



ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΑΡΑΓΩΓΗΣ ΚΑΙ ΔΙΟΙΚΗΣΗΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΕΦΑΡΜΟΓΕΣ ΤΟΥ ANFIS: ΑΝΑΣΚΟΠΗΣΗ ΚΑΙ ΜΕΛΛΟΝΤΙΚΗ ΤΑΣΗ
ΣΕ ΘΕΡΜΟΚΡΑΣΙΑΚΑ ΔΕΔΟΜΕΝΑ

ΤΣΟΥΜΠΡΗΣ ΒΑΣΙΛΕΙΟΣ
Α.Μ.: 2013010183

ΕΞΕΤΑΣΤΙΚΗ ΕΠΙΤΡΟΠΗ:

ΑΤΣΑΛΑΚΗΣ ΓΕΩΡΓΙΟΣ, ΑΝΑΠΛΗΡΩΤΗΣ ΚΑΘΗΓΗΤΗΣ (ΕΠΙΒΛΕΠΩΝ)
ΖΟΠΟΥΝΙΔΗΣ ΚΩΝΣΤΑΝΤΙΝΟΣ, ΚΑΘΗΓΗΤΗΣ
ΤΣΑΦΑΡΑΚΗΣ ΣΤΥΛΙΑΝΟΣ, ΕΠΙΚΟΥΡΟΣ ΚΑΘΗΓΗΤΗΣ

*«Το μέλλον ανήκει στους ανθρώπους που
βλέπουν τις δυνατότητες προτού αυτές γίνουν προφανείς»*

Theodore Levitt

Ευχαριστίες

Ευχαριστώ θερμά τον επιβλέπων καθηγητή μου, κύριο Γεώργιο Ατσαλάκη, για την εμπιστοσύνη που μου έδειξε εξ' αρχής, αναθέτοντάς μου τη συγκεκριμένη διπλωματική, την επιστημονική του καθοδήγηση, τη συνεχή του υποστήριξη και το αμείωτο ενδιαφέρον του από την αρχή μέχρι το τέλος.

Περίληψη

Η πρόβλεψη κλιματολογικών συνθηκών, προσδιορίζεται ως μία από τις σημαντικότερες προκλήσεις της σύγχρονης εποχής όπως έχει επισημανθεί από το Παγκόσμιο Πρόγραμμα Κλιματολογικών Ερευνών (WCRP, 2020). Στην παρούσα διπλωματική επιχειρείται η πρόβλεψη θερμοκρασιακών τάσεων τον επόμενο μήνα, με βάση ένα νευρο-ασαφές μοντέλο. Το μοντέλο αποτελείται από ένα ελεγκτή ANFIS, που χρησιμοποιείται για τον έλεγχο του συστήματος που επεξεργάζεται θερμοκρασιακά δεδομένα, το οποίο επίσης προσδιορίζεται, από μία προσαρμοζόμενη νευρο-ασαφή τεχνική ANFIS. Με την χρήση κατάλληλων μεταβλητών για την παραμετροποίηση του μοντέλου (trial and error), αποδεικνύεται ότι το ποσοστό επιτυχίας πρόβλεψης της τάσης μεταβολής της θερμοκρασίας, αγγίζει σε ακρίβεια το 94%. Το ποσοστό αυτό βάσει διεθνούς βιβλιογραφίας και μελετών, θεωρείται πολύ ικανοποιητικό. Συμπερασματικά το μοντέλο για το οποίο εκπονήθηκε η εργασία δείχνει κατάλληλο για την πρόβλεψη θερμοκρασίας.

Abstract

Predicting climatic conditions is identified as one of the most important challenges of the modern era as highlighted by the World Climate Research Program (WCRP, 2020). This diploma thesis attempts to predict temperature trends on next month, based on a neuro-fuzzy model. The model consists of an ANFIS controller, used to control the system. The system processes temperature data and is also determined by an adaptive neuro-fuzzy ANFIS technique. Using appropriate variables and the trial and error method to set up the model, it turns out that the prediction success rate reaches 94% accuracy. This percentage, based on international literature and studies, is considered very satisfactory in performance. In conclusion, the model for which the work was carried out seems suitable for predicting temperature.

Περιεχόμενα

Περίληψη	5
Abstract.....	5
1.Εισαγωγή	7
2. Θεωρητική Ανασκόπηση σχετικής βιβλιογραφίας	8
3. Θεωρητική Ανασκόπηση Νευρο-ασαφών Συστημάτων	14
3.1.1 Ασαφής Λογική (Fuzzy Logic)	14
3.1.2 Κλασσικά Σύνολα - Ασαφή σύνολα	14
3.1.4 Ασαφείς κανόνες	16
3.1.5 Ασαφής συλλογιστική.....	17
3.1.6 Βασική δομή- χαρακτηριστικά ασαφούς ελεγκτή	18
3.2 Τεχνητά Νευρωνικά Δίκτυα	19
3.2.1 Συναρτήσεις Ενεργοποίησης	21
3.2.2 Αρχιτεκτονικές νευρωνικών δικτύων	22
3.2.3 Κανόνες μάθησης νευρωνικών δικτύων	24
3.3 Νευρο-ασαφή συστήματα.....	27
3.4 Ολοκληρωμένα νευρο-ασαφή συστήματα στην διεθνή βιβλιογραφία	30
3.5 Προτεινόμενο μοντέλο.....	34
3.5.1 Ελεγκτής CON-ANFIS - φάση εκπαίδευσης.....	35
3.5.2 Επεξεργασία PR-ANFIS - φάση εκπαίδευσης.	36
3.6 Σφάλμα RMSE.....	38
4. Περιγραφή δεδομένων και επιλογή/βελτιστοποίηση παραμέτρων της μεθόδου στη φάση εκπαίδευσης.....	39
4.1 Δεδομένα	39
4.2 Επιλογή και βελτιστοποίηση παραμέτρων του συστήματος	41
5. Εφαρμογή της μεθόδου	48
6. Σύγκρισή της μεθόδου με άλλα μοντέλα.	60
7. Συμπεράσματα	71
8. Πηγές και Βιβλιογραφία	72

1.Εισαγωγή

Ζούμε σε μια εποχή που το θέμα των προβλέψεων αποκτά ιδιαίτερη σημασία τόσο για τον επιστημονικό κόσμο όσο και γενικότερα για την κοινωνία. Οι προβλέψεις από την αρχαία εποχή, γοήτευαν τον άνθρωπο, ο οποίος προσπαθούσε να προβλέψει βασιζόμενος στην εμπειρία του, στα φυσικά φαινόμενα και γεγονότα. Στη σύγχρονη εποχή, με την εξέλιξη της τεχνολογίας, η πρόβλεψη επιτυγχάνεται με την ανάπτυξη μοντέλων αξιοποιώντας παρελθοντικά δεδομένα.

Η κατανόηση των «μηχανών» που παράγουν τις όποιες ατμοσφαιρικές καταστάσεις, δηλαδή ο ήλιος, η επιφάνεια της γης και η ατμόσφαιρά της, οντότητες που συγκροτούν ένα θερμικό σύστημα, είναι μία πρόκληση που ενδιαφέρει την επιστημονική κοινότητα αλλά και την κοινωνία γενικότερα, επί αιώνες (Μακρή, 1990). Τα καιρικά φαινόμενα όπως η βροχή, ο άνεμος, οι καταιγίδες, οι τυφώνες κτλ., ως αποτέλεσμα αυτού του θερμικού συστήματος, επιδρούν και επηρεάζουν κάθε είδους ανθρώπινης δραστηριότητας. Επομένως γίνεται αντιληπτό ότι η μελέτη τέτοιου είδους φαινομένων, πόσο μάλλον η έγκυρη αναγνώριση των αιτιών που τα προκαλούν, έχει τεράστιο κοινωνικό και οικονομικό ενδιαφέρον. Ένα παράδειγμα μιας περίπτωσης κλιματικής μεταβολής που παρατηρείται τα τελευταία χρόνια, είναι η υπερθέρμανση του πλανήτη, δηλαδή η άνοδος της μέσης θερμοκρασίας της γης, στην ατμόσφαιρά της καθώς και στους ωκεανούς. Αποτέλεσμα αυτού είναι η εμφάνιση ακραίων καιρικών φαινομένων, προκαλώντας φυσικές και οικονομικές ζημιές ακόμα και απώλειες ανθρώπινων ζωών.

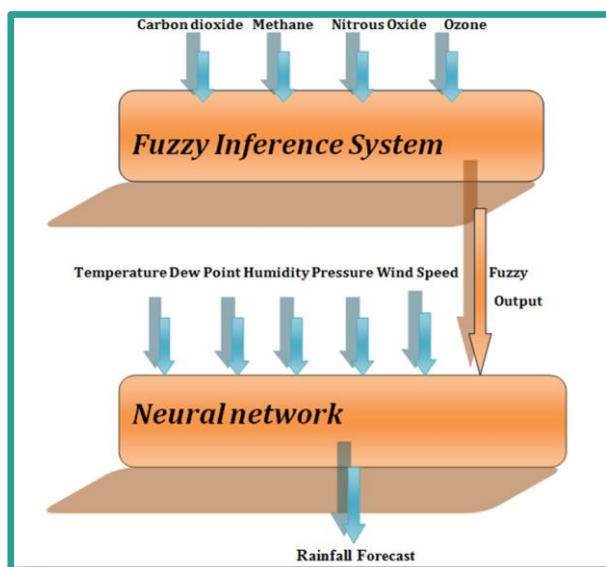
Για αυτό τον λόγο κρίνεται επιτακτική η ανάγκη δημιουργίας μοντέλων πρόβλεψης ικανών να αντιλαμβάνονται το κλίμα γρήγορα και με απλά εισαγόμενα δεδομένα. Τέτοια μοντέλα πρέπει να είναι ικανά να συμβουλεύουν τον επιχειρηματικό κόσμο, το κράτος και άλλους φορείς, ώστε η αγορά, η κοινωνία και η οικονομία να συντονίζονται στις περιβαλλοντικές αλλαγές, αποτελεσματικά και με κύριο γνώμονα την αποφυγή ανεπανόρθωτων ζημιών.

Η συγκεκριμένη διπλωματική παρουσιάζει ένα υβριδικό νεύρο-ασαφές μοντέλο που στηρίζεται στο προσαρμοστικό νεύρο-ασαφές σύστημα ANFIS, το οποίο είναι κατάλληλο για την πρόβλεψη χρονοσειρών. Τέτοιου είδους μοντέλα προσπαθούν να κατανοήσουν τους νόμους των προς μελέτη φαινομένων, με τεχνικές παρόμοιες με του τρόπου σκέψης του ανθρώπινου εγκεφάλου. Σύμφωνα με την διεθνή βιβλιογραφία λίγοι ερευνητές έχουν εφαρμόσει το σύστημα ANFIS για την πρόγνωση βροχοπτώσεων, κλιματικών αλλαγών κ.α. Παρόμοια αλλά λιγοστά νεύρο-ασαφή μοντέλα έχουν δημιουργηθεί για την πρόβλεψη κλιματικών μεταβολών στην ατμόσφαιρα. Για τους παραπάνω λόγους επιλέχθηκε το συγκεκριμένο θέμα διπλωματικής.

2. Θεωρητική Ανασκόπηση σχετικής βιβλιογραφίας

Έχουν γίνει πολλές προσπάθειες πρόβλεψης καιρού, κλιματικών αλλαγών, θερμοκρασιών με διαφόρων ειδών μοντέλα πρόβλεψης μερικά των οποίων αποτελούν νεύρο-ασαφής, ασαφή και τεχνητά νευρωνικά δίκτυα. Παρακάτω παρατίθεται σχετική βιβλιογραφία:


Οι Pathania et al., (2013), δημιούργησαν ένα νεύρο-ασαφές μοντέλο για την πρόβλεψη της βροχόπτωσης στην βόρεια Ινδία. Το μοντέλο εισάγει τα επίπεδα όζοντος, μεθανίου, νιτρικού οξειδίου και οξειδίου του άνθρακα που βρίσκονται στην ατμόσφαιρα, σε ένα ασαφές σύστημα δίνοντας μία έξοδο. Η έξοδος του ασαφούς συστήματος σε συνδυασμό με δεδομένα που αφορούν την θερμοκρασία, την πίεση, την ένταση του ανέμου κτλ. της περιοχής, εισάγονται σε ένα τεχνητό νευρωνικό δίκτυο, το οποίο ως έξοδο δίνει την πρόβλεψη βροχόπτωσης.



Διάγραμμα 2.1 Αρχιτεκτονική μοντέλου των Manjushri Pathania, Gour Sundar Mitra Thakur και Chandra Prakash Meena

Οι Lu et al., (2014) υλοποίησαν το ANFIS-WPM (Neural fuzzy Inference system-Based Weather Prediction Model). Το μοντέλο αποτελείται από δύο μέρη. Το πρώτο μέρος του μοντέλου, πρόκειται για ένα νευρωνικό δίκτυο που βασίζεται σε ασαφείς κανόνες, το οποίο προσομοιώνει τις διαδοχικές σχέσεις μεταξύ των ασαφών συνόλων και κανόνων. Το δεύτερο μέρος είναι ένα νεύρο-ασαφές σύστημα που βασιζόμενο στο πρώτο μέρος, μπορεί να «μαθαίνει» νέους ασαφείς κανόνες από τους προηγούμενους. Και αυτό το μοντέλο χρησιμοποιήθηκε για την πρόβλεψη της βροχόπτωσης.

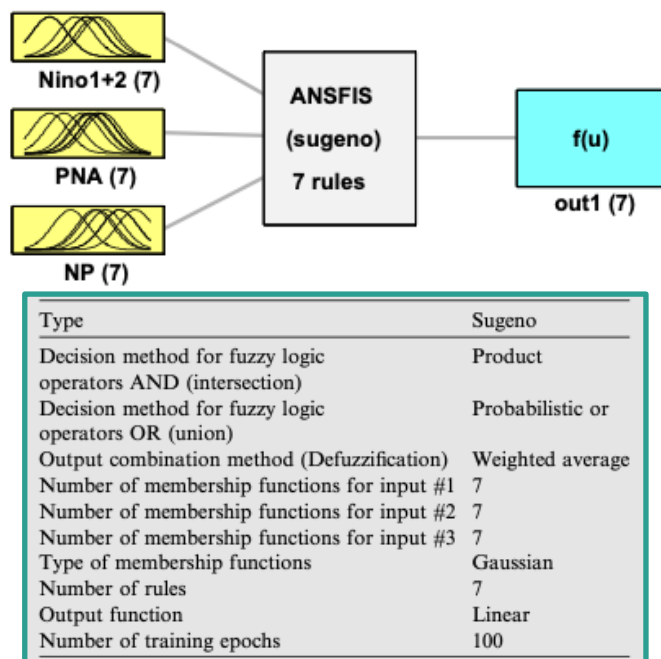
Οι Chattopadhyay et al., (2020) προσπάθησαν να προβλέψουν κατηγορίες καιρικών προτύπων μέσω ενός συνελκτικού νευρωνικού δικτύου (convolutional neural network- CNN), τεσσάρων στρωμάτων, που προβλέπει τον καιρό στις επόμενες 5 μέρες (5 step ahead). Η διαδικασία εκμάθησης είναι χωρίς επίβλεψη και τα δεδομένα αφορούν την βόρεια Αμερική. Το συγκεκριμένο μοντέλο είναι πολύ πιο ακριβέστερο (κατά 25%) από το μοντέλο της λογιστικής παλινδρόμησης, δηλαδή ενός απλού αλγορίθμου μηχανικής εκμάθησης.



Διάγραμμα 2.2: Αρχιτεκτονική μοντέλου των Ashesh Chattopadhyay, Pedram Hassanzadeh και Saba Pasha

Οι Setyaningrum H. και Swarinata P. (2014), δημιούργησαν μια εφαρμογή για την πρόβλεψη καιρού στην δυτική Τζακάρτα, λόγω των έντονων καιρικών αλλαγών που έχουν παρατηρηθεί τα τελευταία χρόνια από την κλιματική αλλαγή. Η εφαρμογή βασίζεται στο υβριδικό νευροασαφές μοντέλο ANFIS δίνοντας πολύ ακριβή αποτελέσματα.

Οι Daneshmand et al., (2015), μέσω ενός μοντέλου ANFIS τριών εισόδων και 7 κανόνων έκαναν πρόβλεψη για τις χαμηλότερες θερμοκρασίες στο Ιράν. Οι εισοδοί ήταν θερμοκρασιακοί δείκτες οι οποίοι επιλέχθηκαν με μετασχηματισμό Fourier ανάμεσα από άλλους δεκατρείς.

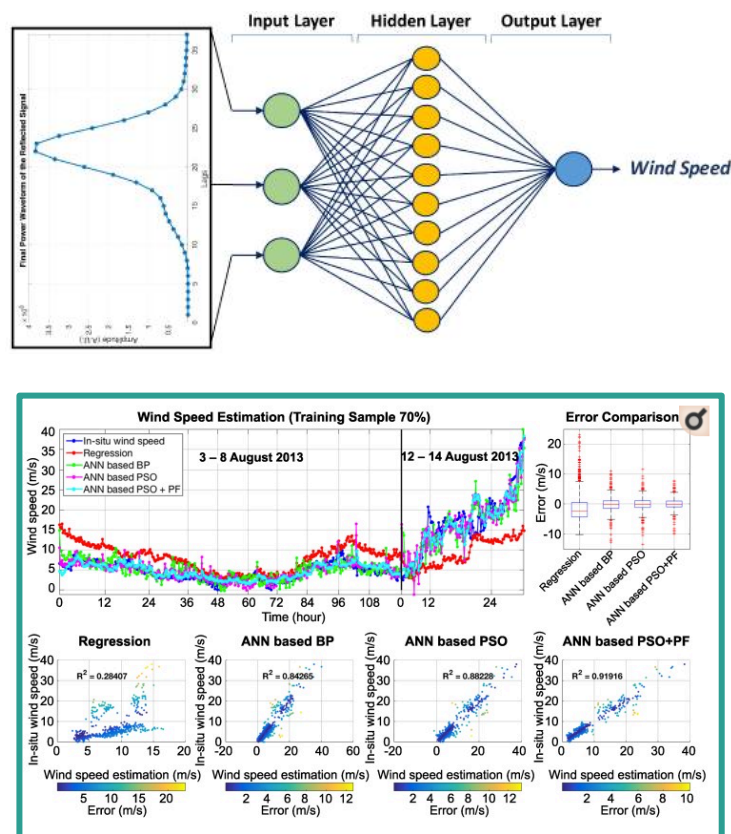


Διάγραμμα 2.3: Αρχιτεκτονική ANFIS των Daneshmand, et al. (2015)

Οι Nezhad et al. (2019), έκαναν μία έρευνα για την πρόβλεψη των υψηλών θερμοκρασιών μέσω νευρωνικών δικτύων. Χρησιμοποιώντας ως δεδομένα τις υψηλότερες καταγεγραμμένες ετήσιες θερμοκρασίες του χειμώνα για το διάστημα 1951-2010, καταλήγουν σε πολύ μικρά σφάλματα, δείχνοντας έτσι πως τεχνικές όπως τα νευρωνικά δίκτυα, είναι κατάλληλες για πρόβλεψη θερμοκρασιών. Η θερμοκρασίες αφορούν την περιοχή της Τεχεράνης.

Οι Mehdizadeh et al. (2020), προέβλεψαν την θερμοκρασία για διαφόρου τύπου περιβάλλοντα στην ευρύτερη περιοχή του Ιράν, μέσω ενός κλασσικού ANFIS αλλά και παραλλαγών του, δηλαδή συστημάτων ANFIS που οι παράμετροί τους βελτιστοποιούνται με γενετικό αλγόριθμο (GA), αλγόριθμο βελτιστοποίησης σωματιδίων (PSO), αλγόριθμο βελτιστοποίησης αποικιών (ACO_R) και αλγόριθμο διαφορικής εξέλιξης (DE). Από την έρευνα φαίνεται πως οι βελτιστοποιήσεις αυτές στις παραμέτρους του ANFIS κατά την εκπαίδευσή του δίνουν καλύτερα αποτελέσματα. Μάλιστα η βελτιστοποίηση του ANFIS με γενετικό αλγόριθμο δίνει τα ακριβέστερα αποτελέσματα.

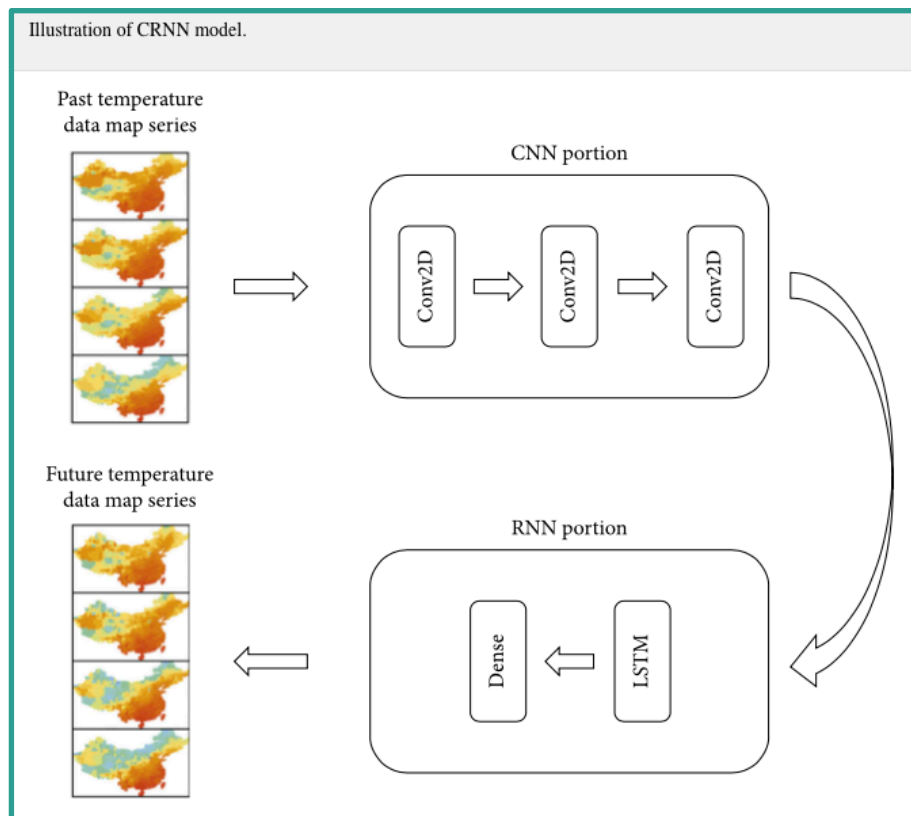
Οι Kasantikul et al., (2018) δημιούργησαν ένα τεχνητό νευρωνικό δίκτυο για την πρόβλεψη της ταχύτητας του ανέμου στην επιφάνεια των ωκεανών σε περιόδους έντονων καιρικών συνθηκών. Το τεχνητό νευρωνικό δίκτυο βελτιστοποιείται με αλγόριθμο PSO και με εφαρμογή φίλτρου σωματιδίων (PF) στα δεδομένα, ώστε να δίνει πιο ακριβή πρόβλεψη.



Διάγραμμα 2.4: Αρχιτεκτονική μοντέλου των Kasantikul, et al, (2018) και τα αποτελέσματά του

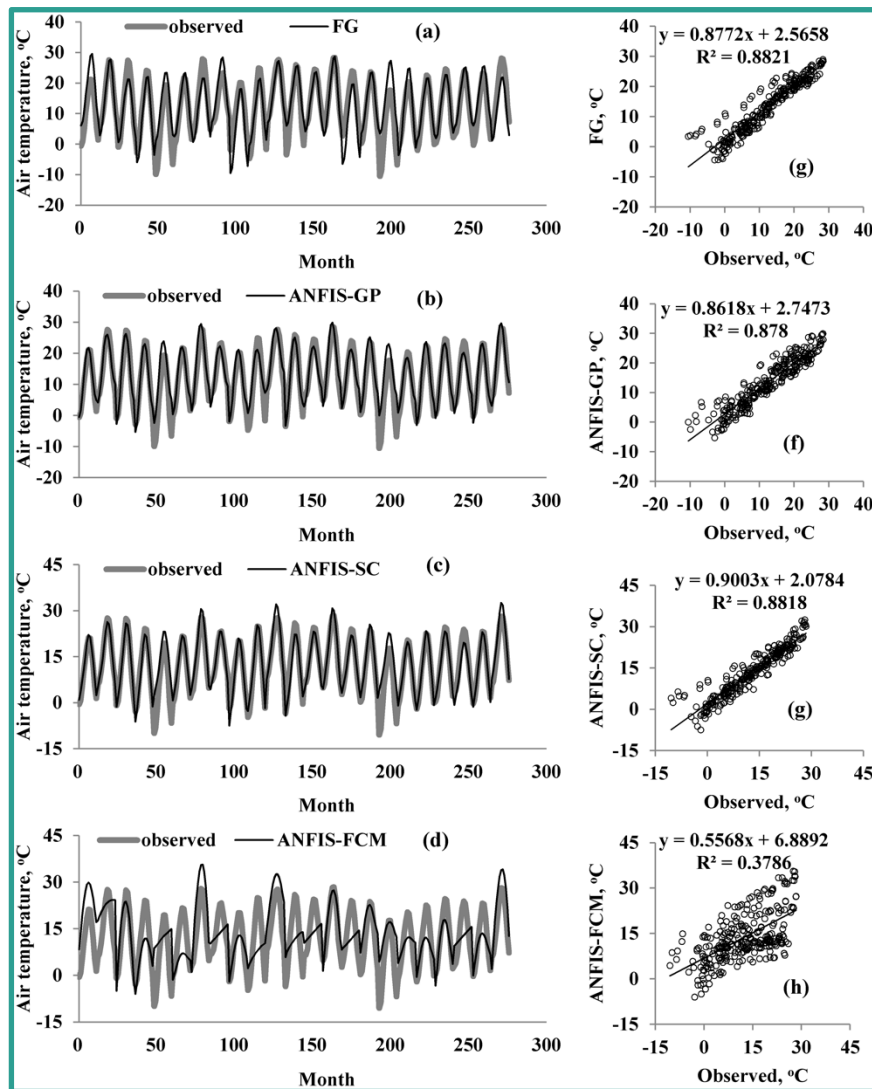
Οι Zhang & Dong, (2020), δημιούργησαν ένα συμβατικό αναδρομικό νευρωνικό δίκτυο (CRNN) για την πρόβλεψη της θερμοκρασίας της Κίνας, πετυχαίνοντας μία ακρίβεια πρόβλεψης με σφάλμα μόνο 0,907 βαθμούς Κελσίου. Τα δεδομένα ήταν μια χρονοσειρά από το 1952 έως και το 2018. Το μοντέλο πρόκειται για τον συνδυασμό δύο νευρωνικών δικτύων,

ενός συμβατικού νευρωνικού δικτύου (CNN) και ενός αναδρομικού (RNN), που εκφράζονται σε ένα πολυστρωματικό δίκτυο (CRNN).




Διάγραμμα 2.5: Αρχιτεκτονική μοντέλου των Zhang και Dong

Οι Sadeghi-Niaraki A. et al., (2020), ερεύνησαν τις δυνατότητες του εξελικτικού ασαφούς γενετικού αλγορίθμου (FZ) και τον σύγκριναν με παραλλαγές του ANFIS. Συγκεκριμένα, τα μοντέλα ANFIS-GP (neuro-fuzzy with grid partitioning), ANFIS-SC (neuro-fuzzy with subtractive clustering), και το ANFIS-FCM (neuro-fuzzy with fuzzy c-means clustering) χρησιμοποιήθηκαν για να προβλέψουν μακροπρόθεσμα την θερμοκρασία σε ορίζοντα 40 ετών μπροστά, στην Τουρκία. Το ακριβέστερο μοντέλο βρέθηκε να είναι το FG, ενώ ακολουθούσε το ANFIS-GP.




Διάγραμμα 2.6: Αποτελέσματα των μοντέλων FG, ANFIS-GP, ANFIS-SC, ANFIS-FCM

Οι Tulunay et al. (2008), έφτιαξαν ένα νεύρο-ασαφές μοντέλο, το Middle East Technical University Fuzzy Neural Network Model (METU-FNN-M). Το μοντέλο αποτελείται από ένα ασαφές σύστημα (METU-FIS) και ένα νευρωνικό δίκτυο (METU-FNN) δομημένο με ένα κρυφό στρώμα αρκετών νευρώνων και με μέθοδο χαρτογράφησης επιφάνειας Bezier. Η πρόβλεψη του μοντέλου γίνεται για την ποσοστιαία νεφοκάλυψη (CC%) και για την θερμοκρασία πάνω από τα σύννεφα (CTT).




Διάγραμμα 2.7.1 Αρχιτεκτονική METU-FIS.

Διάγραμμα 2.7.2 Αρχιτεκτονική METU-FNN



Διάγραμμα 2.7.3 Αρχιτεκτονική METU-FNN-M



Διάγραμμα 2.7.4 Αποτελέσματα Πρόβλεψης του METU-FNN-M

3. Θεωρητική Ανασκόπηση Νευρο-ασαφών Συστημάτων

3.1.1 Ασαφής Λογική (Fuzzy Logic)

Τα ασαφή σύνολα επινοήθηκαν από τον καθηγητή Zadeh L. του πανεπιστημίου του Berkeley, το 1965. Πρόκειται για μια διαφορετική αντίληψη περί της αλήθειας και ψεύδους μίας πρότασης σε σχέση με τη δίτιμη αριστοτελική λογική, καθώς εισήχθησε η έννοια της πλειότιμης (multivalued) λογικής σε μία πρόταση, αντικαθιστώντας την έννοια της υπαγωγής ενός στοιχείου σε ένα σύνολο με την έννοια της συμμετοχής του στοιχείου στο σύνολο. Ωστόσο, ήδη από την εποχή του Πλάτωνα (4^{ος} αιώνας π.Χ.) υπήρχαν αμφισβητήσεις είτε ως προς την ύπαρξη δύο μόνο καταστάσεων, είτε ότι αυτές οι δύο καταστάσεις είναι αμοιβαία αποκλειόμενες. Βέβαια αυτές οι θεωρήσεις δεν αποτυπώθηκαν σε μαθηματική θεωρία παρά μόνο στο πρώτο τέταρτο του 20^{ου} αιώνα, όταν ο Πολωνός Jan Lucasiewicz περιέγραψε μία τρίτιμη λογική, ενώ το 1937 ο αμερικανοβρετανός Max Black επινόησε ένα είδος συνάρτησης συμμετοχής (membership function). Ωστόσο ο Zadeh ήταν αυτός που πυροδότησε μια εναλλακτική λογική στο ευρύ επιστημονικό κοινό.

Η σταδιακή αποδοχή της θεωρίας της ασαφούς λογικής από την επιστημονική κοινότητα ξεκίνησε με την εμφάνιση των πρώτων εφαρμογών της. Κάνοντας χρήση του πλεονεκτήματος που διαθέτουν τα ασαφή συστήματα ελέγχου να μην απαιτούν μαθηματικά μοντέλα των προς έλεγχο διεργασιών, αναπτύχθηκαν εφαρμογές εκεί όπου δεν υφίσταντο μαθηματικά μοντέλα. Το 1975 στην Αγγλία οι Mamdani και Assilian παρουσίασαν έναν ασαφή ελεγκτή για έλεγχο ατμομηχανής, το 1976, επίσης στην Αγγλία, ο Tong πρότεινε έναν ασαφή ελεγκτή στη διαδικασία παραγωγής χάλυβα και το 1978 οι Δανοί Holmblad και Østergaard δημιούργησαν έναν ασαφή ελεγκτή για κάμινο τσιμέντου. Το 1983, ο Ιάπωνας Michio Sugeno μαζί με τον Takagi εφάρμοσαν ένα ασαφές σύστημα (Takagi-Sugeno system) στη βιομηχανία της ρομποτικής, το οποίο μαζί με το σύστημα του Mamdani, αποτελούν τη βάση των ασαφών συστημάτων στη σύγχρονη εποχή.

3.1.2 Κλασσικά Σύνολα - Ασαφή σύνολα

Ένα σύνολο είναι μια συλλογή ομοειδών αντικειμένων, τα οποία είναι στοιχεία του συνόλου. Εάν S είναι ένα σύνολο και x είναι ένα στοιχείο του S , τότε $x \in S$. Εάν το x δεν είναι στοιχείο του συνόλου τότε $x \notin S$. Τα σύνολα μπορούν να προσδιοριστούν με διάφορους τρόπους. Εάν το S περιέχει ένα πεπερασμένο πλήθος στοιχείων, ας πούμε x_1, x_2, \dots, x_n , τα γράφουμε ως μία λίστα στοιχείων, ανάμεσα σε αγκύλες:

$$S = \{ x_1, x_2, \dots, x_n \} \text{ (Εξίσωση 3.1.1)}$$

Εάν το S περιέχει ένα άπειρο πλήθος στοιχείων, τα οποία μπορούν να απαριθμηθούν σε μια λίστα (έτσι ώστε να υπάρχουν τόσα στοιχεία όσοι και οι θετικοί ακέραιοι) γράφουμε:

$$S = \{ x_1, x_2, \dots, x_n \} \text{ (Εξίσωση 3.1.2)}$$

και λέμε ότι το S είναι αριθμήσιμα άπειρο.

Εναλλακτικά, μπορούμε να θεωρήσουμε το σύνολο όλων των τιμών του x οι οποίες έχουν μία συγκεκριμένη ιδιότητα P και να το γράψουμε ως: $\{x \mid x \text{ ικανοποιεί την } P\}$ όπου το σύμβολο

«|» διαβάζεται «έτσι ώστε» (Bertsekas & Tsitsiklis, 2002). Για παράδειγμα εάν $T = \{0,1,2, \dots, 9,10\}$ το σύνολο όλων των βαθμών που μπορεί ένας φοιτητής να πάρει σε ένα μάθημα (πεδίο ορισμού), το σύνολο S που οδηγεί στην επιτυχή εξέταση του φοιτητή στο μάθημα, ορίζεται $S = \{x \mid x \geq 5, x \in T\}$. Συμπερασματικά ένα στοιχείο του πεδίου ορισμού T είτε ανήκει είτε δεν ανήκει στο σύνολο S . Τα στοιχεία του συνόλου S έχουν την ίδια ιδιότητα κατά το ίδιο ποσοστό (100%) το καθένα. Ομοίως, τα στοιχεία του πεδίου ορισμού T που δεν ανήκουν στο σύνολο S έχουν την ίδια ιδιότητα κατά το ίδιο ποσοστό (100%). Εκφράζοντας με μία τιμή από το πεδίο τιμών $\{0,1\}$ το ποσοστό συμμετοχής των στοιχείων, στο σύνολο S , περιγράφεται η χαρακτηριστική συνάρτηση (characteristic function):

$$\chi_s = \begin{cases} 1, & \text{εάν και μόνο εάν } x \in S \\ 0, & \text{εάν και μόνο εάν } x \notin S \end{cases}$$

(Εξίσωση 3.1.3)

Με άλλα λόγια στα κλασσικά σύνολα, συνεπάγεται πως ακολουθείται η λογική της ύπαρξης δύο ομάδων που ανήκουν ή δεν ανήκουν στο σύνολο S και είναι αμοιβαία αποκλειόμενες (αριστοτελική αρχή). Ο τρόπος όπου προσδιορίζονται τα όρια των ομάδων (στοιχείων που ανήκουν ή δεν ανήκουν στο σύνολο) γίνεται με τρόπο απόλυτο και σαφή, για αυτό και τα κλασσικά σύνολα ονομάζονται και σαφή σύνολα.

Όμως, η επίλυση προβλημάτων με την αριστοτελική λογική και τα σαφή σύνολα δεν είναι πάντα εφικτή. Αρκεί η σκέψη, πως μεγάλο πλήθος εννοιών που διαμορφώνει ο ίδιος ο άνθρωπος είναι συχνά μη ακριβής και ασαφής (πχ. ψηλός, νέος κτλ.). Αυτός ο τρόπος αντίληψης αποτέλεσε την βάση για την δημιουργία ασαφών συνόλων και γενικότερα της ασαφούς λογικής.

Κύριο χαρακτηριστικό των ασαφών συνόλων αποτελεί η έννοια της σταδιακής μετάβασης από την κατάσταση της συμμετοχής $\{1\}$ ενός στοιχείου σε ένα σύνολο, στην κατάσταση της μη συμμετοχής $\{0\}$. Η συμμετοχή ενός στοιχείου x στο ασαφές σύνολο S προσδιορίζεται από τη συνάρτηση συμμετοχής (membership function), η οποία συμβολίζεται ως $\mu_s(x)$ και εκφράζει τον βαθμό κατά τον οποίο το x ανήκει στο S . Η συνάρτηση συμμετοχής απεικονίζει ένα πεδίο ορισμού T στο πεδίο τιμών $[0,1]$. Το ζεύγος $(x, \mu_s(x))$ συνήθως αναφέρεται ως ασαφές singleton (fuzzy singleton).

Υπάρχουν δύο κατηγορίες ασαφών συνόλων, τα διακριτά και τα συνεχή. Ένα διακριτό ασαφές σύνολο περιγράφεται από την σχέση:

$$S = \sum_{i=1}^n \mu_s(x_i) / x_i \quad (\text{Εξίσωση 3.1.4})$$

όπου το «/» δηλώνει το ασαφές singleton $(x_i, \mu_s(x_i))$ και το « Σ » την ένωση των ασαφών singleton. Να σημειωθεί ότι τα στοιχεία με μηδενικούς βαθμούς συμμετοχής συνήθως παραλείπονται.

Τα συνεχή ασαφή σύνολα έχουν συνεχείς συναρτήσεις συμμετοχής καθώς και συνεχή πεδία ορισμού. Δηλώνονται ως:

$$S = \int \frac{\mu_s(x)}{x} \quad (\text{Εξίσωση 3.1.5})$$


όπου το ολοκλήρωμα έχει την έννοια της ένωσης των ασαφών singleton. (Θεοδώρου, 2010)

3.1.4 Ασαφείς κανόνες

Ένας ασαφής κανόνας είναι της μορφής: $R: \text{ΕΑΝ } x \text{ είναι } A \text{ ΤΟΤΕ } y \text{ είναι } B$ όπου A, B μεταβλητές που ποσοτικοποιούνται από κάποιες συναρτήσεις συμμετοχής. Το « x είναι A » ορίζεται ως γεγονός ενώ το « y είναι B » ορίζεται ως συμπέρασμα. Τους κανόνες αυτούς συνήθως τους γράφουμε στην μορφή:

$$R: A \rightarrow B \text{ (Εξίσωση 3.1.6)}$$

Με άλλα λόγια ένας ασαφής κανόνας περιγράφει την σχέση $R_{A \rightarrow B}$ μεταξύ των x, y μεταβλητών με μια συνάρτηση συμμετοχής. Η συνάρτηση συμμετοχής, ουσιαστικά είναι μια καμπύλη, η οποία καθορίζει τον βαθμό στον οποίο, κάθε σημείο του πεδίου ορισμού, διαθέτει μια συγκεκριμένη ιδιότητα. Ορίζεται πάντα στο διάστημα $[0,1]$ (Zadeh,1973).



Διάγραμμα 3.1.1 Δύο είδη συναρτήσεων συμμετοχής και ο τρόπος λειτουργίας τους στην ασαφή συλλογιστική

3.1.5 Ασαφής συλλογιστική

Κύριος στόχος της ασαφούς συλλογιστικής είναι η εξαγωγή συμπερασμάτων μέσω μερικών δεδομένων και ενός συνόλου ασαφών κανόνων. Η διαδικασία της απόδειξης στην κλασική λογική στηρίζεται κυρίως σε λογικές ταυτολογίες και συγκεκριμένα στον κανόνα του θέτειν. Έτσι η αλήθεια μιας πρότασης B μπορεί να προκύψει αν γνωρίζουμε την αλήθεια μιας πρότασης A δηλαδή:

Γεγονός: x είναι A

Κανόνας: **EAN** x είναι A **TOTE** y είναι B

Συμπέρασμα: y είναι B

Αν έχουμε ως δεδομένο μια μεταβλητή (πχ. γλωσσική) την A' , όπου $A' \neq A$, τότε η κλασική λογική δεν δίνει κάποιο συμπέρασμα. Η ασαφής συλλογιστική λύνει το πρόβλημα δίνοντας ένα ασαφές σύνολο B' ως συμπέρασμα:

Γεγονός: x είναι A'

Κανόνας: **EAN** x είναι A **TOTE** y είναι B

Συμπέρασμα: y είναι B'

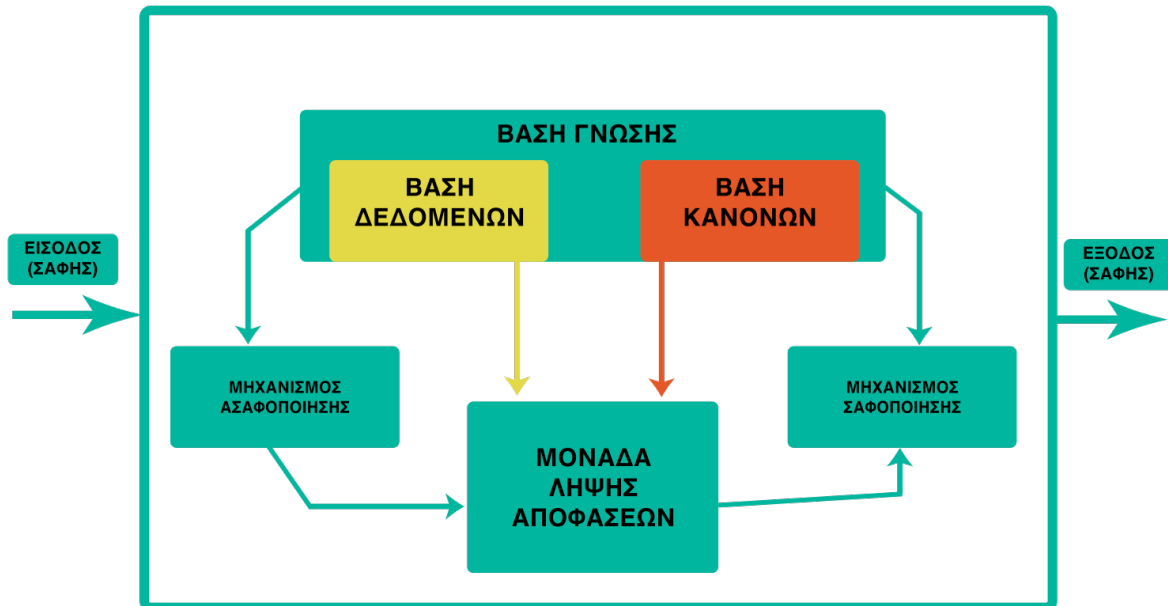
(Dubois, D. & Prade H, 1996)

Η μέθοδος ασαφούς συλλογισμού που χρησιμοποιείται στην παρούσα διπλωματική είναι η Takagi – Sugeno. Προτάθηκε από τους Takagi, Sugeno και Kang στην προσπάθεια να αναπτύξουν έναν τρόπο εξαγωγής ασαφών κανόνων από δεδομένα εισόδου/εξόδου. Οι κανόνες του μοντέλου Takagi – Sugeno είναι της μορφής:

R : **EAN** x είναι A και y είναι B **TOTE** $z = f(x, y)$ (Εξίσωση 3.1.7)

όπου A, B ασαφή σύνολα ενώ το συμπέρασμα είναι $z = f(x, y)$ μια συνάρτηση πολυωνυμική ως προς τις μεταβλητές εισόδου x, y . Αυτή η μέθοδος έχει ως πλεονέκτημα να μειώνει σημαντικά τον αριθμό των ασαφών κανόνων που χρειάζονται για την ασαφή μοντελοποίηση του συστήματος (Sugeno, 1985).

3.1.6 Βασική δομή- χαρακτηριστικά ασαφούς ελεγκτή



Διάγραμμα 3.1.2: Δομή ασαφούς ελεγκτή

Η δομή του ασαφούς ελεγκτή περιγράφεται από τα εξής χαρακτηριστικά (Jang, 1993):

- **Βάση γνώσης:** Αποτελείται από την βάση κανόνων (της μορφής «EAN-TOTE») και βάση δεδομένων, χάρις τους οποίους γίνεται ο έλεγχος της διαδικασίας.
- **Μηχανισμός Ασαφοποίησης:** μετατρέπει τις πραγματικές τιμές των μεταβλητών εισόδου του ελεγκτή σε ασαφή σύνολα.
- **Ασαφή σύνολα:** Ορίζοντας τα ασαφή σύνολα είναι δυνατή η μετατροπή των λεκτικών κανόνων της βάσης γνώσης σε μαθηματικούς κανόνες.
- **Μηχανισμός Συμπερασμού-Λήψης Αποφάσεων:** Εκεί παράγονται τα ασαφή σύνολα των συμπερασμάτων.
- **Μηχανισμός Σαφοποίησης:** Τα ασαφή σύνολα των συμπερασμάτων μετατρέπονται σε πραγματικούς αριθμούς έτσι ώστε να είναι δυνατή η μετάδοση της δράσης ελέγχου στην διαδικασία.

3.2 Τεχνητά Νευρωνικά Δίκτυα

Τεχνητό Νευρωνικό δίκτυο ονομάζεται ένα κύκλωμα διασυνδεδεμένων τεχνητών νευρώνων, ένα αφηρημένο αλγοριθμικό κατασκευάσμα που στόχος του είναι η επίλυση κάποιου υπολογιστικού προβλήματος.

Ουσιαστικά πρόκειται για ένα δίκτυο υπολογιστικών κόμβων (νευρώνες) που συνδέονται μεταξύ τους. Οι νευρώνες ως δομικά στοιχεία του δικτύου, δέχονται ένα σύνολο αριθμητικών εισόδων από το περιβάλλον ή από άλλους νευρώνες, επιτελούν έναν υπολογισμό και παράγουν μία έξοδο, η οποία είτε τροφοδοτείται ως είσοδος σε άλλους νευρώνες του δικτύου είτε κατευθύνεται προς το περιβάλλον.

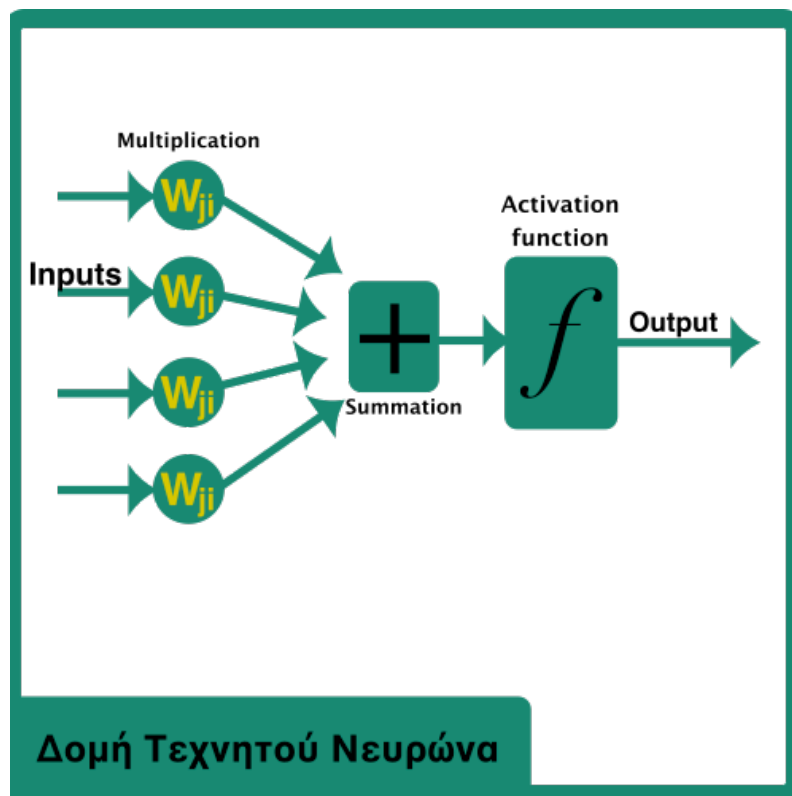
Υπάρχουν τρεις βασικοί τύποι νευρώνων: εισόδου, εξόδου και οι υπολογιστικοί. Οι νευρώνες εισόδου μεσολαβούν ανάμεσα στις περιβαλλοντικές εισόδους του δικτύου και στους υπολογιστικούς νευρώνες και δεν επιτελούν κανέναν υπολογισμό. Οι νευρώνες εξόδου διοχετεύουν στο περιβάλλον τις τελικές αριθμητικές εξόδους του δικτύου. Οι υπολογιστικοί νευρώνες πολλαπλασιάζουν την κάθε είσοδο με το αντίστοιχο συναπτικό βάρος και υπολογίζουν το ολικό άθροισμα των γινομένων. Αυτό το άθροισμα τροφοδοτείται στην συνάρτηση ενεργοποίησης, την οποία τροφοδοτεί εσωτερικά κάθε κόμβος. Συγκεκριμένα εάν x_{ji} είναι η i -οστή είσοδος του j νευρώνα και $G(\cdot)$ μία συνάρτηση ενεργοποίησης, τότε η έξοδος y_j του j νευρώνα ορίζεται ως:

$$G(\sum_{i=0}^N x_{ji} W_{ji}) \text{ (Εξίσωση 3.2.1)}$$


Όπου W_{ji} το συναπτικό i -οστό βάρος του j νευρώνα.

Η τιμή την οποία τελικά παίρνει η συνάρτηση ως όρισμα ουσιαστικά είναι η έξοδος του εν λόγω νευρώνα. Αξίζει να σημειωθεί ότι στον k -οστό νευρώνα υπάρχει ένα συναπτικό βάρος που ονομάζεται κατώφλι (threshold). Η τιμή της εισόδου του ισοδυναμεί πάντοτε με την μονάδα. Σε περίπτωση που το συνολικό άθροισμα από τις υπόλοιπες εισόδους του νευρώνα είναι μεγαλύτερο της μονάδας τότε ο νευρώνας ενεργοποιείται αλλιώς παραμένει ανενεργός.

Πρακτικά αυτή η λογική προσπαθεί να προσομοιάσει τα πρότυπα του ανθρώπινου εγκεφάλου. Οι νευρώνες του ανθρώπινου εγκεφάλου, έχουν μια διακλαδωτική διάρθρωση εισροών, τους δενδρίτες, ένα κυτταρικό σώμα και μια διακλαδωτική δομή εκροών, τον άξονα. Οι άξονες ενός κυττάρου συνδέονται με τους δενδρίτες ενός άλλου, μέσω μιας σύναψης. Όταν, λοιπόν, ένας άξονας ενεργοποιηθεί, πυροδοτεί ένα ηλεκτροχημικό σήμα κατά μήκος του άξονα. Ένας νευρώνας εκτελεί αυτή τη διαδικασία μόνο όταν το συνολικό σήμα το οποίο λήφθηκε από τους δενδρίτες, υπερβεί ένα συγκεκριμένο επίπεδο (firing threshold). (Haykin, 1999).



Διάγραμμα 3.2.1 Δομή Τεχνητού Νευρώνα




Διάγραμμα 3.2.2 Δομή Βιολογικού Νευρώνα

3.2.1 Συναρτήσεις Ενεργοποίησης

Υπάρχουν διάφορων ειδών συναρτήσεις ενεργοποίησης. Οι κυριότερες είναι (Διαμαντάρας, 2007):


- Βηματική συνάρτηση ενεργοποίησης: $G(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x \leq 0 \end{cases}$ (Εξίσωση 3.2.2)



Διάγραμμα 3.2.1.1

Βηματική συνάρτηση ενεργοποίησης



- Γραμμική συνάρτηση ενεργοποίησης: $G(x) = x$ (Εξίσωση 3.2.3)



Διάγραμμα 3.2.1.2

Γραμμική συνάρτηση ενεργοποίησης

- Μη γραμμική συνάρτηση ενεργοποίησης: συνήθως στα νευρωνικά δίκτυα οι μη γραμμικές συναρτήσεις που χρησιμοποιούνται είναι η λογιστική σιγμοειδής $G(x) = \frac{1}{1+e^{-x}}$ (Εξίσωση 3.2.4) και η υπερβολική εφαπτομένη $G(x) = \tanh x$ (Εξίσωση 3.1.5)




Διάγραμμα 3.2.1.2 Σιγμοειδής (αριστερά) και υπερβολική εφαπτομένη (δεξιά) συνάρτηση ενεργοποίησης

3.2.2 Αρχιτεκτονικές νευρωνικών δικτύων

Ως αρχιτεκτονική ενός νευρωνικού δικτύου, νοείται ο τρόπος με τον οποίο συνδέονται μεταξύ τους οι νευρώνες του δικτύου. Η επιλογή της αρχιτεκτονικής του νευρωνικού δικτύου αποτελεί σημαντική απόφαση για τη σχεδίαση του, καθορίζοντας έτσι την ικανότητα του δικτύου να επιλύει συγκεκριμένα προβλήματα, όπως επίσης τον τρόπο εκπαίδευσης του (δηλαδή τους αλγόριθμους που χρησιμοποιούνται στην φάση εκπαίδευσης-εκμάθησης του δικτύου). Γενικά οι κύριες κατηγορίες αρχιτεκτονικής των νευρωνικών δικτύων φαίνονται παρακάτω (Haykin, 1999):


Δίκτυο Εμπρός Τροφοδότησης με Ένα Επίπεδο (Single Layer FeedForward Networks): Ένα νευρωνικό δίκτυο, έχει τους νευρώνες του οργανωμένους σε ομάδες ή αλλιώς επίπεδα. Οι νευρώνες κάθε επιπέδου δε συνδέονται μεταξύ τους, αλλά έχουν συνδέσεις από και προς τους νευρώνες άλλων επιπέδων. Στην πιο απλοποιημένη μορφή το δίκτυο αποτελείται από μόλις ένα επίπεδο. Το δίκτυο διαθέτει ένα επίπεδο εισόδου με κόμβους οι οποίοι συνδέονται ο καθένας με όλους τους νευρώνες του μοναδικού επιπέδου του δικτύου. Να σημειωθεί πως οι κόμβοι του επιπέδου εισόδου δε θεωρούνται νευρώνες μιας και δεν εκτελούν κανένα υπολογισμό αλλά παρέχουν μόνο το διάνυσμα εισόδου στο νευρωνικό δίκτυο. Επιπλέον το σύνολο των εξόδων των νευρώνων του μοναδικού αυτού επιπέδου αποτελεί το διάνυσμα εξόδου από το δίκτυο. Λόγω της ιδιότητας αυτής της μορφής των δικτύων, δηλαδή στο να μεταβιβάζεται η υπολογιστική διαδικασία από την είσοδο του δικτύου προς την έξοδο, τα δίκτυα αυτά ονομάζονται Δίκτυα Εμπρός Τροφοδότησης (Feedforward Networks). Χαρακτηριστική εφαρμογή αυτού του τύπου δικτύων, είναι οι συσχετιστικές μνήμες. Σε αυτού του είδους τις εφαρμογές, το δίκτυο συσχετίζει ένα διάνυσμα εξόδου με ένα διάνυσμα εισόδου. Η πληροφορία αποθηκεύεται στο δίκτυο με τη μορφή αλλαγών που γίνονται στα βάρη των συνάψεων.



Διάγραμμα 3.2.2.1 Δομή Single Layer Feed Forward NN


Δίκτυο Εμπρός Τροφοδότησης Πολλαπλών Επιπέδων (Multilayer FeedForward Networks): Ένα άλλο είδος νευρωνικών δικτύων που μοιάζουν με την προηγούμενη κατηγορία αλλά διαφέρουν ως προς τον αριθμό των επιπέδων των νευρώνων. Συγκεκριμένα αποτελούνται από περισσότερα επίπεδα νευρώνων (κρυφά επίπεδα αποτελούμενα από

κρυφούς νευρώνες). Η λειτουργία τους συνίσταται, στο ότι παρεμβαίνουν μεταξύ της εισόδου στο δίκτυο και της εξόδου του δικτύου. Με την πρόσθεση περισσότερων επιπέδων κρυφών νευρώνων στο νευρωνικό δίκτυο, το δίκτυο αποκτά τη δυνατότητα αφομοίωσης περισσότερων πληροφοριών για τα δεδομένα εισόδου, μέσω των περισσότερων συνάψεων που έχει στη διάθεσή του και των μεγαλύτερης πολυπλοκότητας αλληλεπιδράσεων, μεταξύ των νευρώνων του. Ο τρόπος υπολογισμού της εξόδου του δικτύου είναι παρόμοια με αυτή της προηγούμενης κατηγορίας δικτύων. Οι κόμβοι του επιπέδου εισόδου του δικτύου παρέχουν το διάνυσμα εισόδου του δικτύου στους κόμβους του 1ου κρυφού επιπέδου. Εκτελείται ο υπολογισμός στους κόμβους του 1ου επιπέδου και στη συνέχεια η έξοδος του 1ου κρυφού επιπέδου παρέχεται σαν είσοδος στους νευρώνες του 2ου κρυφού επιπέδου. Αφού εκτελεστεί ο υπολογισμός η έξοδος μεταφέρεται στο επόμενο επίπεδο νευρώνων, και η διαδικασία συνεχίζεται, με το ένα επίπεδο να χρησιμοποιεί σαν είσοδο την έξοδο του προηγούμενου.



Διάγραμμα 3.2.2.1 Δομή Multi- Layer Feed Forward NN

Αναδρομικά Δίκτυα (Recurrent Networks): Η κύρια διαφορά των αναδρομικών δικτύων σε σχέση με τις προηγούμενες δύο κατηγορίες (εμπρός τροφοδότησης), είναι η ύπαρξη ενός τουλάχιστον βρόχου ανάδρασης (feedback loop). Με άλλα λόγια, ένα αναδρομικό νευρωνικό δίκτυο μπορεί να αποτελείται από ένα ή περισσότερα επίπεδα νευρώνων (πολλαπλά κρυφά επίπεδα), στα οποία κάθε κρυφός νευρώνας μπορεί να τροφοδοτεί την έξοδό του ως είσοδο προς όλους τους νευρώνες του δικτύου. Παράλληλα υπάρχει η δυνατότητα αυτοανάδρασης, δηλαδή ένας νευρώνας μπορεί να δέχεται σαν είσοδο την ίδια του την έξοδο.



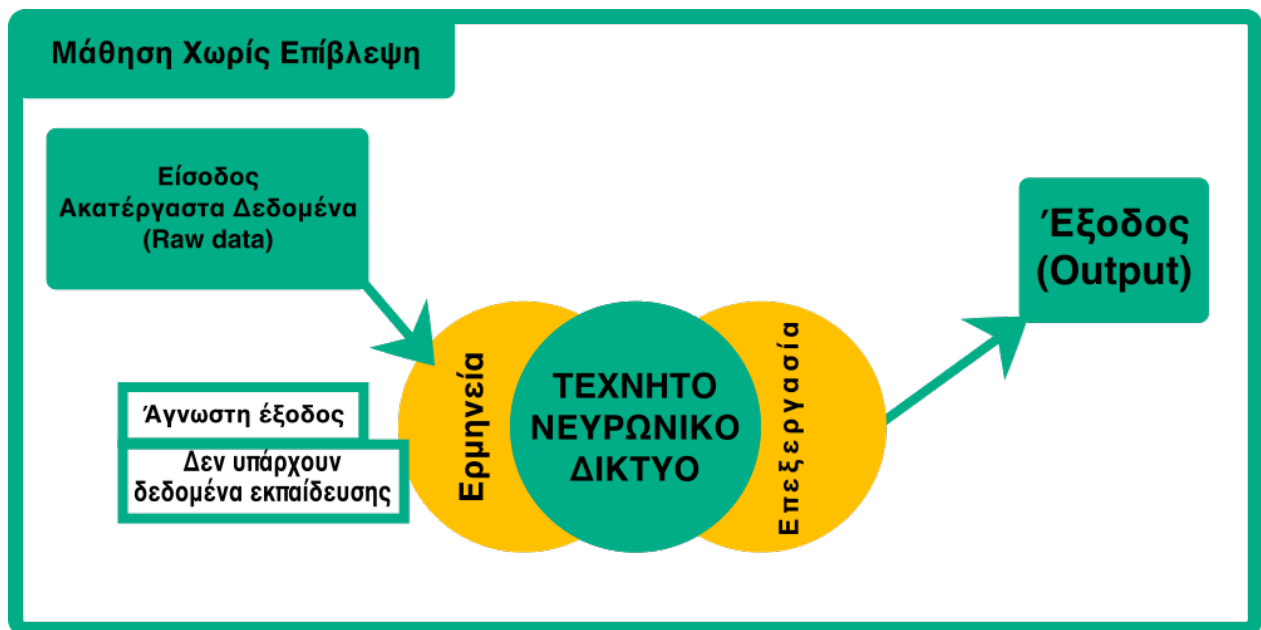
Διάγραμμα 3.2.2.3 Δομή ενός τεχνητού νευρωνικού δικτύου με αναδρομή

3.2.3 Κανόνες μάθησης νευρωνικών δικτύων

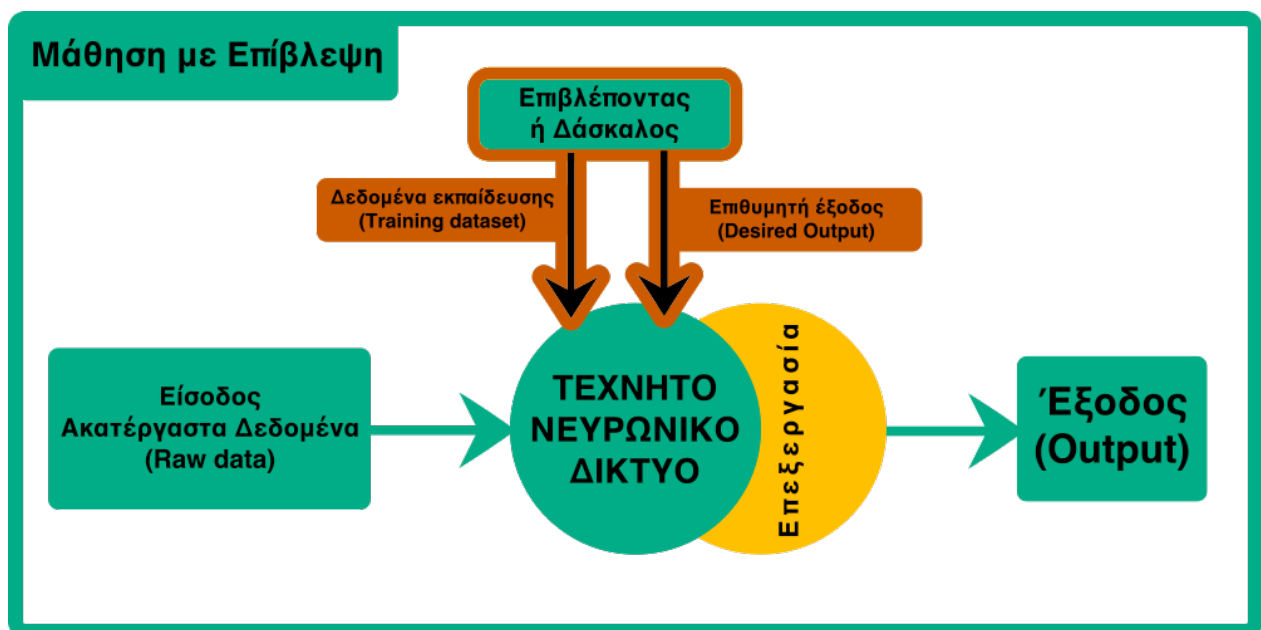
Μία από τις βασικότερες ιδιότητες των τεχνητών νευρωνικών δικτύων είναι η ικανότητα μάθησης από το περιβάλλον τους και η βελτίωση της απόδοσης τους μέσω της φάσης της εκπαίδευσης. Σύμφωνα με τον Haykin (1999), ως μάθηση νευρωνικού ορίζεται «η διαδικασία με την οποία οι ελεύθερες παράμετροι ενός νευρωνικού δικτύου προσαρμόζονται μέσω μιας συνεχούς διαδικασίας διέγερσης από το περιβάλλον μέσα στο οποίο είναι ενσωματωμένο το νευρωνικό δίκτυο. Ο τύπος της μάθησης καθορίζεται από τον τρόπο με τον οποίο γίνεται η μεταβολή των παραμέτρων». Επομένως γίνεται αντιληπτό πως ένα τεχνητό νευρωνικό δίκτυο διεγείρεται από το περιβάλλον του, υφίσταται αλλαγές στην εσωτερική δομή του και τέλος ανταποκρίνεται με ένα νέο τρόπο στο περιβάλλον του.

Για τον σχεδιασμό των νευρωνικών δικτύων, χρησιμοποιούνται ένα σύνολο καλά ορισμένων κανόνων, οι αλγόριθμοι μάθησης. Να επισημανθεί, πως αναλόγως το προς επίλυση πρόβλημα υπάρχουν και διαφορετικοί αλγόριθμοι, ο καθένας με τα δικά του πλεονεκτήματα. Γενικότερα οι αλγόριθμοι μάθησης, οι οποίοι μπορούν να θεωρηθούν ως μια διαδικασία βελτιστοποίησης, διαφέρουν μεταξύ τους ως προς τον τρόπο που μεταβάλλονται και δίδονται τιμές στα βάρη W_{ji} . Ουσιαστικά αυτοί οι αλγόριθμοι κατατάσσονται στις παρακάτω κατηγορίες (Haykin, 1999) :

1. **Μάθηση με επίβλεψη (supervised learning):** πρόκειται για διαδικασία που απαιτείται κάποιο διάνυσμα εξόδου το οποίο αντιστοιχεί στις επιθυμητές τιμές. Ουσιαστικά ο επιβλέπωντας, εφοδιάζει το δίκτυο με την επιθυμητή απόκριση, που αποτελεί την βέλτιστη συμπεριφορά που μπορεί να αναπτύξει το δίκτυο.
2. **Μάθηση χωρίς επίβλεψη (unsupervised learning):** πρόκειται για την διαδικασία που στόχο έχει, τον διαχωρισμό ενός συνόλου δειγμάτων προς εκπαίδευση σε κλάσεις (clusters). Δηλαδή το δίκτυο προσπαθεί να εντοπίσει ομοιότητες ανάμεσα στα δείγματα που του παρέχονται και να τα κατηγοριοποιήσει.
3. **Μάθηση με ενίσχυση (reinforcement learning):** πρόκειται για την διαδικασία που εφαρμόζει την τακτική της δοκιμής και του λάθους (trial and error), προσπαθώντας έτσι να μεγιστοποιήσει την τιμή μιας δείκτριας συνάρτησης που ονομάζεται σήμα ενίσχυσης.



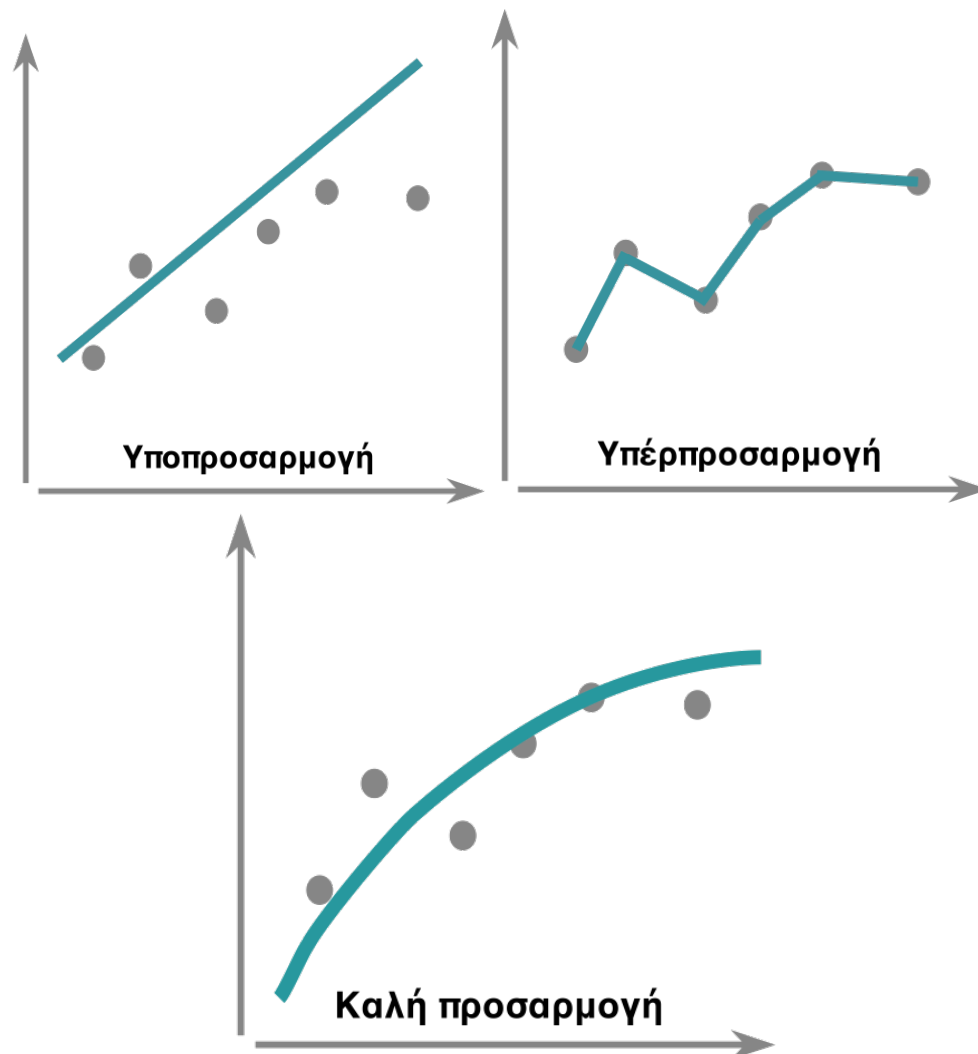
Διάγραμμα 3.2.3.1 Μάθηση χωρίς επίβλεψη



Διάγραμμα 3.2.3.2 Μάθηση με επίβλεψη

Τέλος, αρκετά σημαντικός παράγοντας στην εκπαίδευση ενός νευρωνικού δικτύου είναι ο αριθμός εποχών-επαναλήψεων εκπαίδευσης. Ως εποχή-επανάληψη (epoch) εννοούμε την χρήση όλων των δεδομένων εκπαίδευσης (από το δίκτυο) για μία φορά. Μικρός αριθμός εποχών εκπαίδευσης συνήθως οδηγεί σε άσχημα αποτελέσματα (πχ. υπό-προσαρμογή), ενώ αντίθετα μεγάλος αριθμός εποχών εκπαίδευσης, οδηγεί σε υπερπροσαρμογή και απαιτεί μεγάλο υπολογιστικό χρόνο. Υπερπροσαρμογή έχουμε όταν το τεχνητό νευρωνικό δίκτυο μοντελοποιεί υπερβολικά τα δεδομένα εκπαίδευσης, δίνοντας έτσι, σωστή πρόβλεψη για τα

δεδομένα που χρησιμοποιούνται εκείνη τη στιγμή, αλλά λανθασμένες προβλέψεις για άλλα δεδομένα εισόδου.



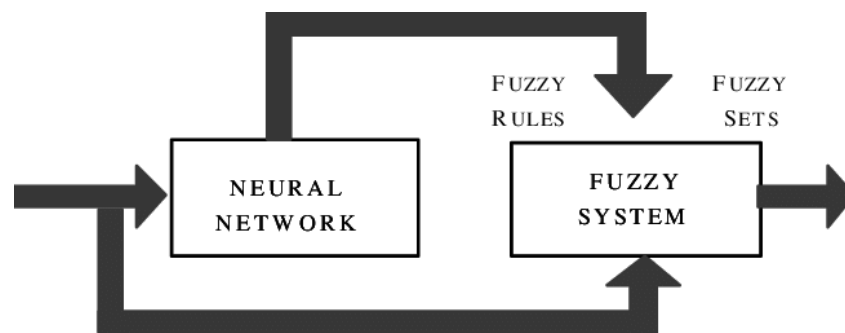
Διάγραμμα 3.2.3.3 Περιπτώσεις μοντελοποίησης δεδομένων: (α) υποπροσαρμογή, (β) υπερπροσαρμογή και (γ) με καλή προσαρμογή

3.3 Νεύρο-ασαφή συστήματα

Προηγουμένως εξετάστηκαν τα ασαφή συστήματα και τα νευρωνικά δίκτυα, δύο κατηγορίες της υπολογιστικής νοημοσύνης. Συνδυάζοντας αυτές τις δύο περιοχές, οδηγούμαστε στη δημιουργία νεύρο-ασαφών συστημάτων, δηλαδή συστημάτων ικανών να εκπαιδεύονται και να έχουν υψηλή συλλογιστική ικανότητα. Τέτοιου είδους συστήματα είναι ιδανικά για την μοντελοποίηση ασαφών και χαοτικών καταστάσεων, λόγω της δυνατότητας να εφαρμόζονται αλγόριθμοι μάθησης νευρωνικών δικτύων, με στόχο την προσαρμογή των παραμέτρων του ασαφούς συστήματος συλλογισμού. Με αυτόν τον τρόπο εξαλείφεται το μειονέκτημα των τεχνητών νευρωνικών δικτύων να μην παρέχουν ένα ισχυρό πλαίσιο για την αναπαράσταση της γνώσης καθώς και αυτό των ελεγκτών ασαφούς λογικής, δηλαδή η ανικανότητα τους για αυτόματη μάθηση.


Υπάρχουν τρεις κατηγορίες νεύρο-ασαφών συστημάτων: **τα συνεργαζόμενα νεύρο-ασαφή συστήματα (cooperative neuro-fuzzy systems), τα συντρέχον νεύρο-ασαφή συστήματα (concurrent neuro-fuzzy systems) και τα υβριδικά νεύρο-ασαφή συστήματα.**

Στα **συνεργαζόμενα νεύρο-ασαφή** συστήματα το νευρωνικό δίκτυο χρησιμοποιείται μόνο στην αρχική φάση καθορίζοντας τις παραμέτρους του ασαφούς συστήματος, βάση των δεδομένων εκπαίδευσης. Έκτοτε εκτελείται μόνο το ασαφές σύστημα.



Διάγραμμα 3.3.1 Συνεργαζόμενο νευρο-ασαφές σύστημα


Στα **συντρέχον νεύρο-ασαφή συστήματα**, το νευρωνικό δίκτυο λειτουργεί μαζί με το ασαφές σύστημα. Αυτό σημαίνει πως οι είσοδοι που εισάγονται σε ένα ασαφές σύστημα προ επεξεργάζονται δίνοντας κάποια έξοδο. Αυτή η έξοδος αποτελεί την είσοδο στο νευρωνικό δίκτυο που την επεξεργάζεται και δίνει μία τελική έξοδο-αποτέλεσμα. Αυτή η διαδικασία μπορεί να πραγματοποιηθεί και αντίστροφα δηλαδή στην αρχική φάση να υπάρχει ένα νευρωνικό δίκτυο και στην τελική ένα ασαφές σύστημα (Vieira et al. 2004).



Διάγραμμα 3.3.2 Συντρέχον νευρο-ασαφές σύστημα


Άλλη μια οπτική σύμφωνα με την οποία κατηγοριοποιούνται τα νεύρο-ασαφή συστήματα είναι η παρακάτω:

Neural Fuzzy System (NFS): Σε αυτού του είδους τα συστήματα τα νευρωνικά δίκτυα χρησιμοποιούνται ως εργαλεία μέσα σε ένα ασαφές μοντέλο. Πρακτικά ενισχύεται ένα ασαφές σύστημα με νευρωνικά δίκτυα, με στόχο την βελτίωση της ευελιξίας, της ταχύτητας και της προσαρμοστικότητας του συστήματος αυτού. Ένα νεύρο-ασαφές σύστημα (NFS) από την άλλη πλευρά έχει ως σκοπό την πραγματοποίηση της διαδικασίας ασαφούς συλλογιστικής (fuzzy reasoning), όπου τα βάρη των συνδέσεων του δικτύου αντιστοιχούν στις παραμέτρους της ασαφούς συλλογιστικής. Χρησιμοποιώντας αλγόριθμους μάθησης, ένα NFS μπορεί να αναγνωρίσει ασαφείς κανόνες και να κατανοήσει τις συναρτήσεις συμμετοχής της ασαφούς συλλογιστικής. Συγκεκριμένα το NFS θα πρέπει να είναι ικανό να κατανοεί λεκτικούς κανόνες και συναρτήσεις συμμετοχής ή να βελτιστοποιεί τους ήδη υπάρχοντες κανόνες ή συναρτήσεις συμμετοχής (Rashid et al., 2012).



Διάγραμμα 3.3.3 Δομή NFS

Fuzzy Neural Networks (FNN): Τα δίκτυα αυτά ουσιαστικά συνιστούν την ασαφοποίηση του συμβατικού μοντέλου νευρωνικού δικτύου. Ουσιαστικά παρέχεται η δυνατότητα σε ένα νευρωνικό δίκτυο να χειρίζεται ασαφείς πληροφορίες. Σε ένα FNN, οι είσοδοι, τα βάρη των συνδέσεων και οι έξοδοι του δικτύου αποτελούν ασαφή υποσύνολα ή ένα σύνολο από τιμές συμμετοχής σε ασαφή σύνολα. Για τη μοντελοποίηση αυτών των δικτύων χρησιμοποιούνται λεκτικές τιμές, όπως "μικρό, μεσαίο, μεγάλο", ή ασαφείς αριθμοί. Νευρωνικά δίκτυα που χρησιμοποιούν ασαφείς νευρώνες χαρακτηρίζονται επίσης FNN, καθώς θεωρούνται ικανά να επεξεργαστούν ασαφείς πληροφορίες (Rashid et al., 2012).




Διάγραμμα 3.3.4 Δομή FNN

Υβριδικά νεύρο-ασαφή συστήματα (Fuzzy-neural Hybrid System): Και στις δύο κατηγοριοποιήσεις τα υβριδικά συστήματα παραμένουν στην ίδια λογική. Τα υβριδικά νεύρο-ασαφή συστήματα, είναι ασαφή συστήματα τα οποία χρησιμοποιούν έναν αλγόριθμο μάθησης εμπνευσμένο από την θεωρία νευρωνικών δικτύων για να καθορίσουν τα ασαφή σύνολα και κανόνες, μέσω κάποιων μοτίβων (εξόδων και των εισόδων στο σύστημα) (Nauck & Kruse, 1997). Σε αυτά τα συστήματα εντάσσεται και το σύστημα ANFIS το οποίο χρησιμοποιήθηκε στην παρούσα διπλωματική. Λεπτομερής ανάλυσή του, θα ακολουθήσει σε επόμενη παράγραφο.

3.4 Ολοκληρωμένα νεύρο-ασαφή συστήματα στην διεθνή βιβλιογραφία


Μερικά από τα σημαντικότερα νεύρο-ασαφή συστήματα που συναντώνται στην διεθνή βιβλιογραφία είναι τα ακόλουθα:

Το **Fuzzy Adaptive Learning Control Network (FALCON)**, (Lin, 1991), χρησιμοποιεί το μηχανισμό συμπερασμού Mamdani με αρχιτεκτονική πέντε επιπέδων. Ο υβριδικός αλγόριθμος μάθησης είναι υβριδικός αποτελείται από δύο φάσεις. Στην αρχική φάση καθορίζονται τα κέντρα και τα βάρη των συναρτήσεων συμμετοχής με τεχνικές μάθησης self-organized. Στη δεύτερη φάση εφαρμόζεται ο αλγόριθμος backpropagation για την προσαρμογή των παραμέτρων των συναρτήσεων συμμετοχής.




Διάγραμμα 3.4.1 Δομή FALCON

Το **GARIC (General Approximate Reasoning-based Intelligent Control)** που δημιουργήθηκε από τους Berenji and Khedkar (1992). Αποτελείται από ένα νεύρο-ασαφές δίκτυο το οποίο μαθαίνει με τη χρήση μεθόδων, βαθμωτής κατάβασης. Περιλαμβάνει τρία κύρια τμήματα: α) Action Evaluation Network (AEN), β) Action Selection Network (ASN) και γ) Stochastic Action Modifier (SAM).



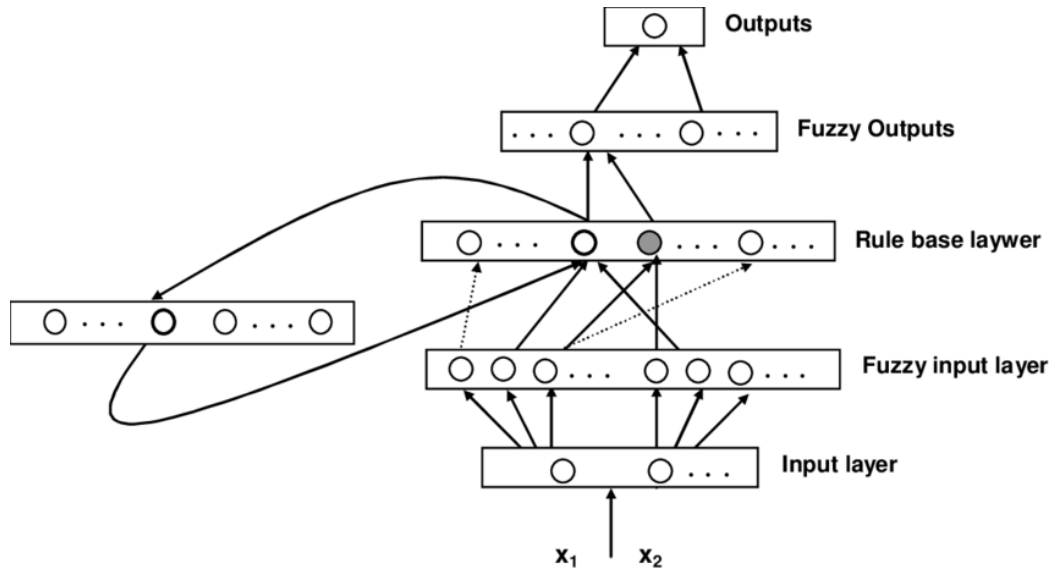
Διάγραμμα 3.4.2 Δομή GARIC

Το **Neuro-Fuzzy Controller (NEFCON)**, το οποίο δημιουργήθηκε από τους Nauck και Kruse (1994). Έχει την δυνατότητα να μαθαίνει ασαφή σύνολα και ασαφείς κανόνες χρησιμοποιώντας τον μηχανισμό συμπερασμού Mamdani. Η διαδικασία μάθησης χωρίζεται σε δύο φάσεις. Στην πρώτη φάση το σύστημα μαθαίνει τους κανόνες και στη δεύτερη φάση βελτιστοποιεί τους κανόνες μεταβάλλοντας τα ασαφή σύνολα των κανόνων. Η μάθηση των κανόνων γίνεται με δύο μεθόδους. Η πρώτη μέθοδος είναι η incremental και χρησιμοποιείται όταν η σωστή έξοδος δεν είναι γνωστή, οπότε οι κανόνες δημιουργούνται με βάση υπολογισμένες τιμές της εξόδου. Καθώς εξελίσσεται η εκπαίδευση όλο και περισσότεροι κανόνες προστίθενται σύμφωνα με τις απαιτήσεις των δεδομένων. Η δεύτερη μέθοδος είναι η decremental στην οποία αρχικά οι κανόνες δημιουργούνται λόγω της ασαφούς διαίρεσης των διαστημάτων των μεταβλητών και στη συνέχεια κατά την διαδικασία της μάθησης απαλείφονται οι κανόνες που δεν χρησιμοποιούνται. Και οι δύο μέθοδοι χρησιμοποιούν ένα ασαφές σφάλμα E , το οποίο αποτυπώνει την ποιότητα του συστήματος, για να δημιουργηθούν και να βελτιστοποιηθούν οι κανόνες. Οι συναρτήσεις συμμετοχής των κανόνων μεταβάλλονται σύμφωνα με τον αλγόριθμο Fuzzy Error Backpropagation.



Διάγραμμα 3.4.3 Δομή NEFCON

Τα **Evolving Fuzzy Neural Networks (EFuNN)** και **Dynamic Evolving Fuzzy Neural Networks (dmFFuNNs)**, (Nauck et al., 1997). Και τα δύο συστήματα βασίζονται στη μεθοδολογία Evolving Connectionist Systems (ECOS) καθώς χρησιμοποιούν υβριδικό αλγόριθμο μάθησης (με επίβλεψη και χωρίς επίβλεψη αντίστοιχα).

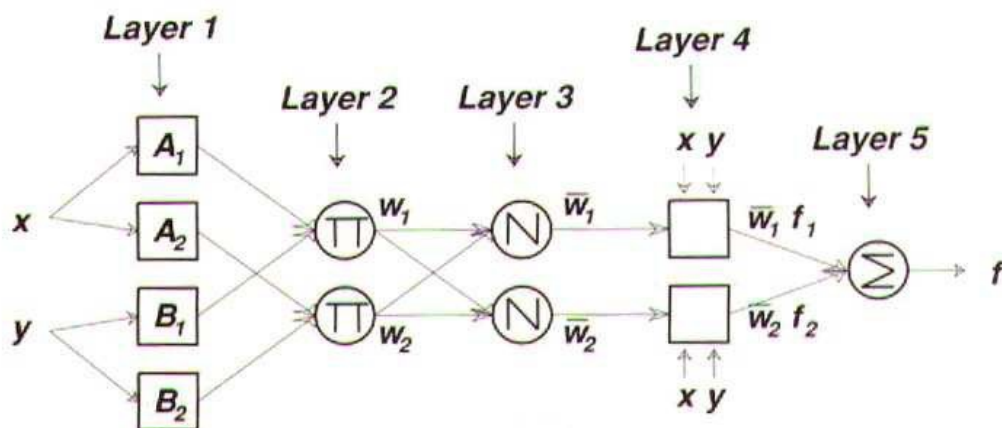


Διάγραμμα 3.4.4 Δομή EFuNN

Το **Adaptive Neuro-Fuzzy Inference System (ANFIS)** το δημιούργησε ο Jang (1992). Βασικό χαρακτηριστικό του είναι ότι χρησιμοποιεί την ασαφή συλλογιστική Takagi-Sugeno. Θεωρώντας ότι ένα σύστημα ANFIS έχει δύο εισόδους x, y και μία έξοδο z μπορούμε να εκφράσουμε ένα πρώτης τάξης σύστημα ασαφούς συλλογισμού Sugeno δύο κανόνων, στην εξής μορφή:

Κανόνας 1: **EAN** x είναι A_1 και y είναι B_1 **TOTE** $f_1 = p_1x + q_1y + r_1$

Κανόνας 2: **EAN** x είναι A_2 και y είναι B_2 **TOTE** $f_2 = p_2x + q_2y + r_2$



Διάγραμμα 3.4.5 Δομή ANFIS

Το διάγραμμα 3.4.5 περιγράφει την αρχιτεκτονική του ANFIS για δύο εισόδους, μία έξοδο και δύο κανόνες. Το ANFIS αποτελείται από 5 στρώματα (layers). Στο 1^ο στρώμα, κάθε κόμβος i

δέχεται τις μεταβλητές x, y με συναρτήσεις συμμετοχής:

$$s_i^{(1)} = \mu_{A_i}(x), \quad i = 1, 2 \quad (\text{Εξίσωση 3.4.1})$$

$$s_i^{(1)} = \mu_{B_{i-2}}(y), \quad i = 3, 4 \quad (\text{Εξίσωση 3.4.2})$$

Όπου A_j, B_j γλωσσικές μεταβλητές που αντιστοιχούν σ' αυτό τον κόμβο με συναρτήσεις συμμετοχής $\mu_{A_j}(x), \mu_{B_j}(y)$. Με άλλα λόγια οι έξοδοι αυτού του στρώματος $s_i^{(1)}$ είναι ο βαθμός συμμετοχής σε κάποιο ασαφές σύνολο και καθορίζει το βαθμό στον οποίο η εκάστοτε είσοδος ικανοποιεί το δεδομένο του αντίστοιχου κανόνα. Στο 2^ο στρώμα, περιλαμβάνονται n κόμβοι, όπου n ο αριθμός των κανόνων. Καθένας από τους n κόμβους δίνει ως έξοδο το γινόμενο των εισόδων του.

$$s_i^{(2)} = w_i = \mu_{A_i}(x)\mu_{B_i}(y), \quad i = 1, 2 \quad (\text{Εξίσωση 3.4.3})$$

Οι συνδέσεις στα πρώτα δύο στρώματα γίνεται με βάση τους ασαφείς κανόνες στους οποίους βασίζεται το ANFIS. Οι έξοδοι του δεύτερου επιπέδου αντιστοιχούν στο βαθμό ενεργοποίησης ασαφών κανόνων. Στο 3^ο στρώμα ο αριθμός των N κόμβων είναι όμοιος με αυτών του 2^{ου} στρώματος. Οι κόμβοι αυτού υπολογίζουν το κλάσμα:


$$s_i^{(3)} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (\text{Εξίσωση 3.4.4})$$

Όπου w_i ο βαθμός ενεργοποίησης του ασαφούς κανόνα i ως προς το άθροισμα όλων των βαθμών ενεργοποίησης όλων των ασαφών κανόνων. Η έξοδος του 3^{ου} στρώματος είναι κανονικοποιημένος βαθμός ενεργοποίησης του κανόνα i . Στο 4^ο στρώμα ο κάθε κόμβος δίνει την παρακάτω έξοδο:

$$s_i^{(4)} = \bar{w}_i f_i \quad (\text{Εξίσωση 3.4.5})$$

Με $f_i = p_i x + q_i y + r_i$. Τα $\{p_i, q_i, r_i\}$ πρόκειται για παραμέτρους του κόμβου που ανανεώνονται στην διαδικασία της εκπαίδευσης. Τέλος στο 5^ο στρώμα υπάρχει μόνο ένας κόμβος Σ που υπολογίζει την συνολική έξοδο του ANFIS:

$$y = s_i^{(5)} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (\text{Εξίσωση 3.4.6})$$



Διάγραμμα 3.4.6 Η ασαφής συλλογιστική του ANFIS (από την είσοδο μέχρι την έξοδο του μοντέλου)

3.5 Προτεινόμενο μοντέλο

Η πρόβλεψη θερμοκρασίας και γενικότερα ατμοσφαιρικών συνθηκών στην σύγχρονη εποχή απαιτεί έξυπνα συστήματα τα οποία αντιλαμβάνονται τις μεταβαλλόμενες συνθήκες.


Η μεθοδολογία που παρουσιάζεται στην συγκεκριμένη διπλωματική θεωρεί ως εισόδους, τα ιστορικά δεδομένα των θερμοκρασιών, για να δημιουργήσει ένα μοντέλο πρόβλεψης, το οποίο αντιλαμβάνεται τους νόμους και τις συνθήκες σύμφωνα με τις οποίες διαμορφώνεται η θερμοκρασία του πλανήτη. Το προτεινόμενο νευρο-ασαφές μοντέλο χρησιμοποιεί την τεχνική ANFIS, η οποία αποδεικνύεται ότι υπερτερεί έναντι άλλων στην μοντελοποίηση χρονοσειρών (time series), όπως φαίνεται στα Abraham et al. (2005), Jang et al. (1997).

Στην εργασία αυτήν χρησιμοποιείτε το μοντέλο πρόβλεψης PATSOS (Atsalakis & Valavanis, 2009). Σύμφωνα με το *διάγραμμα 3.5.1* το μοντέλο αποτελείται από δύο υποσυστήματα ANFIS, τα οποία δημιουργούν έναν κλειστό βρόχο ανατροφοδότησης. Το υποσύστημα PR-ANFIS μοντελοποιεί τα ιστορικά δεδομένα ως μία διαδικασία προς έλεγχο, προκειμένου να προβλέψει την τάση της μηνιαίας θερμοκρασίας τον επόμενο μήνα. Το υποσύστημα CON-ANFIS πρόκειται για τον νευρο-ασαφή ελεγκτή, ο οποίος ελέγχει την επεξεργασία των δεδομένων και προβλέπει την τάση της θερμοκρασίας την επόμενη χρονική στιγμή (one-step-ahead). Για μια διακριτή περίοδο χρόνου, το συνολικό σύστημα λειτουργεί με βάση τις εξισώσεις του ελέγχου και της διαδικασίας όπως φαίνονται παρακάτω:


$$y(k+1) = f(y(k), u(k)) \text{ (Εξίσωση 3.5.1)}$$

$$u(k) = g(y(k)) \text{ (Εξίσωση 3.5.2)}$$

όπου, $y(k+1)$ είναι η τιμή της θερμοκρασίας στην χρονική στιγμή $(k+1)$, $y(k)$ είναι η τιμή της θερμοκρασίας την χρονική στιγμή k . Το πρόβλημα ελέγχου ορίζεται ως ο καθορισμός του G για τον ελεγκτή, ώστε το συνολικό σύστημα που προκύπτει, να παρουσιάζει μία επιθυμητή συμπεριφορά. Ακολουθεί μία λεπτομερής περιγραφή για τον ελεγκτή (CON-ANFIS) και της διαδικασίας (PR-ANFIS) κατά την διάρκεια της εκπαίδευσής τους, στα θερμοκρασιακά δεδομένα.



Διάγραμμα 3.5.1 Προτεινόμενο μοντέλο (φάση εκπαίδευσης)



Διάγραμμα 3.5.1 Προτεινόμενο μοντέλο (φάση αξιολόγησης)

3.5.1 Ελεγκτής CON-ANFIS - φάση εκπαίδευσης.

Η εκπαίδευση του ελεγκτή CON-ANFIS βασίζεται στην μέθοδο της αντίστροφης εκμάθησης (inverse learning technique), γνωστή και ως γενική μάθηση (Jang et al., 1997). Στην φάση της εκπαίδευσης, χρησιμοποιείται μία off-line τεχνική για την μοντελοποίηση των αντίστροφων δυναμικών της διαδικασίας. Στην φάση της εφαρμογής (επικύρωσης), το νευρο-ασαφές μοντέλο που αντιπροσωπεύει την αντίστροφη δυναμική (inverse dynamics) της διαδικασίας, χρησιμοποιείται για να δημιουργήσει δράσεις ελέγχου που καθοδηγούν το θερμοκρασιακό μοντέλο της διαδικασίας (plant). Αυτές οι δύο φάσεις μπορούν και λειτουργούν ταυτόχρονα και ως εκ τούτου αυτή η μέθοδος ταιριάζει σε κλασικά προσαρμοστικά συστήματα ελέγχου (classical adaptive control schemes).

Το μοντέλο της διαδικασίας των θερμοκρασιών εκφράζεται από τον παρακάτω τύπο.

Γενικότερα:

$$y(k+n) = F(y(k), U) \text{ (Εξίσωση 3.5.3)}$$

όπου n είναι το βήμα της επεξεργασίας, η F είναι μία σύνθετη συνάρτηση πολλαπλότητας (multiple composite function) της f και U η δράση ελέγχου από τη k μέχρι τη $k+n-1$ χρονική στιγμή. Ουσιαστικά η εξίσωση (3) υποδεικνύει το γεγονός ότι για μία δοσμένη είσοδο ελέγχου u από την χρονική στιγμή k μέχρι τη $k+n-1$, οι τιμές της θερμοκρασίας θα κινηθούν από την $y(k)$ μέχρι την $y(k+n)$ σε n βήματα. Επίσης, θεωρώντας πως η αντίστροφη δυναμική του μοντέλου της διαδικασίας υπάρχει, η U μπορεί να εκφραστεί ως μία ρητή συνάρτηση της $y(k)$ και της $y(k+n)$. (Atsalakis & Valavanis, 2009)

Με άλλα λόγια:

$$U = G(y(k), y(k+n)) \text{ (Εξίσωση 3.5.4)}$$

Η εξίσωση (3.5.4) δηλώνει ότι υπάρχουν μοναδικές ακολουθίες U , ορισμένες με βάση τον καθορισμό της G , οι οποίες μπορούν και καθοδηγούν τις τιμές της θερμοκρασίας από την θερμοκρασία $y(k)$ στην $y(k+n)$ σε n βήματα. Επομένως πρέπει να βρεθεί ο αντίστροφος καθορισμός της G . Ένας ελεγκτής ANFIS μπορεί να χρησιμοποιηθεί ώστε με $2n$ εισόδους και n εξόδους να προσεγγίζει τον αντίστροφο καθορισμό του G σύμφωνα με τα δεδομένα που χρησιμοποιούνται στην φάση εκπαίδευσης $[y(k)^T, y(k+1)^T, U^T]$. Η τιμή της θερμοκρασίας $y(k+1)$ (output), είναι μια συνάρτηση από την προηγούμενη τιμή $y(k)$ και της εισόδου $u(k)$. Έπειτα από την φάση της εκπαίδευσης, ο ελεγκτής ANFIS μιμείται την είσοδο-έξοδο (input-output) του καθορισμού της αντίστροφης δυναμικής G . Αμέσως μετά και δοθέντος του $y(k)$

και της επιθυμητή τιμής της θερμοκρασίας στο μέλλον $y_d(k+n)$, ο ελεγκτής ANFIS θα δημιουργήσει μία εκτίμηση \hat{U} :

$$\hat{U} = \hat{G}(y(k), y(k+n)) \quad (\text{Εξίσωση 3.5.5})$$

Μετά από n βήματα η ακολουθία ελέγχου θα φέρει τα $y(k)$, κοντά στα επιθυμητά $y_d(k+n)$, εφόσον η συνάρτηση \hat{G} είναι ακριβώς η ίδια με τον αντίστροφο καθορισμό της G . Όταν η \hat{G} δεν πλησιάζει την G , η ακολουθία ελέγχου \hat{U} δεν μπορεί να φέρει το $y(k)$ κοντά στο $y_d(k+n)$ ακριβώς σε n βήματα. Καθώς χρησιμοποιούνται περισσότερα δεδομένα για να βελτιώσουν τις παραμέτρους του ελεγκτή ANFIS, η \hat{G} έρχεται πιο κοντά στην G και ο έλεγχος γίνεται ολοένα και πιο ακριβής. Να σημειωθεί ότι το επιθυμητό $y_d(k+n)$ δεν είναι διαθέσιμο εκ των προτέρων και κατά την διάρκεια την φάσης εκπαίδευσης. (Atsalakis & Valavanis, 2009)

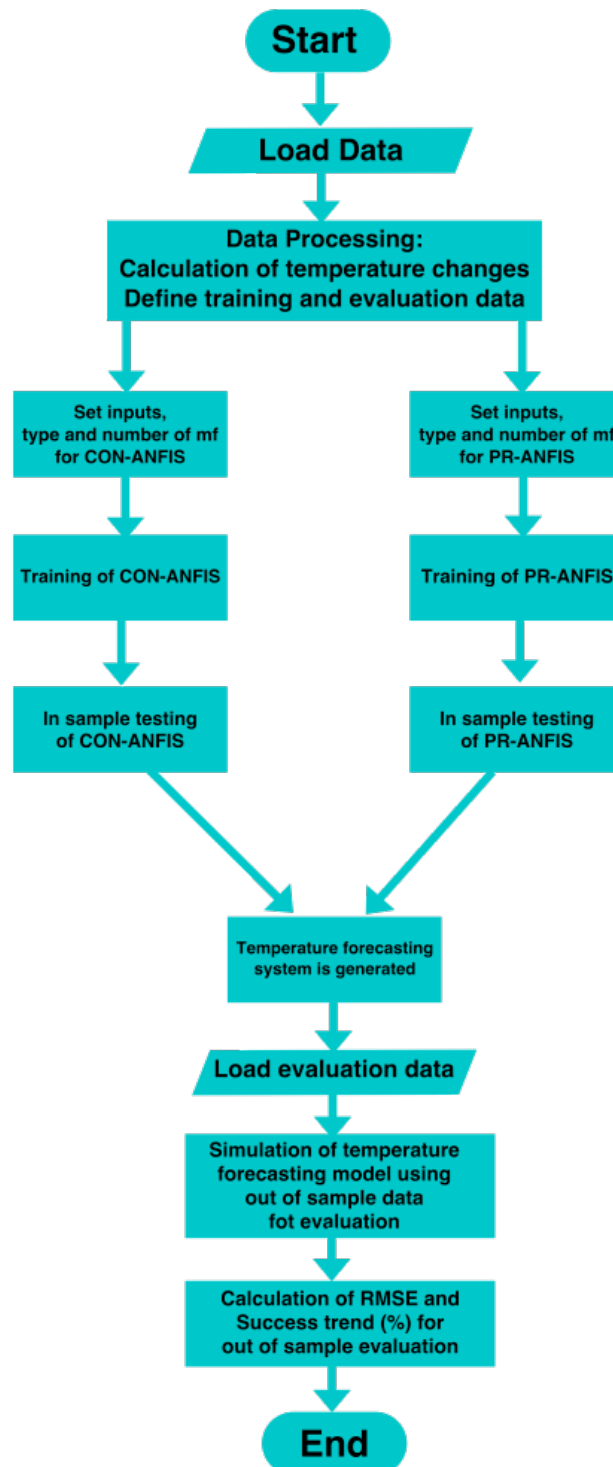
Να σημειωθεί πως στην συγκεκριμένη μεθοδολογία, αντί να χρησιμοποιείται το $y_d(k+n)$ για την επόμενη χρονική στιγμή της σειράς, χρησιμοποιείται ο ρυθμός μεταβολής (rate of change) του κινούμενου μέσου τριών χρονικών στιγμών της θερμοκρασίας.

3.5.2 Επεξεργασία PR-ANFIS - φάση εκπαίδευσης.

Το μοντέλο επεξεργασίας των τιμών της θερμοκρασίας, προσεγγίζεται με μεθόδους αναγνώρισης που βασίζονται αποκλειστικά στα θερμοκρασιακά δεδομένα. Το μοντέλο επεξεργασίας εκπαιδεύεται ώστε να δημιουργήσει μία πρόβλεψη για το επόμενο χρονικό βήμα (one step ahead). Οι είσοδοι είναι οι τρέχουσες και προγενέστερες έξοδοι των πραγματικών μεταβολών των θερμοκρασιακών τιμών καθώς και η δράση ελέγχου, ληφθήσα από τον ελεγκτή CON-ANFIS:

$$y(k+1) = f(y(k), y(k-1), u(k)) \quad (\text{Εξίσωση 3.5.6})$$

Το παρακάτω διάγραμμα ροής εξηγεί όλη την διαδικασία με την οποία λειτουργεί το μοντέλο.



Διάγραμμα 3.5.3 Ροή διαδικασίας με την οποία λειτουργεί το προτεινόμενο μοντέλο

Σύμφωνα με το διάγραμμα ροής, το μοντέλο PATSOS αρχικά δέχεται τα δεδομένα και κάνει μια επεξεργασία πάνω σε αυτά. Υπολογίζονται οι μεταβολές στις μηνιαίες θερμοκρασιακές τιμές και καθορίζονται τα δεδομένα εκπαίδευσης και της αξιολόγησης. Έπειτα ακολουθεί ο καθορισμός των παραμέτρων των υποσυστημάτων CON-ANFIS και PR-ANFIS. Αφού επιλεγθεί ο κατάλληλος τύπος και αριθμός συναρτήσεων συμμετοχής καθώς και επαναλήψεων τα υποσυστήματα εκπαιδεύονται σύμφωνα με αυτές τις παραμέτρους. Ακολουθεί η εντός δείγματος αξιολόγηση των υποσυστημάτων. Ύστερα δημιουργείται το μοντέλο πρόβλεψης

θερμοκρασίας (δηλαδή το μοντέλο PATSOS). Η πρόβλεψη που δημιουργεί το μοντέλο συγκρίνεται μαζί με τα δεδομένα που είχαν επιλεχθεί στην αρχή για την αξιολόγηση. Τέλος, υπολογίζεται το σφάλμα RMSE και η ακρίβεια του ποσοστού σωστής πρόβλεψης της τάσης της θερμοκρασίας.

Να επισημανθεί πως το προτεινόμενο μοντέλο PATSOS χρησιμοποιήθηκε επιτυχώς στην πρόβλεψη διαφόρων μεγεθών όπως:

Α) για την πρόβλεψη της τάσης των εμπορευμάτων που διαπραγματεύονται στις χρηματιστηριακές αγορές (Atsalakis et al., 2015).

Β) Για την πρόβλεψη της τάσης των μετοχών στο χρηματιστήριο Νέας Υόρκης και Αθηνών (Atsalakis & Valavanis, 2009).

Γ) για την πρόβλεψη των τιμών των μετοχών σε περιόδους κρίσης (Atsalakis et al., 2016).

Σε επόμενο κεφάλαιο παρουσιάζονται πώς επιλέχθηκαν οι παράμετροι του μοντέλου.

3.6 Σφάλμα RMSE

Η αξιολόγηση του συστήματος πραγματοποιήθηκε με τον υπολογισμό ενός δημοφιλούς στατιστικού μέτρου μέτρησης του σφάλματος, το οποίο χρησιμοποιείται ευρέως και ιδιαίτερα στην σύγκριση και αξιολόγηση μοντέλων από την ακαδημαϊκή κοινότητα.

Πρόκειται για την ρίζα του μέσου τετραγωνικού σφάλματος (Root square mean error-RMSE) που ορίζεται ως:

$$RMSE = \sqrt{\frac{\sum_{t=1}^N (Pr-Re)^2}{N}} \quad (Εξίσωση 3.6)$$


Όπου Pr η προγνωστική τιμή, Re η πραγματική τιμή και N το πλήθος των ζευγών των τιμών που εξετάζονται. (Papadopoulos, Katsafados, 2009)

4. Περιγραφή δεδομένων και επιλογή/βελτιστοποίηση παραμέτρων της μεθόδου στη φάση εκπαίδευσης


4.1 Δεδομένα

Τα δεδομένα που επιλέχθηκαν, αφορούν την μέση μηνιαία θερμοκρασία του πλανήτη, καταγεγραμμένη σε βαθμούς κελσίου και καλύπτουν μία περίοδο διακοσίων εξήντα πέντε ετών. Αρχίζουν από τον Ιανουάριο του 1750 και τελειώνουν τον Δεκέμβρη του 2015, αριθμώντας 3192 μήνες. Η καταγραφή τους είναι μηνιαία. Το σύνολο των δεδομένων πάρθηκε από το Berkeley Earth (2019). Οι μελέτες που έχει υλοποιήσει το Berkeley Earth συνδυάζει 1,6 δισεκατομμύρια αναφορές θερμοκρασίας από 16 προϋπάρχοντα ιστορικά αρχεία. Συνεργάζεται με ποικίλους φορείς, εξειδικευμένους στην επιστήμη της μετεωρολογίας και κλιματολογίας όπως οι ακόλουθοι: U.S. Energy Information Administration, National Oceanic and Atmospheric Administration, National Aeronautics and Space Administration, International Energy Agency, The Met Office-Hadley Centre for Climate Prediction and Research, Federation of American Scientists, Global Warming Art.


Οι περισσότερες θερμοκρασίες κυμαίνονται από δεκατρείς έως δεκατέσσερις βαθμούς κελσίου. Μεγάλη συχνότητα εμφανίζουν και θερμοκρασίες της τάξεως των δύο έως και τεσσάρων βαθμών, έντεκα έως δώδεκα βαθμών και δεκατεσσάρων έως δεκαπέντε βαθμών. Σημειώνεται πως υπάρχουν μεγάλες αβεβαιότητες, στις παλαιές χρονικά μετρήσεις. Με την πάροδο του χρόνου λόγω της βελτίωσης των τρόπων μέτρησης καθώς και την τεχνολογική εξέλιξη των συσκευών μέτρησης της θερμοκρασίας, οι αβεβαιότητες ελαττώνονται αισθητά. Παρόλα αυτά, από το 1750 έως και το 2015 υπάρχει εμφανή επαναληψιμότητα στα δεδομένα, συνιστώντας ένα εποχιακό μοτίβο, το οποίο συντελεί στην μη εμφάνιση μεγάλου σφάλματος πρόβλεψης, λόγω των αβεβαιοτήτων.




Διάγραμμα 4.1.1 Κατανομή συχνοτήτων των μέσων θερμοκρασιακών τιμών



Διάγραμμα 4.1.2 Δείγμα 120 μηνιαίων θερμοκρασιακών τιμών από διάφορες χρονικές περιόδους



Διάγραμμα 4.1.3 Δείγμα 120 μηνιαίων θερμοκρασιακών αποκλίσεων από διάφορες χρονικές περιόδους



Διάγραμμα 4.1.3 Αποκλίσεις στο σύνολο των δεδομένων

4.2 Επιλογή και βελτιστοποίηση παραμέτρων του συστήματος

Ο ελεγκτής CON-ANFIS είναι ένα μοντέλο Sugeno πρώτης τάξης με δύο εισόδους, τις $y(k)$, $y(k+1)$ καθώς και μία έξοδο, την δράση ελέγχου $u(k)$. Σε όλη την διάρκεια της εκπαίδευσης η δράση ελέγχου παραμένει θετική και υπολογίζεται ως εξής :

$$u(k) = \sqrt{(y(k) - y(k+1))^2} \quad (\text{Εξίσωση 4.2.1}) \quad (\text{George S. Atsalakis, 2016})$$

Για κάθε μία από τις δύο εισόδους χρησιμοποιούνται τέσσερις συναρτήσεις συμμετοχής τύπου Gauss πολύ μικρή, μικρή, μεσαία, μεγάλη. Ο συνδυασμός των συναρτήσεων με τις εισόδους δίνει 16 κανόνες (4^2) της μορφής: EAN $y(k+1)$ είναι μικρή, $y(k)$ είναι μικρή, TOTE η $f_1 = p_1 y(k+1) + q_1 y(k) + r_1$

Οι επαναλήψεις (epochs) επιλέγονται στα 1000 ενώ το μέγεθος του βήματος είναι 0.001.

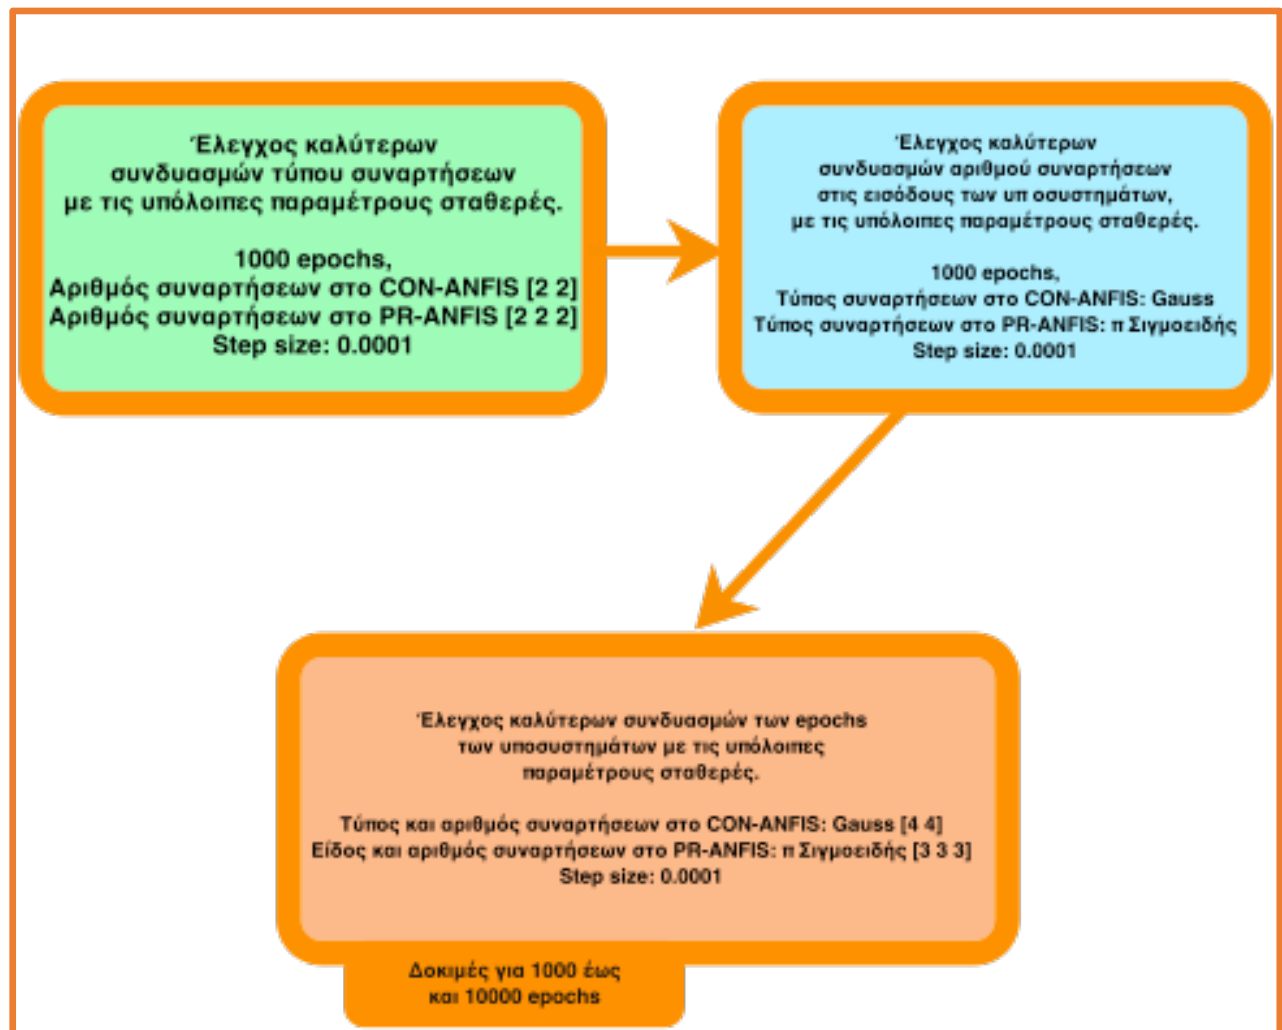
Ομοίως, η διαδικασία PR-ANFIS είναι ένα μοντέλο Sugeno πρώτης τάξης με τρεις εισόδους $y(k)$, $y(k-1)$, $u(k)$ και μία έξοδο. Χρησιμοποιούνται τρεις συναρτήσεις συμμετοχής τύπου Π-Σιγμοειδής μικρή, μεσαία και μεγάλη, δημιουργώντας έτσι 27 (3^3) κανόνες της μορφής: EAN $y(k-1)$ είναι μικρή, $y(k)$ είναι μικρή και $u(k)$ είναι μικρή TOTE η $f_2 = p_2 y(k-1) + q_2 y(k) + s_2 u(k) + r_2$. Επιλέγονται 1000 επαναλήψεις και το μέγεθος βήματος να είναι 0.001.

Ο λόγος για τη χρήση ενός μοντέλου Sugeno πρώτης τάξης είναι κυρίως λόγω της παραμέτρου r_i , που χρησιμοποιείται για την προσέγγιση καλύτερων πραγματικών τιμών. Οι παράμετροι του πρώτου τμήματος (premise) του κανόνα βελτιστοποιούνται χρησιμοποιώντας τη μέθοδο της μείωσης του σφάλματος της οπισθόδρομης μετάδοσης και οι παράμετροι του δεύτερου τμήματος (επακόλουθο) βελτιστοποιούνται χρησιμοποιώντας τη μέθοδο του ελάχιστου τετραγωνικού σφάλματος (Least Square Error method) (George Atsalakis, 2016). Ο πίνακας που ακολουθεί εξηγεί λεπτομερώς τις σταθερές παραμέτρους του ελεγκτή και της διαδικασίας:

Πίνακας 4.2.1: Χαρακτηριστικά υποσυστημάτων CON-ANFIS και PR-ANFIS

Χαρακτηριστικά	CON-ANFIS	PR-ANFIS
Τύπος μηχανισμού ασαφούς συμπερασμού	Sugeno	Sugeno
Αριθμός εισόδων	2	3
Ονομασία 1ης εισόδου	$y(k)$	$y(k)$
Ονομασία 2ης εισόδου	$y(k+1)$	$y(k-1)$
Ονομασία 3ης εισόδου	-	$u(k)$
Αριθμός εξόδων	1	1
Ονομασία εξόδου	$u(k)$	$y(k+1)$
And method	Product	Product
Or method	Max	Max
Imp. method	Product	Product
Agg. method	Max	Max
Defuzz. method	Wtaver	Wtaver

Οι τύποι των συναρτήσεων, ο αριθμός αυτών στην είσοδο των υποσυστημάτων καθώς και οι επαναλήψεις, δεν επιλέχθηκαν τυχαία. Υπήρξε μια λογική σειρά δοκιμών του μοντέλου για τις συγκεκριμένες παραμέτρους όπως φαίνεται στο παρακάτω σχήμα:



Διάγραμμα 4.2.1 Σκεπτικό για την εύρεση βέλτιστων παραμέτρων μοντέλου

Αρχικά, το μοντέλο έτρεξε για όλους τους συνδυασμούς τύπων συνάρτησης με σταθερές τις υπόλοιπες παραμέτρους. Αξιολογώντας τα αποτελέσματα με κυρίαρχο δείκτη την τάση (success trend) και δευτερεύον το σφάλμα RMSE μεταξύ της πρόβλεψης και των κανονικών δεδομένων, επιλέχθηκε ο καλύτερος συνδυασμός των συναρτήσεων.

Πίνακας 4.2.2: Δοκιμές για συνδυασμούς τύπων συναρτήσεων και αποτελέσματα συστήματος


CON-ANFIS	PR-ANFIS	Success Trend (%)	RMSE
<i>gaussmf</i>	<i>gaussmf</i>	86,67	0.21133
<i>gaussmf</i>	<i>gbellmf</i>	66,67	0.28002
<i>gaussmf</i>	<i>trimf</i>	86,67	0.215
<i>gaussmf</i>	<i>gauss2mf</i>	86,67	0.22956
<i>gaussmf</i>	<i>psigmf</i>	90,00	0.21272
<i>gbellmf</i>	<i>gaussmf</i>	70,00	0.23698
<i>gbellmf</i>	<i>gbellmf</i>	80,00	0.22205
<i>gbellmf</i>	<i>trimf</i>	83,33	0.21239
<i>gbellmf</i>	<i>gauss2mf</i>	83,33	0.24042
<i>gbellmf</i>	<i>psigmf</i>	86,67	0.21791
<i>trimf</i>	<i>gaussmf</i>	76,67	0.24924
<i>trimf</i>	<i>gbellmf</i>	73,33	0.29898
<i>trimf</i>	<i>trimf</i>	76,67	0.23599
<i>trimf</i>	<i>gauss2mf</i>	80,00	0.25198
<i>trimf</i>	<i>psigmf</i>	76,67	0.24606
<i>gauss2mf</i>	<i>gaussmf</i>	86,67	0.21141
<i>gauss2mf</i>	<i>gbellmf</i>	66,67	0.27817
<i>gauss2mf</i>	<i>trimf</i>	86,67	0.20602
<i>gauss2mf</i>	<i>gauss2mf</i>	86,67	0.23028
<i>gauss2mf</i>	<i>psigmf</i>	90,00	0.2129
<i>psigmf</i>	<i>gaussmf</i>	70,00	0.24625
<i>psigmf</i>	<i>gbellmf</i>	76,67	0.2387
<i>psigmf</i>	<i>trimf</i>	83,33	0.21174
<i>psigmf</i>	<i>gauss2mf</i>	83,33	0.24806
<i>psigmf</i>	<i>psigmf</i>	76,67	0.23131

Ακολούθησε η εύρεση του βέλτιστου αριθμού των συναρτήσεων στην είσοδο του κάθε υποσυστήματος, ελέγχοντας όλους τους πιθανούς συνδυασμούς κι έχοντας ως σταθερά τον συνδυασμό των τύπων συνάρτησης και τον αριθμό επαναλήψεων. Βρίσκοντας τον κατάλληλο συνδυασμό για τον αριθμό των συναρτήσεων, έγιναν προσπάθειες για την εύρεση του καλύτερου συνδυασμού των επαναλήψεων.


Πίνακας 4.2.3: Δοκιμές για συνδυασμούς αριθμών συναρτήσεων στο σύστημα και αποτελέσματα του.

<i>CON-ANFIS</i>	<i>PR-ANFIS</i>	<i>Success Trend (%)</i>	<i>RMSE</i>
2	2	88	0.22482
2	3	84	0.21223
2	4	83	0.24731
2	5	80	0.25971
3	2	91	0.20826
3	3	92	0.18676
3	4	88	0.19441
3	5	87	0.19287
4	2	91	0.20375
4	3	94	0.17719
4	4	91	0.19264
4	5	91	0.19739
5	2	91	0.20186
5	3	93	0.17469
5	4	91	0.19476
5	5	91	0.19898


Το σκεπτικό βασίστηκε στην αρχική υλοποίηση του μοντέλου στις 10000 επαναλήψεις με τις βέλτιστες παραμέτρους του σταθερές. Με βάση το διάγραμμα σφάλματος των υποσυστημάτων (διάγραμμα 4.2.2 και 4.2.4), το μοντέλο προσαρμόστηκε στο πλέον κατάλληλο αριθμό επαναλήψεων για κάθε υποσύστημά του.




Διάγραμμα 4.2.2 Σφάλμα *RMSE* ελεγκτή *CON-ANFIS* στην διάρκεια 10000 επαναλήψεων (φάση εκπαίδευσης)



Διάγραμμα 4.2.3 Μέγεθος βήματος ελεγκτή CON-ANFIS στην διάρκεια 10000 επαναλήψεων (φάση εκπαίδευσης)



Διάγραμμα 4.2.4 Σφάλμα RMSE της διαδικασίας PR-ANFIS στην διάρκεια 10000 επαναλήψεων (φάση εκπαίδευσης)



Διάγραμμα 4.2.5 Μέγεθος βήματος της διαδικασίας PR-ANFIS στην διάρκεια 10000 επαναλήψεων (φάση εκπαίδευσης)

Στο σημείο που γίνεται οριζόντια η καμπύλη των σφαλμάτων του CON-ANFIS και του PR-ANFIS στην φάση εκπαίδευσης (διαγράμματα 4.2.2 και 4.2.4 αντίστοιχα), φαίνεται και ο αριθμός των επαναλήψεων που θα είναι βέλτιστος. Επομένως σύμφωνα με τα διαγράμματα, ο βέλτιστος αριθμός επαναλήψεων για το CON-ANFIS και το PR-ANFIS, είναι 1000 και 3250 αντίστοιχα. Η τάση (success trend %) για αυτές τις επαναλήψεις είναι 91%. Περισσότερες επαναλήψεις από το σημείο εκείνο, ουσιαστικά προσθέτουν υπολογιστικό φόρτο στο μοντέλο, χωρίς κάποια ουσιώδη μείωση στο σφάλμα εξόδου του κάθε υποσυστήματος. Παρατηρήθηκε όμως, πως η τάση για 1000 επαναλήψεις στο PR-ANFIS ανεβαίνει στο 94%. Για αυτό τον λόγο, έγιναν ενδεικτικά κάποιες επιπλέον δοκιμές γύρω από τις τιμές των επαναλήψεων 1000 και 3250 ώστε να εξακριβωθούν οι τελικές βέλτιστοι παράμετροι με κύριο γνώμονα τον δείκτη της τάσης.

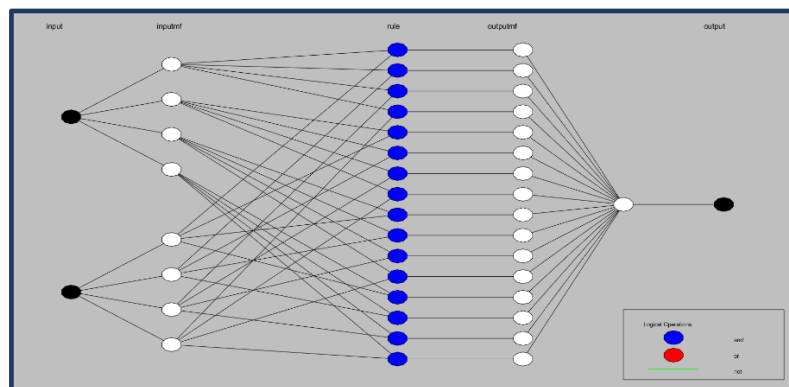
Πίνακας 4.2.4: Δοκιμές για την εύρεση βέλτιστου αριθμού επαναλήψεων στο σύστημα και αποτελέσματά του

Αριθμός Επαναλήψεων (CON-ANFIS)	Αριθμός Επαναλήψεων (PR-ANFIS)	RMSE	Success trend (%)
1300	4000	0,2024	91
1000	1000	0,1772	94 (BEST)
500	1000	0,1804	90
1000	500	0,2009	88
1000	4000	0,2017	91
1000	3250	0,2017	91

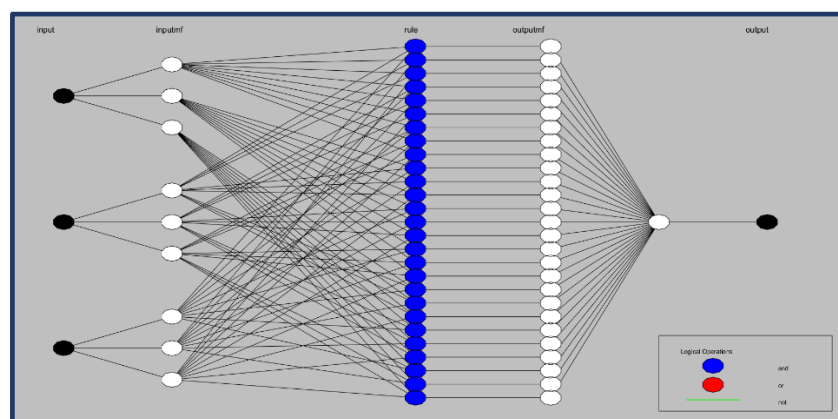
Το μέγεθος του βήματος καθορίστηκε εξ αρχής 0.0001 και διατηρήθηκε το ίδιο σε όλες τις παραπάνω δοκιμές. Στο τέλος έγιναν δοκιμές αλλάζοντας τον αριθμό του βήματος όπως φαίνεται στον παρακάτω πίνακα. Παρατηρήθηκε ότι ελαφρώς καλύτερο αποτέλεσμα δίνει το βήμα 0.001 έναντι του 0.0001, χωρίς όμως να αλλάζει η τάση (94%).

Πίνακας 4.2.5: Βέλτιστες παράμετροι συστήματος

Βέλτιστοι Παράμετροι	CON-ANFIS	PR-ANFIS
Τύπος Συνάρτησης Συμμετοχής	<i>gaussmf</i>	<i>psigmf</i>
Αριθμός Συναρτήσεων Συμμετοχής	4	3
Αριθμός Επαναλήψεων	1000	1000
Βήμα	0,001	0,001



Διάγραμμα 4.2.6 Τελική δομή ελεγκτή CON-ANFIS. Περιλαμβάνει 2 εισόδους με 4 συναρτήσεις συμμετοχής η καθεμία, παράγοντας 16 κανόνες. Η έξοδος είναι μοναδική.




Διάγραμμα 4.2.7 Τελική Δομή διαδικασίας PR-ANFIS. Περιλαμβάνει 3 εισόδους με 3 συναρτήσεις συμμετοχής η καθεμία, παράγοντας 27 κανόνες. Η έξοδος είναι μοναδική.

5. Εφαρμογή της μεθόδου


Παρακάτω ακολουθούν τα αποτελέσματα από την εκτέλεση του αλγορίθμου ο οποίος εκπαιδεύει σε 3092 ιστορικά θερμοκρασιακά δεδομένα δίνοντας πρόβλεψη σε ορίζοντα 100 μηνών μπροστά. Η αξιολόγηση του μοντέλου έγινε συγκρίνοντας τις πραγματικές τιμές θερμοκρασιών με τις αντίστοιχες τιμές πρόβλεψης σε αυτό το διάστημα των 100 μηνών.

Με κίτρινες τελείες εμφανίζεται ένα δείγμα από τα δεδομένα που χρησιμοποιούνται για την φάση εκπαίδευσης του ελεγκτή CON-ANFIS. Φαίνονται οι είσοδοι $y(k)$, $y(k+1)$ η επιθυμητή έξοδος $u(k)$ στα οποία εκπαιδεύεται ο ελεγκτής.



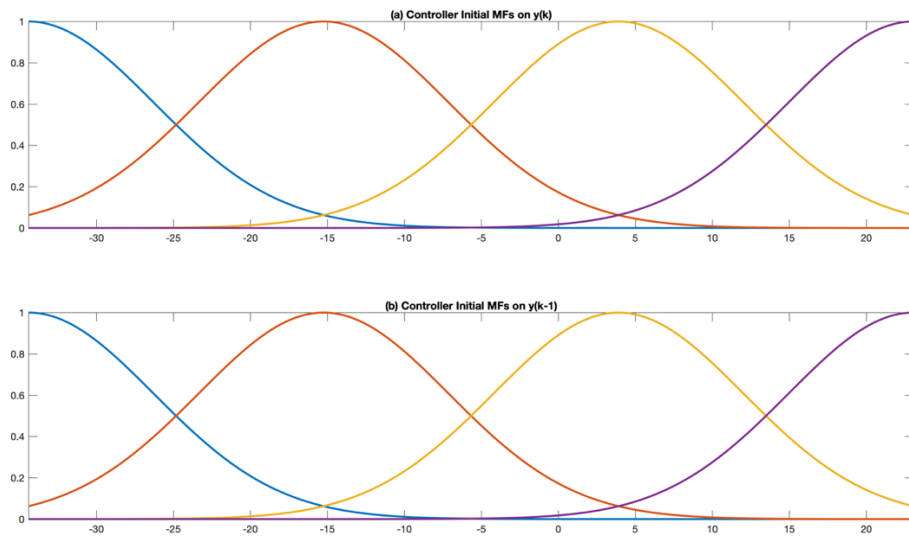
Διάγραμμα 5.1: Δείγμα των τελευταίων 30 τιμών των δεδομένων εκπαίδευσης του ελεγκτή CON-ANFIS

Να σημειωθεί ότι τα δεδομένα που εισάγονται στον ελεγκτή CON-ANFIS πρόκειται για την μεταβολή των θερμοκρασιακών τιμών. Η μία είσοδος προηγείται της άλλης κατά μία χρονική μονάδα.



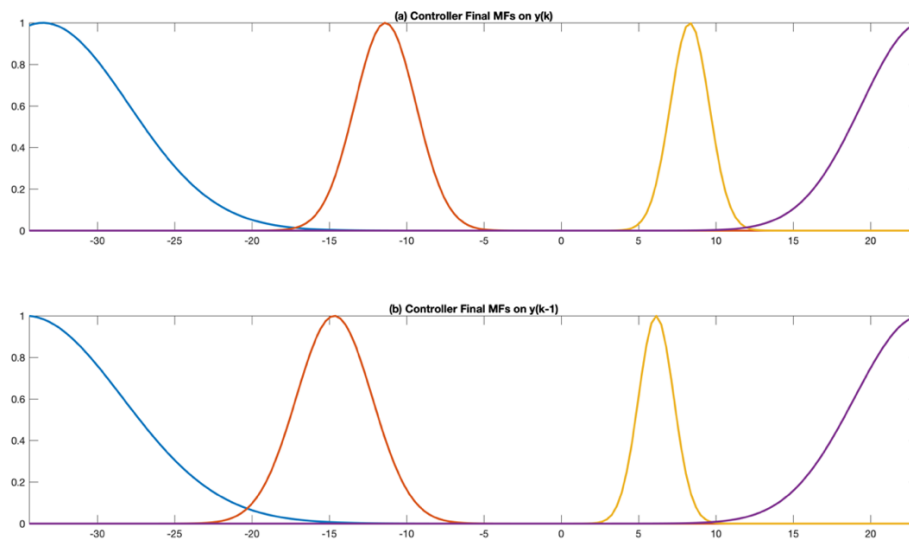
Διάγραμμα 5.2: Δεδομένα εκπαίδευσης του ελεγκτή – μεταβολή των θερμοκρασιακών τιμών

Οι συναρτήσεις συμμετοχής που επιλέγονται για τον ελεγκτή είναι τέσσερις για κάθε μία από τις δύο εισόδους. Στο διάγραμμα 5.3 φαίνονται οι καμπανοειδής καμπύλες τύπου Gauss πριν την εκπαίδευση του συστήματος. Ουσιαστικά είναι οι μεταβλητές με τις οποίες τα αριθμητικά δεδομένα μπορούν να μοντελοποιηθούν σε ένα φαινόμενο.



Διάγραμμα 5.3: Συναρτήσεις συμμετοχής του ελεγκτή CON-ANFIS πριν την εκπαίδευση του


Έπειτα από την εκπαίδευση του ελεγκτή CON-ANFIS, οι συναρτήσεις συμμετοχής προσαρμόζονται με τέτοιον τρόπο, ώστε να καλύπτουν όλο το φάσμα των πιθανών περιπτώσεων, που χρειάζεται για να εκφραστεί σε ασαφείς κανόνες η χρονοσειρά των θερμοκρασιακών τιμών. Πρόκειται για τις μεταβλητές που εκφράζουν τους «νόμους» που διέπουν τα θερμοκρασιακά δεδομένα.



Διάγραμμα 1.4: Συναρτήσεις συμμετοχής του ελεγκτή CON-ANFIS μετά την εκπαίδευση του


Στην εκπαίδευση του ελεγκτή, όπως αναφέρθηκε και σε προηγούμενο κεφάλαιο επιλέχθηκαν 1000 επαναλήψεις (epochs). Πρακτικά η καμπύλη του σφάλματος, οριζοντιώνεται πλήρως

γύρω στις 900 με 1000 επαναλήψεις. Παράλληλα και το μέγεθος του βήματος (step size) με το οποίο εκπαιδεύεται ο CON-ANFIS γίνεται πολύ μικρό μετά τις 900 επαναλήψεις. Πέρα από τις 1000 επαναλήψεις πρακτικά δεν υπάρχει λόγος να συνεχίσει ο αλγόριθμος να δουλεύει αφού το μόνο που προσφέρει στο σύστημα είναι υπολογιστικό φόρτο χωρίς κάποια ιδιαίτερη απόδοση.




Διάγραμμα 5.5: Εξέλιξη σφάλματος RMSE και βήματος του ελεγκτή CON-ANFIS στην φάση εκπαίδευση του (1000 επαναλήψεις)

Παράλληλα στην φάση εκπαίδευσης δημιουργείται η επιφάνεια του ελεγκτή CON-ANFIS, η οποία μας δείχνει μια τρισδιάστατη γραφική απεικόνιση των δύο εισόδων σε σχέση με την έξοδο του συστήματος.




Διάγραμμα 5.6: CON-ANFIS surface

Στο διάγραμμα 5.8. απεικονίζεται η διασπορά των δεδομένων σε σχέση με τις δυο εισόδους του συστήματος.




Διάγραμμα 5.8: Διασπορά των δεδομένων εκπαίδευσης της διαδικασίας PR-ANFIS σε διδιάστατη απεικόνιση.

Έπειτα από την εκπαίδευση, η παραγόμενη έξοδος του ελεγκτή (στην εντός δείγματος αξιολόγηση), συγκρίνεται με τα θερμοκρασιακά δεδομένα ώστε να εξακριβωθεί η ακρίβειά της. Παρακάτω φαίνεται το παραγόμενο σφάλμα, στα τελευταία 30 δείγματα της εντός δείγματος αξιολόγησης.




Διάγραμμα 5.7: Σφάλμα του ελεγκτή για το σύνολο των τελευταίων 30 δειγμάτων της εντός δείγματος αξιολόγησης

Ακολουθεί η εκπαίδευση της διαδικασίας PR-ANFIS. Το μοντέλο της διαδικασίας έχει 3 εισόδους. Η μία είσοδος είναι η παραγόμενη έξοδος του ελεγκτή CON-ANFIS και οι άλλες δύο εισόδους αφορούν τα θερμοκρασιακά δεδομένα την k χρονική στιγμή και την $(k-1)$ χρονική στιγμή.




Διάγραμμα 5.9: Δείγμα των τελευταίων 30 τιμών των δεδομένων εκπαίδευσης της διαδικασίας PR-ANFIS

Στο το διάγραμμα 5.10 απεικονίζεται διδιάστατη γραφική απεικόνιση του εύρους των δεδομένων των δύο εισόδων του μοντέλου της διαδικασίας PR-ANFIS.




Διάγραμμα 5.10: Δυσδιάστατη παρουσίαση των δεδομένων εκπαίδευσης του PR-ANFIS

Στο διάγραμμα 5.11 απεικονίζεται σε τρισδιάστατη μορφή η διασπορά των δεδομένων των τριών εισόδων του συστήματος PR-ANFIS.



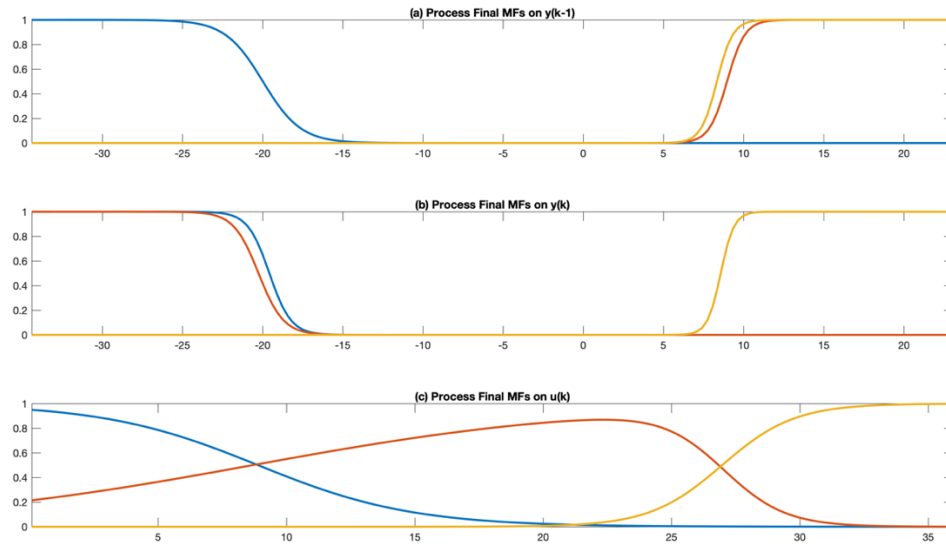
Διάγραμμα 5.11: Τρισδιάστατη παρουσίαση των δεδομένων εκπαίδευσης του PR-ANFIS

Ομοίως με το υποσύστημα CON-ANFIS επιλέγονται συναρτήσεις συμμετοχής για κάθε μία από τις τρεις εισόδους. Για κάθε είσοδο της διαδικασίας, υπάρχουν 3 συναρτήσεις συμμετοχής τύπου καμπανοειδούς σχήματος όπου αντιπροσωπεύουν τις μεταβλητές που αντιπροσωπεύουν τις γλωσσικές μεταβλητές χαμηλή, μεσαία, υψηλή, στην διαδικασία PR-ANFIS. Στο διάγραμμα 5.12 οι καμπανοειδείς συναρτήσεις συμμετοχής φαίνονται στην γενική τους μορφή πριν την εκπαίδευση του υποσυστήματος.




Διάγραμμα 5.12: Συναρτήσεις συμμετοχής της διαδικασίας PR-ANFIS πριν την εκπαίδευση του

Μετά την εκπαίδευση του PR-ANFIS, οι συναρτήσεις συμμετοχής παίρνουν την τελική τους μορφή (διάγραμμα 5.13), αναπαριστώντας έτσι κατάλληλα το σύνολο των δεδομένων στα οποία εκπαιδεύτηκε το υποσύστημα.




Διάγραμμα 5.13: Συναρτήσεις συμμετοχής του ελεγκτή PR-ANFIS μετά την εκπαίδευση του

Η εκπαίδευση του PR-ANFIS έγινε μέχρι και 1000 επαναλήψεις με ένα μέγεθος βήματος 0,001. Μετά τις 1000 επαναλήψεις δεν υπάρχουν έντονες αλλαγές στην μείωση του σφάλματος οπότε και σταματάει η εκπαίδευση του PR-ANFIS. Το μέγεθος βήματος ακολουθεί μια σχετικά οριζόντια πορεία μετά τις 800 επαναλήψεις, μην αλλάζοντας έτσι ιδιαίτερα, τα αποτελέσματα της πρόβλεψης.




Διάγραμμα 5.14: Εξέλιξη σφάλματος RMSE και βήματος του ελεγκτή PR-ANFIS στην φάση εκπαίδευση του (1000 επαναλήψεις)

Στην εκπαίδευση του υποσυστήματος παράγεται η επιφάνεια του PR-ANFIS. Η επιφάνεια μας δείχνει την τρισδιάστατη συσχέτιση των δύο εισόδων με την έξοδο.




Διάγραμμα 5.15: PR-ANFIS surface

Η έξοδος το PR-ANFIS είναι η εκτός δείγματος πρόβλεψη του μοντέλου, η οποία θα πρέπει να συγκριθεί με τις πραγματικές τιμές, προκειμένου να γίνει η αξιολόγηση του προτεινόμενου μοντέλου πρόβλεψης. Στο διάγραμμα 5.16 φαίνεται η πραγματική μεταβολή της θερμοκρασίας σε σχέση με την έξοδο της διαδικασίας PR-ANFIS στην εντός δείγματος αξιολόγηση για 30 δείγματα.




Διάγραμμα 5.16: Πραγματική τιμή του $y(k + 1)$ και έξοδος του PR-ANFIS για 30 δείγματα της εντός δείγματος αξιολόγησης

Παράλληλα υπολογίζονται τα σφάλματα που έκανε η διαδικασία PR-ANFIS σε σχέση με την πραγματική μεταβολή της θερμοκρασίας, όπως φαίνεται στο διάγραμμα 5.17 για ένα δείγμα 30 τιμών.




Διάγραμμα 5.17: Διάγραμμα σφάλματος πρόβλεψης του PR-ANFIS

Αμέσως μετά πραγματοποιείται η φάση της αξιολόγησης εκτός δείγματος. Τα δεδομένα με τα οποία αξιολογούνται τα υποσυστήματα αφορούν τις μεταβολές των θερμοκρασιακών τιμών.




Διάγραμμα 5.18: Δεδομένα εισόδου του ελεγκτή CON-ANFIS κατά την φάση αξιολόγησης

Στο διάγραμμα 5.18 φαίνονται τα δεδομένα (μεταβολές τις μηνιαίας θερμοκρασίας), τα οποία εισάγονται στις δύο εισόδους του ελεγκτή CON-ANFIS στην φάση αξιολόγησης. Ομοίως, στο διάγραμμα 5.19 φαίνονται τα δεδομένα (μεταβολές τις μηνιαίας θερμοκρασίας) που εισάγονται στις τρεις εισόδους της διαδικασίας PR-ANFIS κατά την φάση αξιολόγησης.




Διάγραμμα 5.19: Δεδομένα εισόδου της διαδικασίας PR-ANFIS κατά την φάση αξιολόγησης




Διάγραμμα 5.20: Δράση ελέγχου που παράγει ο ελεγκτής του συστήματος

Στο διάγραμμα 5.20 φαίνεται η δράση ελέγχου που παράγει ο ελεγκτής CON-ANFIS κατά την φάση της αξιολόγησης για 100 μήνες. Η δράση ελέγχου $u(k)$ είναι μία από τις εισόδους στην διαδικασία PR-ANFIS. Σε συνδυασμό με τις άλλες δύο εισόδους του υποσυστήματος, $y(k-1)$ και $y(k)$, παράγεται η πρόβλεψη από την διαδικασία PR-ANFIS.



Διάγραμμα 5.21: Σφάλμα της πρόβλεψης του προτεινόμενου μοντέλου

Το διάγραμμα 5.21 απεικονίζει το σφάλμα μεταξύ των πραγματικών και προβλεπόμενων τιμών της θερμοκρασίας για 100 μήνες.



Διάγραμμα 5.22: Γραφική απεικόνιση της σύγκρισης των μεταβολών των τιμών πρόβλεψης του συστήματος PATSOS με τις μεταβολές των πραγματικών τιμών.

Το διάγραμμα 5.22 απεικονίζει τα αποτελέσματα του συστήματος πρόβλεψης της τάσης της θερμοκρασίας κατά τον επόμενο μήνα του μοντέλου PATSOS.


Η κόκκινη γραμμή απεικονίζει την τιμή πρόβλεψης της τάσης του προτεινόμενου μοντέλου. Με την γκρι γραμμή απεικονίζεται η τάση των πραγματικών τιμών θερμοκρασίας.

Η γραφική παράσταση δείχνει ότι η προβλεπόμενη μεταβολή των τιμών της θερμοκρασίας ακολουθεί την τάση μεταβολής των πραγματικών τιμών με αρκετά μεγάλη ακρίβεια. Σύμφωνα με τον πίνακα 4.2 η ακρίβεια του ποσοστού σωστής πρόβλεψης της τάσης της θερμοκρασία ανέρχεται στο 94% των περιπτώσεων, πράγμα που επιβεβαιώνει και η γραφική απεικόνιση της μεταβολής των τιμών του σχήματος 5.22.

6. Σύγκρισή της μεθόδου με άλλα μοντέλα.


Στο κεφάλαιο 6ο εφαρμόζονται 10 μοντέλα, τα οποία αξιολογούνται βάση του RMSE και συγκρίνονται με το θερμοκρασιακό μοντέλο πρόβλεψης PATSOS που αναπτύχθηκε στην παρούσα διπλωματική. Η εκπαίδευσή τους έγινε στα πρώτα 3092 δεδομένα και έπειτα αξιολογήθηκε η πρόβλεψη που έδωσαν, με τα υπόλοιπα 100 πραγματικά θερμοκρασιακά δεδομένα.

Αυτοπαλινδρομικό μοντέλο - AutoRegressive Model (AR): Πρόκειται για μοντέλο γραμμικής παλινδρόμησης, το οποίο χρησιμοποιείται συχνά για προβλέψεις όταν τα δεδομένα είναι μια χρονική σειρά (time series). Θεωρεί ως εξαρτημένη μεταβλητή την τυχαία μεταβλητή της χρονοσειράς σε μια χρονική στιγμή t , x_t και ως ανεξάρτητες μεταβλητές την τυχαία μεταβλητή σε προηγούμενους χρόνους $x_{t-1}, x_{t-2}, \dots, x_{t-p}$. Ο αριθμός των υστερήσεων που συμπεριλαμβάνουμε στο μοντέλο λέγεται τάξη του αυτοπαλινδρομικού μοντέλου. Ένα αυτοπαλινδρομικό μοντέλο τάξης p ορίζεται ως $x_t = \varphi_0 + \varphi_1 x_{t-1} + \dots + \varphi_p x_{t-p} + z_t$, όπου $\varphi_0, \varphi_1, \dots, \varphi_p$ και z_t τυχαία μεταβλητή που συνοψίζει τις εξωγενείς επιδράσεις την χρονική στιγμή t (στοχαστικό μέρος μοντέλου) (Shumway Robert, Stoffer David 2010). Το μοντέλο έδωσε σφάλμα RMSE 2,1794. Στο διάγραμμα 6.1 φαίνεται η πρόβλεψη του μοντέλου μοντέλου AR (κόκκινη γραμμή), κατά την φάση και 100 μηνιαίες θερμοκρασιακές τιμές (γαλάζια γραμμή).




Διάγραμμα 6.1 Πρόβλεψη AR και 100 μηνιαίες θερμοκρασιακές τιμές

Αυτοπαλινδρομικό μοντέλο με επιπλέον μεταβλητή εισόδου - Autoregressive with Extra Input Model (ARX): Πρόκειται για παραλλαγή του Αυτοπαλινδρομικού μοντέλου, μόνο που στη συγκεκριμένη περίπτωση υπάρχει και μια επιπλέον εξωγενής μεταβλητή, η οποία εισάγεται στο αυτοπαλινδρομικό μοντέλο (Diversi et al. 2010). Το μοντέλο έδωσε σφάλμα RMSE 2,1794. Στο διάγραμμα 6.2 φαίνεται η πρόβλεψη του μοντέλου ARX (κόκκινη γραμμή), κατά την φάση αξιολόγησης και 100 μηνιαίες θερμοκρασιακές τιμές (γαλάζια γραμμή).



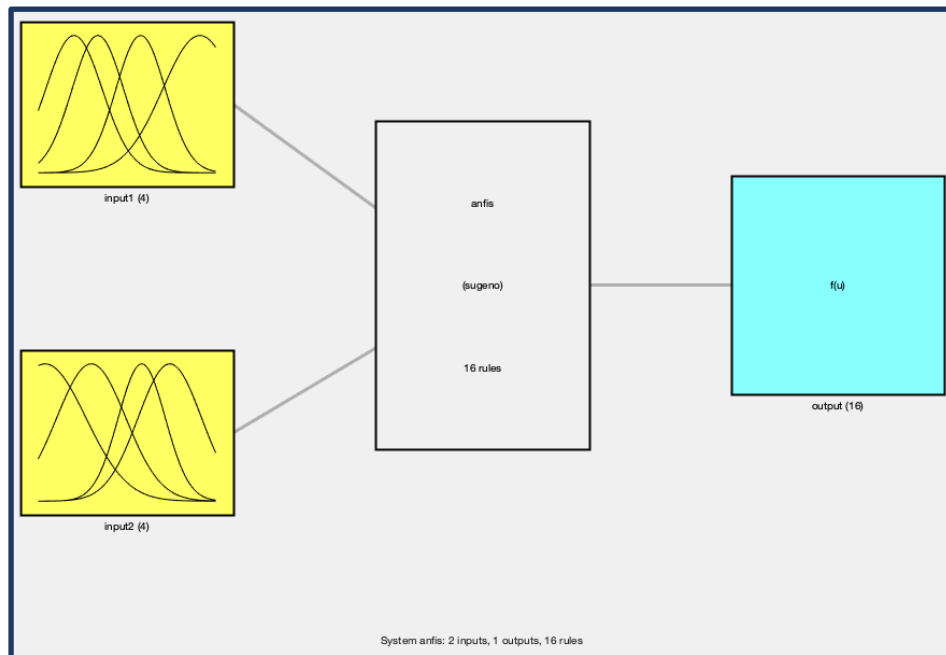
Διάγραμμα 2.2 Η πρόβλεψη του μοντέλου ARX (κόκκινη γραμμή) και 100 μηνιαίες θερμοκρασιακές τιμές

Αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου – Autoregressive moving average model (ARMA): Πρόκειται για τον συνδυασμό δύο μοντέλων, το ένα είναι το αυτοπαλινδρομικό (AR) και το άλλο του κινούμενου μέσου (MA). Το MA υποθέτει πως οι εξωγενείς παράγοντες σε προηγούμενους χρόνους μπορούν να επηρεάσουν την μεταβλητή της χρονοσειράς τη χρονική στιγμή t . Το ARMA ορίζεται ως: $x_t = \varphi_0 + \varphi_1 x_{t-1} + \dots + \varphi_p x_{t-p} + z_t - \theta_1 z_{t-1} - \theta_2 z_{t-2} \dots - \theta_q z_{t-q}$. Το δεύτερο μέρος του ARMA, δηλαδή η διεργασία του κινητού μέσου όρου τάξεως q είναι ένας γραμμικός συνδυασμός του παρόντος όρου λευκού θορύβου και των q πιο πρόσφατων όρων λευκού θορύβου (Whittle, 1951). Το μοντέλο έδωσε σφάλμα RMSE 2,1877. Στο διάγραμμα 6.2 φαίνεται η πρόβλεψη του μοντέλου ARX (κόκκινη γραμμή), κατά την φάση αξιολόγησης και 100 μηνιαίες θερμοκρασιακές τιμές (πράσινη γραμμή).

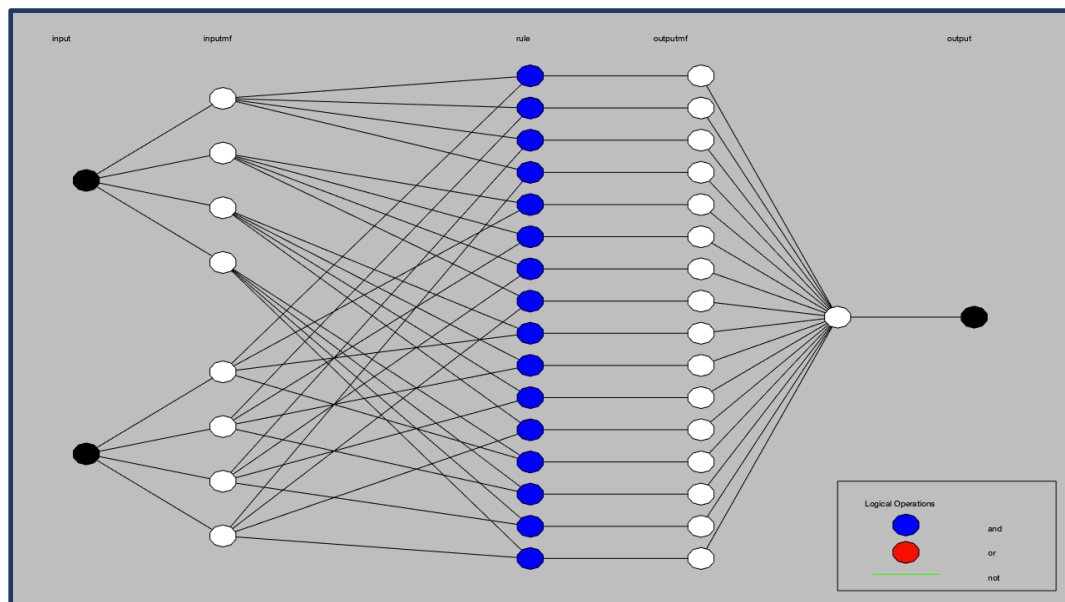


Διάγραμμα 6.3 Η πρόβλεψη του μοντέλου ARMA (πράσινη γραμμή) και 100 μηνιαίες θερμοκρασιακές τιμές

ANFIS μοντέλο με δύο εισόδους και μία έξοδο: Το μοντέλο είναι τύπου Sugeno πρώτης τάξης με δύο εισόδους και μία έξοδο. Σε κάθε είσοδο επιλέγονται 4 συναρτήσεις συμμετοχής τύπου Gauss, παράγοντας έτσι 16 κανόνες. Οι επαναλήψεις που έγιναν ήταν 800. Το μοντέλο έδωσε σφάλμα RMSE 0,6461. Στα διαγράμματα 6.4.1 και 6.4.2 φαίνεται η επιλεγμένη δομή του ANFIS. Στις δύο εισόδους φαίνονται οι συναρτήσεις συμμετοχής μετά την εκπαίδευση του μοντέλου και στο δίκτυο οι 16 κανόνες που παράγει το ANFIS.




Διάγραμμα 6.4.1 Δύο Είσοδοι και μία έξοδος στο ANFIS. Στις εισόδους φαίνονται οι συναρτήσεις συμμετοχής μετά την εκπαίδευση του μοντέλου



Διάγραμμα 6.4.2 Δομή του ANFIS (2 είσοδοι – 4 συναρτήσεις συμμετοχής ανά είσοδο – 16 παραγόμενοι κανόνες – 1 έξοδος)


Στο διάγραμμα 6.5 φαίνεται πως η καμπύλη του σφάλματος RMSE σφάλμα οριζοντιώνεται στις 800 επαναλήψεις. Παράλληλα το μέγεθος βήματος παραμένει στο ίδιο επίπεδο μετά τις

300 επαναλήψεις. Ουσιαστικά μετά τις 800 επαναλήψεις δεν αυξάνει πολύ η απόδοση του μοντέλου.




Διάγραμμα 6.5 Σφάλμα RMSE και μέγεθος βήματος στην διάρκεια των επαναλήψεων κατά την εκπαίδευση.

Στο διάγραμμα 6.6 η ομαλή επιφάνεια είναι μια τρισδιάστατη απεικόνιση των εισόδων και της εξόδου του ANFIS.




Διάγραμμα 6.6 Η επιφάνεια του ANFIS είναι ομαλή δηλώνοντας ότι παράγει καλή πρόβλεψη

Στο διάγραμμα 6.7 απεικονίζεται δισδιάστατη γραφική απεικόνιση του εύρους των δεδομένων των δύο εισόδων του μοντέλου του ANFIS. Τα δεδομένα είναι διάσπαρτα στην επιφάνεια.



Διάγραμμα 6.7 Τα δεδομένα εκπαίδευσης του ANFIS είναι διάσπαρτα στην επιφάνεια δείχνοντας ότι θα παραχθεί καλή πρόβλεψη


Η ομοιόμορφη κατανομή των δεδομένων εκπαίδευσης (διάγραμμα 6.7) σε συνδυασμό με την ομαλή επιφάνεια του ANFIS (διάγραμμα 6.6) κατά την φάση εκπαίδευσης, σημαίνει πως το μοντέλο αποκτά καλή προβλεπτική δυνατότητα. Στο διάγραμμα 6.8 φαίνεται η πρόβλεψη που παράγει το ANFIS (κόκκινη γραμμή), κατά την φάση αξιολόγησης και 100 μηνιαίες θερμοκρασιακές τιμές (μπλε γραμμή).



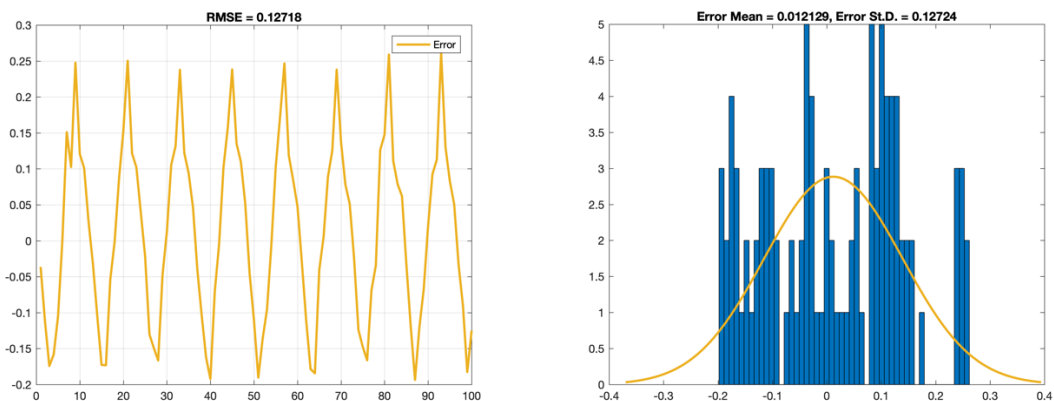
Διάγραμμα 6.8 Πρόβλεψη του ANFIS (κόκκινη γραμμή) και 100 μηνιαίες θερμοκρασιακές τιμές (μπλε γραμμή)

Εξελικτικό ANFIS (με βελτιστοποίηση από Γενετικό Αλγόριθμο ή από Αλγόριθμο Βελτιστοποίησης Σωματιδίων) - Evolutionary ANFIS (with Genetic Algorithm Optimisation - GA or Particle Swarm Optimisation - PSO) : Η εκπαίδευση και ο καθορισμός της δομής του ANFIS μπορεί να θεωρηθεί από μόνο του ως ένα πρόβλημα βελτιστοποίησης. Ο εξελικτικός αλγόριθμος ANFIS αρχικά δημιουργεί ένα μοντέλο ANFIS και έπειτα το εκπαιδεύει με γενετικό αλγόριθμο ή με αλγόριθμο βελτιστοποίησης σωματιδίων (Yarpiz, 2020). Το μοντέλο έδωσε σφάλμα RMSE 0,1272 με βελτιστοποίηση από γενετικό αλγόριθμο (GA) και 0,1453 με αλγόριθμο βελτιστοποίησης σωματιδίων (PSO).


Στο διάγραμμα 6.9.1 φαίνεται η πρόβλεψη του εvoANFIS-GA (κίτρινη γραμμή), κατά την φάση αξιολόγησης και 100 μηνιαίες θερμοκρασιακές τιμές (γκρι γραμμή). Επιπλέον το διάγραμμα 6.9.2 δείχνει το παραγόμενο σφάλμα RMSE από την σύγκριση των δεδομένων με την πρόβλεψη στην φάση αξιολόγησης (κίτρινη γραμμή), καθώς και την κατανομή των σφαλμάτων αυτών (μπλε μπάρες).





Διάγραμμα 6.9.1 Πρόβλεψη του εvoANFIS-GA (κίτρινη γραμμή) και 100 μηνιαίες θερμοκρασιακές τιμές (γκρι γραμμή)



Διάγραμμα 6.9.2 Σφάλμα RMSE στην φάση αξιολόγησης του μοντέλου εvoANFIS-GA και κατανομή σφαλμάτων



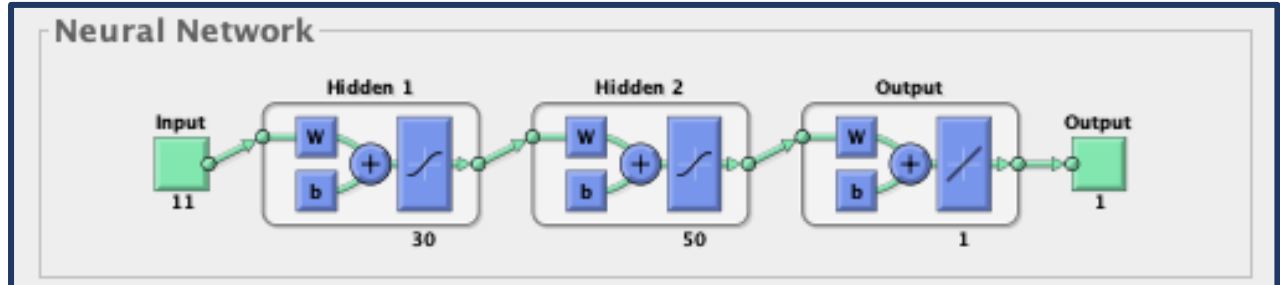
Διάγραμμα 6.10.1 Πρόβλεψη του εvoANFIS-PSO (πορτοκαλί γραμμή) και 100 πραγματικές θερμοκρασιακές τιμές (γκρι γραμμή)



Διάγραμμα 6.10.2 Σφάλμα RMSE στην φάση αξιολόγησης του μοντέλου εvoANFIS-PSO και κατανομή σφαλμάτων


Στο διάγραμμα 6.10.1 φαίνεται η πρόβλεψη του εvoANFIS-PSO (πορτοκαλί γραμμή), κατά την φάση αξιολόγησης και 100 μηνιαίες θερμοκρασιακές τιμές (γκρι γραμμή). Επιπλέον το διάγραμμα 6.10.2 δείχνει το παραγόμενο σφάλμα RMSE από την σύγκριση των δεδομένων με την πρόβλεψη στην φάση αξιολόγησης (πορτοκαλί γραμμή), καθώς και την κατανομή των σφαλμάτων αυτών (μπλε μπάρες).

Νευρωνικό Δίκτυο Εμπρός Τροφοδότησης – FeedForward Neural Network: Απλό νευρωνικό δίκτυο με 11 εισόδους, 1 έξοδο, δύο κρυφά στρώματα, το 1^ο στρώμα αποτελούμενο από 30 νευρώνες και το 2^ο από 50. Οι παράμετροι του μοντέλου καθορίστηκαν μετά από πολλές δοκιμές καταλήγοντας στην βέλτιστη δομή νευρωνικού δικτύου. Το μοντέλο έδωσε σφάλμα RMSE 0,3192.




Διάγραμμα 6.11.1 Δομή FeedForward NN

Στο διάγραμμα 6.11.2 φαίνεται η πρόβλεψη του FeedForward NN (πράσινη γραμμή) και 100 μηνιαίες θερμοκρασιακές τιμές (γκρι γραμμή), κατά την φάση αξιολόγησης. Επιπλέον το διάγραμμα 6.11.3 δείχνει το παραγόμενο σφάλμα RMSE από την σύγκριση των δεδομένων με την πρόβλεψη, στην φάση αξιολόγησης (πράσινη γραμμή), καθώς και την κατανομή των σφαλμάτων αυτών (μπλε μπάρες).



Διάγραμμα 6.11.2 Πρόβλεψη FeedForwardNN και πραγματικές τιμές




Διάγραμμα 6.11.3 Σφάλμα RMSE στην φάση αξιολόγησης του μοντέλου FeedForwardNN και κατανομή σφαλμάτων


Deep learning Bidirectional-Long Short Memory (bi-LSTM) Network (Nejatian, 2020):

Πρόκειται για ένα είδος αναδρομικού νευρωνικού δικτύου με δικιά του μνήμη, όπου εκπαιδεύεται δύο φορές στα δεδομένα εισόδου. Την πρώτη φορά εκπαιδεύεται με τα δεδομένα «ως-έχουν», ενώ την δεύτερη φορά με αντιστροφή της σειράς των ίδιων δεδομένων. Αυτή η μέθοδος βοηθάει στην καλύτερη και συντομότερη εκπαίδευση του συστήματος παράγοντας πρόβλεψη (Siarni-Namini et al. 2019). Το μοντέλο εκτέλεσε 625 επαναλήψεις και έδωσε σφάλμα RMSE 0,3192.


Στο διάγραμμα 6.12.1 φαίνεται η πρόβλεψη του bi-LSTM Network (μπλε γραμμή), κατά την φάση αξιολόγησης και 100 μηνιαίες θερμοκρασιακές τιμές (γκρι γραμμή). Επιπλέον το διάγραμμα 6.12.2 δείχνει το παραγόμενο σφάλμα RMSE από την σύγκριση των δεδομένων με την πρόβλεψη στην φάση αξιολόγησης (μπλε γραμμή), καθώς και την κατανομή των σφαλμάτων αυτών (μπλε μπάρες).



Διάγραμμα 6.12.1 Πρόβλεψη bi-LSTM Network και πραγματικές τιμές




Διάγραμμα 6.12.2 Σφάλμα RMSE στην φάση αξιολόγησης του μοντέλου bi-LSTM Network και κατανομή σφαλμάτων



Διάγραμμα 6.12.3 Σφάλμα RMSE στην στη διάρκεια των 625 επαναλήψεων

Το διάγραμμα 6.12.3 δείχνει το RMSE σφάλμα κατά την εκπαίδευση του μοντέλου στην διάρκεια των 625 επαναλήψεων. Η καμπύλη του σφάλματος (μπλε γραμμή) οριζοντιώνεται μετά την 100^η επανάληψη. Ουσιαστικά η απόδοση του μοντέλου δεν βελτιώνεται πέρα από 100 επαναλήψεις.


Μηχανή Διανυσμάτων Υποστήριξης Ελαχίστων Τετραγώνων – Least Squares Support Vector Machine model (LSSVM): το LSSVM είναι ένα μοντέλο που ανήκει στην κατηγορία των κλασικών μηχανών διανυσμάτων υποστήριξης (SVM). Τα μοντέλα SVM στηρίζονται στην μάθηση με επίβλεψη, αναλύουν και αναγνωρίζουν μοτίβα, δίνοντας λύσεις σε προβλήματα κατηγοριοποίησης και παλινδρόμησης (Suykens & Vandewalle, 1999). Στο συγκεκριμένο μοντέλο η πρόβλεψη βρίσκεται επιλύοντας γραμμικά συστήματα Karush-Kuhn-Tucker (KKT) που δημιουργούνται κατά την εκπαίδευση στα δεδομένα εισόδου. Το μοντέλο έδωσε σφάλμα RMSE 1,031.



Διάγραμμα 6.13 Πρόβλεψη LSSVM (μπλε γραμμή) και 100 μηνιαίες θερμοκρασιακές τιμές (γκρι γραμμή)

Στο διάγραμμα 6.13 φαίνεται η παραγόμενη πρόβλεψη του LSSVM (μπλε γραμμή), κατά την φάση αξιολόγησης και 100 μηνιαίες θερμοκρασιακές τιμές (γκρι γραμμή).

Νευρωνικό Δίκτυο με Συνάρτηση Ενεργοποίησης Ακτινικού τύπου - Radial Basis Function Neural Network RBFNN: Πρόκειται για νευρωνικό δίκτυο όπου η συνάρτηση ενεργοποίησης είναι ακτινικού τύπου (RBF). Αποτελείται από 2 στρώματα το ένα εκ των οποίων είναι κρυφό αυτό-οργανούμενο. Το κρυφό στρώμα εκπαιδεύεται πιο αργά και ξεχωριστά καθώς αποτελεί το βασικό στρώμα αναπαράστασης της RBF. Το στρώμα εξόδου εκπαιδεύεται γρήγορα και πολύ ευκολότερα. (Sadiq Alishba et al., 2018). Το μοντέλο έδωσε σφάλμα RMSE 16,509.



Διάγραμμα 6.14 Πρόβλεψη RBFNN και πραγματικές τιμές

Στο διάγραμμα 6.14 φαίνεται η παραγόμενη πρόβλεψη του RBFNN (μωβ γραμμή), κατά την φάση αξιολόγησης και 100 μηνιαίες θερμοκρασιακές τιμές (γκρι γραμμή).

Πίνακας 6.1: Σύγκριση προτεινόμενου μοντέλου με άλλα μοντέλα πρόβλεψης

Μοντέλα Πρόβλεψης	Σφάλμα RMSE
Προτεινόμενο Μοντέλο PATSOS	0,1772
AR	2,1794
ARX	2,1794
ARMA	2,1877
ANFIS	0,6461
Evolutionary ANFIS GA	0,1272
Evolutionary ANFIS PSO	0,1453
FeedForward NN	0,3192
bi-LSTM Network	0,3192
LSSVM	1,031
RBFNN	16,509

Συνοψίζοντας τα αποτελέσματα στον πίνακα 6.1 φαίνεται πως το προτεινόμενο μοντέλο είναι αρκετά ακριβές έχοντας σφάλμα RMSE πολύ κάτω της μονάδας. Τα μοναδικό μοντέλο που είχε μικρότερο RMSE ήταν το εξελικτικό ANFIS με βελτιστοποίηση. Παρόλα αυτά η τάξη μεγέθους του σφάλματος του προτεινόμενου μοντέλου, είναι ίδια και πολύ μικρή.

7. Συμπεράσματα

Τα τελευταία χρόνια ολοένα και περισσότεροι ερευνητές χρησιμοποιούν μοντέλα τεχνητών νευρωνικών δικτύων και ασαφών συστημάτων με στόχο την πρόβλεψη διαφόρων φαινομένων και καταστάσεων. Η δημιουργία νεύρο-ασαφών συστημάτων, δηλαδή ο συνδυασμός των τεχνητών νευρωνικών δικτύων με την ασαφή συλλογιστική μπορεί σε ελάχιστο χρόνο και με μικρό υπολογιστικό κόστος να δώσει ικανοποιητικά αποτελέσματα.

Στην συγκεκριμένη διπλωματική χρησιμοποιείται ένα νεύρο-ασαφές σύστημα για την πρόβλεψη της θερμοκρασιακής τάσης, αποτελούμενο από δύο υποσυστήματα ANFIS. Ουσιαστικά πρόκειται για έναν ελεγκτή (CON-ANFIS) και μια διαδικασία (PR-ANFIS) που μοντελοποιούν και προβλέπουν την θερμοκρασία την επόμενη χρονική στιγμή.

Ως κυρίαρχο μέτρο αξιολόγησης του προτεινόμενου μοντέλου και σύγκρισης του με άλλα μοντέλα, χρησιμοποιήθηκε η ακρίβεια πρόβλεψης της τάσης μεταβολής της θερμοκρασίας. Τα αποτελέσματα είναι πολύ ενθαρρυντικά αφού στην φάση της αξιολόγησης του μοντέλου η ακρίβεια της τάσης της μεταβολής της θερμοκρασίας άγγιξε το ποσοστό της τάξεως του 94%. Παράλληλα το μοντέλο συγκρίθηκε με άλλα μοντέλα πρόβλεψης με βάση το σφάλμα RMSE. Παρατηρήθηκε ότι δίνει καλύτερα αποτελέσματα (0,1772 RMSE), εκτός του Evolutionary ANFIS-GA (0,1272 RMSE) και Evolutionary ANFIS-PSO (0,1453).

Ενδεχομένως μια πιθανή βελτίωση στον ελεγκτή, θα έδινε ακόμα χαμηλότερο RMSE. Ένας αλγόριθμος βελτιστοποίησης των παραμέτρων του ελεγκτή CON-ANFIS, όπως οι PSO και GA λογικά θα βελτίωναν την απόδοση του. Επίσης θα μπορούσε να υπάρχουν και άλλου είδους είσοδοι όπως δεδομένα ανά χρόνο, πενταετία κτλ. Επιπλέον οι θερμοκρασιακοί χάρτες, οι οποίοι περιέχουν πλήθος πληροφοριών, θα μπορούσαν να επεξεργαστούν από ένα νευρωνικό δίκτυο, δίνοντας μία έξοδο που να δηλώνει την άνοδο ή την κάθοδο της θερμοκρασίας και να εισάγεται στον ελεγκτή, δημιουργώντας μια ακριβέστερη δράση ελέγχου. Τέλος θα μπορούσε να μελετηθούν και άλλα νεύρο-ασαφή μοντέλα αντί του ANFIS στο ίδιο προτεινόμενο σύστημα.

8. Πηγές και Βιβλιογραφία

1. Abolfazl, Nejatian (2020). Time Series Prediction (<https://www.mathworks.com/matlabcentral/fileexchange/69506-time-series-prediction>), MATLAB Central File Exchange. Retrieved September 01, 2020.
2. Abraham, A. (2005). Adaptation of fuzzy inference system using neural learning, fuzzy system engineering: Theory and practice. In Nadia Nedjah et al. (Eds.), Studies in fuzziness and soft computing (pp. 53–83). Germany: Springer-Verlag.
3. Atsalakis, G. (2016). Using computational intelligence to forecast carbon prices, Applied Soft Computing, Volume 43, Pages 107-116, ISSN 1568-4946, <https://doi.org/10.1016/j.asoc.2016.02.029>.
4. Atsalakis, G. & Valavanis, K. (2009). Forecasting stock market short-term trends using a neuro-fuzzy based methodology. Expert Systems with Applications. 36. 10696-10707. 10.1016/j.eswa.2009.02.043.
5. Atsalakis, G., Frantzis, D., & Zopounidis, C. (2015). Commodities' price trend forecasting by a neuro-fuzzy controller. Energy Systems. 7. 10.1007/s12667-015-0154-8.
6. Atsalakis, G., Protopapadakis, E., & Valavanis, K. (2016). "Stock trend forecasting in turbulent market periods using neuro-fuzzy systems," Operational Research, Springer, vol. 16(2), pages 245-269, July. <https://ideas.repec.org/a/spr/operea/v16y2016i2d10.1007_s12351-015-0197-6.html>
7. Berenji, H., R., & Khedkar, P. (1992). Learning and tuning fuzzy logic controllers through reinforcements. IEEE Transactions on Neural Networks, 3(5), 724–740. <https://doi.org/10.1109/72.159061>
8. Berkeley Earth, berkeleyearth.org/data/, accessed 01-05-19
9. Bertsekas, D. P., & Tsitsiklis, J. N. (2002). Introduction to Propability, Athena Scientific.
10. Chattopadhyay, A., Hassanzadeh, P. & Pasha. (2020). S. Predicting clustered weather patterns: A test case for applications of convolutional neural networks to spatio-temporal climate data. *Sci Rep* **10**, 1317, <https://doi.org/10.1038/s41598-020-57897-9>
11. Daneshmand, H., Tavousi, T., Khosravi, M., & Tavakoli, S. (2015). Modeling minimum temperature using adaptive neuro-fuzzy inference system based on spectral analysis of climate indices: A case study in Iran. *Journal of the Saudi Society of Agricultural Sciences*, 14(1), 33–40. <https://doi.org/10.1016/j.jssas.2013.06.001>
12. Diversi, R., & Guidorzi, R., & Soverini, U. (2010). Identification of ARX and ARARX Models in the Presence of Input and Output Noises. European Journal of Control - EUR J CONTROL. 16. 242-255. 10.3166/ejc.16.242-255.
13. Dubois, D., & Prade, H. (1996). What are fuzzy rules and how to use them. Fuzzy Sets and Systems, 84(2), 169–185. [https://doi.org/10.1016/0165-0114\(96\)00066-8](https://doi.org/10.1016/0165-0114(96)00066-8)

14. Fahimi Nezhad, E., Fallah Ghalhari, G., & Bayatani, F. (2019). Forecasting Maximum Seasonal Temperature Using Artificial Neural Networks “Tehran Case Study.” *Asia-Pacific Journal of Atmospheric Sciences*, 55(2), 145–153.
<https://doi.org/10.1007/s13143-018-0051-x>
15. Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*, Prentice Hall, ISBN 0-13-273350-1
16. Jang R. (1992). “Neuro-Fuzzy Modelling: Architectures, Analysis and Applications”, PhD Thesis, University of California, Berkley.
17. Jang, J-S. R., Sun, C-T. E., & Mizutani, E. (1997). *Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence*. NJ: Prentice-Hall.
18. Jang, Jyh-Shing (1993). ANFIS Adaptive-Network-based Fuzzy Inference System. *Systems, Man and Cybernetics, IEEE Transactions on*. 23. 665 - 685.
10.1109/21.256541.
19. Kasantikul, K., Yang, D., Wang, Q., & Lwin, A. (2018). A Novel Wind Speed Estimation Based on the Integration of an Artificial Neural Network and a Particle Filter Using BeiDou GEO Reflectometry. *Sensors (Basel, Switzerland)*, 18(10), 3350.
<https://doi.org/10.3390/s18103350>
20. Lin, C.-T., & Lee, C. S. G. (1991). Neural-network-based fuzzy logic control and decision system. *IEEE Transactions on Computers*, 40(12), 1320–1336.
<https://doi.org/10.1109/12.106218>
21. Lu, Jing & Xue, Shengjun & Zhang, Xiakun & Zhang, Shuyu & Lu, Wanshun, (2014). Neural Fuzzy Inference System-Based Weather Prediction Model and Its Precipitation Predicting Experiment. *Atmosphere*. 5. 788-805. 10.3390/atmos5040788.
22. Mehdizadeh, S., Ahmadi, F., & Kozekalani Sales, A. (2020). Modelling daily soil temperature at different depths via the classical and hybrid models. *Meteorological Applications*, 27(4). <https://doi.org/10.1002/met.1941>
23. Nauck D. and Kruse R. (1997). “Neuro-Fuzzy Systems for Function Approximation”, 4th International Workshop Fuzzy-Neuro Systems.
24. Nauck, D., Klawonn, F., & Kruse, R. (1997). *Foundations of Neuro-Fuzzy Systems* (1st ed.). Wiley.
25. Papadopoulos A., & Katsafados P. (2009): Verification of operational weather forecasts from the POSEIDON system across the Eastern Mediterranean, *Natural Hazards and Earth System Sciences*, 9, 4, 1299-1306.
26. Pathania, Manjushri & Sundar, Gour & Mitra Thakur, Gour & Meena, Chandra. (2013). Neuro-Fuzzy Inference System for Rainfall Prediction over Northern India. 10.13140/2.1.3600.0648.
27. Rashid, Tarik & Ahmed, Haval. (2012). Building an Adaptive Neural Fuzzy Inference System for Revised General Test/Gross Point Average Problem. *International Journal of Emerging Technologies in Computational and Applied Sciences (IJETCAS)*. 56-65.

28. Sadeghi-Niaraki A., Kisi O., Choi S-M. (2020). Spatial modeling of long-term air temperatures for sustainability: evolutionary fuzzy approach and neuro-fuzzy methods. *PeerJ* 8:e8882 <http://doi.org/10.7717/peerj.8882>
29. Sadiq, Alishba & Usman, Muhammad & Zubair, Muhammad & Khan, Shujaat. (2018). Chaotic Time Series Prediction using Spatio-Temporal RBF Neural Networks. 1-5. 10.1109/ICEEST.2018.8643321.
30. Setyaningrum H., & Swarinata, P. M. (2014). "Weather prediction application based on ANFIS (Adaptive neural fuzzy inference system) method in West Jakarta region," *2014 International Conference on Cyber and IT Service Management (CITSM)*, South Tangerang, pp. 113-118, doi: 10.1109/CITSM.2014.7042187
31. Shumway, R. H., & Stoffer, D. S. (2010). Time series analysis and its applications : with R examples (3rd ed.). Springer. ISBN 144197864X.
32. Siami-Namini S., Tavakoli N., & Namin A. S. (2019). "The Performance of LSTM and BiLSTM in Forecasting Time Series," 2019 IEEE International Conference on Big Data (Big Data), Los Angeles, CA, USA, 2019, pp. 3285-3292, doi: 10.1109/BigData47090.2019.9005997.
33. Suykens, J. A. K., Vandewalle, J. (1999) "Least squares support vector machine classifiers", *Neural Processing Letters*, 9 (3), 293–300.
34. Takagi, T., Sugeno, M. (1985). M. Fuzzy identification of systems and its applications to modeling and control. *IEEE Trans. Sys. Man. Cybern.*, 15, 116–132.
35. Tulunay, Y., Şenalp, E. T., Öz, Ş., Dorman, L. I., Tulunay, E., Menteş, S. S., and Akcan, M. E. (2008). A fuzzy neural network model to forecast the percent cloud coverage and cloud top temperature maps, *Ann. Geophys.*, 26, 3945–3954, <https://doi.org/10.5194/angeo-26-3945-2008>.
36. Vieira, J., & Morgado-Dias, F. & Mota, Al. (2004). Neuro-Fuzzy Systems: A Survey. *WSEAS Transactions on Systems*. 3. 414-419.
37. WCRP, <https://www.wcrp-climate.org/component/content/article/695-gc-near-term-climate-overview?catid=138&Itemid=538>, accessed 20-09-20
38. Whittle, P. (1951). Hypothesis Testing in Time Series Analysis. Almqvist and Wicksell. Whittle, P. (1963). Prediction and Regulation. English Universities Press. ISBN 0-8166-1147-5.
39. Yarpiz (2020). ANFIS Training using Evolutionary Algorithms and Metaheuristics(<https://www.mathworks.com/matlabcentral/fileexchange/52971-anfis-training-using-evolutionary-algorithms-and-metaheuristics>), MATLAB Central File Exchange. Retrieved September 01, 2020
40. Zadeh L. (1973). "Outline of a New Approach to the Analysis of Complex Systems and Decision Processes," in *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-3, no. 1, pp. 28-44, doi: 10.1109/TSMC.1973.5408575.

41. Zhang, Z., & Dong, Y. (2020). Temperature Forecasting via Convolutional Recurrent Neural Networks Based on Time-Series Data. *Complexity*, 2020, 1–8.
<https://doi.org/10.1155/2020/3536572>
42. Διαμαντάρας Κ. (2007). Τεχνητά Νευρωνικά Δίκτυα, Κλειδάριθμος, ISBN 9604610805
43. Θεοδώρου, Γ., (2010). Εισαγωγή στην Ασαφή Λογική (Fuzzy Logic), Εκδόσεις ΤΖΙΟΛΑ, ISBN: 978-960-418-218-3.
44. Μακρή, Γ. Ι., Δ/ντή Μετ/κού Ινστ/του Αθήνας, (1990). "Ο Καιρός", Αθήναι. σ.69-70.