

ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ



ΤΜΗΜΑ ΗΛΕΚΤΡΟΝΙΚΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

Διπλωματική εργασία

ΘΕΜΑ: «Στατικές και δυναμικές μηχανές νευρωνικών δικτύων για
πρόβλεψη μετεωρολογικών παραμέτρων»

Εξεταστική επιτροπή:
Σταυρακάκης Γ. (Επιβλέπων)
Ζερβάκης Μ.
Καλαϊτζάκης Κ.

Ζήσος Ιωάννης
Ιούλιος 2006

ΠΕΡΙΕΧΟΜΕΝΑ

ΘΕΩΡΗΤΙΚΟ ΜΕΡΟΣ

ΚΕΦΑΛΑΙΟ 1 :	ΧΡΟΝΟΣΕΙΡΕΣ	1
1.1	ΓΕΝΙΚΑ ΓΙΑ ΧΡΟΝΟΣΕΙΡΕΣ	1
1.2	ΑΝΑΛΥΣΗ ΧΡΟΝΟΣΕΙΡΑΣ	2
1.3	ΠΡΟΒΛΕΨΗ ΧΡΟΝΟΣΕΙΡΑΣ	3
1.3.1	Γενική μεθοδολογία πρόβλεψης με χρονοσειρά	3
1.3.2	Πλεονεκτήματα μοντέλου χρονοσειρών για πρόβλεψη	4
1.4	ΚΑΝΟΝΙΚΟΠΟΙΗΣΗ ΤΩΝ ΧΡΟΝΟΣΕΙΡΩΝ	5
1.5	ΣΥΝΑΡΤΗΣΗ ΑΥΤΟΣΥΣΧΕΤΙΣΗΣ (Autocorrelation Function)	5
ΚΕΦΑΛΑΙΟ 2 :	ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ	6
	(Neural Networks)	
2.1	Ιστορική αναδρομή	6
2.2	ΒΙΟΛΟΓΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ	7
2.2.1	Ο ανθρώπινος εγκέφαλος σαν σύστημα επεξεργασίας πληροφοριών	7
2.2.2.	Βιολογικός Νευρώνας	8
2.2.3	Εκμάθηση συνάψεων	9
2.3	ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ	9
2.3.1	Ορισμός	9
2.3.2	Μοντέλο νευρώνα	10
2.3.3	Συναρτήσεις ενεργοποίησης(Activation functions)	12
2.3.4	Αρχιτεκτονικές δικτύων(Network architectures)	13
2.3.5	Κανόνες μάθησης	15
2.3.6	Κανόνες εκπαίδευσης νευρωνικών δικτύων	17
2.3.6.1	Κανόνας εκπαίδευσης νευρώνα	17
2.3.6.2	Εκπαίδευση μονοστρωματικών νευρωνικών δικτύων	18
2.3.6.3	Εκπαίδευση πολυστρωματικών νευρωνικών δικτύων	19

2.3.6.3.1	Αλγόριθμος οπίσθιας διάδοσης σφαλμάτων για πολυστρωματικά feedforward νευρωνικά δίκτυα (Backpropagation Algorithm)	21
2.3.6.3.2	Μέθοδος Quasi-Newton	25
2.3.6.3.3	Αλγόριθμος Levenberg-Marquardt(LM)	26
2.4	ΠΛΕΟΝΕΚΤΗΜΑΤΑ ΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ	27
2.5	ΖΗΤΗΜΑΤΑ ΥΛΟΠΟΙΗΣΗΣ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ	29
2.5.1	Μέθοδος cross-validation	31
ΚΕΦΑΛΑΙΟ 3 :	ΣΥΝΕΡΓΑΤΙΚΕΣ ΜΗΧΑΝΕΣ ΣΥΛΛΟΓΙΚΗΣ ΑΠΟΦΑΣΗΣ (COMMITTEE MACHINES)	33
3.1	ΕΙΣΑΓΩΓΗ	33
3.2	ΠΛΕΟΝΕΚΤΗΜΑΤΑ ΜΗΧΑΝΩΝ ΑΠΟΦΑΣΗΣ	33
3.3	ΚΑΤΗΓΟΡΙΕΣ ΜΗΧΑΝΩΝ ΑΠΟΦΑΣΗΣ	34
3.3.1	Ensemble averaging	35
3.3.2	Mixture of experts	36
ΚΕΦΑΛΑΙΟ 4 :	ΠΡΟΣΑΡΜΟΣΙΜΟ ΝΕΥΡΟ-ΑΣΑΦΕΣ ΣΥΣΤΗΜΑ (ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM) (ANFIS)	38
4.1	Ασαφής Λογική	38
4.1.1	Ασαφή σύνολα	38
4.1.2	Ασαφής έλεγχος-ασαφής πρόβλεψη	39
4.2	Μέθοδος Mamdani	40
4.3	Μέθοδος Takagi-Sugeno	42
4.4	Νευρο-ασαφή συστήματα	43
4.4.1	ANFIS	44

ΠΕΙΡΑΜΑΤΙΚΟ ΜΕΡΟΣ

ΚΕΦΑΛΑΙΟ 5 :	ΠΕΙΡΑΜΑΤΙΚΟ ΜΕΡΟΣ	46
5.1	ΠΑΡΟΥΣΙΑΣΗ ΤΩΝ ΧΡΟΝΟΣΕΙΡΩΝ ΘΕΡΜΟΚΡΑΣΙΑΣ ΚΑΙ ΗΛΙΑΚΗΣ ΑΚΤΙΝΟΒΟΛΙΑΣ	46
5.1.1	Ηλιακή ακτινοβολία	46
5.1.1.1	Γενικά	46
5.1.1.2	Επεξεργασία των δεδομένων	46
5.1.2	Θερμοκρασία	49
5.1.2.1	Γενικά	49
5.1.2.2	Επεξεργασία των δεδομένων	50
5.1.3	Κανονικοποίηση των χρονοσειρών ηλιακής ακτινοβολίας και θερμοκρασίας	53
5.1.4	Αυτοσυσχέτιση των χρονοσειρών ηλιακής ακτινοβολίας και θερμοκρασίας	55
5.1.5	Περίοδος χρονοσειρών	56
5.1.6	Τροποποίηση χρονοσειρών για χρήση τους στα συστήματα πρόβλεψης	57
5.2	ΠΡΟΒΛΕΨΗ ΜΕ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ(Neural Network Prediction)	59
5.2.1	Εισαγωγή	59
5.2.2	Ανάπτυξη νευρωνικών δικτύων πρόβλεψης	59
5.2.2.1	Διαδικασία πρόβλεψης	60
5.2.2.1.1	Δεδομένα εκπαίδευσης – Δεδομένα δοκιμής	60
5.2.2.1.2	Δομή των νευρωνικών δικτύων	62
5.2.2.1.3	Μέθοδος Εκπαίδευσης	65
5.2.2.1.4	Μετρικές απόδοσης	69
5.2.3	Εκπαίδευση νευρωνικών δικτύων – Αποτελέσματα προβλέψεων	70
5.2.3.1	Ηλιακή ακτινοβολία	70
5.2.3.2	Θερμοκρασία	73
5.3	ΠΡΟΒΛΕΨΗ ΜΕ ANFIS	77
5.3.1	Αποτελέσματα προβλέψεων ηλιακής ακτινοβολίας με ANFIS	78
5.3.2	Αποτελέσματα προβλέψεων θερμοκρασίας με ANFIS	78

5.4	ΑΝΑΠΤΥΞΗ ΜΗΧΑΝΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ (Neural Committee Machines)	80
5.4.1	Στατικές μηχανές νευρωνικών δικτύων	81
5.4.2	Δυναμικές μηχανές νευρωνικών δικτύων	87
5.4.3	Πρόβλεψη με μηχανές νευρωνικών δικτύων - Αποτελέσματα προβλέψεων	88
5.4.3.1	Αποτελέσματα προβλέψεων ηλιακής ακτινοβολίας με τις επτά μηχανές νευρωνικών δικτύων	90
5.4.3.2	Αποτελέσματα προβλέψεων θερμοκρασίας με τις επτά μηχανές νευρωνικών δικτύων	91
5.5	ΓΡΑΦΙΚΕΣ ΠΑΡΑΣΤΑΣΕΙΣ ΕΚΠΑΙΔΕΥΣΗΣ ΜΕ ΠΡΑΓΜΑΤΙΚΑ ΔΕΔΟΜΕΝΑ	96
	ΚΕΦΑΛΑΙΟ 6 : ΣΥΜΠΕΡΑΣΜΑΤΑ – ΠΕΡΑΙΤΕΡΩ ΕΡΕΥΝΑ	102
	ΠΑΡΑΡΤΗΜΑ	105
	ΒΙΒΛΙΟΓΡΑΦΙΑ-ΑΝΑΦΟΡΕΣ	

ΕΙΣΑΓΩΓΗ

Σ' αυτή τη διπλωματική γίνεται μια προσέγγιση επίλυσης του προβλήματος της πρόβλεψης μετεωρολογικών παραμέτρων. Για την επίλυση αυτού του ανοικτού προβλήματος υπάρχουν σημαντικές ερευνητικές προσπάθειες με πολύ καλά αποτελέσματα. Η γνώση των μελλοντικών τιμών (βραχυχρόνια πρόβλεψη) των μετεωρολογικών παραμέτρων, όπως η θερμοκρασία περιβάλλοντος και η ηλιακή ακτινοβολία, συνεισφέρει σημαντική πληροφορία σε πολλές επιστημονικές περιοχές.

Στην εργασία αυτή υλοποιήθηκαν νευρωνικά δίκτυα με ποικίλες τοπολογίες και μεθόδους εκπαίδευσης με στόχο την εύρεση της καταλληλότερης δομής νευρωνικού δικτύου ως forecaster, δηλαδή τον καθορισμό του πλήθους των εισόδων και του αριθμού των κρυφών στρωμάτων και των αντίστοιχων κόμβων του νευρωνικού δικτύου.

Ένα σημαντικό μέρος της εργασίας καταπιάνεται με την ανάπτυξη στατικών και δυναμικών μηχανών (Committee Machines) αποτελούμενες από νευρωνικά δίκτυα και νευροασαφή συστήματα (ANFIS) σε συνεργατική μορφή. Ο στόχος της υλοποίησης αυτών των μηχανών ήταν η επίτευξη βέλτιστης πρόβλεψης σε σχέση με την πρόβλεψη των μεμονωμένων νευροασαφών predictors.

Η δομή της εργασίας έχει ως εξής:

Δύο γενικά μέρη: το **Θεωρητικό** και το **Πειραματικό** μέρος

Στο **Θεωρητικό** μέρος ανήκουν τα κεφάλαια **1,2,3,4** ενώ στο **Πειραματικό** μέρος ανήκει το **5^ο** κεφάλαιο.

Το **κεφάλαιο 1** περιγράφει τη χρονοσειρά σαν έννοια, αναφέρει τα σημαντικότερα προβλήματα ανάλυσης χρονοσειράς και στη συνέχεια επικεντρώνεται στη πρόβλεψη χρονοσειράς και στα πλεονεκτήματα του συγκεκριμένου μοντέλου πρόβλεψης.

Το **κεφάλαιο 2** περιγράφει τα νευρωνικά δίκτυα. Αναφέρεται στη λειτουργία των βιολογικών νευρωνικών δικτύων τη συσχετίζει με το μοντέλο επεξεργασία ενός συμβατικού υπολογιστή και στη συνέχεια διεισδύει στα τεχνητά νευρωνικά δίκτυα. Τα ορίζει, αναφέρει τις διαφορετικές αρχιτεκτονικές τους, αναλύει κάποιες μεθόδους μάθησης και εκπαίδευσης νευρωνικών δικτύων και καταλήγει στα πλεονεκτήματα τους σαν συστήματα καθώς και σε κάποια ζητήματα υλοποίησης τους.

Το **κεφάλαιο 3** περιγράφει τις συνεργατικές μηχανές συλλογικής απόφασης. Αναφέρεται στα πλεονεκτήματα τους, στις κατηγορίες μηχανών και αναλύει τη λειτουργία δύο διαφορετικών δομών μηχανών συλλογικής απόφασης που χρησιμοποιούνται.

Το **κεφάλαιο 4** περιγράφει το ANFIS. Αρχικά γίνεται αναφορά στην ασαφή λογική και στις αρχές της καθώς και στην πρόβλεψη με χρήση ασαφούς λογικής. Εν συνεχεία ορίζονται τα νευρο-ασαφή συστήματα και περιγράφεται συνοπτικά η λειτουργία του ANFIS.

Το **κεφάλαιο 5** αποτελεί το πειραματικό μέρος της εργασίας. Στη παράγραφο **5.1** παρουσιάζονται οι χρονοσειρές ηλιακής ακτινοβολίας και θερμοκρασίας και γίνεται επεξεργασία τους ώστε να χρησιμοποιηθούν στα συστήματα πρόβλεψης που υλοποιούνται. Στη παράγραφο **5.2** αναπτύσσονται δομές νευρωνικών δικτύων πρόβλεψης, οι οποίες εκπαιδεύονται με τα δεδομένα των χρονοσειρών ηλιακής ακτινοβολίας και θερμοκρασίας και στη συνέχεια κάνουν πρόβλεψη αυτών των μετεωρολογικών παραμέτρων. Οι διαφορετικές δομές νευρωνικών δικτύων συγκρίνονται για τις προβλέψεις τους με βάση κάποιες μετρικές απόδοσης. Στη παράγραφο **5.3** υλοποιείται το ANFIS και στη συνέχεια γίνεται πρόβλεψη ηλιακής ακτινοβολίας και θερμοκρασίας με βάση το συγκεκριμένο νευρο-ασαφές σύστημα. Στη παράγραφο **5.4** αναπτύσσονται επτά διαφορετικές συνεργατικές μηχανές συλλογικής απόφασης. Στη συνέχεια ακολουθεί, η διαδικασία πρόβλεψης ηλιακής ακτινοβολίας και θερμοκρασίας με χρήση καθεμιάς απ' τις μηχανές, καθώς και η μεταξύ τους σύγκριση με βάση μετρικές απόδοσης. Στη παράγραφο **5.5** παρατίθενται γραφικές παραστάσεις προβλέψεων με χρήση πραγματικών δεδομένων για τα "καλύτερα" νευρωνικά δίκτυα πρόβλεψης, το ANFIS και τη "καλύτερη" συνεργατική μηχανή συλλογικής απόφασης.

Το **κεφάλαιο 6** περιέχει τα γενικά συμπεράσματα της εργασίας καθώς και προτάσεις για περαιτέρω έρευνα.

Στη συνέχεια ακολουθεί το **Παράρτημα** με πίνακες αποτελεσμάτων προσομοιώσεων με όλες τις δομές νευρωνικών δικτύων που υλοποιήθηκαν, καθώς και με γραφικές παραστάσεις προβλέψεων για τα "καλύτερα" νευρωνικά δίκτυα που προέκυψαν.

ΚΕΦΑΛΑΙΟ

1

ΘΕΩΡΗΤΙΚΟ ΜΕΡΟΣ

ΧΡΟΝΟΣΕΙΡΕΣ

1.1 ΓΕΝΙΚΑ ΓΙΑ ΧΡΟΝΟΣΕΙΡΕΣ

Ορισμός χρονοσειράς (timeseries): Χρονοσειρά είναι μια ακολουθία μετρούμενων ποσοτήτων x_1, x_2, \dots, x_n , ενός φυσικού συστήματος που έχουν ληφθεί ανά συγκεκριμένα τακτά χρονικά διαστήματα. Τα διαστήματα αυτά μπορεί να είναι ωριαία, ημερήσια, μηνιαία ή ετήσια.

Ποιοτικά χαρακτηριστικά των χρονοσειρών:

1. Στασιμότητα (Stationary),
2. Τάση (Trend),
3. Περιοδικότητα ή Εποχικότητα (Seasonal),
4. Κυκλικότητα (Cyclical),
5. Ασυνέχειες (Discontinuity): Ασυνήθιστες τιμές (Outliers),
6. Τυχαιότητα (Randomization).

Μια χρονοσειρά θεωρείται στάσιμη, όταν οι στατιστικές ιδιότητες της χρονοσειράς δεν αλλάζουν με το χρόνο. Ειδικότερα μια χρονοσειρά θα είναι στάσιμη αν έχει μέση τιμή και διακύμανση μη μεταβαλλόμενα με το χρόνο, καθώς και αν η συνδιασπορά μεταξύ τιμών της χρονοσειράς σε δύο διαφορετικά χρονικά σημεία εξαρτάται μόνο από την απόσταση ανάμεσα σε αυτά τα χρονικά σημεία και όχι από τις συγκεκριμένες χρονικές στιγμές.

Το στοιχείο της τάσης περιγράφει τη μακροχρόνια συμπεριφορά μιας χρονοσειράς. Ειδικότερα, αν για μία μακρά χρονική περίοδο οι τιμές μιας χρονοσειράς τείνουν να αυξάνονται ή να μειώνονται, τότε λέμε ότι η σειρά των παρατηρήσεων παρουσιάζει μακροχρόνια τάση.

Το στοιχείο της περιοδικότητας ή εποχικότητας περιγράφει κανονικές επαναλαμβανόμενες διακυμάνσεις των τιμών μιας χρονοσειράς σε κάποια χρονική περίοδο που αυτές μπορεί να αντιστοιχούν σε ένα χρόνο, μια εποχή του χρόνου, ένα μήνα ή και μια βδομάδα. Οι εποχικές μεταβολές είναι ρυθμικές, επαναλαμβανόμενες

στο χρόνο και φέρονται να αναφέρονται σε κάποιο πρότυπο, που ακολουθεί το μετρούμενο μέγεθος, το οποίο αποτυπώνεται στις τιμές της χρονοσειράς κατά τη διάρκεια αντίστοιχων μηνών σε διαδοχικά έτη.

Το στοιχείο της κυκλικότητας αναφέρεται σε μακράς περιόδου ταλαντεύσεις των τιμών, γύρω από μία γραμμή ή καμπύλη τάσης. Οι κυκλικές μεταβολές διαφέρουν από τις περιοδικές, καθώς είναι μεγαλύτερης διάρκειας και δεν παρουσιάζουν μεγάλη περιοδικότητα.

Οι ασυνέχειες αποτελούν "παραμορφώσεις" των χρονοσειρών σε ορισμένα σημεία και οφείλονται κυρίως σε σφάλματα των οργάνων μέτρησης, των μετρούμενων μεγεθών, τις συγκεκριμένες χρονικές στιγμές. Οι τιμές της χρονοσειράς στα σημεία αυτά αποτελούν σφάλματα οργάνων. Επειδή οι τιμές-σφάλματα οργάνων αποτελούν πρόβλημα στην επεξεργασία των χρονοσειρών, απαλείφονται ή αντικαθίστανται, προκειμένου να επιτευχθεί εξομάλυνση της χρονοσειράς.

Η τυχαιότητα έχει να κάνει με απροσδόκητες διακυμάνσεις των τιμών της χρονοσειράς που έχουν να κάνουν είτε με φυσικά αίτια, είτε με ξαφνικά και απρόβλεπτα συμβάντα.

1.2 ΑΝΑΛΥΣΗ ΧΡΟΝΟΣΕΙΡΑΣ

Η ανάλυση των χρονοσειράς περιλαμβάνει τρία σημαντικά ειδικά προβλήματα:

1. Πρόβλεψη (Prediction)
2. Μοντελοποίηση (Modeling)
3. Χαρακτηρισμός (Characterization)

Στόχος της πρόβλεψης είναι να υπολογίσει, με όσο το δυνατόν μεγαλύτερη ακρίβεια την εξέλιξη του συστήματος για μικρή χρονική διάρκεια, δηλαδή ουσιαστικά να υπολογίσει τις μελλοντικές τιμές της μεταβλητής της χρονοσειράς.

Στόχος της μοντελοποίησης είναι να 'κατανοήσει' τη συμπεριφορά και τις χαρακτηριστικές ιδιότητες του συστήματος, για μεγάλη χρονική διάρκεια, μέσω της διαδοχής των μετρήσεων.

Στόχος του χαρακτηρισμού του συστήματος είναι ο καθορισμός κάποιων θεμελιωδών ιδιοτήτων του συστήματος.

1.3 ΠΡΟΒΛΕΨΗ ΧΡΟΝΟΣΕΙΡΑΣ

Ορισμός πρόβλεψης χρονοσειράς (timeseries prediction) : Μέθοδος απεικόνισης παρελθοντικών σημείων της χρονοσειράς σε μελλοντικά.

Η μέθοδος βασίζεται στην υπόθεση ότι η μεταβολή της τιμής του μεγέθους ακολουθεί ένα συγκεκριμένο πρότυπο ("λανθάνον πρότυπο") που επαναλαμβάνεται στο χρόνο και παραμένει σταθερό.

Βασικός στόχος αυτής της μεθόδου είναι η αναγνώριση του ακολουθούμενου προτύπου των ιστορικών δεδομένων και η προέκταση του στο μέλλον.

Με μια έννοια, το μοντέλο χρονοσειρών θεωρείται σαν ένα "μαύρο κουτί" (black box) που δεν κάνει καμία προσπάθεια να ανακαλύψει τους συντελεστές που επηρεάζουν τη συμπεριφορά του.

Η παραστατική μορφή του μοντέλου χρονοσειρών δίνεται στο παρακάτω σχήμα:



Σχήμα 1.1 Μπλοκ διάγραμμα μοντέλου χρονοσειρών

Είσοδος του μοντέλου είναι παρελθοντικές τιμές X_i μέχρι τη χρονική στιγμή $x = t$ και έξοδος Y είναι η πρόβλεψη της μελλοντικής τιμής τη χρονική στιγμή $x = t+P$. Η βασική μέθοδος για τον τύπο αυτό πρόβλεψης είναι η δημιουργία μιας απεικόνισης από D σημεία της χρονοσειράς που απέχουν κατά Δ μονάδες μεταξύ τους, π.χ. $x(t-(D-1)\Delta), \dots, x(t-\Delta), x(t)$ προκειμένου να επιτευχθεί πρόβλεψη της μελλοντικής τιμής $x(t+P)$.

1.3.1 Γενική μεθοδολογία πρόβλεψης με χρονοσειρά

Γενικά η προβλεπόμενη τιμή μιας μεταβλητής σε μια μελλοντική χρονική στιγμή, στηρίζεται σε m προηγούμενες τιμές. Το m καλείται καθυστέρηση της πρόβλεψης (lag of prediction). Αν έχουμε τις τιμές της μεταβλητής x για τις χρονικές στιγμές $k-m$ έως $k-1$, δηλαδή, $x(k-1), x(k-2), \dots, x(k-m)$, μπορούμε να προβλέψουμε το $x(k)$, καθώς και τις επόμενες τιμές $x(k+1), \dots, x(k+p)$.

Η μεθοδολογία που χρησιμοποιείται για να δημιουργηθεί ένας predictor είναι η εξής:

1. Προεπεξεργασία των δεδομένων.
2. Απόφαση των m τιμών lag.
3. Διαχωρισμός των δεδομένων παρατήρησης σε δεδομένα εκπαίδευσης και δεδομένα δοκιμής (ελέγχου).
4. Δημιουργία τοπικού (local) ή ολικού (global) predictor βασισμένου σε αρχιτεκτονικές όπως fourier gray models, προσαρμογή πολυωνύμου, μοντέλα ασαφούς λογικής, νευρωνικά δίκτυα.
5. Αρχικοποίηση των αρχικών βαρών του predictor σε μηδενικές τιμές.
6. Χρήση των δεδομένων εκπαίδευσης για εκπαίδευση του predictor. Η εκπαίδευση λειτουργεί ως εξής: τη χρονική στιγμή k , εφαρμογή των $x(k-1)$, $x(k-2)$, ..., $x(k-m)$ στον predictor. Παίρνουμε την έξοδο του predictor $x(k+p)$. Υπολογίζουμε τα σφάλματα εξόδου (με χρήση κάποιων κριτηρίων) και αλλαγή των τιμών των βαρών του predictor ανάλογα με τον αλγόριθμο εκπαίδευσης που χρησιμοποιείται (learning algorithm) (π.χ. Back Propagation, Genetic Algorithms).
7. Υπολογισμός της απόδοσης του εκπαιδευμένου predictor με τα δεδομένα ελέγχου.

1.3.2 Πλεονεκτήματα μοντέλου χρονοσειρών για πρόβλεψη

Υπάρχουν τρία βασικά πλεονεκτήματα της θεώρησης του “μαύρου κουτιού” που αποτελούν και τους βασικούς λόγους της συχνότατης επιλογής του μοντέλου των χρονοσειρών:

1. Δεν υπάρχει πάντα η δυνατότητα να συσχετίσουμε ένα μεταβαλλόμενο μέγεθος με κάποιους παράγοντες και πολύ περισσότερο να προσδιορίσουμε τον τρόπο αλληλεπίδρασής τους.
2. Σε πολλές περιπτώσεις ενδιαφερόμαστε να προσδιορίσουμε μόνο το τι θα συμβεί και όχι το γιατί.
3. Το κόστος που απαιτείται στην περίπτωση αυτή είναι πολύ μικρότερο σε σχέση με άλλες κατηγορίες μοντέλων (όπως το επεξηγηματικό).

1.4 ΚΑΝΟΝΙΚΟΠΟΙΗΣΗ ΤΩΝ ΧΡΟΝΟΣΕΙΡΩΝ

Μια από τις συχνά χρησιμοποιούμενες μεθόδους προεπεξεργασίας δεδομένων αποτελεί η κανονικοποίηση τους. Κανονικοποιώντας τα δεδομένα επιτυγχάνεται ουσιαστικά εξομάλυνση της χρονοσειράς, καθώς οι τιμές που έχουν πλέον τα δεδομένα περικλείονται σε ένα συγκεκριμένο εύρος τιμών προκαθορισμένο και μικρότερο από το πραγματικό. Είναι επίσης χαρακτηριστικό να σημειωθεί ότι η εκπαίδευση των νευρωνικών δικτύων, που ουσιαστικά αποτελούν τα συστήματα στα οποία οι χρονοσειρές θα χρησιμοποιηθούν στη συνέχεια σαν πρότυπα εκπαίδευσης, μπορεί να γίνει πιο αποτελεσματική, με χρήση κανονικοποιημένων δεδομένων. Οι πιο συχνά χρησιμοποιούμενες κανονικοποιήσεις είναι: ο μετασχηματισμός των δεδομένων ώστε να έχουν μέση τιμή μηδενική και τυπική απόκλιση μοναδιαία, καθώς και η αντιστοίχιση των δεδομένων σε ένα μικρό εύρος τιμών, π.χ. κανονικοποίηση 0.1 έως 0.9 όπου η ελάχιστη τιμή των πραγματικών δεδομένων αντιστοιχεί στο 0.1 και η μέγιστη στο 0.9.

1.5 ΣΥΝΑΡΤΗΣΗ ΑΥΤΟΣΥΣΧΕΤΙΣΗΣ (Autocorrelation Function)

Η συνάρτηση αυτοσυσχέτισης είναι ένα μαθηματικό εργαλείο που χρησιμοποιείται στην ανάλυση των χρονοσειρών, και δείχνει τη συσχέτιση μιας συνάρτησης με τον εαυτό της, για διαδοχικά χρονικά διαστήματα. Αποτελεί έναν τρόπο ανίχνευσης της περιοδικότητας ενός σήματος. Ο τύπος υπολογισμού της είναι ο παρακάτω:

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{i=1}^n (Y_t - \bar{Y})^2}$$

όπου r_k η αυτοσυσχέτιση με καθυστέρηση k (lag), Y_t η τιμή της συνάρτησης τη χρονική στιγμή t , \bar{Y} η μέση τιμή της συνάρτησης και Y_{t-k} η τιμή της συνάρτησης Y τη χρονική στιγμή $t-k$.

Η συνάρτηση αυτοσυσχέτισης ουσιαστικά δείχνει τη σχέση εξάρτησης των επόμενων τιμών μιας συνάρτησης από τις προηγούμενες. Όσο μεγαλύτερες τιμές παίρνει η αυτοσυσχέτιση τόσο πιο μεγάλη εξάρτηση υπάρχει μεταξύ διαδοχικών τιμών της συνάρτησης.

ΚΕΦΑΛΑΙΟ

2

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ (Neural Networks)

2.1 Ιστορική αναδρομή

Η πρώτη ουσιαστική δημοσίευση πάνω στο τομέα των νευρωνικών δικτύων έγινε το 1943, από τους McCulloch και Pitts, οι οποίοι κατάφεραν την πρώτη λογική ανάλυση των νευρωνικών δικτύων, που συνέδεε τις επιστήμες την νευροφυσιολογίας και της μαθηματικής λογικής. Ορίζοντας το μοντέλο του νευρώνα, οι δύο επιστήμονες απέδειξαν ότι με τη χρήση νευρώνων και συναπτικών συνδέσεων, σε ταυτόχρονη λειτουργία, θα μπορούσε να υπολογιστεί οποιαδήποτε υπολογιστική συνάρτηση. Αυτό ήταν ένα πολύ σημαντικό αποτέλεσμα, στο οποίο ουσιαστικά στηρίχτηκαν οι έννοιες των νευρωνικών δικτύων και της τεχνητής νοημοσύνης.

Στη συνέχεια ακολούθησε το 1949 το βιβλίο του Hebb, όπου παρουσιάστηκε ένας κανόνας εκμάθησης των συναπτικών βαρών, με βάση τη θεώρηση ότι ο οργανισμός "μαθαίνει" αυξάνοντας την αποτελεσματικότητα των συνάψεων που συνδέουν επανηλειμένως ενεργοποιημένους νευρώνες. Το 1958 ο Rosenblatt παρουσίασε το perceptron, μία καινοτόμο μέθοδο μάθησης με εποπτεία (supervised learning). Το 1960, οι Widrow και Hoff παρουσίασαν τον αλγόριθμο ελαχιστοποίησης του μέσου τετραγωνικού σφάλματος. Το 1970, παρουσιάστηκε η έννοια του αυτο-οργανωνόμενου χάρτη (self-organizing map), με χρήση ανταγωνιστικής (competitive) μάθησης. Μέσα στο 1982, ο Hopfield χρησιμοποίησε την ιδέα της συνάρτησης ενέργειας (energy function), για την κατανόηση της λειτουργίας των επαναλαμβανόμενων δικτύων (recurrent networks), ενώ τη ίδια περίοδο έγινε η δημοσίευση του Kohonen πάνω στους αυτο-οργανωνόμενους χάρτες (Kohonen's self-organizing maps), που ήταν πρωτοποριακή. Το 1986 σημαδεύτηκε από την ανάπτυξη του αλγορίθμου εκπαίδευσης με οπισθοχώρηση (Backpropagation algorithm) από τους Rumelhart, Hinton και Williams. Ακολούθησαν πολλές ακόμα δημοσιεύσεις αλλά αυτές του Hopfield το 1982 και του Rumelhart το 1986 ήταν οι πιο καθοριστικές για την μεταγενέστερη εξέλιξη του τομέα των νευρωνικών δικτύων.

2.2 ΒΙΟΛΟΓΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

2.2.1 Ο ανθρώπινος εγκέφαλος σαν σύστημα επεξεργασίας πληροφοριών

Το ανθρώπινο νευρικό σύστημα μπορεί να προσεγγιστεί σαν ένα τριεπίπεδο σύστημα. Πυρήνας του συστήματος είναι ο εγκέφαλος, που δέχεται αδιάλειπτα πληροφορίες, τις αντιλαμβάνεται και παίρνει τις απαραίτητες αποφάσεις. Παρακάτω παρατίθεται ένα μπλοκ διάγραμμα που απεικονίζει το προαναφερθέν σύστημα.



Σχήμα 2.1: Διάγραμμα προσέγγισης εγκεφάλου σαν τριεπίπεδο σύστημα



Στο διάγραμμα παρουσιάζονται δύο είδη από βελάκια. Αυτά που έχουν φορά από αριστερά προς δεξιά και δείχνουν την εμπρόσθια κίνηση των σημάτων που περιέχουν τα δεδομένα διαμέσου του συστήματος και τα βέλη με αντίθετη φορά που δείχνουν την παρουσία ανάδρασης στο σύστημα. Οι υποδοχείς μετατρέπουν τα ερεθίσματα από το ανθρώπινο σώμα ή το εξωτερικό περιβάλλον σε ηλεκτρικούς παλμούς, που παρέχουν πληροφορίες στο σύστημα. Οι μετατροπείς είναι οι δέκτες των ηλεκτρικών σημάτων, που παράγονται από τον εγκέφαλο, που στη συνέχεια τα μετατρέπουν σε διακριτές αποκρίσεις, που αποτελούν τις εξόδους του συστήματος.

Η προσπάθεια κατανόησης της λειτουργίας του εγκεφάλου σημαδεύτηκε από την πρωτοποριακή δουλειά του Ramon Cajal(1911), που παρουσίασε την ιδέα των νευρώνων, σαν στοιχειωδών μονάδων του εγκεφάλου. Ο ανθρώπινος εγκέφαλος αποτελείται από περίπου 10 δισεκατομμύρια νευρικά κύτταρα ή νευρώνες. Ένας νεύρωνας συνδέεται με άλλους νευρώνες, με κατά μέσο όρο περίπου 10.000 συνάψεις. Το δίκτυο νευρώνων του εγκεφάλου αποτελεί ένα ευρέως παράλληλο επεξεργαστικό σύστημα πληροφοριών. Αυτό έρχεται σε αντιδιαστολή με τους σύγχρονους συμβατικούς υπολογιστές, όπου ένας επεξεργαστής εκτελεί σειριακά μια μοναδική αλληλουχία εντολών.

Τυπικά, οι νευρώνες είναι πέντε με έξι φορές πιο αργοί από τις λογικές πύλες πυριτίου (τρανζίστορς), π.χ. εφαρμογές που στη πλακέτα πυριτίου τρέχουν σε ένα νανοδευτερόλεπτο(10^{-9} seconds), στο νευρώνα τρέχουν σε ένα χιλιοστό του δευτερο-

λέπτου(10^{-3} seconds). Ο σχετικά αργός αυτός ρυθμός λειτουργίας τους αντισταθμίζεται από τον πολύ μεγάλο αριθμό νευρώνων και των μεταξύ τους συνδέσεων.


Πίνακας 2.1: Σύγκριση του μοντέλου λειτουργίας του εγκεφάλου με ένα συμβατικό υπολογιστή

	Επεξεργαστικά στοιχεία	Μέγεθος στοιχείων	Ισχύς	Ταχύτητα επεξεργασίας	Τρόπος υπολογισμού	Ανθεκτικός σε λάθη
	10^{14} Νευρώνες	10^{-6} m	30W	100 Hz	Παράλληλος Κατανεμημένος	Ναι
	10^8 Τρανζίστορες	10^{-6} m	30W	10^9 Hz	Σειριακός Συγκεντρωτικός	Όχι

2.2.2 Βιολογικός Νευρώνας

Η βασική μονάδα επεξεργασίας του νευρικού συστήματος είναι το νευρικό κύτταρο ή νευρώνας. Ο νευρώνας αποτελείται από τα εξής δομικά στοιχεία:

1. Δενδρίτες (Dendrites). Αποτελούν τις εισόδους του νευρώνα.
2. Σώμα του κυττάρου (Cell body). Αποτελεί το μέρος όπου γίνεται η επεξεργασία των σημάτων-εισόδων.
3. Άξονας (Axon). Αποτελεί την έξοδο του νευρώνα.



Σχήμα 2.2: Βιολογικός νευρώνας

Ένας νευρώνας δέχεται είσοδο από άλλους νευρώνες (τυπικά αρκετές χιλιάδες), μέσω των δενδριτών. Οι εισοδοί αθροίζονται και αν το άθροισμα ξεπεράσει μια συγκεκριμένη “κρίσιμη” τιμή, ο νευρώνας απελευθερώνει ένα ηλεκτρικό παλμό, που διαπερνάει το σώμα του κυττάρου και τον άξονα, και τελικά μεταδίδεται στους επόμενους νευρώνες. Η διαδικασία αυτή ονομάζεται αποφόρτιση και ακολουθείται

από μια περίοδο αδράνειας, κατά την οποία ο νευρώνας είναι ανίκανος να λειτουργήσει.

Οι καταλήξεις του άξονα (axon endings) σχεδόν αγγίζουν τους δενδρίτες του επόμενου νευρώνα. Η μετάδοση του ηλεκτρικού παλμού από τον ένα νευρώνα στον επόμενο, επιτυγχάνεται με τους νευρικούς πομπούς (neurotransmitters), χημικές ουσίες που απελευθερώνονται από τον πρώτο νευρώνα και δεσμεύονται από τους υποδοχείς του επόμενου. Η σύζευξη αυτή ονομάζεται σύναψη. Η μετάβαση του σήματος από τον ένα νευρώνα στον επόμενο εξαρτάται από παράγοντες όπως η διαθεσιμότητα νευρικών πομπών, ο αριθμός και η διάταξη των υποδοχέων.

2.2.3 Εκμάθηση συνάψεων

Ο εγκέφαλος έχει τη δυνατότητα να μαθαίνει ως γνωστόν. Με βάση τις δομές των νευρώνων, ένας τρόπος μάθησης είναι η εναλλαγή της ισχύος των συνδέσεων μεταξύ των νευρώνων (των βαρών των συνδέσεων), καθώς και η αύξηση ή μείωση του αριθμού των συνδέσεων μεταξύ των νευρώνων. Επιπλέον, έχει την ικανότητα για άμεση (online) μάθηση, που βασίζεται στην εμπειρία. Η ισχύς μιας σύναψης μπορεί να μεταβληθεί ανάλογα με την εμπειρία, εξασφαλίζοντας μνήμη και εκμάθηση μέσω της μακροχρόνιας εξέλιξής της. Ένας τρόπος μεταβολής της είναι απελευθερώνοντας περισσότερους νευρικούς πομπούς.

Αξίωμα Hebb: «Όταν ένας άξονας ενός κυττάρου *A* διεγείρει ένα κύτταρο *B*, και επαναλαμβανόμενα και εξακολουθητικά παίρνει μέρος στην ενεργοποίησή του, κάποια διαδικασία εξέλιξης ή αλλαγή του μεταβολισμού λαμβάνει χώρα σε ένα από τα δύο ή και στα δύο κύτταρα, έτσι ώστε η αποτελεσματικότητα του *A* στην ενεργοποίηση του *B* να αυξάνεται».

2.3 ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

2.3.1 Ορισμός

Το νευρωνικό δίκτυο είναι ένας επεξεργαστής κατανεμημένης παράλληλης αρχιτεκτονικής, που αποτελείται από απλές επεξεργαστικές μονάδες, οι οποίες έχουν μια φυσική τάση να αποθηκεύουν εμπειρική γνώση και να την κανουν κατάλληλη για χρήση. Μοιάζει στον εγκέφαλο σε δύο τομείς:

1. Η γνώση αποκτάται από το δίκτυο, από το περιβάλλον του, μέσω μιας διαδικασίας μάθησης.
2. Η ισχύς των διανευρωνικών συνδέσεων, γνωστή ως συναπτικό βάρος, χρησιμοποιείται για αποθήκευση της αποκτημένης γνώσης.

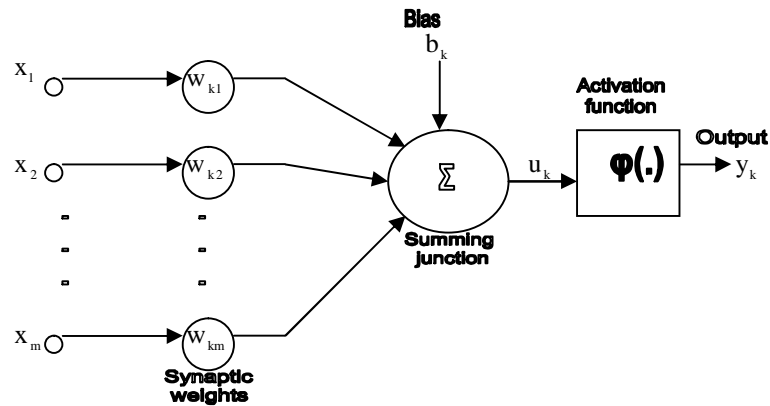
Το νευρωνικό δίκτυο μπορεί πιο γενικά να περιγραφεί σαν μια μηχανή που σχεδιάζεται για να μοντελοποιεί τον τρόπο, με τον οποίο ο εγκέφαλος εκτελεί μια συγκεκριμένη λειτουργία, που μας ενδιαφέρει. Το δίκτυο είναι συνήθως υλοποιημένο με χρήση ηλεκτρονικών στοιχείων ή προσομοιώνεται με χρήση λογισμικού σε ψηφιακό υπολογιστή.

Τα νευρωνικά δίκτυα γενικά προσδιορίζονται από την αρχιτεκτονική τους (τοπολογία) και τη διαδικασία εκπαίδευσής τους. Σχεδιάζονται και εκπαιδεύονται για να επιτελέσουν πολύπλοκες λειτουργίες σε διαφορετικούς τομείς εφαρμογών.

- Αναγνώριση προτύπων
- Αναγνώριση δυναμικών συστημάτων
- Ταξινόμηση δεδομένων
- Μηχανική οραση
- Εφαρμογές φωνής
- Συστήματα αυτομάτου ελέγχου
- Ανάλυση χρονοσειρών
- Πρόβλεψη

2.3.2 Μοντέλο νευρώνα

Νευρώνας είναι μια στοιχειώδης επεξεργαστική μονάδα που είναι θεμελιώδης για τη λειτουργία ενός νευρωνικού δικτύου. Ο νευρώνας μπορεί να είναι γραμμικός ή μη γραμμικός. Κάθε νευρώνας δέχεται σήματα εισόδου από τις εξόδους των νευρώνων του προηγούμενου επιπέδου, υπολογίζει το σταθμισμένο άθροισμα όλων των σημάτων εισόδου και το σήμα αυτό περνά μέσα από μια συνάρτηση ενεργοποίησης (activation function), το αποτέλεσμα της οποίας αποτελεί είσοδο στους νευρώνες του επόμενου επιπέδου. Τα σήματα σε ένα νευρώνα σταθμίζονται με ένα συντελεστή βάρους. Παρακάτω παρατίθεται το μπλοκ διάγραμμα του μοντέλου ενός μη γραμμικού νευρώνα.



Σχήμα 2.3:Μπλόκ διάγραμμα του νευρώνα

Στο παραπάνω διάγραμμα ξεχωρίζουμε τρία βασικά στοιχεία του νευρωνικού μοντέλου:

1. Ένα σύνολο συνάψεων που η καθεμιά χαρακτηρίζεται από το αντίστοιχο συναπτικό βάρος της. Πιο συγκεκριμένα ένα σήμα x_j που βρίσκεται στην είσοδο της σύναψης j και είναι συνδεδεμένο με το νευρώνα k , πολλαπλασιάζεται με το συναπτικό βάρος w_{kj} .
2. Έναν αθροιστή για πρόσθεση των σημάτων εισόδου που είναι πολλαπλασιασμένα με τα αντίστοιχα συναπτικά βάρη.
3. Μια συνάρτηση ενεργοποίησης για περιορισμό του πλάτους εξόδου του νευρώνα.

Το μοντέλο νευρωνικού επίσης περιλαμβάνει μια εξωτερική του συστήματος μεταβλητή που συνήθως είναι σταθερός όρος και ονομάζεται συναπτικό βάρος του νευρώνα (bias). Το bias αυξάνει ή μειώνει την είσοδο την συνάρτησης ενεργοποίησης ανάλογα αν είναι θετικό ή αρνητικό.

Με μαθηματικούς όρους ο νευρώνας k μπορεί να περιγραφεί από τις εξής εξισώσεις:

$$u_k = \sum_{j=1}^m w_{kj} x_j$$

και

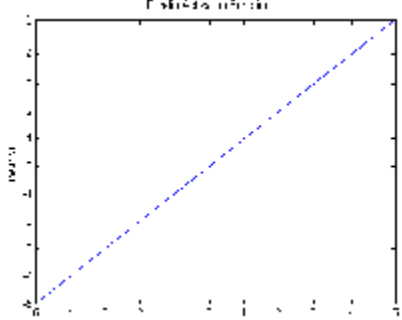
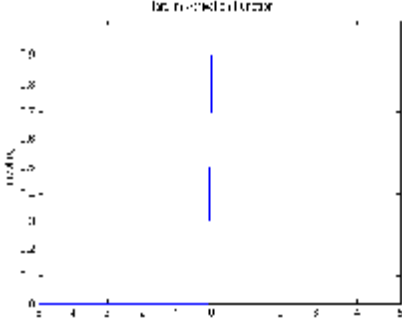
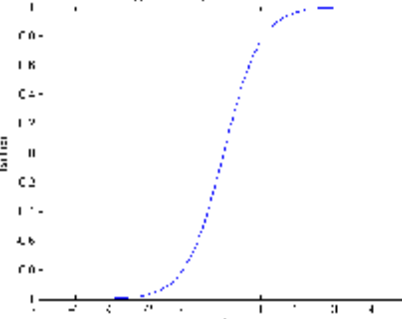
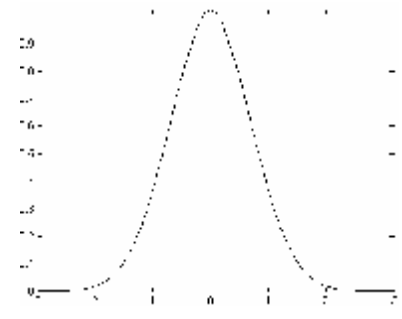
$$y_k = \phi(u_k + b_k)$$

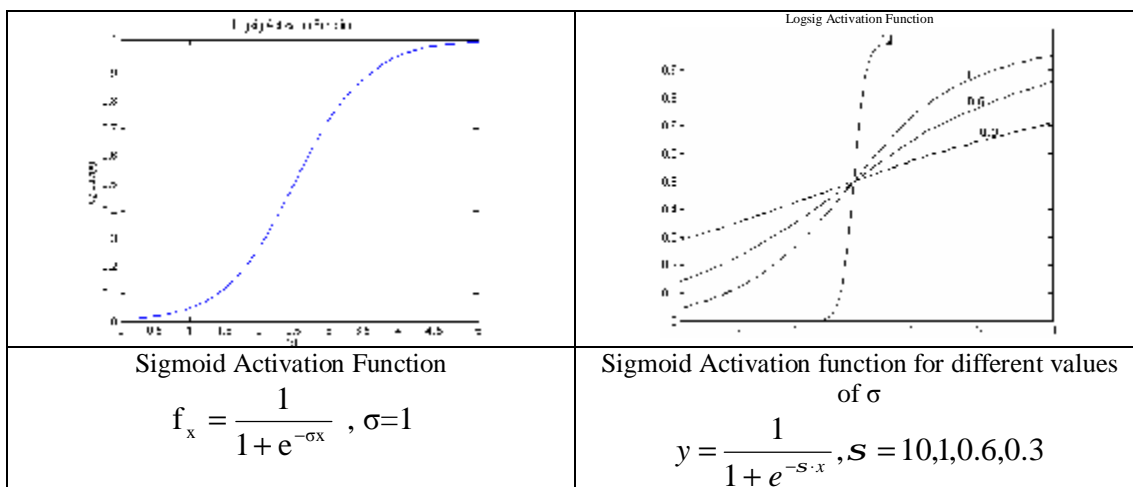
όπου X_1, X_2, \dots, X_m είναι τα σήματα εισόδου, W_1, W_2, \dots, W_{km} είναι τα συναπτικά βάρη του νευρώνα k , u_k είναι η έξοδος του αθροιστή, b_k είναι το bias, $\phi(\cdot)$ είναι η συνάρτηση ενεργοποίησης και y_k η έξοδος του νευρώνα.

2.3.3 Συναρτήσεις ενεργοποίησης(Activation functions)

Η συνάρτηση ενεργοποίησης που συμβολίζεται με $\phi(u)$, ορίζει την έξοδο του νευρώνα σε σχέση με την τιμή της εξόδου του αθροιστή u .

Παρακάτω παρατίθενται μερικές από τις πιο συχνά χρησιμοποιούμενες συναρτήσεις ενεργοποίησης.

	
<p>Linear Activation Function. $f_x = x$</p>	<p>Hardlim Activation Function $y = 1, x \geq 0$ $y = 0, x < 0$</p>
	
<p>Hyperbolic tangent Activation Function $f_x = \frac{e^x - e^{-x}}{e^x + e^{-x}}$</p>	<p>Radial Activation Function $f_x = e^{-x^2}$</p>



Σχήμα 2.4: Συναρτήσεις ενεργοποίησης των νευρωνικών δικτύων

2.3.4 Αρχιτεκτονικές δικτύων(Network architectures)

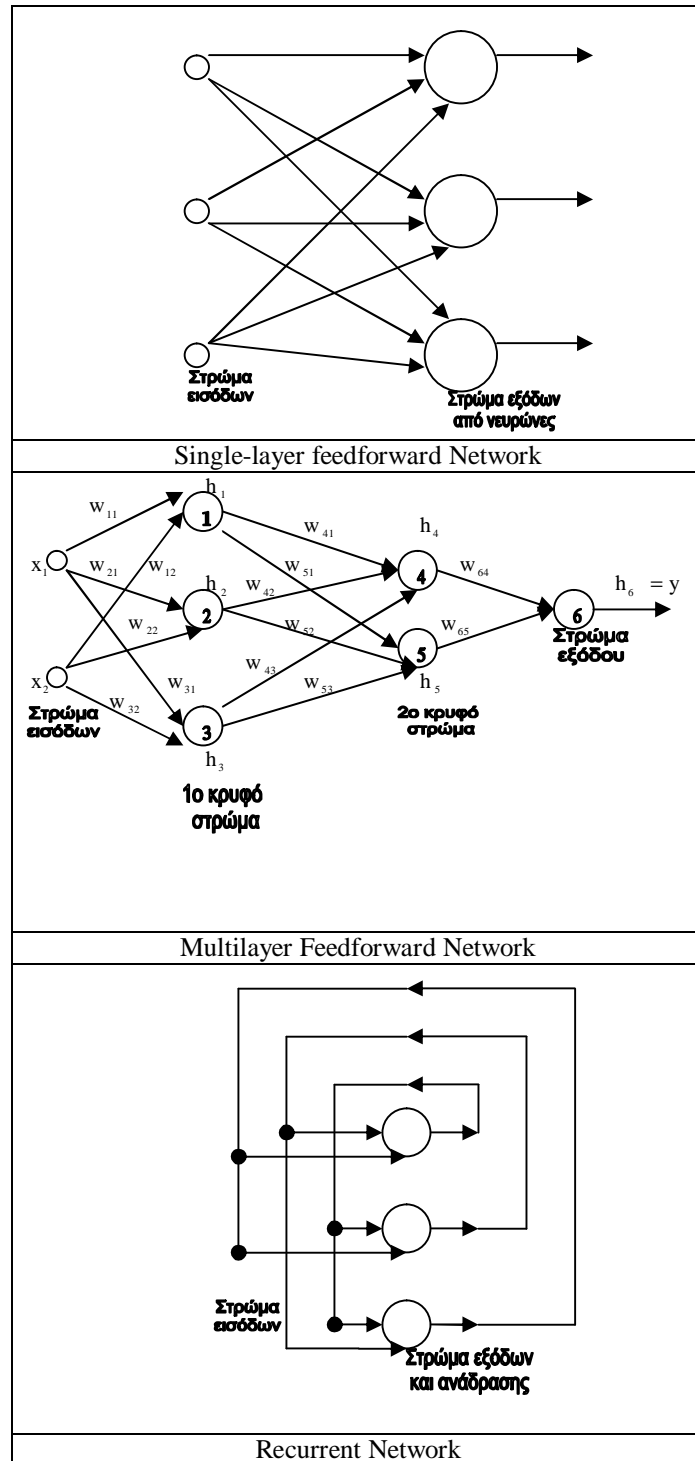
Οι αρχιτεκτονικές δικτύων είναι αλληλένδετες με τους αλγορίθμους εκμάθησης που χρησιμοποιούνται για τα δίκτυα.

Οι αρχιτεκτονικές των νευρωνικών δικτύων μπορούν να διαχωριστούν σε τρεις κύριες κατηγορίες:

1. Τα Μονοστρωματικά Νευρωνικά Δίκτυα Εμπρόσθιας Τροφοδότησης (Single-layer feedforward Networks). Στη περίπτωση αυτή έχουμε ένα στρώμα εισόδου που αποτελείται από τις εισόδους του νευρωνικού και συνδέεται με ένα στρώμα εξόδου αποτελούμενο από νευρώνες (υπολογιστικοί κόμβοι). Η μετακίνηση δεδομένων γίνεται μόνο προς τα εμπρός και δεν υφίσταται ανάδραση.
2. Τα Πολυστρωματικά Νευρωνικά Δίκτυα Εμπρόσθιας Τροφοδότησης (Multilayer Feedforward Networks). Στην περίπτωση αυτή δικτύων μεταξύ του στρώματος εισόδων και του στρώματος εξόδων παρεμβάλεται ένα ή περισσότερα ενδιάμεσα στρώματα, τα επονομαζόμενα κρυφά στρώματα (hidden layers), τα οποία αποτελούνται από νευρώνες. Με τη χρήση των κρυφών στρωμάτων επιτυγχάνεται μεγαλύτερος βαθμός επεξεργασίας των δεδομένων. Συνήθως κάθε κόμβος ενός στρώματος είναι συνδεδεμένος με καθέναν από τους κόμβους του στρώματος που ακολουθεί. Σε αυτή την περίπτωση το νευρωνικό δίκτυο ονομάζεται πλήρως συνδεδεμένο (fully connected). Υπάρχουν περιπτώσεις δικτύων όπου λείπουν

κάποιες συναπτικές ενώσεις, οπότε το δίκτυο ονομάζεται μερικώς συνδεδεμένο (partially connected).

3. Επαναλαμβανόμενα Νευρωνικά Δίκτυα (Recurrent Networks). Τα νευρωνικά δίκτυα που ανήκουν στη συγκεκριμένη κατηγορία διαφέρουν από τα νευρωνικά δίκτυα εμπρόσθιας μετάδοσης από το γεγονός ότι έχουν τουλάχιστον μια ανάδραση.

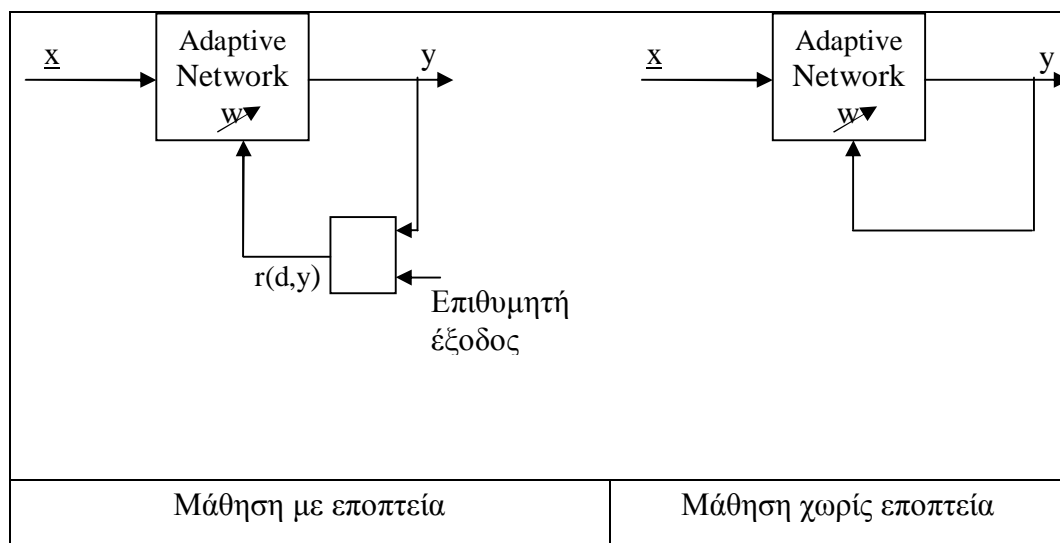


Σχήμα 2.5: Αρχιτεκτονικές νευρωνικών δικτύων

2.3.5 Κανόνες μάθησης

Μάθηση είναι η διαδικασία προσαρμογής των βαρών του νευρωνικού δικτύου για να παράγει αυτό, το επιθυμητό διάνυσμα εξόδου, σε απόκριση στο διάνυσμα εισόδου. Οι κανόνες μάθησης ενός νευρωνικού δικτύου δεικνύουν πώς τα βάρη ρυθμίζονται εφαρμόζοντας ένα παράδειγμα μάθησης. Οι κανόνες μάθησης χωρίζονται σε δύο κατηγορίες:

1. Μάθηση με εποπτεία ή επίβλεψη (Supervised Learning): Υπάρχει ουσιαστικά ένα σύνολο ζευγών τιμών εισόδου-εξόδου, σύμφωνα με τα οποία εκπαιδεύεται το δίκτυο, και στη συνέχεια μπορεί να δοκιμαστεί για επαλήθευση της καλής λειτουργίας του.
2. Μάθηση χωρίς εποπτεία (Unsupervised Learning), όπου δεν υπάρχει εξωτερική γνώση, αλλά η απόκριση βασίζεται στην ικανότητα των δικτύων να αυτοοργανώνονται εσωτερικά.



Κανόνες μάθησης:

1. Hebbian Rule (Unsupervised Learning)

$$W_{k+1} = W_k + bxy$$

W_{k+1} : Τιμή του βάρους κατά τον επόμενο κύκλο μάθησης.

x : Είσοδος

y : Έξοδος

b : Ρυθμός μάθησης

Ο Hebbian Rule απαιτεί τα βάρη να έχουν αρχικές τιμές κοντά στο μηδέν πριν την μάθηση.

2. Delta Learning Rule (Supervised Learning)

Ο κανόνας αυτός είναι εφαρμόσιμος μόνον όταν η συνάρτηση ενεργοποίησης είναι διαφορίσιμη. Για την λειτουργία αυτού του κανόνα, χρησιμοποιείται η μέθοδος ελαχιστοποίησης του μέσου τετραγωνικού σφάλματος. Το σήμα εκπαίδευσης είναι η διαφορά μεταξύ της επιθυμητής και της πραγματικής απόκρισης του νευρώνα. Ορίζουμε τη συνάρτηση τετραγωνικού σφάλματος ως εξής:

$$E = \frac{1}{2}(d_i - y_i)^2$$

Το σήμα εκπαίδευσης δίνεται από τον παρακάτω τύπο:

$$r_i = [d_i - f_i(w_i^T x)] \cdot (f_i(w_i^T x))$$

Ο κανόνας εκπαίδευσης μπορεί εύκολα να προκύψει από την συνθήκη των ελαχίστων τετραγώνων μεταξύ y_i και d_i .

$$E = \frac{1}{2}(d_i - y_i)^2 \quad \text{α} \quad E = \frac{1}{2}[d_i - f_i(w_i^T x)]^2$$

$$E = - (d_i - y_i) \cdot (f_i(w_i^T x) \cdot x)$$

$$\Delta w_i = -nE$$

Οπότε :

$$\Delta w_i = n(d_i - y_i) \cdot (f(s_i) \cdot x)$$

3. Widrow – Hoff Learning Rule

Ο κανόνας εκπαίδευσης Widrow – Hoff θεωρείται μια ειδική περίπτωση του κανόνα Delta. Η μόνη διαφορά τους είναι ότι η έξοδος της συνάρτησης ενεργοποίησης είναι ίδια με την είσοδο. Για το λόγο αυτό η εκπαίδευση του δικτύου είναι ανεξάρτητη της συνάρτησης ενεργοποίησης.

Το σήμα εκπαίδευσης ισούται με:


$$r_i = d_i - s_i = d_i - w_i^T x$$

Η αναπροσαρμογή των βαρών δίνεται από το τύπο:

$$\Delta w_i = \gamma \cdot (d_i - s_i) \cdot \underline{x}$$

2.3.6 Κανόνες εκπαίδευσης νευρωνικών δικτύων

2.3.6.1 Κανόνας εκπαίδευσης νευρώνα



Σχήμα 2.6: Μοντέλο απεικόνισης του ith νευρώνα

Γενικός κανόνας εκπαίδευσης του ith νευρώνα: Το διάνυσμα των βαρών \underline{w}_i αυξάνει με το γινόμενο των εισόδων \underline{x} και του σήματος εκπαίδευσης r_i . Το σήμα r_i είναι γενικά μία συνάρτηση των w_i, \underline{x} και μερικές φορές των επιθυμητών σημάτων d_i .

$$r_i = r_i(\underline{w}_i^{(t)}, \underline{x}, d_i^{(t)})$$

Η αύξηση των βαρών δίνεται από την εξίσωση

$$\Delta w_i(t) = \gamma \cdot r_i[\underline{w}_i(t), \underline{x}(t), d_i(t)] \cdot \underline{x}(t)$$

γ : θετικός αριθμός που ονομάζεται σταθερά εκπαίδευσης και καθορίζει το ρυθμό εκπαίδευσης

$$\underline{w}_i(t+1) = \underline{w}_i(t) + \gamma \cdot r_i[\underline{w}_i(t), \underline{x}(t), d_i(t)] \cdot \underline{x}(t)$$

ή

$$\underline{w}_i(k+1) = \underline{w}_i(k) + \gamma \cdot r_i[\underline{w}_i(k), \underline{x}(k), d_i(k)] \cdot \underline{x}(k) \quad k=1,2,\dots$$

διακριτού χρόνου


$$\frac{d\underline{w}(t)}{dt} = g \cdot r_i[\underline{w}_i(t), \underline{x}(t), d(t)] \cdot \underline{x}(t),$$

συνεχούς χρόνου.

2.3.6.2 Εκπαίδευση μονοστρωματικών νευρωνικών δικτύων

Perceptron

Το perceptron δημιουργήθηκε με βάση το μοντέλο του μη γραμμικού νευρώνα, από τον Rosenblatt το 1958. Το νευρωνικό αυτό δίκτυο είναι μονοστρωματικό και σαν συνάρτηση ενεργοποίησης χρησιμοποιεί τη hardlim, η οποία για θετική είσοδο παίρνει τιμή 1 και για αρνητική -1. Παρακάτω δίνεται το μοντέλο του perceptron, που αποτελείται από τρεις εισόδους x_1, x_2, x_3 , τα αντίστοιχα βάρη τους w_{i1}, w_{i2}, w_{i3} , το bias, τη συνάρτηση ενεργοποίησης που είναι η προαναφερθείσα και την έξοδο y_i .



Σχήμα 2.7: Perceptron

Το perceptron ανήκει στη κατηγορία της μάθησης με εποπτεία, και χρησιμοποιείται κυρίως για περιπτώσεις προβλημάτων ταξινόμησης προτύπων (pattern classification). Ένα άλλο σπουδαίο χαρακτηριστικό του, είναι ότι αν στο πρόβλημα που καλείται να λύσει, υπάρχει λύση, δηλαδή ένα σύνολο βαρών, που να δίνουν τη λύση, τότε το perceptron σίγουρα θα βρει τις τιμές των βαρών. Ο αλγόριθμος εκπαίδευσης των βαρών του είναι ο εξής: Έχοντας αρχικοποιήσει τα βάρη σε μηδέν, και εφαρμόζοντας είσοδο \underline{x} στο νευρώνα προκύπτει το ακόλουθο σήμα εκπαίδευσης :

$$r_i = d_i - y_i$$

και η έξοδος του νευρωνικού ισούται με:

$$y_i = \text{sgn}(s_i) = \text{sgn}(w_i^T \underline{x})$$

οπότε η διαφορά του επόμενου βάρους από το παρόν είναι ίση με:

$$\Delta w_i = \gamma \cdot [d_i - \text{sgn}(w_i^T \underline{x})] \cdot \underline{x}$$


2.3.6.3 Εκπαίδευση πολυστρωματικών νευρωνικών δικτύων

Τα πολυστρωματικά νευρωνικά δίκτυα, όπως προαναφέρθηκε, αποτελούνται από τις εξής δομικές μονάδες: στρώμα εισόδου (input layer), ένα ή περισσότερα ενδιάμεσα στρώματα (hidden layers), ένα στρώμα εξόδου, τα οποία αποτελούνται από νευρώνες. Σε αυτό τον τύπο δικτύου εντοπίζονται δύο είδη σημάτων: τα σήματα συνάρτησης και τα σήματα σφάλματος.

Το σήμα συνάρτησης είναι ένα σήμα εισόδου, που διαδίδεται μέσα στο δίκτυο με κατεύθυνση προς τα εμπρός, συμβατικά, από τα αριστερά προς τα δεξιά, από στρώμα σε στρώμα και καταλήγει στην έξοδο του δικτύου σαν ένα σήμα εξόδου. Ονομάζεται σήμα συνάρτησης για δύο λόγους: πρώτον γιατί θεωρείται ότι εκτελεί μια "χρήσιμη" συνάρτηση στην έξοδο του δικτύου και δεύτερον γιατί κατά το πέρασμα του σήματος συνάρτησης από οποιονδήποτε νευρώνα, το σήμα υπολογίζεται σαν μια συνάρτηση των εισόδων και των βαρών που εφαρμόζονται στον συγκεκριμένο νευρώνα.

Το σήμα σφάλματος προέρχεται από έναν νευρώνα εξόδου του δικτύου και διαδίδεται προς τα πίσω, συμβατικά από δεξιά προς τα αριστερά, από στρώμα σε στρώμα, μέσα στο δίκτυο. Ονομάζεται σήμα σφάλματος για το λόγο ότι ο υπολογισμός του σήματος από κάθε νευρώνα του δικτύου, συνεπάγεται μια συνάρτηση σφάλματος.

Παρακάτω παρατίθεται ένα νευρωνικό δύο εισόδων, δύο κρυφών στρωμάτων, που το καθένα αποτελείται από τρεις και δύο νευρώνες αντίστοιχα και του στρώματος εξόδου, που αποτελείται από ένα νευρώνα (2-3-2-1 νευρωνικό δίκτυο).



Σχήμα 2.8: 2-3-2-1 νευρωνικό δίκτυο

Στο παραπάνω νευρωνικό με τους αριθμούς 1 έως 6 συμβολίζονται οι νευρώνες κάθε στρώματος. Οπου x_1 και x_2 οι είσοδοι, h_1 έως h_6 οι έξοδοι καθενός

από τους νευρώνες και w_{ij} τα βάρη των συνάψεων, όπου i ο νευρώνας-κατάληξη της σύναψης και j ο νευρώνας-αρχή της σύναψης.

Διαδικασία διάδοσης του σήματος συνάρτησης μέσα από το νευρωνικό δίκτυο.

1^ο βήμα : Υπολογίζουμε την έξοδο του κάθε κόμβου του στρώματος εισόδου, δηλαδή την είσοδο της συνάρτησης ενεργοποίησης έστω Q . Στον κόμβο 1 θα έχουμε :

$$Q_1 = W_{11}X_1 + W_{12}X_2$$

$$Q_2 = W_{21}X_1 + W_{22}X_2$$

$$Q_3 = W_{31}X_1 + W_{32}X_2$$

2^ο βήμα : Υπολογισμός των εξόδων των συναρτήσεων ενεργοποίησης του πρώτου στρώματος.

$$h_1 = \sigma(Q_1)$$

$$h_2 = \sigma(Q_2)$$

$$h_3 = \sigma(Q_3)$$

3^ο βήμα : Υπολογισμός των εισόδων των συναρτήσεων ενεργοποίησης του κρυφού-ενδιάμεσου στρώματος.

$$Q_4 = W_{41}h_1 + W_{42}h_2 + W_{43}h_3$$

$$Q_5 = W_{51}h_1 + W_{52}h_2 + W_{53}h_3$$

4^ο βήμα : Υπολογισμός των εξόδων των συναρτήσεων ενεργοποίησης του κρυφού στρώματος.

$$h_4 = \sigma(Q_4)$$

$$h_5 = \sigma(Q_5)$$

5^ο βήμα : Υπολογισμός της εξόδου του νευρωνικού δικτύου.

$$Q_6 = W_{64}h_4 + W_{65}h_5$$

$$Y = h_6 = \sigma(Q_6)$$

2.3.6.3.1 Αλγόριθμος οπίσθιας διάδοσης σφαλμάτων για πολυστρωματικά feedforward νευρωνικά δίκτυα (Backpropagation Algorithm)

Ο αλγόριθμος οπίσθεν διάδοσης σφαλμάτων είναι μια γενική μέθοδος για υπολογισμό των βαρών ενός πολυστρωματικού δικτύου. Στόχος της μεθόδου είναι να εκπαιδευτούν τα βάρη με βάση το σύνολο των τιμών των ζευγών εισόδου-εξόδου, καθώς το δίκτυο ανήκει στη κατηγορία supervised learning, μειώνοντας με κάθε εποχή λειτουργίας του αλγορίθμου το σήμα σφάλματος στην έξοδο του νευρωνικού δικτύου. Το σήμα σφάλματος του j νευρώνα στη n επανάληψη ορίζεται e και ισούται με $e_j(n) = t_j(n) - y_j(n)$, όπου t η επιθυμητή τιμή εξόδου και y η απόκριση του νευρώνα j εξόδου του δικτύου. Επίσης ορίζουμε την ενέργεια σφάλματος για τους νευρώνες του

στρώματος εξόδου σαν E και ισούται με $E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n)$, όπου C το σύνολο των

νευρώνων εξόδου. Η μέση τετραγωνική ενέργεια σφάλματος καλείται E_{av} και

ισούται με $E_{av} = \frac{1}{N} \sum_{n=1}^N E(n)$. Για ένα σετ δεδομένων εκπαίδευσης η E_{av} αναπαριστά

την συνάρτηση κόστους, σαν ένα μέτρο απόδοσης της εκπαίδευσης. Στόχος της διαδικασίας εκπαίδευσης είναι η προσαρμογή των παραμέτρων του δικτύου, ώστε να έχουμε ελαχιστοποίηση της συνάρτησης κόστους.

Για μικρές τιμές ρυθμού μάθησης, αποτελεί μια πολύ σταθερή μέθοδο, αλλά μειονέκτημά της αποτελεί η αρκετά αργή σύγκλισή του. Παρακάτω περιγράφεται βηματικά η λειτουργία του αλγορίθμου.

1. Απόδοση αρχικών τιμών στα βάρη.
2. Επιλογή προτύπου και έναρξη επαναληπτικής διαδικασίας για κάθε πρότυπο εκπαίδευσης.
3. Εκπαίδευση προτύπου.
4. Τέλος βρόχου.
5. Επανάληψη της παραπάνω διαδικασίας μέχρι κάλυψη του κριτηρίου τερματισμού των επαναλήψεων.

Εκπαίδευση προτύπου

1. Εμφάνιση προτύπου στο στρώμα εισόδου.
2. Υπολογισμός εξόδων ενδιάμεσων κόμβων (στρωμάτων).

3. Υπολογισμός τελικής εξόδου του δικτύου (κόμβος εξόδου).
4. Εφαρμογή επιθυμητού προτύπου t (target) στην έξοδο.
5. Υπολογισμός δ για κόμβους εξόδου.
6. Εκπαίδευση κόμβων εξόδου με βάση τον τύπο:

$$\delta_k = \sigma'(\alpha_k) (t_k^p - y_k^p)$$

όπου $\sigma'()$ η παράγωγος της συνάρτησης ενεργοποίησης του κόμβου εξόδου k , α_k το άθροισμα των εισόδων της συνάρτησης ενεργοποίησης, t_k^p η επιθυμητή τιμή (target) που αφορά τον κόμβο k για το πρότυπο εισόδου p , y_k^p η έξοδος του κόμβου εξόδου k για το πρότυπο p .

7. Υπολογισμός δ για ενδιάμεσους κόμβους
8. Εκπαίδευση ενδιάμεσων στρωμάτων με βάση τον τύπο:

$$\delta_k = \sigma'(\alpha_k) \sum_{j \in I_k} \delta_j^p w_{jk}$$

όπου $\sigma'()$ η παράγωγος της συνάρτησης ενεργοποίησης του ενδιάμεσου κόμβου k , I_k το πλήθος των κόμβων εξόδου, που παίρνουν είσοδο από τον κόμβο k , και w_{jk} το βάρος της σύναψης, που συνδέει το κόμβο k με τον κόμβο εξόδου j .

Για την εκπαίδευση των βαρών χρησιμοποιείται ο τύπος:

$$\Delta w_{ki} = \rho^* \delta_k^* x_{ki}^p$$

Όπου Δw_{ki} η διαφορά του προηγούμενο από το επόμενο βάρος, ρ ο ρυθμός μάθησης, δ_k το αποτέλεσμα μιας από τις παραπάνω εξισώσεις ανάλογα με το αν αφορά κόμβο εξόδου ή ενδιάμεσο κόμβο αντίστοιχα, x_{ki}^p η i είσοδος στον κόμβο k για το πρότυπο p .

Κριτήρια τερματισμού των επαναληψεων

1. Κοντινότερη απόσταση της απόκρισης κόμβων εξόδου από την επιθυμητή τιμή, για όλα τα πρότυπα.
2. Προσδιορισμός επαρκώς χαμηλής τιμής σφάλματος, δηλαδή χαμηλής τιμής της συνάρτησης κόστους.
3. Μείωση του ρυθμού μεταβολής σφάλματος.

Είναι απαραίτητο να αναφερθεί ότι για τον υπολογισμό των βαρών με backpropagation, χρησιμοποιείται ο κανόνας της αλυσίδας, ο οποίος καταρχάς απαιτεί την ύπαρξη και στη συνέχεια τη χρήση των παραγώγων των συναρτήσεων ενεργοποίησης, οι οποίες πρέπει να είναι συνεχείς. Για τις πιο συχνά χρησιμοποιούμενες συναρτήσεις ενεργοποίησης, που είναι η γραμμική, η σιγμοειδής και η υπερβολική εφραπτομένη, παρατίθενται παρακάτω οι παράγωγοί τους.


Πίνακας 2.2: Συναρτήσεις ενεργοποίησης και οι παράγωγοί τους

Τύπος συνάρτησης	Συνάρτηση ενεργοποίησης	Παράγωγος συνάρτησης
Linear	$\sigma(x)=x$	$\sigma'(x)=1$
Logistic	$\sigma(x) = \frac{1}{1+e^{-ax}}$	$\sigma'(x)=a*\sigma(x)(1-\sigma(x))$
Tanh	$\sigma(x) = \frac{e^{ax} - e^{-ax}}{e^{ax} + e^{-ax}}$	$\sigma'(x)=a(1-\sigma(x)^2)$

Το a ονομάζεται παράμετρος κλίσης και συνήθως παίρνει την τιμή 1.

Ακολουθεί περιγραφή της διαδικασίας ανανέωσης των βαρών των συνάψεων, με βάση τον αλγόριθμο όπισθεν διάδοσης σφαλμάτων με παράδειγμα.

Έστω το παρακάτω νευρωνικό δίκτυο.



Σχήμα 2.9: 3-3-1 νευρωνικό δίκτυο

Έστω ότι στους νευρώνες χρησιμοποιείται σιγμοειδής συνάρτηση και το δίκτυο εκπαιδεύεται με ρυθμό μάθησης p .

Έχουμε λοιπόν το διάνυσμα εισόδων που είναι: $x = \begin{bmatrix} x_0 \\ x_1 \\ x_2 \end{bmatrix}$, το διάνυσμα βαρών των

συνάψεων μεταξύ εισόδων και ενδιάμεσου στρώματος που είναι:

$w = \begin{bmatrix} w_{10} & w_{11} & w_{12} \\ w_{20} & w_{21} & w_{22} \end{bmatrix}$ και το διάνυσμα των βαρών των συνάψεων μεταξύ ενδιάμεσου

στρώματος και της εξόδου που είναι: $u = \begin{bmatrix} u_{10} \\ u_{11} \\ u_{12} \end{bmatrix}$.

Κατά την εμπρόσθια διάδοση του σήματος συνάρτησης έχουμε τις εξής σχέσεις:

$$\alpha_j = w_j \bullet x = \begin{bmatrix} \alpha_1 \\ \alpha_2 \end{bmatrix}$$

από την οποία προκύπτουν οι είσοδοι των νευρώνων του ενδιάμεσου στρώματος, οι οποίες περνάνε από τις συναρτήσεις ενεργοποίησης οπότε προκύπτουν οι εξής σχέσεις:

$$h_j = \sigma(\alpha_j) = \frac{1}{1 + e^{-\alpha_j}} = \begin{bmatrix} h_0 & h_1 & h_2 \end{bmatrix}^T = \begin{bmatrix} 1 & \sigma(\alpha_1) & \sigma(\alpha_2) \end{bmatrix}$$

Ακολουθεί η έξοδος του νευρώνα εξόδου που δίνεται από την παρακάτω σχέση:

$$y_1 = \sigma(u \bullet h_j)$$

Μετά τον υπολογισμό της εξόδου ξεκινάει η διαδικασία ανανέωσης των βαρών με βάση τη διαφορά της απόκρισης εξόδου από την επιθυμητή έξοδο. Κάνουμε λοιπόν χρήση του τύπου $\delta_k = \sigma'(\alpha_k) (t_k^p - y_k^p)$ για τον κόμβο εξόδου. Έτσι έχουμε:

$$\delta_{y_1} = \sigma'(\alpha_{y_1})(t - y_1) = y_1(1 - y_1)(t - y_1)$$

Έχοντας υπολογίσει το δ_{y_1} μπορούμε να υπολογίσουμε τα ανανεωμένα βάρη των συνάψεων u .

Οπότε έχουμε: $\Delta u = \begin{bmatrix} \Delta u_{10} \\ \Delta u_{11} \\ \Delta u_{12} \end{bmatrix} = \begin{bmatrix} p\delta_{y_1}h_0 \\ p\delta_{y_1}h_1 \\ p\delta_{y_1}h_2 \end{bmatrix}$ και τελικά τα ανανεωμένα βάρη u που

ισούνται με: $u_{\text{new}} = \begin{bmatrix} u_{10} + \Delta u_{10} \\ u_{11} + \Delta u_{11} \\ u_{12} + \Delta u_{12} \end{bmatrix}$. Ουσιαστικά τα νέα βάρη προέκυψαν εφαρμόζοντας

τον εξής κανόνα αλυσίδας: $u_{\text{new}} \rightarrow Q_3 \rightarrow y_1 \rightarrow e$, όπου $e = t - y_1$

Στη συνέχεια προκειμένου να υπολογίσουμε τα ανανεωμένα βάρη για τα w , πρέπει πρώτα να υπολογίσουμε τα δ_{h_1} και δ_{h_2} με χρήση του τύπου $\delta_k = \sigma'(a_k) \sum_{j \in I_k} \delta^j w_{jk}$.

Οπότε έχουμε:

$$\delta_{h_1} = \sigma'(a_{h_1}) * \sum_{j \in I_k} \delta_{y_1} * u_{11} = h_1 (1 - h_1) (\delta_{y_1}) (u_{11})$$

$$\delta_{h_2} = \sigma'(a_{h_2}) * \sum_{j \in I_k} \delta_{y_1} * u_{12} = h_2 (1 - h_2) (\delta_{y_1}) (u_{12}).$$

Έχοντας υπολογίσει τα δ_{h_1} και δ_{h_2} μπορούμε να υπολογίσουμε τα ανανεωμένα βάρη των συνάψεων w .

$$\Delta w = \begin{bmatrix} \Delta w_{10} & \Delta w_{11} & \Delta w_{12} \\ \Delta w_{20} & \Delta w_{21} & \Delta w_{22} \end{bmatrix} = \begin{bmatrix} p(\delta h_1) x_0 & p(\delta h_1) x_1 & p(\delta h_1) x_2 \\ p(\delta h_2) x_0 & p(\delta h_2) x_1 & p(\delta h_2) x_2 \end{bmatrix}$$

$$w_{\text{new}} = \begin{bmatrix} w_{10} + \Delta w_{10} & w_{11} + \Delta w_{11} & w_{12} + \Delta w_{12} \\ w_{20} + \Delta w_{20} & w_{21} + \Delta w_{21} & w_{22} + \Delta w_{22} \end{bmatrix}$$

Το ανανεωμένο βάρος $w_{10\text{new}}$ προέκυψε από τον εξής κανόνα αλυσίδας:

$$w_{10\text{new}} \rightarrow Q_1 \rightarrow h_1 \rightarrow Q_3 \rightarrow y_1 \rightarrow e, \text{ όπου } e = t - y_1.$$

Από τα παραπάνω διαφαίνεται ότι η παραγωγικότητα του αλγορίθμου είναι άμεσα συνδεδεμένη με την ελαχιστοποίηση της συνάρτησης κόστους, που αποτελεί το κριτήριο καλής απόδοσης του αλγορίθμου. Το σημαντικό αυτού του κριτηρίου είναι η γενικότητά του. Παρακάτω παρατίθενται δύο μέθοδοι ελαχιστοποίησης της συνάρτησης κόστους που έχουν αρκετά ταχύτερη σύγκλιση του κριτηρίου απ' τον backpropagation.

2.3.6.3.2 Μέθοδος Quasi-Newton

Το χαρακτηριστικό της μεθόδου αυτής είναι ότι χρησιμοποιεί δεδομένα δευτέρας τάξης για την επιφάνεια σφάλματος, χωρίς ουσιαστικά να υπολογίζει τον Hessian πίνακα H της συνάρτησης κόστους. Ο Hessian πίνακας της συνάρτησης κόστους ($E_{av}(w)$) είναι η δεύτερη παραγωγός της, ως προς το βάρος (w), και ο υπολογισμός του είναι πολύ απαιτητικός υπολογιστικά. Η συγκεκριμένη μέθοδος χρησιμοποιεί πληροφορίες της τρέχουσας επανάληψης για να υπολογίζει τον καινούριο Hessian. Γενική εξίσωση της μεθόδου είναι: $w(n+1) = w(n) + \eta(n)s(n)$,

όπου $s(n) = -S(n)g(n)$. Ο πίνακας $S(n)$ είναι ένας θετικά ορισμένος πίνακας που προσαρμόζεται από επανάληψη σε επανάληψη. Αυτό γίνεται ώστε το διάνυσμα διεύθυνσης $s(n)$ να υπολογίσει τη διεύθυνση του Newton που ισούται με $-((E_{av}(w))'')^{-1} (E_{av}(w))'$.

Χρησιμοποιώντας τα βάρη δύο συνεχόμενων επαναλήψεων, $w(n), w(n+1)$, με τα αντίστοιχα τους διανύσματα κλίσης $g(n), g(n+1)$, έστω $q(n) = g(n+1) - g(n)$, $\Delta w(n) = w(n+1) - w(n)$, μπορούμε να πάρουμε πληροφορίες δευτέρας τάξης, δηλαδή σχετικά με τη καμπύλωση, χρησιμοποιώντας την ακόλουθη φόρμουλα:

$$q(n) \approx \left(\frac{\partial}{\partial w} g(n) \right) \Delta w(n).$$

Το χαρακτηριστικό αυτής της μεθόδου είναι ότι έχει ταχεία σύγκλιση καθώς δεν κάνει υπολογισμό του Hessian matrix.

2.3.6.3.3 Αλγόριθμος Levenberg-Marquardt(LM)

Όπως και η προηγούμενη μέθοδος έτσι και ο αλγόριθμος LM, σχεδιάστηκε για να ελαχιστοποιεί τη συνάρτηση κόστους, με μεγάλη ταχύτητα χωρίς να χρειάζεται να υπολογίσει τον Hessian matrix. Όταν η συνάρτηση κόστους έχει τη μορφή του αθροίσματος τετραγώνων, όπως στη περίπτωση των νευρωνικών δικτύων, ο Hessian matrix μπορεί να υπολογιστεί από το παρακάτω γινόμενο:

$$H = J^T J$$

,όπου J ο Jacobian matrix, που περιέχει τις πρώτες παραγώγους των σφαλμάτων δικτύου ως προς τα βάρη και τα bias, δηλαδή:

$$J = \begin{bmatrix} \frac{\partial e}{\partial W_1} & \frac{\partial e}{\partial W_2} & \dots \end{bmatrix}$$

Ο Jacobian matrix μπορεί να υπολογιστεί με μεθόδους πολύ λιγότερο σύνθετες υπολογιστικά σε σχέση με τον υπολογισμό του Hessian matrix.

Επίσης ορίζουμε το διάνυσμα κλίσης g που υπολογίζεται ως:

$$g = J^T e$$

με T να υποδηλώνεται ο ανάστροφος πίνακας και e το σφάλμα δικτύου.

Η επαναληπτική σχέση υπολογισμού των βαρών με χρήση LM είναι :

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

όπου μ ένα συντελεστής που αυξάνεται ή μειώνεται ανάλογα με το αν η επανάληψη είναι επιτυχημένη ή όχι, δηλαδή αν η συνάρτηση κόστους έχει αυξηθεί ή μειωθεί αντίστοιχα μετά από την επανάληψη. Ο \mathbf{I} είναι ο διαγώνιος μοναδιαίος πίνακας.

2.4 ΠΛΕΟΝΕΚΤΗΜΑΤΑ ΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Το νευρωνικό δίκτυο γενικά αντλεί την υπολογιστική του ισχύ μέσω: πρώτον, της μαζικά παράλληλης κατανεμημένης δομής του και δεύτερον μέσω της ικανότητας του να μαθαίνει και συνεπώς να γενικεύει. Η *γενίκευση* αναφέρεται στην ικανότητα του νευρωνικού δικτύου να παράγει λογικές εξόδους, για κάποιες εισόδους που δεν λήφθησαν υπόψιν κατά την εκπαίδευση. Η χρήση των νευρωνικών δικτύων προσφέρει τις παρακάτω ιδιότητες και δυνατότητες:

1. Μη γραμμικότητα (Nonlinearity). Ένα νευρωνικό δίκτυο μπορεί να είναι γραμμικό ή μη γραμμικό. Ένα νευρωνικό δίκτυο, που αποτελείται από τη διασύνδεση μη γραμμικών μονάδων-νευρώνων, είναι μη γραμμικό. Η μη γραμμικότητα των νευρωνικών δικτύων είναι μια ιδιότητα μεγάλης σπουδαιότητας, ιδίως χρήσιμη στην περίπτωση που ο φυσικός μηχανισμός παραγωγής του σήματος εισόδου είναι έμφυτα μη γραμμικός π.χ. σήμα φωνής.
2. Απεικόνιση Εισόδου-Εξόδου (Input-Output Mapping). Ένα χαρακτηριστικό παράδειγμα περιγραφής αυτής της ιδιότητας είναι η μάθηση με εποπτεία (supervised learning). Στη περίπτωση αυτή έχουμε τροποποίηση των συναπτικών βάρων με εφαρμογή στο νευρωνικό δίκτυο ενός σετ δειγμάτων εκπαίδευσης, καθένα από τα οποία αποτελείται από ένα μοναδικό σήμα εισόδου και την αντίστοιχη του επιθυμητή απόκριση. Το δίκτυο παρουσιάζεται με ένα δείγμα επιλεγμένο τυχαία από το σύνολο των δειγμάτων και τα συναπτικά βάρη τροποποιούνται, ώστε να ελαχιστοποιήσουν τη διαφορά μεταξύ επιθυμητής και πραγματικής απόκρισης του δικτύου, που παράχθηκε από το δίκτυο, σε συνδυασμό με ένα στατιστικό κριτήριο. Η εκπαίδευση του δικτύου επαναλαμβάνεται για πολλά δείγματα του συνόλου δειγμάτων μέχρι το δίκτυο να φτάσει σε μια σταθερή κατάσταση (steady state), που δεν θα υπάρχουν πλέον σημαντικές διαφορές στα συναπτικά βάρη. Έτσι το δίκτυο μαθαίνει μέσα από τα

δείγματα δημιουργώντας ουσιαστικά μια αντιστοίχιση εισόδων-εξόδων του σετ.

3. Προσαρμοστικότητα (Adaptivity). Τα νευρωνικά δίκτυα έχουν μια έμφυτη ικανότητα, να προσαρμόζουν τα συναπτικά βάρη τους σε μεταβολές του περιβάλλοντός. Πιο συγκεκριμένα, ένα νευρωνικό δίκτυο, που είναι εκπαιδευμένο να λειτουργεί σε ένα συγκεκριμένο περιβάλλον μπορεί εύκολα να επαναεκπαιδευτεί για να αντιμετωπίσει μικρές μεταβολές στις συνθήκες του περιβάλλοντος λειτουργίας του. Επιπρόσθετα σε περίπτωση που το περιβάλλον είναι μη στατικό, το νευρωνικό δίκτυο μπορεί να σχεδιαστεί, ώστε να αλλάζει τα βάρη του σε πραγματικό χρόνο. Έτσι η φυσική αρχιτεκτονική ενός νευρωνικού δικτύου, για αναγνώριση προτύπων, επεξεργασία σημάτων και εφαρμογές αυτομάτου ελέγχου σε συνδυασμό με την προσαρμοστική ικανότητά του, το κάνουν χρήσιμο εργαλείο για προσαρμοστική αναγνώριση προτύπων, προσαρμοστική επεξεργασία σημάτων και προσαρμοστικό έλεγχο.
4. Αποδεικτική Απόκριση (Evidential Response). Στο τομέα της ταξινόμησης προτύπων, ένα νευρωνικό δίκτυο μπορεί να χρησιμοποιηθεί, όχι μόνο για την επιλογή του κατάλληλου προτύπου, αλλά και για την εγκυρότητα της απόφασης. Αυτή η πληροφορία μπορεί να χρησιμοποιηθεί για να απορρίψει διφορούμενα πρότυπα, που μπορεί να προκύψουν, βελτιώνοντας έτσι την απόδοση του συστήματος.
5. Ανθεκτικότητα σε Σφάλματα (Fault tolerance). Ένα νευρωνικό δίκτυο, που έχει υλοποιηθεί σε επίπεδο υλικού, έχει τη δυνατότητα να είναι ανθεκτικό σε λάθη, με την έννοια ότι η απόδοσή του θα πέσει σταδιακά σε περίπτωση δυσμενών συνθηκών λειτουργίας.
6. Ικανότητα εφαρμογής σε τεχνολογία πολύ υψηλού επιπέδου ολοκλήρωσης (VLSI Implementability). Η παράλληλη αρχιτεκτονική ενός νευρωνικού δικτύου το καθιστά πολύ γρήγορο, σε περιπτώσεις υπολογισμού συγκεκριμένων εφαρμογών. Αυτό το χαρακτηριστικό του το κάνει ιδανικό για υλοποίηση εφαρμογών, με τεχνολογία πολύ υψηλού επιπέδου ολοκλήρωσης συστημάτων.
7. Νευροβιολογική Αναλογία (Neurobiological Analogy). Η σχεδίαση του νευρωνικού δικτύου παρακινήθηκε από την αναλογία του με τον ανθρώπινο εγκέφαλο, κάτι που αποτελεί ζωντανή απόδειξη ότι η

ανθεκτική σε σφάλματα παράλληλη επεξεργασία δεν είναι μόνο φυσικά πιθανή αλλά και γρήγορη και ισχυρή. Οι νευροβιολόγοι βλέπουν τα τεχνητά νευρωνικά δίκτυα σαν ένα εργαλείο έρευνας, για εξήγηση των νευροβιολογικών φαινομένων.

2.5 ΖΗΤΗΜΑΤΑ ΥΛΟΠΟΙΗΣΗΣ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ

Κατά την υλοποίηση ενός νευρωνικού δικτύου ανακύπτουν αρκετές αποφάσεις, που πρέπει να παρθούν για τη λύση ενός προβλήματος. Αυτές οι αποφάσεις αφορούν την επιλογή του συνόλου των δεδομένων εκπαίδευσης και δεδομένων δοκιμής (training-test set), τη δομή του δικτύου (network architecture), τη μέθοδο εκπαίδευσης (training method) και τη τιμή-στόχο του σφάλματος (error goal).

Μεθοδολογία εκπαίδευσης νευρωνικού δικτύου

Αρχικά πρέπει να γίνει η συλλογή ή η παραγωγή των δεδομένων που θα χρησιμοποιηθούν για τη εκπαίδευση και δοκιμή του δικτύου. Μετά τη συλλογή των δεδομένων ,πρέπει να γίνει διαχωρισμός τους σε δεδομένα εκπαίδευσης και δεδομένα εξακρίβωσης. Το σύνολο των δεδομένων εκπαίδευσης πρέπει να είναι όλα ή ένα μέρος των δεδομένων εισόδου, που να λειτουργεί, αλλιώς η έξοδος του δικτύου δεν θα είναι δεκτή, δηλαδή δεν θα γίνει καλή εκπαίδευση. Η απόφαση περί του μέρους των δεδομένων που θα χρησιμοποιηθούν σαν δεδομένα εκπαίδευσης είναι δύσκολη, καθώς απ'τη μια μεριά είναι επιθυμητό το σετ να είναι μικρό, για να έχουμε γρήγορη εκπαίδευση και απ' την άλλη θέλουμε μεγάλο μέρος των δεδομένων, για καλύτερη εκπαίδευση και συνεπώς γενίκευση.

Μετά την επιλογή του σετ δεδομένων εκπαίδευσης ακολουθεί η επιλογή της δομής του νευρωνικού δικτύου. Στη απόφαση αυτή υπάρχουν δύο επιλογές, ή θα επιλεγεί εξ αρχής μεγάλο δίκτυο, ώστε να υπάρχουν πολλοί νευρώνες στο ενδιάμεσο στρώμα και η εκπαίδευση να καταλήξει πιο εύκολα στην επιθυμητή τιμή-στόχο σφάλματος, οπότε στη συνέχεια θα γίνει επιχείρηση μείωσης του μεγέθους του δικτύου, ώστε να καταλήξουμε στο ιδανικό μέγεθος δικτύου, που θα εκπαιδεύει το σετ προτύπων, ή θα επιλεγεί ένα μικρό δίκτυο αρχικά, το οποίο θα μεγαλώσει σταδιακά ώσπου η εκπαίδευση να φτάσει στην επιθυμητή τιμή σφάλματος.

Στη συνέχεια επιλέγεται μια μέθοδος εκπαίδευσης, κατά την οποία αρχειοποιούνται τα βάρη και τα biases (πολώσεις) και εκπαιδεύεται το δίκτυο. Το

δίκτυο μπορεί να μην φτάσει στην τιμή-στόχο σφάλματος για έναν ή και περισσότερους από τους ακόλουθους λόγους:

1. Η εκπαίδευση εγκλωβίζεται σε ένα τοπικό ελάχιστο.
2. Το δίκτυο δεν έχει αρκετούς νευρώνες υπολογισμού, με αποτέλεσμα να μην μπορεί να προσαρμοστεί στο επιθυμητό μοντέλο εισόδου εξόδου.
3. Δεν υπάρχουν αρκετές πληροφορίες στο σετ δεδομένων εκπαίδευσης, ώστε να επιτύχει την επιθυμητή αντιστοίχιση.

Στην πρώτη περίπτωση τα βάρη και τα biases ξαναρχικοποιούνται και επανεκκινούμε την εκπαίδευση. Στη δεύτερη περίπτωση προστίθενται κόμβοι, ή στρώματα και η εκπαίδευση ξαναρχίζει. Η τρίτη περίπτωση δεν είναι πολύ εύκολο να διαπιστωθεί και θεωρείται ότι ισχύει, όταν οι δύο προηγούμενοι τρόποι αντιμετώπισης αποτυγχάνουν.

Όταν εκπαιδεύουμε ένα δίκτυο, στόχος είναι να καταλήξουμε στην ελάχιστη δυνατή τοπολογία (μικρότερο δυνατόν δίκτυο). Σε αντίθετη περίπτωση μπορεί να προκύψει υπερπροσαρμογή (overfitting). Η υπερπροσαρμογή είναι εμφανής, όταν το επίπεδο σφάλματος του δικτύου για τα δεδομένα εκπαίδευσης είναι σημαντικά καλύτερο από το επίπεδο σφάλματος για τα δεδομένα εξακρίβωσης. Η υπερπροσαρμογή μπορεί να μειωθεί με τους εξής τρόπους:

1. Περιορίζοντας τον αριθμό των νευρώνων στο ελάχιστο.
2. Αυξάνοντας το μέγεθος του σετ δεδομένων εκπαίδευσης ώστε ο θόρυβος να αμβλύνεται.
3. Σταματώντας την εκπαίδευση πριν να εμφανισθεί υπερπροσαρμογή χρησιμοποιώντας τη μέθοδο crossvalidation.

Στη συνέχεια αφού υλοποιηθεί η βέλτιστη εκπαίδευση το δίκτυο, πρέπει να επαληθευτεί με τα δεδομένα εξακρίβωσης. Στόχος της επαλήθευσης, είναι ο υπολογισμός του σφάλματος να καταλήξει στην επιθυμητή τιμή σφάλματος. Αν δεν επιτευχθεί αυτό, θα συντρέχουν δύο λόγοι:

1. "Φτωχή" γενίκευση, που θα οφείλεται στο ανεπαρκές σετ δεδομένων εκπαίδευσης.
2. Υπερπροσαρμογή, που θα οφείλεται είτε σε ανεπαρκές σετ δεδομένων εκπαίδευσης είτε μεγάλο μέγεθος δικτύου.

Η αιτία της χαμηλής απόδοσης της επαλήθευσης είναι συνήθως δύσκολο να διαπιστωθεί και για αυτό χρησιμοποιείται η μέθοδος crossvalidation. Σε περίπτωση που αιτία είναι το ανεπαρκές σετ δεδομένων εξακρίβωσης είτε χρειάζεται να επιλεγεί

ένα άλλο μέρος των δεδομένων εισόδου σαν δεδομένα επαλήθευσης είτε χρειάζεται τα δεδομένα να συλλεγούν ξανά.

2.5.1 Μέθοδος cross-validation

Η μέθοδος αυτή χρησιμοποιείται για να επιτευχθεί η επιλογή της κατάλληλης δομής νευρωνικού δικτύου ώστε να αποφευχθεί η υπερπροσαρμογή των δεδομένων εκπαίδευσης. Σύμφωνα με τη μέθοδο αυτή, το σετ δεδομένων εκπαίδευσης αρχικά διαχωρίζεται σε δύο υποσύνολα: το υποσύνολο εκτίμησης (estimation subset), που χρησιμοποιείται για να επιλέξει το μοντέλο και το υποσύνολο επαλήθευσης (validation subset), που χρησιμοποιείται για να επαληθεύσει το μοντέλο.

Στη μεθολογία αυτή επιλέγεται ένα μέγιστο μοντέλο νευρωνικού δικτύου, δηλαδή που έχει μια συγκεκριμένη δομή και ένα συγκεκριμένο αριθμό διανυσμάτων βαρών, και ακολουθείται από μοντέλα με ίδια δομή αλλά με όλο και λιγότερους κόμβους στα ενδιάμεσα στρώματα. Το σετ δεδομένων εκπαίδευσης χωρίζεται σύμφωνα με έναν παράγοντα r , σε υποσύνολο εκτίμησης, που περιέχει $N(1-r)$ πρότυπα και σε υποσύνολο επαλήθευσης, που περιέχει Nr πρότυπα. Όλα τα μοντέλα εκπαιδεύονται στο υποσύνολο εκτίμησης και επαληθεύονται από το σετ επαλήθευσης και στόχος είναι να βρεθεί το μοντέλο με τις καλύτερες παραμέτρους (βάρη και biases), δηλαδή αυτό με το μικρότερο σφάλμα επαλήθευσης.

Το θέμα είναι ο προσδιορισμός του r . Σύμφωνα με αποτελέσματα από τον Kearns(1996) μια ιδανική τιμή για το r αποτελεί το 0.2.

Η ουσιαστική διαφορά της υλοποίησης της μεθόδου αυτής σε σχέση με την εκπαίδευση του δικτύου με όλο το σύνολο των δεδομένων εκπαίδευσης είναι η εξής: κατά την εκπαίδευση του δικτύου με το υποσύνολο εκτίμησης, η διαδικασία της εκπαίδευσης σταματάει περιοδικά, και το δίκτυο επαληθεύεται με το υποσύνολο επαλήθευσης. Έτσι υπολογίζεται περιοδικά και το σφάλμα του υποσυνόλου επαλήθευσης. Το σφάλμα αυτό τη χρονική στιγμή που συμβαίνει η υπερπροσαρμογή σταματάει να μειώνεται και αρχίζει να αυξάνεται. Οπότε ο εντοπισμός του ελάχιστου σφάλματος του υποσυνόλου επαλήθευσης μπορεί να λειτουργήσει σαν κριτήριο διακοπής της διαδικασίας εκπαίδευσης.

Μια παραλλαγή της μεθόδου cross-validation αποτελεί η multifold cross-validation κατά την οποία το σύνολο των N δεδομένων διαιρείται σε K υποσύνολα. Το μοντέλο εκπαιδεύεται σε όλα τα υποσύνολα εκτός από ένα, και το σφάλμα του

υποσύνολου επαλήθευσης μετριέται στο υποσύνολο που δεν συμπεριελήφθηκε. Η διαδικασία αυτή επαναλαμβάνεται K φορές, κάθε φορά μη συμπεριλαμβανομένου διαφορετικού υποσύνολου. Μειονέκτημα της μεθόδου αποτελεί η μεγάλη απαίτηση υπολογιστικής ισχύος που έχει.

1^η επανάληψη: σφάλμα e_1

1	2	3	
---	---	---	--

2^η επανάληψη: σφάλμα e_2

1	2		3
---	---	--	---

3^η επανάληψη: σφάλμα e_3

1		2	3
---	--	---	---

4^η επανάληψη: σφάλμα e_4

	1	2	3
--	---	---	---

Σχήμα 2.10: Multifold cross-validation

ΚΕΦΑΛΑΙΟ

3

ΣΥΝΕΡΓΑΤΙΚΕΣ ΜΗΧΑΝΕΣ ΣΥΛΛΟΓΙΚΗΣ ΑΠΟΦΑΣΗΣ (COMMITTEE MACHINES)

3.1 ΕΙΣΑΓΩΓΗ

Σύμφωνα με την αρχή *διαίρει και βασίλευε* ένα σύνθετο υπολογιστικό πρόβλημα λύνεται, αναλύοντας το σε ένα αριθμό απλούστερων υπολογιστικά προβλημάτων αρχικά, και στη συνέχεια συνθέτοντας τις λύσεις των προβλημάτων αυτών. Στη μάθηση με εποπτεία, η υπολογιστική αυτή απλούστευση επιτυγχάνεται διανέμοντας το πρόβλημα εκπαίδευσης σε ένα αριθμό από 'ειδικούς' (experts), οι οποίοι με τη σειρά τους διαιρούν το δειγματοχώρο εισόδου σε σύνολα από μικρότερους δειγματοχώρους. Ο συνδυασμός των experts αποτελεί τη μηχανή απόφασης (committee machine). Βασικά ο συνδυασμός αυτός συγχωνεύει τη γνώση που αποκτήθηκε από τους ειδικούς, για να φτάσει σε μια συνολική απόφαση, που υποτίθεται ότι θα είναι καλύτερη από οποιαδήποτε από τις αποφάσεις που θα έχει πάρει ο καθένας από τους ειδικούς ξεχωριστά. Ουσιαστικά αναμένεται ότι τα σφάλματα αποφάσεων στα οποία μπορεί να έχει υποπέσει ένας από τους ειδικούς, θα αναιρούνται από τις σωστές αποφάσεις άλλων ειδικών.

3.2 ΠΛΕΟΝΕΚΤΗΜΑΤΑ ΜΗΧΑΝΩΝ ΑΠΟΦΑΣΗΣ

Ένας αλγόριθμος εκπαίδευσης γενικά προσπαθεί να εντοπίσει μια πιθανή συνάρτηση ή υπόθεση h , που να αντιστοιχεί τα δεδομένα διανύσματα εισόδου x_i στις δοσμένες τιμές εξόδου(στόχους) y_i , όσο καλύτερα γίνεται. Συνήθως όμως η συνάρτηση αυτή αντιστοίχισης δεν εντοπίζεται. Αυτό οφείλεται σε τρία ουσιαστικά προβλήματα των απλών experts: το στατιστικό πρόβλημα(statistical problem), το υπολογιστικό πρόβλημα (computational problem) και το πρόβλημα απεικόνισης (representation problem).

Το στατιστικό πρόβλημα υπάρχει λόγω του γεγονότος ότι για ένα δεδομένο σύνολο προτύπων εκπαίδευσης υπάρχουν συνήθως παραπάνω από μια συναρτήσεις

μοντελοποίησης, αλλά επιλέγεται μόνο μία, η οποία μπορεί να μην λειτουργεί καλά για μελλοντικά πρότυπα.

Το υπολογιστικό πρόβλημα υπάρχει, γιατί κάποιοι αλγόριθμοι, όπως για παράδειγμα ο backpropagation για τα νευρωνικά δίκτυα, δεν προλαβαίνουν να υπολογίσουν την καλύτερη συνάρτηση μοντελοποίησης σε κάποιες περιπτώσεις, γιατί δεσμεύονται σε τοπικά ελάχιστα.

Το πρόβλημα αναπαράστασης ουσιαστικά είναι ότι συχνά είναι ανέφικτο να αναπαρασταθεί η πραγματική συνάρτηση αντιστοίχισης των δεδομένων με μία απλή υπόθεση.

Η επιτυχία των μηχανών συλλογικής απόφασης είναι ότι μπορούν να ξεπεράσουν σε μεγάλο βαθμό τα παραπάνω προβλήματα. Για το στατιστικό πρόβλημα με χρήση περισσότερων του ενός experts με διαφορετικές συναρτήσεις μοντελοποίησης είναι πολύ πιο πιθανό το σύστημα να γενικεύσει καλύτερα. Για το υπολογιστικό πρόβλημα, με τη χρήση ενός σταθμισμένου συνδυασμού αρκετών διαφορετικών υποθέσεων, μειώνεται η πιθανότητα να χρησιμοποιηθεί σαν ταξινομητής (classifier) ως πρόβλεψη, ένα σφάλμα που προέκυψε από τοπικό ελάχιστο. Τέλος για το πρόβλημα αναπαράστασης, με χρήση σταθμισμένου αθροίσματος αρκετών υποθέσεων είναι πιθανό να επεκταθεί ο χώρος των αντιπροσωπευτικών συναρτήσεων.

3.3 ΚΑΤΗΓΟΡΙΕΣ ΜΗΧΑΝΩΝ ΑΠΟΦΑΣΗΣ

Οι μηχανές απόφασης διαχωρίζονται σε δύο βασικές κατηγορίες: 1.στατικές μηχανές, 2.δυναμικές μηχανές.

1.Στατικές μηχανές. Στην κατηγορία αυτή μηχανών απόφασης, οι αποκρίσεις αρκετών experts συνδυάζονται με ένα μηχανισμό, ο οποίος δεν εμπεριέχει το σήμα εισόδου ξανά. Αυτή η κατηγορία αποτελείται από τις ακόλουθες μεθόδους:

- Ensemble averaging, όπου οι έξοδοι διαφορετικών experts συνδυάζονται γραμμικά για να παράγουν μια συνολική έξοδο.
- Boosting, όπου ένας αδύνατος αλγόριθμος εκπαίδευσης μετατρέπεται σε έναν που επιτυγχάνει αυθαίρετα μεγάλη ακρίβεια

2. Δυναμικές μηχανές. Στη κατηγορία αυτή το σήμα εισόδου συμμετέχει ενεργά στο μηχανισμό που συνδυάζει το σύνολο των εξόδων των experts σε μια τελική έξοδο. Στη κατηγορία αυτή υπάρχουν δύο είδη τέτοιων δομών:

- Mixture of experts, όπου οι ξεχωριστές αποκρίσεις των experts συνδυάζονται μη γραμμικά, με χρήση ενός απλού δικτύου που ονομάζεται gating network.
- Hierarchical mixture of experts, όπου οι ξεχωριστές αποκρίσεις των experts συνδυάζονται μη γραμμικά με χρήση αρκετών gating networks, που είναι ταξινομημένα ιεραρχικά.

3.3.1 Ensemble averaging

Το σχήμα 3.1 δείχνει έναν αριθμό από διαφορετικά εκπαιδευμένους experts (π.χ. νευρωνικά δίκτυα) που δέχονται μια κοινή είσοδο και των οποίων οι ξεχωριστές έξοδοι συνδυάζονται με κάποιο τρόπο, για να παράγουν μια συνολική έξοδο y . Η μέθοδος αυτή πλεονεκτεί για δύο λόγους:


1. Αν ο συνδυασμός των experts αντικαθίστατο από ένα απλό νευρωνικό δίκτυο, θα είχαμε ένα δίκτυο αποτελούμενο από πάρα πολλές παραμέτρους, που θα είχε σαν αποτέλεσμα πολύ μεγάλο χρόνο εκπαίδευσης.
2. Το ρίσκο για υπερπροσαρμογή των δεδομένων αυξάνεται σε μεγάλο βαθμό, όταν ο αριθμός των παραμέτρων είναι πολύ μεγαλύτερος σε σύγκριση με το μέγεθος του συνόλου των δεδομένων εκπαίδευσης.

Η προσδοκία από τη χρήση μιας μηχανής απόφασης όπως αυτής του σχήματος 4.1 είναι ότι οι χρησιμοποιούμενοι experts θα έχουν υποπέσει σε διαφορετικά τοπικά ελάχιστα στην επιφάνεια σφάλματος, με αποτέλεσμα η συνολική απόδοση να αυξάνεται με το συνδυασμό των εξόδων με κάποια συγκεκριμένη μεθοδολογία.

Η διαδικασία που χρησιμοποιείται για μια μηχανή αυτού του είδους είναι η εξής:

1. Εισάγονται τα ίδια δεδομένα σε καθέναν από τους experts (π.χ. νευρωνικά δίκτυα). Τα δεδομένα αυτά αποτελούν και την είσοδο της μηχανής.
2. Γίνεται εκπαίδευση και δοκιμή των experts (καθένας ξεχωριστά σύμφωνα με τη δομή του).

3. Η έξοδος που προκύπτει από τη φάση δοκιμής του κάθε expert κατευθύνεται προς το συνδυασμό.
4. Ανάλογα με τη συνάρτηση που ακολουθεί ο συνδυασμός δημιουργεί την έξοδο της μηχανής.



Σχήμα 3.1 Μπλοκ διάγραμμα μηχανής απόφασης που στηρίζεται στο ensemble averaging

3.3.2 Mixture of experts

Το σχήμα 4.2 περιγράφει το μοντέλο ενός συστήματος mixture of experts. Το σύστημα αυτό αποτελείται: από ένα σύνολο από experts και από ένα δίκτυο που ονομάζεται gating network. Κάθε expert μπορεί να είναι ένα εμπρόσθιας διάδοσης νευρωνικό δίκτυο και όλοι οι experts δέχονται κοινή είσοδο και έχουν τον ίδιο αριθμό εξόδων. Το gating network δέχεται επίσης την ίδια είσοδο με τους experts και είναι νευρωνικό δίκτυο που έχει K νευρώνες εξόδου. Καθένας από τους νευρώνες αντιστοιχεί σε έναν συγκεκριμένο expert του συστήματος. Οι νευρώνες εξόδου του gating network είναι μη γραμμικοί και οι συναρτήσεις ενεργοποίησης τους προσδιορίζονται από το εξής τύπο [C21]:

$$g_k = \frac{\exp(u_k)}{\sum_{j=1}^K \exp(u_j)}, \quad k = 1, 2, \dots, K$$

όπου g_k οι εξοδοί του gating network οι οποίες σταθμίζουν τις εξόδους των experts του συστήματος και u_k η είσοδος του k νευρώνα του gating network, που ισούται με το γινόμενο του συναπτικού βάρους με την έξοδο του προηγούμενου στρώματος. Η χρήση των προαναφερθεισών συναρτήσεων ενεργοποίησης διασφαλίζει ότι οι εξοδοί του gating network θα πληρούν τις εξής απαιτήσεις:

$$0 \leq g_k \leq 1 \text{ για όλα τα } k$$

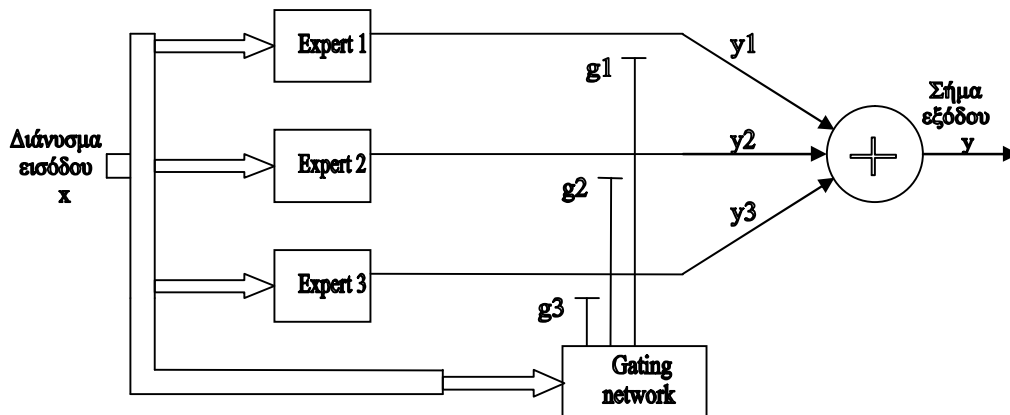
και

$$\sum_{k=1}^K g_k = 1$$

Έτσι μπορούμε να πούμε ότι οι έξοδοι του gating network αποτελούν τις πιθανότητες συμμετοχής της εξόδου του εκάστοτε expert στη συνολική έξοδο του συστήματος, οι οποίες προέκυψαν με βάση τη γνώση που αποκτήθηκε από το σετ δεδομένων εισόδου.

Αν θεωρήσουμε σαν έξοδο του k expert τη y_k , τότε η συνολική έξοδος του συστήματος mixture of experts είναι ίση με:

$$y = \sum_{k=1}^K g_k y_k$$



Σχήμα 3.2 Μπλοκ διάγραμμα μηχανής απόφασης που στηρίζεται στη δομή mixture of experts

ΚΕΦΑΛΑΙΟ

4


ΠΡΟΣΑΡΜΟΣΙΜΟ ΝΕΥΡΟ-ΑΣΑΦΕΣ ΣΥΣΤΗΜΑ ΑΠΟΦΑΣΕΩΝ ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM (ANFIS)

4.1 ΑΣΑΦΗΣ ΛΟΓΙΚΗ

Η ασαφής λογική είναι ένας τρόπος μοντελοποίησης της ανθρώπινης εμπειρίας με γλωσσικούς κανόνες. Στην ασαφή λογική ο αριθμός των πραγματικών τιμών είναι άπειρος και ουσιαστικά χαρακτηρίζονται από γλωσσικές μεταβλητές που έχουν ορισμένο αριθμό όρων όπως σωστό, λάθος, περισσότερο σωστό, λιγότερο σωστό κ.τ.λ.

4.1.1 Ασαφή σύνολα

Βασικό όρο της ασαφούς λογικής αποτελεί το ασαφές σύνολο. Το ασαφές (fuzzy) σύνολο είναι διαφορετικό από το διακριτό(crisp) σύνολο τιμών και σύμφωνα με τον Zadeh που πρωτοπαρουσίασε την ιδέα του ασαφούς συνόλου το 1965, το βασικό χαρακτηριστικό του είναι ότι επεκτείνει το νόημα του συνόλου, δεχόμενο διαφορετικούς βαθμούς συμμετοχής. Οι διαφορετικοί αυτοί βαθμοί συμμετοχής καθορίζονται από τη συνάρτηση συμμετοχής. Το ασαφές σύνολο δηλαδή περιέχει όλες τις ενδιάμεσες καταστάσεις, μεταξύ της απόλυτης συμμετοχής και της μηδενικής συμμετοχής, σε ένα σύνολο. Σαν υπερσύνολο αναφοράς χαρακτηρίζεται ένα σύνολο, που περιέχει άλλα υποσύνολα.



Σχήμα 4.1 Fuzzy vs Crisp

Έστω X ένα υπερσύνολο αναφοράς που περιλαμβάνει το σύνολο τιμών μεταξύ 0 και 1, $U(x)$ η συνάρτηση συμμετοχής και A, B δύο ασαφή σύνολα, που ανήκουν στο X .

Η τομή των δύο ασαφών συνόλων A, B ορίζεται ως εξής:

ΚΑΙ(AND): $U_{A \cap B}(x) = \min[U_A(x), U_B(x)]$, για κάθε $x \in X$

Η ένωση των δύο ασαφών συνόλων ορίζεται ως εξής:

Ή(OR): $U_{A \cup B}(x) = \max[U_A(x), U_B(x)]$, για κάθε $x \in X$

Το συμπλήρωμα ενός ασαφούς συνόλου A ορίζεται ως εξής:

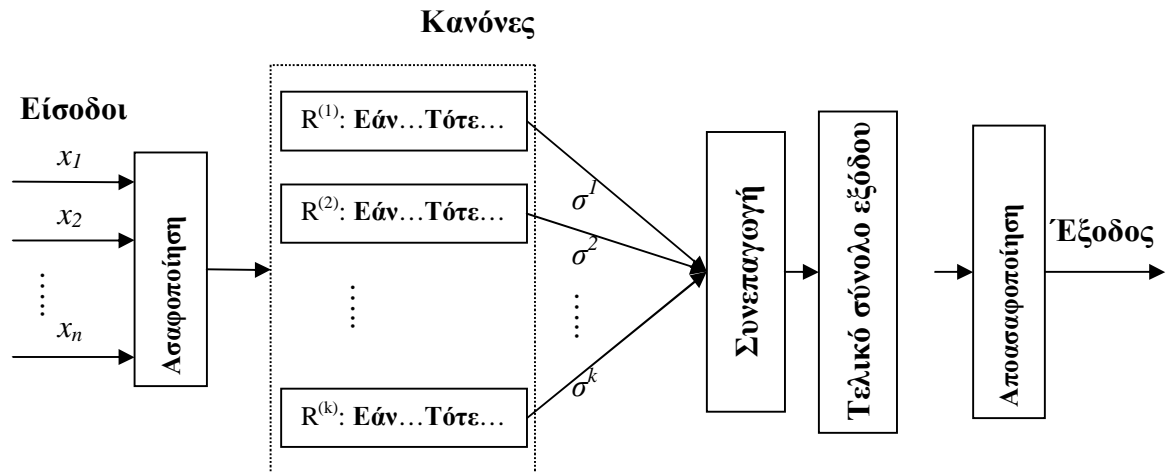
ΟΧΙ(NOT): $U_{A'}(x) = 1 - U_A(x)$, για κάθε $x \in X$

4.1.2 Ασαφής έλεγχος-ασαφής πρόβλεψη

Ο ασαφής έλεγχος έχει τη ρίζα του στις ανθρώπινες εμπειρίες. Στόχος των συστημάτων ασαφούς ελέγχου είναι να ελέγχει σύνθετες διαδικασίες με τη βοήθεια της ανθρώπινης εμπειρίας.

Ο συμβατικός μη-ασαφής έλεγχος συστημάτων χρησιμοποιεί φυσικά μοντέλα για να αντιμετωπίσει τις διάφορες διαδικασίες. Αυτό όμως είναι χρονοβόρο και απαιτεί αρκετά καλό θεωρητικό υπόβαθρο από τον σχεδιαστή. Υπάρχουν περιπτώσεις διαδικασιών, που μπορούν να ελεγχθούν από ένα άνθρωπο, χωρίς να υπάρχει κάποιο μοντέλο αντιμετώπισής τους, με αποτέλεσμα να μην μπορούν να ελεγχθούν από συμβατικά συστήματα ελέγχου. Οι διαχειριστές των διαδικασιών αυτών μπορούν να τις ελέγξουν απλά, επειδή έχουν εμπειρία από αυτές. Αυτή, η τυποποίηση της εμπειρίας του διαχειριστή, είναι η βασική ιδέα του ασαφούς ελέγχου με τις μεθόδους της ασαφούς λογικής.

Οι ασαφείς ελεγκτές λοιπόν είναι ειδικά ελεγχόμενα από υπολογιστή συστήματα, που χρησιμοποιούν κανόνες για να μοντελοποιήσουν τη διαδικασία γνώσης. Στην περίπτωση μας ο ασαφής ελεγκτής παίρνει τη μορφή ασαφούς προβλεπτή (Fuzzy Forecaster) και δημιουργεί κανόνες πρόβλεψης. Παρακάτω παρατίθεται ένα σχηματικό διάγραμμα του μοντέλου του FF.



Σχήμα 4.2 Σχηματικό διάγραμμα FF

Τις εισόδους αποτελούν το πλήθος των σημάτων εισόδου, καθώς και οι διάφορες καταστάσεις στις οποίες μπορεί να βρεθούν στην είσοδο τα σήματα εισόδου π.χ. κανονικοποιημένα.

Κατά την ασαφοποίηση επιλέγεται ο τύπος και ο αριθμός των συναρτήσεων ενεργοποίησης π.χ. Τριγωνική, τραπεζοειδής, γκαουσιανή συνάρτηση συμμετοχής

Οι κανόνες είναι το πιο σημαντικό κομμάτι ενός ασαφούς συστήματος για το λόγο ότι είναι αυτοί που καθορίζουν την συμπεριφορά του συστήματος. Η μορφή των κανόνων είναι:

EAN η είσοδος 1 είναι **x** **ΚΑΙ** / **Ή** η είσοδος 2 είναι **y** **TOTE** η έξοδος είναι **z**

Το μέρος EAN του κανόνα, καλείται αίτιο (antecedent ή premise) και το μέρος TOTE του κανόνα αποτέλεσμα (consequent ή conclusion).


Το επόμενο βήμα είναι η δημιουργία μιας τελικής συνάρτησης συμμετοχής για κάθε μία από τις εισόδους. Η διαδικασία είναι γνωστή σαν συνεπαγωγή (implication).

Το τελευταίο στάδιο ενός FF είναι η αποασαφοποίηση. Εδώ πρέπει να δοσθεί σαφής διακριτή τιμή στην έξοδο. Οι κυριότερες μέθοδοι αποασαφοποίησης είναι οι εξής : Αποασαφοποίηση μεγίστου (Maximum defuzzifier), Αποασαφοποίηση κεντρώου ή κέντρου βάρους (Centre of Area(COA) ή Centre of Gravity(COG) defuzzifier).

4.2 Μέθοδος Mamdani


Η μέθοδος Mamdani χρησιμοποιεί γλωσσικές μεταβλητές για να περιγράψει τις διάφορες καταστάσεις των μεταβλητών και χρησιμοποιεί αυτές τις μεταβλητές

σαν εισόδους για να ελέγξει τους κανόνες. Σε ένα παράδειγμα συστήματος θέρμανσης, η μεταβλητή εισόδου είναι η θερμοκρασία δωματίου. Οι όροι των γλωσσικών μεταβλητών είναι ασαφή σύνολα με συγκεκριμένο σχήμα. Αυτό το σχήμα μπορεί να είναι τραπεζοειδές ή τριγωνικό συνήθως. Σε αυτή τη περίπτωση οι όροι του ασαφούς συνόλου μπορεί να είναι: "πολύ χαμηλή", "χαμηλή", "άνετη", "υψηλή", "πολύ υψηλή", και είναι αυτοί που περιγράφουν τη θερμοκρασία. Παρακάτω παρατίθεται γραφική παράσταση της συμμετοχής σε συνάρτηση με τη θερμοκρασία σε βαθμούς Κελσίου.



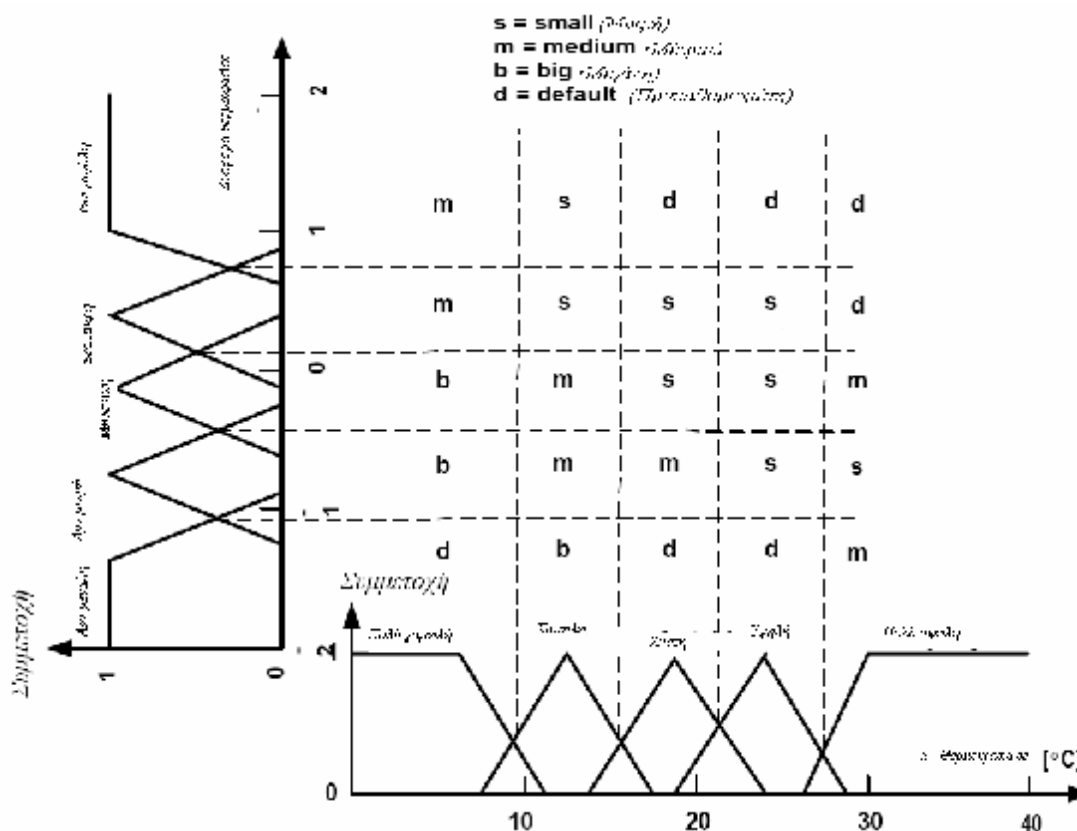
Σχήμα 4.3 Γραφική παράσταση γλωσσικής μεταβλητής θερμοκρασίας

Από το σημείο αναφοράς και την ανάδραση μπορούμε να πάρουμε τη διαφορά θερμοκρασίας στο χώρο.



Σχήμα 4.4 Γραφική παράσταση γλωσσικής μεταβλητής διαφοράς θερμοκρασίας

Τον ίδιο τρόπο χρησιμοποιεί για να βρει και τη συμμετοχή της μεταβλητής εξόδου: Ισχύς συστήματος θέρμανσης (Μικρή, Μέτρια, Μεγάλη). Από τις δύο γλωσσικές μεταβλητές που περιγράφηκαν, φτιάχνονται οι κανόνες λειτουργίας του συστήματος θέρμανσης. Η γραφική παράσταση 4.5 περιγράφει τους κανόνες, σύμφωνα με τους οποίους θα μετατραπεί η ισχύς του συστήματος θέρμανσης για κάθε περίπτωση.



Σχήμα 4.5 Γραφική παράσταση γλωσσικού χώρου καταστάσεων

Όλα τα παραπάνω αποτελούν το βασικό τρόπο σχεδιασμού ενός mamdani ελεγκτή. Η είσοδος σε κάθε περίπτωση ανάλογα με το "ερέθισμα" που θα δέχεται θα υπολογίζει την αντίστοιχη πράξη ελέγχου. Μετά τον υπολογισμό της εξόδου, σύμφωνα με τους κανόνες, ακολουθεί η ασαφοποίηση, δηλαδή ο υπολογισμός μιας πραγματικής τιμής για να ελεγχθεί η διαδικασία.

4.3 Μέθοδος Takagi-Sugeno

Αποτελεί την παραλλαγή της μεθόδου mamdani. Όσον αφορά την ασαφοποίηση και την υπόλοιπη διαδικασία, είναι ακριβώς ίδια. Διαφέρει στη συνάρτηση συμμετοχής εξόδου. Οι συναρτήσεις συμμετοχής με τη μέθοδο Sugeno είναι είτε γραμμικές είτε σταθερές. Όταν οι συναρτήσεις εξόδου είναι σταθερές τότε το σύστημα λέγεται πρώτης τάξης ασαφές μοντέλο Sugeno. Ένας κανόνας με το μοντέλο πρώτης τάξης μπορεί να διατυπωθεί ως εξής:

If x is A and y is B, then z=k.

Όπου A, B ασαφή σύνολα που ορίζουν με τις συναρτήσεις συμμετοχής τα x, y και k είναι μια σταθερή διακριτή τιμή και αποτελεί το αποτέλεσμα (consequent) του κανόνα.


Τα πλεονεκτήματα χρήσης της μεθόδου sugeno είναι τα εξής:

1. Είναι πολύ εύκολο να υπολογιστεί
2. Χρησιμοποιεί γραμμικές τεχνικές για να ελέγξει μη-γραμμικά συστήματα
3. Μπορεί να βελτιστοποιήσει τις παραμέτρους της εξόδου για να βελτιώσει την αποτελεσματικότητα.
4. Μπορεί να αναλυθεί μαθηματικά.

4.4 Νευρο-ασαφή συστήματα

Τα νευρο-ασαφή συστήματα αποτελούν μια υβριδική τεχνική του ευφυούς ελέγχου, που έχει σαν σκοπό να συνδυάσει τα στοιχεία της κάθε τεχνικής ώστε να πετύχει καλύτερα αποτελέσματα. Τα ασαφή συστήματα είναι ικανά να μοντελοποιήσουν την γνώση με περιφραστικούς κανόνες, σε αντίθεσή με τα νευρωνικά δίκτυα που η γνώση κωδικοποιείται με τις μεταβολές των βαρών του δικτύου. Ο υπολογισμός των βαρών του δικτύου βασίζεται σε αριθμητικές μεθόδους, ενώ η επεξεργασία των γλωσσικών κανόνων γίνεται με ασαφή λογική. Παρόλο ότι τα νευρωνικά δίκτυα και τα ασαφή συστήματα έχουν τελείως διαφορετική τεχνική για την αναπαράσταση της γνώσης είναι δυνατόν να έχουμε καλύτερα αποτελέσματα με τον συνδυασμό τους.

Το ANFIS μπορεί να οριστεί σαν ένα σύστημα ασαφούς λογικής εφοδιασμένο με έναν αλγόριθμο εκπαίδευσης. Το σύστημα ασαφούς λογικής είναι "οικοδομημένο" με βάση ένα σύνολο ασαφών κανόνων (IF-THEN), χρησιμοποιώντας αρχές της ασαφούς λογικής, και ο αλγόριθμος εκπαίδευσης προσαρμόζει τις παραμέτρους τους συστήματος της ασαφούς λογικής. Το σύστημα αυτό παρουσιάστηκε από τους Jang και Sun το 1995 και κάνει χρήση ενός υβριδικού κανόνα εκπαίδευσης για να βελτιστοποιήσει τις ασαφείς παραμέτρους ενός πρώτης τάξεως συστήματος Sugeno. Ένα πρώτης τάξης σύστημα Sugeno παρουσιάζεται γραφικά παρακάτω.



Σχήμα 4.6 Αρχιτεκτονική ANFIS για ένα πρώτης τάξης σύστημα Sugeno με δύο εισόδους και δύο κανόνες

4.4.1 ANFIS

Η αρχιτεκτονική του ANFIS στηρίζεται σε δύο σύνολα εκπαιδευόμενων παραμέτρων:

1. Τις παραμέτρους των συναρτήσεων συμμετοχής αιτίου (antecedent) $[a, b, c, d]$, δηλαδή του IF μέρους των κανόνων.
2. Τις πολωνυμικές παραμέτρους $[p, q, r]$ της εξόδου, που καλούνται και παράμετροι αποτελέσματος.

Κατά την εκπαίδευση του ANFIS χρησιμοποιείται ένας αλγόριθμος σταδιακής μείωσης για βελτιστοποίηση των παραμέτρων αιτίου και ένας αλγόριθμος ελαχίστων τετραγώνων για την επίλυση των παραμέτρων του αποτελέσματος. Επειδή χρησιμοποιεί δύο εντελώς διαφορετικούς αλγορίθμους για να επιτύχει μείωση του σφάλματος, ο κανόνας εκπαίδευσης καλείται υβριδικός. Αρχικά ανανεώνονται οι παράμετροι αποτελέσματος με χρήση ενός αλγορίθμου ελαχίστων τετραγώνων και στη συνέχεια ανανεώνονται οι παράμετροι αιτίου με όπισθεν διάδοση των σφαλμάτων που εξακολουθούν να υπάρχουν.

Όπως διαφαίνεται από το σχήμα 4.6 η αρχιτεκτονική του ANFIS αποτελείται από πέντε επίπεδα. Παρακάτω παρατίθεται περιγραφή της αρχιτεκτονικής του ANFIS για ένα πρώτης τάξης σύστημα Sugeno με δύο εισόδους και δύο κανόνες. Με O_i^1 θα χαρακτηριστεί η έξοδος του i κόμβου του επιπέδου 1.

Επίπεδο 1 : Παραγωγή των βαθμών συμμετοχής:

$$O_i^1 = \mu_{A_i}(x)$$

Επίπεδο 2 : Παραγωγή των ενεργοποιούμενων βαρών

$$O_i^2 = w_i = \prod_{j=1}^m \mu_{A_j}(x)$$

Επίπεδο 3 : Κανονικοποίηση των βαρών

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}$$

Επίπεδο 4 : Υπολογισμός των εξόδων των κανόνων με βάση τις παραμέτρους αποτελέσματος

$$O_i^4 = y_i = \bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i)$$

Επίπεδο 5 : Αθροισμα όλων των εισόδων από το τέταρτο επίπεδο

$$O_i^5 = \sum_i y_i = \sum_i \bar{w}_i f_i = (\bar{w}_1 x_1) p_1 + (\bar{w}_1 x_2) q_1 + \bar{w}_1 r_1 + (\bar{w}_2 x_1) p_2 + (\bar{w}_2 x_2) q_2 + \bar{w}_2 r_2$$

Μετά το επίπεδο πέντε γίνεται έλεγχος της τιμής του σφάλματος και σε περίπτωση μη ικανοποιητικής τιμής, χρησιμοποιείται αλγόριθμος βαθμιαίας μείωσης, ο οποίος εκπαιδεύει τις παραμέτρους αιτίου.

Κάθε εποχή εκπαίδευσης του ANFIS, που χρησιμοποιεί υβριδικό κανόνα εκπαίδευσης, αποτελείται από δύο περάσματα. Αρχικά υπολογίζονται οι παράμετροι αποτελέσματος κατά το εμπρόσθιο πέρασμα, με χρήση αλγορίθμου βελτιστοποίησης ελαχίστων τετραγώνων, και στην συνέχεια ενημερώνονται οι παράμετροι αιτίου με χρήση βαθμιαίας μείωσης. Κατά το εμπρόσθιο πέρασμα υπολογίζονται οι έξοδοι όλων των κόμβων μέχρι το επίπεδο 4. Στο επίπεδο 4 υπολογίζονται οι παράμετροι αποτελέσματος. Στη συνέχεια υπολογίζονται οι έξοδοι με τις νέες τιμές των παραμέτρων αποτελέσματος και σήματα σφαλμάτων διαδίδονται πίσω, μέσα από τα επίπεδα για να ενημερώσουν τις παραμέτρους αιτίου.

ΚΕΦΑΛΑΙΟ 5

ΠΕΙΡΑΜΑΤΙΚΟ ΜΕΡΟΣ

5.1 ΠΑΡΟΥΣΙΑΣΗ ΤΩΝ ΧΡΟΝΟΣΕΙΡΩΝ ΘΕΡΜΟΚΡΑΣΙΑΣ ΚΑΙ ΗΛΙΑΚΗΣ ΑΚΤΙΝΟΒΟΛΙΑΣ

5.1.1 Ηλιακή ακτινοβολία


5.1.1.1 Γενικά

Η μελέτη του φυσικού μεγέθους της ηλιακής ακτινοβολίας (solar radiation) έγινε με βάση πραγματικές τιμές μετρήσεων, που προέρχονται από υποσταθμό του Εθνικού Αστεροσκοπείου Αθηνών. Οι τιμές αυτές αποτέλεσαν τα δεδομένα που χρησιμοποιήθηκαν στην εργασία για την τεκμηρίωση της λειτουργικότητας των συστημάτων πρόβλεψης που υλοποιήθηκαν.

Τα δεδομένα είναι ωριαίες τιμές μετρήσεων ηλιακής ακτινοβολίας, επί εικοσιτετραώρου βάσεως για το χρονικό διάστημα 1981-2000 με μονάδα μέτρησης $Watt/m^2$.

5.1.1.2 Επεξεργασία των δεδομένων

Οι μετρήσεις ηλιακής ακτινοβολίας αντιμετωπίστηκαν σαν μια χρονοσειρά δεδομένων. Παρακάτω παρατίθεται μια γραφική παράσταση των δεδομένων, όπως ακριβώς δόθηκαν από το Αστεροσκοπείο:



Σχήμα 5.1 Καμπύλη ωριαίων τιμών ηλιακής ακτινοβολίας

Από την παραπάνω γραφική παράσταση φαίνεται ότι ανάμεσα στις μετρήσεις που έχουν λογικές τιμές ηλιακής ακτινοβολίας συμπεριλαμβάνονται και κάποιες που έχουν αρνητικές τιμές και συγκεκριμένα είναι όλες ίσες με -99.9. Οι τιμές αυτές αποτελούν σφάλματα μέτρησης των οργάνων. Ο αριθμός των τιμών-σφαλμάτων είναι 2394 ενώ ο συνολικός αριθμός μετρήσεων, που έχουμε στη διαθεσή μας, είναι 175320. Τα σφάλματα μέτρησης αποτελούν δηλαδή ένα ποσοστό 0.014% των συνολικών μετρήσεων.

Επειδή τα δεδομένα, που αποτελούν σφάλματα μέτρησης, θα αποτελέσουν πρόβλημα στην ορθή λειτουργία των συστημάτων πρόβλεψης, πρέπει να απαλειφθούν. Σε περίπτωση όμως οριστικής απαλοιφής τους, θα δημιουργηθεί πρόβλημα ασυνέχειας στη χρονοσειρά της ηλιακής ακτινοβολίας. Για αυτό το λόγο ακολουθήθηκε μια διαδικασία αντικατάστασής τους από άλλες τιμές, σύμφωνα με μια μεθοδολογία που θα περιγραφεί παρακάτω.


Πρέπει να σημειωθεί ότι η χρονοσειρά που χρειαζόμαστε για τα συστήματα, θέλουμε να περιέχει μέσες ημερήσιες τιμές ηλιακής ακτινοβολίας, καθώς οι προβλέψεις που θέλουμε να κάνουμε, είναι για μέση ημερήσια ακτινοβολία και όχι για ωριαία. Συνεπώς από τη χρονοσειρά ωριαίων τιμών που έχουμε στη διαθεσή μας, θα πρέπει να δημιουργήσουμε τη χρονοσειρά μέσης ημερήσιας ακτινοβολίας, στην οποία πρέπει να έχουμε λύσει και το πρόβλημα με την ύπαρξη σφαλμάτων μέτρησης.

Είναι χαρακτηριστικό επίσης ότι επειδή η ηλιακή ακτινοβολία είναι ένα μέγεθος που αρκετές ώρες του 24-ώρου παίρνει μηδενικές τιμές(π.χ. τη νύχτα δεν υπάρχει ηλιοφάνεια), θα υπολογίσουμε τη μέση ημερήσια ακτινοβολία, σαν μέσο όρο των μη-μηδενικών τιμών της ακτινοβολίας μέσα στο 24-ωρο, ώστε οι τιμές της χρονοσειράς της μέσης ημερήσιας ακτινοβολίας να μην διαφέρουν σε μεγάλο βαθμό από τις ωριαίες.

Έτσι ακολουθήθηκε η παρακάτω διαδικασία στη χρονοσειρά ωριαίων δεδομένων :

1. Στη θέση των τιμών σφαλμάτων των οργάνων (-99.9) βάζουμε μηδενικά.
2. Για κάθε 24-ωρο υπολογίζουμε το μέσο όρο των μη μηδενικών ωριαίων τιμών και δημιουργούμε τη χρονοσειρά των μέσων ημερησίων τιμών. Αυτό επιτυγχάνεται αντικαθιστώντας αρχικά τις μηδενικές τιμές της χρονοσειράς των ωριαίων τιμών με την συμβολοσειρά NaN(Not a Number), προκειμένου να ληφθούν υπόψη στον υπολογισμό του μέσου όρου του 24-ώρου, μόνο οι πραγματικές τιμές μετρήσεων. Αυτό επιτυγχάνεται με τη συνάρτηση nonzeros του Matlab. Αφού γίνει η παραπάνω αντικατάσταση και υπολογιστούν οι μέσες ημερήσιες τιμές της ηλιακής ακτινοβολίας, παρατηρούμε ότι στη χρονοσειρά που έχει προκύψει υπάρχουν κάποιες μέρες, που έχουν πάρει την τιμή NaN. Αυτό οφείλεται στο γεγονός ότι στη χρονοσειρά των ωριαίων τιμών υπήρχαν ολόκληρα 24-ωρα με σφάλματα μετρήσεων, που είχαν αντικατασταθεί με τη τιμή NaN. Οπότε σε αυτές τις περιπτώσεις ο μέσος όρος που προέκυψε είναι ίσος με NaN. Στη συνέχεια ξαναγίνεται αντικατάσταση στη χρονοσειρά μέσων ημερησίων τιμών των NaN με μηδενικά.
3. Για τις ημέρες που έχουν μηδενική τιμή ακτινοβολίας παίρνουμε τις εξής περιπτώσεις:
 1. Αν η προηγούμενη και η επόμενη μέρα της μέρας με μηδενική τιμή έχουν τιμή διάφορη του μηδενός, αντικαθιστούμε τη τιμή της μέρας αυτής με το μέσο όρο των άλλων δύο ημερών.
 2. Αν η προηγούμενη μέρα αυτής με τη μηδενική τιμή έχει τιμή διάφορη του μηδενός και η επόμενη της έχει μηδενική τιμή, τότε η μέρα που μας ενδιαφέρει, παίρνει την τιμή της προηγούμενης από αυτή μέρας.
 3. Όταν έχουμε περισσότερες από δύο μέρες συνεχόμενες με τιμές μηδενικές, τότε οι τιμές των ημερών αυτών αντικαθίστανται με την πρώτη προηγούμενη μη μηδενική τιμή.

Μετά τα παραπάνω βήματα προέκυψε η χρονοσειρά των μέσων ημερησίων τιμών ηλιακής ακτινοβολίας για την περίοδο 1981-2000, που περιλαμβάνει 7305(175320/24) τιμές. Η γραφική παράσταση της χρονοσειράς των μέσων ημερησίων τιμών ηλιακής ακτινοβολίας για το χρονικό διάστημα 1981-2000 παρατίθεται παρακάτω:



Σχήμα 5.2 Καμπύλη μέσων ημερησίων τιμών ηλιακής ακτινοβολίας

5.1.2 Θερμοκρασία


5.1.2.1 Γενικά

Η μελέτη του φυσικού μεγέθους της θερμοκρασίας (temperature) έγινε επίσης με βάση πραγματικές τιμές μετρήσεων, που προέρχονται από υποσταθμούς του Εθνικού Αστεροσκοπείου Αθηνών. Οι τιμές αυτές αποτέλεσαν τα δεδομένα που χρησιμοποιήθηκαν στην εργασία για την τεκμηρίωση της λειτουργικότητας των συστημάτων πρόβλεψης που υλοποιήθηκαν.

Τα δεδομένα είναι ωριαίες τιμές μετρήσεων θερμοκρασίας, επί εικοσιτετραώρου βάσεως για χρονικό διάστημα 23 χρόνων (1981-2003), με μονάδα μέτρησης τους βαθμούς Κελσίου (C°).

5.1.2.2 Επεξεργασία των δεδομένων

Οι μετρήσεις θερμοκρασίας αντιμετωπίστηκαν σαν μια χρονοσειρά δεδομένων. Παρακάτω παρατίθεται μια γραφική παράσταση των δεδομένων όπως ακριβώς δόθηκαν από το Αστεροσκοπείο:



Σχήμα 5.3 Καμπύλη ωριαίων τιμών θερμοκρασίας

Όπως παρατηρούμε από την παραπάνω γραφική παράσταση πέραν των φυσιολογικών τιμών θερμοκρασίας, που κυμαίνονται από 0~45 (C°) και σε αυτά τα δεδομένα, όπως και σε αυτά της ηλιακής ακτινοβολίας, υπάρχουν τιμές που δηλώνουν σφάλμα του οργάνου μέτρησης και έχουν την τιμή -99.9. Το πλήθος των τιμών αυτών είναι 256 σε ένα σύνολο 201600 τιμών. Τα σφάλματα μέτρησης αποτελούν δηλαδή ένα ποσοστό 0.0013% των συνολικών μετρήσεων.

Τα δεδομένα αυτά, όπως και στην περίπτωση της ηλιακής ακτινοβολίας, είναι απαραίτητο να αντικατασταθούν, προκειμένου οι χρονοσειρές να γίνουν επεξεργάσιμες. Για την απαλοιφή των σφαλμάτων μέτρησης, θα χρησιμοποιηθεί η ίδια μέθοδος που χρησιμοποιήθηκε για την ηλιακή ακτινοβολία με κάποιες


μικρές παραλλαγές. Παίρνουμε λοιπόν τα ωριαία δεδομένα θερμοκρασίας, όπως τα παραλάβαμε απο το Αστεροσκοπείο, και προβαίνουμε στις εξής ενέργειες:

Για τα δεδομένα που ισούνται με -99.9 παίρνουμε τις εξής περιπτώσεις:


1. Αν η προηγούμενη και η επόμενη τιμή της ωριαίας τιμής με τιμή ίση με -99.9 έχουν τιμή διάφορη του -99.9, αντικαθιστούμε τη τιμή αυτή με το μέσο όρο των άλλων δύο τιμών.
2. Αν η προηγούμενη τιμή αυτής με την τιμή -99.9 έχει τιμή διάφορη του -99.9 και η επόμενη της έχει τιμή -99.9, τότε η ωριαία τιμή που μας ενδιαφέρει παίρνει την τιμή της προηγούμενης από αυτή.
3. Όταν έχουμε περισσότερες από δύο ωριαίες τιμές συνεχόμενες με τιμές ίσες με -99.9, τότε οι τιμές αυτών αντικαθίστανται με την πρώτη προηγούμενη μη μηδενική τιμή .

Έτσι προκύπτει η χρονοσειρά ωριαίων δεδομένων που είναι απαλλαγμένη απο τα σφάλματα οργάνων μέτρησης.


Στην περίπτωση της θερμοκρασίας, δημιουργήσαμε τρεις διαφορετικές χρονοσειρές: τη χρονοσειρά των μέσων ημερησίων τιμών θερμοκρασίας, τη χρονοσειρά των μέγιστων ημερησίων τιμών θερμοκρασίας και τη χρονοσειρά των ελάχιστων ημερησίων τιμών θερμοκρασίας. Έτσι παίρνουμε την χρονοσειρά ωριαίων δεδομένων και για την περίπτωση των μέσων ημερησίων τιμών υπολογίζουμε τον μέσο όρο των τιμών για κάθε 24-ωρο. Για την περίπτωση των μέγιστων ημερησίων τιμών υπολογίζουμε τη μέγιστη τιμή για κάθε 24-ωρο και για την περίπτωση των ελάχιστων ημερησίων τιμών, την ελάχιστη τιμή για κάθε 24-ωρο. Οπότε και για τις 3 παραπάνω περιπτώσεις προκύπτουν χρονοσειρές, που περιέχουν 8400 ημερήσιες τιμές δεδομένων θερμοκρασίας. Παρακάτω παρατίθενται οι γραφικές για καθεμία από τις τρεις χρονοσειρές:



Σχήμα 5.4 Καμπύλη μέσων ημερησίων τιμών θερμοκρασίας



Σχήμα 5.5 Καμπύλη ελαχίστων ημερησίων τιμών θερμοκρασίας



Σχήμα 5.6 Καμπύλη μέγιστων ημερησίων τιμών θερμοκρασίας

5.1.3 Κανονικοποίηση των χρονοσειρών ηλιακής ακτινοβολίας και θερμοκρασίας

Στην συγκεκριμένη εργασία χρησιμοποιήθηκαν δύο διαφορετικά είδη κανονικοποίησης, τα οποία εφαρμόστηκαν σε καθεμιά από τις προαναφερθείσες στο κεφάλαιο 5.1.2, χρονοσειρές. Η πρώτη προσέγγιση κανονικοποίησης που χρησιμοποιήθηκε είναι η κανονικοποίηση των δεδομένων, ώστε να έχουν μέση τιμή μηδενική και τυπική απόκλιση μοναδιαία, ενώ η δεύτερη προσέγγιση που χρησιμοποιήθηκε αφορούσε την απεικόνιση των πραγματικών δεδομένων σε ένα εύρος τιμών που κυμαίνεται από 0.1 έως 0.9.

Για την υλοποίηση της κανονικοποίησης με μέση τιμή ίση με μηδέν και τυπική απόκλιση ίση με ένα, σε καθεμιά από τις τιμές των χρονοσειρών των ημερησίων τιμών ηλιακής ακτινοβολίας και θερμοκρασίας εφαρμόστηκε ο τύπος:

$$Y_k = \frac{X_k - \text{mean}}{\text{std}}$$


όπου X_k οι μέσες ημερήσιες τιμές, mean η μέση τιμή όλων των τιμών της χρονοσειράς και std η τυπική απόκλιση των τιμών της χρονοσειράς, για την εκάστοτε χρονοσειρά.

Για την υλοποίηση της κανονικοποίησης με μέγιστη τιμή 0.9 και ελάχιστη τιμή 0.1, σε καθεμιά από τις τιμές των χρονοσειρών των ημερησίων τιμών ηλιακής ακτινοβολίας και θερμοκρασίας εφαρμόστηκε ο τύπος:


$$Y_k = \frac{0.8}{\text{max} - \text{min}} * X_k + \frac{0.1 * \text{max} - 0.9 * \text{min}}{\text{max} - \text{min}}$$

όπου X_k οι μέσες ημερήσιες τιμές, max η μέγιστη τιμή των τιμών της χρονοσειράς και min η ελάχιστη τιμή της χρονοσειράς, για την εκάστοτε χρονοσειρά.


Οπότε στις ήδη υπάρχουσες χρονοσειρές μέσης ημερήσιας ηλιακής ακτινοβολίας, μέσης, μέγιστης και ελάχιστης ημερήσιας θερμοκρασίας προστέθηκαν επιπλέον οχτώ χρονοσειρές, που περιέχουν τις κανονικοποιημένες τιμές τους σύμφωνα με τις προαναφερθείσες μεθόδους κανονικοποίησης. Οι δώδεκα αυτές χρονοσειρές είναι αυτές που θα χρησιμοποιηθούν στη συνέχεια σαν είσοδοι στα συστήματα προβλεψης, που θα υλοποιήσουμε. Παρακάτω παρατίθενται γραφικές χρονοσειρών με κανονικοποιημένες τιμές:



Σχήμα 5.7 Καμπύλη μέγιστων ημερησίων τιμών θερμοκρασίας(0.1-0.9)



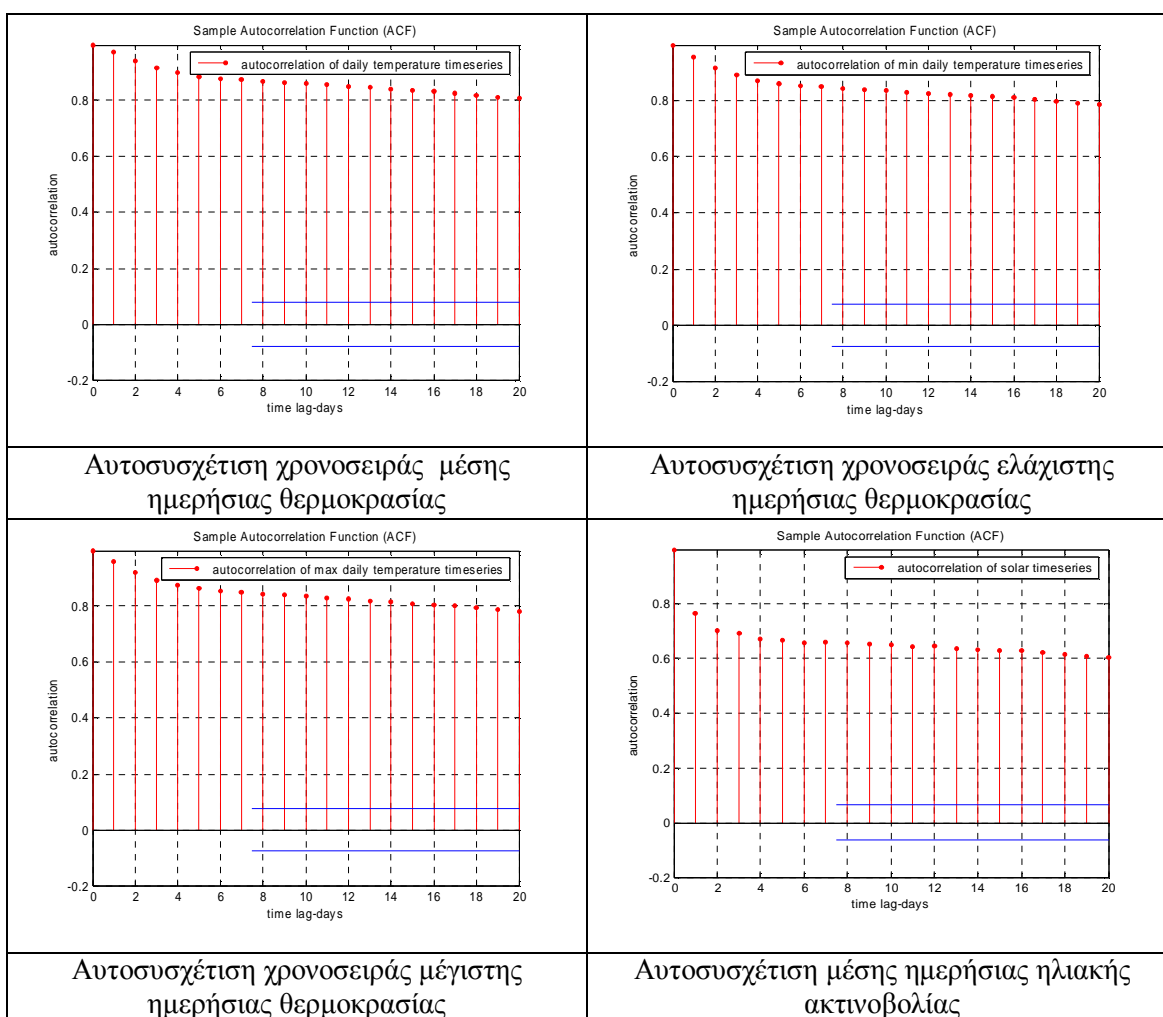
Σχήμα 5.8 Καμπύλη μέσων ημερησίων τιμών θερμοκρασίας(mean=0,std=1)



Σχήμα 5.9 Καμπύλη μέσων ημερησίων τιμών ηλιακής ακτινοβολίας(0.1-0.9)

5.1.4 Αυτοσυσχέτιση των χρονοσειρών ηλιακής ακτινοβολίας και θερμοκρασίας

Στις δικές μας περιπτώσεις χρονοσειρών θα εφαρμόσουμε τη συνάρτηση αυτοσυσχέτισης, προκειμένου να προσδιορίσουμε τη συσχέτιση των διαδοχικών ημερήσιων τιμών ηλιακής ακτινοβολίας και θερμοκρασίας, κάτι που θα αποτελέσει και ένα κριτήριο της ποιότητας και περιοδικότητας των χρονοσειρών, που θα χρησιμοποιηθούν αργότερα στα νευρωνικά συστήματα πρόβλεψης. Επίσης οι γραφικές των αυτοσυσχετίσεων θα μας καθοδηγήσουν με ποιές τιμές lag να προσπαθήσουμε να κάνουμε πρόβλεψη. Παρακάτω παρατίθενται οι αυτοσυσχετίσεις για καθεμιά απ' τις χρονοσειρές.



Σχήμα 5.10 Αυτοσυσχετίσεις χρονοσειρών


Παρατηρώντας τις αυτοσυσχετίσεις των χρονοσειρών συμπεραίνουμε ότι η συσχέτιση μεταξύ των τιμών μειώνεται καθώς αυξάνεται το lag. Βλέπουμε ότι και για

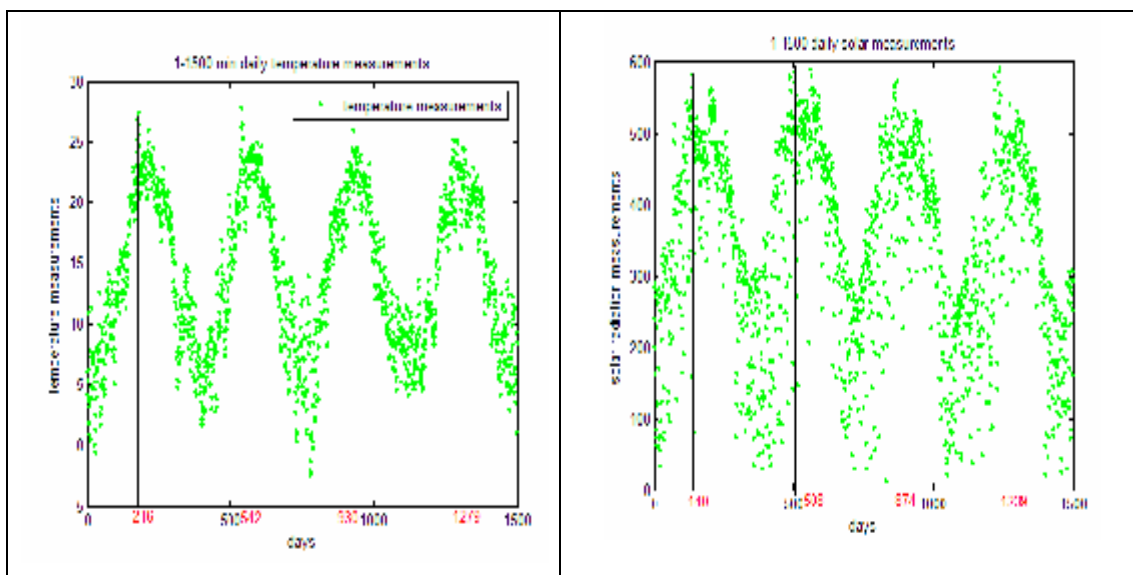
τις τρεις χρονοσειρές η καλύτερη τιμή αυτοσυσχέτισης επιτυγχάνεται για lag ίσο με μια μέρα.

5.1.5 Περίοδος χρονοσειρών

Παρατηρώντας τις κυματομορφές της ημερήσιας ηλιακής ακτινοβολίας καθώς και της μέσης, μέγιστης και ελάχιστης ημερήσιας θερμοκρασίας διαπιστώνουμε ότι η δυναμική και των τεσσάρων χρονοσειρών φέρεται να είναι ντετερμινιστική. Είναι χαρακτηριστικό ότι και στις τέσσερις γραφικές παραστάσεις, το γράφημα προσεγγίζει τη καμπύλη του ημιτόνου. Θεωρήσαμε λοιπόν και τις τέσσερις χρονοσειρές περιοδικές και θελήσαμε να βρούμε προσεγγιστικά την περίοδο τους. Προκειμένου να υλοποιηθεί αυτό απομονώσαμε τις 1500 πρώτες τιμές των χρονοσειρών, τις απεικονίσαμε γραφικά και στη συνέχεια αφού προβάλλαμε τις max τιμές κάθε ανόδου των καμπυλών, στον άξονα χ, υπολογίσαμε τις αποστάσεις των διαδοχικών προβολών τους.

Παρατηρώντας τις αποστάσεις των διαδοχικών προβολών, βλέπουμε ότι αυτές έχουν τιμές που κυμαίνονται απο 335 έως 395 μέρες. Έχοντας λοιπόν υπόψιν ότι ένας χρόνος έχει 365 μέρες, μπορούμε να θεωρήσουμε ότι όλες οι προαναφερθείσες χρονοσειρές είναι «σχεδόν» περιοδικές ($\frac{335 + 395}{2} = 365$ μέρες), με περίοδο ένα έτος. Παρακάτω παρατίθενται οι καμπύλες των χρονοσειρών, ενώ με κόκκινα γράμματα στον άξονα των χ έχουν σημειωθεί οι προβολές, και πιο συγκεκριμένα οι μέρες που έχουμε τις μέγιστες τιμές:





Σχήμα 5.11 Καμπύλες μέσων, μεγίστων, ελαχίστων ημερησίων τιμών θερμοκρασίας και μέσων ημερησίων τιμών ηλιακής ακτινοβολίας με χρήση προβολών για προσεγγιστικό εντοπισμό της περιόδου των χρονοσειρών.

5.1.6 Τροποποίηση χρονοσειρών για χρήση τους στα συστήματα πρόβλεψης

Τα συστήματα πρόβλεψης που θα περιγραφούν στα επόμενα κεφάλαια δέχονται τις χρονοσειρές σαν δεδομένα προς επεξεργασία. Επίσης τα συστήματα αυτά όπως θα περιγραφεί αναλυτικά αργότερα, ακολουθούν αλγορίθμους εκπαίδευσης που στηρίζονται στη μάθηση με εποπτεία (supervised learning). Αυτό σημαίνει ότι τα δεδομένα των χρονοσειρών πρέπει να πάρουν τη μορφή είσοδος-έξοδος του συστήματος πρόβλεψης. Έχοντας εντοπίσει μέσω της αυτοσυσχέτισης το βέλτιστο lag, που είναι η μια ημέρα, με τη βοήθεια των συστημάτων πρόβλεψης, θέλουμε να κάνουμε πρόβλεψη ημερήσιας τιμής ηλιακής ακτινοβολίας και θερμοκρασίας για τις εξής περιπτώσεις:

1. Πρόβλεψη της τιμής μιας ημέρας, χρησιμοποιώντας ως εισόδους τις τιμές των δύο προηγούμενων ημερών.
2. Πρόβλεψη της τιμής μιας ημέρας, χρησιμοποιώντας ως εισόδους τις τιμές των τριών προηγούμενων ημερών.
3. Πρόβλεψη της τιμής μιας ημέρας, χρησιμοποιώντας ως εισόδους τις τιμές των πέντε προηγούμενων ημερών.
4. Πρόβλεψη της τιμής μιας ημέρας, χρησιμοποιώντας ως εισόδους τις τιμές των επτά προηγούμενων ημερών.

Οι δύο, τρεις, πέντε και επτά προηγούμενες ημερήσιες τιμές θα αποτελέσουν τις εισόδους των συστημάτων μας, ενώ η έξοδος τους θα είναι η πρόβλεψη της συγκεκριμένης "παρούσας" ημέρας. Για την εκπαίδευση των συστημάτων θα συγκρίνουμε τη πρόβλεψη της τιμής για τη συγκεκριμένη ημέρα με την πραγματική τιμή της ημέρας αυτής, που τη γνωρίζουμε από τις χρονοσειρές. Συνεπώς οι χρονοσειρές πρέπει να πάρουν τη μορφή: πραγματικοί εισοδοι-πραγματική έξοδος.

Προκειμένου να υλοποιηθεί το προαναφερθέν μοντέλο και έχοντας υπόψη ότι τόσο οι χρονοσειρές με τα πραγματικά δεδομένα, όσο και αυτές με τα κανονικοποιημένα δεδομένα έχουν τη μορφή στήλης συνεχόμενων ημερησίων δεδομένων εφαρμόστηκαν τα παρακάτω:

1. Φορτώθηκε το αρχείο που συμπεριλάμβανε την καθεμία από τις χρονοσειρές.
2. Με ένα loop διατρήθηκαν όλες οι τιμές της χρονοσειράς.
3. Για κάθε τιμή δημιουργήθηκε ένα πρότυπο εκπαίδευσης πραγματικών εισόδων - πραγματικής (επιθυμητής) εξόδου, στο οποίο πρότυπο η τιμή αυτή αποτελεί την πρώτη απ' τις τιμές εισόδου.

Πρακτικά υλοποιήθηκε ένας πίνακας που είχε αριθμό γραμμών όσες οι τιμές των δεδομένων, και αριθμό στηλών όσες ήταν οι επιθυμητοί εισοδοι, συν μια στήλη για την επιθυμητή έξοδο. Κάθε γραμμή του πίνακα περιέχει ένα πρότυπο εκπαίδευσης, π.χ. για την περίπτωση πρόβλεψης της τιμής μια ημέρας χρησιμοποιώντας τις τιμές δύο προηγούμενων ημερών, αν η χρονοσειρά έχει όνομα *chron*, και είμαστε στη τιμή *chron(t)*, τότε η αντίστοιχη γραμμή του πίνακα θα είναι:

[*chron(t)* *chron(t+1)* *chron(t+2)*].

4. Αποθήκευση του πίνακα σε αρχείο με κατάληξη .txt.

Στο παρακάτω σχήμα φαίνεται ο πίνακας που περιλαμβάνει τα 20 πρώτα πρότυπα εκπαίδευσης για πρόβλεψη με τιμές πέντε προηγούμενων ημερών σαν εισόδους, για τις αντίστοιχες πρώτες 20 τιμές της χρονοσειράς των μέγιστων ημερήσιων τιμών θερμοκρασίας με πραγματικά δεδομένα.

12.5000	12.500000	12.200000	8.300000	14.700000	15.400000	9.900000
12.2000	12.200000	8.300000	14.700000	15.400000	9.900000	4.800000
8.3000	8.300000	14.700000	15.400000	9.900000	4.800000	5.400000
14.7000	14.700000	15.400000	9.900000	4.800000	5.400000	3.900000
15.4000	15.400000	9.900000	4.800000	5.400000	3.900000	3.300000
9.9000	9.900000	4.800000	5.400000	3.900000	3.300000	10.300000

4.8000	4.800000	5.400000	3.900000	3.300000	10.300000	12.400000
5.4000	5.400000	3.900000	3.300000	10.300000	12.400000	13.600000
3.9000	3.900000	3.300000	10.300000	12.400000	13.600000	14.100000
3.3000	3.300000	10.300000	12.400000	13.600000	14.100000	13.100000
10.3000	10.300000	12.400000	13.600000	14.100000	13.100000	13.200000
12.4000	12.400000	13.600000	14.100000	13.100000	13.200000	9.100000
13.6000	13.600000	14.100000	13.100000	13.200000	9.100000	12.500000
14.1000	14.100000	13.100000	13.200000	9.100000	12.500000	13.600000
13.1000	13.100000	13.200000	9.100000	12.500000	13.600000	10.700000
13.2000	13.200000	9.100000	12.500000	13.600000	10.700000	9.700000
9.1000	9.100000	12.500000	13.600000	10.700000	9.700000	9.100000
12.5000	12.500000	13.600000	10.700000	9.700000	9.100000	10.200000
13.6000	13.600000	10.700000	9.700000	9.100000	10.200000	7.900000
10.7000	10.700000	9.700000	9.100000	10.200000	7.900000	10.900000
	1 ^η είσοδος	2 ^η είσοδος	3 ^η είσοδος	4 ^η είσοδος	5 ^η είσοδος	έξοδος
Χρονοσειρά	Πίνακας προτύπων εκπαίδευσης					

Σχήμα 5.12 Χρονοσειρά max ημερησίων τιμών θερμοκρασίας - Πίνακας προτύπων 5 εισόδων-1 εξόδου

5.2 ΠΡΟΒΛΕΨΗ ΜΕ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ (Neural Network Prediction)

5.2.1 Εισαγωγή

Όπως προαναφέρθηκε στο κεφάλαιο 2, τα νευρωνικά δίκτυα είναι ικανά να μαθαίνουν και να γενικεύουν μέσω της εμπειρίας. Στην περίοδο που διανύουμε τα νευρωνικά δίκτυα χρησιμοποιούνται σε ένα μεγάλο εύρος εφαρμογών σε διαφορετικούς τομείς των επιχειρήσεων, της βιομηχανίας και της έρευνας. Ένας μείζων τομέας εφαρμογής των νευρωνικών δικτύων είναι η πρόβλεψη. Τα νευρωνικά δίκτυα έχουν χρησιμοποιηθεί για επίλυση αρκετών προβλημάτων πρόβλεψης όπως: των χαοτικών χρονοσειρών, οικονομικών εφαρμογών, βιομηχανικής παραγωγής, ηλεκτρικού φορτίου, μετεωρολογικών παραμέτρων. Στη συγκεκριμένη εργασία τα νευρωνικά δίκτυα θα χρησιμοποιηθούν για τη πρόβλεψη της θερμοκρασίας και της ηλιακής ακτινοβολίας. Για την εκπαίδευση των νευρωνικών δικτύων, για την πρόβλεψη των προαναφερθέντων παραμέτρων, θα χρησιμοποιηθεί η γενική μεθοδολογία εκπαίδευσης νευρωνικών δικτύων, που παρουσιάστηκε στην παράγραφο 2.5.

5.2.2 Ανάπτυξη νευρωνικών δικτύων πρόβλεψης

Στόχος είναι η ανάπτυξη νευρωνικών δικτύων που θα διαφέρουν στη κανονικοποίηση των δεδομένων της χρονοσειράς (πραγματικά δεδομένα- κανονικοποιημένα δεδομένα), στον αριθμό εισόδων, στον αριθμό κόμβων στο

ενδιάμεσο στρώμα, στις συναρτήσεις ενεργοποίησης, ώστε τελικά χρησιμοποιώντας κάποια κριτήρια απόδοσης να καταλήξουμε στα καλύτερα νευρωνικά, τα οποία θα χρησιμοποιηθούν περαιτέρω για υλοποίηση συστημάτων πρόβλεψης συλλογικής μάθησης. Χρησιμοποιώντας τη μεθοδολογία εκπαίδευσης θα δείξουμε βηματικά την υλοποίηση και την εκπαίδευση των νευρωνικών δικτύων για την ηλιακή ακτινοβολία και την θερμοκρασία ξεχωριστά.

5.2.2.1 Διαδικασία πρόβλεψης

5.2.2.1.1 Δεδομένα εκπαίδευσης – Δεδομένα δοκιμής

Ηλιακή Ακτινοβολία

Όπως έχει περιγραφεί στη παράγραφο 5.1, τα δεδομένα που έχουμε στη διάθεση μας είναι διάρκειας 20 χρόνων (1981-2000). Στόχος μας είναι να γίνει πρόβλεψη σε επίπεδο ημερήσιο, οπότε οι αρχικά ωριαίες τιμές έχουν μετατραπεί σε ημερήσιες. Προκειμένου να εκπαιδευτούν τα δίκτυα, τα τρία σετ δεδομένων που έχουν δημιουργηθεί (πραγματικά ημερήσια δεδομένα-κανονικοποιημένα δεδομένα με μέση τιμή μηδέν και διακύμανση ένα, κανονικοποιημένα δεδομένα 0.1-0.9) και περιλαμβάνουν τιμές 20 χρόνων (7305 ημερήσιες τιμές) πρέπει να διαχωριστούν σε σετ δεδομένων εκπαίδευσης και σετ δεδομένων δοκιμής (εξακρίβωσης). Το σετ δεδομένων εκπαίδευσης θα χρησιμοποιηθεί για ανάπτυξη του μοντέλου του Ν.Δ. (Νευρωνικού Δικτύου), και το σετ δεδομένων δοκιμής για αξιολόγηση της δυνατότητας πρόβλεψης του μοντέλου. Για το διαχωρισμό δεν υπάρχει ένα πάγιο μοντέλο, αλλά γενικά πρέπει τόσο το σετ δεδομένων εκπαίδευσης όσο και το σετ δεδομένων ελέγχου να αποτελούν ένα αντιπροσωπευτικό δείγμα των δεδομένων. Το σετ δεδομένων εκπαίδευσης σίγουρα πρέπει να αποτελεί το μεγαλύτερο απ' τα δύο σετ. Έτσι αποφασίστηκε το σετ δεδομένων εκπαίδευσης να αποτελεί το 0.75 των συνολικών δεδομένων και το σετ δεδομένων ελέγχου το 0.25. Δηλαδή θα κάνουμε training των δικτύων για 15 χρόνια και test για 5 χρόνια.

Στη συνέχεια τέθηκε θέμα για το ποιά πέντε χρόνια θα χρησιμοποιηθούν σαν σετ δεδομένων ελέγχου απ' τις συνολικά τέσσερις πενταετίες των είκοσι χρόνων δεδομένων. Το πρόβλημα αυτό αντιμετωπίστηκε με τη χρήση της μεθόδου multifold cross-validation. Εκπαιδεύσαμε ένα απλό δίκτυο δύο εισόδων, τριών κόμβων στο ενδιάμεσο στρώμα και μιας εξόδου, με χρήση του backpropagation αλγορίθμου, με πραγματικά δεδομένα, τέσσερις φορές, χρησιμοποιώντας κάθε φορά διαφορετικά 15

χρόνια σαν σύνολο δεδομένων εκπαίδευσης και αντίστοιχα διαφορετική πενταετία σαν σετ δεδομένων ελέγχου. Από τις τέσσερις αυτές εκπαιδεύσεις αποδείχτηκε ότι οποιαδήποτε περίπτωση και να χρησιμοποιήσουμε προκύπτει περίπου το ίδιο σφάλμα πρόβλεψης. Έτσι καταλήξαμε να χρησιμοποιήσουμε σαν σετ δεδομένων εκπαίδευσης τα πρώτα 15 χρόνια(1981-1995) και σαν σετ δεδομένων ελέγχου τα υπόλοιπα 5(1996-2000). Συνεπώς οι ημερήσιες τιμές 1-5478 των τριών διαφορετικών χρονοσειρών αποτελούν το σετ δεδομένων εκπαίδευσης και οι 5479-7305, το σετ δεδομένων ελέγχου.

Αφού έχουμε διαχωρίσει τις χρονοσειρές πρέπει να προβούμε στη διαδικασία που περιγράφεται στη παράγραφο 5.1.6 ώστε τα διαχωρισμένα δεδομένα να έρθουν στη μορφή πινάκων προτύπων ανάλογα με τον αριθμό εισόδων του νευρωνικού και θα χρησιμοποιηθούν στη συνέχεια στην εκπαίδευση των νευρωνικών δικτύων.

Θερμοκρασία

Στη περίπτωση της θερμοκρασίας έχουμε τιμές από 23 χρόνια (1981-2003). Έχουμε δηλαδή ένα σύνολο 8400 ημερησίων τιμών. Για τη θερμοκρασία αποφασίστηκε τα 15 χρόνια τιμών να αποτελέσουν τα δεδομένα εκπαίδευσης και τα υπόλοιπα 8 να αποτελέσουν τα δεδομένα ελέγχου. Όπως και στην περίπτωση της ηλιακής ακτινοβολίας έτσι και στη θερμοκρασία έγινε χρήση της multifold cross-validation μεθόδου, διαχωρίζοντας τα 23 χρόνια σε 2 οχταετίες και μία εφταετία και αφού έγινε εκπαίδευση διαπιστώθηκε ότι το σφάλμα που προέκυπτε ήταν περίπου το ίδιο. Οπότε σαν σετ δεδομένων εκπαίδευσης χρησιμοποιήθηκαν οι τιμές των πρώτων 15 χρόνων (1981-1995), που είναι οι ημερήσιες τιμές 1-5478, και σαν σετ δεδομένων ελέγχου χρησιμοποιήθηκαν οι τιμές των υπόλοιπων οχτώ χρόνων (1996-2003), που είναι οι τιμές 5479-8400.

Μετά το διαχωρισμό των τιμών, δημιουργήθηκαν οι πίνακες προτύπων σύμφωνα με τη διαδικασία που περιγράφεται στη παράγραφο 5.1.6, και πλέον τα σετ δεδομένων είναι έτοιμα να διοχετευτούν στην εκπαίδευση των νευρωνικών πρόβλεψης θερμοκρασίας.

5.2.2.1.2 Δομή των νευρωνικών δικτύων

Ηλιακή ακτινοβολία και θερμοκρασία

Η δομή των νευρωνικών δικτύων αποτελεί ένα σημαντικό θέμα συζήτησης και τίθενται αρκετά ερωτήματα προτού καταλήξουμε σε συγκεκριμένη αρχιτεκτονική.

Όσον αφορά τις εισόδους τους, απ' τη στιγμή που θέλουμε να κάνουμε πρόβλεψη της τιμής μιας ημέρας, έχοντας σαν δεδομένα τις τιμές δύο, τριών, πέντε ή επτά προηγούμενων ημερών, θεωρείται δεδομένο ότι τις εισόδους στα νευρωνικά θα αποτελέσουν οι εκάστοτε προηγούμενες τιμές. Συνεπώς θα δημιουργηθούν Ν.Δ. δύο, τριών, πέντε και επτά εισόδων.

Στη συνέχεια τίθεται το ζήτημα του αριθμού των ενδιάμεσων στρώματων που θα έχουν τα Ν.Δ. και του αριθμού των κόμβων που θα τα αποτελούν. Γενικά για τα ενδιάμεσα στρώματα ισχύουν τα εξής:


1. Τα τοπικά χαρακτηριστικά αναδεικνύονται από το πρώτο κρυφό στρώμα. Πιο συγκεκριμένα κάποιοι νευρώνες στο πρώτο κρυφό στρώμα χρησιμοποιούνται για να διαχωρίσουν το δειγματοχώρο εισόδου σε περιοχές και κάποιοι άλλοι του ίδιου στρώματος, για να μάθουν τα τοπικά χαρακτηριστικά, χαρακτηρίζοντας τις περιοχές αυτές.
2. Τα γενικά χαρακτηριστικά αναδεικνύονται στο δεύτερο κρυφό στρώμα. Συγκεκριμένα, ένας νευρώνας στο δεύτερο κρυφό στρώμα συνδυάζει τις εξόδους των νευρώνων του πρώτου κρυφού στρώματος λειτουργώντας σε μια συγκεκριμένη περιοχή του δειγματοχώρου εισόδου και έτσι μαθαίνει τα γενικά χαρακτηριστικά της περιοχής αυτής, ενώ οπουδήποτε εκτός της περιοχής αυτής βγάζει έξοδο μηδέν.(Funahashi 1989,Chester,1990)

Στη δική μας περίπτωση οι χρονοσειρές μας έχουν τοπικά χαρακτηριστικά (ημερήσια). Οπότε δεν μας χρειάζεται δεύτερο ενδιάμεσο στρώμα. Συνεπώς όλα τα Ν.Δ. θα έχουν ένα ενδιάμεσο στρώμα. Όσον αφορά τον αριθμό των κόμβων του ενδιάμεσου στρώματος αυτός προκύπτει εμπειρικά μετά από αρκετές προσομοιώσεις. Πάντως από μελέτες άλλες σχετικά με πρόβλεψη έχει προκύψει ότι ο αριθμός κόμβων θα πρέπει να είναι ίσος ή μεγαλύτερος απ'τον αριθμό των προτύπων εισόδου του στρώματος. Εμείς για όλα τα Ν.Δ. που δημιουργήσαμε πήραμε τις εξής περιπτώσεις: δύο, τρείς, πέντε, δέκα και δεκαπέντε κόμβους.

Τέλος θα έχουμε μία έξοδο, καθώς θέλουμε να κάνουμε πρόβλεψη για μια ημερήσια τιμή.

Επιπρόσθετα τίθεται και το θέμα των συναρτήσεων ενεργοποίησης που θα χρησιμοποιούνται σε καθένα απ' τους νευρώνες του νευρωνικού δικτύου. Γενικά συνηθίζεται στα προβλήματα πρόβλεψης, οι κόμβοι εξόδου να έχουν γραμμική συνάρτηση ενεργοποίησης, σε αντίθεση με προβλήματα ταξινόμησης που προτιμάται η σιγμοειδής συνάρτηση. Όσον αφορά τους νευρώνες των ενδιαμέσων στρωμάτων ως επί τω πλείστω χρησιμοποιούνται οι εξής συναρτήσεις ενεργοποίησης: γραμμική, σιγμοειδής, υπερβολική εφαπτομένη. Μέχρι τώρα καμία έρευνα δεν έχει επαληθεύσει τη σχετική απόδοση των προαναφερθείσων συναρτήσεων ενεργοποίησης, οπότε δεν υφίστανται καθόλου πειραματικά αποτελέσματα, που να υποστηρίζουν την προτίμηση τη μίας ή της άλλης. Στη δική μας περίπτωση έγιναν μερικές προσομοιώσεις και αποδείχτηκε ότι η χρήση της υπερβολικής εφαπτομένης έδωσε ίδια αποτελέσματα με αυτά της σιγμοειδούς. Οπότε προσομοιώσαμε τα νευρωνικά δίκτυα για τις περιπτώσεις της γραμμικής και της σιγμοειδούς συνάρτησης ενεργοποίησης.

Συνεπώς υλοποιήθηκαν οι εξής περιπτώσεις νευρωνικών δικτύων:



Σχήμα 5.13: Γενική περιγραφή νευρωνικού που χρησιμοποιήθηκε

Είσοδοι:

1. Χρονοσειρά μέσω των ημερησίων τιμών των δεδομένων ηλιακής ακτινοβολίας
2. Χρονοσειρά μέσω των ημερησίων τιμών των δεδομένων θερμοκρασίας
3. Χρονοσειρά μέγιστων ημερησίων τιμών των δεδομένων θερμοκρασίας
2. Χρονοσειρά ελάχιστων ημερησίων τιμών των δεδομένων θερμοκρασίας

με καθεμιά από τις παραπάνω περιπτώσεις χρονοσειρών να περιλαμβάνει τις εξής υποπεριπτώσεις:

α. Πραγματικές τιμές με τις εξής περιπτώσεις:

- i. 2 προηγούμενες ημερήσιες τιμές σαν εισόδους.
- ii. 3 προηγούμενες ημερήσιες τιμές σαν εισόδους.
- iii. 5 προηγούμενες ημερήσιες τιμές σαν εισόδους.
- iv. 7 προηγούμενες ημερήσιες τιμές σαν εισόδους.

β. Κανονικοποιημένες με κανονικοποίηση μέσης τιμής μηδενικής και τυπικής απόκλισης μοναδιαίας με τις εξής περιπτώσεις:

- i. 2 προηγούμενες ημερήσιες τιμές σαν εισόδους.
- ii. 3 προηγούμενες ημερήσιες τιμές σαν εισόδους.
- iii. 5 προηγούμενες ημερήσιες τιμές σαν εισόδους.
- iv. 7 προηγούμενες ημερήσιες τιμές σαν εισόδους.

γ. Κανονικοποιημένες τιμές με κανονικοποίηση 0.1-0.9 με τις εξής περιπτώσεις:

- i. 2 προηγούμενες ημερήσιες τιμές σαν εισόδους.
- ii. 3 προηγούμενες ημερήσιες τιμές σαν εισόδους.
- iii. 5 προηγούμενες ημερήσιες τιμές σαν εισόδους.
- iv. 7 προηγούμενες ημερήσιες τιμές σαν εισόδους.

Δηλαδή θα δημιουργηθούν νευρωνικά 2,3,5 και 7 εισόδων.

Ενδιάμεσο στρώμα:

Στο ενδιάμεσο στρώμα θα έχουμε τις εξής περιπτώσεις αριθμού κόμβων(νευρώνων)

- 1. 2 κόμβων
- 2. 3 κόμβων
- 3. 5 κόμβων
- 4. 10 κόμβων
- 5. 15 κόμβων

και για καθεμιά από τις παραπάνω περιπτώσεις θα περιλαμβάνονται οι υποπεριπτώσεις:

- α. Γραμμική συνάρτηση ενεργοποίησης νευρώνα
- β. Σιγμοειδής συνάρτηση ενεργοποίησης νευρώνα.

Έξοδος:

Η έξοδος θα περιλαμβάνει ένα νευρώνα με γραμμική συνάρτηση ενεργοποίησης.

5.2.2.1.3 Μέθοδος Εκπαίδευσης

Ηλιακή ακτινοβολία και θερμοκρασία

Η εκπαίδευση των νευρωνικών δικτύων είναι ένα χωρίς περιορισμούς, μη γραμμικό πρόβλημα ελαχιστοποίησης, όπου τα συναπτικά βάρη τροποποιούνται επαναληπτικά, προκειμένου να ελαχιστοποιήσουν το μέσο ή συνολικό τετραγωνικό σφάλμα μεταξύ των επιθυμητών και των πραγματικών εξόδων, για όλους τους κόμβους εξόδου και για όλα τα πρότυπα εισόδου. Υπάρχουν πολλές μέθοδοι βελτιστοποίησης, με αποτέλεσμα να υπάρχουν πολλές επιλογές για εκπαίδευση του Ν.Δ.. Δεν υπάρχει όμως κανένας αλγόριθμος που να εγγυάται τη συνολικά βέλτιστη λύση για ένα γενικό μη-γραμμικό πρόβλημα βελτιστοποίησης σε ένα λογικό χρονικό διάστημα.

Προκειμένου να καταλήξουμε σε ένα συγκεκριμένο αλγόριθμο τον οποίο θα χρησιμοποιήσουμε για να εκπαιδεύσουμε όλα τα νευρωνικά δίκτυα που δημιουργήσαμε και με δεδομένο ότι για την εργασία έγινε χρήση του neural toolbox του προγράμματος matlab, που έχει ενσωματωμένους ένα πλήθος αλγορίθμων εκπαίδευσης Ν.Δ., επελέξαμε ένα μικρό Ν.Δ. τριών εισόδων, 10 κόμβων στο κρυφό στρώμα και μιας εξόδου, με σιγμοειδή συνάρτηση ενεργοποίησης για το κρυφό στρώμα και γραμμική για το στρώμα εξόδου και το τρέξαμε για κανονικοποιημένα δεδομένα με κανονικοποίηση 0.1-0.9, για τις όλες τις περιπτώσεις αλγορίθμων. Προκειμένου να διαπιστωθεί ποιός αλγόριθμος είναι ο καταλληλότερος χρησιμοποιήθηκαν οι εξής μετρικές απόδοσης:

M.S.E.=Mean Square Error (Μέσο τετραγωνικό σφάλμα)


R.M.S.E=Root Mean Square Error (Ρίζα του μέσου τετραγωνικού σφάλματος)

A.M.E.=Absolute Mean Error (Απόλυτο μέσο σφάλμα)


N.D.E.I=Normalized Root Mean Square Error Index (Κανονικοποιημένος δείκτης ρίζας μέσου τετραγωνικού σφάλματος)

ρ =Correlation Coefficient (Συντελεστής συσχέτισης)


Οι προαναφερθείσες μετρικές θα περιγραφούν αργότερα. Παρακάτω παρατίθενται οι γραφικές παραστάσεις με τις τιμές των μετρικών για καθέναν από τους αλγορίθμους.




Mean Square Error




Root Mean Square Error



Absolute Mean Error



Normalized Root Mean Square Error Index



Σχήμα 5.14 Γραφική απεικόνιση μετρικών απόδοσης των αλγορίθμων εκπαίδευσης

Στις παραπάνω γραφικές παραστάσεις στο Y-άξονα συμβολίζονται οι τιμές της εκάστοτε μετρικής και στον X-άξονα, ο καθένας από τους 13 αλγορίθμους εκπαίδευσης που χρησιμοποιήθηκαν. Οι αλγόριθμοι εκπαίδευσης που χρησιμοποιήθηκαν είναι οι εξής:

1. Quasi Newton Backpropagation(trainbfg)
2. Bayesian regularization backpropagation(trainbr)
3. Conjugate gradient backpropagation with Powell-Beale restarts(traincgb)
4. Conjugate gradient backpropagation with Fletcher-Reeves updates(traincgf)
5. Conjugate gradient backpropagation with Polak-Ribiere updates(traincgp)
6. Gradient descent backpropagation(traingd)
7. Gradient descent with adaptive learning rate backpropagation(traingda)
8. Gradient descent with momentum backpropagation(traingdm)
9. Gradient descent with momentum and adaptive learning rate backpropagation (traingdx)
10. Levenberg-Marquardt backpropagation(trainlm)

11. One step secant backpropagation(trainoss)
12. Resilient backpropagation(trainrp)
13. Scaled conjugate gradient backpropagation(trainscg)

Η παραπάνω αρίθμηση είναι η αντιστοίχη και στις γραφικές. Παρατηρώντας τις γραφικές και πιο συγκεκριμένα τις τιμές των μετρικών για καθέναν από τους αλγορίθμους, συμπεραίνουμε ότι καταλληλότερος αλγόριθμος για εκπαίδευση των νευρωνικών μας δικτύων είναι ο Levenberg-Marquardt Backpropagation. Πρέπει να επισημανθεί ότι ο συγκεκριμένος αλγόριθμος δεν είχε τον πιο γρήγορο χρόνο εκπαίδευσης, αλλά σε σχέση με τους αλγόριθμους που ήταν πιο γρήγοροι απ' αυτόν είχε πολύ καλύτερες τιμές μετρικών, ενώ όποιοι αλγόριθμοι τον πλησίαζαν σε τιμές μετρικών ήταν πολύ πιο αργοί απ' αυτόν.

5.2.2.1.4 Μετρικές απόδοσης

Παρά το γεγονός ότι μπορεί να υπάρχουν αρκετά μέτρα απόδοσης για ένα νευρωνικό δίκτυο πρόβλεψης, όπως ο χρόνος εκπαίδευσης, το βασικό και πιο σημαντικό μέτρο απόδοσης είναι η ακρίβεια-εγκυρότητα πρόβλεψης που μπορεί να επιτευχθεί μετά την εκπαίδευση. Μια μετρική συχνά χρησιμοποιούμενη είναι το σφάλμα πρόβλεψης, που είναι η διαφορά μεταξύ της πραγματικής τιμής (επιθυμητής) και της προβλεπόμενης. Υπάρχει ένας αριθμός μετρικών ακρίβειας που χρησιμοποιούνται και καθεμιά απ' αυτές έχει τα πλεονεκτήματά της και τα μειονεκτήματά της. Η απόδοση των μοντέλων πρόγνωσης που υλοποιήθηκαν υπολογίστηκε με βάση τα εξής κριτήρια: MSE, RMSE, AME, NDEI, ρ. Οι τύποι υπολογισμού των κριτηρίων αυτών είναι οι εξής:

$$1. \text{MSE} = \frac{1}{n} \sum_{k=1}^n (x(k) - \hat{x}(k))^2$$

$$2. \text{RMSE} = \sqrt{\frac{1}{n} \sum_{k=1}^n (x(k) - \hat{x}(k))^2}$$

$$3. \text{AME} = \frac{1}{n} \sum_{k=1}^n |x(k) - \hat{x}(k)|$$

$$4. \text{NDEI} = \frac{\text{RMSE}}{s} = \sqrt{\frac{\sum_{k=1}^n (x(k) - \hat{x}(k))^2}{\sum_{k=1}^n x^2(k)}}$$

$$5. r = \frac{\sum_{k=1}^n (x(k) - \bar{x}) \cdot (\hat{x}(k) - \bar{\hat{x}})}{\sqrt{\sum_{k=1}^n (x(k) - \bar{x})^2 \cdot \sum_{k=1}^n (\hat{x}(k) - \bar{\hat{x}})^2}}$$

M.S.E.= Mean Square Error (Μέσο τετραγωνικό σφάλμα)

R.M.S.E= Root Mean Square Error (Ρίζα του μέσου τετραγωνικού σφάλματος)

A.M.E.= Absolute Mean Error (Απόλυτο μέσο σφάλμα)

N.D.E.I= Normalized Root Mean Square Error Index (Κανονικοποιημένος δείκτης ρίζας μέσου τετραγωνικού σφάλματος)

ρ = Correlation Coefficient (Συντελεστής συσχέτισης)

Όπου $x(k)$ είναι η πραγματική τιμή για τη χρονική στιγμή k , $\hat{x}(k)$ είναι η προβλεπόμενη τιμή (έξοδος μοντέλου) τη χρονική στιγμή k , n είναι το πλήθος των δεδομένων ελέγχου που χρησιμοποιούνται για τη πρόβλεψη, \bar{x} , $\bar{\hat{x}}$ είναι οι μέσες τιμές των παρατηρημένων και των προβλεπόμενων τιμών αντίστοιχα, σ είναι η τυπική απόκλιση των τιμών στόχων. Ο συντελεστής συσχέτισης ρ μετράει πόσο καλά συσχετίζονται οι προβλεπόμενες τιμές με τις πραγματικές τιμές. Ουσιαστικά τιμή του συντελεστή συσχέτισης κοντά στη μονάδα σημαίνει καλύτερη πρόβλεψη.

5.2.3 Εκπαίδευση νευρωνικών δικτύων – Αποτελέσματα προβλέψεων

5.2.3.1 Ηλιακή ακτινοβολία

Η εκπαίδευση των νευρωνικών δικτύων για τα δεδομένα της ηλιακής ακτινοβολίας, όπως προαναφέρθηκε, έγινε με τη μέθοδο Levenberg-Marquardt backpropagation και οι παράμετροι της εκπαίδευσης, mse_goal(στόχος εκπαίδευσης για μέσο τετραγωνικό σφάλμα), epochs (εποχές εκπαίδευσης), Learning Rate (ρυθμός μάθησης), πήραν τις εξής αρχικές τιμές:

1. Για πραγματικές τιμές δεδομένων: mse_goal = 5000
Epochs = 200
Lr = 0.075
2. Για κανονικοποίηση mean=0, std=1: mse_goal = 0.6
Epochs = 200
Lr = 0.1
3. Για κανονικοποίηση 0.1-0.9: mse_goal = 0.01

Epochs = 200

Lr = 0.1

Παρατηρήσεις

Για την επιλογή των συγκεκριμένων τιμών παραμέτρων προηγήθηκαν προσομοιώσεις οι οποίες μας οδήγησαν στις συγκεκριμένες αρχικές τιμές. Δηλαδή οι παραπάνω τιμές προέκυψαν εμπειρικά. Κατά τη διαδικασία των διαδοχικών προσομοιώσεων με διαφορετικές τιμές για τις παραμέτρους, παρατηρήθηκε σε κάποιες περιπτώσεις νευρωνικών δικτύων υπερπροσαρμογή (overfitting), π.χ. στο 2-15-1 νευρωνικό δίκτυο για κανονικοποιημένα δεδομένα 0.1-0.9, παρατηρήθηκε υπερπροσαρμογή στην περίπτωση όπου ο αριθμός των εποχών εκπαίδευσης αυξήθηκε σε 350.

Μετά την εκπαίδευση των νευρωνικών δικτύων για όλες τις περιπτώσεις που προαναφέρθηκαν (διαφορετικές κανονικοποιήσεις δεδομένων χρονοσειράς, διαφορετικός αριθμός εισόδων νευρωνικού, διαφορετικός αριθμός κόμβων στο ενδιάμεσο στρώμα, διαφορετικές συναρτήσεις ενεργοποίησης νευρώνων ενδιάμεσου στρώματος), προκειμένου να κατασταλλάξουμε στις τέσσερις καλύτερες σε προβλεψεις περιπτώσεις νευρωνικών δικτύων, οι οποίες θα χρησιμοποιηθούν στη συνέχεια σαν experts στις μηχανές νευρωνικών δικτύων, αρχικά επιλέξαμε τις τέσσερις καλύτερες περιπτώσεις νευρωνικών για κάθε διαφορετική κανονικοποίηση. Η επιλογή αυτή έγινε με βάση τις τιμές των μετρικών απόδοσης, για τα δεδομένα ελέγχου, που περιγράφηκαν παραπάνω. Παρακάτω παρατίθενται πίνακες με τις 4 καλύτερες περιπτώσεις για κάθε κανονικοποίηση. Στο παράρτημα παρατίθενται οι πίνακες 1, 2, 3 που περιλαμβάνουν τα αποτελέσματα εκπαίδευσης των νευρωνικών για όλες τις περιπτώσεις.

Πραγματικά δεδομένα						
Νευρωνικό δίκτυο	Συνάρτηση Ενεργοποίησης	MSE	AME	RMSE	p	NDEI
7-3-1	Γραμμική	7483.011	63.2687	86.5044	0.81433	0.22256
5-3-1	Γραμμική	7652.773	63.9124	87.4801	0.80998	0.22518
3-5-1	Σιγμοειδής	7782	63.986	88.2199	0.80667	0.2271
3-3-1	Γραμμική	7961.158	65.4578	89.2253	0.80165	0.22979

Κανονικοποιημένα δεδομένα με μέση τιμή=0, τυπική απόκλιση=1						
Νευρωνικό δίκτυο	Συνάρτηση Ενεργοποίησης	MSE	AME	RMSE	p	NDEI
5-10-1	Σιγμοειδής	0.77129	0.64236	0.87823	0.81711	0.37978
5-5-1	Σιγμοειδής	0.77663	0.6445	0.88127	0.81566	0.38109
7-5-1	Σιγμοειδής	0.77929	0.64856	0.88277	0.81467	0.38156
7-3-1	Σιγμοειδής	0.77929	0.64573	0.88278	0.81461	0.38156

Κανονικοποιημένα δεδομένα 0.1-0.9						
Νευρωνικό δίκτυο	Συνάρτηση Ενεργοποίησης	MSE	AME	RMSE	p	NDEI
5-15-1	Σιγμοειδής	0.010896	0.078213	0.10438	0.81751	0.18914
7-3-1	Σιγμοειδής	0.010889	0.076501	0.10435	0.81694	0.189
7-10-1	Σιγμοειδής	0.010965	0.075266	0.10471	0.81623	0.18965
5-10-1	Σιγμοειδής	0.010967	0.076796	0.10472	0.816	0.18975

Πίνακες 5.1,5.2,5.3. Οι τέσσερις καλύτερες περιπτώσεις εκπαίδευσης για κάθε διαφορετική κανονικοποίηση των δεδομένων ηλιακής ακτινοβολίας

Παρατηρήσεις

Για την περίπτωση των πραγματικών δεδομένων ηλιακής ακτινοβολίας, κατά την εκπαίδευση των νευρωνικών με χρήση σιγμοειδούς συνάρτησης στους νευρώνες του ενδιάμεσου στρώματος δεν επετεύχθηκε καλή γενίκευση, δηλαδή οι προβλέψεις ήταν κακές, σε αντίθεση με την περίπτωση χρήσης γραμμικής συνάρτησης ενεργοποίησης που είχαμε μια αρκετά ποιοτική γενίκευση. Η χρησιμοποίηση πραγματικών δεδομένων για την εκπαίδευση του Νευρωνικού Δικτύου και η μη πρόβλεψη κατάλληλων gain factors στους μη γραμμικούς νευρώνες (σιγμοειδής συνάρτηση) προκαλεί φτωχή γενίκευση. Οι μη γραμμικοί νευρώνες δεν επενεργούν σε όλο το εύρος των τιμών- εισόδων. Στις υπόλοιπες περιπτώσεις, που είχαμε κανονικοποιημένα δεδομένα, είχαμε αρκετά καλές προβλέψεις και για τις δύο περιπτώσεις συναρτίσεων ενεργοποίησης.

Κάτι άλλο που είναι επίσης άξιο παρατήρησης, είναι ότι για τα νευρωνικά δίκτυα που εκπαιδεύτηκαν με γραμμική συνάρτηση ενεργοποίησης στους κόμβους του ενδιάμεσου στρώματος, είχαμε τις ίδιες εξόδους για όλα τα νευρωνικά που είχαν ίδιο αριθμό εισόδων, ανεξαρτήτου του αριθμού των κόμβων του ενδιάμεσου στρώματος. Επειδή η θερμοκρασία και η ηλιακή ακτινοβολία έχουν ημιτονοειδή μορφή, ο αριθμός των εσωτερικών κόμβων δεν επηρεάζει ουσιαστικά την πρόβλεψη λόγω της γραμμικότητας του νευρωνικού δικτύου. Η πρόβλεψη στη περίπτωση αυτή επηρεάζεται μόνο από τον αριθμό των εισόδων.

Από τους παραπάνω πίνακες είναι προφανές ότι η σύγκριση των προβλέψεων που έχουν προκύψει από δεδομένα διαφορετικών κανονικοποιήσεων μπορεί να γίνει με βάση δύο από τις χρησιμοποιημένες μετρικές απόδοσης: το p και nde_i . Παρατηρώντας λοιπόν τους παραπάνω πίνακες και συγκρίνοντας τις μετρικές τους καταλήξαμε στα εξής τέσσερα "καλύτερα" νευρωνικά δίκτυα που θα χρησιμοποιηθούν στις μηχανές νευρωνικών δικτύων:

1. 5-15-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.
2. 7-3-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.

3. 7-10-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.
4. 5-10-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.

5.2.3.2 Θερμοκρασία

Όπως στη περίπτωση των δεδομένων ηλιακής ακτινοβολίας έτσι και για τα δεδομένα της θερμοκρασίας η εκπαίδευση έγινε με χρήση του αλγορίθμου Levenberg-Marquardt backpropagation και οι παράμετροι της εκπαίδευσης, mse_goal, epochs, Learning Rate, πήραν τις εξής αρχικές τιμές:

Για μέσες ημερήσιες τιμές θερμοκρασίας έχουμε:

1. Για πραγματικές τιμές δεδομένων: mse_goal = 1
Epochs = 150
Lr = 0.0001
2. Για κανονικοποίηση mean=0, std=1: mse_goal = 0.001
Epochs = 150
Lr = 0.01
3. Για κανονικοποίηση 0.1-0.9: mse_goal = 0.00001
Epochs = 150
Lr = 0.01

Τόσο για τις μέγιστες ημερήσιες τιμές θερμοκρασίας όσο και για τις ελάχιστες τιμές χρησιμοποιήθηκαν ακριβώς οι ίδιες τιμές στις παραμέτρους εκπαίδευσης.

Παρατηρήσεις

Στις εκπαδεύσεις,για πραγματικά δεδομένα μέσω των ημερησίων τιμών, οι παράμετροι ήταν ιδανικοί για όλες τις περιπτώσεις εκτός απ' το 3-3-1 με σιγμοειδή συνάρτηση ενεργοποίησης όπου χρειάστηκε ο ρυθμός μάθησης να πάρει ακόμα μικρότερη τιμή προκειμένου να επιτευχθεί γενίκευση. Έτσι στη περίπτωση αυτή το Lr πήρε τιμή ίση με 0.00001.

Στην περίπτωση της χρονοσειράς μέγιστων ημερησίων τιμών με πραγματικά δεδομένα, για όλα τα νευρωνικά με είσοδο 7 προηγούμενες ημερήσιες τιμές χρησιμοποιήθηκε διαφορετική, σε σχέση με όλα τα υπόλοιπα νευρωνικά, τιμή για το Lr, που ήταν η 0.01.

Τέλος, για τη χρονοσειρά των ελάχιστων ημερησίων τιμών με κανονικοποίηση 0.1-0.9, στη περίπτωση των νευρωνικών 7 εισόδων χρησιμοποιήθηκε μικρότερο Lr, ίσο με 0.00001.

Όπως για την ηλιακή ακτινοβολία έτσι και για τη θερμοκρασία μετά την εκπαίδευση των νευρωνικών δικτύων, επελέχθηκαν τα τέσσερα καλύτερα νευρωνικά για κάθε κανονικοποίηση για καθεμία από τις χρονοσειρές, των μέσων, των μέγιστων και των ελάχιστων τιμών θερμοκρασίας, τα οποία παρατίθενται στους παρακάτω πίνακες. Στους πίνακες 4 έως 12 του παραρτήματος παρατίθενται τα αποτελέσματα των προβλέψεων για όλες τις προσομοιώσεις.

- Για τα δεδομένα μέσης ημερήσιας θερμοκρασίας έχουμε τα εξής αποτελέσματα:

5.4

Πραγματικά δεδομένα						
Νευρωνικό δίκτυο	Συνάρτηση Ενεργοποίησης	MSE	AME	RMSE	p	NDEI
7-3-1	Σιγμοειδής	2.6487	1.1938	1.6275	0.97684	0.080617
7-5-1	Σιγμοειδής	2.664	1.1995	1.6322	0.9767	0.080849
7-3-1	Γραμμική	2.6687	1.1967	1.6336	0.97665	0.080921
5-3-1	Σιγμοειδής	2.6725	1.2007	1.6348	0.97665	0.081003

5.5.

Κανονικοποιημένα δεδομένα με μέση τιμή=0, τυπική απόκλιση=1						
Νευρωνικό δίκτυο	Συνάρτηση Ενεργοποίησης	MSE	AME	RMSE	p	NDEI
7-3-1	Γραμμική	0.043681	0.1531	0.209	0.97665	0.21402
7-3-1	Σιγμοειδής	0.043729	0.15393	0.20912	0.97664	0.21414
5-3-1	Σιγμοειδής	0.043845	0.15432	0.20939	0.97664	0.21436
7-5-1	Σιγμοειδής	0.043919	0.15407	0.20957	0.97656	0.2146

5.6

Κανονικοποιημένα δεδομένα 0.1-0.9						
Νευρωνικό δίκτυο	Συνάρτηση Ενεργοποίησης	MSE	AME	RMSE	p	NDEI
5-10-1	Σιγμοειδής	0.000801	0.020861	0.028308	0.97689	0.057741
3-5-1	Σιγμοειδής	0.000806	0.020964	0.028387	0.9768	0.057915
7-3-1	Σιγμοειδής	0.000805	0.020884	0.028378	0.97675	0.057871
7-3-1	Γραμμική	0.000807	0.020812	0.028411	0.97665	0.057938

- Για τα δεδομένα μέγιστης ημερήσιας θερμοκρασίας έχουμε τα εξής αποτελέσματα:

5.7

Πραγματικά δεδομένα						
Νευρωνικό δίκτυο	Συνάρτηση Ενεργοποίησης	MSE	AME	RMSE	p	NDEI
7-5-1	Σιγμοειδής	5.0823	1.7215	2.2544	0.96453	0.092043
7-3-1	Σιγμοειδής	5.0947	1.7238	2.2572	0.96449	0.092043
7-10-1	Σιγμοειδής	5.09	1.7234	2.2561	0.96448	0.092001
7-3-1	Γραμμική	5.1247	1.7244	2.2638	0.96417	0.092314

5.8

Κανονικοποιημένα δεδομένα με μέση τιμή=0, τυπική απόκλιση=1						
Νευρωνικό δίκτυο	Συνάρτηση Ενεργοποίησης	MSE	AME	RMSE	p	NDEI
7-3-1	Σιγμοειδής	0.083771	0.22112	0.28943	0.96429	0.22918
7-3-1	Γραμμική	0.083882	0.22062	0.28962	0.96417	0.22934
5-3-1	Σιγμοειδής	0.08427	0.22145	0.29029	0.96411	0.22989
7-5-1	Σιγμοειδής	0.084357	0.22211	0.29044	0.9641	0.22998

5.9

Κανονικοποιημένα δεδομένα 0.1-0.9						
Νευρωνικό δίκτυο	Συνάρτηση Ενεργοποίησης	MSE	AME	RMSE	p	NDEI
7-5-1	Σιγμοειδής	0.001537	0.02992	0.039206	0.96458	0.069198
7-3-1	Σιγμοειδής	0.001539	0.02994	0.039226	0.96451	0.069235
7-10-1	Σιγμοειδής	0.001555	0.030153	0.039436	0.96419	0.069604
7-3-1	Γραμμική	0.00155	0.02999	0.03937	0.96417	0.069489

- Για τα δεδομένα ελάχιστης ημερήσιας θερμοκρασίας έχουμε τα εξής αποτελέσματα:

5.10

Πραγματικά δεδομένα						
Νευρωνικό δίκτυο	Συνάρτηση Ενεργοποίησης	MSE	AME	RMSE	p	NDEI
5-10-1	Σιγμοειδής	6.4482	1.4777	2.5393	0.93469	0.15097
3-15-1	Σιγμοειδής	6.4805	1.4851	2.5457	0.93442	0.15139
2-15-1	Σιγμοειδής	6.4953	1.4849	2.5486	0.93428	0.15157
7-15-1	Σιγμοειδής	6.5357	1.4766	2.5565	0.93391	0.15194

5.11

Κανονικοποιημένα δεδομένα με μέση τιμή=0, τυπική απόκλιση=1						
Νευρωνικό δίκτυο	Συνάρτηση Ενεργοποίησης	MSE	AME	RMSE	p	NDEI
7-10-1	Σιγμοειδής	0.09819	0.19016	0.31335	0.93949	0.3205
3-5-1	Σιγμοειδής	0.098071	0.18836	0.31316	0.93941	0.32001
5-15-1	Σιγμοειδής	0.099801	0.19568	0.31591	0.93855	0.32295
3-15-1	Σιγμοειδής	0.10046	0.19137	0.31695	0.93812	0.32388

5.12

Κανονικοποιημένα δεδομένα 0.1-0.9						
Νευρωνικό δίκτυο	Συνάρτηση Ενεργοποίησης	MSE	AME	RMSE	p	NDEI
2-15-1	Σιγμοειδής	0.001716	0.025549	0.04142	0.94254	0.096309
5-3-1	Σιγμοειδής	0.001731	0.02526	0.0416	0.94214	0.096699
7-3-1	Σιγμοειδής	0.001753	0.025244	0.041874	0.94136	0.097316
5-5-1	Σιγμοειδής	0.001786	0.025641	0.042264	0.94039	0.098244

Πίνακες 5.4 έως 5.12. Οι τέσσερις καλύτερες περιπτώσεις εκπαίδευσης για τις χρονοσειρές μέσης, μέγιστης και ελάχιστης ημερήσιας θερμοκρασίας για κάθε διαφορετική κανονικοποίηση

Όπως και στην περίπτωση των δεδομένων ηλιακής ακτινοβολίας οι προβλέψεις συγκρίθηκαν με βάση το ρ και n_{dei} . Παρατηρώντας λοιπόν τους παραπάνω πίνακες και συγκρίνοντας τις μετρικές τους καταλήξαμε στα τέσσερα "καλύτερα" νευρωνικά δίκτυα για τις χρονοσειρές μέσης, μέγιστης και ελάχιστης ημερήσιας θερμοκρασίας, που θα χρησιμοποιηθούν στις μηχανές νευρωνικών δικτύων:

Μέση ημερήσια θερμοκρασία:

1. 5-10-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.
2. 7-3-1 για πραγματικά δεδομένα με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.
3. 3-5-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.
4. 7-3-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.

Μέγιστη ημερήσια θερμοκρασία:

1. 7-5-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.
2. 7-5-1 για πραγματικά δεδομένα με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.
3. 7-3-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.
4. 7-3-1 για πραγματικά δεδομένα με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.

Ελάχιστη ημερήσια θερμοκρασία:

1. 2-15-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.
2. 5-3-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.
3. 7-3-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.
4. 5-5-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.

Παρατηρήσεις

Άξιο παρατήρησης είναι το γεγονός ότι τα περισσότερα από τα "καλύτερα" σε προβλέψεις νευρωνικά δίκτυα είχαν εισόδους με κανονικοποιημένα δεδομένα 0.1-0.9, ενώ στις "καλύτερες" περιπτώσεις δεν συμπεριλαμβάνετο καμία περίπτωση κανονικοποιημένων δεδομένων με μέση τιμή μηδενική και τυπική απόκλιση μοναδιαία.

Όσον αφορά τον αριθμό των εισόδων παρατηρείται ότι σε αρκετές από τις "καλύτερες" περιπτώσεις έχουμε νευρωνικά δίκτυα 5 και 7 εισόδων, δηλαδή έχουμε καλύτερη πρόβλεψη με γνώση των τιμών 5 και 7 προηγούμενων ημερών αντίστοιχα.

Σε σχέση με τον αριθμό των κόμβων στο ενδιάμεσο στρώμα δείχνουν να υπερτερούν νευρωνικά με 3 και 5 κόμβους, ενώ όσον αφορά τη συνάρτηση ενεργοποίησης των νευρώνων ενδιάμεσου στρώματος παρατηρούμε ότι σχεδόν σε όλες τις "καλύτερες" περιπτώσεις έχουμε χρήση της σιγμοειδούς συνάρτησης.

Επίσης πρέπει να σημειωθεί ότι για κάθε διαφορετική περίπτωση εκπαίδευσης και δοκιμής νευρωνικού δικτύου, πέραν των μετρικών απόδοσης εμφανίζονται και οι εξής γραφικές παραστάσεις:

1. Y-άξονας: Πραγματικές ημερήσιες τιμές και αντίστοιχες προβλέψεις δεδομένων εκπαίδευσης ηλιακής ακτινοβολίας ή θερμοκρασίας

X-άξονας: Αριθμός δεδομένων

2. Y-άξονας: Τιμές σφάλματος για προβλέψεις δεδομένων εκπαίδευσης ηλιακής ακτινοβολίας ή θερμοκρασίας

X-άξονας: Αριθμός δεδομένων

3. Y-άξονας: Πραγματικές ημερήσιες τιμές και αντίστοιχες προβλέψεις δεδομένων δοκιμής ηλιακής ακτινοβολίας ή θερμοκρασίας

X-άξονας: Αριθμός δεδομένων

4. Y-άξονας: Τιμές σφάλματος για προβλέψεις δεδομένων δοκιμής ηλιακής ακτινοβολίας ή θερμοκρασίας

X-άξονας: Αριθμός δεδομένων

5. Y-άξονας: Τιμές προβλέψεων δεδομένων εκπαίδευσης ηλιακής ακτινοβολίας ή θερμοκρασίας

X-άξονας: Τιμές δεδομένων εκπαίδευσης

6. Y-άξονας: Τιμές προβλέψεων δεδομένων δοκιμής ηλιακής ακτινοβολίας ή θερμοκρασίας

X-άξονας: Τιμές δεδομένων δοκιμής.

Στο παράρτημα έχουν παρατεθεί οι γραφικές που αφορούν τα δεδομένα δοκιμής για τις εκπαιδευθείσες καθενός από τα τα 16 συνολικά 'καλύτερα' νευρωνικά.

5.3 ΠΡΟΒΛΕΨΗ ΜΕ ANFIS

Για την εκπαίδευση με ANFIS χρησιμοποιήθηκε ο ANFIS Editor GUI που είναι υλοποιημένος στο Fuzzy Logic Toolbox του προγράμματος Matlab. Δημιουργήθηκε πρώτης τάξης νευροασαφές σύστημα Sugeno επτά εισόδων και εκπαιδεύτηκε και δοκιμάστηκε για τις τέσσερις χρονοσειρές δεδομένων (μέσης ημερήσιας ηλιακής ακτινοβολίας, μέσης, μέγιστης και ελάχιστης ημερήσιας

θερμοκρασίας) κανονικοποιημένες με κανονικοποίηση 0.1-0.9. Η παραγωγή του Fuzzy Inference System έγινε με επιλογή της μεθόδου sub.clustering, ως μέθοδος βελτιστοποίησης χρησιμοποιήθηκε η backpropagation, ενώ επίσης στις επιλογές είχαμε μηδενικό fault tolerance και 3 επόχες εκπαίδευσης για όλες τις περιπτώσεις.


5.3.1 Αποτελέσματα προβλέψεων ηλιακής ακτινοβολίας με ANFIS

Για τα δεδομένα μέσης ημερήσιας ηλιακής ακτινοβολίας έχουμε τα εξής αποτελέσματα

MSE	RMSE	AME	p	NDEI
0.011115	0.10543	0.078098	0.81305	0.1962

Παρακάτω παρατίθενται γραφικές παραστάσεις όπου συγκρίνονται οι προβλεψεις με τις πραγματικές τιμές δεδομένων μέσης ημερήσιας ηλιακής ακτινοβολίας και στο πάνω μέρος των γραφικών παρατίθενται οι μετρικές απόδοσης για την εκπαίδευση της χρονοσειράς, που δείχνουν την ποιότητα των προβλέψεων με χρήση αυτού του νευροασαφούς συστήματος.

Παρακάτω έχουμε παράθεση των γραφικών σύγκρισης των προβλέψεων με τα πραγματικά δεδομένα που έχουμε στη διάθεση μας για τα δεδομένα δοκιμής (test data):




Σχήμα 5.15 Γραφική απεικόνιση σύγκρισης των προβλέψεων με χρήση ANFIS με πραγματικά δεδομένα για τα δεδομένα δοκιμής ηλιακής ακτινοβολίας

5.3.2 Αποτελέσματα προβλέψεων θερμοκρασίας με ANFIS

- Για τα δεδομένα μέσης ημερήσιας θερμοκρασίας έχουμε τα εξής αποτελέσματα

MSE	RMSE	AME	p	NDEI
0.00084434	0.029058	0.021414	0.97699	0.058671

Παρακάτω παρατίθενται γραφικές παραστάσεις, όπου συγκρίνονται οι προβλέψεις με τις πραγματικές τιμές δεδομένων μέσης ημερήσιας θερμοκρασίας και στο πάνω μέρος των γραφικών παρατίθενται οι μετρικές απόδοσης για την εκπαίδευση της χρονοσειράς, που δείχνουν την ποιότητα των προβλέψεων με χρήση αυτού του νευροασαφούς συστήματος.




Σχήμα 5.16 Γραφική απεικόνιση σύγκρισης των προβλέψεων με χρήση ANFIS με πραγματικά δεδομένα για τα δεδομένα δοκιμής μέσης ημερήσιας θερμοκρασίας

- Για τα δεδομένα μέγιστης ημερήσιας θερμοκρασίας έχουμε τα εξής αποτελέσματα

MSE	RMSE	AME	p	NDEI
0.0016815	0.041006	0.032029	0.96413	0.073831

Παρακάτω παρατίθενται γραφικές παραστάσεις όπου συγκρίνονται οι προβλέψεις με τις πραγματικές τιμές δεδομένων μέγιστης ημερήσιας θερμοκρασίας και στο πάνω μέρος των γραφικών παρατίθενται οι μετρικές απόδοσης για την εκπαίδευση της χρονοσειράς.

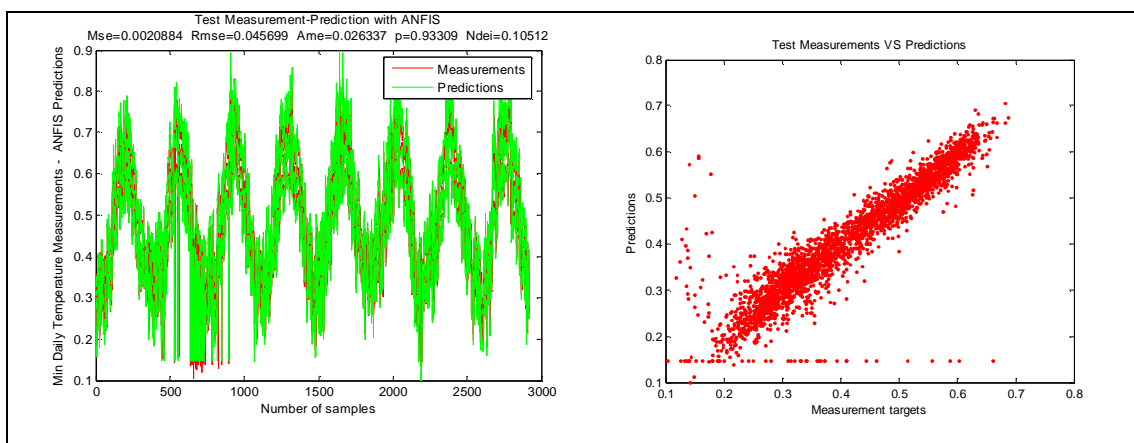


Σχήμα 5.17 Γραφική απεικόνιση σύγκρισης των προβλέψεων με χρήση ANFIS με πραγματικά δεδομένα για τα δεδομένα δοκιμής μέγιστης ημερήσιας θερμοκρασίας

- Για τα δεδομένα ελάχιστης ημερήσιας θερμοκρασίας έχουμε τα εξής αποτελέσματα:

MSE	RMSE	AME	p	NDEI
0.0020884	0.045699	0.026337	0.93309	0.10512

Παρακάτω παρατίθενται γραφικές παραστάσεις όπου συγκρίνονται οι προβλεψεις με τις πραγματικές τιμές δεδομένων ελάχιστης ημερήσιας θερμοκρασίας και στο πάνω μέρος των γραφικών παρατίθενται οι μετρικές απόδοσης για την εκπαίδευση της χρονοσειράς




Σχήμα 5.18 Γραφική απεικόνιση σύγκρισης των προβλέψεων με χρήση ANFIS με πραγματικά δεδομένα για τα δεδομένα δοκιμής ελάχιστης ημερήσιας θερμοκρασίας

5.4 ΑΝΑΠΤΥΞΗ ΜΗΧΑΝΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ (Neural Committee Machines)

Για την βελτιστοποίηση των προβλέψεων που έγιναν με τη χρήση των νευρωνικών δικτύων υλοποιήθηκαν επτά διαφορετικές μηχανές απόφασης. Οι έξι από αυτές ανήκουν στην κατηγορία των στατικών μηχανών και πιο συγκεκριμένα υλοποιήθηκαν με την μέθοδο ensemble averaging, ενώ η έβδομη ανήκει στη κατηγορία των δυναμικών μηχανών και υλοποιήθηκε με βάση τη δομή mixture of experts.

5.4.1 Στατικές μηχανές νευρωνικών δικτύων

Από τις έξι στατικές μηχανές απόφασης, οι πέντε πρώτες αποτελούνται από τέσσερις experts και ένα συνδυασμό (σχήμα 5.19), διαφορετικό για τη κάθε μηχανή, ενώ η έκτη αποτελείται από πέντε experts και τον συνδυασμό τους (σχήμα 5.23). Στις πρώτες πέντε μηχανές νευρωνικών δικτύων τους experts αποτελούν τα 4 "καλύτερα" σε προβλέψεις νευρωνικά δίκτυα για κάθε διαφορετική χρονοσειρά, που έχει προκύψει από τις προσομοιώσεις όλων των νευρωνικών και παρουσιάζονται στη παράγραφο 5.2. Στην έκτη μηχανή μαζί με τα 4 "καλύτερα" νευρωνικά δίκτυα έχει χρησιμοποιηθεί σαν πέμπτος expert το ANFIS.



Σχήμα 5.19 Μπλοκ διάγραμμα μηχανής απόφασης που στηρίζεται στο ensemble averaging με 4 experts

1^η Μηχανή νευρωνικών δικτύων

Στην πρώτη μηχανή νευρωνικών που υλοποιήθηκε (έχει τη δομή του σχήματος 5.19) χρησιμοποιούνται ως experts τα τέσσερα "καλύτερα" νευρωνικά δίκτυα για κάθε διαφορετική χρονοσειρά (μέσης ημερήσιας ηλιακής ακτινοβολίας, μέσης ημερήσιας θερμοκρασίας, μέγιστης ημερήσιας θερμοκρασίας, ελάχιστης ημερήσιας θερμοκρασίας) και η έξοδος Y της μηχανής προκύπτει από το συνδυασμό των εξόδων των νευρωνικών (y_1, y_2, y_3, y_4) με τη εξής σχέση:

$$Y = \frac{y_1 + y_2 + y_3 + y_4}{4}$$

Ο γενικός τύπος του συνδυασμού των εξόδων των experts για τη συγκεκριμένη μηχανή είναι:

$$Y = \frac{y_1 + y_2 + y_3 + \dots + y_N}{N}$$

όπου $y_1, y_2, y_3 \dots y_N$ οι εξοδοί των αντίστοιχων 1 έως N experts και N το πλήθος των experts.

Η διαδικασία που χρησιμοποιείται για τη μηχανή αυτή είναι η εξής:

1. Εισάγονται όλα τα δεδομένα της ίδιας χρονοσειράς σε καθένα από τα νευρωνικά δίκτυα.
2. Γίνεται εκπαίδευση και δοκιμή των νευρωνικών δικτύων (το καθένα ξεχωριστά σύμφωνα με τη δομή του και τον αλγόριθμο εκπαίδευσης που χρησιμοποιεί).
3. Η έξοδος που προκύπτει από τη φάση δοκιμής του κάθε νευρωνικού δικτύου κατευθύνεται προς το συνδυασμό.
4. Στο στάδιο του συνδυασμού χρησιμοποιείται η προαναφερθείσα σχέση που ουσιαστικά υπολογίζει το μέσο όρο των εξόδων των νευρωνικών δικτύων και υπολογίζεται η έξοδος της μηχανής.

Η έξοδος της μηχανής στη δική μας περίπτωση αποτελεί την πρόβλεψη της για τη συγκεκριμένη χρονοσειρά εισόδου. Προκειμένου να προσδιορίσουμε την ποιότητα πρόβλεψης της, υπολογίζουμε τις μετρικές απόδοσης που χρησιμοποιήθηκαν για σύγκριση των νευρωνικών δικτύων για την έξοδο της.

Παρατηρήσεις

Πρέπει να σημειωθεί ότι μιλώντας για έξοδο του νευρωνικού δικτύου δεν αναφερόμαστε σε μια τιμή, αλλά σε ένα πίνακα-στήλη τιμών που αποτελούν ημερήσιες προβλέψεις ηλιακής ακτινοβολίας και

θερμοκρασίας για πέντε και οκτώ χρόνια αντίστοιχα. Συνεπώς στο συνδυασμό προκειμένου να προκύψει η έξοδος της μηχανής, γίνονται πράξεις μεταξύ πινάκων καθώς τόσο τα y_1, y_2, y_3, y_4 όσο και η έξοδος Y είναι πίνακες-στήλες.

2^η Μηχανή νευρωνικών δικτύων

Η δεύτερη μηχανή νευρωνικών δικτύων που υλοποιήθηκε έχει ακριβώς την ίδια δομή με το πρώτη και ακολουθεί την ίδια διαδικασία υπολογισμού της εξόδου της. Η διαφοροποίηση της είναι στο τύπο που χρησιμοποιείται στο συνδυασμό. Η έξοδος Y της δεύτερης μηχανής νευρωνικών δικτύων προκύπτει από το συνδυασμό των εξόδων των νευρωνικών (y_1, y_2, y_3, y_4) με τη εξής σχέση:

$$Y = \frac{(y_1 + y_2 + y_3 + y_4) - (y_{\max} + y_{\min})}{2}$$

Ο γενικός τύπος του συνδυασμού των εξόδων των experts για τη συγκεκριμένη μηχανή είναι [C16]:

$$Y = \frac{(y_1 + y_2 + y_3 + \dots y_N) - (y_{\max} + y_{\min})}{N - 2}$$

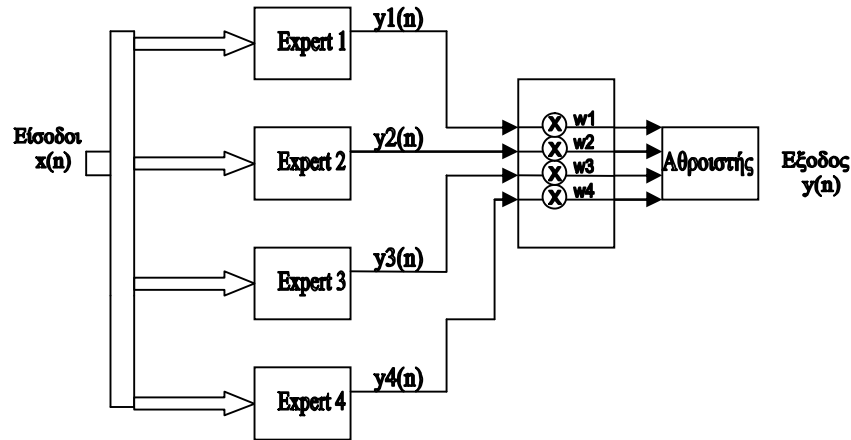
όπου $y_1, y_2, y_3, \dots y_N$ οι έξοδοι των αντίστοιχων 1 έως N experts, N το πλήθος των experts και y_{\max}, y_{\min} η μέγιστη και ελάχιστη τιμή μεταξύ των N εξόδων.

Για την περιπτωσή μας όπου έχουμε 4 εξόδους νευρωνικών (πίνακες-στήλες), τα y_{\max}, y_{\min} αποτελούν τη μέγιστη και την ελάχιστη πρόβλεψη κάθε ημέρας. Δηλαδή ουσιαστικά τα y_{\max} και y_{\min} είναι δύο πίνακες με στοιχεία τις μέγιστες και ελάχιστες ημερήσιες προβλέψεις για τις τέσσερις εξόδους των νευρωνικών, π.χ. αν έχουμε τις προβλέψεις των τεσσάρων νευρωνικών για τρεις μέρες που

$$\text{είναι: } y_1 = \begin{bmatrix} 30 \\ 40 \\ 10 \end{bmatrix}, y_2 = \begin{bmatrix} 29 \\ 35 \\ 11 \end{bmatrix}, y_3 = \begin{bmatrix} 31 \\ 37 \\ 9 \end{bmatrix}, y_4 = \begin{bmatrix} 31.5 \\ 41 \\ 7 \end{bmatrix} \text{ τότε το } y_{\max} = \begin{bmatrix} 31.5 \\ 41 \\ 11 \end{bmatrix}, y_{\min} = \begin{bmatrix} 29 \\ 35 \\ 7 \end{bmatrix}.$$

3^η Μηχανή νευρωνικών δικτύων

Η δομή της τρίτης μηχανής νευρωνικών δικτύων αποτελεί μια παραλλαγή της γενικής δομής που παρουσιάζεται στο σχήμα 5.19. Η μηχανή αυτή έχει την εξής δομή:



Σχήμα 5.20 Μπλοκ διάγραμμα 3^{ης} μηχανής νευρωνικών δικτύων που στηρίζεται στο ensemble averaging με 4 experts και χρησιμοποιεί βάρη για βελτιστοποίηση πρόβλεψης

Όπως φαίνεται στο σχήμα η 3^η μηχανή απόφασης μέχρι το στάδιο παραγωγής των experts ακολουθεί την ίδια διαδικασία με τις δύο προηγούμενες μηχανές. Ουσιαστικά διαφοροποιείται στο στάδιο του συνδυασμού, που το σπάει σε δύο στάδια. Στο 1^ο στάδιο πολλαπλασιάζονται καθεμιά από τις εξόδους των νευρωνικών δικτύων με το αντίστοιχο βάρος της, και στο 2^ο στάδιο έχουμε το άθροισμα των γινομένων των εξόδων των νευρωνικών με τα βάρη το οποίο αποτελεί και την τελική έξοδο.

Τα βάρη w_1, w_2, w_3, w_4 , παράγονται από τον εξής τύπο [C8]:

$$w_i = \frac{1}{s_i \left(\frac{1}{s_1} + \frac{1}{s_2} + \dots + \frac{1}{s_k} \right)}, \quad i=1 \dots k$$

όπου s_i τυπική απόκλιση του σφάλματος πρόβλεψης του i expert (νευρωνικού δικτύου), και k ο τελευταίος expert. Ισχύει πάντα ότι $\sum w_i = 1$. Οπότε για την δική μας περίπτωση το βάρος w_1 υπολογίζεται από τον εξής τύπο:

$$w_1 = \frac{1}{s_1 \left(\frac{1}{s_1} + \frac{1}{s_2} + \frac{1}{s_3} + \frac{1}{s_4} \right)}$$

όπου s_1, s_2, s_3, s_4 οι τυπικές αποκλίσεις των σφαλμάτων πρόβλεψης του 1^{ου}, 2^{ου}, 3^{ου} και 4^{ου} νευρωνικού δικτύου αντίστοιχα. Το σφάλμα πρόβλεψης ορίζεται ως η διαφορά: (πρόβλεψη)-(πραγματική τιμή).

Η τελική έξοδος της μηχανής απόφασης προκύπτει από τον εξής τύπο:

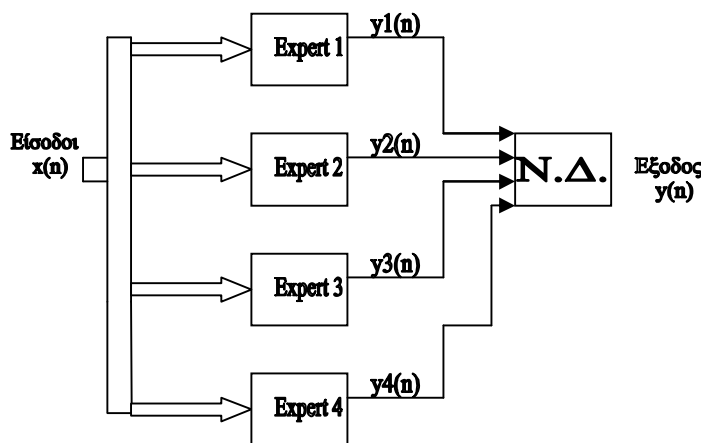
$$Y = \sum w_i y_i.$$

4^η Μηχανή νευρωνικών δικτύων

Η τέταρτη μηχανή νευρωνικών δικτύων έχει την ίδια δομή με τη πρώτη και τη δεύτερη και διαφέρει από αυτές στο τρόπο συνδυασμού των εισόδων. Στο στάδιο του συνδυασμού που περιγράφεται στο μπλοκ διάγραμμα του σχήματος 5.19 η 4^η μηχανή νευρωνικών δικτύων χρησιμοποιεί ένα νευρωνικό δίκτυο.

Το νευρωνικό δίκτυο έχει δομή 4-10-1, δηλαδή έχει τέσσερις εισόδους, δέκα κόμβους στο ενδιάμεσο στρώμα και μια έξοδο, η οποία αποτελεί και την έξοδο της μηχανής. Το νευρωνικό αυτό δίκτυο εκπαιδεύεται με τον αλγόριθμο Levenberg-Marquardt και χρησιμοποιεί γραμμική συνάρτηση ενεργοποίησης στο ενδιάμεσο στρώμα.

Έτσι μετά την εκπαίδευση καθενός από τα νευρωνικά δίκτυα(experts), προκύπτουν οι έξοδοί τους, δηλαδή οι προβλέψεις τους, οι οποίες με τη σειρά τους αποτελούν τις εισόδους του νευρωνικού δικτύου εξόδου της μηχανής. Το δίκτυο εκπαιδεύεται και δοκιμάζεται με τα ίδια δεδομένα. Έτσι σαν έξοδο παίρνουμε τις προβλέψεις του τις οποίες όπως και για όλες τις παραπάνω μηχανές τις αξιολογούμε με βάση τις μετρικές απόδοσης που έχουν χρησιμοποιηθεί για την αξιολόγηση των νευρωνικών δικτύων. Παρακάτω παρατίθεται το μπλοκ διάγραμμα της 4^{ης} μηχανής.




Σχήμα 5.21 Μπλοκ διάγραμμα 4^{ης} μηχανής νευρωνικών δικτύων που στηρίζεται στο ensemble averaging με 4 experts και σαν συνδυασμό χρησιμοποιεί ένα νευρωνικό δίκτυο 4-10-1

5^η Μηχανή νευρωνικών δικτύων

Στη πέμπτη μηχανή νευρωνικών δικτύων γίνεται χρήση του ANFIS στο στάδιο του συνδυασμού. Και αυτή η μηχανή έχει τη δομή του σχήματος 5.19. Τις εισόδους του ANFIS αποτελούν οι εξοδοί των τεσσάρων νευρωνικών δικτύων. Η διαδικασία μέχρι το στάδιο του συνδυασμού είναι η ίδια με τις προηγούμενες μηχανές.

Για την εκπαίδευση με ANFIS χρησιμοποιήθηκε ο ANFIS Editor που είναι υλοποιημένος στο Fuzzy Logic Toolbox του προγράμματος Matlab. Κατά τη λειτουργία του ANFIS φορτώσαμε τα δεδομένα εκπαίδευσης του, που είναι ένας πίνακας που αποτελείται από 4 στήλες, που η καθεμία αποτελεί έξοδο ενός από τα τέσσερα "καλύτερα" νευρωνικά, και τα εκπαιδεύσαμε όπως περιγράφεται στο κεφάλαιο 4. Ο ελεγκτής ANFIS που υλοποιήθηκε είχε τέσσερις εισόδους και μια έξοδο. Στη συνέχεια έγινε δοκιμή με τα ίδια δεδομένα. Οι εξοδοί της δοκιμής αποτελούν και τις τελικές προβλέψεις της 5^{ης} μηχανής. Παρακάτω παρατίθεται το μπλοκ διάγραμμα της 5^{ης} μηχανής.



Σχήμα 5.22 Μπλοκ διάγραμμα της 5^{ης} μηχανής όπου ο συνδυασμός εξόδων γίνεται από το ANFIS

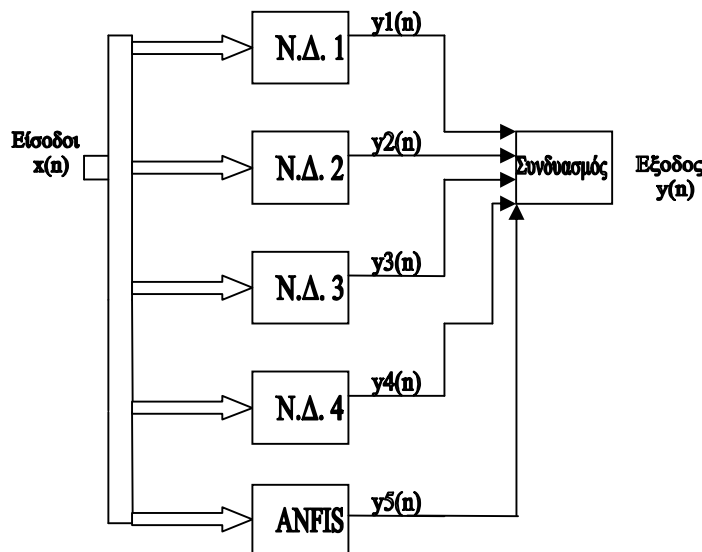
6^η Μηχανή νευρωνικών δικτύων

Η 6^η μηχανή νευρωνικών δικτύων έχει τη δομή που φαίνεται στο σχήμα 5.23. Αποτελείται από 5 experts αντί για τέσσερις που έχουν οι προηγούμενες μηχανές απόφασης. Από τους 5 experts οι τέσσερις είναι τα "καλύτερα" νευρωνικά δίκτυα που έχουν χρησιμοποιηθεί και για τις άλλες μηχανές, ενώ ο πέμπτος expert είναι το σύστημα ANFIS. Ο τελικός συνδυασμός των εξόδων των experts γίνεται, όπως και στη

περίπτωση της 2^{ης} μηχανής. Δηλαδή ο συνδυασμός των εξόδων των experts δίνεται από τον τύπο:

$$Y = \frac{(y_1 + y_2 + y_3 + \dots + y_N) - (y_{\max} + y_{\min})}{N - 2}$$

όπου $y_1, y_2, y_3, \dots, y_N$ οι εξοδοι των αντίστοιχων 1 έως N experts, N το πλήθος των experts και y_{\max}, y_{\min} η μέγιστη και ελάχιστη τιμή μεταξύ των N εξόδων. Το μπλοκ διάγραμμα της μορφής της 6^{ης} μηχανής νευρωνικών δικτύων φαίνεται στο σχήμα 5.23. Με Ν.Δ. συμβολίζονται τα Νευρωνικά Δίκτυα.



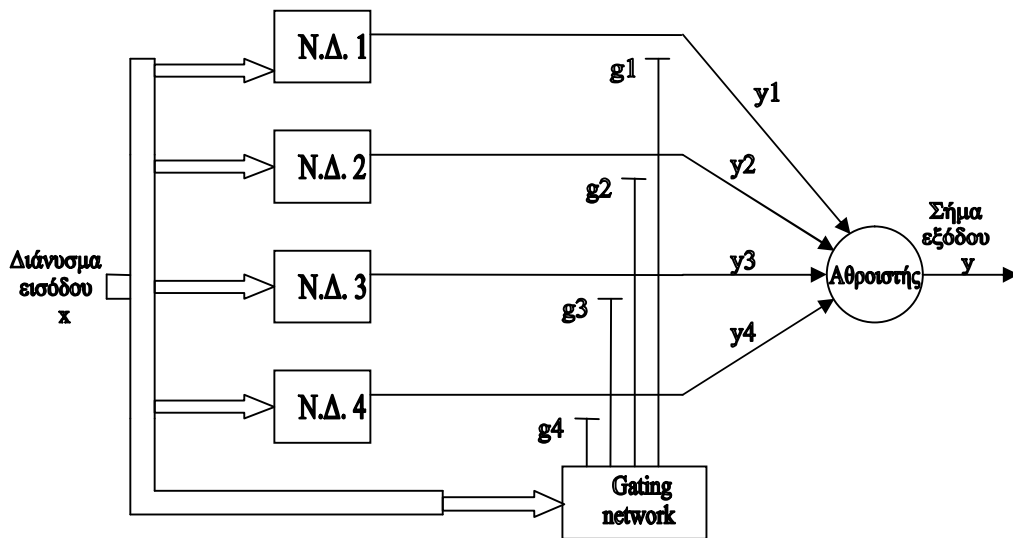
Σχήμα 5.23 Μπλοκ διάγραμμα μηχανής απόφασης που στηρίζεται στο ensemble averaging με 5 experts

5.4.2 Δυναμικές μηχανές νευρωνικών δικτύων

7^η Μηχανή νευρωνικών δικτύων

Η έβδομη μηχανή νευρωνικών δικτύων που υλοποιήθηκε αποτελεί μια δυναμική μηχανή, και στηρίχτηκε στη δομή mixture of experts. Σαν experts χρησιμοποιήθηκαν τα τέσσερα "καλύτερα" νευρωνικά δίκτυα για κάθε χρονοσειρά. Το Gating Network αποτελεί ένα νευρωνικό δίκτυο με δομή 7-5-4, με αλγόριθμο εκπαίδευσης τον Levenberg Marquardt. Η είσοδος του gating network είναι η ίδια που μπαίνει και στα νευρωνικά δίκτυα. Οι εξοδοι του gating network αποτελούν τα

βάρη για τις αντίστοιχες εξόδους των νευρωνικών δικτύων. Τα βάρη πολλαπλασιάζονται με τις αντίστοιχες εξόδους των νευρωνικών δικτύων και το άθροισμα των γινομένων τους αποτελεί την έξοδο της μηχανής. Παρακάτω παρατίθεται το μπλοκ διάγραμμα για τη δομή MOE που υλοποιήθηκε.[C4]



Σχήμα 5.24 Μπλοκ διάγραμμα μηχανής απόφασης που στηρίζεται στη δομή mixture of experts

5.4.3 Πρόβλεψη με μηχανές νευρωνικών δικτύων – Αποτελέσματα προβλέψεων

Η χρήση των μηχανών νευρωνικών δικτύων για πρόβλεψη της ηλιακής ακτινοβολίας και της θερμοκρασίας απέδειξε ότι έχουμε βελτιστοποίηση των προβλέψεων σε σχέση με τις απλές δομές νευρωνικών δικτύων, με κάποιες μηχανές σε μικρό βαθμό και με κάποιες άλλες σε μεγαλύτερο. Πριν προχωρήσουμε στη παράθεση των αποτελεσμάτων των προβλέψεων και τη σύγκριση των μηχανών πρέπει να αναφερθούν κάποιες λεπτομέρειες σχετικά με την υλοποίησή τους.

1. Τα “καλύτερα” νευρωνικά που χρησιμοποιήθηκαν στις μηχανές νευρωνικών δικτύων είχαν διαφορετικό αριθμό εισόδων.

Απ’ αυτό εξυπακούεται ότι ένα νευρωνικό δίκτυο τριών εισόδων έκανε πρόβλεψη με εισόδους τρεις προηγούμενες ημερήσιες τιμές και είχε σαν έξοδο την επόμενη ημερήσια τιμή, ενώ ένα νευρωνικό δίκτυο επτά εισόδων είχε σαν εισόδους επτά προηγούμενες ημερήσιες τιμές και σαν έξοδο τη πρόβλεψη της επόμενης. Αυτό είχε σαν αποτέλεσμα το νευρωνικό τριών εισόδων να έχει σαν πρώτη έξοδο τη πρόβλεψη για

την τέταρτη τιμή της χρονοσειράς δεδομένων, ενώ το νευρωνικό επτά εισόδων να έχει σαν πρώτη έξοδο την πρόβλεψη για την όγδοη τιμή της χρονοσειράς δεδομένων. Δηλαδή στη έξοδο του νευρωνικού τριών εισόδων υπήρχαν τέσσερις παραπάνω ημερήσιες προβλέψεις από ότι στο νευρωνικό επτά εισόδων.

Για να λυθεί το πρόβλημα και να είναι δυνατόν να γίνει συνδυασμός των προβλέψεων που αφορούν τις ίδιες ημέρες, μετά την εκπαίδευση και τη δοκιμή των τεσσάρων νευρωνικών δικτύων, αφαιρούνταν από τις εξόδους των νευρωνικών που είχαν μικρότερο αριθμό εισόδων από επτά, οι προβλέψεις που αφορούσαν τις επτά πρώτες ημερήσιες τιμές της χρονοσειράς εισόδου. Πιο αναλυτικά, για να έχουν όλες οι εξοδοί των νευρωνικών δικτύων τον ίδιο αριθμό στοιχείων στους πίνακες εξόδου τους, για κάθε νευρωνικό διαφορετικού αριθμού εισόδων έγινε η εξής διαδικασία:

- Για νευρωνικό 2 εισόδων, δεν λήφθηκαν υπόψη οι 5 πρώτες προβλέψεις
- Για νευρωνικό 3 εισόδων, δεν λήφθηκαν υπόψη οι 4 πρώτες προβλέψεις
- Για νευρωνικό 5 εισόδων, δεν λήφθηκαν υπόψη οι 2 πρώτες προβλέψεις
- Για νευρωνικό 7 εισόδων, λήφθηκαν υπόψη όλες οι προβλέψεις.

2. Οι περισσότερες από τις εξόδους των "καλύτερων" νευρωνικών δικτύων ήταν κανονικοποιημένες με κανονικοποίηση 0.1-0.9. Στο σύνολο των 16 διαφορετικών εξόδων των νευρωνικών για τις τέσσερις διαφορετικές χρονοσειρές (μέσης, μέγιστης και ελάχιστης ημερήσιας θερμοκρασίας και μέσης ημερήσιας ηλιακής ακτινοβολίας), μόνο οι τρεις εξοδοί ήταν διαφορετικής μορφής και είχαν πραγματικές τιμές, ενώ οι υπόλοιπες δεκατρείς ήταν κανονικοποιημένες 0.1-0.9. Επειδή ο συνδυασμός των εξόδων έπρεπε να γίνει με ίδια δεδομένα, οι εξοδοί που περιείχαν πραγματικές τιμές μετασχηματίστηκαν με κανονικοποίηση 0.1-0.9. Έτσι οι προβλέψεις των μηχανών νευρωνικών δικτύων γίνονταν αρχικά με κανονικοποίηση 0.1-0.9 και στη συνέχεια αποκανονικοποιούνταν σε πραγματικά δεδομένα.

Στη συνέχεια θα γίνει σύγκριση των προβλέψεων των επτά μηχανών νευρωνικών δικτύων με βάση τις ίδιες μετρικές απόδοσης που χρησιμοποιήθηκαν για τα νευρωνικά δίκτυα, για εξόδους με κανονικοποιημένα δεδομένα 0.1-0.9.


5.4.3.1 Αποτελέσματα προβλέψεων ηλιακής ακτινοβολίας με τις επτά μηχανές νευρωνικών δικτύων


Στον παρακάτω πίνακα παρατίθενται οι μετρικές απόδοσης για τις προβλέψεις των επτά υλοποιημένων μηχανών νευρωνικών δικτύων για μέσες ημερήσιες τιμές ηλιακής ακτινοβολίας.

Μηχανές Νευρωνικών Δικτύων	M.S.E.	R.M.S.E.	A.M.E.	p	N.D.E.I
1 ^η μηχανή	0.010734	0.103606	0.076094	0.819757	0.190840
2 ^η μηχανή	0.010777	0.103811	0.076134	0.818972	0.191183
3 ^η μηχανή	0.010734	0.103605	0.076095	0.819758	0.190840
4 ^η μηχανή	0.010707	0.103477	0.076157	0.820246	0.187413
5 ^η μηχανή	0.010509	0.102514	0.073934	0.824584	0.185669
6 ^η μηχανή	0.010769	0.103775	0.076284	0.819106	0.191550
7 ^η μηχανή	0.010721	0.103542	0.076080	0.820007	0.190760

Πίνακας 5.13. Αποτελέσματα μετρικών απόδοσης για τις προβλέψεις μέσω ημερησίων τιμών ηλιακής ακτινοβολίας με κανονικοποίηση 0.1-0.9 για τις επτά μηχανές νευρωνικών δικτύων

Παρακάτω παρατίθενται γραφικές παραστάσεις όπου συγκρίνονται οι τιμές των μετρικών απόδοσης για τις επτά μηχανές νευρωνικών δικτύων για δεδομένα μέσω ημερησίων τιμών ηλιακής ακτινοβολίας με κανονικοποίηση 0.1-0.9.





Σχήμα 5.25 Γραφικές παραστάσεις σύγκρισης των 7 μηχανών απόφασης με βάση τις μετρικές απόδοσης για πρόβλεψη ηλιακής ακτινοβολίας

5.4.3.2 Αποτελέσματα προβλέψεων θερμοκρασίας με τις επτά μηχανές νευρωνικών δικτύων

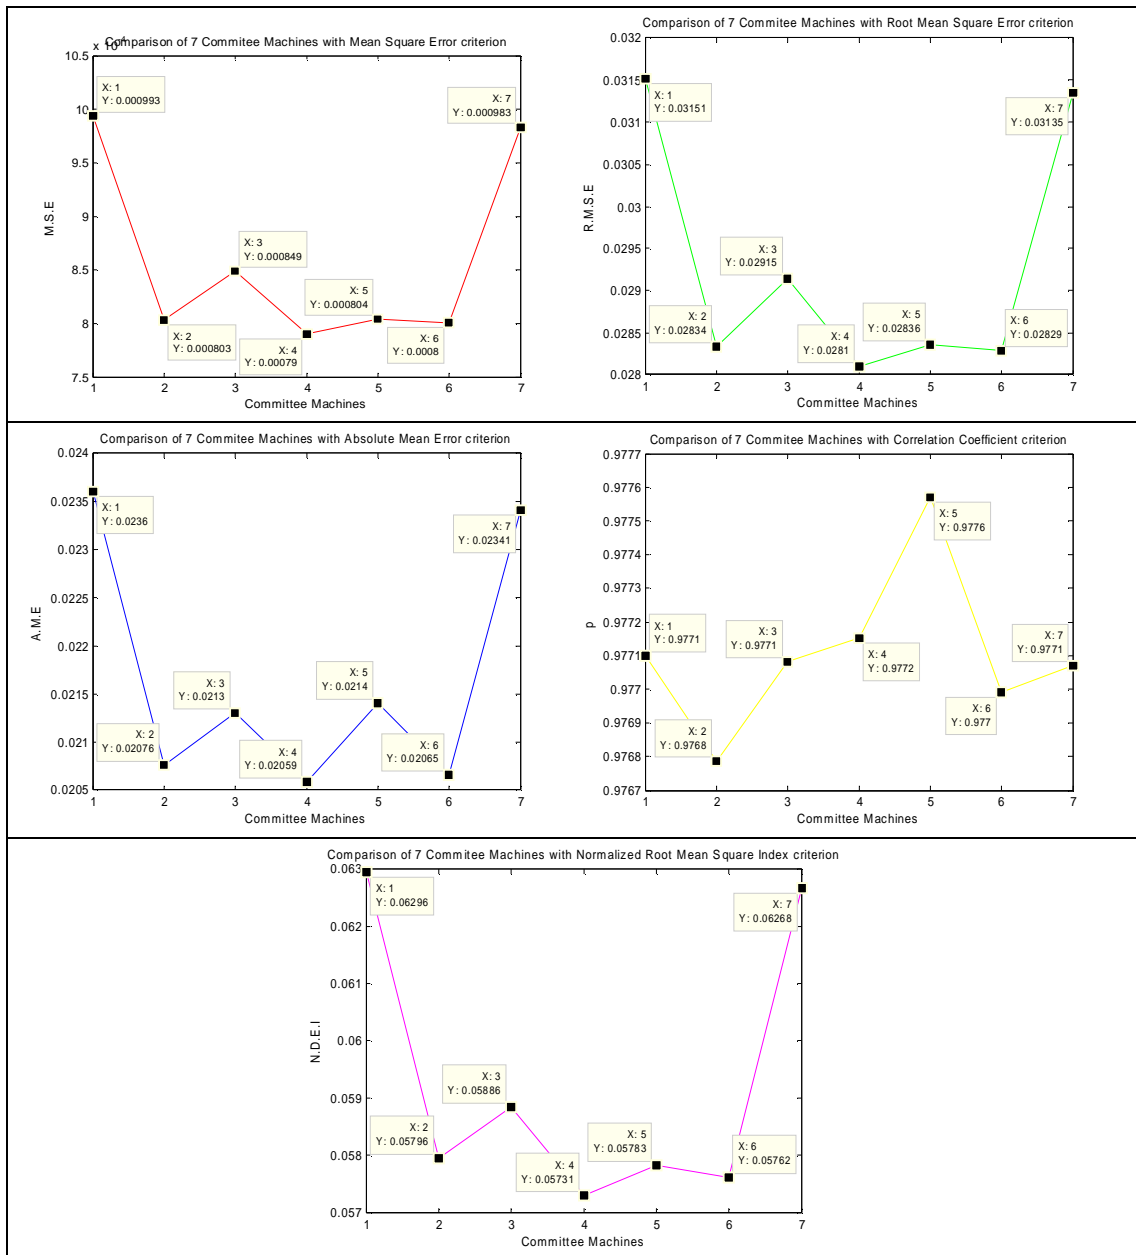
Παρακάτω παρατίθενται οι πίνακες με τις μετρικές απόδοσης για την πρόβλεψη των τιμών μέσης, μέγιστης και ελάχιστης ημερήσιας θερμοκρασίας καθώς και οι γραφικές παραστάσεις σύγκρισης των μετρικών για τις επτά μηχανές νευρωνικών δικτύων που υλοποιήθηκαν

- Για τα δεδομένα μέσης ημερήσιας θερμοκρασίας έχουμε τα εξής αποτελέσματα:

Μηχανές Νευρωνικών Δικτύων	M.S.E.	R.M.S.E.	A.M.E.	p	N.D.E.I
1 ^η μηχανή	0.000993	0.031512	0.023604	0.977100	0.062957
2 ^η μηχανή	0.000803	0.028337	0.020760	0.976786	0.057955
3 ^η μηχανή	0.000849	0.029145	0.021300	0.977083	0.058859
4 ^η μηχανή	0.000790	0.028103	0.020588	0.977153	0.057312
5 ^η μηχανή	0.000804	0.028356	0.021403	0.977570	0.057826
6 ^η μηχανή	0.000800	0.028292	0.020654	0.976990	0.057617
7 ^η μηχανή	0.000983	0.031354	0.023408	0.977070	0.062679

Πίνακας 5.14. Αποτελέσματα μετρικών απόδοσης για τις προβλέψεις μέσω ημερησίων τιμών θερμοκρασίας με κανονικοποίηση 0.1-0.9 για τις επτά μηχανές νευρωνικών δικτύων

Παρακάτω παρατίθενται οι γραφικές παραστάσεις όπου συγκρίνονται οι τιμές των μετρικών απόδοσης για τις επτά μηχανές νευρωνικών δικτύων για μέσες ημερήσιες τιμές θερμοκρασίας με κανονικοποίηση 0.1-0.9.



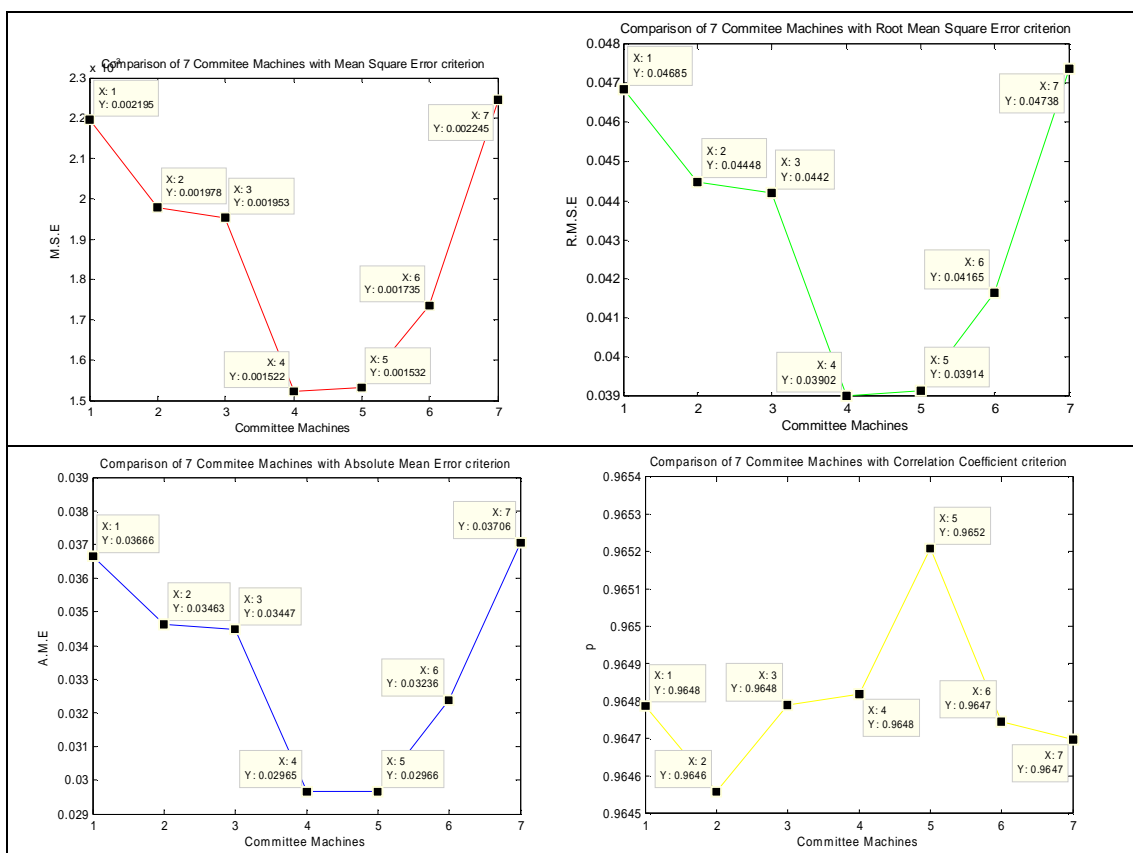
Σχήμα 5.26 Γραφικές παραστάσεις σύγκρισης των 7 μηχανών απόφασης με βάση τις μετρικές απόδοσης για πρόβλεψη μέσης ημερήσιας θερμοκρασίας


- Για τα δεδομένα μέγιστης ημερήσιας θερμοκρασίας έχουμε τα εξής αποτελέσματα:

Μηχανές Νευρωνικών Δικτύων	M.S.E.	R.M.S.E.	A.M.E.	p	N.D.E.I
1η μηχανή	0.002195	0.046853	0.036655	0.964787	0.084298
2η μηχανή	0.001978	0.044477	0.034630	0.964558	0.079813
3η μηχανή	0.001953	0.044196	0.034473	0.964791	0.079300
4η μηχανή	0.001522	0.039016	0.029650	0.964819	0.068863
5η μηχανή	0.001532	0.039135	0.029662	0.965210	0.069073
6η μηχανή	0.001735	0.041647	0.032363	0.964745	0.074608
7η μηχανή	0.002245	0.047382	0.037059	0.964699	0.085280

Πίνακας 5.15. Αποτελέσματα μετρικών απόδοσης για τις προβλέψεις μέγιστων ημερησίων τιμών θερμοκρασίας με κανονικοποίηση 0.1-0.9 για τις επτά μηχανές νευρωνικών δικτύων

Παρακάτω παρατίθενται οι γραφικές παραστάσεις όπου συγκρίνονται οι τιμές των μετρικών απόδοσης για τις επτά μηχανές νευρωνικών δικτύων για μέγιστες ημερήσιες τιμές θερμοκρασίας με κανονικοποίηση 0.1-0.9.





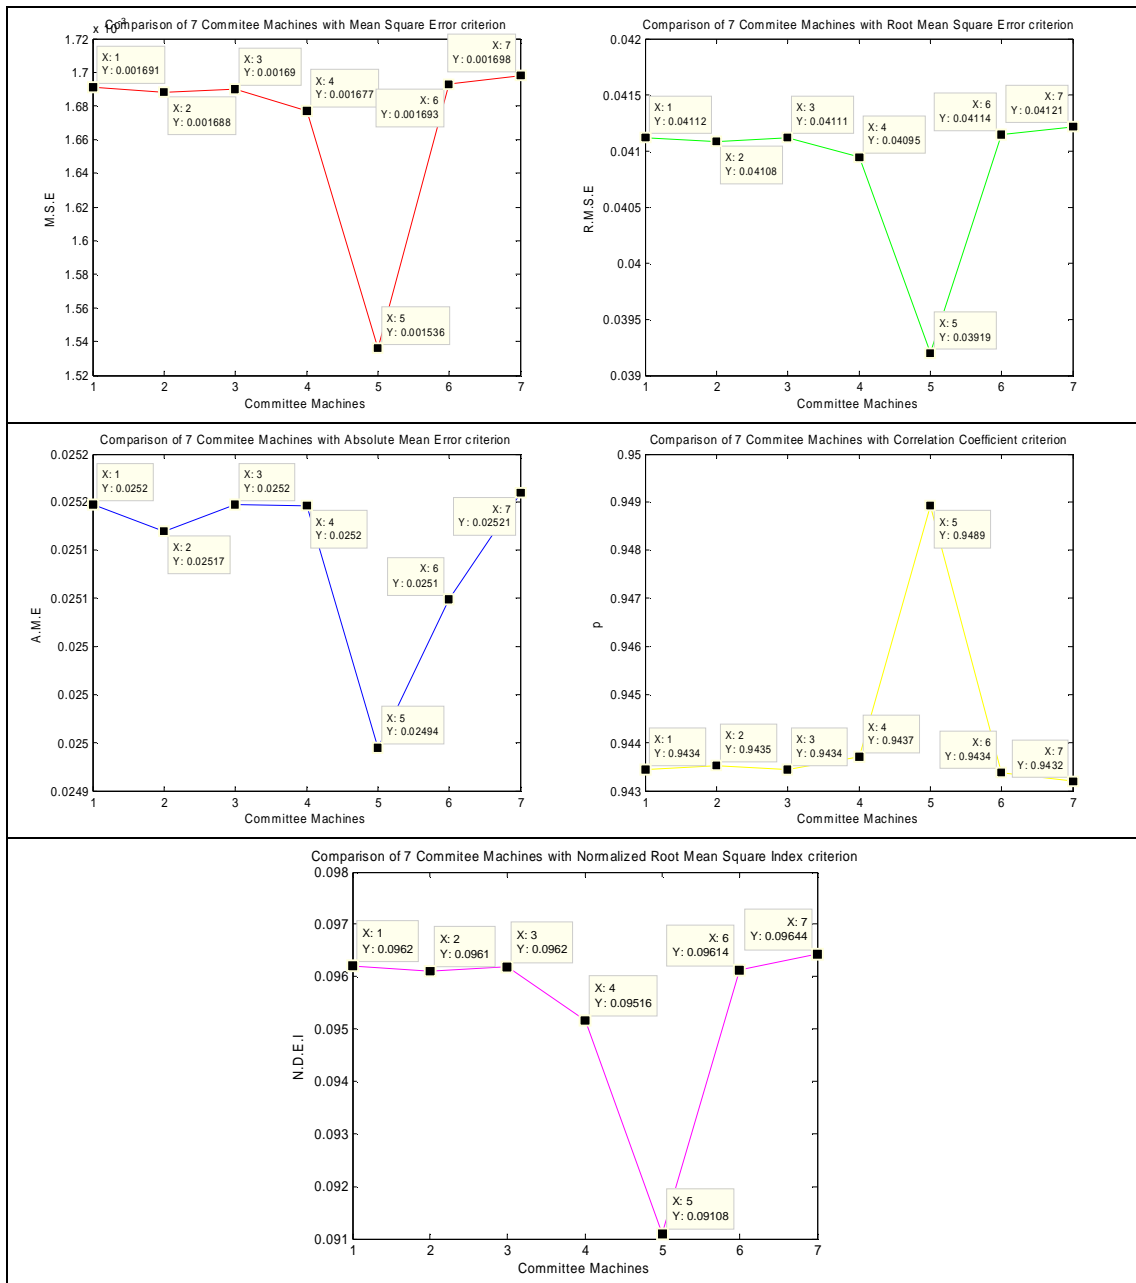
Σχήμα 5.27 Γραφικές παραστάσεις σύγκρισης των 7 μηχανών απόφασης με βάση τις μετρικές απόδοσης για πρόβλεψη μέγιστης ημερήσιας θερμοκρασίας

- Για τα δεδομένα ελάχιστης ημερήσιας θερμοκρασίας έχουμε τα εξής αποτελέσματα

Μηχανές Νευρωνικών Δικτύων	M.S.E.	R.M.S.E.	A.M.E.	p	N.D.E.I
1η μηχανή	0.001691	0.041117	0.025197	0.943432	0.096199
2η μηχανή	0.001688	0.041081	0.025170	0.943528	0.096098
3η μηχανή	0.001690	0.041115	0.025197	0.943436	0.096195
4η μηχανή	0.001677	0.040946	0.025196	0.943708	0.095160
5η μηχανή	0.001536	0.039193	0.024945	0.948921	0.091084
6η μηχανή	0.001693	0.041143	0.025099	0.943380	0.096137
7η μηχανή	0.001698	0.041211	0.025210	0.943187	0.096441

Πίνακας 5.16. Αποτελέσματα μετρικών απόδοσης για τις προβλέψεις ελάχιστων ημερησίων τιμών θερμοκρασίας με κανονικοποίηση 0.1-0.9 για τις επτά μηχανές νευρωνικών δικτύων

Παρακάτω παρατίθενται οι γραφικές παραστάσεις όπου συγκρίνονται οι τιμές των μετρικών απόδοσης για τις επτά μηχανές νευρωνικών δικτύων για ελάχιστες ημερήσιες τιμές θερμοκρασίας με κανονικοποίηση 0.1-0.9.




Σχήμα 5.28 Γραφικές παραστάσεις σύγκρισης των 7 μηχανών απόφασης με βάση τις μετρικές απόδοσης για πρόβλεψη ελάχιστης ημερήσιας θερμοκρασίας

5.5 ΓΡΑΦΙΚΕΣ ΠΑΡΑΣΤΑΣΕΙΣ ΕΚΠΑΙΔΕΥΣΗΣ ΜΕ ΠΡΑΓΜΑΤΙΚΑ ΔΕΔΟΜΕΝΑ


Παρακάτω παρατίθενται οι γραφικές παραστάσεις που δείχνουν τις προβλέψεις και τα αντίστοιχα δεδομένα του συνόλου δοκιμής για πραγματικά δεδομένα των χρονοσειρών μέσης ημερήσιας ηλιακής ακτινοβολίας, μέσης ,μέγιστης και ελάχιστης ημερήσιας θερμοκρασίας για πρόβλεψη με το "καλύτερο" νευρωνικό δίκτυο, με το ANFIS και με την "καλύτερη" συνεργατική μηχανή συλλογικής απόφασης.

Οι γραφικές παραστάσεις παρατίθενται ως εξής: για κάθε διαφορετική χρονοσειρά συμπεριλαμβάνονται οι γραφικές παραστάσεις για όλα τα δεδομένα δοκιμής και για ένα μικρότερο δείγμα των ίδιων δεδομένων (2-4 μήνες προβλέψεων) με το "καλύτερο" νευρωνικό δίκτυο, το ANFIS και την "καλύτερη" μηχανή. Έχουμε λοιπόν:


1. Ηλιακή Ακτινοβολία



Σχήμα 5.29 Γραφικές παραστάσεις πρόβλεψης μέσης ημερήσιας ηλιακής ακτινοβολίας για χρονοσειρά πραγματικών δεδομένων με το νευρωνικό δίκτυο 5-15-1

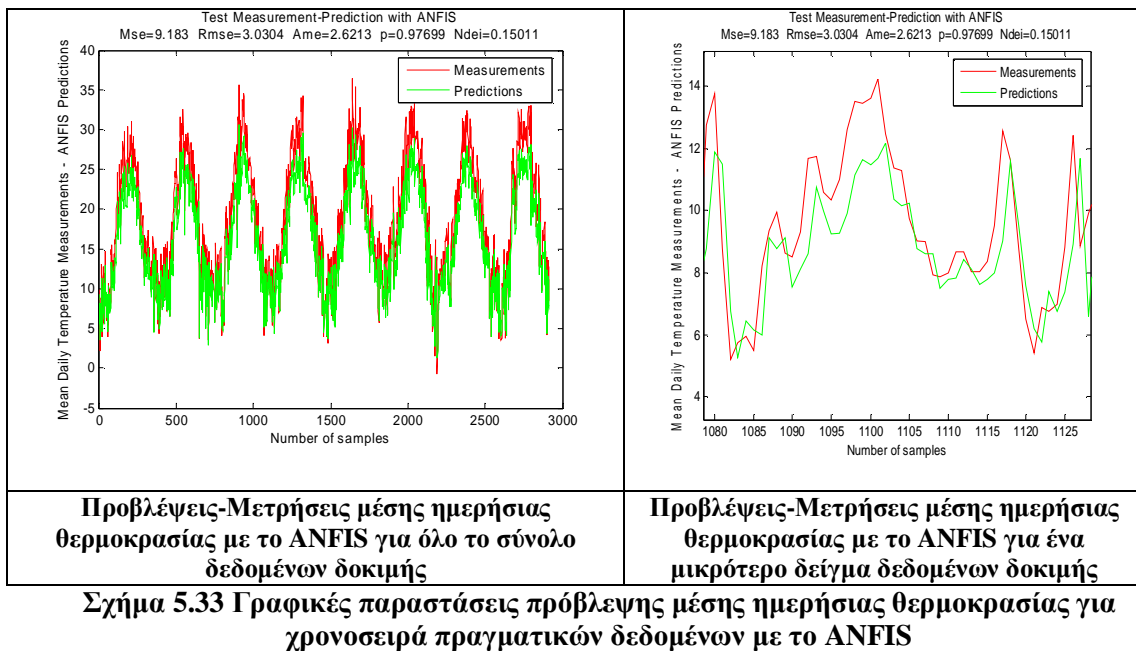



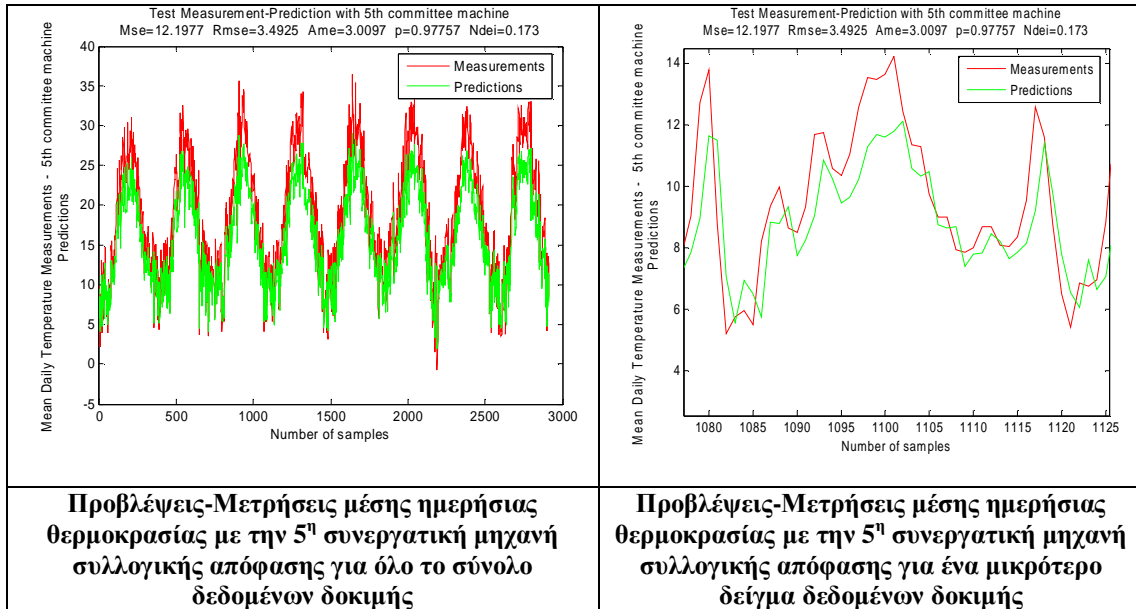
Σχήμα 5.30 Γραφικές παραστάσεις πρόβλεψης μέσης ημερήσιας ηλιακής ακτινοβολίας για χρονοσειρά πραγματικών δεδομένων με το ANFIS



Σχήμα 5.31 Γραφικές παραστάσεις πρόβλεψης μέσης ημερήσιας ηλιακής ακτινοβολίας για χρονοσειρά πραγματικών δεδομένων με την 5^η συνεργατική μηχανή συλλογικής απόφασης


2. Μέση ημερήσια θερμοκρασία






Σχήμα 5.34 Γραφικές παραστάσεις πρόβλεψης μέσης ημερήσιας θερμοκρασίας για χρονοσειρά πραγματικών δεδομένων με την 5^η συνεργατική μηχανή συλλογικής απόφασης

3. Μέγιστη ημερήσια θερμοκρασία




Σχήμα 5.35 Γραφικές παραστάσεις πρόβλεψης μέγιστης ημερήσιας θερμοκρασίας για χρονοσειρά πραγματικών δεδομένων με το νευρωνικό δίκτυο 7-5-1



Προβλέψεις-Μετρήσεις μέγιστης ημερήσιας θερμοκρασίας με το ANFIS για όλο το σύνολο δεδομένων δοκιμής

Προβλέψεις-Μετρήσεις μέγιστης ημερήσιας θερμοκρασίας με το ANFIS για ένα μικρότερο δείγμα δεδομένων δοκιμής

Σχήμα 5.36 Γραφικές παραστάσεις πρόβλεψης μέγιστης ημερήσιας θερμοκρασίας για χρονοσειρά πραγματικών δεδομένων με το ANFIS




Προβλέψεις-Μετρήσεις μέγιστης ημερήσιας θερμοκρασίας με την 5^η συνεργατική μηχανή συλλογικής απόφασης για όλο το σύνολο δεδομένων δοκιμής

Προβλέψεις-Μετρήσεις μέγιστης ημερήσιας θερμοκρασίας με την 5^η συνεργατική μηχανή συλλογικής απόφασης για ένα μικρότερο δείγμα δεδομένων δοκιμής

Σχήμα 5.37 Γραφικές παραστάσεις πρόβλεψης μέγιστης ημερήσιας θερμοκρασίας για χρονοσειρά πραγματικών δεδομένων με την 5^η συνεργατική μηχανή συλλογικής απόφασης


4. Ελάχιστη ημερήσια θερμοκρασία




Προβλέψεις-Μετρήσεις ελάχιστης ημερήσιας θερμοκρασίας με το νευρωνικό δίκτυο 2-15-1 για όλο το σύνολο δεδομένων δοκιμής

Προβλέψεις-Μετρήσεις ελάχιστης ημερήσιας θερμοκρασίας με το νευρωνικό δίκτυο 2-15-1 για ένα μικρότερο δείγμα δεδομένων δοκιμής

Σχήμα 5.38 Γραφικές παραστάσεις πρόβλεψης ελάχιστης ημερήσιας θερμοκρασίας για χρονοσειρά πραγματικών δεδομένων με το νευρωνικό δίκτυο 2-15-1



Σχήμα 5.39 Γραφικές παραστάσεις πρόβλεψης ελάχιστης ημερήσιας θερμοκρασίας για χρονοσειρά πραγματικών δεδομένων με το ANFIS



Σχήμα 5.40 Γραφικές παραστάσεις πρόβλεψης ελάχιστης ημερήσιας θερμοκρασίας για χρονοσειρά πραγματικών δεδομένων με την 5^η συνεργατική μηχανή συλλογικής απόφασης

ΚΕΦΑΛΑΙΟ

6

ΣΥΜΠΕΡΑΣΜΑΤΑ – ΠΕΡΑΙΤΕΡΩ ΕΡΕΥΝΑ

Στην παρούσα εργασία χρησιμοποιήθηκαν ευφυή συστήματα προκειμένου να επιτευχθεί βελτιστοποίηση πρόβλεψης των εξής μετεωρολογικών παραμέτρων: Ηλιακής ακτινοβολίας και Θερμοκρασίας.

Όσον αφορά τα Νευρωνικά Δίκτυα Πρόβλεψης που υλοποιήθηκαν, στόχος ήταν να ανακαλυφθεί, μέσα από δοκιμές, η βέλτιστη αρχιτεκτονική των Νευρωνικών Δικτύων που να επιτελεί την καλύτερη πρόβλεψη όσον αφορά τις μετεωρολογικές παραμέτρους της θερμοκρασίας και της ηλιακής ακτινοβολίας. Μέσα από τις δοκιμές προέκυψαν τα εξής συμπεράσματα:

- Καταλληλότερη, σε ποιότητα και σε ταχύτητα, μέθοδος εκπαίδευσης των Νευρωνικών Δικτύων Πρόβλεψης αποδείχτηκε η Levenberg-Marquardt Backpropagation.
- Η κανονικοποίηση των δεδομένων στην περιοχή 0.1-0.9 αποδείχτηκε η καλύτερη σε συνδυασμό με σιγμοειδείς συναρτήσεις στους ενδιάμεσους κόμβους.
- Όπως φάνηκε από την εφαρμογή της συνάρτησης αυτοσυσχέτισης για τα δεδομένα, το πλήθος των χρονικών καθυστερήσεων (lags) που έπρεπε να χρησιμοποιήσουμε για τη δόμηση της χρονοσειράς ήταν 2-7. Οι καθυστερήσεις αυτές μας έδωσαν αυτοσυσχετίσεις > 0.85 για τη θερμοκρασία και > 0.65 για την ηλιακή ακτινοβολία. Επομένως οι είσοδοι των Νευρωνικών Δικτύων είναι από 2 έως 7 με καλύτερη επιλογή 5 και 7.
- Όσον αφορά τον αριθμό των κόμβων του ενδιάμεσου στρώματος αυτός δεικνύει την εμβάθυνση που επιχειρείται στη χρονοσειρά για την εξόρυξη των χρήσιμων χαρακτηριστικών ιδιοτήτων της. Η επιλογή του πλήθους των εσωτερικών κόμβων όπως φάνηκε από τα πειράματα εξαρτάται ισχυρά από το είδος της χρονοσειράς (Ηλιακής

ακτινοβολίας ή Θερμοκρασίας), τον αριθμό των εισόδων, την πολυπλοκότητα της χρονοσειράς.

- Από το σύνολο των πειραμάτων προέκυψαν για την ηλιακή ακτινοβολία και τη θερμοκρασία οι βέλτιστες αρχιτεκτονικές Νευρωνικών Δικτύων ως forecasters. Η αξιολόγησή τους πραγματοποιήθηκε με την καταγραφή των δεικτών: MSE, AME, RMSE, ρ , NDEI.

Σε σχέση με το νευροασαφές σύστημα ANFIS που υλοποιήθηκε και χρησιμοποιήθηκε για την εκπαίδευση των δεδομένων των χρονοσειρών παρατηρούμε ότι ο συνδυασμός, των γλωσσικών κανόνων της ασαφούς λογικής με την κωδικοποίηση της γνώσης μέσω των συναπτικών βαρών, έχει σαν αποτέλεσμα μια αρκετά ποιοτική πρόβλεψη, συγκρίσιμη με τις προβλέψεις των ‘καλύτερων’ νευρωνικών δικτύων που προέκυψαν από τα πειράματα που προαναφέρθηκαν.

Τέλος έγινε μια προσπάθεια συνδυασμού Νευρωνικών Δικτύων για τη βελτιστοποίηση της πρόβλεψης των ατομικών forecasters, με την υλοποίηση των μηχανών απόφασης ή μηχανών νευρωνικών δικτύων. Υλοποιήθηκαν δύο είδη συνδυασμών: στατικοί και δυναμικοί. Από τα αποτελέσματα προέκυψαν τα εξής:

- Για τις χρονοσειρές που μελετώνται, ο στατικός συνδυασμός των ‘καλύτερων’ νευρωνικών δικτύων (experts) με combinator το ANFIS δίνει τα καλύτερα αποτελέσματα. Δεύτερος καλύτερος συνδυασμός σύμφωνα πάντα με τις μετρικές απόδοσης που χρησιμοποιήθηκαν είναι ο συνδυασμός Ν.Δ. με combinator ένα άλλο νευρωνικό δίκτυο.

Γενικότερα πάντως παρατηρείται ότι ο συνδυασμός της ασαφούς λογικής και των μεθόδων εκπαίδευσης των νευρωνικών δικτύων δημιουργεί καλύτερους forecasters. Αυτό οφείλεται στο γεγονός ότι στα Ν.Δ. η πληροφορία από τη χρονοσειρά αποθηκεύεται στα συναπτικά βάρη του δικτύου, ενώ στα ασαφή συστήματα περιγράφεται με γλωσσικούς κανόνες. Οι γλωσσικοί κανόνες εμπεριέχουν ασαφή σύνολα για να εκφράσουν με γλωσσικές μεταβλητές την περιοχή μεταβλητότητας των τιμών των εισόδων. Ένα σημαντικό πλεονέκτημα των ασαφών συστημάτων είναι η ενσωμάτωση στο σύστημα εμπειρικών κανόνων.

Σε σχέση με την ερευνητική εργασία που έγινε στον τομέα της πρόβλεψης μετεωρολογικών παραμέτρων, με χρήση ευφών τεχνικών, μπορούν να διατυπωθούν οι εξής προτάσεις για περαιτέρω έρευνα:

- Σύγκριση ευφών τεχνικών πρόβλεψης με συμβατικές τεχνικές.
- Ασαφή συστήματα πρόβλεψης που συνδυάζουν περισσότερες από μία μετεωρολογικές παραμέτρους για πρόβλεψη.
- Χρησιμοποίηση Νευρωνικών και Νευροασαφών συστημάτων για διόρθωση της πρόβλεψης σε μεγάλα υπολογιστικά συστήματα πρόγνωσης καιρού.
- Νευροασαφή συστήματα για την πρόβλεψη μετεωρολογικών παραμέτρων σε περιοχές από μετρήσεις σταθμών που γεωγραφικά γειτνιάζουν με την περιοχή.(Περιοχές χωρίς σταθμούς μέτρησης ή με σταθμούς αλλά χωρίς ιστορική πληροφορία)
- Σύνδεση νευροασαφών predictors για την πρόβλεψη της ζήτησης ηλεκτρικού φορτίου σε μια περιοχή.
- Οι τεχνικές αυτές μπορούν να χρησιμοποιηθούν για πρόβλεψη μετεωρολογικών παραμέτρων σε περιοχές όπου μελετάται το αιολικό δυναμικό της περιοχής.

ΠΑΡΑΡΤΗΜΑ

1. Πίνακες

Ηλιακή Ακτινοβολία

Για την ηλιακή ακτινοβολία υλοποιήθηκαν 3 πίνακες με αποτελέσματα από προσομοιώσεις στα νευρωνικά. Οι πίνακες αυτοί περιέχουν τα εξής δεδομένα:

a. real data (πραγματικά δεδομένα)

b. mean=0, std=1 data (Κανονικοποιημένα δεδομένα με μέση τιμή 0, τυπική απόκλιση 1)

c. 0.1-0.9 normalization data (Κανονικοποιημένα δεδομένα 0.1-0.9)

Παρακάτω παρατίθενται οι επεξηγήσεις των όρων που υπάρχουν στους πίνακες.

Lm= Levenberg-Marquardt backpropagation (Μέθοδος εκπαίδευσης)

IN=number of inputs (Αριθμός εισόδων)

HID=number of nodes in the hidden layer (Αριθμός κόμβων στο ενδιάμεσο στρώμα)

OUT=number of nodes in the output layer (Αριθμός κόμβων στο στρώμα εξόδου)

Metr=Metrics (Μετρικές απόδοσης)

a.f.=activation function of hidden layer (Συνάρτηση ενεργοποίησης του ενδιάμεσου στρώματος)

LINEAR=Γραμμική (αναφέρεται στη συνάρτηση ενεργοποίησης)

TANSIG=Σιγμοειδής (αναφέρεται στη συνάρτηση ενεργοποίησης)

Epochs=Διάρκεια εκπαίδευσης σε εποχές

c.t.=computation time (διάρκεια εκπαίδευσης και δοκιμής σε seconds)

M.S.E.=Mean Square Error (Μέσο τετραγωνικό σφάλμα)

A.M.E.=Absolute Mean Error (Απόλυτο μέσο σφάλμα)

R.M.S.E.=Root Mean Square Error (ρίζα του μέσου τετραγωνικού σφάλματος)

ρ = Correlation Coefficient (Συντελεστής συσχέτισης)

N.D.E.I.= Normalized Root Mean Square Index (Κανονικοποιημένος δείκτης ρίζας μέσου τετραγωνικού σφάλματος)

a.

PREDICTOR(lm) IN-HID-OUT	TRAINING			TESTING			EPOCHS linear tansig
2-2-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	72 200
	c.t.	3.886	0.49	c.t.	0.01	0.01	
	M.S.E	7902.28	19425	M.S.E	8488.9	21330	
	AME	64.734	118.1	AME	67.8235	126.0056	
	RMSE	88.8948	139.37	RMSE	92.1352	146.494	
	p	0.78911	0.27	p	0.78709	0.22088	
	NDEI	0.23457	0.3678	NDEI	0.23734	0.37623	
2-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	10 200
	c.t.	2.904	0.7	c.t.	0.02	0.01	
	M.S.E	7902.28	20325	M.S.E	8488.9	21310	
	AME	64.734	118.165	AME	67.8235	125.01	
	RMSE	88.8948	139.3712	RMSE	92.1352	145.44	
	p	0.78911	0.285	p	0.78709	0.2388	
	NDEI	0.23457	0.3677	NDEI	0.23734	0.3664	
2-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	42 200
	c.t.	3.284	1.2	c.t.	0.01	0.01	
	M.S.E	7902.28	20200.3	M.S.E	8488.9	20310	
	AME	64.734	116.15	AME	67.8235	122.11	
	RMSE	88.8948	125.3712	RMSE	92.1352	143.1441	
	p	0.78911	0.325	p	0.78709	0.29658	
	NDEI	0.23457	0.366	NDEI	0.23734	0.3687	
2-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	10 200
	c.t.	1.952	3.7	c.t.	0.01	0.01	
	M.S.E	7902.28	18325	M.S.E	8488.9	20710	
	AME	64.734	115.15	AME	67.8235	123.15	
	RMSE	88.8948	136.37	RMSE	92.1352	144.41	
	p	0.78911	0.3364	p	0.78709	0.2768	
	NDEI	0.23457	0.3655	NDEI	0.23734	0.3717	
3-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	57 200
	c.t.	2.063	0.7	c.t.	0.01	0.01	
	M.S.E	7511.7245	20325	M.S.E	7961.158	22710	
	AME	63.4061	122.15	AME	65.4578	128.15	
	RMSE	86.6702	146.3	RMSE	89.2253	148.41	
	p	0.80087	0.1364	p	0.80165	0.1268	
	NDEI	0.22869	0.3755	NDEI	0.22979	0.3817	
3-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	50 200
	c.t.	2.443	2.624	c.t.	0.01	0.01	
	M.S.E	7511.7245	7320.03	M.S.E	7961.158	7782	
	AME	63.4061	62.4473	AME	65.4578	63.986	
	RMSE	86.6702	85.5572	RMSE	89.2253	88.2199	
	p	0.80087	0.80657	p	0.80165	0.80667	
	NDEI	0.22869	0.2215	NDEI	0.22979	0.2271	
3-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	12 200
	c.t.	1.513	27.7	c.t.	0.02	0.02	
	M.S.E	7511.7245	18325	M.S.E	7961.158	20825	
	AME	63.4061	114.165	AME	65.4578	124.16	
	RMSE	86.6702	136.37	RMSE	89.2253	144.37	
	p	0.80087	0.33484	p	0.80165	0.2655	
	NDEI	0.22869	0.3597	NDEI	0.22979	0.3777	
3-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	8
	c.t.	2.133	7.76	c.t.	0.01	0.02	
	M.S.E	7511.7245	17325.1	M.S.E	7961.158	19585.2	
	AME	63.4061	108.16	AME	65.4578	119.56	

	RMSE	86.6702	136.17		RMSE	89.2253	139.34		200
	p	0.80087	0.4184		p	0.80165	0.35055		
	NDEI	0.22869	0.347		NDEI	0.22979	0.36044		
5-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		81 200
	c.t.	3.515	0.55		c.t.	0.01	0.01		
	M.S.E	7238.083	19325		M.S.E	7652.773	21210.6		
	AME	62.4059	118.465		AME	63.9124	126.01		
	RMSE	85.0769	139.4112		RMSE	87.4801	145.74		
	p	0.80899	0.26853		p	0.80998	0.2288		
	NDEI	0.22446	0.36783		NDEI	0.22518	0.3754		
5-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		40 200
	c.t.	2.644	1.76		c.t.	0.02	0.03		
	M.S.E	7238.083	17663.1		M.S.E	7652.773	19825		
	AME	62.4059	110.15		AME	63.9124	119.13		
	RMSE	85.0769	132.97		RMSE	87.4801	139.37		
	p	0.80899	0.3984		p	0.80998	0.3525		
	NDEI	0.22446	0.357		NDEI	0.22518	0.36007		
5-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		19 200
	c.t.	3.024	1.832		c.t.	0.021	0.03		
	M.S.E	7238.083	17263.1		M.S.E	7652.773	19315		
	AME	62.4059	108.11		AME	63.9124	117.63		
	RMSE	85.0769	131.37		RMSE	87.4801	139.17		
	p	0.80899	0.418		p	0.80998	0.3625		
	NDEI	0.22446	0.3472		NDEI	0.22518	0.35807		
5-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		9 200
	c.t.	3.355	3.445		c.t.	0.02	0.03		
	M.S.E	7238.083	17675.1		M.S.E	7652.773	19945.8		
	AME	62.4059	110.19		AME	63.9124	120.13		
	RMSE	85.0769	132.954		RMSE	87.4801	141.37		
	p	0.80899	0.39518		p	0.80998	0.3325		
	NDEI	0.22446	0.357		NDEI	0.22518	0.36357		
7-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		174 200
	c.t.	8.872	0.83		c.t.	0.02	0.02		
	M.S.E	7049.174	20263		M.S.E	7483.011	21298.1		
	AME	61.8443	122.1		AME	63.2687	128.77		
	RMSE	83.9594	143.37		RMSE	86.5044	148.33		
	p	0.81443	0.13788		p	0.81433	0.11136		
	NDEI	0.22149	0.37277		NDEI	0.22256	0.38152		
7-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		101 200
	c.t.	8.923	1.055		c.t.	0.01	0.02		
	M.S.E	7049.174	19125.54		M.S.E	7483.011	20890.6		
	AME	61.8443	116.475		AME	63.2687	124.01		
	RMSE	83.9594	138.4112		RMSE	86.5044	143.574		
	p	0.81443	0.29653		p	0.81433	0.25188		
	NDEI	0.22149	0.36503		NDEI	0.22256	0.37184		
7-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		8 200
	c.t.	2.394	1.823		c.t.	0.03	0.03		
	M.S.E	7049.174	17603.1		M.S.E	7483.011	19667.2		
	AME	61.8443	109.21		AME	63.2687	119.46		
	RMSE	83.9594	132.47		RMSE	86.5044	140.374		
	p	0.81443	0.3998		p	0.81433	0.3438		
	NDEI	0.22149	0.34992		NDEI	0.22256	0.361		
7-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		8 200
	c.t.	4.045	11.832		c.t.	0.04	0.041		
	M.S.E	7049.174	16463.1		M.S.E	7483.011	18653.1		
	AME	61.8443	106.145		AME	63.2687	116.167		
	RMSE	83.9594	129.343		RMSE	86.5044	137.345		

	p	0.81443	0.44812		p	0.81433	0.3924	
	NDEI	0.22149	0.34711		NDEI	0.22256	0.3524	

Πίνακας 1: Αποτελέσματα προσομοιώσεων των νευρωνικών δικτύων για πραγματικά δεδομένα ηλιακής ακτινοβολίας

b.

PREDICTOR(lm) IN-HID-OUT	TRAINING			TESTING			EPOCHS (tansig)
2-2-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	8 35
	c.t.	0.51	1.252	c.t.	0.02	0.01	
	M.S.E	0.83339	0.78695	M.S.E	0.90628	0.86019	
	AME	0.6654	0.64335	AME	0.70206	0.66752	
	RMSE	0.9129	0.8871	RMSE	0.95199	0.92746	
	p	0.78533	0.7988	p	0.78513	0.79753	
	NDEI	0.412	0.40036	NDEI	0.41358	0.40293	
2-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	6 200
	c.t.	0.581	22.883	c.t.	0.01	0.02	
	M.S.E	0.83339	0.80283	M.S.E	0.90628	0.89882	
	AME	0.6654	0.64894	AME	0.70206	0.68382	
	RMSE	0.9129	0.89601	RMSE	0.95199	0.94806	
	p	0.78533	0.79422	p	0.78513	0.78737	
	NDEI	0.412	0.40438	NDEI	0.41358	0.41187	
2-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 200
	c.t.	0.771	46137	c.t.	0.02	0.01	
	M.S.E	0.83339	0.76822	M.S.E	0.90628	0.87042	
	AME	0.6654	0.6371	AME	0.70206	0.67356	
	RMSE	0.9129	0.87648	RMSE	0.95199	0.93296	
	p	0.78533	0.80418	p	0.78513	0.79492	
	NDEI	0.412	0.39557	NDEI	0.41358	0.40531	
2-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 200
	c.t.	0.901	85.003	c.t.	0.01	0.02	
	M.S.E	0.83339	0.76391	M.S.E	0.90628	0.88426	
	AME	0.6654	0.6349	AME	0.70206	0.67998	
	RMSE	0.9129	0.87402	RMSE	0.95199	0.94035	
	p	0.78533	0.80541	p	0.78513	0.79137	
	NDEI	0.412	0.39445	NDEI	0.41358	0.40852	
3-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 200
	c.t.	0.521	18.446	c.t.	0.01	0.02	
	M.S.E	0.78246	0.7417	M.S.E	0.82927	0.80246	
	AME	0.64713	0.62828	AME	0.66807	0.65083	
	RMSE	0.88457	0.86122	RMSE	0.91064	0.8958	
	p	0.80087	0.81245	p	0.80165	0.80895	
	NDEI	0.39883	0.3883	NDEI	0.394	0.38758	
3-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 200
	c.t.	0.541	27.36	c.t.	0.01	0.01	
	M.S.E	0.78246	0.74144	M.S.E	0.82927	0.8018	
	AME	0.64713	0.62999	AME	0.66807	0.65392	
	RMSE	0.88457	0.86107	RMSE	0.91064	0.89543	
	p	0.80087	0.81253	p	0.80165	0.80915	
	NDEI	0.39883	0.38823	NDEI	0.394	0.38742	
3-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	7 200
	c.t.	1.001	58.264	c.t.	0.01	0.02	
	M.S.E	0.78246	0.71969	M.S.E	0.82927	0.80558	
	AME	0.64713	0.62258	AME	0.66807	0.66159	
	RMSE	0.88457	0.84834	RMSE	0.91064	0.89754	
	p	0.80087	0.81864	p	0.80165	0.80827	

	NDEI	0.39883	0.38249		NDEI	0.394	0.38833	
3-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	4 200
	c.t.	1.332	106.403		c.t.	0.01	0.02	
	M.S.E	0.78246	0.71385		M.S.E	0.82927	0.80324	
	AME	0.64713	0.61903		AME	0.66807	0.66132	
	RMSE	0.88457	0.84489		RMSE	0.91064	0.89623	
	p	0.80087	0.82027		p	0.80165	0.80895	
	NDEI	0.39883	0.38094		NDEI	0.394	0.38777	
5-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	9 200
	c.t.	0.741	24.325		c.t.	0.01	0.02	
	M.S.E	0.75395	0.72178		M.S.E	0.79715	0.79086	
	AME	0.63692	0.62422		AME	0.6523	0.64661	
	RMSE	0.8683	0.84958		RMSE	0.89283	0.8893	
	p	0.80899	0.81805		p	0.80998	0.81184	
	NDEI	0.39153	0.38299		NDEI	0.38609	0.38457	
5-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	10 200
	c.t.	1.061	38.826		c.t.	0.02	0.02	
	M.S.E	0.75395	0.70794		M.S.E	0.79715	0.77663	
	AME	0.63692	0.62021		AME	0.6523	0.6445	
	RMSE	0.8683	0.84139		RMSE	0.89283	0.88127	
	p	0.80899	0.82192		p	0.80998	0.81566	
	NDEI	0.39153	0.37929		NDEI	0.38609	0.38109	
5-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	5 200
	c.t.	1.312	85.222		c.t.	0.01	0.021	
	M.S.E	0.75395	0.69597		M.S.E	0.79715	0.77129	
	AME	0.63692	0.6144		AME	0.6523	0.64236	
	RMSE	0.8683	0.83425		RMSE	0.89283	0.87823	
	p	0.80899	0.82509		p	0.80998	0.81711	
	NDEI	0.39153	0.37607		NDEI	0.38609	0.37978	
5-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6 200
	c.t.	0.75395	154.442		c.t.	0.03	0.03	
	M.S.E	0.63692	0.68859		M.S.E	0.79715	0.79044	
	AME	0.8683	0.61247		AME	0.6523	0.6575	
	RMSE	0.80899	0.82981		RMSE	0.89283	0.88906	
	p	0.39153	0.8273		p	0.80998	0.81222	
	NDEI	0.75395	0.37407		NDEI	0.38609	0.38446	
7-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	11 200
	c.t.	3.155	28.861		c.t.	0.02	0.02	
	M.S.E	0.73428	0.70248		M.S.E	0.77947	0.77929	
	AME	0.63119	0.61895		AME	0.64573	0.64573	
	RMSE	0.8569	0.83814		RMSE	0.88287	0.88278	
	p	0.81443	0.82333		p	0.81433	0.81461	
	NDEI	0.38624	0.37779		NDEI	0.3816	0.38156	
7-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6 200
	c.t.	0.882	45.856		c.t.	0.01	0.02	
	M.S.E	0.73428	0.69504		M.S.E	0.77947	0.77929	
	AME	0.63119	0.61702		AME	0.64573	0.64856	
	RMSE	0.8569	0.83369		RMSE	0.88287	0.88277	
	p	0.81443	0.8254		p	0.81433	0.81467	
	NDEI	0.38624	0.37578		NDEI	0.3816	0.38156	
7-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	5 200
	c.t.	1.542	105.021		c.t.	0.02	0.02	
	M.S.E	0.73428	0.67655		M.S.E	0.77947	0.79021	
	AME	0.63119	0.61038		AME	0.64573	0.65796	
	RMSE	0.8569	0.82253		RMSE	0.88287	0.88894	
	p	0.81443	0.83052		p	0.81433	0.81198	
	NDEI	0.38624	0.37075		NDEI	0.3816	0.38422	

3-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 200
	c.t.	0.711	56.602		c.t.	0.02	
	M.S.E	0.011068	0.010151		M.S.E	0.011731	
	AME	0.076967	0.074064		AME	0.079457	
	RMSE	0.10521	0.10075		RMSE	0.10831	
	p	0.80087	0.81922		p	0.80165	
	NDEI	0.19467	0.18643		NDEI	0.19633	
3-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 106
	c.t.	1.111	65.284		c.t.	0.02	
	M.S.E	0.011068	0.01		M.S.E	0.011731	
	AME	0.076967	0.073744		AME	0.079457	
	RMSE	0.10521	0.1		RMSE	0.10831	
	p	0.80087	0.8222		p	0.80165	
	NDEI	0.19467	0.18504		NDEI	0.19633	
5-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	7 163
	c.t.	0.641	23584		c.t.	0.01	
	M.S.E	0.010665	0.010125		M.S.E	0.011276	
	AME	0.075753	0.074077		AME	0.077581	
	RMSE	0.10327	0.10062		RMSE	0.10619	
	p	0.80899	0.81973		p	0.80998	
	NDEI	0.19107	0.18617		NDEI	0.19241	
5-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 22
	c.t.	0.631	1.823		c.t.	0.01	
	M.S.E	0.010665	0.0099982		M.S.E	0.011276	
	AME	0.075753	0.073581		AME	0.077581	
	RMSE	0.10327	0.099991		RMSE	0.10619	
	p	0.80899	0.82224		p	0.80998	
	NDEI	0.19107	0.185		NDEI	0.19241	
5-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 9
	c.t.	1.112	1.763		c.t.	0.01	
	M.S.E	0.010665	0.0099693		M.S.E	0.011276	
	AME	0.075753	0.073726		AME	0.077581	
	RMSE	0.10327	0.099846		RMSE	0.10619	
	p	0.80899	0.82373		p	0.80998	
	NDEI	0.19107	0.18473		NDEI	0.19241	
5-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 7
	c.t.	1.512	2.724		c.t.	0.02	
	M.S.E	0.010665	0.0098746		M.S.E	0.011276	
	AME	0.075753	0.074609		AME	0.077581	
	RMSE	0.10327	0.099371		RMSE	0.10619	
	p	0.80899	0.82509		p	0.80998	
	NDEI	0.19107	0.18385		NDEI	0.19241	
7-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	6 11
	c.t.	0.651	0.951		c.t.	0.01	
	M.S.E	0.010387	0.0099865		M.S.E	0.011026	
	AME	0.075071	0.073976		AME	0.0768	
	RMSE	0.10192	0.099932		RMSE	0.105	
	p	0.81443	0.82236		p	0.81433	
	NDEI	0.18854	0.18487		NDEI	0.19018	
7-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 6
	c.t.	0.751	0.901		c.t.	0.02	
	M.S.E	0.010387	0.0099785		M.S.E	0.011026	
	AME	0.075071	0.07556		AME	0.0768	
	RMSE	0.10192	0.099892		RMSE	0.105	
	p	0.81443	0.82329		p	0.81433	
	NDEI	0.18854	0.1848		NDEI	0.19018	
7-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	

	c.t.	1.873	1.603		c.t.	0.02	0.02	6 5
	M.S.E	0.010387	0.009946		M.S.E	0.011026	0.010965	
	AME	0.075071	0.072851		AME	0.0768	0.075266	
	RMSE	0.10192	0.09973		RMSE	0.105	0.10471	
	p	0.81443	0.82401		p	0.81433	0.81623	
	NDEI	0.18854	0.18449		NDEI	0.19018	0.18965	
7-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6 6
	c.t.	3.275	3.155		c.t.	0.03	0.03	
	M.S.E	0.010387	0.0097837		M.S.E	0.011026	0.01093	
	AME	0.075071	0.072386		AME	0.0768	0.075813	
	RMSE	0.10192	0.098912		RMSE	0.105	0.10455	
	p	0.81443	0.82889		p	0.81433	0.8173	
	NDEI	0.18854	0.18298		NDEI	0.19018	0.18935	

Πίνακας 3: Αποτελέσματα προσομοιώσεων των νευρωνικών δικτύων για δεδομένα ηλιακής ακτινοβολίας με κανονικοποίηση 0.1-0.9

Θερμοκρασία

Για την θερμοκρασία υλοποιήθηκαν 9 πίνακες με αποτελέσματα από προσομοιώσεις στα νευρωνικά. Οι πίνακες αυτοί περιέχουν τα εξής δεδομένα:

1. Μέση ημερήσια θερμοκρασία

1a. real data(πραγματικά δεδομένα)

1b. mean=0, std=1 data(Κανονικοποιημένα δεδομένα με μέση τιμή 0, τυπική απόκλιση 1)

1c. 0.1-0.9 normalization data(Κανονιοποιημένα δεδομένα 0.1-0.9)

2. Μέγιστη ημερήσια θερμοκρασία

2a. real data(πραγματικά δεδομένα)

2b. mean=0, std=1 data(Κανονικοποιημένα δεδομένα με μέση τιμή 0, τυπική απόκλιση 1)

2c. 0.1-0.9 normalization data(Κανονιοποιημένα δεδομένα 0.1-0.9)

3. Ελάχιστη ημερήσια θερμοκρασία

3a. real data(πραγματικά δεδομένα)

3b. mean=0, std=1 data(Κανονικοποιημένα δεδομένα με μέση τιμή 0, τυπική απόκλιση 1)

3c. 0.1-0.9 normalization data(Κανονιοποιημένα δεδομένα 0.1-0.9)

Η επεξήγηση των όρων που υπάρχουν στους πίνακες έχει γίνει παραπάνω.

1a

PREDICTOR(lm) IN-HID-OUT	TRAINING			TESTING			EPOCHS linear tansig
2-2-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	

	c.t.	0.561	1.372		c.t.	0.02	0.02	9
	M.S.E	2.412	2.3531		M.S.E	2.8468	2.7872	34
	AME	1.1537	1.1397		AME	1.2326	1.2246	
	RMSE	1.553	1.534		RMSE	1.6873	1.6695	
	p	0.97621	0.9768		p	0.97511	0.97567	
	NDEI	0.081404	0.080404		NDEI	0.083635	0.082755	
2-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	7
	c.t.	0.631	8.412		c.t.	0.02	0.02	150
	M.S.E	2.412	2.3438		M.S.E	2.8468	2.7764	
	AME	1.1537	1.136		AME	1.2326	1.2245	
	RMSE	1.553	1.5309		RMSE	1.6873	1.6663	
	p	0.97621	0.97689		p	0.97511	0.97577	
	NDEI	0.081404	0.080244		NDEI	0.083635	0.082595	
2-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	4
	c.t.	0.761	14.621		c.t.	0.01	0.02	150
	M.S.E	2.412	2.3243		M.S.E	2.8468	2.7832	
	AME	1.1537	1.1314		AME	1.2326	1.2274	
	RMSE	1.553	1.5246		RMSE	1.6873	1.6683	
	p	0.97621	0.97709		p	0.97511	0.97571	
	NDEI	0.081404	0.07991		NDEI	0.083635	0.082695	
2-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6
	c.t.	2.534	26.849		c.t.	0.01	0.03	150
	M.S.E	2.412	2.3075		M.S.E	2.8468	2.7987	
	AME	1.1537	1.1277		AME	1.2326	1.2338	
	RMSE	1.553	1.5191		RMSE	1.6873	1.6729	
	p	0.97621	0.97726		p	0.97511	0.97564	
	NDEI	0.081404	0.79622		NDEI	0.083635	0.082926	
3-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	9
	c.t.	0.661	1.552		c.t.	0.02	0.02	29
	M.S.E	2.3129	2.2729		M.S.E	2.7538	2.7183	
	AME	1.1351	1.1263		AME	1.2138	1.2101	
	RMSE	1.5208	1.5076		RMSE	1.6595	1.6487	
	p	0.9772	0.97759		p	0.97593	0.97627	
	NDEI	0.079708	0.79016		NDEI	0.082249	0.081172	
3-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	5
	c.t.	0.661	9.194		c.t.	0.02	0.02	150
	M.S.E	2.3129	2.2686		M.S.E	2.7538	2.7269	
	AME	1.1351	1.1249		AME	1.2138	1.2124	
	RMSE	1.5208	1.5062		RMSE	1.6595	1.6513	
	p	0.9772	0.97764		p	0.97593	0.97619	
	NDEI	0.079708	0.078941		NDEI	0.082249	0.081846	
3-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6
	c.t.	1.061	17.476		c.t.	0.02	0.02	150
	M.S.E	2.3129	2.2436		M.S.E	2.7538	2.7195	
	AME	1.1351	1.1189		AME	1.2138	1.2142	
	RMSE	1.5208	1.4979		RMSE	1.6595	1.6491	
	p	0.9772	0.97789		p	0.97593	0.97626	
	NDEI	0.079708	0.078505		NDEI	0.082249	0.081734	
3-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	5
	c.t.	1.583	33.037		c.t.	0.03	0.031	150
	M.S.E	2.3129	2.2171		M.S.E	2.7538	2.7211	
	AME	1.1351	1.1095		AME	1.2138	1.2177	
	RMSE	1.5208	1.489		RMSE	1.6595	1.6496	
	p	0.9772	0.97815		p	0.97593	0.97628	
	NDEI	0.079708	0.078039		NDEI	0.082249	0.081759	
5-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	7
	c.t.	0.66	2.033		c.t.	0.02	0.02	

	M.S.E	2.2721	2.2443		M.S.E	2.6978	2.6725	34
	AME	1.1257	1.1195		AME	1.2039	1.2007	
	RMSE	1.5074	1.4981		RMSE	1.6425	1.6348	
	p	0.97761	0.97788		p	0.97641	0.97665	
	NDEI	0.078993	0.078509		NDEI	0.081386	0.081003	
5-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	11
	c.t.	1.171	12.748		c.t.	0.02	0.02	150
	M.S.E	2.2721	2.2202		M.S.E	2.6978	2.6852	
	AME	1.1257	1.1145		AME	1.2039	1.2044	
	RMSE	1.5074	1.49		RMSE	1.6425	1.6387	
	p	0.97761	0.97812		p	0.97641	0.97654	
	NDEI	0.078993	0.078086		NDEI	0.081386	0.081195	
5-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	5
	c.t.	1.322	28		c.t.	0.02	0.03	150
	M.S.E	2.2721	2.2249		M.S.E	2.6978	2.7052	
	AME	1.1257	1.1149		AME	1.2039	1.2073	
	RMSE	1.5074	1.4916		RMSE	1.6425	1.6448	
	p	0.97761	0.97808		p	0.97641	0.97636	
	NDEI	0.078993	0.078168		NDEI	0.081386	0.081497	
5-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6
	c.t.	2.454	48.229		c.t.	0.02	0.03	150
	M.S.E	2.2721	2.2018		M.S.E	2.6978	2.6998	
	AME	1.1257	1.1065		AME	1.2039	1.21	
	RMSE	1.5074	1.4838		RMSE	1.6425	1.6431	
	p	0.97761	0.97831		p	0.97641	0.97641	
	NDEI	0.078993	0.077761		NDEI	0.081386	0.081415	
7-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	10
	c.t.	0.972	9.593		c.t.	0.03	0.03	150
	M.S.E	2.2335	2.2112		M.S.E	2.6687	2.6487	
	AME	1.1188	1.1127		AME	1.1967	1.1938	
	RMSE	1.4945	1.487		RMSE	1.6336	1.6275	
	p	0.97797	0.97819		p	0.97665	0.97684	
	NDEI	0.078305	0.077914		NDEI	0.080921	0.080617	
7-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	9
	c.t.	1.242	15.272		c.t.	0.03	0.02	150
	M.S.E	2.2335	2.1987		M.S.E	2.6687	2.664	
	AME	1.1188	1.1099		AME	1.1967	1.1995	
	RMSE	1.4945	1.4828		RMSE	1.6336	1.6322	
	p	0.97797	0.97832		p	0.97665	0.9767	
	NDEI	0.078305	0.077694		NDEI	0.080921	0.080849	
7-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6
	c.t.	1.863	34.319		c.t.	0.03	0.04	150
	M.S.E	2.2335	2.1787		M.S.E	2.6687	2.6924	
	AME	1.1188	1.1035		AME	1.1967	1.2095	
	RMSE	1.4945	1.476		RMSE	1.6336	1.6408	
	p	0.97797	0.97852		p	0.97665	0.97647	
	NDEI	0.078305	0.077339		NDEI	0.080921	0.081279	
7-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	10
	c.t.	4.827	65.394		c.t.	0.04	0.04	150
	M.S.E	2.2335	2.1853		M.S.E	2.6687	2.6816	
	AME	1.1188	1.1052		AME	1.1967	1.2065	
	RMSE	1.4945	1.4783		RMSE	1.6336	1.6376	
	p	0.97797	0.97845		p	0.97665	0.97658	
	NDEI	0.078305	0.077456		NDEI	0.080921	0.081116	

Πίνακας 4: Αποτελέσματα προσομοιώσεων των νευρωνικών δικτύων για πραγματικά δεδομένα μέσω ημερησίων τιμών θερμοκρασίας

1b

PREDICTOR(lm) IN-HID-OUT	TRAINING			TESTING			EPOCHS linear tansig
2-2-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 104
	c.t.	0.631	3.024	c.t.	0.01	0.01	
	M.S.E	0.039479	0.038166	M.S.E	0.046607	0.045883	
	AME	0.1476	0.14531	AME	0.15778	0.15821	
	RMSE	0.19869	0.19536	RMSE	0.21589	0.2142	
	p	0.97621	0.97701	p	0.97512	0.97561	
	NDEI	0.21656	0.21293	NDEI	0.22093	0.2192	
2-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	9 150
	c.t.	0.681	7.26	c.t.	0.01	0.02	
	M.S.E	0.039479	0.038057	M.S.E	0.046607	0.045772	
	AME	0.1476	0.14518	AME	0.15778	0.15795	
	RMSE	0.19869	0.19508	RMSE	0.21589	0.21394	
	p	0.97621	0.97708	p	0.97512	0.97565	
	NDEI	0.21656	0.21262	NDEI	0.22093	0.21894	
2-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	0.651	14.641	c.t.	0.01	0.02	
	M.S.E	0.039479	0.037536	M.S.E	0.046607	0.04554	
	AME	0.1476	0.14397	AME	0.15778	0.15766	
	RMSE	0.19869	0.19374	RMSE	0.21589	0.2134	
	p	0.97621	0.9774	p	0.97512	0.97581	
	NDEI	0.21656	0.21116	NDEI	0.22093	0.21838	
2-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	0.922	26.788	c.t.	0.01	0.03	
	M.S.E	0.039479	0.037233	M.S.E	0.046607	0.045587	
	AME	0.1476	0.1437	AME	0.15778	0.15848	
	RMSE	0.19869	0.19296	RMSE	0.21589	0.21351	
	p	0.97621	0.97758	p	0.97512	0.97574	
	NDEI	0.21656	0.21031	NDEI	0.22093	0.2185	
3-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	0.47	5.628	c.t.	0.02	0.02	
	M.S.E	0.037858	0.036818	M.S.E	0.045075	0.044052	
	AME	0.14522	0.14301	AME	0.15529	0.15499	
	RMSE	0.19457	0.19188	RMSE	0.21231	0.20989	
	p	0.9772	0.97783	p	0.97593	0.97654	
	NDEI	0.2121	0.20916	NDEI	0.2173	0.21482	
3-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	6 150
	c.t.	0.601	8.151	c.t.	0.02	0.02	
	M.S.E	0.037858	0.03666	M.S.E	0.045075	0.045324	
	AME	0.14522	0.14315	AME	0.15529	0.15731	
	RMSE	0.19457	0.19147	RMSE	0.21231	0.2129	
	p	0.9772	0.97793	p	0.97593	0.97588	
	NDEI	0.2121	0.20872	NDEI	0.2173	0.2179	
3-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	10 150
	c.t.	1.382	17.555	c.t.	0.02	0.03	
	M.S.E	0.037858	0.036484	M.S.E	0.045075	0.044858	
	AME	0.14522	0.14309	AME	0.15529	0.15671	
	RMSE	0.19457	0.19101	RMSE	0.21231	0.2118	
	p	0.9772	0.97803	p	0.97593	0.97612	
	NDEI	0.2121	0.20821	NDEI	0.2173	0.21678	
3-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4

	c.t.	1.131	33.167		c.t.	0.02	0.03	150
	M.S.E	0.037858	0.035999		M.S.E	0.045075	0.044847	
	AME	0.14522	0.1416		AME	0.15529	0.15684	
	RMSE	0.19457	0.18974		RMSE	0.21231	0.21177	
	p	0.9772	0.97833		p	0.97593	0.97618	
	NDEI	0.2121	0.20683		NDEI	0.2173	0.21675	
5-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	5
	c.t.	0.55	7.411		c.t.	0.021	0.02	150
	M.S.E	0.03719	0.036291		M.S.E	0.044159	0.043845	
	AME	0.14402	0.14209		AME	0.15403	0.15432	
	RMSE	0.19285	0.1905		RMSE	0.21014	0.20939	
	p	0.97761	0.97815		p	0.97641	0.97664	
	NDEI	0.21021	0.20765		NDEI	0.21513	0.21436	
5-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	5
	c.t.	0.651	12.047		c.t.	0.02	0.03	150
	M.S.E	0.03719	0.035969		M.S.E	0.044159	0.044057	
	AME	0.14402	0.14146		AME	0.15403	0.15507	
	RMSE	0.19285	0.18966		RMSE	0.21014	0.2099	
	p	0.97761	0.97835		p	0.97641	0.97654	
	NDEI	0.21021	0.20673		NDEI	0.21513	0.21488	
5-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	3
	c.t.	0.841	26.128		c.t.	0.02	0.03	150
	M.S.E	0.03719	0.035667		M.S.E	0.044159	0.044778	
	AME	0.14402	0.14099		AME	0.15403	0.15558	
	RMSE	0.19285	0.18886		RMSE	0.21014	0.21161	
	p	0.97761	0.97853		p	0.97641	0.97611	
	NDEI	0.21021	0.20586		NDEI	0.21513	0.21663	
5-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	4
	c.t.	1.522	47.719		c.t.	0.03	0.03	150
	M.S.E	0.03719	0.034926		M.S.E	0.044159	0.044466	
	AME	0.14402	0.13965		AME	0.15403	0.15673	
	RMSE	0.19285	0.18688		RMSE	0.21014	0.21087	
	p	0.97761	0.97898		p	0.97641	0.97632	
	NDEI	0.21021	0.20371		NDEI	0.21513	0.21587	
7-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	7
	c.t.	0.701	9.103		c.t.	0.02	0.02	150
	M.S.E	0.036557	0.036037		M.S.E	0.043681	0.043729	
	AME	0.14314	0.14214		AME	0.1531	0.15393	
	RMSE	0.1912	0.18983		RMSE	0.209	0.20912	
	p	0.97797	0.97829		p	0.97665	0.97664	
	NDEI	0.20851	0.20702		NDEI	0.21402	0.21414	
7-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6
	c.t.	0.931	15.082		c.t.	0.03	0.03	150
	M.S.E	0.036557	0.035631		M.S.E	0.043681	0.043919	
	AME	0.14314	0.14114		AME	0.1531	0.15407	
	RMSE	0.1912	0.18876		RMSE	0.209	0.20957	
	p	0.97797	0.97854		p	0.97665	0.97656	
	NDEI	0.20851	0.20585		NDEI	0.21402	0.2146	
7-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	4
	c.t.	1.281	34.29		c.t.	0.03	0.03	150
	M.S.E	0.036557	0.034325		M.S.E	0.043681	0.0444	
	AME	0.14314	0.1388		AME	0.1531	0.15561	
	RMSE	0.1912	0.18527		RMSE	0.209	0.21071	
	p	0.97797	0.97933		p	0.97665	0.97627	
	NDEI	0.20851	0.20204		NDEI	0.21402	0.21578	
7-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	
	c.t.	2.955	64.443		c.t.	0.04	0.04	

	p	0.9772	0.97802		p	0.97593	0.9768	
	NDEI	0.056122	0.055113		NDEI	0.058882	0.057915	
3-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	0.771	19.057		c.t.	0.02	0.02	
	M.S.E	0.000699	0.000672		M.S.E	0.000833	0.000826	
	AME	0.01974	0.019322		AME	0.021109	0.021183	
	RMSE	0.026449	0.025927		RMSE	0.02886	0.028754	
	p	0.9772	0.9781		p	0.97593	0.97622	
	NDEI	0.056122	0.055014		NDEI	0.058882	0.058664	
3-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	1.172	33.338		c.t.	0.02	0.02	
	M.S.E	0.000699	0.000668		M.S.E	0.000833	0.000834	
	AME	0.01974	0.019269		AME	0.021109	0.021273	
	RMSE	0.026449	0.025845		RMSE	0.02886	0.02888	
	p	0.9772	0.97824		p	0.97593	0.97604	
	NDEI	0.056122	0.055484		NDEI	0.058882	0.058922	
5-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6 150
	c.t.	0.601	7.881		c.t.	0.02	0.02	
	M.S.E	0.000687	0.00067		M.S.E	0.000816	0.000813	
	AME	0.019577	0.019316		AME	0.020938	0.021027	
	RMSE	0.026215	0.025888		RMSE	0.028565	0.028514	
	p	0.97761	0.97817		p	0.97641	0.97657	
	NDEI	0.055621	0.054927		NDEI	0.058267	0.058163	
5-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	0.651	12.368		c.t.	0.02	0.02	
	M.S.E	0.000687	0.000662		M.S.E	0.000816	0.000841	
	AME	0.019577	0.019242		AME	0.020938	0.021003	
	RMSE	0.026215	0.025737		RMSE	0.028565	0.028997	
	p	0.97761	0.97842		p	0.97641	0.97578	
	NDEI	0.055621	0.054608		NDEI	0.058267	0.059147	
5-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	1.001	26.207		c.t.	0.02	0.03	
	M.S.E	0.000687	0.000658		M.S.E	0.000816	0.000801	
	AME	0.019577	0.019204		AME	0.020938	0.020861	
	RMSE	0.026215	0.025657		RMSE	0.028565	0.028308	
	p	0.97761	0.97856		p	0.97641	0.97689	
	NDEI	0.055621	0.054437		NDEI	0.058267	0.057741	
5-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	1.582	47.679		c.t.	0.03	0.04	
	M.S.E	0.000687	0.000649		M.S.E	0.000816	0.000839	
	AME	0.019577	0.019072		AME	0.020938	0.021345	
	RMSE	0.026215	0.025483		RMSE	0.028565	0.028965	
	p	0.97761	0.97885		p	0.97641	0.97581	
	NDEI	0.055621	0.054069		NDEI	0.058267	0.059083	
7-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	7 150
	c.t.	0.731	9.424		c.t.	0.03	0.02	
	M.S.E	0.000675	0.000663		M.S.E	0.000807	0.000805	
	AME	0.019457	0.019123		AME	0.020812	0.020884	
	RMSE	0.025991	0.025753		RMSE	0.028411	0.028378	
	p	0.97797	0.97838		p	0.97665	0.97675	
	NDEI	0.055138	0.054633		NDEI	0.057938	0.057871	
7-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	0.781	15.623		c.t.	0.021	0.02	
	M.S.E	0.000675	0.000653		M.S.E	0.000807	0.000815	
	AME	0.019457	0.019134		AME	0.020812	0.02086	
	RMSE	0.025991	0.025554		RMSE	0.028411	0.028549	
	p	0.97797	0.97871		p	0.97665	0.97647	

	NDEI	0.055138	0.054211		NDEI	0.057938	0.058221	
7-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	1.252	34.359		c.t.	0.03	0.041	
	M.S.E	0.000675	0.000651		M.S.E	0.000807	0.000811	
	AME	0.019457	0.01909		AME	0.020812	0.020889	
	RMSE	0.025991	0.025516		RMSE	0.028411	0.028485	
	p	0.97797	0.97878		p	0.97665	0.97658	
	NDEI	0.055138	0.054131		NDEI	0.057938	0.058091	
7-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	2.133	64.723		c.t.	0.04	0.04	
	M.S.E	0.000675	0.000643		M.S.E	0.000807	0.000857	
	AME	0.019457	0.019045		AME	0.020812	0.021221	
	RMSE	0.025991	0.025351		RMSE	0.028411	0.029269	
	p	0.97797	0.97905		p	0.97665	0.97528	
	NDEI	0.055138	0.053781		NDEI	0.057938	0.059689	

Πίνακας 6: Αποτελέσματα προσομοιώσεων των νευρωνικών δικτύων για μέσες ημερήσιες τιμές θερμοκρασίας με κανονικοποίηση 0.1-0.9

2 a

PREDICTOR(lm) IN-HID-OUT	TRAINING			TESTING			EPOCHS linear tansig
2-2-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	14 150
	c.t.	0.66	4.316	c.t.	0.021	0.01	
	M.S.E	5.467	5.2713	M.S.E	5.4273	5.3477	
	AME	1.7741	1.746	AME	1.7752	1.7699	
	RMSE	0.95722	2.2959	RMSE	2.3297	2.3125	
	p	0.95722	0.95878	p	0.96211	0.96284	
	NDEI	0.10009	0.09828	NDEI	0.095065	0.094365	
2-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	6 150
	c.t.	0.671	7.751	c.t.	0.021	0.02	
	M.S.E	5.467	5.2619	M.S.E	5.4273	5.2853	
	AME	1.7741	1.7383	AME	1.7752	1.7631	
	RMSE	0.95722	2.2939	RMSE	2.3297	2.299	
	p	0.95722	0.95886	p	0.96211	0.96322	
	NDEI	0.10009	0.098191	NDEI	0.095065	0.093813	
2-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	6 150
	c.t.	0.972	16.093	c.t.	0.01	0.02	
	M.S.E	5.467	5.3077	M.S.E	5.4273	5.3061	
	AME	1.7741	1.7502	AME	1.7752	1.7632	
	RMSE	0.95722	2.3038	RMSE	2.3297	2.3035	
	p	0.95722	0.95849	p	0.96211	0.96309	
	NDEI	0.10009	0.098618	NDEI	0.095065	0.093997	
2-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	7 150
	c.t.	1.562	27.58	c.t.	0.02	0.03	
	M.S.E	5.467	5.2521	M.S.E	5.4273	5.3202	
	AME	1.7741	1.7424	AME	1.7752	1.7647	
	RMSE	0.95722	2.2918	RMSE	2.3297	2.3066	
	p	0.95722	0.95894	p	0.96211	0.963	
	NDEI	0.10009	0.0981	NDEI	0.095065	0.094123	
3-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	10
	c.t.	1.792	6.029	c.t.	0.02	0.02	
	M.S.E	5.3843	5.2616	M.S.E	5.3305	5.2433	

	AME	1.7616	1.744		AME	1.7603	1.7545		150
	RMSE	2.3204	2.2938		RMSE	2.3088	2.2898		
	p	0.95786	0.95885		p	0.96279	0.96351		
	NDEI	0.099319	0.098181		NDEI	0.094203	0.093429		
3-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		9
	c.t.	0.821	9.374		c.t.	0.02	0.02		150
	M.S.E	5.3843	5.246		M.S.E	5.3305	5.2511		
	AME	1.7616	1.7425		AME	1.7603	1.7547		
	RMSE	2.3204	2.2904		RMSE	2.3088	2.2915		
	p	0.95786	0.95897		p	0.96279	0.96344		
	NDEI	0.099319	0.098035		NDEI	0.094203	0.093498		
3-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		8
	c.t.	1.152	17.736		c.t.	0.02	0.02		150
	M.S.E	5.3843	5.263		M.S.E	5.3305	5.2323		
	AME	1.7616	1.7445		AME	1.7603	1.7507		
	RMSE	2.3204	2.2941		RMSE	2.3088	2.2874		
	p	0.95786	0.95884		p	0.96279	0.96358		
	NDEI	0.099319	0.098193		NDEI	0.094203	0.093331		
3-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		10
	c.t.	2.504	34.059		c.t.	0.02	0.04		150
	M.S.E	5.3843	5.2283		M.S.E	5.3305	5.2425		
	AME	1.7616	1.7406		AME	1.7603	1.7513		
	RMSE	2.3204	2.2865		RMSE	2.3088	2.2897		
	p	0.95786	0.95911		p	0.96279	0.96351		
	NDEI	0.099319	0.097869		NDEI	0.094203	0.093422		
5-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		6
	c.t.	0.671	7.581		c.t.	0.02	0.02		150
	M.S.E	5.2764	5.182		M.S.E	5.1933	5.1498		
	AME	1.748	1.735		AME	1.7357	1.7309		
	RMSE	2.297	2.2764		RMSE	2.2789	2.2693		
	p	0.95873	0.95949		p	0.96373	0.96411		
	NDEI	0.098308	0.097425		NDEI	0.092956	0.092566		
5-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		9
	c.t.	1.111	12.158		c.t.	0.02	0.02		150
	M.S.E	5.2764	5.1813		M.S.E	5.1933	5.1418		
	AME	1.748	1.7339		AME	1.7357	1.7291		
	RMSE	2.297	2.2762		RMSE	2.2789	2.2675		
	p	0.95873	0.95949		p	0.96373	0.96417		
	NDEI	0.098308	0.097418		NDEI	0.092956	0.092494		
5-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		8
	c.t.	1.853	26.398		c.t.	0.02	0.03		150
	M.S.E	5.2764	5.0878		M.S.E	5.1933	5.2335		
	AME	1.748	1.7181		AME	1.7357	1.7528		
	RMSE	2.297	2.2556		RMSE	2.2789	2.2877		
	p	0.95873	0.96024		p	0.96373	0.96358		
	NDEI	0.098308	0.096535		NDEI	0.092956	0.093315		
5-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		6
	c.t.	2.533	47.909		c.t.	0.03	0.04		150
	M.S.E	5.2764	5.0727		M.S.E	5.1933	5.2254		
	AME	1.748	1.7171		AME	1.7357	1.7516		
	RMSE	2.297	2.2523		RMSE	2.2789	2.2859		
	p	0.95873	0.96036		p	0.96373	0.9636		
	NDEI	0.098308	0.096392		NDEI	0.092956	0.093243		
7-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		9
	c.t.	1.041	10.165		c.t.	0.03	0.02		150
	M.S.E	5.1861	5.0444		M.S.E	5.1247	5.0947		
	AME	1.7338	1.7109		AME	1.7244	1.7238		

	RMSE	2.2773	2.246		RMSE	2.2638	2.2572	
	p	0.95942	0.96055		p	0.96417	0.96449	
	NDEI	0.097447	0.096107		NDEI	0.092314	0.092043	
7-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	
	c.t.	1.252	16.083		c.t.	0.03	0.03	
	M.S.E	5.1861	5.1233		M.S.E	5.1247	5.0823	
	AME	1.7338	1.7259		AME	1.7244	1.7215	
	RMSE	2.2773	2.2635		RMSE	2.2638	2.2544	
	p	0.95942	0.95992		p	0.96417	0.96453	
	NDEI	0.097447	0.096856		NDEI	0.092314	0.092043	
7-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	
	c.t.	2.043	34.59		c.t.	0.03	0.03	
	M.S.E	5.1861	5.1184		M.S.E	5.1247	5.09	
	AME	1.7338	1.7237		AME	1.7244	1.7234	
	RMSE	2.2773	2.2624		RMSE	2.2638	2.2561	
	p	0.95942	0.95996		p	0.96417	0.96448	
	NDEI	0.097447	0.09681		NDEI	0.092314	0.092001	
7-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	
	c.t.	3.424	64.312		c.t.	0.041	0.04	
	M.S.E	5.1861	4.9952		M.S.E	5.1247	5.1722	
	AME	1.7338	1.706		AME	1.7244	1.7414	
	RMSE	2.2773	2.235		RMSE	2.2638	2.2743	
	p	0.95942	0.96094		p	0.96417	0.96397	
	NDEI	0.097447	0.095637		NDEI	0.092314	0.09274	

Πίνακας 7: Αποτελέσματα προσομοιώσεων των νευρωνικών δικτύων για πραγματικά δεδομένα μέγιστων ημερησίων τιμών θερμοκρασίας

2b

PREDICTOR(lm) IN-HID-OUT	TRAINING			TESTING			EPOCHS linear tansig
2-2-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 68
	c.t.	0.441	4.026	c.t.	0.01	0.02	
	M.S.E	0.089485	0.08615	M.S.E	0.088854	0.086423	
	AME	0.22697	0.22273	AME	0.22725	0.22546	
	RMSE	0.29914	0.29352	RMSE	0.29808	0.29398	
	p	0.95722	0.95885	p	0.96213	0.96334	
	NDEI	0.2607	0.2558	NDEI	0.23611	0.23286	
2-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	6 150
	c.t.	0.581	7.33	c.t.	0.02	0.021	
	M.S.E	0.089485	0.085245	M.S.E	0.088854	0.085923	
	AME	0.22697	0.22194	AME	0.22725	0.22496	
	RMSE	0.29914	0.29197	RMSE	0.29808	0.29313	
	p	0.95722	0.95929	p	0.96213	0.96357	
	NDEI	0.2607	0.25445	NDEI	0.23611	0.23218	
2-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	0.651	14.581	c.t.	0.02	0.02	
	M.S.E	0.089485	0.08477	M.S.E	0.088854	0.086888	
	AME	0.22697	0.2211	AME	0.22725	0.22676	
	RMSE	0.29914	0.29115	RMSE	0.29808	0.29477	
	p	0.95722	0.95952	p	0.96213	0.96312	
	NDEI	0.2607	0.25374	NDEI	0.23611	0.23348	
2-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	
	c.t.	0.921	26.719	c.t.	0.02	0.03	

	M.S.E	0.089485	0.083811	M.S.E	0.088854	0.087789	4
	AME	0.22697	0.22025	AME	0.22725	0.22733	150
	RMSE	0.29914	0.2895	RMSE	0.29808	0.29629	
	p	0.95722	0.95999	p	0.96213	0.9628	
	NDEI	0.2607	0.2523	NDEI	0.23611	0.23469	
3-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4
	c.t.	0.481	5.818	c.t.	0.02	0.02	150
	M.S.E	0.088131	0.085011	M.S.E	0.08725	0.085454	
	AME	0.22538	0.22157	AME	0.22521	0.22411	
	RMSE	0.29687	0.29157	RMSE	0.29538	0.29232	
	p	0.95786	0.95939	p	0.96279	0.96371	
	NDEI	0.25873	0.25411	NDEI	0.23395	0.23153	
3-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	8
	c.t.	0.751	8.573	c.t.	0.02	0.02	150
	M.S.E	0.088131	0.084654	M.S.E	0.08725	0.086184	
	AME	0.22538	0.22136	AME	0.22521	0.22561	
	RMSE	0.29687	0.29095	RMSE	0.29538	0.29357	
	p	0.95786	0.95956	p	0.96279	0.96334	
	NDEI	0.25873	0.25357	NDEI	0.23395	0.23251	
3-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5
	c.t.	0.872	18.547	c.t.	0.01	0.02	150
	M.S.E	0.088131	0.08375	M.S.E	0.08725	0.08657	
	AME	0.22538	0.22041	AME	0.22521	0.2261	
	RMSE	0.29687	0.2894	RMSE	0.29538	0.29423	
	p	0.95786	0.96	p	0.96279	0.96324	
	NDEI	0.25873	0.25221	NDEI	0.23395	0.23303	
3-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	6
	c.t.	1.692	33.498	c.t.	0.02	0.03	150
	M.S.E	0.088131	0.083135	M.S.E	0.08725	0.085997	
	AME	0.22538	0.22052	AME	0.22521	0.22512	
	RMSE	0.29687	0.28833	RMSE	0.29538	0.29325	
	p	0.95786	0.9603	p	0.96279	0.96348	
	NDEI	0.25873	0.25129	NDEI	0.23395	0.23226	
5-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	7
	c.t.	0.631	7.311	c.t.	0.02	0.02	150
	M.S.E	0.086365	0.08472	M.S.E	0.085005	0.08427	
	AME	0.22363	0.222	AME	0.22206	0.22145	
	RMSE	0.29388	0.29107	RMSE	0.29156	0.29029	
	p	0.95873	0.95953	p	0.96373	0.96411	
	NDEI	0.25608	0.25363	NDEI	0.23089	0.22989	
5-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	11
	c.t.	1.111	11.586	c.t.	0.01	0.02	150
	M.S.E	0.086365	0.083132	M.S.E	0.085005	0.085257	
	AME	0.22363	0.21938	AME	0.22206	0.22338	
	RMSE	0.29388	0.28833	RMSE	0.29156	0.29199	
	p	0.95873	0.96031	p	0.96373	0.96374	
	NDEI	0.25608	0.25124	NDEI	0.23089	0.23123	
5-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4
	c.t.	0.991	27.109	c.t.	0.03	0.03	150
	M.S.E	0.086365	0.080414	M.S.E	0.085005	0.086669	
	AME	0.22363	0.21745	AME	0.22206	0.22494	
	RMSE	0.29388	0.28357	RMSE	0.29156	0.29494	
	p	0.95873	0.96163	p	0.96373	0.9631	
	NDEI	0.25608	0.2471	NDEI	0.23089	0.23314	
5-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	
	c.t.	1.573	48.24	c.t.	0.04	0.03	
	M.S.E	0.086365	0.081635	M.S.E	0.085005	0.085582	

	AME	0.22363	0.2176		AME	0.22206	0.22488		4
	RMSE	0.29388	0.2872		RMSE	0.29156	0.29254		150
	p	0.95873	0.96104		p	0.96373	0.96367		
	NDEI	0.25608	0.24897		NDEI	0.23089	0.23167		
7-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		5
	c.t.	0.621	9.453		c.t.	0.02	0.02		150
	M.S.E	0.084886	0.083039		M.S.E	0.083882	0.083771		
	AME	0.22182	0.21977		AME	0.22062	0.22112		
	RMSE	0.29135	0.28816		RMSE	0.28962	0.28943		
	p	0.95942	0.96032		p	0.96417	0.96429		
	NDEI	0.2539	0.25112		NDEI	0.22934	0.22918		
7-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		7
	c.t.	1.122	15.202		c.t.	0.02	0.03		150
	M.S.E	0.084886	0.081626		M.S.E	0.083882	0.084357		
	AME	0.22182	0.21731		AME	0.22062	0.22211		
	RMSE	0.29135	0.2857		RMSE	0.28962	0.29044		
	p	0.95942	0.96101		p	0.96417	0.9641		
	NDEI	0.2539	0.24898		NDEI	0.22934	0.22998		
7-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		7
	c.t.	2.154	34.71		c.t.	0.03	0.03		150
	M.S.E	0.084886	0.080138		M.S.E	0.083882	0.084416		
	AME	0.22182	0.21657		AME	0.22062	0.2226		
	RMSE	0.29135	0.28309		RMSE	0.28962	0.29054		
	p	0.95942	0.96173		p	0.96417	0.96405		
	NDEI	0.2539	0.2467		NDEI	0.22934	0.23006		
7-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		4
	c.t.	2.113	65.444		c.t.	0.03	0.04		150
	M.S.E	0.084886	0.078765		M.S.E	0.083882	0.086594		
	AME	0.22182	0.21457		AME	0.22062	0.22623		
	RMSE	0.29135	0.28065		RMSE	0.28962	0.29427		
	p	0.95942	0.9624		p	0.96417	0.9631		
	NDEI	0.2539	0.24457		NDEI	0.22934	0.23301		

Πίνακας 8: Αποτελέσματα προσομοιώσεων των νευρωνικών δικτύων για μέγιστες ημερήσιες τιμές θερμοκρασίας με κανονικοποίηση μέσης τιμής ίσης με μηδέν και τυπικής απόκλισης μοναδιαίας

2 c

PREDICTOR(lm) IN-HID-OUT	TRAINING			TESTING			EPOCHS linear tansig
2-2-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	8
	c.t.	4.346	4.146	c.t.	0.01	0.01	150
	M.S.E	0.001653	0.001594	M.S.E	0.001642	0.001599	
	AME	0.030854	0.030276	AME	0.030872	0.030673	
	RMSE	0.040664	0.039924	RMSE	0.040516	0.039992	
	p	0.95722	0.95879	p	0.96211	0.96319	
	NDEI	0.074402	0.073048	NDEI	0.071551	0.070625	
2-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5
	c.t.	0.541	7.821	c.t.	0.01	0.01	150
	M.S.E	0.001653	0.001573	M.S.E	0.001642	0.001618	
	AME	0.030854	0.030118	AME	0.030872	0.030781	
	RMSE	0.040664	0.039661	RMSE	0.040516	0.04022	
	p	0.95722	0.95935	p	0.96211	0.96275	
	NDEI	0.074402	0.072568	NDEI	0.071551	0.071028	

2-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	0.691	14.361		c.t.	0.02	
	M.S.E	0.001653	0.001561		M.S.E	0.001642	
	AME	0.030854	0.030042		AME	0.030872	
	RMSE	0.040664	0.039511		RMSE	0.040516	
	p	0.95722	0.95966		p	0.96211	
	NDEI	0.074402	0.072294		NDEI	0.071551	
2-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	0.932	26.648		c.t.	0.02	
	M.S.E	0.001653	0.001554		M.S.E	0.001642	
	AME	0.030854	0.029945		AME	0.030872	
	RMSE	0.040664	0.039422		RMSE	0.040516	
	p	0.95722	0.95985		p	0.96211	
	NDEI	0.074402	0.07213		NDEI	0.071551	
3-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	0.691	5.879		c.t.	0.01	
	M.S.E	0.001628	0.001575		M.S.E	0.001612	
	AME	0.030637	0.030115		AME	0.030615	
	RMSE	0.040355	0.039692		RMSE	0.040153	
	p	0.95786	0.95927		p	0.96279	
	NDEI	0.073832	0.072619		NDEI	0.070903	
3-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	0.581	8.181		c.t.	0.01	
	M.S.E	0.001628	0.001573		M.S.E	0.001612	
	AME	0.030637	0.030134		AME	0.030615	
	RMSE	0.040355	0.039662		RMSE	0.040153	
	p	0.95786	0.95933		p	0.96279	
	NDEI	0.073832	0.072565		NDEI	0.070903	
3-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	7 150
	c.t.	1.131	18.156		c.t.	0.02	
	M.S.E	0.001628	0.001549		M.S.E	0.001612	
	AME	0.030637	0.02998		AME	0.030615	
	RMSE	0.040355	0.039362		RMSE	0.040153	
	p	0.95786	0.95996		p	0.96279	
	NDEI	0.073832	0.072016		NDEI	0.070903	
3-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	1.171	33.127		c.t.	0.02	
	M.S.E	0.001628	0.001544		M.S.E	0.001612	
	AME	0.030637	0.029975		AME	0.030615	
	RMSE	0.040355	0.0393		RMSE	0.040153	
	p	0.95786	0.96008		p	0.96279	
	NDEI	0.073832	0.071903		NDEI	0.070903	
5-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	0.551	7.301		c.t.	0.02	
	M.S.E	0.001596	0.00155		M.S.E	0.001571	
	AME	0.030399	0.029975		AME	0.030186	
	RMSE	0.039949	0.039373		RMSE	0.039633	
	p	0.95873	0.95994		p	0.96373	
	NDEI	0.073083	0.07203		NDEI	0.069969	
5-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	6 150
	c.t.	0.831	12.037		c.t.	0.02	
	M.S.E	0.001596	0.001523		M.S.E	0.001571	
	AME	0.030399	0.029754		AME	0.030186	
	RMSE	0.039949	0.039021		RMSE	0.039633	
	p	0.95873	0.96066		p	0.96373	
	NDEI	0.073083	0.071387		NDEI	0.069969	
5-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	

	c.t.	0.991	26.298		c.t.	0.02	0.03		4 150
	M.S.E	0.001596	0.001513		M.S.E	0.001571	0.001598		
	AME	0.030399	0.029675		AME	0.030186	0.030545		
	RMSE	0.039949	0.0389		RMSE	0.039633	0.039982		
	p	0.95873	0.96091		p	0.96373	0.96324		
	NDEI	0.073083	0.071165		NDEI	0.069969	0.070585		
5-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		4 150
	c.t.	1.582	48.139		c.t.	0.03	0.03		
	M.S.E	0.001596	0.001503		M.S.E	0.001571	0.001598		
	AME	0.030399	0.029596		AME	0.030186	0.030545		
	RMSE	0.039949	0.038763		RMSE	0.039633	0.039982		
	p	0.95873	0.96119		p	0.96373	0.96324		
	NDEI	0.073083	0.070914		NDEI	0.069969	0.070585		
7-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		5 150
	c.t.	0.701	9.133		c.t.	0.02	0.02		
	M.S.E	0.001569	0.001521		M.S.E	0.00155	0.001539		
	AME	0.030153	0.02975		AME	0.02999	0.02994		
	RMSE	0.039605	0.039005		RMSE	0.03937	0.039226		
	p	0.95942	0.96066		p	0.96417	0.96451		
	NDEI	0.072445	0.071347		NDEI	0.069489	0.069235		
7-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		5 150
	c.t.	0.822	15.362		c.t.	0.02	0.03		
	M.S.E	0.001569	0.001504		M.S.E	0.00155	0.001537		
	AME	0.030153	0.029559		AME	0.02999	0.02992		
	RMSE	0.039605	0.038783		RMSE	0.03937	0.039206		
	p	0.95942	0.96112		p	0.96417	0.96458		
	NDEI	0.072445	0.070942		NDEI	0.069489	0.069198		
7-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		4 150
	c.t.	1.262	34.42		c.t.	0.03	0.03		
	M.S.E	0.001569	0.001475		M.S.E	0.00155	0.001555		
	AME	0.030153	0.029337		AME	0.02999	0.030153		
	RMSE	0.039605	0.038413		RMSE	0.03937	0.039436		
	p	0.95942	0.96187		p	0.96417	0.96419		
	NDEI	0.072445	0.070264		NDEI	0.069489	0.069604		
7-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		4 150
	c.t.	2.123	64.422		c.t.	0.04	0.04		
	M.S.E	0.001569	0.001464		M.S.E	0.00155	0.001572		
	AME	0.030153	0.02923		AME	0.02999	0.030409		
	RMSE	0.039605	0.038267		RMSE	0.03937	0.039651		
	p	0.95942	0.96217		p	0.96417	0.96376		
	NDEI	0.072445	0.069997		NDEI	0.069489	0.069985		

Πίνακας 9: Αποτελέσματα προσομοιώσεων των νευρωνικών δικτύων για μέγιστες ημερήσιες τιμές θερμοκρασίας με κανονικοποίηση 0.1-0.9

3a

PREDICTOR(lm) IN-HID-OUT	TRAINING			TESTING			EPOCHS linear tansig
2-2-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	

	c.t.	0.59	4.416		c.t.	0.01	0.02	11
	M.S.E	2.6664	2.6105		M.S.E	6.9931	6.5542	69
	AME	1.2283	1.219		AME	1.5048	1.4852	
	RMSE	1.6329	1.6157		RMSE	2.6444	2.5601	
	p	0.96825	0.96893		p	0.92943	0.9336	
	NDEI	0.10342	0.10233		NDEI	0.15728	0.15226	
2-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	7
	c.t.	0.721	7.711		c.t.	0.02	0.02	150
	M.S.E	2.6664	2.5781		M.S.E	6.9931	6.8289	
	AME	1.2283	1.2105		AME	1.5048	1.501	
	RMSE	1.6329	1.6057		RMSE	2.6444	2.6132	
	p	0.96825	0.96932		p	0.92943	0.93084	
	NDEI	0.10342	0.1017		NDEI	0.15728	0.15542	
2-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	8
	c.t.	0.992	15.182		c.t.	0.02	0.02	150
	M.S.E	2.6664	2.5451		M.S.E	6.9931	6.7883	
	AME	1.2283	1.2035		AME	1.5048	1.5045	
	RMSE	1.6329	1.5953		RMSE	2.6444	2.6054	
	p	0.96825	0.96972		p	0.92943	0.93124	
	NDEI	0.10342	0.10104		NDEI	0.15728	0.15496	
2-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	4
	c.t.	1.152	28.721		c.t.	0.02	0.03	150
	M.S.E	2.6664	2.5346		M.S.E	6.9931	6.4953	
	AME	1.2283	1.2001		AME	1.5048	1.4849	
	RMSE	1.6329	1.592		RMSE	2.6444	2.5486	
	p	0.96825	0.96985		p	0.92943	0.93428	
	NDEI	0.10342	0.10083		NDEI	0.15728	0.15157	
3-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	10
	c.t.	0.621	5.899		c.t.	0.02	0.02	150
	M.S.E	2.6137	2.5139		M.S.E	7.1537	6.9317	
	AME	1.2199	1.1967		AME	1.5143	1.4913	
	RMSE	1.6167	1.5855		RMSE	2.6746	2.6328	
	p	0.96888	0.97009		p	0.92794	0.93014	
	NDEI	0.10239	0.10041		NDEI	0.15906	0.15657	
3-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	8
	c.t.	0.731	8.021		c.t.	0.02	0.021	150
	M.S.E	2.6137	2.5519		M.S.E	7.1537	6.7532	
	AME	1.2199	1.2082		AME	1.5143	1.4989	
	RMSE	1.6167	1.5975		RMSE	2.6746	2.5987	
	p	0.96888	0.96963		p	0.92794	0.9317	
	NDEI	0.10239	0.10117		NDEI	0.15906	0.15454	
3-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6
	c.t.	1.011	17.605		c.t.	0.02	0.02	150
	M.S.E	2.6137	2.4837		M.S.E	7.1537	7.1335	
	AME	1.2199	1.19		AME	1.5143	1.5063	
	RMSE	1.6167	1.576		RMSE	2.6746	2.6709	
	p	0.96888	0.97045		p	0.92794	0.92823	
	NDEI	0.10239	0.09981		NDEI	0.15906	0.15883	
3-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6
	c.t.	1.682	34.73		c.t.	0.03	0.04	150
	M.S.E	2.6137	2.5075		M.S.E	7.1537	6.4805	
	AME	1.2199	1.1991		AME	1.5143	1.4851	
	RMSE	1.6167	1.5835		RMSE	2.6746	2.5457	
	p	0.96888	0.97017		p	0.92794	0.93442	
	NDEI	0.10239	0.10028		NDEI	0.15906	0.15139	
5-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	8
	c.t.	0.791	2.744		c.t.	0.02	0.03	

	M.S.E	2.5639	2.5306		M.S.E	6.9796	6.6733		47
	AME	1.2118	1.2055		AME	1.4987	1.4864		
	RMSE	1.6012	1.5908		RMSE	2.6419	2.5833		
	p	0.96948	0.96989		p	0.92967	0.93248		
	NDEI	0.10139	0.10073		NDEI	0.15706	0.15358		
5-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		8
	c.t.	0.952	13.72		c.t.	0.02	0.03		150
	M.S.E	2.5639	2.5185		M.S.E	6.9796	6.6483		
	AME	1.2118	1.2035		AME	1.4987	1.4804		
	RMSE	1.6012	1.587		RMSE	2.6419	2.5784		
	p	0.96948	0.97003		p	0.92967	0.93277		
	NDEI	0.10139	0.10049		NDEI	0.15706	0.15329		
5-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		9
	c.t.	1.943	27.269		c.t.	0.02	0.03		150
	M.S.E	2.5639	2.5056		M.S.E	6.9796	6.4482		
	AME	1.2118	1.1991		AME	1.4987	1.4777		
	RMSE	1.6012	1.5829		RMSE	2.6419	2.5393		
	p	0.96948	0.97019		p	0.92967	0.93469		
	NDEI	0.10139	0.10024		NDEI	0.15706	0.15097		
5-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		10
	c.t.	3.606	48.19		c.t.	0.03	0.04		150
	M.S.E	2.5639	2.4111		M.S.E	6.9796	6.6294		
	AME	1.2118	1.1801		AME	1.4987	1.5005		
	RMSE	1.6012	1.5528		RMSE	2.6419	2.5748		
	p	0.96948	0.97133		p	0.92967	0.93313		
	NDEI	0.10139	0.098327		NDEI	0.15706	0.15307		
7-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		7
	c.t.	0.801	10.195		c.t.	0.03	0.02		150
	M.S.E	2.5123	2.4886		M.S.E	6.8781	6.6038		
	AME	1.2042	1.1983		AME	1.4871	1.4752		
	RMSE	1.585	1.5775		RMSE	2.6226	2.5698		
	p	0.97008	0.97037		p	0.93067	0.93318		
	NDEI	0.10035	0.099876		NDEI	0.15587	0.15273		
7-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		8
	c.t.	1.312	15.282		c.t.	0.03	0.03		150
	M.S.E	2.5123	2.484		M.S.E	6.8781	6.6241		
	AME	1.2042	1.1974		AME	1.4871	1.4756		
	RMSE	1.585	1.5761		RMSE	2.6226	2.5737		
	p	0.97008	0.97043		p	0.93067	0.93297		
	NDEI	0.10035	0.099783		NDEI	0.15587	0.15297		
7-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		5
	c.t.	1.743	34.21		c.t.	0.03	0.03		150
	M.S.E	2.5123	2.4666		M.S.E	6.8781	6.639		
	AME	1.2042	1.1932		AME	1.4871	1.4838		
	RMSE	1.585	1.5705		RMSE	2.6226	2.5766		
	p	0.97008	0.97064		p	0.93067	0.93277		
	NDEI	0.10035	0.099434		NDEI	0.15587	0.15314		
7-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG		6
	c.t.	3.736	72.414		c.t.	0.03	0.04		150
	M.S.E	2.5123	2.4295		M.S.E	6.8781	6.5357		
	AME	1.2042	1.1847		AME	1.4871	1.4766		
	RMSE	1.585	1.5587		RMSE	2.6226	2.5565		
	p	0.97008	0.97108		p	0.93067	0.93391		
	NDEI	0.10035	0.098683		NDEI	0.15587	0.15194		

Πίνακας 10: Αποτελέσματα προσομοιώσεων των νευρωνικών δικτύων για πραγματικά δεδομένα ελάχιστων ημερησίων τιμών θερμοκρασίας

3b

PREDICTOR(lm) IN-HID-OUT	TRAINING			TESTING			EPOCHS linear tansig
2-2-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	2.764	4.046	c.t.	0.02	0.02	
	M.S.E	0.043643	0.04197	M.S.E	0.11446	0.14279	
	AME	0.15714	0.15452	AME	0.19252	0.19942	
	RMSE	0.20891	0.20486	RMSE	0.33832	0.37787	
	p	0.96825	0.96949	p	0.92943	0.9131	
	NDEI	0.21817	0.21394	NDEI	0.34573	0.38615	
2-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	7 150
	c.t.	0.661	7.391	c.t.	0.02	0.02	
	M.S.E	0.043643	0.041576	M.S.E	0.11446	0.10666	
	AME	0.15714	0.15377	AME	0.19252	0.19094	
	RMSE	0.20891	0.2039	RMSE	0.33832	0.32659	
	p	0.96825	0.96978	p	0.92943	0.93401	
	NDEI	0.21817	0.21294	NDEI	0.34573	0.33374	
2-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	0.851	15.832	c.t.	0.01	0.02	
	M.S.E	0.043643	0.04119	M.S.E	0.11446	0.11651	
	AME	0.15714	0.15294	AME	0.19252	0.19307	
	RMSE	0.20891	0.20295	RMSE	0.33832	0.34133	
	p	0.96825	0.97007	p	0.92943	0.92821	
	NDEI	0.21817	0.21195	NDEI	0.34573	0.34881	
2-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	1.182	26.728	c.t.	0.02	0.031	
	M.S.E	0.043643	0.04105	M.S.E	0.11446	0.10869	
	AME	0.15714	0.15289	AME	0.19252	0.19125	
	RMSE	0.20891	0.20261	RMSE	0.33832	0.32968	
	p	0.96825	0.97017	p	0.92943	0.93299	
	NDEI	0.21817	0.21159	NDEI	0.34573	0.3369	
3-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 130
	c.t.	0.681	5.248	c.t.	0.02	0.02	
	M.S.E	0.042782	0.041244	M.S.E	0.11709	0.11316	
	AME	0.15607	0.15359	AME	0.19374	0.19296	
	RMSE	0.20684	0.20309	RMSE	0.34219	0.33639	
	p	0.96888	0.97002	p	0.92794	0.9303	
	NDEI	0.21605	0.21213	NDEI	0.34967	0.34374	
3-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	0.581	9.033	c.t.	0.02	0.01	
	M.S.E	0.042782	0.040878	M.S.E	0.11709	0.098071	
	AME	0.15607	0.15279	AME	0.19374	0.18836	
	RMSE	0.20684	0.20218	RMSE	0.34219	0.31316	
	p	0.96888	0.97029	p	0.92794	0.93941	
	NDEI	0.21605	0.21119	NDEI	0.34967	0.32001	
3-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	0.751	18.747	c.t.	0.02	0.03	
	M.S.E	0.042782	0.040674	M.S.E	0.11709	0.10252	
	AME	0.15607	0.15238	AME	0.19374	0.19105	
	RMSE	0.20684	0.20168	RMSE	0.34219	0.32019	
	p	0.96888	0.97044	p	0.92794	0.93694	
	NDEI	0.21605	0.21066	NDEI	0.34967	0.3272	
3-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	1.081	36.292	c.t.	0.02	0.03	
	M.S.E	0.042782	0.040404	M.S.E	0.11709	0.10046	

	AME	0.15607	0.15166		AME	0.19374	0.19137	
	RMSE	0.20684	0.20101		RMSE	0.34219	0.31695	
	p	0.96888	0.97064		p	0.92794	0.93812	
	NDEI	0.21605	0.20996		NDEI	0.34967	0.32388	
5-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	0.681	7.821		c.t.	0.02	0.02	
	M.S.E	0.041966	0.041428		M.S.E	0.11424	0.1083	
	AME	0.15503	0.15437		AME	0.19174	0.18923	
	RMSE	0.20486	0.20354		RMSE	0.338	0.32909	
	p	0.96948	0.96988		p	0.92967	0.93302	
	NDEI	0.21401	0.21263		NDEI	0.34553	0.33642	
5-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	0.671	12.018		c.t.	0.02	0.02	
	M.S.E	0.041966	0.040082		M.S.E	0.11424	0.1098	
	AME	0.15503	0.15149		AME	0.19174	0.19249	
	RMSE	0.20486	0.20021		RMSE	0.338	0.33136	
	p	0.96948	0.97088		p	0.92967	0.9325	
	NDEI	0.21401	0.20915		NDEI	0.34553	0.33874	
5-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	10 150
	c.t.	2.033	28.611		c.t.	0.02	0.03	
	M.S.E	0.041966	0.039714		M.S.E	0.11424	0.12695	
	AME	0.15503	0.15084		AME	0.19174	0.19713	
	RMSE	0.20486	0.19928		RMSE	0.338	0.3563	
	p	0.96948	0.97115		p	0.92967	0.92236	
	NDEI	0.21401	0.20819		NDEI	0.34553	0.36423	
5-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	7 150
	c.t.	2.954	47.709		c.t.	0.031	0.04	
	M.S.E	0.041966	0.039361		M.S.E	0.11424	0.099801	
	AME	0.15503	0.14964		AME	0.19174	0.19568	
	RMSE	0.20486	0.1984		RMSE	0.338	0.31591	
	p	0.96948	0.97141		p	0.92967	0.93855	
	NDEI	0.21401	0.20726		NDEI	0.34553	0.32295	
7-3-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6 150
	c.t.	0.681	9.714		c.t.	0.02	0.02	
	M.S.E	0.041122	0.039749		M.S.E	0.11258	0.11576	
	AME	0.15406	0.15135		AME	0.19026	0.19017	
	RMSE	0.20278	0.19937		RMSE	0.33553	0.34023	
	p	0.97008	0.9711		p	0.93067	0.929	
	NDEI	0.21197	0.2084		NDEI	0.34318	0.34795	
7-5-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6 150
	c.t.	0.871	15.242		c.t.	0.02	0.03	
	M.S.E	0.041122	0.039511		M.S.E	0.11258	0.11733	
	AME	0.15406	0.15069		AME	0.19026	0.19252	
	RMSE	0.20278	0.19877		RMSE	0.33553	0.34253	
	p	0.97008	0.97127		p	0.93067	0.92782	
	NDEI	0.21197	0.20778		NDEI	0.34318	0.35034	
7-10-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	6 150
	c.t.	2.083	34.169		c.t.	0.03	0.03	
	M.S.E	0.041122	0.039072		M.S.E	0.11258	0.09819	
	AME	0.15406	0.14983		AME	0.19026	0.19016	
	RMSE	0.20278	0.19767		RMSE	0.33553	0.31335	
	p	0.97008	0.9716		p	0.93067	0.93949	
	NDEI	0.21197	0.20662		NDEI	0.34318	0.3205	
7-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	5
	c.t.	2.984	68.178		c.t.	0.03	0.04	
	M.S.E	0.041122	0.038019		M.S.E	0.11258	0.12217	
	AME	0.15406	0.14799		AME	0.19026	0.20079	

	RMSE	0.20278	0.19498		RMSE	0.33553	0.34953	150
	p	0.97008	0.97237		p	0.93067	0.925	
	NDEI	0.21197	0.20382		NDEI	0.34318	0.3575	

Πίνακας 11: Αποτελέσματα προσομοιώσεων των νευρωνικών δικτύων για ελάχιστες ημερήσιες τιμές θερμοκρασίας με κανονικοποίηση μέσης τιμής ίσης με μηδέν και τυπικής απόκλισης μοναδιαίας

3c

PREDICTOR(lm) IN-HID-OUT	TRAINING			TESTING			EPOCHS linear tansig
2-2-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	2.583	4.196	c.t.	0.01	0.01	
	M.S.E	0.000865	0.000779	M.S.E	0.002115	0.002153	
	AME	0.021361	0.02105	AME	0.02617	0.026306	
	RMSE	0.028398	0.027909	RMSE	0.04599	0.046405	
	p	0.96825	0.96936	p	0.92943	0.9281	
	NDEI	0.068781	0.06756	NDEI	0.10694	0.1079	
2-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	6 150
	c.t.	0.531	7.091	c.t.	0.01	0.02	
	M.S.E	0.000865	0.000765	M.S.E	0.002115	0.002276	
	AME	0.021361	0.020881	AME	0.02617	0.026627	
	RMSE	0.028398	0.027659	RMSE	0.04599	0.04771	
	p	0.96825	0.96991	p	0.92943	0.92486	
	NDEI	0.068781	0.066991	NDEI	0.10694	0.11093	
2-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	3 150
	c.t.	0.601	14.531	c.t.	0.01	0.02	
	M.S.E	0.000865	0.000762	M.S.E	0.002115	0.002423	
	AME	0.021361	0.020849	AME	0.02617	0.026769	
	RMSE	0.028398	0.02761	RMSE	0.04599	0.049229	
	p	0.96825	0.97002	p	0.92943	0.9197	
	NDEI	0.068781	0.066873	NDEI	0.10694	0.11447	
2-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	0.911	26.708	c.t.	0.02	0.03	
	M.S.E	0.000865	0.000762	M.S.E	0.002115	0.001716	
	AME	0.021361	0.020817	AME	0.02617	0.025549	
	RMSE	0.028398	0.027596	RMSE	0.04599	0.04142	
	p	0.96825	0.97005	p	0.92943	0.94254	
	NDEI	0.068781	0.066838	NDEI	0.10694	0.096309	
3-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 29
	c.t.	0.501	6.329	c.t.	0.01	0.01	
	M.S.E	0.00079	0.000758	M.S.E	0.002164	0.001787	
	AME	0.021216	0.020798	AME	0.026336	0.025521	
	RMSE	0.028117	0.027541	RMSE	0.046515	0.042274	
	p	0.96888	0.97016	p	0.92794	0.94032	
	NDEI	0.068095	0.0667	NDEI	0.10815	0.098287	
3-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	7 150
	c.t.	0.761	8.262	c.t.	0.02	0.02	
	M.S.E	0.00079	0.000754	M.S.E	0.002164	0.002174	
	AME	0.021216	0.020747	AME	0.026336	0.026386	
	RMSE	0.028117	0.027457	RMSE	0.046515	0.04663	
	p	0.96888	0.97035	p	0.92794	0.92822	
	NDEI	0.068095	0.066497	NDEI	0.10815	0.10842	
3-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	0.912	18.687	c.t.	0.02	0.02	
	M.S.E	0.00079	0.000751	M.S.E	0.002164	0.002402	
	AME	0.021216	0.020715	AME	0.026336	0.026632	

	RMSE	0.028117	0.027411	RMSE	0.046515	0.049007	
	p	0.96888	0.97045	p	0.92794	0.92124	
	NDEI	0.068095	0.066385	NDEI	0.10815	0.11394	
3-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	1.342	33.338	c.t.	0.02	0.03	
	M.S.E	0.00079	0.000749	M.S.E	0.002164	0.000729	
	AME	0.021216	0.020702	AME	0.026336	0.029816	
	RMSE	0.028117	0.027364	RMSE	0.046515	0.085409	
	p	0.96888	0.97055	p	0.92794	0.80395	
	NDEI	0.068095	0.066272	NDEI	0.10815	0.19858	
5-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	7 150
	c.t.	0.711	7.651	c.t.	0.02	0.02	
	M.S.E	0.000775	0.000745	M.S.E	0.002111	0.001731	
	AME	0.021074	0.020649	AME	0.026064	0.02526	
	RMSE	0.027847	0.027296	RMSE	0.045946	0.0416	
	p	0.96948	0.9707	p	0.92967	0.94214	
	NDEI	0.067437	0.066103	NDEI	0.1068	0.096699	
5-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	0.681	12.147	c.t.	0.02	0.021	
	M.S.E	0.000775	0.000742	M.S.E	0.002111	0.001786	
	AME	0.021074	0.020604	AME	0.026064	0.025641	
	RMSE	0.027847	0.027246	RMSE	0.045946	0.042264	
	p	0.96948	0.97081	p	0.92967	0.94039	
	NDEI	0.067437	0.06598	NDEI	0.1068	0.098244	
5-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	0.991	29.623	c.t.	0.02	0.02	
	M.S.E	0.000775	0.000729	M.S.E	0.002111	0.004293	
	AME	0.021074	0.020487	AME	0.026064	0.028317	
	RMSE	0.027847	0.027005	RMSE	0.045946	0.065523	
	p	0.96948	0.97133	p	0.92967	0.86871	
	NDEI	0.067437	0.065397	NDEI	0.1068	0.15231	
5-15-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	6 150
	c.t.	2.053	48.296	c.t.	0.03	0.03	
	M.S.E	0.000775	0.000733	M.S.E	0.002111	0.007073	
	AME	0.021074	0.020549	AME	0.026064	0.030187	
	RMSE	0.027847	0.027077	RMSE	0.045946	0.084099	
	p	0.96948	0.97118	p	0.92967	0.80465	
	NDEI	0.067437	0.06557	NDEI	0.1068	0.19549	
7-3-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	6 150
	c.t.	0.691	9.524	c.t.	0.03	0.02	
	M.S.E	0.000759	0.000735	M.S.E	0.00208	0.001753	
	AME	0.020943	0.02057	AME	0.025863	0.025244	
	RMSE	0.027566	0.027104	RMSE	0.045611	0.041874	
	p	0.97008	0.97109	p	0.93067	0.94136	
	NDEI	0.066745	0.065627	NDEI	0.106	0.097316	
7-5-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	5 150
	c.t.	0.801	16.834	c.t.	0.02	0.03	
	M.S.E	0.000759	0.000735	M.S.E	0.00208	0.002785	
	AME	0.020943	0.020594	AME	0.025863	0.026884	
	RMSE	0.027566	0.027103	RMSE	0.045611	0.052778	
	p	0.97008	0.97109	p	0.93067	0.90912	
	NDEI	0.066745	0.065626	NDEI	0.106	0.12266	
7-10-1	Metr/a.f.	LINEAR	TANSIG	Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	1.352	34.72	c.t.	0.03	0.03	
	M.S.E	0.000759	0.000725	M.S.E	0.00208	0.0070948	
	AME	0.020943	0.02047	AME	0.025863	0.031582	
	RMSE	0.027566	0.026924	RMSE	0.045611	0.084231	

	p	0.97008	0.97148		p	0.93067	0.80242	
	NDEI	0.066745	0.065192		NDEI	0.106	0.19575	
7-15-1	Metr/a.f.	LINEAR	TANSIG		Metr/a.f.	LINEAR	TANSIG	4 150
	c.t.	2.143	64.473		c.t.	0.04	0.04	
	M.S.E	0.000759	0.000713		M.S.E	0.00208	0.010963	
	AME	0.020943	0.020325		AME	0.025863	0.033548	
	RMSE	0.027566	0.026694		RMSE	0.045611	0.10471	
	p	0.97008	0.972		p	0.93067	0.73321	
	NDEI	0.066745	0.064634		NDEI	0.106	0.24334	

Πίνακας 12: Αποτελέσματα προσομοιώσεων των νευρωνικών δικτύων για ελάχιστες ημερήσιες τιμές θερμοκρασίας με κανονικοποίηση 0.1-0.9

2. ΓΡΑΦΙΚΕΣ ΠΑΡΑΣΤΑΣΕΙΣ

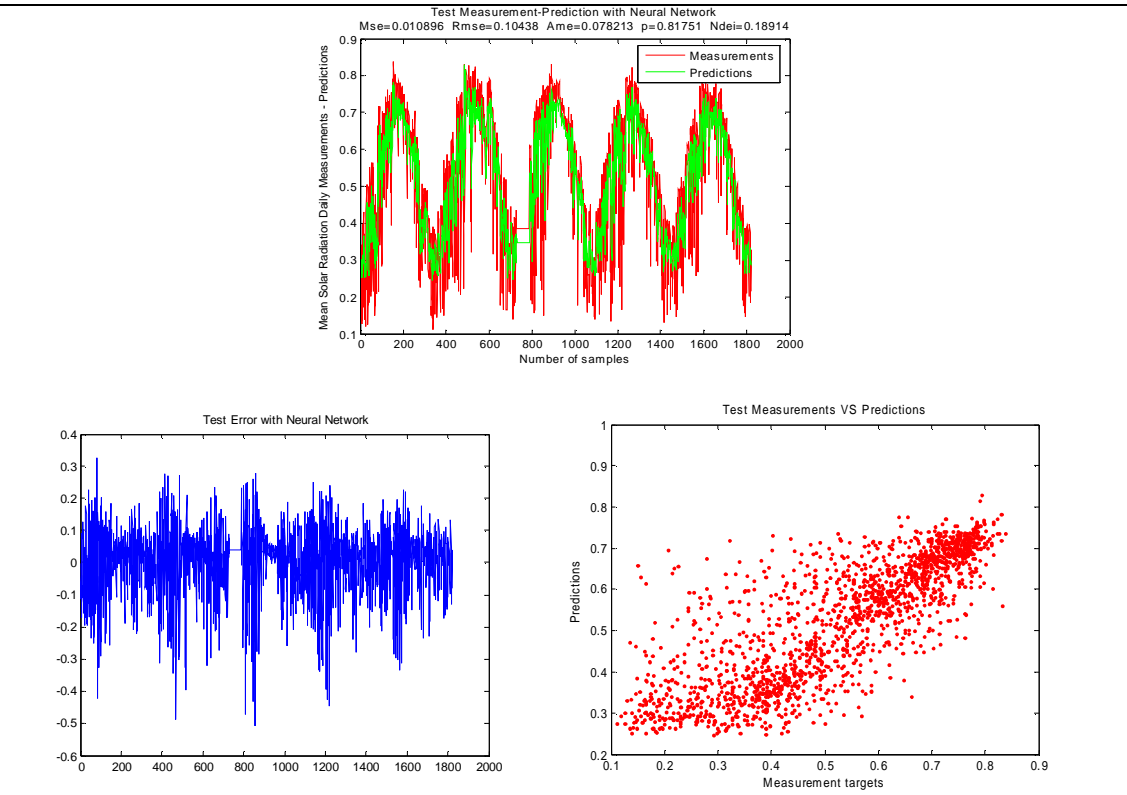
Παρακάτω παρατίθενται οι εξής τρεις γραφικές παραστάσεις για καθεμιά από τις περιπτώσεις εκπαίδευσεων των ‘καλύτερων’ 16 νευρωνικών δικτύων:

1. Y-αξονας: Πραγματικές ημερήσιες τιμές και αντίστοιχες προβλέψεις
δεδομένων δοκιμής ηλιακής ακτινοβολίας ή θερμοκρασίας
X-άξονας: Αριθμός δεδομένων
2. Y-αξονας: Τιμές σφάλματος για προβλέψεις δεδομένων δοκιμής ηλιακής
ακτινοβολίας ή θερμοκρασίας
X-άξονας: Αριθμός δεδομένων
3. Y-αξονας: Τιμές προβλέψεων δεδομένων δοκιμής ηλιακής ακτινοβολίας ή
θερμοκρασίας
X-άξονας: Τιμές δεδομένων δοκιμής

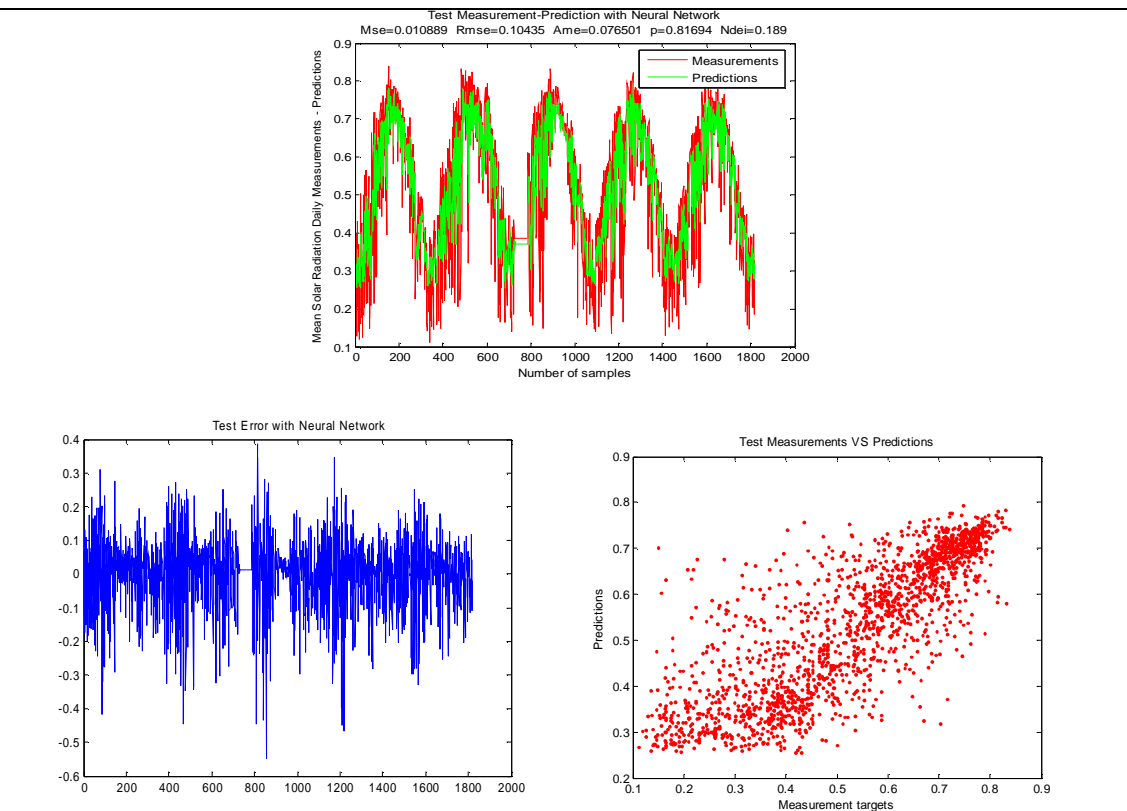
Για τα δεδομένα ηλιακής ακτινοβολίας έχουν προκύψει τα εξής τέσσερα καλύτερα νευρωνικά δίκτυα.

5. 5-15-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος
6. 7-3-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος
7. 7-10-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος
4. 5-10-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος

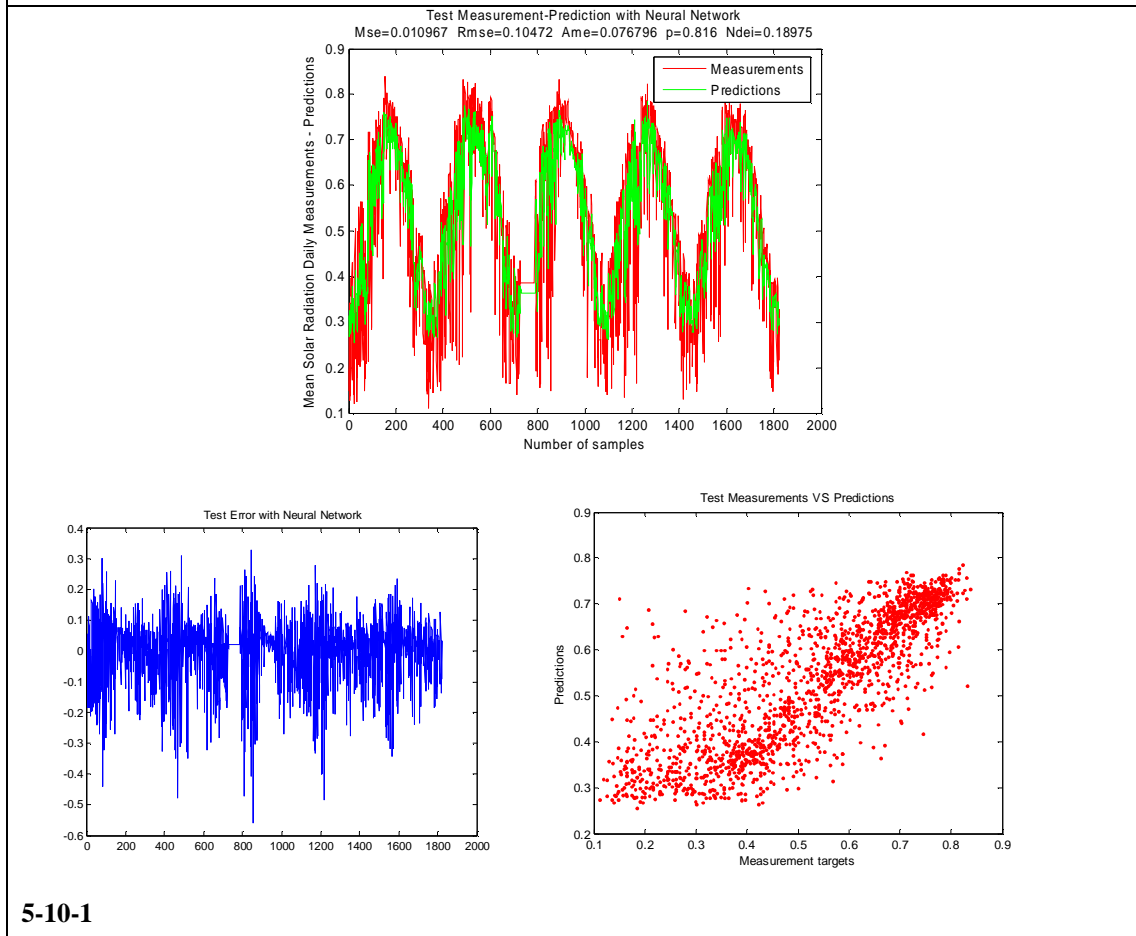
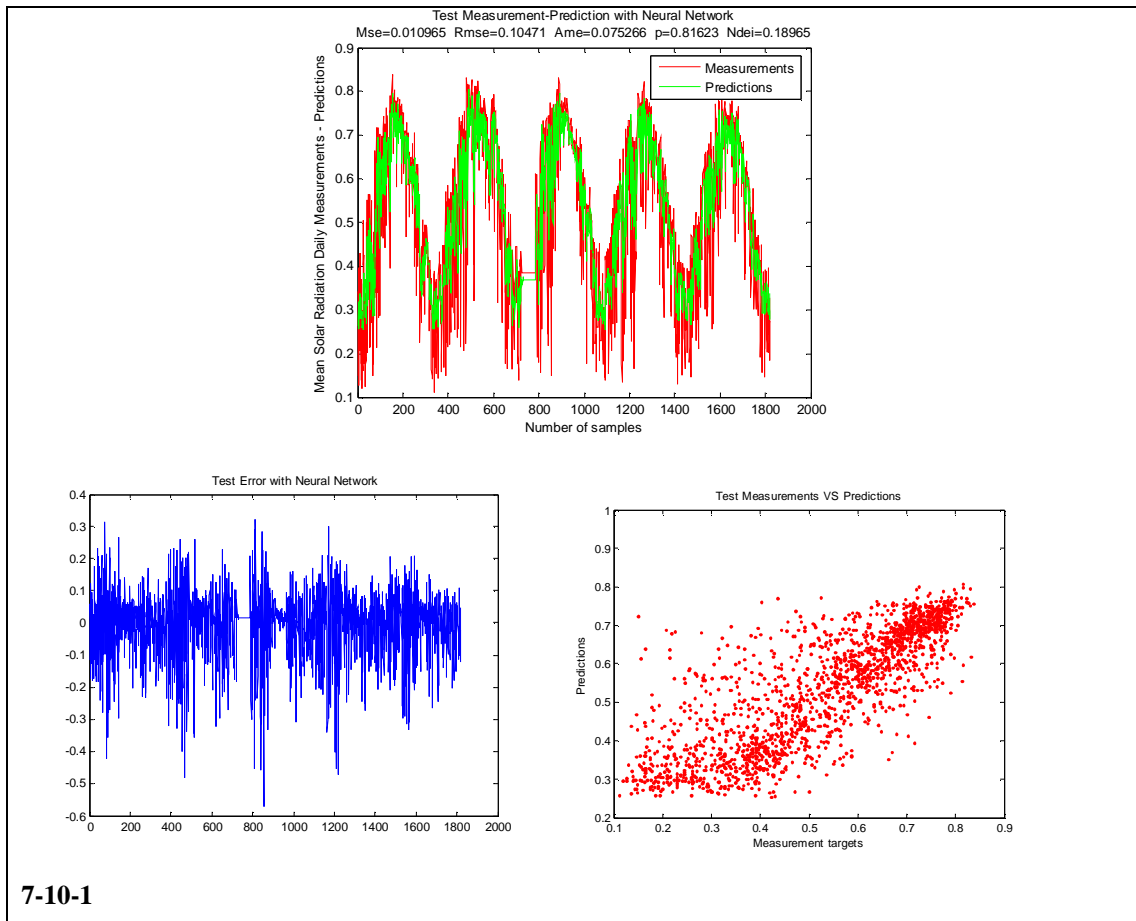
Έχουμε λοιπόν τις παρακάτω γραφικές για τα προαναφερθέντα νευρωνικά δίκτυα.



5-15-1



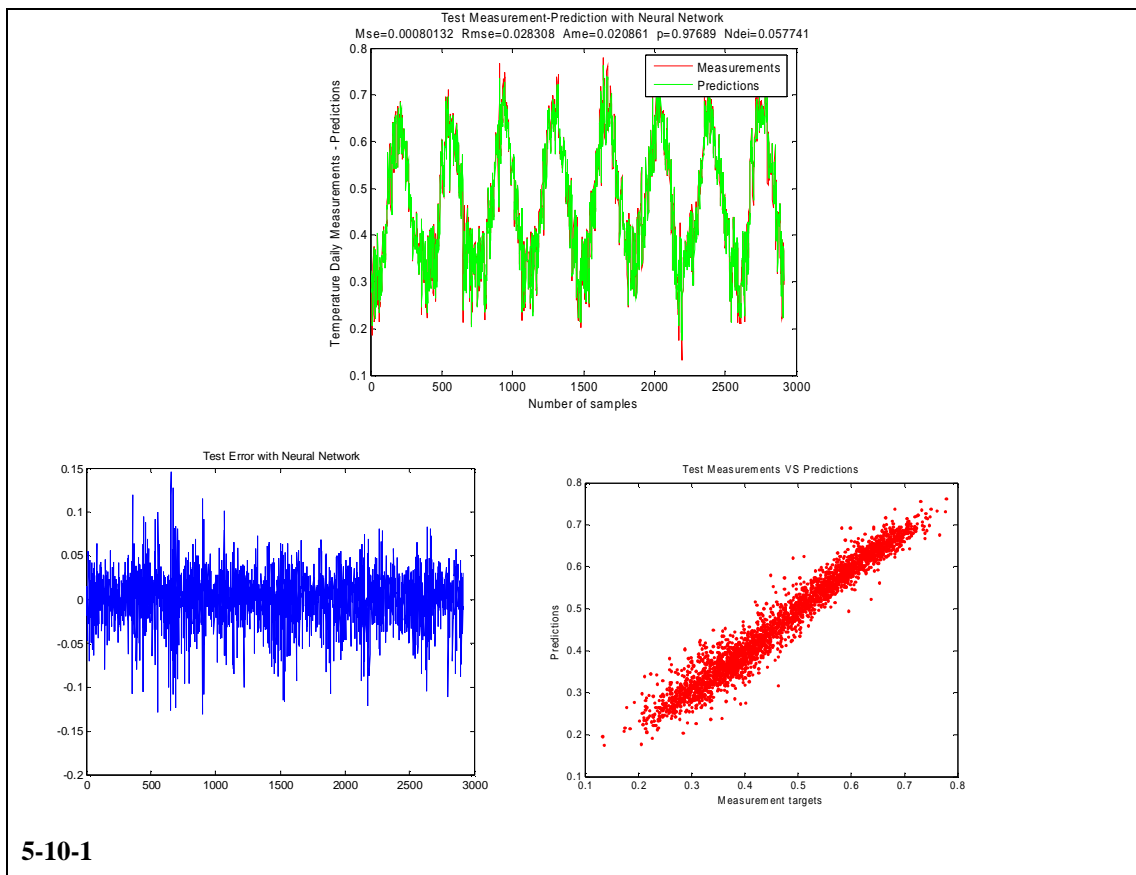
7-3-1

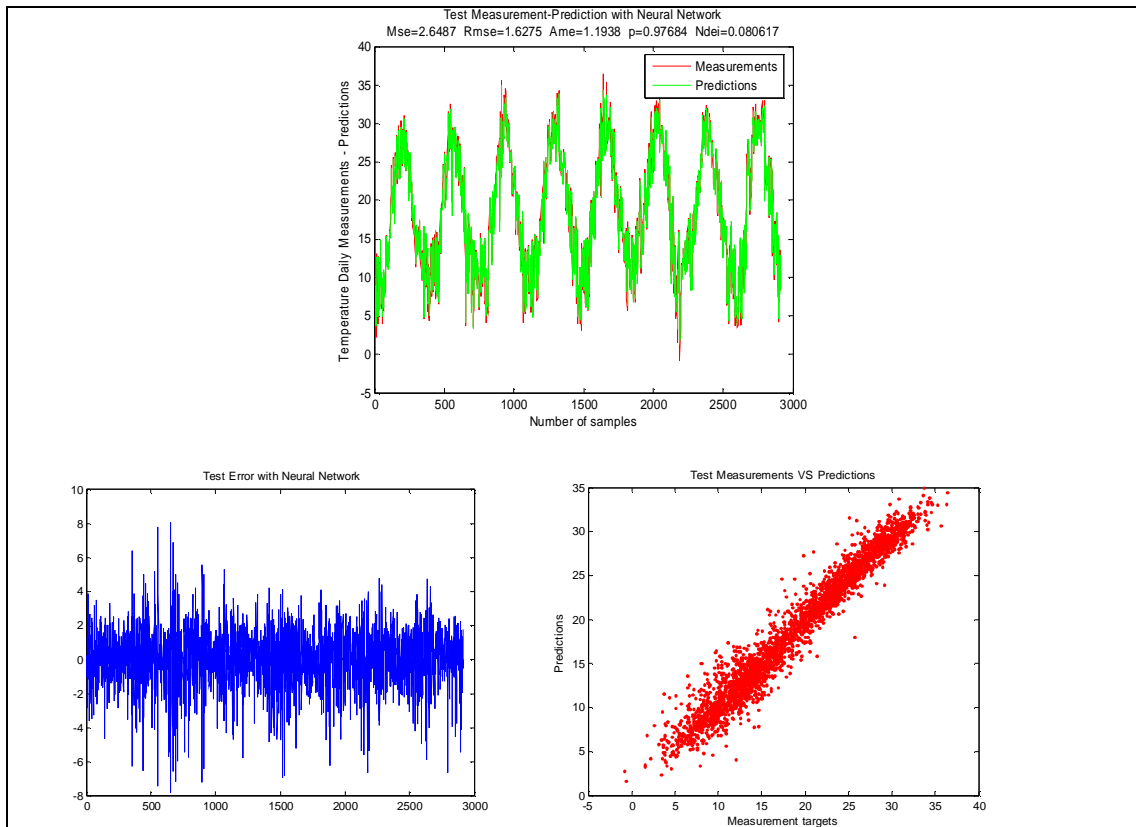


Για τα δεδομένα μέσης ημερήσιας θερμοκρασίας έχουν προκύψει τα εξής τέσσερα καλύτερα νευρωνικά δίκτυα.

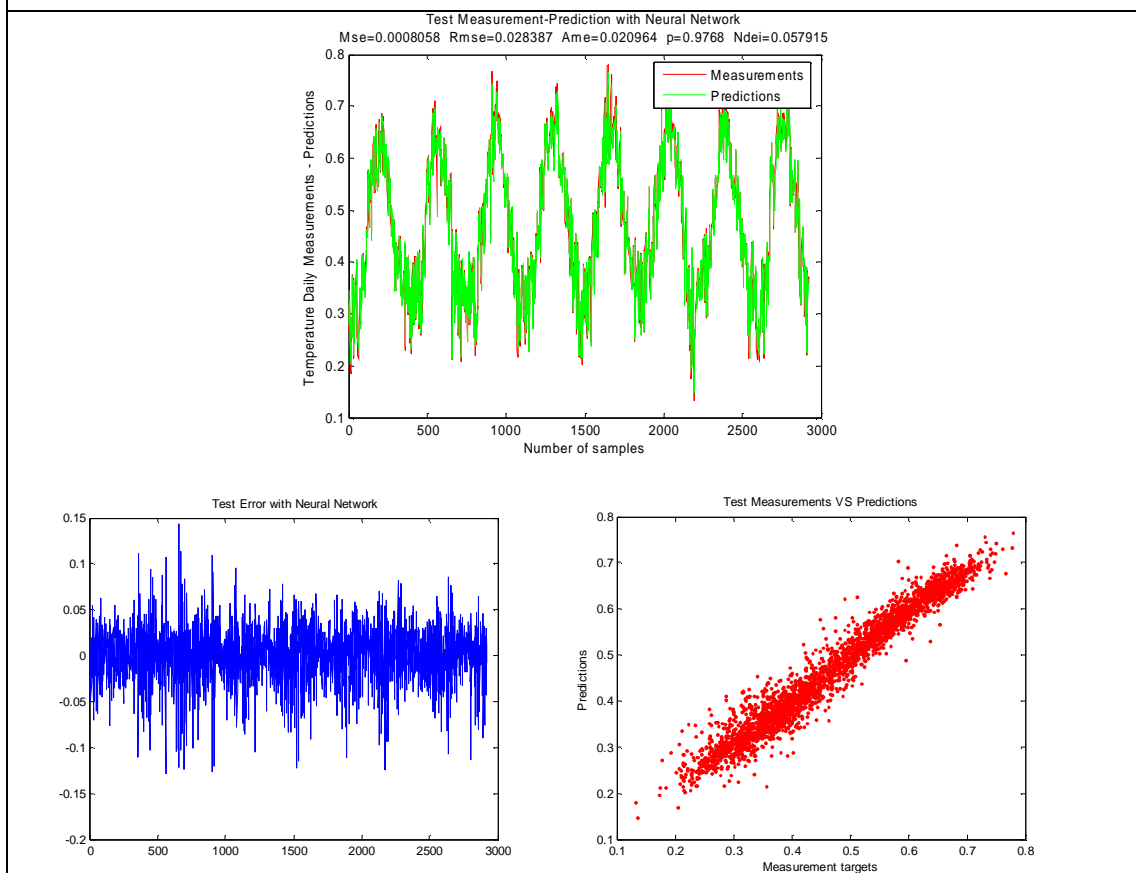
1. 5-10-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος
2. 7-3-1 για πραγματικά δεδομένα με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος
3. 3-5-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος
4. 7-3-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος

Οι αντίστοιχες γραφικές παραστάσεις για παραπάνω νευρωνικά δίκτυα παρατίθενται παρακάτω:

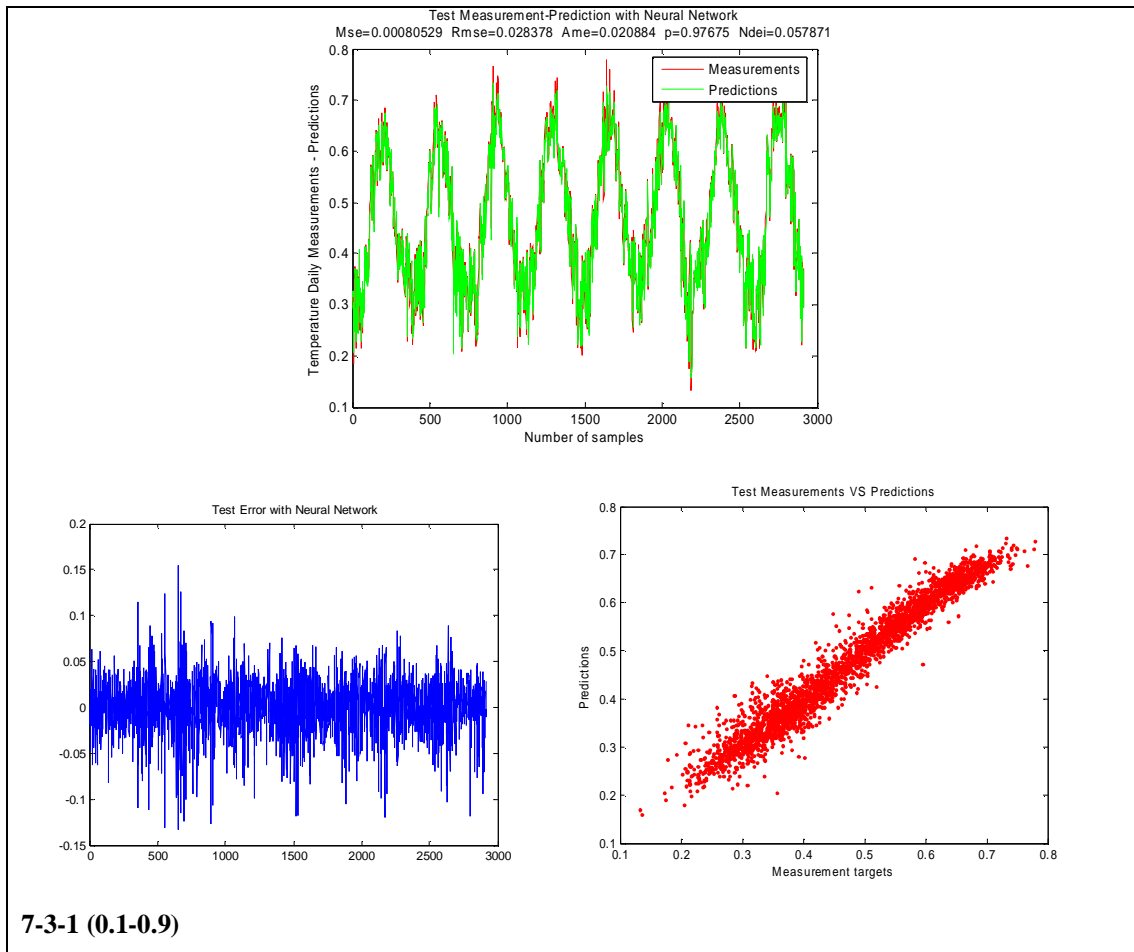




7-3-1 πραγματικά δεδομένα



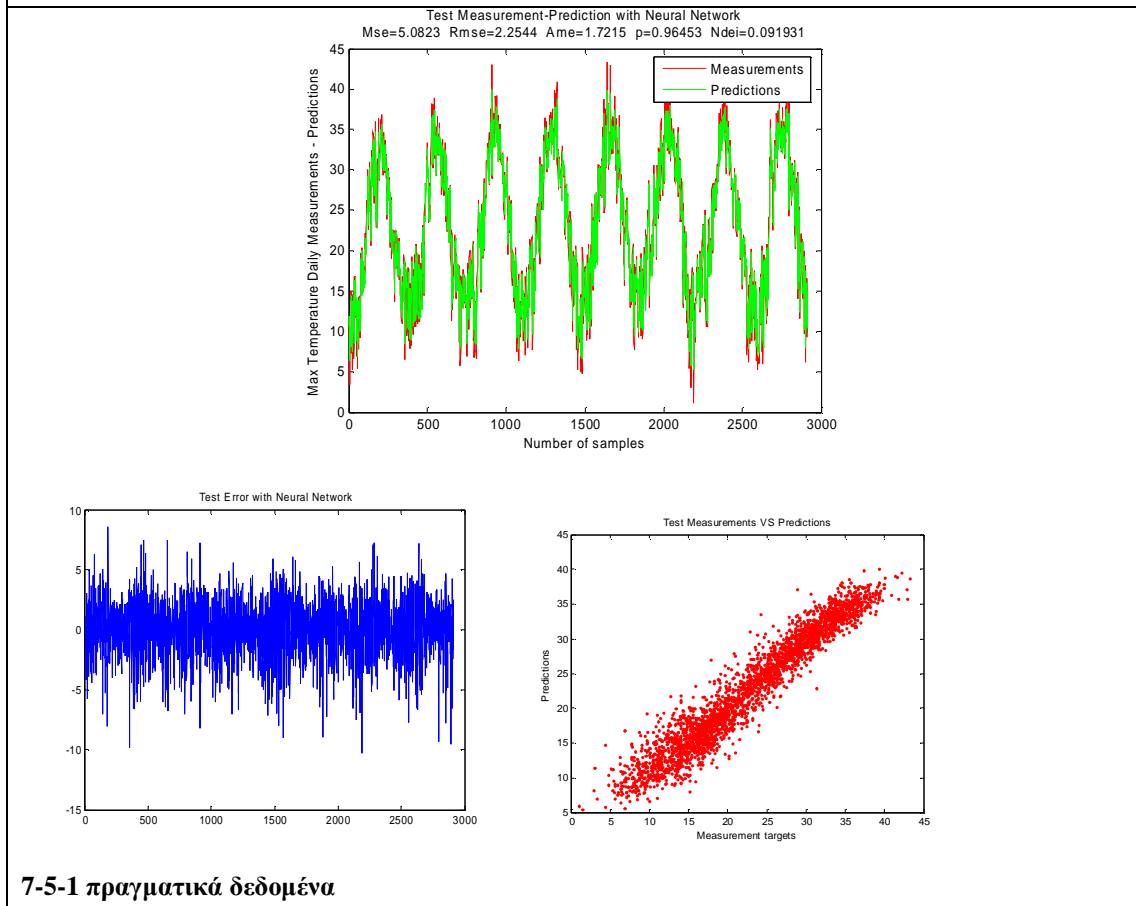
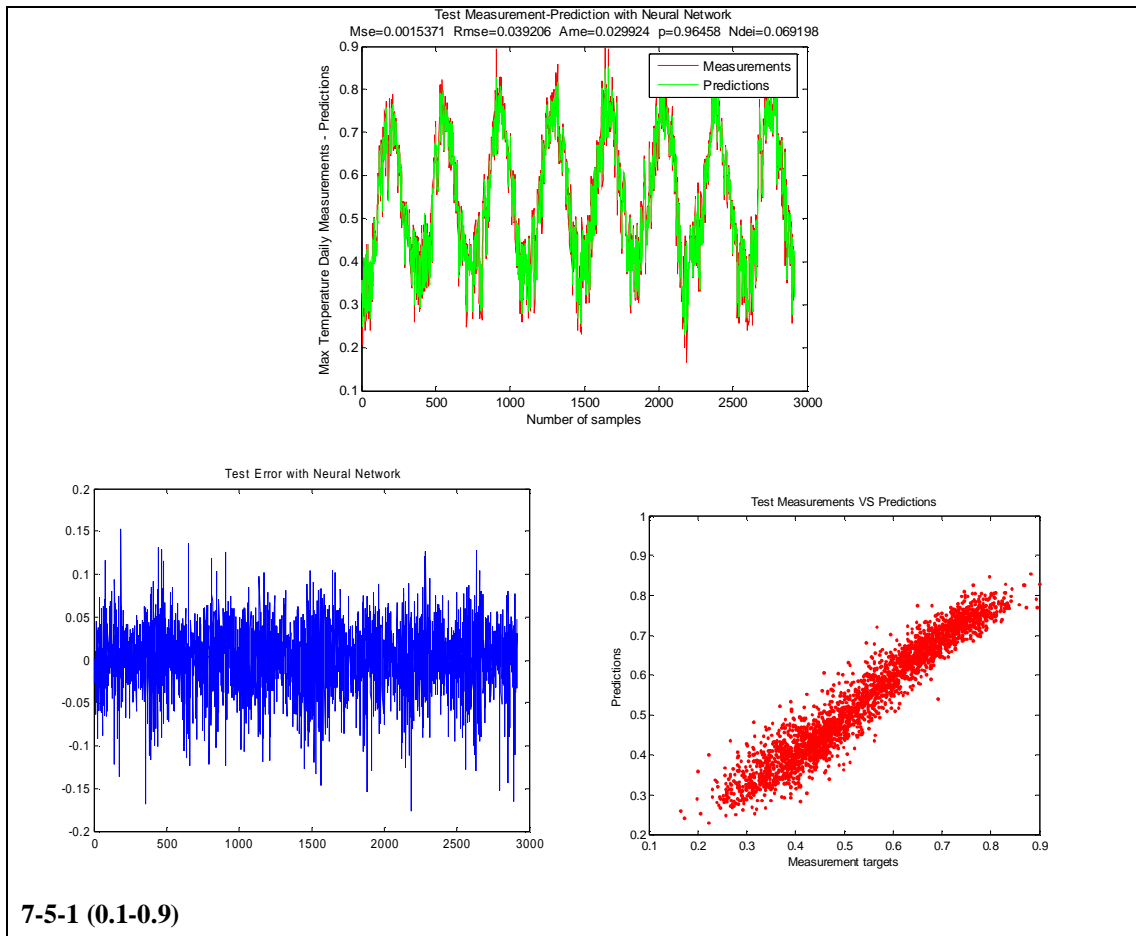
3-5-1

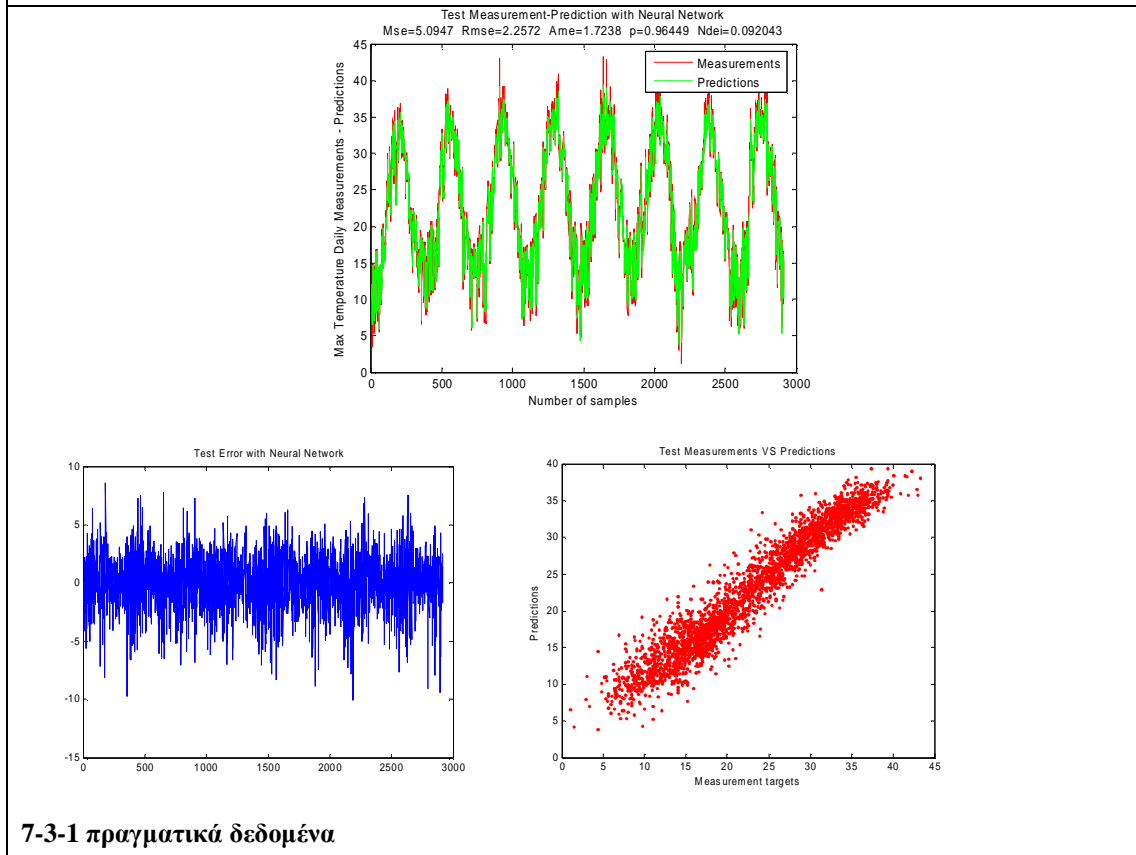
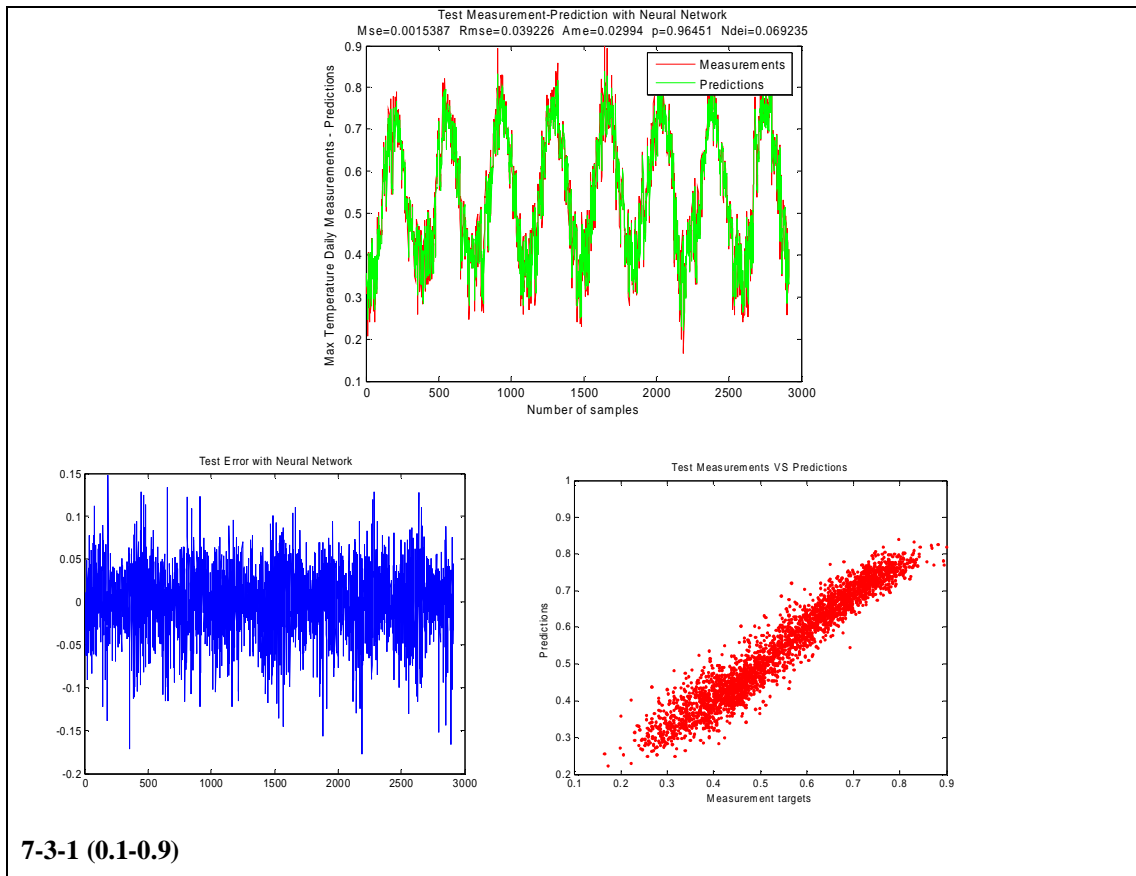


Για τα δεδομένα μέγιστης ημερήσιας θερμοκρασίας έχουν προκύψει τα εξής τέσσερα καλύτερα νευρωνικά δίκτυα.

1. 7-5-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος
2. 7-5-1 για πραγματικά δεδομένα με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος
3. 7-3-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος
4. 7-3-1 για πραγματικά δεδομένα με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.

Οι αντίστοιχες γραφικές παραστάσεις για τα προαναφερθέντα νευρωνικά δίκτυα παρατίθενται παρακάτω:

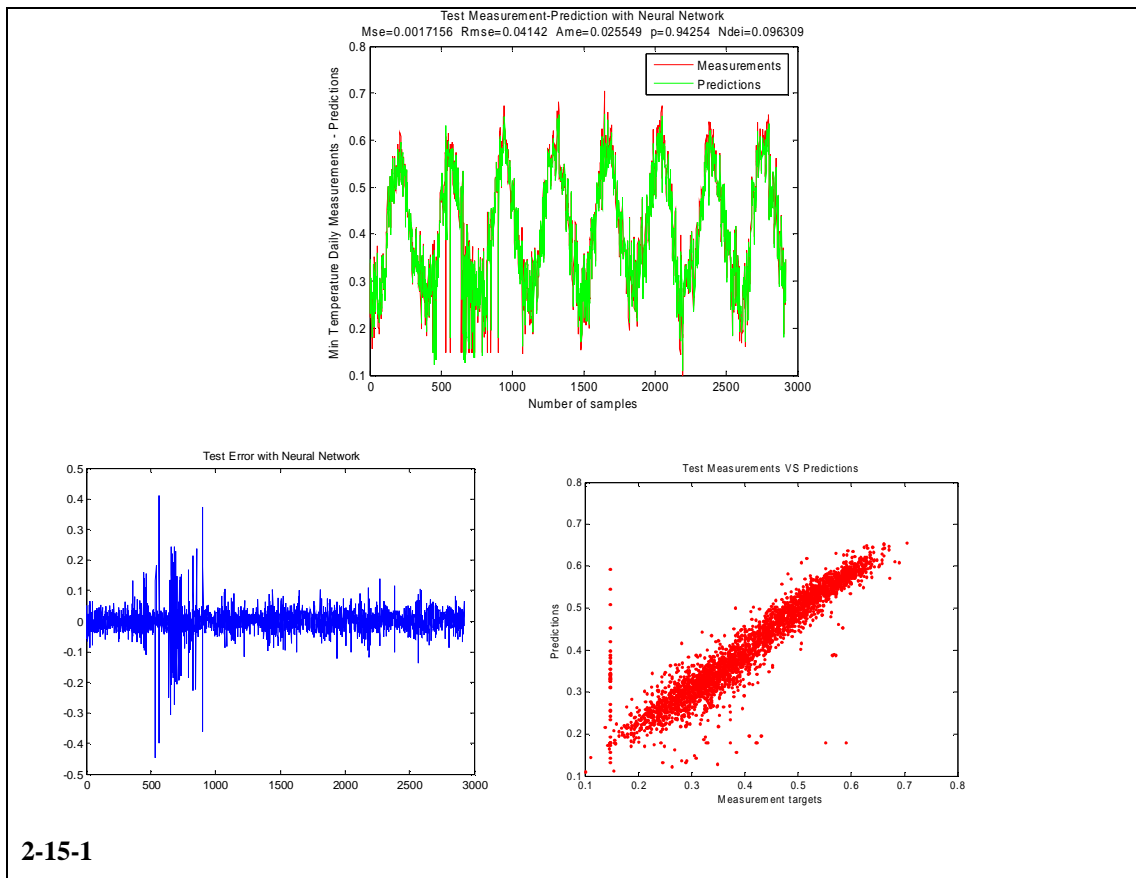


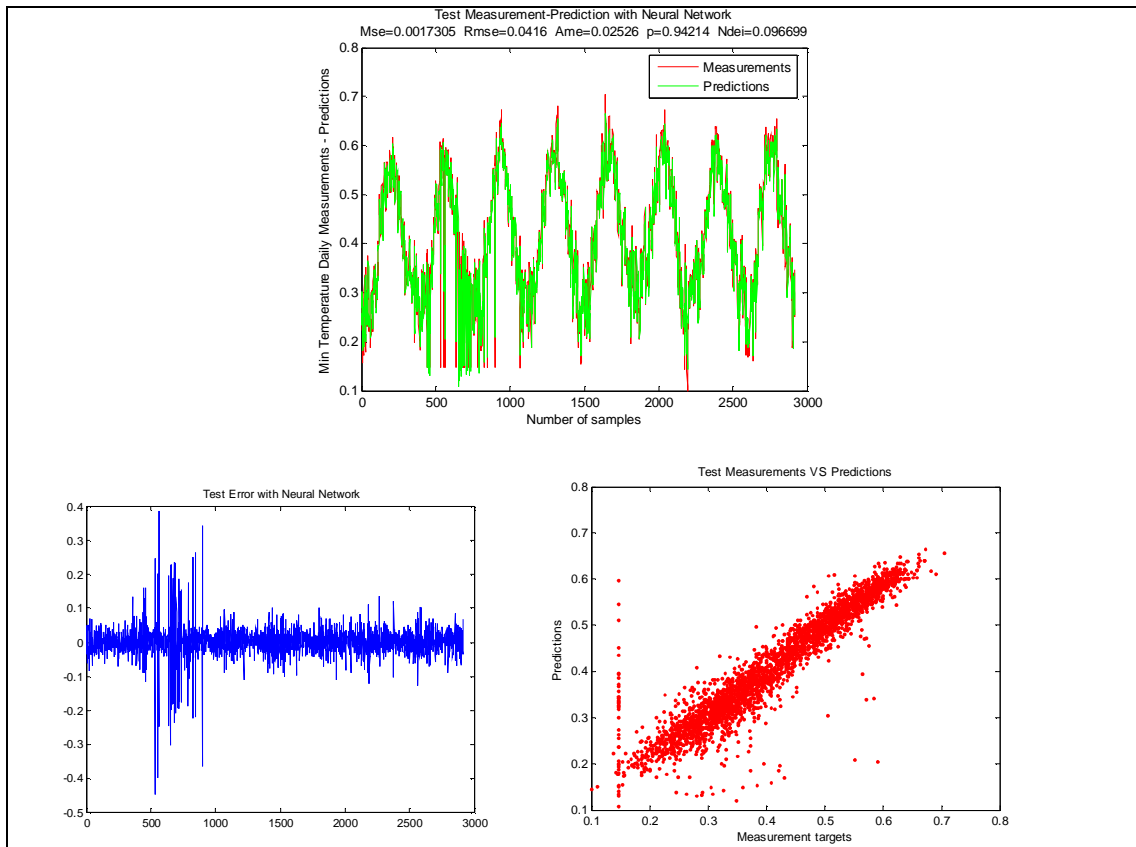


Για τα δεδομένα ελάχιστης ημερήσιας θερμοκρασίας έχουν προκύψει τα εξής τέσσερα καλύτερα νευρωνικά δίκτυα.

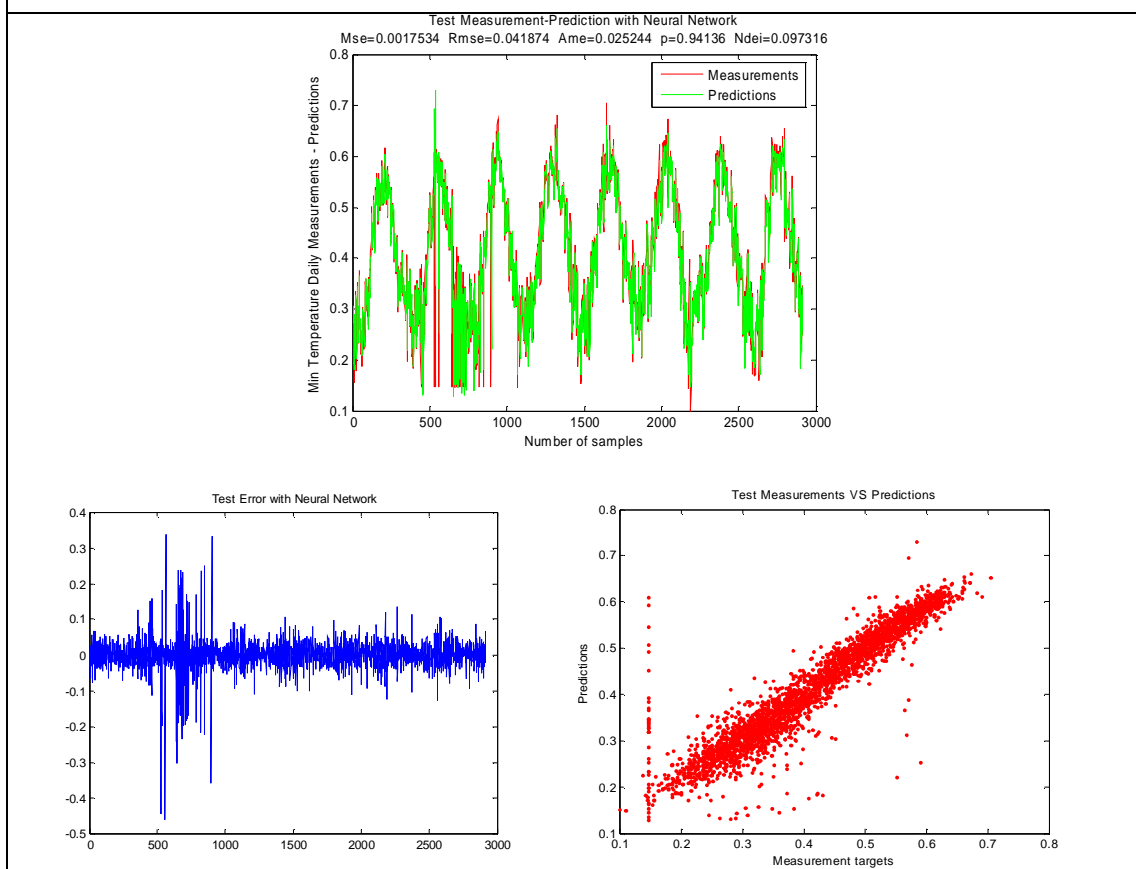
1. 2-15-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος
2. 5-3-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος
3. 7-3-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος
4. 5-5-1 για κανονικοποίηση 0.1-0.9 με χρήση σιγμοειδούς συνάρτησης ενεργοποίησης των κόμβων ενδιάμεσου στρώματος.

Οι αντίστοιχες γραφικές παραστάσεις για τα προαναφερθέντα νευρωνικά δίκτυα παρατίθενται παρακάτω:

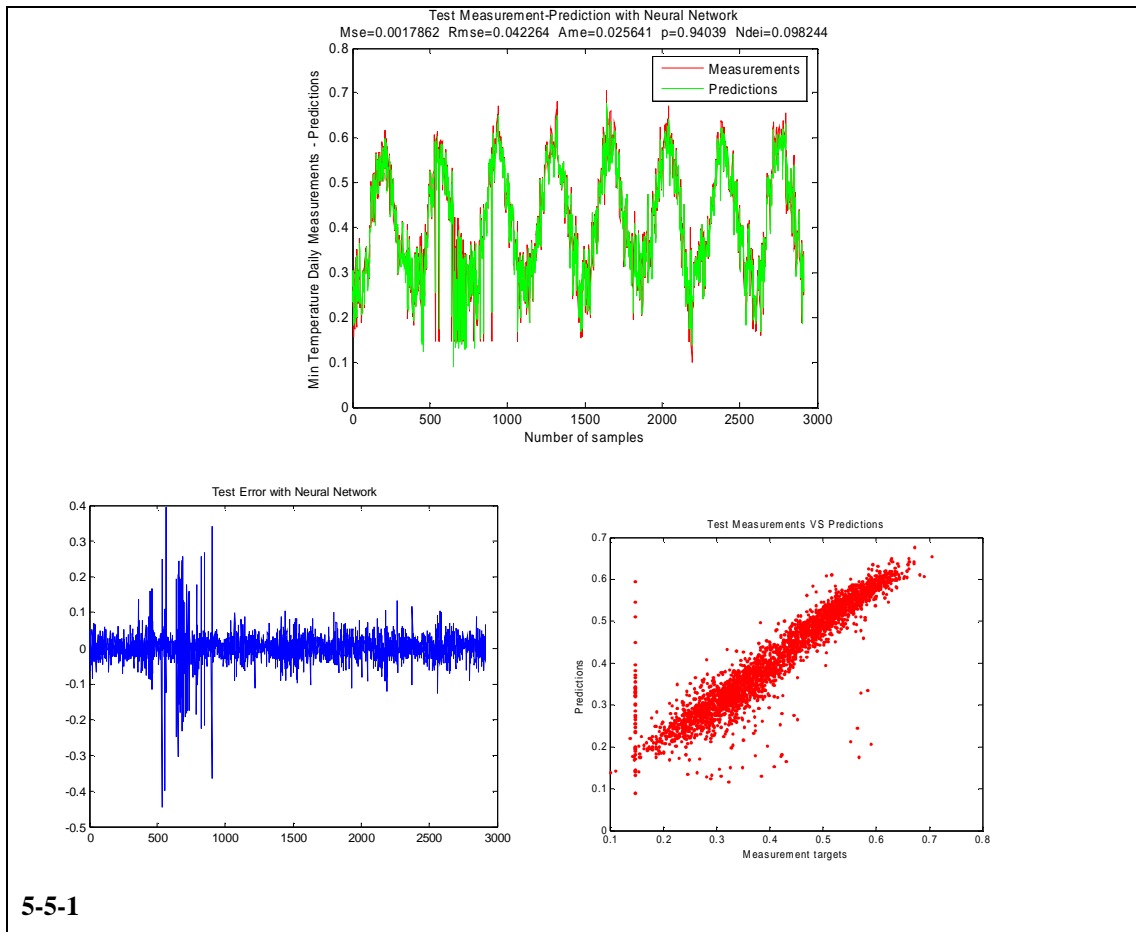




5-3-1



7-3-1



BIBΛΙΟΓΡΑΦΙΑ - ΑΝΑΦΟΡΕΣ

Βιβλιογραφία

- [A1]. Γεωργαντά Ζ. *"Επιστημονικές Μελέτες. Η προσέγγιση BOX-Jenkins στην ανάλυση και πρόβλεψη χρονολογικών σειρών."* Αθήνα 1987.
- [A2]. Παπαιωάννου Γ. *"ΧΑΟΤΙΚΕΣ ΧΡΟΝΟΣΕΙΡΕΣ"*. Leader Books. 1^η έκδοση 2000.
- [A3]. Detelf Nauck, Frank Klawonn, Rudolf Kruse. *"Foundations Of Neuro-fuzzy Systems"*. ISBN:0-471-97151-0
- [A4]. Gurney Kevin *"An introduction to neural networks"*. University of Sheffield. Routledge. Taylor and Francis Group. London 1997.
- [A5]. J. Wesley Hines. *"Matlab Supplement to Fuzzy and Neural approaches in engineering"*. John Wiley and Sons. New York 1997.
- [A6]. Simon Haykin. *"NEURAL NETWORKS - A Comprehensive Foundation-Second Edition"*. McMaster University Hamilton, Ontario, Canada. 1999 by Prentice Hall.

Σημειώσεις

- [B1]. Δρ. Διακολουκάς Βασίλης. *"Σημειώσεις μαθήματος 'Στατιστική επεξεργασία σήματος για τηλεπικοινωνίες'"*. Πολυτεχνείο Κρήτης. Χανιά
- [B2]. Δρ. Ντουνής Αναστάσιος, *"Σημειώσεις Νευρωνικών Δικτύων"*. Α.Τ.Ε.Ι Πειραιά
- [B3]. Δρ. Ντουνής Αναστάσιος, *"Computational Intelligence"*. Α.Τ.Ε.Ι Πειραιά
- [B4]. Δρ. Χριστοδούλου Μ. *"Σημειώσεις μαθήματος 'Νευρωνικά Δίκτυα και Εφαρμογές'"*. Πολυτεχνείο Κρήτης. Χανιά.
- [B5]. Genevieve Orr *"Neural networks lecture notes"*. Willamette University.
- [B6]. Systems Realization Laboratory *"Optimization in Engineering design, Quasi-Newton Methods"*. Georgia Institute of Technology.

Άρθρα

- [C1]. Α.Ι. Ντουνής, Β. Μπράχος, Β. Σταθούλιας, Δ. Τσελές. *"Σύστημα ασαφούς λογικής για την πρόβλεψη της μέσης ημερήσιας ηλιακής ακτινοβολίας"*. 2^ο Συνέδριο Τεχνολογίας και Αυτοματισμού Θεσ/κη 2-3 Οκτωβρίου 1998.
- [C2]. Δρ. Σ. Μαρκουλάκης, Δρ. Γ. Σταυρακάκης. *"ΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ ΤΟΥ ΗΛΕΚΤΡΙΚΟΥ ΦΟΡΤΙΟΥ ΜΕ ΧΡΗΣΗ ΤΟΥ ΦΙΛΤΡΟΥ KALMAN ΚΑΙ ΤΟΥ ΝΕΥΡΩΔΑΣΑΦΟΥΣ ΔΙΚΤΥΟΥ ANFIS"*. Τμήμα ΗΜΜΥ, Πολυτεχνείο Κρήτης, Χανιά.
- [C3]. Δρ. Τσελές Δημήτριος. *"Τεχνητή Νοημοσύνη και Νέα Τεχνολογία στην υπηρεσία προβλέψεων φυσικών μεγεθών"*. Α.Τ.Ε.Ι Πειραιά. 4^ο Επιστ. Συμπόσιο "Μεγάλες στιγμές της Φυσικής" Αιγάλεω, 1-3 Απριλίου 2005.
- [C4]. Α.Ι. Dounis, D.I. Tseles, D. Bellis, M. Darachianakis. *"Neuro-fuzzy network for ambient temperature prediction"*. Neties 97 European Conference of Networking Entities, Ancona 1-3 October 1997.

- [C5]. A. I. Dounis, G. Nikolaou, D. Tseles. *"Intelligent methodologies for meteorological parameters, forecasting: a review"*. Technological Education Institute of Piraeus, Athens, Greece. 1st International .Scientific Conference in Information Technology & Quality.
- [C6]. Dr. A. G. Tony Pipe. *"Takagi - Sugeno fuzzy logic versus Mamdani fuzzy logic"*. University of West England.
- [C7]. Demola Popoola . *"Fuzzy Expert Systems. CS364 Artificial Intelligence"*. Department of Computing, University of Surrey.
- [C8]. D. Kim & C. Kim, *"Forecasting Time Series with Genetic Fuzzy Prediction Ensemble"*. IEEE Tr. On Fuzzy Systems, Vol 5, No 4., Nov 1997, pp 523-535.
- [C9]. Dounis A. Tseles D., Belis D, Daratsianakis M. *"Neuro-fuzzy Network for Ambient Temperature Prediction"*. Ancona 1997.
- [C10]. Guoqiang Zhang, B. Eddy Patuwo, Michael Y. Hu. *"Forecasting with artificial neural networks: the state of art"*. Kent State University, Kent, Ohio, USA. 31 July 1997.
- [C11]. Heikki Koivo. *"ANFIS (Adaptive Neuro-Fuzzy Inference System) "*. 2000
- [C12]. JYH-SHING ROGER JANG, CHUEN_TSAI SUN. *"Neuro-Fuzzy Modeling and Control"*. IEEE 1995.
- [C13]. K. Kalaitzakis, G.S. Stavrakakis, E.M. Anagnostakis. *"Short-term load forecasting based on artificial neural networks parallel implementation"*. Technical University of Crete, Chania, Greece.
- [C14]. Manolis Lourakis. *"A brief Description of the Levenberg - Marquardt Algorithm "*. Institute of Computer Science. Heraklion, Greece. February 11, 2005
- [C15]. Mayte Farinas, Carlos Pedreira. *"Mixture of experts and local-global neural networks"*. Catholic University of Rio de Janeiro. ESANN' 2003-Bruges (Belgium).
- [C16]. M-S. Kim, S-G Kong, *"Parallel Structure Fuzzy Systems for Time Series Prediction"*. International Journal of Fuzzy Systems, Vol. 3, No. 1, March 2001, pp. 331-340
- [C17]. Robert Jacobs, Michael Jordan Steven Nowlan, Geoffrey Hinton. *"Adaptive mixtures of local experts "*. from Massachusetts Institute of Technology, University of Toronto. 1991.
- [C18]. Ronald Scoenberg. *"Optimization with the Quasi-Newton Method"*. Aptech Systems, Maple Valley. September 5, 2001.
- [C19]. Ricardo M. Trigo, Jean P. Palutikof. *"Simulation of Daily temperatures for climate change scenarios over Portugal: a neural network model approach"*. University of East Anglia, Norwich, United Kingdom 1999.
- [C20]. Sam Roweis. *"Levenberg-Marquardt Optimization"*.
- [C21]. Shuang Yang and Antony Browne, *"Neural network ensembles: Combining multiple models for enhanced performance using a multistage approach "*. University of Surrey. November 2004
- [C22]. Steven J. Nowlan and Geoffrey E. Hinton. *"Evaluation of Adaptive Mixtures of Competing Experts "*. University of Toronto.
- [C23]. S-Y Kung, J. Taur & S-H Lin. *"Synergistic Modeling and Applications of Hierarchical fuzzy Neural Networks"*. Proceeding of the IEEE. Sept. 1999, Vol. 87, No 9, pp. 1550-1574
- [C24]. Tracey A. Bale and Khushid Ahmad. *"Introducing Feedback into a Mixture-of-Experts Model"*. University of Surrey, Guilford, UK.