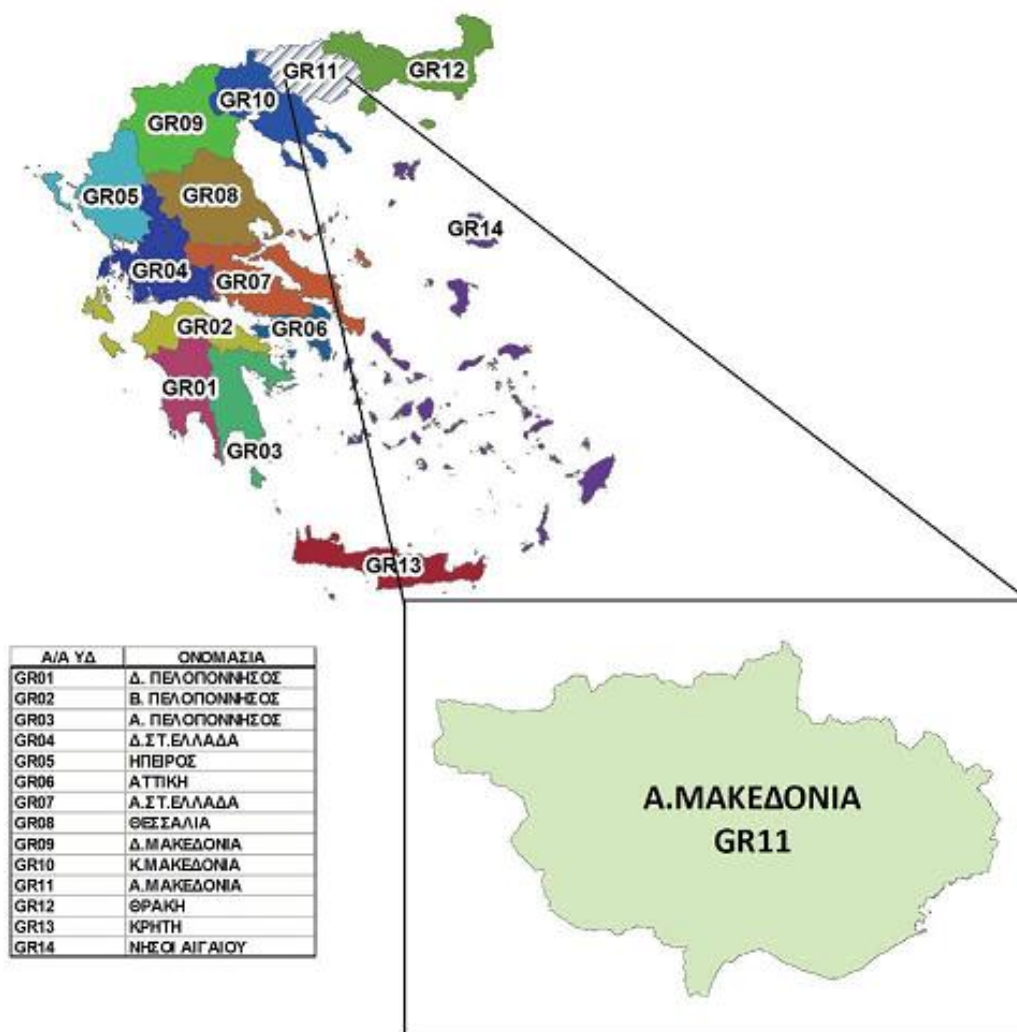
Τα τεχνητά νευρικά δίκτυα (ANNs) παρέχουν μια πολυπαραγοντική ανάλυση δεδομένων. Με το να εκπαιδεύονται από συγκεκριμένα παραδείγματα, μπορούν να μάθουν τη λύση σε σύνθετα προβλήματα χωρίς έναν ρητό προγραμματισμό. Αυτό επιτρέπει στο χρήστη να παράγει ένα ευλογοφανές αποτέλεσμα, ακόμη και όταν οι λεπτομέρειες της σχέσης μεταξύ της εξαρτώμενης τιμής και του παράγοντα ελέγχου είναι άγνωστες (Noacketal., 2014).

1.3 ΤΟ ΠΡΟΒΛΗΜΑ

Περιοχή μελέτης και διαθέσιμα δεδομένα


Η περιοχή μελέτης βρίσκεται στον νομό Δράμας στη Βόρεια Ελλάδα. Τα δεδομένα συλλέχτηκαν από τη Διοίκηση Υδάτων της Ανατολικής Μακεδονίας και Θράκης και από τη Διοίκηση Περιβάλλοντος και Χωροταξικού Σχεδιασμού Δράμας. Η περιοχή ανήκει στο υδάτινο διαμέρισμα της Ανατολικής Μακεδονίας (GR11), το οποίο καλύπτει έκταση 7.320 km². Το υδάτινο διαμέρισμα αποτελείται κυρίως από πεδιάδες και μια μικρή ποσότητα ορεινού και ημιορεινού εδάφους. Οι πεδιάδες της Δράμας και των Σερρών είναι το μεγαλύτερο μέρος της περιοχής.

Το κλίμα της περιοχής είναι ημιηπειρωτικό, με μέση θερμοκρασία από 14,5 °C έως 16 °C. Τα καλοκαίρια είναι ζεστά και οι χειμώνες είναι κρύοι, με τον Ιανουάριο να είναι ο πιο κρύος μήνας και τον Ιούλιο να είναι ο πιο θερμός. Το μέσο ετήσιο ύψος βροχής είναι μεταξύ 508 mm και 576 mm. Η κύρια χρήση του νερού στην περιοχή του νερού είναι για άρδευση (92%).




Εικόνα 1.2 Τα υδάτινα διαμερίσματα της Ελλάδας και το υδάτινο διαμέρισμά της Ανατολικής Μακεδονίας (GR11)

Η περιοχή ενδιαφέροντος, εντός της οποίας συλλέχθηκαν τα δεδομένα, έχει έκταση 210 km². Ο υδροφορέας καλύπτεται κυρίως από αλλουβιακές αποθέσεις και βρίσκεται κάτω από τμήματα των περιοχών Δράμας, Προσοτσάνης και Δοξάτου.



Εικόνα 1.3 Η περιοχή μελέτης και η θέση της εντός της υδατικής περιοχής της Ανατολικής Μακεδονίας (GR11).

Τα δεδομένα συλλέγονται από ένα δίκτυο παρακολούθησης υπογείων υδάτων με 250 πηγάδια. Κάθε φρεάτιο ορίζεται από τις συντεταγμένες x και y και από το υδραυλικό του ύψος z (σε μέτρα).



Εικόνα 1.4 Χωρική κατανομή των 250 πηγαδιών.

Σκοπός

Ο σκοπός αυτής της εργασίας είναι να παράσχει μια χωρική εκτίμηση του υδραυλικού ύψους του υδροφορέα στην περιοχή ενδιαφέροντός μας με τη χρήση ενός τύπου ANN που ονομάζεται RadialBasisFunctionNetwork (RBFN). Θα καθορίσει εάν αυτός ο τύπος δικτύου μπορεί να χρησιμοποιηθεί αποτελεσματικά για ακριβή χωρική εκτίμηση της ανύψωσης της επιφάνειας του νερού και συνεπώς αν μπορεί να χρησιμοποιηθεί αποτελεσματικά και ικανά ως εναλλακτική λύση στις συμβατικές τεχνικές μοντελοποίησης (αριθμητική επίλυση των εξισώσεων ροής).

ΚΕΦΑΛΑΙΟ 2 : ΥΠΟΒΑΘΡΟ ΚΑΙ ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ

2.1 ΤΕΧΝΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ (ANN)

2.1.1 Ορισμός

Όπως αναφέρθηκε προηγουμένως, οι πολυπαραγοντικές προσεγγίσεις, όπως τα τεχνητά νευρωνικά δίκτυα, δίνουν τη δυνατότητα να προσδιορίσουν τα δεδομένα που λείπουν, χωρίς να γνωρίζουν τις φυσικές παραμέτρους του συστήματος που εξετάζεται. Το μόνο που απαιτείται είναι η μέτρηση της στάθμης (υδραυλικό ύψος) του υδροφόρεα, σε γνωστές/συγκεκριμένες συντεταγμένες, ώστε να εκπαιδευθεί το δίκτυο να προβλέπει το ύψος σε άλλες συντεταγμένες.

Ένα τεχνητό νευρωνικό δίκτυο (ANN) είναι ένα υπολογιστικό μοντέλο σχεδιασμένο για να προσομοιώνει τους νευρώνες του ανθρώπινου εγκεφάλου, που είναι σε θέση να εκτελούν αυτές τις συγκεκριμένες εργασίες επεξεργασίας πληροφοριών. Πρόκειται για ένα σύστημα που αποτελείται από πολλούς απλούς κόμβους επεξεργασίας, των οποίων η λειτουργία καθορίζεται από τη δομή του δικτύου και τα συναπτικά βάρη (Gopal 2017).

Η γνώση αποκτάται από το δίκτυο από το περιβάλλον του μέσα από μια διαδικασία μάθησης. Η διαδικασία που χρησιμοποιείται για τη διεξαγωγή της μαθησιακής διαδικασίας ονομάζεται αλγόριθμος μάθησης, η λειτουργία της οποίας είναι να τροποποιήσει τα συναπτικά βάρη του δικτύου κατά τρόπο ομαλό, ώστε να επιτευχθεί ένας σχεδιαστικός στόχος. Οι ενδονευρωνικές δυνάμεις σύνδεσης, γνωστές ως συναπτικά βάρη, χρησιμοποιούνται για την αποθήκευση της αποκτηθείσας γνώσης (Haykin, 1999). Κάθε τεχνητός νευρώνας λαμβάνει ένα ή περισσότερα σήματα εισόδου και τα αθροίζει για να παράγει μια έξοδο. Τα ποσά κάθε κόμβου σταθμίζονται και οι τιμές περνούν μέσω μιας μη γραμμικής συνάρτησης, γνωστής ως συνάρτηση ενεργοποίησης ή συνάρτησης μεταφοράς. Η συνάρτηση μεταφοράς στα νευρωνικά δίκτυα τύπου MLP (Multilayer perceptron) είναι συνήθως μια σιγμοειδής συνάρτηση (Gopal, 2017).

Χάρη στην ικανότητά τους να μαθαίνουν από τα δεδομένα, τα νευρωνικά δίκτυα μπορούν να προσαρμοστούν στις αλλαγές στο περιβάλλον και να αντιμετωπίσουν με πολύ αποτελεσματικό τρόπο τις ελλείψεις πληροφορίες και τα θορυβώδη δεδομένα. Σε αντίθεση με τα αριθμητικά μοντέλα, μπορούν να είναι χρήσιμα σε προβλήματα όπου δεν είναι δυνατόν να οριστούν οι κανόνες ή τα βήματα που οδηγούν σε λύση (Gopal 2017). Έχουν εφαρμογές σε πολλούς τομείς, όπως τα χρηματοοικονομικά, η τεχνολογία, η ρομποτική, η προσομοίωση, ο αυτόματος έλεγχος, ενώ η χρήση τους συνεχίζει να επεκτείνεται καθώς αυξάνεται η ποσότητα των δεδομένων παγκοσμίως, καθώς και η ταχύτητα επεξεργασίας δεδομένων των υπολογιστών (Gopal, 2017).


Η προσομοίωση του τρόπου λειτουργίας του ανθρώπινου εγκεφάλου βρίσκεται στο επίκεντρο της έννοιας των τεχνητών νευρωνικών δικτύων και της έρευνας που έχει πραγματοποιηθεί γύρω από αυτά. Επομένως, θα ήταν χρήσιμο να αναφερθούμε σύντομα στη δομή και τη λειτουργία του ανθρώπινου εγκεφάλου.

2.1.2 Ανθρώπινος εγκέφαλος και τεχνητά νευρωνικά δίκτυα (ANN)

Η συνειδητοποίηση ότι ο ανθρώπινος εγκέφαλος δεν λειτουργεί ως ένας συμβατικός υπολογιστής, αλλά αντίθετα μέσω μιας πολύ σύνθετης, μη γραμμικής και παράλληλης λειτουργίας, που του επιτρέπει να επεξεργάζεται τις πληροφορίες με τεράστια ταχύτητα και ευκολία, έχει προκαλέσει το επιστημονικό ενδιαφέρον για την σημαντική εξέλιξη στον τομέα της τεχνητής νοημοσύνης (Haykin, 1999).


Ο εγκέφαλος είναι το κεντρικό τμήμα του ανθρώπινου νευρικού συστήματος και αποτελείται από εκατοντάδες δισεκατομμύρια νευρικά κύτταρα, τους νευρώνες. Η συνεργασία μεταξύ αυτών των δισεκατομμυρίων νευρώνων έχει ως αποτέλεσμα μια ενοποιημένη, συντονισμένη και οργανωμένη ανθρώπινη συμπεριφορά (Kalat, 2001). Η ιδέα των νευρώνων ως δομικών τεμαχίων του ανθρώπινου εγκεφάλου εισήχθη από τον Ramon y Cajal πριν από έναν αιώνα και διευκόλυνε σημαντικά την κατανόηση αυτού του περίπλοκου θέματος (Haykin, 1999). Περαιτέρω, κάθε νευρώνας αποτελείται από:

- **Το σώμα των κυττάρων**, όπου αποθηκεύονται όλες οι γενετικές πληροφορίες και πραγματοποιείται το μεγαλύτερο μέρος της μεταβολικής του δραστηριότητας.
- **Τους δενδρίτες**, οι οποίοι εξέχουν από το κυτταρικό σώμα και εμπεριέχουν τις συνάψεις, δηλαδή τις συνδετικές μονάδες μεταξύ των νευρώνων.
- **Τον άξονα**, ένα ενιαίο και πολύ μακρύτερο νήμα που ξεκινάει από το σώμα του κυττάρου. Ο άξονας είναι υπεύθυνος για τη μετάδοση «δυνατοτήτων δράσης» (σύντομων παλμών τάσης) κατά μήκος του σώματός του προς έναν άλλο νευρώνα. Κάθε άξονας, με τη σειρά του, τελειώνει επίσης σε συναπτικά τερματικά.



Εικόνα 2.1: Βιολογικός νευρώνας (Woodford, 2018).

Στην παραπάνω περιγραφή οι συνάψεις κατέχουν μια θέση κλειδί στην επικοινωνία μεταξύ των νευρώνων. Η πρωτοποριακή εργασία στον τομέα αυτό πραγματοποιήθηκε από τον Sherrington ήδη από το 1906, ο οποίος εισήγαγε για πρώτη φορά τον όρο (Kalat, 2001). Οι συνάψεις είναι οι βασικές μονάδες σύνδεσης και λειτουργίας, που επιτρέπουν την αλληλεπίδραση μεταξύ νευρώνων. Αυτή η αλληλεπίδραση είναι κυρίως χημικής φύσης. Μια ουσία εκπομπής (χημική) απελευθερώνεται μέσω μιας προσυναπτικής διαδικασίας. Αυτή η ουσία διαχέεται σε όλη τη συναπτική σύνδεση μεταξύ νευρώνων και στη συνέχεια ξεκινά μια μετασυναπτική διαδικασία. Επομένως, η συναπτική σύνδεση μεταξύ νευρώνων γεφυρώνεται με τον ακόλουθο τρόπο: Ένα προσυναπτικό ηλεκτρικό σήμα μετατρέπεται σε ένα χημικό σήμα και στη συνέχεια πίσω σε ένα μετασυναπτικό ηλεκτρικό σήμα (Haykin, 1999).



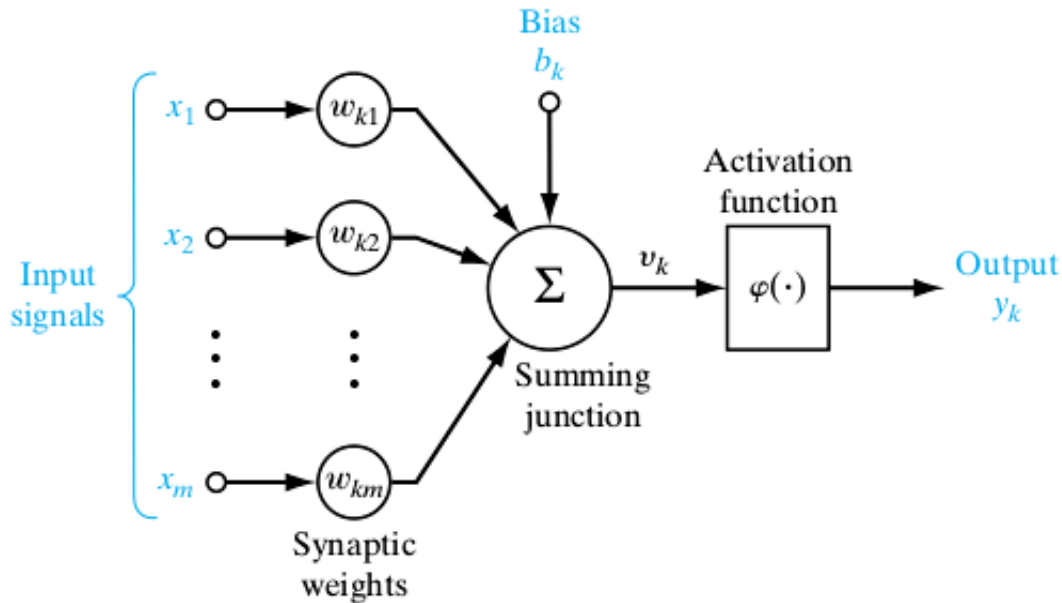
Εικόνα 2.2: Αντιπροσωπευτική απεικόνιση του νευρικού συστήματος (Haykin, 1999).

Στο παραπάνω σχήμα το ανθρώπινο νευρικό σύστημα απεικονίζεται ως σύστημα τριών σταδίων. Ο εγκέφαλος αντιπροσωπεύεται από το νευρωνικό δίκτυο που κατέχει κεντρική θέση στο σύστημα και το οποίο λαμβάνει συνεχώς πληροφορίες, τις επεξεργάζεται και λαμβάνει τις κατάλληλες αποφάσεις. Οι υποδοχείς μετατρέπουν τα ερεθίσματα (εισροές) από το ανθρώπινο σώμα ή το εξωτερικό περιβάλλον σε ηλεκτρικές παλμούς. Αυτά, με τη σειρά τους μεταφέρουν πληροφορίες στο νευρωνικό δίκτυο (στον εγκέφαλο). Τέλος, οι ηλεκτρικοί παλμοί που παράγονται από το νευρικό δίκτυο συνδέονται σε αποκρίσεις (εξόδους συστήματος) από τους τελεστές.

2.1.3 Θεμελιώδη στοιχεία τεχνητών νευρωνικών δικτύων (ANN)

Σε αυτό το κεφάλαιο θα παρουσιαστούν τα βασικά στοιχεία των τεχνητών νευρωνικών δικτύων και των βασικών δομικών στοιχείων. Στη συνέχεια, στα κεφάλαια που ακολουθούν, θα εξετασθούν διάφορα είδη αρχιτεκτονικής και νευρωνικών δικτύων, που είναι παραλλαγές αυτών των βασικών στοιχείων.

Ο νευρώνας είναι η βασική μονάδα επεξεργασίας πληροφοριών, που είναι ζωτικής σημασίας για τη λειτουργία του νευρωνικού δικτύου. Το μοντέλο του νευρώνα αποτελεί τη βάση για το σχεδιασμό τεχνητών νευρωνικών δικτύων (Haykin, 1999).



Εικόνα 2.3: Μη γραμμικό μοντέλο ενός νευρώνα (Haykin , 1999).

Το νευρωνικό μοντέλο αποτελείται από ένα σύνολο συνδέσεων μεταξύ των νευρώνων, που χαρακτηρίζονται από ένα βάρος. Ειδικότερα, ένα σήμα εισόδου x της συνάψεως j συνδεδεμένο με τον νευρώνα k πολλαπλασιάζεται με το βάρος w_{kj} . Περιλαμβάνει επίσης έναν αθροιστή για την αθροιστική εισαγωγή των σημάτων εισόδου που έχουν τροποποιηθεί από τα βάρη, σε μια λειτουργία που αποτελεί έναν γραμμικό συνδυαστή. Μια συνάρτηση ενεργοποίησης μειώνει το εύρος της εξόδου των νευρώνων σε ένα ορισμένο εύρος τιμών (Haykin , 1999). Τέλος, το νευρωνικό μοντέλο περιλαμβάνει μια εξωτερικά προστιθέμενη τιμή b_k . Η τιμή αυτή είναι μια σταθερά που είναι ανεξάρτητη από την είσοδο των δικτύων αλλά προσαρμόζεται από τον κανόνα μάθησης (Krose et al , 1996).

2.1.4 Συνάρτηση ενεργοποίησης

Η συνάρτηση ενεργοποίησης δίνει την επίδραση της συνολικής εισόδου στην ενεργοποίηση της μονάδας k (νευρώνας). Είναι μια συνάρτηση φ η οποία λαμβάνει τη συνολική είσοδο και παράγει μια νέα τιμή για την ενεργοποίηση της μονάδας k (Krose Smagt , 1996). Σύμφωνα με τον (Haykin , 1999) υπάρχουν 3 τύποι λειτουργιών ενεργοποίησης (για δίκτυα MLP):

1. Λειτουργία κατωφλίου: Αυτός ο τύπος λειτουργίας ενεργοποίησης λειτουργεί ως εξής

$$\varphi(u) = \begin{cases} 1 & \text{if } u_k \geq 0 \\ 0 & \text{if } u_k < 0 \end{cases} \quad (2.1)$$


Επομένως η έξοδος του νευρώνα k γράφεται ως εξής :

$$y_k = \begin{cases} 1 & \text{if } u_k \geq 0 \\ 0 & \text{if } u_k < 0 \end{cases} \quad (2.2)$$

Το προκαλούμενο τοπικό πεδίο u_k του νευρώνα είναι,

$$u_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (2.3)$$

Η γραφική παράσταση της συνάρτησης κατωφλίου φαίνεται στην Εικόνα 2.4.




Εικόνα 2.4: Λειτουργία κατωφλίου (Haykin , 1999).

2. Τμηματική-γραμμική λειτουργία : Για αυτή τη συνάρτηση έχουμε την εξίσωση

$$\varphi(u) = \begin{cases} 1, & u \geq \frac{1}{2} \\ u, & -\frac{1}{2} < u < \frac{1}{2} \\ 0, & u \leq -\frac{1}{2} \end{cases} \quad (2.4)$$

Αυτή είναι μια ημιγραμμική εξίσωση, που λειτουργεί όπως φαίνεται στην Εικόνα 2.5.




Εικόνα 2.5: Λειτουργία τμηματικής γραμμικής συνάρτησης (Haykin , 1999).

3. Σιγμοειδής συνάρτηση: Αυτή η συνάρτηση κυρίως χρησιμοποιείται στην κατασκευή τεχνητών νευρωνικών δικτύων. Ορίζεται ως μια αυστηρά αυξανόμενη συνάρτηση, που εμφανίζει μια αρμονική ισορροπία μεταξύ γραμμικής και μη γραμμικής συμπεριφοράς. Επομένως, αυτό καθιστά τη σιγμοειδή λειτουργία ένα πολύ κοντινό μοντέλο στη λειτουργία των βιολογικών νευρώνων. Η λογιστική συνάρτηση είναι ένα παράδειγμα σιγμοειδούς συνάρτησης και ορίζεται ως

$$\varphi(u) = \frac{1}{1 + e^{-au}}. \quad (2.5)$$

Η παράμετρος a είναι η παράμετρος κλίσης, το μέγεθος της οποίας παράγει σιγμοειδείς συναρτήσεις διαφορετικών κλίσεων. Όταν το a πλησιάζει το άπειρο, η σιγμοειδής συνάρτηση μετατρέπεται σε συνάρτηση κατωφλίου. Ενώ η συνάρτηση κατωφλίου λαμβάνει τιμές 0 και 1, η σιγμοειδής συνάρτηση λαμβάνει ένα συνεχές εύρος τιμών από 0 έως 1.



Εικόνα 2.6: Σιγμοειδής συνάρτηση για μεταβλητή παράμετρο a (Haykin , 1999).

Σε ορισμένες περιπτώσεις, η συνάρτηση υπερβολικής εφαπτομένης μπορεί να χρησιμοποιηθεί ως σιγμοειδής συνάρτηση. Αυτή παράγει αποτελέσματα εξόδου από -1 έως 1.

$$\varphi(u) = \tanh(u) \quad (2.6)$$


2.1.5 Αρχιτεκτονικές τεχνητών νευρωνικών δικτύων (ANN)

Υπάρχουν διαφορετικά τεχνητά νευρωνικά δίκτυα, ανάλογα με το μοτίβο των συνδέσεων μεταξύ των νευρώνων. Η κύρια διάκριση είναι (Krose et al., 1996):

- Δίκτυα πρόσωτροφοδότησης, όπου έχουμε μια αυστηρά εμπρόσθια ροή δεδομένων από τις μονάδες εισόδου στις μονάδες εξόδου. Αυτό έχει τη δυνατότητα να εκτείνεται επί πολλά στρώματα (επίπεδα) των μονάδων, αλλά δεν υπάρχουν συνδέσεις ανατροφοδότησης που να επιτρέπουν τη ροή δεδομένων από τις μονάδες εξόδου προς μονάδες εισόδου του ίδιου ή διαφορετικού στρώματος.
- Δίκτυα Ανάδρασης: Αυτοί οι τύποι δικτύων περιέχουν συνδέσεις ανατροφοδότησης. Είναι σύνθετα δίκτυα, των οποίων οι δυναμικές ιδιότητες είναι σημαντικές. Οι τιμές ενεργοποίησης των μονάδων τους αλλάζουν μέσα από μια επαναλήπτική διαδικασία μέχρι να φτάσουν σε μια σταθερή κατάσταση.

Ανάλογα με τον αριθμό των στρώματων (επιπέδων), τα τεχνητά νευρωνικά δίκτυα μπορούν να κατηγοριοποιηθούν σε:

- Μονοστρωματικά δίκτυα πρόσωτροφοδότησης: Αυτή είναι η απλούστερη μορφή ενός δικτύου, όπου έχουμε ένα επίπεδο εισόδου με κόμβους πηγής, που τροφοδοτεί σε ένα επίπεδο εξόδου αλλά όχι το αντίστροφο (εμπροσθοτροφοδοτικά). Ο όρος "μονοστρωματικά" αναφέρεται στο στρώμα εξόδου των κόμβων υπολογισμού, καθώς τα στρώματα εισόδου δεν εκτελούν κανένα υπολογισμό (Haykin, 1999).



Εικόνα 2. 7 : Μονοστρωματικό δίκτυο προώθησης (MasFlores, 2008).

- Πολυστρωματικά δίκτυα πρόσωτροφοδότησης: Αυτό είδος της τεχνητού νευρωνικού δικτύου έχει τουλάχιστον ένα κρυφό στρώμα (επίπεδο) νευρώνων, που ονομάζονται κρυφοί νευρώνες ή κρυφές μονάδες μεταξύ των κόμβων εισόδου και εξόδου. Η λειτουργία των κρυφών μονάδων επιτρέπει στο δίκτυο να εξαγάγει στατιστικά στοιχεία υψηλής τάξης από ένα μεγάλο μέγεθος κόμβων εισόδου (Haykin, 1999).

2.1.6 Είδη μάθησης

Ένα τεχνητό νευρωνικό δίκτυο πρέπει να εκπαιδευτεί προκειμένου μια εφαρμογή ενός συνόλου εισόδων να παράξει το επιθυμητό σύνολο εξόδων. Υπάρχουν πολλοί τρόποι για να ρυθμιστούν τα βάρη των συνδέσεων μεταξύ των κόμβων. Ένας τρόπος είναι να καθοριστούν εκ των προτέρων τα βάρη, αλλά ο κυρίαρχος τρόπος είναι να εκπαιδευτεί το νευρωνικό δίκτυο, τροφοδοτώντας το με τα πρότυπα διδασκαλίας και επιτρέποντάς του να αλλάξει τα βάρη του σύμφωνα με έναν κανόνα μάθησης (Krose et al., 1996). Υπάρχουν δύο κύριοι τύποι μάθησης για τα τεχνητά νευρωνικά δίκτυα, ο εποπτευόμενος και ο χωρίς επόπτευση:

- Εποπτευόμενη Μάθηση: Αυτή η μορφή μάθησης ονομάζεται επίσης μάθηση με έναν "δάσκαλο". Ο όρος δάσκαλος αναφέρεται στη γνώση του περιβάλλοντος με τη μορφή ενός συνόλου παραδειγμάτων εισόδου-εξόδου. Όταν το νευρωνικό δίκτυο εκτίθεται, π.χ. σε ένα διάνυσμα εκπαίδευσης, τουπαρέχεται μια επιθυμητή απάντηση από τον "δάσκαλο". Ως αποτέλεσμα, οι παράμετροι του νευρωνικού δικτύου ρυθμίζονται υπό την επίδραση του διανύσματος εκπαίδευσης και του σήματος σφάλματος (η διαφορά μεταξύ της επιθυμητής απόκρισης και της πραγματικής απόκρισης). Μετά από ένα μεγάλο αριθμό επαναλήψεων της προσαρμογής, το νευρωνικό δίκτυο μπορεί να μιμηθεί τον "δάσκαλο" και να αντιμετωπίσει το περιβάλλον μόνο του (Haykin, 1999).
- Μη εποπτευόμενη μάθηση: Σε αυτή τη μορφή μάθησης, σε αντίθεση με την εποπτευόμενη μάθηση, η διαδικασία εκπαίδευσης αποτελείται μόνο από δεδομένα εισόδου. Το νευρωνικό δίκτυο ανακαλύπτει μερικές από τις ιδιότητες του συνόλου δεδομένων και μαθαίνει να τις εμφανίζει στην έξοδο του. Αναφορικά με το τι ακριβώς είναι αυτές οι ιδιότητες, εξαρτάται από τον τύπο του νευρωνικού δικτύου και τον κανόνα μάθησης (Gopal, 2017). Για παράδειγμα, μπορεί να χρησιμοποιηθεί ένας ανταγωνιστικός κανόνας μάθησης, ο οποίος περιγράφει ένα νευρωνικό δίκτυο που αποτελείται από ένα επίπεδο εισόδου και ένα ανταγωνιστικό επίπεδο. Αφού ληφθούν τα διαθέσιμα δεδομένα μέσω του επιπέδου εισόδου, το ανταγωνιστικό επίπεδο, το οποίο αποτελείται από νευρώνες που ανταγωνίζονται μεταξύ τους, ανταποκρίνεται στα χαρακτηριστικά που περιέχονται στα δεδομένα εισόδου (Haykin, 1999).

2.1.7 Ιστορία ANN

Τα παρακάτω γεγονότα και οι ημερομηνίες τους θεωρούνται τα κύρια ορόσημα στην ιστορία των τεχνητών νευρωνικών δικτύων.

Το 1943 το πρωτοποριακό έργο του McCulloch (ψυχίατρος και νευροανατόμος) και του Pitts (μαθηματικός) εισήγαγε λογικό υπολογισμό των νευρωνικών δικτύων, ενώνοντας με αυτόν τον τρόπο τις μελέτες της νευροφυσιολογίας και των μαθηματικών (McCullochetal., 1943). Το έργο τους εμπνεύστηκε από τη δομή και τη λειτουργία του ανθρώπινου βιολογικού νευρικού συστήματος και ιδιαίτερα από τα χαρακτηριστικά του νευρώνα. Αναφορικά με τον πολύπλοκο τρόπο με τον οποίο λειτουργεί ο ανθρώπινος εγκέφαλος, έδειξαν ότι ένα δίκτυο που αποτελείται από έναν επαρκή αριθμό μονάδων, πουλειτουργούν παράλληλα μέσω συναπτικών συνδέσεων, θα μπορούσε να εκτελέσει οποιαδήποτε υπολογιστική εργασία.

Το 1948, στο βιβλίο του *“Cybernetics”*, ο Wiener είναι ο πρώτος που διατυπώνει τη σχέση μεταξύ της στατιστικής μηχανικής και των συστημάτων μάθησης (Wiener, 1948). Το βιβλίο του Wiener ακολουθήθηκε το 1949 από το βιβλίο *“The Organization of Behavior”* του Hebb (Hebb, 1949), στο οποίο παρουσιάζει για πρώτη φορά έναν κανόνα μάθησης βασισμένο στην ικανότητα του εγκεφάλου για συνεχή αλλαγή, καθώς αντιμετωπίζει διάφορα καθήκοντα. Ξεκινώντας από το αρχικό έργο του Ramon y Calais, ο Hebb δηλώνει ότι κάθε φορά που ενεργοποιούνται οι συνδέσεις των συνάψεων μεταξύ των νευρώνων, αυτές οι συνάψεις ενισχύονται μεταξύ τους. Ως αποτέλεσμα, το δίκτυο αναπτύσσεται και προσαρμόζεται στο μαθησιακό μοντέλο που εισάγεται σε αυτό. Το βιβλίο του Hebb τελικά οδήγησε στην ανάπτυξη υπολογιστικών μοντέλων μαθησιακών και προσαρμοστικών συστημάτων (Haykin, 1999). Μια πρώτη απόπειρα να χρησιμοποιηθεί υπολογιστική προσομοίωση ώστε να δοκιμαστεί η νευρωνική θεωρία της μάθησης του Hebb, παρουσιάζεται στην εργασία των Rochester, Holland, Haibt και Duda το 1956 (Rochesteretal., 1956).

Το 1958 ο Rosenblatt εισήγαγε μια νέα μέθοδο επιτηρούμενης μάθησης, το «perceptron», το οποίο προσέφερε μια νέα προσέγγιση στην αναγνώριση προτύπων. Ο Rosenblatt ανέπτυξε πρώτα ένα δίκτυο που θα μπορούσε να εκτελέσει πολλαπλές εργασίες (Rosenblatt, 1958). Το 1960 οι Widrow και Hoff εισήγαγαν τον Αλγόριθμο LMS, που χρησιμοποιήθηκε για πρώτη φορά για την ανάπτυξη του δικτύου Adaline, συμπεριλαμβάνοντας πρώτα ένα προσαρμοστικό γραμμικό στοιχείο και σε δεύτερη φάση το δίκτυο Madaline, μία πολλαπλή δομή-adaline (Widrowetal., 1960).

Το 1961, δημοσιεύθηκε μια εργασία του Minsky με τίτλο *“Steps toward Artificial Intelligence”* (Minsky, 1961). Ένα μεγάλο τμήμα αυτού του έργου αναφέρεται σε υλικό που αναγνωρίζεται τώρα ως σχετικό με τα νευρωνικά δίκτυα. Αργότερα το 1967, στο βιβλίο του *“Computation: Finite and Infinite Machines”* (Minsky, 1967) ο Minsky τοποθετεί το έργο που παρουσίασαν ο McCulloch και ο Pitts το 1943 στο πλαίσιο της θεωρίας των υπολογισμών και της θεωρίας αυτοματισμού. Ωστόσο, το 1969 οι Minsky και Papert έθεσαν ένα όριο στις προσδοκίες που είχαν προκύψει στον τομέα των νευρωνικών δικτύων εξαιτίας των

εργασιών για το μοντέλο perceptron. Χρησιμοποίησαν μαθηματικά για να αποδείξουν ότι τα perceptrons ενός επιπέδου δεν μπορούν να εκτελέσουν ορισμένους υπολογισμούς(Minskyetal., 1969).

Το παραπάνω ήταν ένας από τους κύριους παράγοντες που αποθαρρύναν τις εξελίξεις στην περιοχή των ΤΝΔ. Το ενδιαφέρον για τον τομέα αναζωπυρώθηκε στη δεκαετία του 1980.ΟHorfield έδειξε το 1982 ότι ένα νευρωνικό μπορεί να χρησιμοποιηθεί για την αποθήκευση πληροφοριών(Horfield, 1982).

Το 1986, οι Rumelhart, Hinton και Williams ανέπτυξαν τον «αλγόριθμο οπισθοδιάδοσης σφάλματος» (backpropagation algorithm), ο οποίος αποδείχθηκε ο πιο δημοφιλής αλγόριθμος εκμάθησης για την εκπαίδευση πολυστρωματικών perceptrons (MLPs) (Rumelhartetal., 1986). Αυτή η εργασία αποτελεί ένα βήμα πέρα από το μοντέλο perceptron, ενώ, αν και ο αλγόριθμος είχε περιγραφεί νωρίτερα από τον Werbos το 1974(Werbos, 1974), οι Rumelhart, Hinton και Williams πιστώνονται την εισαγωγή του στη μηχανική μάθηση και την απόδειξη με αυστηρούς μαθηματικούς όρους τούπως θα μπορούσε να χρησιμοποιηθεί.

Αξίζει να σημειωθεί ότι μετά από πολύ καιρό υπάρχει αναζωπύρωση και ανανεωμένο ενδιαφέρον για τεχνητά νευρωνικά δίκτυα. Οι σύγχρονοι υπολογιστές επιτρέπουν πολύ ταχύτερους υπολογισμούς, ενώ οι κάρτες γραφικών (GPU) έχουν αποδειχθεί ένα πολύ επιτυχημένο εργαλείο στην εκπαίδευση των τεχνητών νευρωνικών δικτύων. Ο συνδυασμός μεγάλων ποσοτήτων αποθηκευμένων δεδομένων και υψηλής ταχύτητας υπολογιστών, έχουν θέσει τα τεχνητά νευρωνικά δίκτυα στην πρώτη γραμμή της τεχνητής νοημοσύνης κάτω από τον όρο *βαθιά μάθηση* (deep learning).

2.1.8 Πλεονεκτήματα των τεχνητών νευρωνικών δικτύων (ΤΝΔ - ANN)

Τα τεχνητά νευρωνικά δίκτυα βασίζονται στην παράλληλα κατανομημένη δομή τους και την ικανότητά τους να μαθαίνουν από τα δεδομένα και να γενικεύουν. Με τη γενίκευση τα τεχνητά νευρωνικά δίκτυα μπορούν να παράγουν εξόδους από εισόδους που δεν ήταν μέρος της εκπαίδευσής τους. Ως εκ τούτου μπορούν να λύσουν πολύπλοκα και μεγάλης κλίμακας προβλήματα, όποια αριθμητικά μοντέλα αντιμετωπίζουν μεγάλη δυσκολία. Πιο συγκεκριμένα, τα τεχνητά νευρωνικά δίκτυα έχουν τα ακόλουθα οφέλη και δυνατότητες, όπως παρουσιάζονται από τον Haykin (Haykin, 1999):

Μη γραμμικότητα: Οι τεχνητοί νευρώνες μπορεί να είναι μη γραμμικοί, καθιστώντας ολόκληρο το δίκτυο μη γραμμικό. Στη συνέχεια, το τεχνητό νευρωνικό δίκτυο μπορεί να είναι ιδιαίτερα αποτελεσματικό όταν ο υποκείμενος μηχανισμός του σήματος εισόδου είναι εγγενώς μη γραμμικός.

Απεικόνιση εισόδου-εξόδου: Τα νευρωνικά δίκτυα εκπαιδεύονται μέσω της έννοιας της εποπτευόμενης μάθησης, όπου τα συναπτικά βάρη τους αλλάζουν τιμές καθώς λαμβάνει χώρα η διαδικασία της εκπαίδευσης. Επαναλαμβάνοντας τα

προηγούμενα παραδείγματα εκπαίδευσης μέσω διαφορετικής σειράς, το δίκτυο κατασκευάζει μια χαρτογράφηση εισόδου-εξόδου για το πρόβλημα. Αυτό υποδηλώνει μια μη παραμετρική προσέγγιση στατιστικού προσδιορισμού του προβλήματος, που σημαίνει ότι δεν υπάρχουν προηγούμενες παραδοχές σε ένα στατιστικό μοντέλο για τα δεδομένα εισόδου.

Προσαρμοστικότητα: Τα νευρωνικά δίκτυα προσαρμόζουν τα συναπτικά βάρη τους στο περιβάλλον τους. Ακόμη και όταν υπάρχουν αλλαγές σε ένα περιβάλλον στο οποίο έχει εκπαιδευτεί το νευρωνικό δίκτυο, μπορεί εύκολα να επανεκπαιδευτεί. Επιπλέον, εάν το περιβάλλον δεν είναι στάσιμο και οι παράμετροι του αλλάζουν με το χρόνο, το νευρωνικό δίκτυο μπορεί να σχεδιαστεί για να αλλάζει συνεχώς τα συναπτικά του βάρη σε πραγματικό χρόνο.

Αποδεικτική απάντηση: Αναφέρεται στην ικανότητα των νευρωνικών δικτύων να παρέχουν πληροφορίες σχετικά με την εμπιστοσύνη στις αποφάσεις που λαμβάνονται, κυρίως σε εργασίες ταξινόμησης.

Συναφής πληροφορία: Δεδομένου ότι κάθε νευρώνας στο δίκτυο επηρεάζεται από τη δραστηριότητα των υπόλοιπων νευρώνων και η γνώση εκπροσωπείται στη δομή του και στην κατάσταση ενεργοποίησης του, τα νευρωνικά δίκτυα μπορούν να συνδιαλλαγούν με φυσικό τρόπο με τις συναφείς πληροφορίες.

Ανεκτικότητα σφαλμάτων: Τα νευρωνικά δίκτυα έχουν τη δυνατότητα να είναι εγγενώς ανεκτικά σε σφάλματα. Ο λόγος είναι ότι όταν οι νευρώνες και οι συλλεκτικές τους συνδέσεις έχουν υποστεί βλάβη, οι αποθηκευμένες πληροφορίες εμφανίζουν μόνομείωση της ποιότητας, λόγω της κατανεμημένης φύσης του δικτύου.

Υλοποίηση σε συστήματα VLSI (VeryLargeScaleIntegration): Χάρη στη μαζική παράλληλη φύση των νευρωνικών δικτύων, ορισμένες εργασίες μπορούν να εκτελεστούν με απίστευτη ταχύτητα. Αυτό καθιστά την ολοκληρωμένη τεχνολογία πολύ μεγάλης κλίμακας έναν κατάλληλο τρόπο για την υλοποίηση νευρωνικών δικτύων, προκειμένου να συλλάβει πολύπλοκα σχέδια με έναν πολύ ιεραρχικό τρόπο.

Ομοιομορφία της ανάλυσης και του σχεδιασμού: Αναφέρεται στην ικανότητα νευρωνικών δικτύων να λειτουργούν καθολικά ως επεξεργαστές πληροφοριών. Οι νευρώνες είναι ένα κοινό συστατικό σε όλα τα νευρωνικά δίκτυα. Αυτό σημαίνει ότι είναι δυνατόν να μοιράζονται οι αλγόριθμοι μάθησης μεταξύ διαφορετικών πεδίων και εφαρμογών των νευρωνικών δικτύων.


Νευροβιολογική αναλογία: Οινευροεπιστήμονες μελετούν τα τεχνητά νευρωνικά δίκτυα προκειμένου να ερμηνεύσουν νευροβιολογικά φαινόμενα, ενώ επιστήμονες της πληροφορικής και μηχανικοί της τεχνητής νοημοσύνης μελετούν νευροβιολογία για νέες μεθόδους επίλυσης σύνθετων προβλημάτων.

Στη συνέχεια θα αναλυθούν οι δύο κύριοι τύποι τεχνητών νευρωνικών δικτύων και θα συγκριθούν τα πλεονεκτήματα και τα μειονεκτήματά τους.

2.1.9 Πολυστρωματικά δίκτυα perceptron (MLP)

Τα πολυστρωματικά δίκτυα perceptron είναι τα πιο συχνά χρησιμοποιούμενα τεχνητά νευρωνικά δίκτυα. Έχουν εφαρμοστεί με επιτυχία για την επίλυση σύνθετων και ποικίλων προβλημάτων, έχοντας εκπαιδευτεί με εποπτευόμενο τρόπο μέσω ενός πολύ δημοφιλούς αλγορίθμου που ονομάζεται αλγόριθμος οπισθοδιάδοσης σφάλματος (error back-propagation algorithm). Μέσω αυτού, η εκμάθηση πραγματοποιείται στο δίκτυο, τροποποιώντας τα συναπτικά βάρη μετά από επεξεργασία κάθε διανύσματος εκπαίδευσης, με βάση το μέγεθος του σφάλματος στην έξοδο σε σύγκριση με τα αναμενόμενα αποτελέσματα (Gopal, 2017). Υπάρχουν τρία διακριτικά χαρακτηριστικά που ορίζουν τα πολυστρωματικά δίκτυα perceptron (Haykin, 1999):

1. Το μοντέλο νευρώνων του δικτύου περιέχει μια μη γραμμική συνάρτηση ενεργοποίησης, συνήθως μια σιγμοειδή λογιστική συνάρτηση (sigmoid logistic function). Η χρήση της συνάρτησης αυτής, όπως αναφέρθηκε προηγουμένως, είναι βασισμένη στην βιολογία, δεδομένου ότι επιχειρεί να μιμηθεί την λειτουργία των πραγματικών νευρώνων.
2. Το νευρωνικό δίκτυο περιέχει ένα ή περισσότερα στρώματα (επίπεδα) κρυμμένων νευρώνων, που δεν είναι ούτε επίπεδα εισόδου ούτε εξόδου του δικτύου. Οι κρυμμένοι νευρώνες επιτρέπουν στο δίκτυο να μαθαίνει πολύπλοκες συναρτήσεις, εξαγοντας προοδευτικά πιο σημαντικά χαρακτηριστικά από τα δεδομένα εισόδου.
3. Το νευρωνικό δίκτυο εμφανίζει υψηλό βαθμό συνδεσιμότητας.



Εικόνα 2. 8 : Πολυστρωματικό δίκτυο perceptron (Haykin, 1999).

Στηνεπόμενη ενότητα θα παρουσιαστεί η βασική ιδέα πίσω από τον αλγόριθμο οπισθοδιάδοσης (backpropagationalgorithm).

Η ιδέα πίσω από τη διαδικασία είναι ότι όταν ένα πρότυπο εκμάθησης προβάλλεται στο δίκτυο, οι τιμές ενεργοποίησης μεταδίδονται στις μονάδες εξόδου και η πραγματική έξοδος δικτύου συγκρίνεται με τις επιθυμητές τιμές εξόδου. Μέσα από αυτό καταλήγουμε σε ένα σφάλμα e_o σε κάθε μονάδα εξόδου o . Η τιμή σφάλματος e_o πρέπει να τείνει στο μηδέν. Ο ευκολότερος τρόπος για να επιτευχθεί αυτό είναι να αλλάξουντα συναπτικά βάρη στο νευρωνικό δίκτυο κατά τέτοιο τρόπο ώστε στην επόμενη επανάληψη το σφάλμα e_o να είναι μηδέν για αυτό το συγκεκριμένο πρότυπο. (Krose et al., 1996).

Αλλά αυτό το βήμα αφορά μόνο τα βάρη του κρυμμένου στρώματος προς το στρώμα εξόδου. Προκειμένου να αλλάξουντα βάρη του στρώματος εισόδου προς το κρυμμένο στρώμα, υπάρχει μια δεύτερη φάση η οποία περιλαμβάνει ένα οπίσθιο πέρασμα μέσω του δικτύου, κατά τη διάρκεια του οποίου το σήμα σφάλματος διέρχεται σε κάθε μονάδα του δικτύου και υπολογίζονται οι κατάλληλες αλλαγές συναπτικών βαρών (Krose et al., 1996).

Δεδομένου ότι στην εφαρμογή μας δεν θα χρησιμοποιήσουμε πολυστρωματικά νευρωνικά δίκτυα perceptron (MLP), δεν θα εμβαθύνουμε στην λειτουργία και τις εξισώσεις τους. Αντ'αυτού, θα παρουσιαστούν λεπτομερώς οι ιδιότητες και η λειτουργία των νευρωνικών δικτύων ακτινικών συναρτήσεων βάσης (Radial Basis Function Networks -RBFN).

2.1.10 Δίκτυα ακτινικών συναρτήσεων βάσης (RBFN)

Τα νευρωνικά δίκτυα ακτινικών συναρτήσεων βάσης είναι τεχνητά νευρωνικά δίκτυα των οποίων η συνάρτηση ενεργοποίησης είναι μια ακτινική συνάρτηση.

Ακτινικές συναρτήσεις

Οι ακτινικές συναρτήσεις αποτελούν μια ειδική κατηγορία συναρτήσεων. Το κύριο χαρακτηριστικό τους είναι ότι η ανταπόκρισή τους μειώνεται (ή αυξάνεται) μονότονα με την απόσταση (συνήθως χρησιμοποιείται μια Ευκλείδεια συνάρτηση απόκλισης) από το κεντρικό τους σημείο. Το κέντρο, η κλίμακα απόστασης και το ακριβές σχήμα της ακτινικής συνάρτησης είναι παράμετροι του μοντέλου (όλα σταθερά εάν είναι γραμμικά). Μια τυπική ακτινική συνάρτηση είναι αυτή του Gauss, η οποία στην περίπτωση της κλιμακωτής εισόδου είναι ως εξής

$$h(x) = \exp\left(-\frac{(x - c)^2}{r^2}\right) \quad (2.7)$$

Οι παράμετροί της είναι το κέντρο της c και η ακτίνα της r (Mark JL Orr, 1996).

Μια ακτινική συνάρτηση βάσης Gauss μειώνεται μονότονα με την απόσταση από το κέντρο. Αντίθετα, μια πολυτετραγωνική (multiquadric) ακτινική συνάρτηση βάσης

αυξάνει μονότονα με την απόσταση από το κέντρο της που στην περίπτωση της κλιμακωτής εισόδου η συνάρτηση είναι

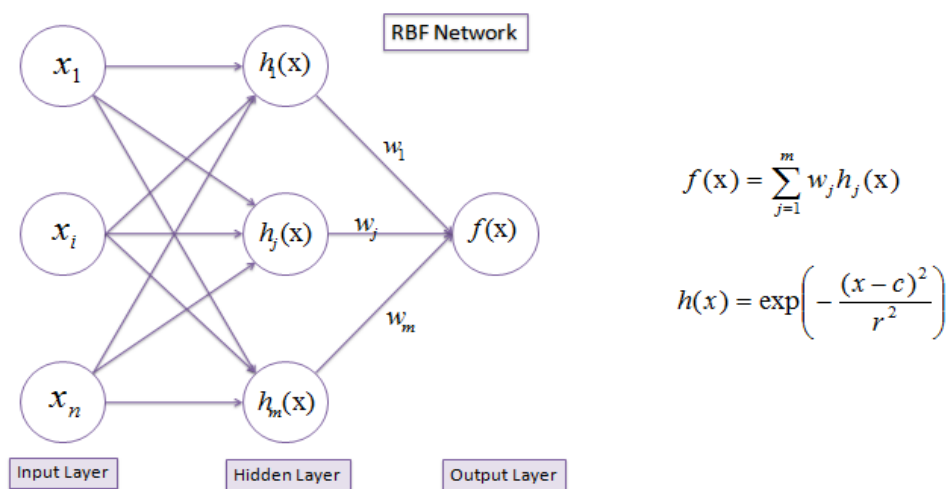
$$h(x) = \frac{\sqrt{r^2 + (x - c)^2}}{r} \quad (2.8)$$

Οι ακτινικές συναρτήσεις βάσης τύπου Gauss είναι τοπικές (δίνουν σημαντική απόκριση μόνο σε γειτνίαση με το κέντρο) και χρησιμοποιούνται συχνότερα από τις πολυτετραγωνικές συναρτήσεις ακτινικής βάσης, που έχουν μια καθολική απόκριση. Είναι επίσης πιο κοντά στη βιολογία, επειδή η απόκρισή τους είναι πεπερασμένη (Mark J.L Orr, 1996).

Τα δίκτυα ακτινικών συναρτήσεων βάσης (RBFN) αποτελούνται από μια απλή αρχιτεκτονική τριών στρωμάτων. Το στρώμα εισόδου μεταδίδει τις τιμές εισόδου σε ένα μόνο κρυφό στρώμα (επίπεδο), το οποίο διαθέτει νευρώνες με συναρτήσεις ενεργοποίησης ακτινικής βάσης. Στο στρώμα εξόδου κάθε νευρώνας λαμβάνει ένα γραμμικό συνδυασμό των εξαγομένων των κρυμμένων νευρώνων. Στην περίπτωση ενός κόμβου εξόδου, η καθολική μη γραμμική συνάρτηση, υπολογισμένη από το δίκτυο, μπορεί να εκφραστεί ως ένας γραμμικός συνδυασμός συναρτήσεων βάσης m που συνδέονται με κάθε νευρώνα κρυμμένου στρώματος (Binaghi, 2013).

$$f(x) = \sum_i^m w_j h_j(x) \quad (2.9)$$

Εδώ $x = [x_1, \dots, x_k]^T$ είναι το διάνυσμα εισόδου k -διαστάσεων, w_j είναι οι συντελεστές στάθμισης του γραμμικού συνδυασμού και το $h_j(x)$ αντιπροσωπεύει την έξοδο της συνάρτησης βάσης Gauss, με ακτίνα r_j που σχετίζεται με τον νευρώνα j στο δεύτερο στρώμα. Η απόκριση του νευρώνα j μειώνεται μονότονα με την απόσταση μεταξύ του διανύσματος εισόδου x και το κέντρο της κάθε συνάρτησης c_j (Binaghi et al., 2013).



Εικόνα 2.9: Αρχιτεκτονική δικτύου βάσης ακτινικής βάσης (Chandradevan, 2017).

Καθώς εκπαιδεύεται το δίκτυο ακτινικών συναρτήσεων βάσης (RBFN), μαθαίνει μια προσέγγιση για την πραγματική σχέση εισόδου-εξόδου βασισμένη σε ένα σύνολο εκπαιδευτικών παραδειγμάτων, που απαρτίζεται από N ζεύγη εισόδου-εξόδου $[x_i, y_i], i = 1, 2, \dots, N$. Κατά τον Moody and Darken (1989) το σχέδιο εκπαίδευσης είναι δύο φάσεων:

1. Η πρώτη φάση είναι μη επιτηρούμενη και αποφασίζει τιμές για $c_j, j = 1, \dots, M$.
2. Η δεύτερη φάση λύνει ένα γραμμικό πρόβλημα για να βρει τιμές για το $w_i, i = 1, \dots, M$.

Η διαμόρφωση του μοντέλου απαιτεί την εισαγωγή δύο παραμέτρων.

1. Τον αριθμό M των τοπικών μονάδων επεξεργασίας πρώτου επιπέδου
2. Τον αριθμό p των p -means που χρησιμοποιούνται ευρετικά για τον ορισμό του $r_j, j = 1, \dots, M$ των ακτινικών συναρτήσεων βάσης που συνδέονται με μονάδες επεξεργασίας πρώτου επιπέδου.

Για τη δεύτερη φάση, έχοντας τις παραμέτρους μοντέλου, για $c_j, j = 1, \dots, M, r_j, j = 1, \dots, M$ γνωστές, τα βάρη $w_i, i = 1, \dots, M$ υπολογίζονται, ελαχιστοποιώντας τη διαφορά μεταξύ προβλεπόμενης και πραγματικής εξόδου μέσω ελαχίστων τετραγώνων, υπολογισμένη μέσω του

$$w = (H^T H)^{-1} H^T y = H^+ y \quad (2.10)$$

όπου

$$H = \begin{bmatrix} h_1(x_1) & \dots & h_M(x_1) \\ \vdots & \ddots & \vdots \\ h_1(x_N) & \dots & h_M(x_N) \end{bmatrix} \quad (2.11)$$

Το διάνυσμα των δεδομένων εξόδου δίδεται

$$y = [y_1, \dots, y_N] \quad (2.12)$$

ενώ τα βάρη δεύτερου επιπέδου δίδονται

$$w = [w_1, \dots, w_M]^T \quad (2.13)$$

Το εκπαιδευμένο δίκτυο δοκιμάζεται χρησιμοποιώντας ένα κατάλληλο σύνολο παραδειγμάτων, τα οποία δεν έχουν χρησιμοποιηθεί στην εκπαίδευση (Binaghi et al., 2013).

2.1.11 Σύγκριση του MLP και του RBFN

Τα RBFN και τα MLP είναι παραδείγματα μη γραμμικών στρωματοποιημένων δικτύων πρόσω τροφοδότησης. Είναι και τα δύο προσεγγιστές καθολικής φύσης. Επομένως, δεν προκαλεί έκπληξη το γεγονός ότι υπάρχει πάντα ένα δίκτυο RBF ικανό να μιμείται με ακρίβεια ένα συγκεκριμένο MLP ή αντίστροφα. Ωστόσο, υπάρχουν διαφορές μεταξύ τους (Haykin, 1999).

Πρώτα απ' όλα, ένα δίκτυο RBF έχει ένα μόνο κρυφό στρώμα, ενώ ένα MLP μπορεί να έχει περισσότερα από ένα κρυμμένα στρώματα. Στη συνέχεια, οι κόμβοι υπολογισμού ενός MLP, που βρίσκονται σε ένα κρυμμένο ή σε ένα στρώμα εξόδου, μοιράζονται ένα κοινό νευρωνικό μοντέλο ενώ από την άλλη, οι κόμβοι υπολογισμού σε ένα κρυμμένο στρώμα ενός δικτύου RBF είναι αρκετά διαφορετικοί και εξυπηρετούν διαφορετικό σκοπό, από εκείνους στο στρώμα εξόδου του δικτύου. Επιπλέον, το κρυμμένο στρώμα ενός δικτύου RBF είναι μη γραμμικό, ενώ το στρώμα εξόδου είναι γραμμικό. Ωστόσο, τα κρυφά επίπεδα και τα επίπεδα εξόδου ενός MLP, που χρησιμοποιείται ως ταξινομητής προτύπων, είναι συνήθως μη γραμμικά. Όταν το MLP χρησιμοποιείται για την επίλυση προβλημάτων μη γραμμικής οπισθοδρόμησης, ένα γραμμικό επίπεδο για την έξοδο είναι συνήθως η προτιμώμενη επιλογή. Μια άλλη διαφορά είναι η λειτουργία ενεργοποίησης στις κρυφές μονάδες όπου τα RBFNs υπολογίζουν την Ευκλείδειαν όρμα (απόσταση) μεταξύ του διανύσματος εισόδου και του κέντρου της μονάδας, ενώ τα MLPs υπολογίζουν το εσωτερικό γινόμενο του διανύσματος εισόδου και του διανύσματος συναπτικού βάρους αυτής της μονάδας. Τέλος, τα MLP κατασκευάζουν γενικές προσεγγίσεις με μη γραμμική αντιστοίχιση εισόδου-εξόδου ενώ από την άλλη πλευρά τα RBFNs χρησιμοποιώντας τοπικές μη γραμμικές συναρτήσεις που μειώνονται εκθετικά και δημιουργούν τοπικές προσεγγίσεις σε μη γραμμικές συναρτήσεις εισόδου-εξόδου. Για το λόγο αυτό, για την προσέγγιση της μη γραμμικής αντιστοίχισης εισόδου-εξόδου, τα MLP μπορεί να απαιτούν μικρότερο αριθμό παραμέτρων από το δίκτυο RBF για τον ίδιο βαθμό ακρίβειας (Haykin, 1999).

Για την εφαρμογή μας θα χρησιμοποιηθεί ένα δίκτυο ακτινικών συναρτήσεων βάσης αντί για ένα πολυστρωματικό perceptron, καθώς θεωρούμε την ιδιότητα της τοπικής προσέγγισης του RBFN καλύτερα προσαρμοσμένη στις παραμέτρους του προβλήματός μας.

2.2 ΠΑΛΑΙΟΤΕΡΕΣ ΕΡΓΑΣΙΕΣ

2.2.1 Χρήσεις MLP για χωρικές προβλέψεις

Τα πολυστρωματικά νευρωνικά δίκτυα perceptron έχουν χρησιμοποιηθεί για χωρικές προβλέψεις από τη δεκαετία του 1990. Μια κοινή μέθοδος συνδυάζει το νευρωνικό δίκτυο με τα Γεωγραφικά Συστήματα Πληροφοριών (GIS). Γενικά, η ενσωμάτωση των νευρωνικών δικτύων και των χαρτών περιλαμβάνει τα ακόλουθα βήματα:

Για να εκπαιδεύσουν το MLP, τα δειγματοληπτικά δεδομένα για επιτηρούμενη εκπαίδευση συχνά υποδιαιρούνται σε σύνολα *εκπαίδευσης*, *επικύρωσης* και *δοκιμών*. Οι διαφορές μεταξύ αυτών των υποσυνόλων είναι κρίσιμες. Τα δεδομένα εκπαίδευσης είναι ένα σύνολο παραδειγμάτων που χρησιμοποιούνται για μάθηση που οφείλει να ταιριάζει με τις παραμέτρους [βάρη] του ταξινομητή. Τα δεδομένα επικύρωσης είναι ένα σύνολο παραδειγμάτων που χρησιμοποιούνται για να συντονιστούν οι παράμετροι ενός ταξινομητή, για παράδειγμα για να επιλεγεί αριθμός των κρυφών μονάδων σε ένα νευρωνικό δίκτυο, ενώ τα δεδομένα των δοκιμών είναι ένα σύνολο παραδειγμάτων που χρησιμοποιούνται μόνο για την εκτίμηση της απόδοσης [γενίκευσης] ενός πλήρως εξειδικευμένου ταξινομητή (Ripley, 1996).

Προσδιορισμός της διάρθρωσης των δικτύων: Συνηθέστερα θα είναι ένα τριών στρωμάτων (είσοδος, κρυφό, έξοδος) νευρωνικό δίκτυοπροσωτροφοδότησης. Οι μονάδες εισόδου σε μια τέτοια εφαρμογή είναι οι μεταβλητές εισόδου, οπότε ο αριθμός τους είναι ο αριθμός των μονάδων εισόδου. Οι μονάδες εξόδου και ο αριθμός τους είναι οι μεταβλητές εξόδου, ανάλογα με την εφαρμογή (Gopal, 2017). Ο αριθμός των κρυφών μονάδων μπορεί να προσδιοριστεί μέσω δοκιμής και σφάλματος. Εάν οι κρυφές μονάδες είναι πολύ λίγες, το νευρωνικό δίκτυο θα έχει χαμηλή ακρίβεια στη λειτουργία του. Από την άλλη πλευρά, ένας μεγάλος αριθμός κρυφών μονάδων μπορεί να προκαλέσει το νευρωνικό δίκτυο να προσαρμοστεί σε μεγάλο βαθμό στα δεδομένα εκπαίδευσης, με αποτέλεσμα τη μείωση της ακρίβειας γενίκευσης.

Κανόνες μάθησης: Οπισθοδιάδοση

Συνάρτηση μεταφοράς: Η συνάρτηση ενεργοποίησης που χρησιμοποιείται είναι μη γραμμική, συνήθως είναι η σιγμοειδής συνάρτηση.

Χωρικές προβλέψεις για τη ρύπανση των υπόγειων υδάτων με την ενσωμάτωση ενός δικτύου MLP και GIS

Εργασία 1: Προσομοίωση υπογείων υδάτων της πεδιάδας Mazandaran, Ιράν

Σε αυτή την εργασία (Gholami, 2016) τα δεδομένα GWQI από 85 πηγάδια ποσίμου ύδατος χωρίστηκαν σε δεδομένα εκπαίδευσης, διασταυρούμενα δεδομένα επικύρωσης και δεδομένα δοκιμών. Η δομή του νευρικού δικτύου προσδιορίστηκε με δοκιμή και σφάλμα και αξιολογήθηκε χρησιμοποιώντας τα δεδομένα δοκιμών.

Το μοντέλο εφαρμόστηκε στην περιοχή μελέτης για τον υπολογισμό του GWQI σε τοποθεσίες χωρίς δοκιμές ποιότητας νερού. Η περιοχή μελέτης η οποία είναι 10000 km² χωρίζεται σε 10000 pixels μεγέθους 1x1 km. Κάθε pixel έχει τις τιμές εισόδου των παραγόντων ποιότητας των υπογείων υδάτων. Οι συντεταγμένες των pixels προστίθενται στο GIS και για κάθε pixel προσθέτουμε τις τιμές εισόδου του στο ANN για να υπολογίσουμε το GWQI. Οι πραγματικές τιμές GWQI από τα 85 πηγάδια πόσιμου νερού επικαλύφθηκαν στο GIS για να αξιολογηθεί ακρίβεια με τη σύγκριση. Στην περίπτωση αυτή τα αποτελέσματα ήταν πολύ ακριβή.

Εργασία 2: Πρόβλεψη ρύπανσης υπογείων υδάτων από νιτρικά άλατα σε υδροφορέα της Νότιας Ροδόπης (Θράκη, Ελλάδα)

Σε αυτή την εργασία (Gemitzi, 2008) χρησιμοποιήθηκε ένα MLP με έναν αλγόριθμο οπισθοδιάδοσης (back-propagation) για ταξινόμηση. Τα pixel δοκιμής αντιστοιχούν στα σημεία δειγματοληψίας όπου μετρήθηκε η συγκέντρωση νιτρικών στα υπόγεια ύδατα. Κάθε θέση δειγματοληψίας είναι ένα σύμπλεγμα εννέα pixel, όπου το κεντρικό είναι το σημείο δειγματοληψίας και τα οκτώ γειτονικά υποτίθεται ότι είναι ίδια με το κεντρικό pixel. Ένα διάνυσμα χαρακτηριστικών συσχετίζεται με κάθε pixel. Έτσι για τις 214 γεωτρήσεις, που χρησιμοποιήθηκαν ως θέσεις δειγματοληψίας, έχουμε συνολικά 1926 pixels, όπου η συγκέντρωση νιτρικού άλατος μετρήθηκε για να χρησιμοποιηθεί για την εκπαίδευση και τη δοκιμή του δικτύου.

Το λογισμικό GIS IdrisiAndes χρησιμοποιήθηκε μαζί με το MLP. Κάθε pixel ταξινομήθηκε σε μία από τις τέσσερις κατηγορίες ρύπανσης από νιτρικά άλατα. Το ήμισυ του συνόλου δεδομένων χρησιμοποιήθηκε για την εκπαίδευση και το υπόλοιπο για τη δοκιμή του δικτύου, για την επικύρωση των αποτελεσμάτων. Το νευρωνικό δίκτυο αναλύθηκε πολλές φορές για να προσδιοριστεί η αρχιτεκτονική του και ο ρυθμός εκμάθησης, έως ότου υπήρχε ακρίβεια μεγαλύτερη από 70%. Τα αποτελέσματα αυτής της εφαρμογής ήταν ιδιαίτερα υποσχόμενα, καθώς το μοντέλο ήταν επιτυχές στο 74% των περιπτώσεων.

Συμπεράσματα - MLP για χωρικές προβλέψεις

Μπορούμε να συμπεράνουμε ότι τα MLP παρέχουν μια πολύ καλή εναλλακτική λύση στις συμβατικές τεχνικές μοντελοποίησης όσον αφορά στις χωρικές προβλέψεις. Όταν εφαρμόζονται σε μη γραμμικά προβλήματα, τα MLP προσφέρουν δύο βασικά πλεονεκτήματα.

Το πρώτο είναι ο προσαρμοστικός χαρακτήρας τους, καθώς τα MLPs μαθαίνουν από προηγούμενα δεδομένα και ρυθμίζουν αυτόματα τις παραμέτρους τους (τα συνδεδετικά βάρη). Το δεύτερο πλεονέκτημα είναι ότι δεν απαιτείται φυσικό μοντέλο, το οποίο τους επιτρέπει να εκτιμούν τις λειτουργίες από ένα μικρό αριθμό δεδομένων εκπαίδευσης και στη συνέχεια να κατασκευάζουν αριθμητικούς εκτιμητές που μπορούν να εφαρμοστούν σε πολλά φυσικά προβλήματα. Επιπλέον, έχουν χαμηλή ευαισθησία σε αβέβαιες παραμέτρους.

Ένα MLP, που έχει εκπαιδευτεί για ένα συγκεκριμένο μοντέλο, μπορεί να εφαρμοστεί σε παρόμοια μοντέλα χωρίς μεγάλη μείωση της ακρίβειας. Ωστόσο, αν υπάρχουν σημαντικές διαφορές, είναι προτιμότερο να επανεκπαιδευθεί.

2.2.2 Χρήσεις RBFN για χωρικές προβλέψεις

Τα νευρωνικά δίκτυα ακτινικών συναρτήσεων βάσης (RBFNS) είναι μια πολύ ευέλικτη μέθοδος για χωρικές προβλέψεις. Παρομοίως με τα MLP, παρέχουν καλά αποτελέσματα και μπορούν να χρησιμοποιηθούν από μη έμπειρους χρήστες, σε σύγκριση με τις συμβατικές τεχνικές μοντελοποίησης και στατιστικής.

Προσδιορισμός δομής δικτύων : Τα RBFNs για χωρικές προβλέψεις συνήθως έχουν 3 στρώματα. Το στρώμα εισόδου έχει τόσες μονάδες όσο ο αριθμός των χαρακτηριστικών εισόδου. Ανάλογα με το εάν έχουμε μια παλινδρόμηση, ή μια εργασία ταξινόμησης, το RBFN έχει 1 μονάδα εξόδου ή πολλαπλές, ανάλογα με τον αριθμό των τάξεων του προβλήματος. Ο αριθμός των κρυφών μονάδων με συναρτήσεις ακτινικής βάσης προσδιορίζεται με δοκιμή και σφάλμα.

Ακτινική συνάρτηση: Συνήθως τα RBFN's χρησιμοποιούν την συνάρτηση ακτινικής βάσης Gauss για χωρικές προβλέψεις. Αυτό διότι η συνάρτηση αυτή δίνει μια σημαντική απόκριση στην περιοχή κοντά στο κέντρο της σε σύγκριση με τις γενικές συναρτήσεις ακτινικής βάσης, των οποίων η απόκριση αυξάνει μονότονα με την απόσταση από το κέντρο.

Περίπτωση 1: Εκτίμηση πάχους χιονόστρωσης χρησιμοποιώντας RBFN's

Σε αυτήν την περίπτωση (Binaghi et al., 2013) ένα RBFN χρησιμοποιείται για την εκτίμηση του πάχους του χιονιού με μια συνάρτηση παλινδρόμησης και μια ταξινόμησης. Το μοντέλο βασίζεται σε ένα ελάχιστο σύνολο τοπογραφικών δεδομένων από έναν περιορισμένο αριθμό σταθμών στις ιταλικές κεντρικές Άλπεις. Χρησιμοποιήθηκαν έντεκα μεταβλητές εισόδου (που αντιστοιχούσαν σε 11 νευρώνες εισόδου για αμφότερες τις εργασίες), 8 από τις οποίες ήταν κλιματικές και 3 γεωγραφικές.

Για την εργασία παλινδρόμησης η αρχιτεκτονική προσδιορίστηκε με μεταβολή του χρονικού παραθύρου T και δοκιμή με διαφορετικούς αριθμούς κρυφών μονάδων M με συναρτήσεις ακτινικής βάσης. Χρησιμοποιήθηκαν τιμές 100, 250, 500, 600 και 750. Οι βέλτιστες τιμές προσδιορίστηκαν ότι είναι $T = 45$ με $M = 500$. Υπάρχει ένας νευρώνας εξόδου για την εργασία παλινδρόμησης. Ο πίνακας παρακάτω περιέχει τα αποτελέσματα παλινδρόμησης με βάση τον αριθμό των κέντρων M στη μορφή των σφαλμάτων RMSE, NRMSE και MAE.

#Centroids	RMSE	NRMSE	MAE
100	26.22	6.60%	15.18
250	22.31	5.61%	12.03
500	18.20	4.58%	9.58
600	17.63	4.44%	9.28
750	16.99	4.27%	8.74

Πίνακας 2.1 Αποτελέσματα παλινδρόμησης (Binaghi et al., 2013)

Για την εργασία ταξινόμησης χρησιμοποιήθηκαν 4 κατηγορίες ανάλογα με το πάχος του χιονιού. Αρκετές διαμορφώσεις ελήφθησαν υπόψη, αλλά και πάλι η βέλτιστη αρχιτεκτονική αποδείχθηκε ότι είναι $T = 45$ και $M = 500$, αλλά αυτή τη φορά με 4 νευρώνες εξόδου, έναν για κάθε κατηγορία.

Για να παραχθεί ένας χάρτης κάλυψης χιονιού χρησιμοποιήθηκε χωρική παρεμβολή κλιματικών μεταβλητών εισόδου και στη συνέχεια χρησιμοποιήθηκε το δίκτυο RBF για να υπολογιστεί η αντίστοιχη προβλεπόμενη τιμή κάλυψης χιονιού για κάθε τιμή εισόδου.

Overall accuracy								Mean	Far
Date	Methods	0– 1000	1000– 1300	1300– 1600	1600– 1900	1900– 2200	>2200		
11-Feb-03	RBF	99.67%	91.98%	93.60%	67.60%	60.77%	87.44%	83.51%	15.62%
	iDW	7.46%	12.90%	15.45%	29.50%	59.86%	85.58%	35.12%	31.10%
	Spline	85.44%	53.35%	45.38%	52.01%	67.17%	74.20%	62.92%	15.30%
25-Feb-03	RBF	99.98%	96.32%	98.79%	72.89%	46.92%	86.17%	83.51%	20.63%
	IDW	7.47%	9.68%	11.07%	17.95%	41.86%	80.64%	28.11%	28.66%
	Spline	84.64%	50.03%	42.46%	44.18%	53.45%	70.85%	57.60%	16.68%
29-April-03	RBF	99.97%	98.31%	99.92%	91.96%	61.96%	71.93%	87.34%	16.38%
	IDW	60.41%	35.13%	30.97%	27.23%	33.62%	58.42%	40.96%	14.56%
	Spline	49.92%	46.93%	40.46%	38.76%	39.39%	53.46%	44.82%	6.17%

Πίνακας 2.2 Ακρίβεια για 6 διαστήματα υψομέτρου (Binaghi et al., 2013)

Σε σύγκριση με τις συμβατικές ντετερμινιστικές μεθόδους, όπως οι Spline και η IDW (Inverse Distance Weighting), το RBFN παρουσίασε καλύτερη απόδοση με ακρίβεια 72% σε σύγκριση με το 60% των άλλων 2 μεθόδων. Ωστόσο, όσον αφορά τις χωρικές προβλέψεις από κλιματικά δεδομένα, τα RBFNs μπορούν να υπερεκτιμούν τιμές λόγω των μικροκλιματικών συνθηκών γύρω από τους σταθμούς που παρέχουν δεδομένα. Παράδειγμα είναι η διάρκεια της περιόδου τήξης και οι αρχές του φθινοπώρου, όταν η κατανομή του χιονιού είναι εξαιρετικά ανομοιογενής.


Εργασία 2: SIC 2004

Αυτή η εργασία αποτελεί μέρος των ασκήσεων για τη σύγκριση χωρικών παρεμβολών (SIC) που διοργανώνει η Ευρωπαϊκή Επιτροπή μέσω του Κοινού Κέντρου Ερευνών (JRC). Η εργασία παρουσιάζεται σε μία δημοσίευση που συγκρίνει RBFs με γεωστατιστική (Rusu et al., 2006).


Διαφορετικές μέθοδοι δοκιμάστηκαν με εκτίμηση τιμών μιας μεταβλητής σε διαφορετικές θέσεις με τη βοήθεια ενός υποσυνόλου των παρατηρούμενων μετρήσεων. Αφού πραγματοποιήθηκαν οι μετρήσεις, δόθηκαν οι πραγματικές τιμές

για να συγκριθεί η ακρίβεια κάθε προσέγγισης. Τα στοιχεία της SIC 2004 ήταν ημερήσιες μέσες τιμές των ποσοστών δόσης γάμμα που μετρήθηκαν στη Νοτιοδυτική Γερμανία σε μια περιοχή που κάλυπτε 400 kmx700 km και 1008 σταθμούς παρακολούθησης.

Οι 808 πραγματικές τιμές χρησιμοποιήθηκαν για σύγκριση με τα αποτελέσματα παρεμβολής. Τα αποτελέσματα του RBFN και της γεωστατιστικής τεχνικής εκτίμησης (kriging) παρουσιάστηκαν σε ένα 3D γράφημα.



Εικόνα 2.10 Αποτελέσματα μοντελοποίησης υπολογιζόμενα από το RBFN (Rusu et al., 2006).



Εικόνα 2.11 Αποτελέσματα μοντελοποίησης υπολογιζόμενα με γεωστατιστική τεχνική εκτίμησης (kriging) (Rusu*et al.*, 2006).

Οι δείκτες (ME, MAE, PMAE, MIN, MAX, PMIN, PMAX, PEAR) της σύγκρισης μεταξύ RBFN και γεωστατιστικής τεχνικής εκτίμησης (kriging) είναι διαφορετικοί τύποι σφαλμάτων και παρουσιάστηκαν σε πίνακα καθώς και η σύγκριση μεταξύ διαφορετικών συναρτήσεων (MQ, MLOG, INVMQ, SPLINE) για το RBFN.

	ME	MAE	PMAE	MIN	MAX	PMIN	PMAX	PEAR
RBF	-1,41	9,15	9,2	-61,14	44,53	0	53,91	0,78
KRG	-1,31	9,28	9,34	-58,39	47,28	0,06	55,82	0,77

Πίνακας 2.3 Στατιστικά RBF και αποτελεσμάτων παρεμβολής kriging (Rusu*et al.*, 2006).

	ME	MAE	PMAE	MIN	MAX	PMIN	PMAX	PEAR
MQ	-1,41	9,15	9,2	-61,14	44,53	0	53,91	0,78
MLOG	-1,19	9,82	9,94	-71,82	34,15	0	45,3	0,77
INVMQ	-12,18	199,4	190,78	-2017	1446	0,42	2004	-0,01
SPLINE	-2,94	53,23	54,59	-635,54	704,15	0,03	706,15	0,17

Πίνακας 2.4 Στατιστικά στοιχεία αποτελεσμάτων παρεμβολής χρησιμοποιώντας διάφορους τύπους RBF (Rusu*et al.*, 2006).

Αρχικά, εξετάζοντας τα τριδιάστατα μοντέλα, η μελέτη καταλήγει στο συμπέρασμα ότι η γεωστατιστική τεχνική εκτίμησης (kriging) υπογραμμίζει περισσότερες λεπτομέρειες, αλλά οι διαφορές είναι μικρές και αφορούν στο διαφορετικό επίπεδο ομαλότητας. Αναφερόμενη στα αποτελέσματα που παρουσιάζονται στους πίνακες, η μελέτη καταλήγει στο συμπέρασμα ότι για τα RBFNs η επιλογή της συνάρτησης είναι σημαντική. Οι πολυτετραγωνικές συναρτήσεις βάσης είναι πιο κατάλληλες για αραιά δεδομένα, επειδή προσφέρουν μια πιο γενική απόκριση σε σύγκριση με τις συναρτήσεις τύπου Gauss. Το πιο σημαντικό είναι ότι η μελέτη καταλήγει στο συμπέρασμα ότι αν και τα αποτελέσματα και ο χρόνος που απαιτείται για την εκτέλεση είναι παρόμοια για τα RBFN και kriging, τα RBFNs είναι πολύ πιο εύκολα και πιο απλά στη χρήση. Το μόνο που απαιτείται για τα RBFNs είναι η επιλογή της συνάρτησης και η εξομάλυνση της παραμέτρου, ενώ για γεωστατιστική τεχνική εκτίμησης (kriging) απαιτείται ένα πολύπλοκο μοντέλο variogram.

Εργασία 3: Δίκτυο RBF για τη χωρική χαρτογράφηση των υψών των κυμάτων

Αυτή η εργασία (Kalraetal., 2005) περιγράφει τη χρήση των RBFNs για πληροφορίες από τηλεπισκόπηση, και πιο συγκεκριμένα για δορυφορικές πληροφορίες. Η εφαρμογή αποτελείται από την χαρτογράφηση των κύματων από τηλεπισκόπηση σε βαθέαυδάτα μέσω των παράκτιων κυμάτων. Η εργασία επικεντρώνεται στη σύγκριση μεταξύ των RBFNs και των δικτύωνπροσωτροφοδότησης και οπισθοδιάδοσης(Feedforwardbackpropagation), καθώς και του συστήματος adaptiveneuro-fuzzyinference (ANFIS), το οποίο συνδυάζει τα πλεονεκτήματα των ANN και της ασαφούς λογικής. Θα επικεντρωθούμε στη σύγκριση μεταξύ του RBFN και του FFBP.

Σκοπός αυτής της έρευνας ήταν να υπολογίσει τα ημερήσια σημαντικά ύψη κύματος σε μια παράκτια τοποθεσία, ανάλογα με τα ύψη των κυμάτων που συλλέγει ένας δορυφόρος κατά μήκος των διαδρομών του. Η κοινή προσέγγιση για την προβολή των δορυφορικών δεδομένων που συλλέγονται σε βαθύτερες ωκεάνιες τοποθεσίες σε μια ρηχή περιοχή θα ήταν η στατιστική παλινδρόμηση. Αλλά αυτή θα έπασχε από τον περιορισμό των μοντέλων και τις αριθμητικές προσεγγίσεις καθώς και από την απαίτηση σημαντικών εξωγενών πληροφοριών, χρόνου και απαιτήσεις αποθήκευσης των ηλεκτρονικών υπολογιστών. Επομένως, ταANNs εξετάστηκαν σε τρεις διαφορετικές αρχιτεκτονικές.

Η περιοχή μελέτης βρίσκεται στη δυτική πλευρά της ινδικής ακτογραμμής. Οι πληροφορίες τηλεπισκόπησης συλλέχθηκαν από ένα ραντάρ υψομέτρησης πάνω σε ένα δορυφόρο. Ο αριθμός κόμβων εισόδου και εξόδου για το FFBP και το ANFIS ήταν 21 και για το δίκτυο RBF 21 και 1. Ο αριθμός των κρυφών μονάδων για το FFBP αποφασίστηκε από δοκιμές να είναι 9 και για το δίκτυο RBF 13. Για τη βαθμονόμηση του δικτύου RBF, το 80% περίπου των διαθέσιμων δεδομένων χρησιμοποιήθηκε και τα υπόλοιπα χρησιμοποιήθηκαν για να τα δοκιμάσουν ή να τα επικυρώσουν.

Errormeasure	RBF	ANFIS	FFBP(Algorithm-RP)
R	0.90	0.82	0.87
MAE	0.26	0.32	0.34
RMSE	0.40	0.56	0.48
SI	0.28	0.40	0.34
MSRE	0.11	0.16	0.12

Πίνακας 2.5 Μέτρα σφάλματος (Kalraetal., 2005).

Η επιλογή του RBFN αποδείχθηκε ότι είναι κατάλληλη για αυτή την εφαρμογή, παρά το γεγονός ότι στην μηχανική των ωκεανών πρώτη επιλογή των περισσότερων εφαρμογών ANN είναι η FFBP. Αυτό μπορεί να φανεί από τα ικανοποιητικά μέτρα σφάλματος που παρήχθησαν κατά τη διάρκεια της φάσης δοκιμής στον πίνακα μετρήσεων σφάλματος. Το δίκτυο RBF έχει το υψηλότερο μέγεθος R και στο υπόλοιπο των μετρήσεων σφάλματος το χαμηλότερο.

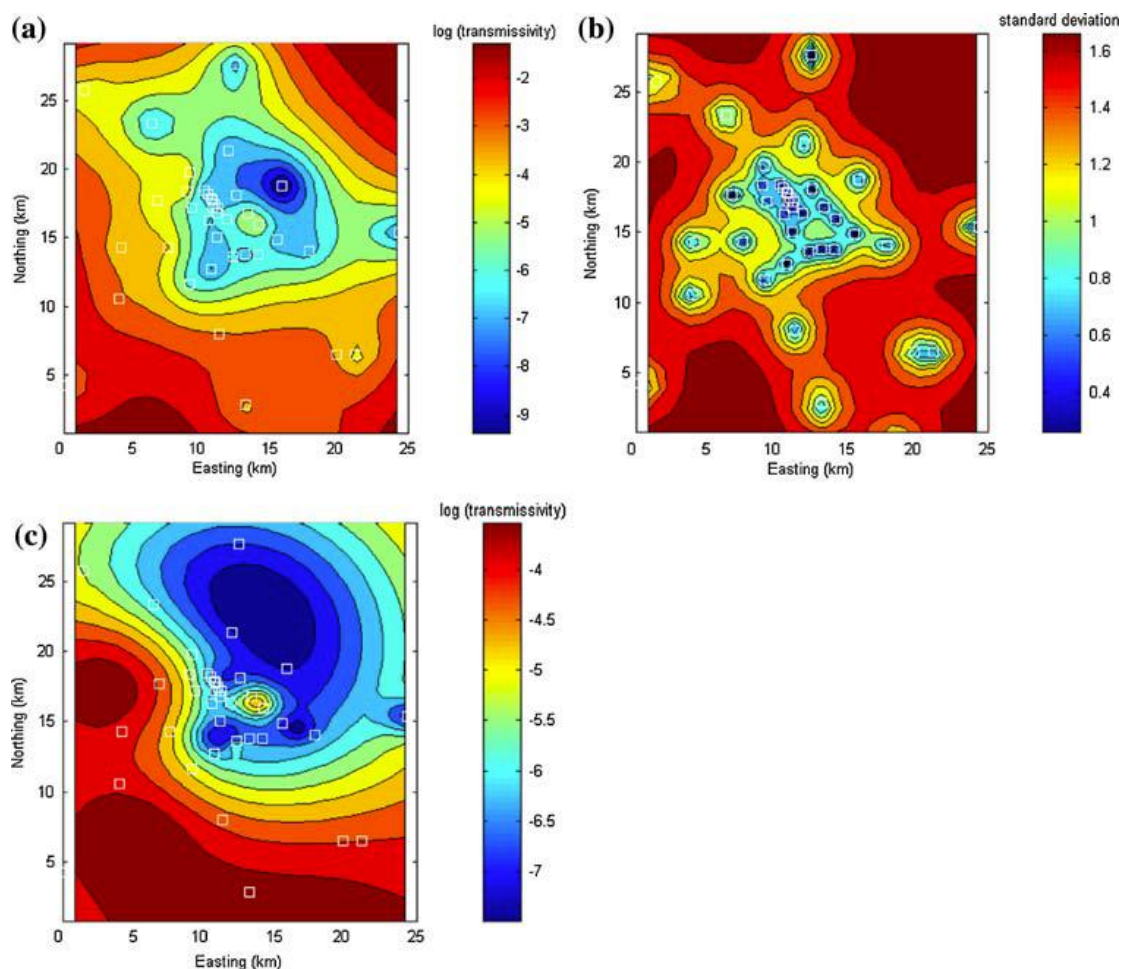
Η μελέτη καταλήγει στο συμπέρασμα ότι το RBFN βρέθηκε πιο κατάλληλο για τη χαρτογράφηση σε σύγκριση με το ANFIS και το FFBP. Ο λόγος είναι ότι τα δορυφορικά δεδομένα χρειάζονται έναν «τοπικό συντονισμό» χωρίς εποπτεία πριν χρησιμοποιηθούν στη ρύθμιση του νευρωνικού δικτύου. Το δίκτυο RBF, όπως αναφέρθηκε προηγουμένως στο κεφάλαιο 2.1.11, διασφαλίζει την τοπική λειτουργία της λειτουργίας μεταφοράς σε αντίθεση με την γενική λειτουργία του FFBP. Η εν λόγω εργασία τονίζει επίσης τη σημασία της ρύθμισης του δικτύου με βάση το συγκεκριμένο σύνολο δεδομένων.

Εργασία 4: Νευρωνικό δίκτυο ακτινικών συναρτήσεων βάσης για υδρολογική αναστροφή: αξιολόγηση με κλασικές και χωροχρονικές γεωστατιστικές τεχνικές στο πλαίσιο του χαρακτηρισμού τοποθεσίας

Αυτή η εργασία (Bagtzoglouetal., 2008) υπογραμμίζει την απόδοση των δικτύων RBF σε σύγκριση με τις κλασικές και χρονικές γεωστατιστικές τεχνικές, όπως η OrdinaryKriging (OK) και η τεχνική χαρτογράφησης BayesianMaximumEntropy (BME). Η εστίαση είναι γύρω από τη χρήση τριών τεχνικών (RBF, OK και BME) για τη χωρική χαρτογράφηση. Η υδραυλική αγωγιμότητα (ή η διαπερατότητα) είναι η υδραυλική ιδιότητα που είναι στο επίκεντρο της μελέτης. Σε αυτό το έργο χρησιμοποιούνται υδρολογικά δεδομένα, τα οποία το καθιστούν κατάλληλο και για την εφαρμογή μας. Θα επικεντρωθούμε κυρίως στις παραμέτρους που βελτιστοποιούν την απόδοση των δικτύων RBF.

Η περιοχή μελέτης είναι η μια μονάδα εναπόθεσης αποβλήτων (WIPP-Waste IsolationPilotPlant)) που βρίσκεται στην έρημο Chihuahuan του νοτιοανατολικού Νέου Μεξικού. Στην περιοχή WIPP υπάρχουν 21 σημεία συλλογής δεδομένων και συμπεριλαμβάνοντας την περιβάλλουσα γεωφυσική περιοχή ενδιαφέροντος, υπάρχουν 41 σημεία. Οι τιμές υδραυλικής αγωγιμότητας μετρήθηκαν και στις 41 θέσεις και οι τιμές υδραυλικού ύψους σε 32 θέσεις. Οι τιμές υδραυλικής αγωγιμότητας ελήφθησαν από δοκιμές DST γεωτρύπανου, δοκιμές Slug (προσθαφαίρεση νερού στην γεώτρηση) και δοκιμές άντλησης μεγάλων περιόδων. Μετρώνται σε (m^2/sec) και ποικίλλουν ανάλογα με τις τάξεις μεγέθους, έτσι ώστε να χρησιμοποιείται το \log_{10} των πρώτων τιμών. Τα δεδομένα υδραυλικής αγωγιμότητας κυμαίνονται από -10,1 έως -2,9 και οι τιμές υδραυλικού ύψους κυμαίνονται από 905 m έως 938 m. Οι τιμές αντλήθηκαν από περιοχή 27 χλμ. Χ 28 χλμ., ενώ η τοποθεσία WIPP είναι ένα τετράγωνο με πλευρά 6 χλμ.

Το δίκτυο RBF εκπαιδεύτηκε χρησιμοποιώντας τις συντεταγμένες χωρικής κατεύθυνσης 41 x και y και τα αντίστοιχα σημεία δεδομένων λογαριθμικής διαπερατότητας. Η σύγκλιση παρατηρήθηκε μετά από 150-300 περιόδους, ένα τμήμα που αντιστοιχεί στο ένα δέκατο των υπολογιστικών απαιτήσεων σε σύγκριση με την οπισθοδιάδοση των ANN. Η προσέγγιση k-meansclustering χρησιμοποιήθηκε για τον ορισμό των κέντρων RBF. Το δίκτυο RBF παράγαγε αποτελέσματα σε 2287 απεικονισμένα στοιχεία. Αυτά τα αποτελέσματα είναι τα δεδομένα που χρησιμοποιήθηκαν για τη σύγκριση του δικτύου RBF με τη γεωστατιστική τεχνική εκτίμησης (kriging). Διαπιστώθηκε ότι το δίκτυο RBF μπορεί να παράγει ένα ρεαλιστικό μοντέλο με περιορισμένα δεδομένα με πολύ παρόμοια με το kriging αποτελέσματα και είναι ακριβέστερο όταν αυξάνεται ο αριθμός των κρυμμένων κόμβων. Η εργασία επίσης ελέγχει τη σύζευξη “soft” ή αλληλεξαρτώμενων δεδομένων με “hard” δεδομένα για το RBF, μέσω της εξόδου δικτύου.



Εικόνα 2.12 Παρεμβολή της λογαριθμική τιμής διαπερατότητας στην τοποθεσία WIPP με: *a) OK b) τυπική απόκλιση kriging και c) RBF-ANN (Bagtzoglou et al., 2008).*

Όσον αφορά τις παραμέτρους που βελτιστοποιούν την απόδοση του δικτύου RBF, σύμφωνα με την εργασία, η αρχικοποίηση του δικτύου με μικρά τυχαία βάρη μπορεί να είναι κρίσιμη για τη σύγκλιση και την επαναληψιμότητα. Επιπλέον, είναι σημαντικό να δημιουργηθούν οι εξαπλώσεις (spreads) των συναρτήσεων βάσης πριν από την εκπαίδευση, επειδή μεταβάλλονται μόνο με τιμές εκπαίδευσης που ενεργοποιούν τη συνάρτηση.

Συμπεράσματα - RBFNs

Υπάρχουν πολλά πλεονεκτήματα στη χρήση των RBFNs για χωρικές προβλέψεις (Rusu et al., 2006). Πρώτον, ανάλογα με τον τύπο των ακτινικών λειτουργιών, το μοντέλο RBF μπορεί να προσφέρει μια τοπική απόκριση (ως εκ τούτου είναι σε θέση να προσδιορίσει τα τοπικά χαρακτηριστικά της επιφάνειας που πρόκειται να μοντελοποιηθεί) ή μια γενικευμένη απόκριση (προσδιορίζοντας έτσι τα γενικά χαρακτηριστικά της προς μοντελοποίηση επιφάνειας). Τα RBFNs είναι ακριβείς παρεμβολείς, προτιμώντας τα σημεία ελέγχου όταν το σημείο συμπίπτει με τον κόμβο του προς παρεμβολήν δικτύου. Επιπλέον, μπορούν να χρησιμοποιηθούν παράγοντες εξομάλυνσης προκειμένου να μειωθούν οι επιπτώσεις της

μεταβλητότητας μικρής κλίμακας μεταξύ γειτονικών σημείων δεδομένων (Rusu et al., 2006).

Ωστόσο, για καλά αποτελέσματα πρέπει να προσδιοριστεί η βέλτιστη αρχιτεκτονική, η οποία δεν είναι πάντα απλή διαδικασία. Πρέπει να δοκιμαστεί με πραγματικά σύνολα δεδομένων, όπως φαίνεται στις περιπτώσεις που μελετήθηκαν.

ΚΕΦΑΛΑΙΟ 3 : ΜΕΘΟΔΟΣ ΚΑΙ ΕΦΑΡΜΟΓΗ

3.1 Ο ΑΛΓΟΡΙΘΜΟΣ ΤΟΥ ANN

3.1.1 Χαρακτηριστικά

Ο αλγόριθμος που χρησιμοποιείται για το νευρωνικό δίκτυο ακτινικών συναρτήσεων βάσης είναι γραμμένος στη γλώσσα προγραμματισμού FORTRAN (Nikolov et al., 2007). Γενικά, ένα RBFN είναι ένα τριών στρωμάτων, πλήρως συνδεδεμένο δίκτυο προσωτροφοδότησης (feed-forward), το οποίο εκτελεί μια μη γραμμική χαρτογράφηση από τον χώρο εισόδου προς στον κρυμμένο χώρο ($R^L \rightarrow R^M$), ακολουθούμενη από μια γραμμική χαρτογράφηση ($R^M \rightarrow R^1$) από το κρυφό προς το χώρο εξόδου (L είναι ο αριθμός των κόμβων εισόδου, M είναι ο αριθμός των κρυφών κόμβων, ενώ το επίπεδο εξόδου έχει έναν μοναδικό κόμβο).

Η αντίστοιχη έξοδος $yy(xx)$, για ένα διάνυσμα εισόδου $xx = [xx_1, xx_2, \dots, xx_L]$ είναι

$$yy(xx) = \sum_{i=1}^M w_i \cdot \varphi_i(xx) \quad (3.1)$$

όπου $\varphi_i(xx)$ είναι η έξοδος της i κρυμμένης μονάδας

$$\varphi_i(xx) = G(\|xx - cc_i\|), \quad i = 1, \dots, M \quad (3.2)$$

Οι συνδέσεις (βάρη) στη μονάδα εξόδου ($w_i, i = 1, \dots, M$) είναι οι μόνοι ρυθμιζόμενες παράμετροι. Τα κέντρα RBFN στις κρυφές μονάδες $cc_i, i = 1, \dots, M$ επιλέγονται με τρόπο ώστε να μεγιστοποιηθούν οι ιδιότητες γενίκευσης του δικτύου. Η συνάρτηση μη γραμμικής ενεργοποίησης G στην περίπτωση μας επιλέγεται να είναι η ακτινική συνάρτηση βάσης του Gauss

$$G(u, \sigma) = \exp\left[-u^2 / \sigma^2\right] \quad (3.3)$$

όπου σ είναι η τυπική απόκλιση της βασικής συνάρτησης.

Υπάρχουν διάφορες στρατηγικές που μπορούν να υιοθετηθούν σχετικά με την επιλογή των κέντρων συναρτήσεων ακτινικής βάσης στο κρυμμένο επίπεδο, όταν σχεδιάζεται ένα RBFN: α) Τυχαία επιλογή σταθερών κέντρων, η οποία είναι η απλούστερη προσέγγιση και η επιλογή κέντρων από τα δεδομένα εκπαίδευσης είναι μια λογική επιλογή. β) Αυτο-οργανωμένη επιλογή κέντρων. γ) Εποπτευόμενη επιλογή κέντρων, η οποία είναι η πιο γενικευμένη μορφή ενός RBFN. Η τυπική διαδικασία είναι να επιλεγούν διανύσματα εισόδου στο σύνολο εκπαίδευσης ως κέντρα RBFN. Σε αυτή την περίπτωση τα αποτελέσματα $M = NR$, όπου NR είναι ο

αριθμός των δεδομένων εκπαίδευσης. Για τα μεγάλα σύνολα εκπαίδευσης (με αποτέλεσμα μεγάλες τιμές M) αυτή η επιλογή αναμένεται να αυξήσει τις απαιτήσεις αποθήκευσης και το κόστος της CPU. Επιπλέον, η επιλογή $M = NR$ θα μπορούσε να οδηγήσει σε υπερβολική προσαρμογή (overfitting) και/ή κακή δυνατότητα γενίκευσης του δικτύου. Η χρησιμοποιούμενη λύση είναι η επιλογή του $M < NR$ και, κατά συνέπεια, η αναζήτηση υποβέλτιστων λύσεων, οι οποίες θα δώσουν μια καλύτερη ικανότητα γενίκευσης στο δίκτυο.

Όσον αφορά στην εκπαίδευση, υπάρχουν δύο διαφορετικές προσεγγίσεις, η άμεση και η επαναληπτική μάθηση. Στην περίπτωση μας επιλέχθηκε η πρώτη προσέγγιση. Η διαδικασία άμεσης εκμάθησης βασίζεται σε μια πινακοποίηση των εξισώσεων που διέπουν το δίκτυο RBF. Η παρουσίαση του δικτύου με τα πρότυπα εισόδου NR επιτρέπει τη διαμόρφωση ενός πίνακα $H(NR \times M)$, που γίνεται τετράγωνος στην ειδική περίπτωση όταν $NR = M$. Κάθε γραμμή στον πίνακα παρεμβολής H αντιστοιχεί σε ένα παράδειγμα μάθησης και κάθε στήλη σε ένα κέντρο RBFN. Οι τιμές των μονάδων εξόδου έχουν ως αποτέλεσμα το προϊόν του πίνακα:

$$H(NR \times M) w(M \times 1) = yy(NR \times 1) \quad (3.4)$$

όπου yy είναι το επιθυμητό διάνυσμα εξόδου, όπως παρέχεται από το σύνολο εκπαίδευσης και w είναι το διάνυσμα συνναπτικών βαρών, το οποίο αποτελείται από M αγνώστους, που πρέπει να υπολογιστούν. Η αναστροφή του H επιτυγχάνεται μέσω της τεχνικής Gram-Schmidt (Nikolos et al., 2007).

3.1.2 Δομή των αρχείων εισόδου

Οι ρυθμίσεις του ANNs τροποποιούνται μέσω των ακόλουθων αρχείων εισόδου: "case.txt", "data.txt", "evaluate.txt", "initialize.txt", "NeuralCombo.txt".

Αρχείο εισόδου "data.txt"

Σε αυτό το αρχείο, το μέγεθος του διαθέσιμου συνόλου δεδομένων εισάγεται στην πρώτη γραμμή και, κάτω από αυτό, τα αντίστοιχα δεδομένα (με τη μορφή των x, y, z συντεταγμένων) εισάγονται σε μορφή τριών στηλών. Οι πρώτες δύο στήλες είναι οι μεταβλητές x και y που αντιστοιχούν στις γεωγραφικές συντεταγμένες και η τρίτη στήλη είναι η γνωστή μέτρηση του υδραυλικού ύψους του υδροφορέα z για τη συγκεκριμένη γεωγραφική θέση (Εικόνα 3.1).

data - Σημειωματάριο

Αρχείο	Επεξεργασία	Μορφή	Προβολή	Βοήθεια
250				
499293	4551336	10		
499350	4551274	9		
500124	4552202	9		
500139	4550691	6		
500186	4550590	3		
500298	4551123	5		
500800	4549971	13		
500948	4550337	13		
501158	4551493	8.7		
501200	4551100	9		

Εικόνα 3.1: Αρχείο εισόδου "data.txt".

Αρχείο εισόδου "evaluate.txt"

Εδώ, οι x, y γεωγραφικές συντεταγμένες, που χρησιμοποιούνται για την αξιολόγηση του ANN, εισάγονται σε δύο στήλες. Το μέγεθος του συνόλου δεδομένων βρίσκεται στην πρώτη γραμμή. Όπως θα περιγραφεί αργότερα σε αυτήν την εργασία, για κάποιες περιπτώσεις θα χρησιμοποιηθούν οι ίδιες συντεταγμένες που χρησιμοποιήθηκαν για την εκπαίδευση και για τη διαδικασία αξιολόγησης (Εικόνα 3.2)

evaluate - Σημειωματάριο

Αρχείο	Επεξεργασία	Μορφή	Προβολή	Βοήθεια
250				
499293	4551336			
499350	4551274			
500124	4552202			
500139	4550691			
500186	4550590			
500298	4551123			
500800	4549971			
500948	4550337			
501158	4551493			
501200	4551100			

Εικόνα 3.2: Αρχείο εισόδου "evaluate.txt".

Αρχείο εισόδου "case.txt"

Σε αυτό το αρχείο, ορίζονται η αρχιτεκτονική και τα χαρακτηριστικά εκπαίδευσης του νευρωνικού δικτύου, όπως περιγράφεται στην Εικόνα 3.3.

```

case - Σημειωματάριο
Αρχείο  Επεξεργασία  Μορφή  Προβολή  Βοήθεια
| Test Case main data
|=====
popsize   =          250
nvars     =           2
NeuralTrain=         198
NeuralTest =          52
globmax   = 25.000000000000000
globmin   = 0.000000000000000E+000
|=====
RBF_NEURAL
NUM_LAYERS=          3
Units(    0  )=          2
Units(    1  )=         198
Units(    2  )=          1

```

Εικόνα 3.3: Αρχείο εισόδου "case.txt".

- *popsize*: Το μέγεθος του συνόλου δεδομένων.
- *nvars*: Ο αριθμός των μεταβλητών εισόδου.
- *NeuralTrain*: Αριθμός δεδομένων που θα χρησιμοποιηθούν για εκπαίδευση.
- *NeuralTest*: Αριθμός δεδομένων που θα χρησιμοποιηθούν για έλεγχο.
- *Globmax*: Η μέγιστη τιμή εξόδου του ANN.
- *Globmin*: Η ελάχιστη τιμή εξόδου του ANN.
- *NUM_LAYERS*: Ο αριθμός των επιπέδων του δικτύου ακτινικών συναρτήσεων βάσης.
- *Units(0)*: Αριθμός νευρωνικών μονάδων του πρώτου επιπέδου (εισόδου).
- *Units(1)*: Αριθμός νευρωνικών μονάδων του δεύτερου επιπέδου.
- *Units(2)*: Αριθμός νευρωνικών μονάδων του τρίτου επιπέδου (εξόδου).

Αρχείο εισόδου "initialize.txt"

Σε αυτό το αρχείο εισόδου ορίζουμε τον αριθμό των μεταβλητών εισόδου, το εύρος της μίας μεταβλητής εξόδου και το εύρος των μεταβλητών εισόδου (Εικόνα 3.4):


nvars: αριθμός μεταβλητών εισόδου.

globmax: η μέγιστη αναμενόμενη τιμή της μεταβλητής εξόδου (στην περίπτωση μας η συντεταγμένη *z*).

globmin: η ελάχιστη αναμενόμενη τιμή της μεταβλητής εξόδου (στην περίπτωση μας η συντεταγμένη *z*).

lobound (1), *upbound (1)*: ελάχιστες και μέγιστες τιμές της πρώτης μεταβλητής εισόδου (στην περίπτωση μας της συντεταγμένης *x*).

lobound (2), *upbound (2)*: ελάχιστες και μέγιστες τιμές της δεύτερης μεταβλητής εισόδου (στην περίπτωση μας της συντεταγμένης *y*).

 initialize - Σημειωματάριο

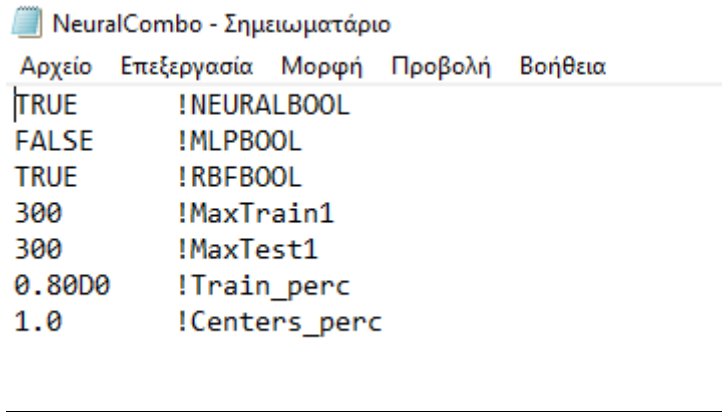
Αρχείο Επεξεργασία Μορφή Προβολή Βοήθεια

```
1
2  25.0  0.0          !nvars, globmax, globmin [zmax, zmin]
499293  519877        !lobound(1), upbound(1) [xmin, xmax]
4538828 4555898       !lobound(2), upbound(2) [ymin, ymax]
```

Εικόνα 3.4: Αρχείο εισόδου "initialize.txt".

Αρχείο εισόδου "NeuralCombo.txt"

Αυτό το αρχείο ορίζει ορισμένες επιλογές σχετικά με τη φύση και τη διαδικασία εκπαίδευσης του χρησιμοποιούμενου τεχνητού νευρωνικού δικτύου (Εικόνα 3.5).



NeuralCombo - Σημειωματάριο

Αρχείο	Επεξεργασία	Μορφή	Προβολή	Βοήθεια
TRUE	!NEURALBOOL			
FALSE	!MLPBOOL			
TRUE	!RBFBOOL			
300	!MaxTrain1			
300	!MaxTest1			
0.8000	!Train_perc			
1.0	!Centers_perc			

Εικόνα 3.5: Αρχείο εισόδου "NeuralCombo.txt".

NEURALBOOL: ορισμένο πάντα ως "TRUE".

MLPBOOL: TRUE εάν χρησιμοποιείται το δίκτυο MLP, FALSE διαφορετικά.

RBFBOOL: TRUE εάν χρησιμοποιείται το δίκτυο RBF, FALSE διαφορετικά.

MaxTrain1: Ο μέγιστος αναμενόμενος αριθμός διαθέσιμων δεδομένων εκπαίδευσης.

MaxTest1: Ο μέγιστος αναμενόμενος αριθμός διαθέσιμων δεδομένων δοκιμών.

Train_perc: Ποσοστό δεδομένων που χρησιμοποιείται για την εκπαίδευση.

Centers_perc: Ποσοστό δεδομένων εκπαίδευσης που χρησιμοποιείται ως κέντρα RBF (συνήθως σύνολο ίσο με 1.0).

3.1.3 Δομή των αρχείων εξόδου

Τα αποτελέσματα της διαδικασίας εμφανίζονται στα αρχεία εξόδου "evalfit.txt" και RBF_error.txt "(ή στο MLP_error.txt, όταν χρησιμοποιείται ένα πολυστρωματικό δίκτυο perceptron).

Αρχείο εξόδου "evalfit.txt"

Αυτό το αρχείο κειμένου περιέχει τα αποτελέσματα της διαδικασίας αξιολόγησης (χρησιμοποιώντας τα δεδομένα εισόδου που περιέχονται στο αρχείο εισόδου evaluation.txt). Οι δύο πρώτες στήλες είναι οι δύο μεταβλητές εισόδου που περιέχονται στο αρχείο εισαγωγής evaluation.txt (οι συντεταγμένες x και y στις οποίες αξιολογείται το δίκτυο) και η τρίτη στήλη είναι οι προβλέψεις τεχνητού νευρωνικού δικτύου της μεταβλητής εξόδου στις αντίστοιχες θέσεις (το υδραυλικό ύψος του υδροφορέα z σε αυτές τις συντεταγμένες) (Εικόνα 3.6).

evalfit - Σημειωματάριο

Αρχείο	Επεξεργασία	Μορφή	Προβολή	Βοήθεια
250				
499293.000000000	4551336.00000000	8.27193182121846		
499350.000000000	4551274.00000000	8.37243501664489		
500124.000000000	4552202.00000000	6.09304553145193		
500139.000000000	4550691.00000000	8.76794195064576		
500186.000000000	4550590.00000000	8.90733081905637		
500298.000000000	4551123.00000000	7.97876479336992		
500800.000000000	4549971.00000000	9.07895026466576		
500948.000000000	4550337.00000000	8.71162906041718		
501158.000000000	4551493.00000000	8.40888767197612		
501380.000000000	4551199.00000000	8.71239374173456		
501416.000000000	4551427.00000000	8.73566983646015		
501467.000000000	4548607.00000000	9.13955109499511		
501542.000000000	4550078.00000000	8.63720524721430		
501543.000000000	4552518.00000000	8.63089402773767		
501554.000000000	4549517.00000000	8.55840435106074		

Εικόνα 3.6: Αρχείο εξόδου "evalfit.txt".

Αρχείο εξόδου "RBF_error.txt"

Σε αυτό το αρχείο εξόδου παρατίθενται τα σφάλματα των προβλέψεων του δικτύου ακτινικών συναρτήσεων βάσης. Αυτά τα σφάλματα υπολογίζονται χρησιμοποιώντας τις διαφορές μεταξύ των μετρούμενων τιμών και των αντίστοιχων προβλεπόμενων τιμών του ύψους του υδροφορέαζ. Η πρώτη τιμή είναι το μέσο σφάλμα εκπαίδευσης (χρησιμοποιώντας το σύνολο δεδομένων εκπαίδευσης), ενώ η δεύτερη τιμή είναι το μέσο σφάλμα δοκιμής (χρησιμοποιώντας το σύνολο δεδομένων δοκιμών) (Εικόνα 3.7).

RBF_error - Σημειωματάριο

Αρχείο	Επεξεργασία	Μορφή	Προβολή	Βοήθεια
3.261853760668297E-003	1.049440636440963E-002			

Εικόνα 3.7: Αρχείο εξόδου "RBF_error.txt".

Γραφική απεικόνιση των αποτελεσμάτων


Για τη γραφική παρουσίαση των δεδομένων και των αποτελεσμάτων χρησιμοποιήθηκε το Microsoft Excel. Οι συντεταγμένες x και y αντιστοιχούν στον άξονα x και y αντιστοίχως. Το υδραυλικό ύψος του υδροφορέα εμφανίζεται ως η ακτίνα ενός κύκλου που έχει το κέντρο του στη θέση της μέτρησης (ή της πρόβλεψης). Όσο μεγαλύτερη είναι η ακτίνα του κύκλου, τόσο μεγαλύτερο είναι το υδραυλικό ύψος. Οι μπλε κύκλοι αντιστοιχούν στο μετρημένο υδραυλικό ύψος του υδροφορέα, ενώ οι κόκκινοι κύκλοι αντιστοιχούν στο προβλεπόμενο υδραυλικό ύψος του υδροφορέα, όπως υπολογίζεται από το δίκτυο ακτινικών συναρτήσεων βάσης. Όσο περισσότερα ταιριάζουν οι 2 τύποι κύκλων, τόσο πιο ακριβής είναι η πρόβλεψη του νευρωνικού δικτύου στις αντίστοιχες συντεταγμένες.

3.2 ΔΟΚΙΜΗ ΤΟΥ ΑΛΓΟΡΙΘΜΟΥ RBFN


Σε αυτό το μέρος, θα χρησιμοποιήσουμε τα διαθέσιμα μετρημένα δεδομένα για την εκπαίδευση του ANN και την αξιολόγηση της ακρίβειάς του. Σε κάθε δοκιμή τα περισσότερα δεδομένα θα χρησιμοποιηθούν για την εκπαίδευση του ANN και τα υπόλοιπα πρόκειται να χρησιμοποιηθούν ως δεδομένα δοκιμών. Στο πρώτο μέρος θα χρησιμοποιήσουμε ολόκληρο το σύνολο των δεδομένων. Στη συνέχεια, τα δεδομένα θα χωριστούν σε δύο υποσύνολα στο $x = 510000$ για να προσδιοριστεί αν η ακρίβεια αυξάνεται εάν δοκιμάζουμε το ANN σε κάθε υποσύνολο ξεχωριστά.

3.2.1 Δοκιμές με ολόκληρο το σύνολο των δεδομένων


Στο σύνολο δεδομένων με μέγεθος 250, το 98% των δεδομένων χρησιμοποιήθηκαν για εκπαίδευση και το υπόλοιπο 2% για τις δοκιμές (αυτό έγινε για να μεγιστοποιηθεί η χρησιμοποιούμενη πληροφορία για την εκπαίδευση του δικτύου). Τα αντίστοιχα σφάλματα εκπαίδευσης και δοκιμής είναι $3,26 \cdot 10^{-3}$ και $1,05 \cdot 10^{-2}$. Τα αποτελέσματα πρόβλεψης για ολόκληρο το σύνολο δεδομένων απεικονίζονται στο ακόλουθο γράφημα (Εικόνα 3.8). Στο διάγραμμα αυτό η ακτίνα κάθε κύκλου απεικονίζει το ύψος του υδροφόρου ορίζοντα στην αντίστοιχη θέση (στο κέντρο του κύκλου). Οι μπλε κύκλοι αντιστοιχούν στο ύψος του μετρημένου υδραυλικού ύψους, ενώ οι κόκκινοι κύκλοι αντιστοιχούν στο ύψος του προβλεπόμενου υδραυλικού ύψους, όπως υπολογίζεται από το δίκτυο ακτινικών συναρτήσεων βάσης (αφού έχει εκπαιδευτεί). Όπως φαίνεται στις Εικόνες 3.8 έως 3.11, έχει επιτευχθεί μια καλή προσέγγιση του υδραυλικού ύψους του υδροφόρου για τα περισσότερα διαθέσιμα πηγάδια. Μπορούμε επίσης να παρατηρήσουμε ότι οι θέσεις των διαθέσιμων πηγιδιών μπορούν να χωριστούν σε δύο διακριτές ομάδες, αριστερά και δεξιά της αξονικής θέσης $x = 510000$ περίπου (Εικόνα 3.8).




Εικόνα 3.8: Δοκιμή με ολόκληρο το σύνολο δεδομένων.



Εικόνα 3.9: Δοκιμή με ολόκληρο το σύνολο δεδομένων (λεπτομέρεια – αριστερό τρίτο).



Εικόνα 3.10: Δοκιμή με ολόκληρο το σύνολο δεδομένων (λεπτομέρεια - μεσαίο τρίτο).




Εικόνα 3.11: Δοκιμή με ολόκληρο το σύνολο δεδομένων (λεπτομέρεια - δεξί τρίτο).

3.2.2 Δοκιμές σε υποσύνολα των δεδομένων


Όπως αναφέρθηκε προηγουμένως, οι θέσεις των πηγαδιών μπορούν οπτικά να χωριστούν σε δύο ξεχωριστές υπο-ομάδες. Αυτή η παρατήρηση θα χρησιμοποιηθεί προκειμένου να αυξηθεί η προβλεπτική ικανότητα του χρησιμοποιούμενου RBFN. Για το σκοπό αυτό εκπαιδεύτηκαν δύο διαφορετικά RBFNs, με τα δεδομένα των δύο διακριτών ομάδων φρεατίων, και συγκρίναμε τα αντίστοιχα αποτελέσματα με τα αποτελέσματα της πρόβλεψης με βάση μια ενιαία ομάδα.

Δοκιμή στην πρώτη ομάδα δεδομένων


Η πρώτη (αριστερή) ομάδα δεδομένων έχει μέγεθος 110 μονάδων, εκ των οποίων το 99% (108 μονάδες) θα χρησιμοποιηθεί για την εκπαίδευση και το 1% για τις δοκιμές (2 μονάδες). Τα προκύπτοντα σφάλματα εκπαίδευσης και δοκιμής είναι $3 * 10^{-4}$ και $4,7 * 10^{-5}$, αντίστοιχα. Η αντίστοιχη σύγκριση μεταξύ του μετρούμενου και του προβλεπόμενου υδραυλικού ύψους του υδροφόρεα παρουσιάζεται στην Εικόνα 3.12 και μεγεθύνεται περισσότερο σε κάθε αριστερό και δεξιό μισό, στις Εικόνες 3.13 και 3.14.



Εικόνα 3.12: Δοκιμή με την πρώτη ομάδα συνόλου δεδομένων.




Εικόνα 3.13: Δοκιμή με την πρώτη ομάδα συνόλου δεδομένων (λεπτομέρεια - αριστερό μισό).




Εικόνα 3.14: Δοκιμή με την πρώτη ομάδα συνόλου δεδομένων (λεπτομέρεια - δεξί μισό).

Δοκιμή με τη δεύτερη ομάδα δεδομένων


Η δεύτερη (δεξιά) ομάδα δεδομένων έχει μέγεθος 140 μονάδων, εκ των οποίων το 99% (138) έχει χρησιμοποιηθεί για εκπαίδευση και 1% (2) για δοκιμές. Τα προκύπτοντα σφάλματα εκπαίδευσης και δοκιμής είναι αντίστοιχα $2,49 \cdot 10^{-3}$ και $4,4 \cdot 10^{-2}$. Η αντίστοιχη σύγκριση μεταξύ του μετρούμενου και του προβλεπόμενου υδραυλικού ύψους του υδροφορέα παρουσιάζεται στην Εικόνα 3.15 και λεπτομερέστερα για κάθε τέταρτοστις Εικόνες 3.16 έως 3.19.




Εικόνα 3.15: Δοκιμή με τη δεύτερη ομάδα συνόλου δεδομένων.




Εικόνα 3.16: Δοκιμή με τη δεύτερη ομάδα συνόλου δεδομένων (λεπτομέρεια - άνω αριστερό τέταρτο).



Εικόνα 3.17: Δοκιμή με τη δεύτερη ομάδα συνόλου δεδομένων (λεπτομέρεια - άνω δεξί τέταρτο).




Εικόνα 3.18: Δοκιμή με τη δεύτερη ομάδα συνόλου δεδομένων (λεπτομέρεια - κάτω αριστερό τέταρτο).




Εικόνα 3.19: Δοκιμή με τη δεύτερη ομάδα του συνόλου δεδομένων (λεπτομέρεια - κάτω δεξί τέταρτο).

Σύγκριση εκπαίδευσης σε χωρισμένο σύνολο δεδομένων έναντι σε ολόκληρο σύνολο δεδομένων.


Το παρακάτω γράφημα περιλαμβάνει τα προβλεπόμενα αποτελέσματα για κάθε μια από τις 250 θέσεις και για τους δύο τρόπους εκπαίδευσης (ολόκληρο σύνολο δεδομένων και διαιρεμένο σύνολο δεδομένων) σε σύγκριση με τα δεδομένα που μετρήθηκαν. Οι κόκκινοι κύκλοι αντιστοιχούν στην εκπαίδευση σε διαιρεμένο σύνολο δεδομένων, ενώ οι μπλε κύκλοι στην εκπαίδευση σε ολόκληρο το σύνολο δεδομένων και οι πράσινοι κύκλοι στα δεδομένα μέτρησης. Τα αποτελέσματα παρουσιάζονται στην Εικόνα 3.20 και λεπτομερέστερα για κάθε τέταρτο στις Εικόνες 3.21 έως 3.24.




Εικόνα 3.20: Σύγκριση εκπαίδευσης σε χωρισμένο σύνολο δεδομένων έναντι σε ολόκληρο σύνολο δεδομένων.




Εικόνα 3.21: Σύγκριση εκπαίδευσης σε χωρισμένο σύνολο δεδομένων έναντι σε ολόκληρο σύνολο δεδομένων (λεπτομέρεια - κάτω αριστερό τέταρτο).



Εικόνα 3.22: Σύγκριση εκπαίδευσης σε χωρισμένο σύνολο δεδομένων έναντι σε ολόκληρο σύνολο δεδομένων (λεπτομέρεια - άνω αριστερό τέταρτο).




Εικόνα 3.23: Σύγκριση εκπαίδευσης σε χωρισμένο σύνολο δεδομένων έναντι σε ολόκληρο σύνολο δεδομένων(λεπτομέρεια - κάτω δεξί τέταρτο).




Εικόνα 3.24: Σύγκριση εκπαίδευσης σε χωρισμένο σύνολο δεδομένων έναντι σε ολόκληρο σύνολο δεδομένων (λεπτομέρεια - άνω δεξί τέταρτο).

3.2.3 Χάρτες Ισοϋψών


Οι Εικόνες 3.25 έως 3.30 παρουσιάζουν χάρτες της περιοχής μελέτης με τις ισοϋψείς για το υδραυλικό ύψος του υδροφορέα. Αυτοί οι χάρτες έχουν κατασκευαστεί για να αποδείξουν καλύτερα την ακρίβεια προβλέψεων του δικτύου RBF για τις δύο διαφορετικές περιπτώσεις. Πρώτον, παρουσιάζονται οι ισοϋψείς των μετρημένων δεδομένων. Όπως μπορεί να παρατηρηθεί με σαφήνεια, τα αποτελέσματα που λαμβάνονται με εκπαίδευση σε διαχωρισμένο σύνολο δεδομένων παρέχουν περισσότερες λεπτομέρειες σχετικά με την κατανομή του υδραυλικού ύψους του υδροφορέα, σε σύγκριση με αυτά που λαμβάνονται με εκπαίδευση σε ολόκληρο το σύνολο δεδομένων. Χρησιμοποιήθηκε το λογισμικό Grapher 13 για την κατασκευή των χαρτών.




Εικόνα 3.25: Ισουψείς του μετρημένου υδραυλικού ύψους υδροφορέα.




Εικόνα 3.26: Ισουψείς του μετρημένου υδραυλικού ύψους υδροφορέα, μαζί με τις 250 θέσεις μέτρησης που εμφανίζονται με κόκκινους κύκλους.




Εικόνα 3.27: Ισοϋψείς του προβλεπόμενου υδραυλικού ύψους υδροφορέα χρησιμοποιώντας ολόκληρο το σύνολο δεδομένων για την εκπαίδευση του RBFN.



Εικόνα 3.28: Ισοϋψείς του προβλεπόμενου υδραυλικού ύψους υδροφορέα χρησιμοποιώντας ολόκληρο το σύνολο δεδομένων για την εκπαίδευση του RBFN, μαζί με τα 250 σημεία μέτρησης που εμφανίζονται με κόκκινους κύκλους.



Εικόνα 3.29: Ισοϋψείς του προβλεπόμενου υδραυλικού ύψους υδροφορέα χρησιμοποιώντας το διαχωρισμένο σύνολο δεδομένων για την εκπαίδευση του RBFN.




Εικόνα 3.30: Ισοϋψείς του προβλεπόμενου υδραυλικού ύψους υδροφορέα χρησιμοποιώντας το διαχωρισμένο σύνολο δεδομένων για την εκπαίδευση του RBFN, μαζί με τα 250 σημεία μέτρησης που εμφανίζονται με κόκκινους κύκλους.

3.2.4 Δοκιμή με τυχαία δεδομένα


Το νευρωνικό δίκτυο δοκιμάστηκε χρησιμοποιώντας μια μαθηματική συνάρτηση για την παραγωγή των "μετρημένων δεδομένων", ενώ οι χωρικές θέσεις για τις "μετρήσεις" έχουν παραχθεί τυχαία σε μια περιοχή από 0 έως 100 για τις στήλες x και y . Η συνάρτηση που παράγει τη συντεταγμένη z των "μετρημένων δεδομένων" είναι η ακόλουθη:

$$z = 2 * \sin\left(\frac{x}{10}\right) + 3 * \cos\left(\frac{y}{10}\right) + 6$$


Τα παραγόμενα δεδομένα χρησιμοποιήθηκαν για την εκπαίδευση του δικτύου RBF, χρησιμοποιώντας 99% (247) των δεδομένων ως δεδομένα εκπαίδευσης και 1% (3) ως δεδομένα δοκιμών. Τα αντίστοιχα αποτελέσματα δείχνουν σφάλματα εκπαίδευσης και δοκιμής $3,33 * 10^{-4}$ και $3,87 * 10^{-4}$. Τα αποτελέσματα φαίνονται στην Εικόνα 3.25 και με περισσότερες λεπτομέρειες για κάθε τέταρτο στις Εικόνες 3.31 έως 3.35. Όπως μπορεί να φανεί, υπάρχει πολύ καλή σύγκλιση μεταξύ των "μετρημένων" και των προβλεπόμενων δεδομένων. Ο λόγος είναι ότι η χωρική κατανομή των διαθέσιμων δεδομένων εκπαίδευσης είναι πολύ ομοιόμορφη, με αποτέλεσμα μια πολύ ομοιόμορφη χωρική κατανομή των κέντρων της ακτινικής συνάρτησης βάσης. Αυτό έχει ως αποτέλεσμα μια καλύτερη δυνατότητα προσέγγισης του δικτύου.




Εικόνα 3.31: Εκπαίδευση με τυχαίο σύνολο δεδομένων (ολόκληρο σύνολο).




Εικόνα 3.32: Εκπαίδευση με τυχαίο σύνολο δεδομένων (λεπτομέρεια - κάτω αριστερό τέταρτο).



Εικόνα 3.33: Εκπαίδευση με τυχαίο σύνολο δεδομένων (λεπτομέρεια - άνω αριστερό τέταρτο).



Εικόνα 3.34: Εκπαίδευση με τυχαίο σύνολο δεδομένων (λεπτομέρεια - κάτω δεξί τέταρτο).



Εικόνα 3.35: Εκπαίδευση με τυχαίο σύνολο δεδομένων (λεπτομέρεια - άνω δεξί τέταρτο).

3.2.5 Παρατηρήσεις

Είναι σαφές ότι ο χωρισμός των δεδομένων εκπαίδευσης σε δύο συγκεντρωμένες ομάδες βελτίωσε την ακρίβεια του ANN. Στην πρώτη ομάδα δεδομένων τα σφάλματα του ANN έχουν μειωθεί κατά περισσότερο από έναν παράγοντα, ενώ στη δεύτερη έχουν ελαφρώς αυξηθεί. Ωστόσο, όπως προκύπτει από τους παραγόμενους χάρτες ισοϋψών του υδραυλικού ύψους του υδροφόρου, το εκπαιδευμένο δίκτυο στο διαιρεμένο σύνολο δεδομένων παρείχε προβλέψεις με καλύτερες λεπτομέρειες, σε σύγκριση με εκείνες που παράγονται με εκπαίδευση σε ολόκληρο το σύνολο δεδομένων.

Αυτό είναι αναμενόμενο, επειδή το νευρωνικό δίκτυο με αυτόν τον τρόπο εκπαιδεύεται να προσαρμόζεται σε κάθε συγκεκριμένο τοπικό σύνολο δεδομένων με καλύτερο τρόπο. Καθώς οι θέσεις των μετρήσεων είναι διάσπαρτες με μη κανονικό τρόπο, ο διαχωρισμός του συνόλου δεδομένων σε δύο υποσύνολα, τα οποία είναι πιο κανονικά κατανομημένα, επιτρέπει μια πιο ομοιόμορφη κατανομή των κέντρων RBF και μια καλύτερη προγνωστική ικανότητα του δικτύου.

ΚΕΦΑΛΑΙΟ 4: ΣΥΜΠΕΡΑΣΜΑΤΑ

Αυτή η μελέτη παρουσίασε τη χρήση ενός συγκεκριμένου τύπου τεχνητού νευρικού δικτύου, το δίκτυο ακτινικών συναρτήσεων βάσης (RBFN) για τη χωρική πρόβλεψη υδραυλικού ύψους υδροφόρεα. Αυτή η μέθοδος αποδείχθηκε επιτυχής, καθώς οι μετρήσεις σφάλματος είναι χαμηλές και η προβλεπόμενη χωρική κατανομή του υδραυλικού ύψους του υδροφόρεα πλησιάζει την αντίστοιχη μετρούμενη κατανομή.

Το κύριο συμπέρασμά μας σχετικά με τη λειτουργία του δικτύου ακτινικών συναρτήσεων βάσης RBFN είναι ότι τα σύνολα δεδομένων που έχουν μια πιο ομοιόμορφη κατανομή αυξάνουν την ακρίβεια του δικτύου, καθώς αυτό επιτρέπει μια πιο ομοιόμορφη κατανομή των κέντρων RBFN. Αυτό προσδιορίστηκε από την αύξηση της ακρίβειας όταν το σύνολο δεδομένων χωρίστηκε από ένα άνισα κατανεμημένο σύνολο δεδομένων, σε δύο πιο κανονικά κατανεμημένα υποσύνολα δεδομένων. Παρατηρήθηκε επίσης ότι όταν το RBFN εκπαιδεύτηκε και δοκιμάστηκε σε ένα τεχνητό σύνολο δεδομένων με τυχαία αλλά σχεδόν ομοιόμορφη χωρική κατανομή, παρείχε πολύ ικανοποιητικά αποτελέσματα. Αυτό το χαρακτηριστικό σχετίζεται με τη χρήση της συνάρτησης Gauss για το RBFN, η οποία παρέχει μια ισχυρή επίδραση στην περιοχή κοντά στο κέντρο της.

Τέλος, η χρήση των τεχνητών νευρωνικών δικτύων RBF για αυτή την εφαρμογή δείχνει την ευκολία χρήσης και πρακτικότητάς τους, καθώς δεν χρησιμοποιήθηκε μοντελοποίηση των φυσικών και χημικών διεργασιών στην περιοχής μελέτης μας. Το τεχνητό νευρωνικό δίκτυο παρείχε τις λύσεις χωρίς να καθορίζει τη σχέση μεταξύ των δεδομένων εισόδου και των αποτελεσμάτων. Ως εκ τούτου, παρέχουν μια βιώσιμη εναλλακτική στις υδρολογικές τεχνικές μοντελοποίησης.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- F. Akram, M.G. Rasul, M.M.K. Khan, M.S.I.I Amir (2012), “A Comparative View of Groundwater Flow Simulation Using Two Modelling Software - MODFLOW and MIKE SHE”, *Proceedings of the 18th Australasian Fluid Mechanics Conference*, Launceston, Australia.
- J. Arnold, R. Srinivasan, R.S. Muttiah, J.R. Williams (1998), “Large Area Hydrologic Modeling and Assessment Part I: Model Development”, *JAWRA Journal of the American Water Resources Association*, vol. 34(1), pp. 73-89.
- A.C. Bagtzoglou, F. Hossain (2008), “Radial basis function neural network for hydrologic inversion: an appraisal with classical and spatio-temporal geostatistical techniques in the context of site characterization”, *Stochastic Environmental Research and Risk Assessment*, vol. 23(7), pp. 933–945.
- E. Binaghi, V. Pedoia, A. Guidali, M. Guglielmin (2013), “Snow cover thickness estimation using radial basis function networks”, *The Cryosphere*, vol. 7, pp. 841–854.
- M.T. Brown, L.R. Wicker (2000), “Discriminant Analysis”, *Handbook of Applied Multivariate Statistics and Mathematical Modeling*, pp. 209-235.
- R. Callan (1999), *The essence of Neural Networks*, Prentice Hall Europe.
- A. Gemitzi, C. Petalas, V. Pisinaras, V.A. Tsihrintzis(2008), “Spatial prediction of nitrate pollution in ground waters using neural networks and GIS: an application to South Rhodope aquifer (Thrace, Greece)”, *Hydrological Processes*, vol. 23, pp. 372–383.
- V. Gholami, M. Sebghati, Z. Yousefi (2016), “Integration of artificial neural network and geographic information system applications in simulating groundwater quality”, *Environmental Health Engineering and Management Journal*, vol. 3(4), pp. 173-182.
- S. Gopal (2017), “Artificial neural networks in geospatial analysis”, *The International Encyclopedia of Geography*, John Wiley & Sons Ltd.
- S. Grimaldi, S.-C. Kao, A. Castellarin, S.-M. Papalexiou, A. Viglione, F. Laio, H. Aksoy and A. Gedikli (2011), “Statistical Hydrology”. In: P. Wilderer (Ed.) *Treatise on Water Science*, vol. 2, pp. 479–517, Oxford Academic Press.
- T. Harter (2003), *Basic Concepts of Groundwater Hydrology*, Agriculture and Natural Resources (ANR), Publication 8083, University of California, Davis, USA.

S. Haykin (1999), *Neural Networks a Comprehensive Foundation*, 2nd Edition, Prentice-Hall.

D.O. Hebb (1949), *The Organization of Behavior: A Neuropsychological Theory*, Wiley, New York.

J.J. Hopfield (1982), “Neural Networks and physical systems with emergent collective computational abilities”, *Proceedings of the National Academy of Sciences, USA*, vol. 79, pp. 2554-2558.

J.W. Kalat (2001), *Biological Psychology*, 7th edition, Wadsworth Thomson Learning.

R, Kalra, M.C. Deo, R. Kumar, V. K. Agarwal (2005), “RBF network for spatial mapping of wave heights”, *Marine Structures*, vol. 18(3), pp. 289-300.

B. Krose, P. Smagt (1996), *An Introduction to Neural Networks*, 8th Edition, The University of Amsterdam.

J.F. Mas, J.J. Flores (2008), “The application of artificial neural networks to the analysis of remotely sensed data”, *International Journal of Remote Sensing*, vol. 29(3), pp. 617-663.

W.S. McCulloch, W. Pitts (1943), “A logical calculus of the ideas immanent in nervous activity”, *Bulletin of Mathematical Biophysics*, vol. 5, pp. 115-133.

M.L. Minsky (1961), “Steps toward artificial intelligence”, *Proceedings of the Institute of Radio Engineers*, vol. 49, pp. 8-30, (Reprinted in: E.A. Feigenbaum, and J. Feldman, (Eds.), *Computers and Thought*, pp. 406-450, McGraw-Hill, New York).

M.L. Minsky (1967), *Computation: Finite and Infinite Machines*, Englewood Cliffs, Prentice-Hall.

M.L. Minsky, S.A Papert (1969), *Perceptrons*, MIT Press.

S.A. Nelson (2015), *Ground water*, Lecture Notes, Tulane University.

I.K. Nikolos, E.S. Zografos, A.N. Brintaki (2007), “UAV Path Planning Using Evolutionary Algorithms”, in J.S. Chahl et al. (Eds.), *Innovations in Intelligent Machines - 1*, (Series: Studies in Computational Intelligence – SCI, vol. 70), pp. 77-111, Springer.

S. Noack, A. Knobloch, S.H. Etzold, A. Barth, E. Kallmeier (2014), “Spatial predictive mapping using Artificial Neural Networks”, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XL-2, ISPRS Technical Commission II Symposium, 6 – 8 October, Toronto, Canada.

M.J.L. Orr (1996), *Introduction to Radial Basis Function Networks*, Centre for Cognitive Science, University of Edinburgh, Scotland, U.K.

M. Richarme (2002), “Eleven Multivariate Analysis Techniques: Key Tools In Your Marketing Research Survival Kit”.

<https://www.decisionanalyst.com/whitepapers/multivariate/>

B.D. Ripley (1996), *Patern Recognition and Neural Networks*, 1st Edition, Cambridge University Press.

N. Rochester, J.H Holland, L.H Haibt, W.L Duda (1956), “Tests on a cell assembly theory of the action of the brain using a large digital computer”, *IRE Transactions on Information Theory*, vol. IT-2, pp. 80-93.

F. Rosenblatt (1958), “The perceptron: A probabilistic model for information storage and organization in the brain”, *Psychological Review*, vol. 65, pp. 386-408.

D.E. Rumelhart, G.E. Hinton, R.J. Williams (1986), “Learning representations of back-propagation errors”, *Nature*, vol. 323, pp. 533-536.

C. Rusu, V. Rusu(2006), “Radial Basis Functions Versus Geostatistics in Spatial Interpolations”, *International Federation for Information Processing (IFIP)*, vol. 217, pp. 119–128.

S.M. Seth (2009), “Physically based hydrological modelling”.
<https://www.geospatialworld.net/article/physically-based-hydrological-modelling/>

P.J. Werbos (1974), *Beyond Regression: New tools for prediction and analysis in the behavioral sciences*, Ph. D Thesis, Harvard University, Cambridge, MA, USA.

B. Widrow, M.E. Hoff (1960), “Adaptive switching circuits”, *IRE WESCON Convention Record*, pp. 96-104.

N. Wiener (1948), *Cybernetics: Or Control and Communication in the Animal and the Machine*, Wiley, New York.

C. Woodford (2018), “Neural Networks”.

<http://www.explainthatstuff.com/introduction-to-neural-networks.html>

Chong Yu. Xu (2002), *Hydrologic Models*, Textbooks of Uppsala University, Department of Earth Sciences Hydrology.

The USGS Water Science School (2016), “Infiltration - The water cycle”.
<https://water.usgs.gov/edu/watercycleinfiltration.html>