

*«Πρόβλεψη της τάσης της χρηματιστηριακής
αγοράς με χρήση νευρο-ασαφών μεθόδων.»*



ΒΛΑΧΟΣ ΣΤΑΥΡΟΣ

ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ ΠΑΡΑΓΩΓΗΣ & ΔΙΟΙΚΗΣΗΣ

ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΑΡΑΓΩΓΗΣ & ΔΙΟΙΚΗΣΗΣ

Μεταπτυχιακό πρόγραμμα: "Διοίκηση Επιχειρήσεων - Master in Business Administration (MBA)"

Ειδίκευση: Χρηματοοικονομικά

A.M. 2018019019

ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ: ΓΕΩΡΓΙΟΣ ΑΤΣΑΛΑΚΗΣ

Ιανουάριος 2020

*«Πρόβλεψη της τάσης της χρηματιστηριακής
αγοράς με χρήση νευρο-ασαφών μεθόδων.»*



ΒΛΑΧΟΣ ΣΤΑΥΡΟΣ
ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ ΠΑΡΑΓΩΓΗΣ & ΔΙΟΙΚΗΣΗΣ
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΑΡΑΓΩΓΗΣ & ΔΙΟΙΚΗΣΗΣ

Μεταπτυχιακό πρόγραμμα: "Διοίκηση Επιχειρήσεων - Master in Business Administration (MBA)"

Ειδίκευση: Χρηματοοικονομικά

A.M. 2018019019

ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ: ΓΕΩΡΓΙΟΣ
ΑΤΣΑΛΑΚΗΣ

**Αυτή η διατριβή υποβάλλεται για την μερική ικανοποίηση των απαιτήσεων
για την απόκτηση του Μεταπτυχιακού Διπλώματος Ειδίκευσης «Διοίκηση Επιχειρήσεων - Master in
Business Administration (MBA)»**

Ιανουάριος 2020



Το παρόν έργο αδειοδοτείται υπό τους όρους της άδειας Creative Commons

Copyright © Βλάχος Σταύρος 2020

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Η έγκριση της Διατριβής από το Τμήμα Παραγωγής & Διοίκησης του Πολυτεχνείου

Κρήτης δεν υποδηλώνει απαραίτητως και αποδοχή των απόψεων του συγγραφέα εκ μέρους του Τμήματος.

Η διατριβή του Βλάχου Σταύρου εγκρίνεται από τα μέλη της Επιτροπής:

1. Ατσαλάκη Γεώργιο.
2. Τσαφάρáκη Στυλιανό.
3. Ζοπουνίδη Κωνσταντίνο.

Στην οικογένεια μου για την πολύχρονη στήριξή της..

Πρωταρχικά θα ήθελα να ευχαριστήσω τον κ.Ατσαλάκη που δέχθηκε να είναι ο επιβλέπων καθηγητής στην παρούσα διπλωματική εργασία και βοήθησε στα μέγιστα για την επιτυχή ολοκλήρωσή της. Ένα μεγάλο ευχαριστώ οφείλω και σε πολλούς καθηγητές της σχολής Μηχανικών Παραγωγής και Διοίκησης για τις γνώσεις και τις δεξιότητες που μου μετέδωσαν τόσο κατά την φοίτησή μου ως προπτυχιακός φοιτητής όσο και ως μεταπτυχιακός.

Έπειτα, θα ήθελα να ευχαριστήσω τους φίλους μου που σε όλη την διάρκεια των σπουδών μου ήταν δίπλα μου για να χαρούν τις χαρές μου και να με στηρίζουν στις δύσκολες στιγμές. Τέλος, δεν γίνεται να μην ευχαριστήσω την οικογένειά μου που σε δύσκολες συνθήκες με στήριξε ώστε να ολοκληρώσω τις σπουδές μου.

Περίληψη

Η πρόβλεψη της τάσης των τιμών των μετοχών ή/και χρηματιστηριακών δεικτών είναι σίγουρα ένα από τα πιο σημαντικά θέματα του κλάδου των χρηματοοικονομικών και έχει καταστεί μία από τις σοβαρές ανησυχίες των επενδυτών και των μετόχων, καθώς οι ακριβείς και αυθεντικές προβλέψεις της τάσης τους έχουν ελκυστικά οφέλη και κερδοφόρα πλεονεκτήματα και ανακριβείς και αναξιόπιστες προβλέψεις μπορούν να έχουν ανεπανόρθωτες συνέπειες . Ως εκ τούτου, είναι σημαντικό να παρέχεται ένα ακριβές και αποτελεσματικό μοντέλο για την πρόβλεψη τους. Η δεδομένη δυσκολία που προκύπτει είναι το γεγονός ότι πως η μεταβλητότητα της αγοράς, η οποία είναι μη-γραμμική, πρέπει να συμπεριληφθεί στα μοντέλα πρόβλεψης ενώ ομοίως παράγοντες όπως η πολυπλοκότητα και το θορυβώδες περιβάλλον της αγοράς πρέπει να εισαχθούν σε αυτά.

Σκοπός της παρούσας διπλωματικής εργασίας είναι η ανάπτυξη ενός συνολικού προσαρμοστικού νευρο-ασαφούς συστήματος που αποτελείται από έναν ελεγκτή (Adaptive Neuro-Fuzzy Inference System – ANFIS), για την πρόβλεψη με όσο το δυνατόν πιο ακριβή τρόπο της τάσης της χρηματιστηριακής αγοράς της επόμενης ημέρας χρησιμοποιώντας ιστορικά δεδομένα για τις τιμές κλεισίματος των μετοχών. Η προσέγγιση μας, που βασίζεται στο ANFIS, είναι δικαιολογημένη λόγω της αβεβαιότητας και της πολυπλοκότητας των χρηματιστηριακών αγορών που απαιτούν ανάμειξη της ανθρώπινης εμπειρογνωμοσύνης και των μαθηματικών μοντέλων, προσαρμογή στις αλλαγές και ενσωμάτωση διαφόρων παραγόντων στην πρόβλεψη των τιμών των μετοχών. Το προσαρμοστικό νευρο-ασαφές σύστημα προσφέρει μια βιώσιμη εναλλακτική λύση για την καταγραφή της συμπεριφοράς της χρηματιστηριακής αγοράς: τα νευρωνικά δίκτυα χρησιμοποιούνται για να αναγνωρίζουν τα πρότυπα και να προσαρμόζονται για να αντιμετωπίζουν τα μεταβαλλόμενα περιβάλλοντα. Τα ασαφή συστήματα χρησιμοποιούνται για να ενσωματώνουν την ανθρώπινη γνώση, εκτελούν συμπεράσματα και βοηθούν στη λήψη αποφάσεων. Η ενσωμάτωση αυτών των δύο με ορισμένες τεχνικές βελτιστοποίησης χωρίς παράγωγα οδηγεί σε προσεγγίσεις βασισμένες σε νευρο-ασαφείς και «απαλές» υπολογιστικές μεθόδους. Στην παρούσα έρευνα η χρηματιστηριακή αγορά που χρησιμοποιείται είναι το Ελληνικό Χρηματιστήριο.

Abstract

Predicting stock prices or/and indices trend is certainly one of the most important issues in the financial sector and has become one of the major concerns of investors and shareholders, as accurate and authentic forecasts of stock prices or/and indices trend have attractive benefits and profitability advantages while inaccurate and unreliable forecasts can have irreparable consequences. Therefore, it is important to provide an accurate and efficient model for their prediction. The given difficulty is that market volatility, which is non-linear, must be included in forecasting models while factors such as complexity and noisy market environment must be incorporated into them.

The purpose of this thesis is to develop a comprehensive Adaptive Neuro-Fuzzy Inference System (ANFIS) for predicting the next day's stock market general index trend as accurately as possible from historical data on stock closing prices. Our approach, based on ANFIS, is justified by the uncertainty and complexity of stock markets that require the mixing of human expertise and mathematical models, adapting to changes and integrating various factors into stock price forecasts. The adaptive neuro-fuzzy system offers a viable alternative to recording stock market behavior: neural networks are used to identify patterns and adapt to meet changing environments and fuzzy systems are used to integrate human knowledge and to perform inference and decision making. The integration of these two with some derivative-free optimization techniques leads to neuro-fuzzy and soft computing based approaches. In the present study the stock market used is the Athens Stock Exchange (ASE).

Περιεχόμενα.

1. Εισαγωγή.	4
2. Προβλέψεις και σχετική βιβλιογραφία.	6
3. Θεωρία Νευρωνικών Δικτύων.	9
3.1 Εισαγωγή στα τεχνητά νευρωνικά δίκτυα.	9
3.2 Ιστορική Αναδρομή	10
3.3 Θεωρία νευρωνικών δικτύων.	13
3.3.1 Μοντέλα νευρώνων.	13
3.3.2 Τύποι συναρτήσεων ενεργοποίησης.	15
3.3.3 Αρχιτεκτονική τεχνητών νευρωνικών δικτύων.	17
3.3.4 Εκπαίδευση νευρωνικών δικτύων.	19
3.4 Πλεονεκτήματα των τεχνητών νευρωνικών δικτύων.	20
4. Ασαφή Σύνολα.	23
4.1 Εισαγωγή στα ασαφή σύνολα.	23
4.2 Ιστορική αναδρομή ασαφών συνόλων.	25
4.3 Θεωρία ασαφών συνόλων.	26
4.3.1 Κατηγορίες ασαφών συνόλων.	26
4.3.2 Ορισμοί – χαρακτηριστικά των ασαφών συνόλων.	29
4.3.3 Πράξεις Ασαφών Συνόλων.	31
4.3.4 Τύποι συναρτήσεων συμμετοχής.	33
4.3.5 Ασαφή συστήματα.	37
5. ΠΡΟΣΑΡΜΟΣΤΙΚΑ ΝΕΥΡΟ-ΑΣΑΦΗ ΣΥΣΤΗΜΑΤΑ (ANFIS).	42
5.1 Νευρο-ασαφή συστήματα.	42
5.2 Τύποι νευρο-ασαφών συστημάτων.	43
5.2.1 Συνεργατικά νευρο-ασαφή συστήματα.	43
5.2.2 Παράλληλα νευρο-ασαφή συστήματα.	44

5.2.4 Γνωστές νευρο-ασαφείς αρχιτεκτονικές.	45
5.3 Προσαρμοστικό νευρο-ασαφές σύστημα (ANFIS).....	48
5.3.1 Αρχιτεκτονική του ANFIS.	49
5.3.2 Εκπαίδευση του ANFIS.....	52
6. Εφαρμογή του ANFIS για την πρόβλεψη της τάσης του γενικού δείκτη του Χρηματιστηρίου Αθηνών.	56
6.1 Δεδομένα.	56
6.2 Κατασκευή του δείκτη.	56
6.3 Εφαρμογή στα δεδομένα.	57
6.4 Μεθοδολογία αξιολόγησης του μοντέλου.....	59
6.5 Αποτελέσματα του μοντέλου.....	60
7. Συμπεράσματα.....	64
Βιβλιογραφία.	65
Παράρτημα Α.	69

Κατάλογος Σχημάτων.

Σχήμα 3.3.1: Η μορφή του τεχνητού νευρώνα. (Πηγή: Haykin ,1998).....	13
Σχήμα 3.3.2: Βηματική συνάρτηση ενεργοποίησης. (Πηγή: Haykin ,1998).....	15
Σχήμα 3.3.3: Γραμμική συνάρτηση ενεργοποίησης (Πηγή: Haykin ,1998).....	16
Σχήμα 3.3.4: Σιγμοειδής συνάρτηση ενεργοποίησης (Πηγή: Haykin ,1998).....	16
Σχήμα 3.3.5: Δίκτυο πρόσθιας τροφοδότησης ενός επιπέδου (Πηγή: Haykin ,1998)	17
Σχήμα 3.3.6: Πλήρως συνδεδεμένο εμπρόσθιο δίκτυο με ένα κρυμμένο επίπεδο και ένα επίπεδο εξόδου.(Πηγή: Haykin ,1998)	18
Σχήμα 3.3.7: Αναδρομικό δίκτυο χωρίς βρόχους αυτοανατροφοδότησης και κρυμμένους νευρώνες.(Πηγή: Haykin ,1998)	18
Σχήμα 4.1: Συνάρτηση συμμετοχής σε ένα διακριτό, μη διατεταγμένο, σύνολο.	27

Σχήμα 4.2: Συνάρτηση συμμετοχής σε ένα διακριτό σύνολο. Πηγή: Jang, Sun and Mizutani (1997).	28
Σχήμα 4.3: Συνάρτηση συμμετοχής σε ένα συνεχές σύνολο. Πηγή: Jang, Sun and Mizutani (1997).	28
Σχήμα 4.4: Τυπικές συναρτήσεις συμμετοχής για τις λεκτικές τιμές “νέος”, “μεσήλικας” και “ηλικιωμένος”. Πηγή: Jang, Sun and Mizutani (1997).	30
Σχήμα 4.5 : Η συνάρτηση συμμετοχής του ασαφούς συνόλου “μεσήλικας”. Πηγή: Jang, Sun and Mizutani (1997)	31
Σχήμα 4.6: Τομή δύο συνόλων A και C.....	33
Σχήμα 4.7: Ένωση δύο συνόλων A και B.....	33
Σχήμα 4.8: Τριγωνική συνάρτηση συμμετοχής. Πηγή: Jang, Sun and Mizutani (1997).	34
Σχήμα 4.9: Τραπεζοειδής συνάρτηση συμμετοχής. Πηγή: Jang, Sun and Mizutani (1997).	35
Σχήμα 4.10: Γκαουσιανή συνάρτηση συμμετοχής. Πηγή: Jang, Sun and Mizutani (1997).	35
Σχήμα 4.11: Γενικευμένη καμπανοειδής συνάρτηση συμμετοχής. Πηγή: Jang, Sun and Mizutani (1997).	36
Σχήμα 4.12: Σιγμοειδής συνάρτηση συμμετοχής. (α) Δύο σιγμοειδής συναρτήσεις. (β) Μία κλειστή συνάρτηση συμμετοχής. (γ) Δύο σιγμοειδής συναρτήσεις. (δ) Μία κλειστή συνάρτηση συμμετοχής από τον συνδυασμό των y_1, y_2 . Πηγή: Jang, Sun and Mizutani (1997).	37
Σχήμα 4.13: Βασική διαμόρφωση των καθαρών ασαφών συστημάτων. Πηγή: Wang (1997).	39
Σχήμα 4.15: Μέθοδοι από-ασαφοποίησης. Πηγή: Atsalakis, Dimitrakakis and Zopounidis (2011).	40
Σχήμα 4.16: Η μέθοδος Sugeno. Πηγή: Jang, Sun and Mizutani (1997)	41
Σχήμα 5.1: Συνεργατικό νευρο-ασαφές σύστημα.....	43
Σχήμα 5.3: Αρχιτεκτονική του FALCON. Πηγή: Altug, Trussell and Chow (1999).	45

Σχήμα 5.4: Αρχιτεκτονική του FuNe I. Πηγή: Halgamuge and Glesner (1994).	46
Σχήμα 5.5: Αρχιτεκτονική του GARIC. Πηγή: Berenji and Khedkar (1992).....	47
Σχήμα 5.8: Η αρχιτεκτονική ANFIS για το ασαφές μοντέλο Sugeno, όπου η κανονικοποίηση των βαρών εκτελείται στο τελευταίο επίπεδο. Πηγή: Jang, Sun and Mizutani (1997)	52
Σχήμα 6.1: Διαγράμματα διασποράς των δεδομένων εκπαίδευσης και ελέγχου.	57
Σχήμα 6.2: Ρίζα της μέσης τετραγωνικής απόκλισης ως προς τον αριθμό των επαναλήψεων για τα δεδομένα εκπαίδευσης και ελέγχου.	58
Σχήμα 6.3: Το σύστημα FIS του μοντέλου.....	60
Σχήμα 6.4: Αρχικές και τελικές συναρτήσεις συμμετοχής.....	61
Σχήμα 6.5: (α) Σφάλματα εκπαίδευσης και ελέγχου και (β) μέγεθος βήματος σε σχέση με τον αριθμό των επαναλήψεων.....	61
Σχήμα 6.6: Πραγματικές και προβλεπόμενες τιμές του γενικού δείκτη.	62
Σχήμα 6.7: Αρχιτεκτονική του μοντέλου ANFIS.	62
 Πίνακας 5.1: Δύο περάσματα στην μέθοδο υβριδικής μάθησης για το ANFIS. Πηγή: Jang (1993).....	53
Πίνακας 6.1: Παράμετροι και στοιχεία του μοντέλου ANFIS.	60
Πίνακας 6.2: Αξιολόγηση του μοντέλου ANFIS.....	63

1. Εισαγωγή.

Βασικός παράγοντας στη διαδικασία λήψης μιας απόφασης, είναι οι επιπτώσεις της στο μέλλον. Από την αρχαιότητα οι προβλέψεις διαδραματίζουν εξαιρετικά σημαντικό ρόλο στην καθημερινότητα του ανθρώπου και συχνά επηρεάζουν το μέλλον του. Από το μαντείο των Δελφών και τις προβλέψεις της Πυθίας, μέχρι σήμερα και στα εξελιγμένα πληροφοριακά συστήματα και μοντέλα για την πρόβλεψη πληθώρας στοιχείων, η χρήση προβλέψεων αποδεικνύεται σημαντική και ίσως αναγκαία λόγω της ανάγκης του ανθρώπου για μοντελοποίηση μελλοντικών γεγονότων έτσι ώστε να γνωρίζει εκ των πρότερων μια πιθανή έκβαση των δραστηριοτήτων του με απώτερο σκοπό, φυσικά, την εκμετάλλευση επιτυχιών αλλά και την διαχείριση των αποτυχιών. Προβλέψεις χρειάζονται στην οικονομία, στο εμπόριο, στην παραγωγή, στην κυβέρνηση, σε συλλόγους αλλά και στις πολιτικές παρατάξεις.

Λόγω της φύσης των τιμών των χρηματιστηριακών αξιών, της μεταβλητότητας αυτών στο χρόνο αλλά και του ανθρώπινου παράγοντα τα μοντέλα πρόβλεψης των χρηματαγορών παρουσιάζουν ιδιαίτερη δυσκολία αλλά και σημαντικό ενδιαφέρον. Η ακριβής μοντελοποίηση απαιτεί, μεταξύ άλλων παραγόντων, την εξέταση των φαινομένων που χαρακτηρίζονται, για παράδειγμα, από περιόδους ύφεσης ή επέκτασης και περιόδους υψηλής ή χαμηλής μεταβλητότητας. Η παρατηρούμενη μεταβλητότητα στις αποδόσεις / τιμές της χρηματιστηριακής αγοράς προκύπτει από το γεγονός ότι οι επιθυμητοί (απαιτούμενοι) ρυθμοί απόδοσης είναι εξαιρετικά ασταθής λόγω των κυκλικών και άλλων βραχυπρόθεσμων διακυμάνσεων της συνολικής ζήτησης (Atsalakis and Valavanis, 2009). Είναι εύκολα αντιληπτό ότι ένα επενδυτής που γνωρίζει εκ των προτέρων αυτές τις πληροφορίες έχει την δυνατότητα να προχωρήσει σε σωστές επενδυτικές επιλογές. Χρηματιστηριακές εταιρείες, ιδιώτες, επενδυτικές τράπεζες και άλλοι Χρηματοοικονομικοί οργανισμοί καταναλώνουν πολύτιμο χρόνο αλλά και μεγάλα χρηματικά ποσά για τη δημιουργία μοντέλων πρόβλεψης.

Η δημοφιλέστερη μέθοδος πρόβλεψης είναι η μέθοδος των χρονοσειρών. Η μελέτη των χρονοσειρών έχουν σαν στόχο την “αναγνώριση” ενός προτύπου συμπεριφοράς (ή επανάληψης) της χρονοσειράς υπό μελέτη έτσι ώστε να υπολογιστεί και η μελλοντική μεταβολή των τιμών. Στηρίζονται σε μεγάλο βαθμό στην θεώρηση ότι η μελλοντική μεταβολή της τιμής του μεγέθους, θα ακολουθήσει το ίδιο πρότυπο μεταβολής με τα παρελθοντικά στοιχεία. Με άλλα λόγια ότι η ιστορία επαναλαμβάνεται. Η μέθοδος των

χρονοσειρών έρχεται σε ευθεία αντίθεση με την μορφή ασθενούς αποτελεσματικότητας της θεωρίας της Αποτελεσματικής Αγοράς (Efficient Market Theory). Σύμφωνα με την τελευταία, ιστορικές πληροφορίες (π.χ. παρελθούσες τιμές, αποδόσεις, όγκος συναλλαγών) αντικατοπτρίζονται ήδη στις τιμές και δεν μπορούν να χρησιμοποιηθούν από τους επενδυτές για να προβλέψουν μελλοντικές τιμές και να πετύχουν υπερβολικές αποδόσεις. Στην πράξη όμως, υπάρχει πλήθος ερευνητικών και καθημερινών αποτελεσμάτων που αμφισβητούν την EME και αναδεικνύουν την αποτελεσματικότητα της χρήσης χρονοσειρών στην κατασκευή μοντέλων πρόβλεψης.

Στην συνέχεια περιγράφουμε την δομή της παρούσας διπλωματικής εργασίας.

Στο δεύτερο κεφάλαιο γίνεται μια μικρή επισκόπηση επιστημονικών άρθρων που χρησιμοποιούν παρεμφερή μοντέλα ή έχουν παρόμοιο σκοπό με την παρούσα διπλωματική εργασία.

Στο τρίτο κεφάλαιο προχωρούμε στην παρουσίαση της ιστορίας των τεχνητών νευρωνικών δικτύων καθώς και παρουσίαση των βασικών χαρακτηριστικών τους όπως οι τύποι των συναρτήσεων ενεργοποίησης, η αρχιτεκτονική τους και η μέθοδος εκπαίδευσής τους.

Στο τέταρτο κεφάλαιο παρουσιάζουμε την ιστορία των ασαφών συνόλων, τα οποία παίζουν σημαντικό ρόλο στην εφαρμογή της μεθόδου που χρησιμοποιεί η παρούσα ανάλυση, καθώς και του θεωρητικού τους πλαισίου. Γίνεται λόγος για τις κατηγορίες, τα χαρακτηριστικά και τις βασικές πράξεις των ασαφών συνόλων, καθώς και για τις διάφορες συναρτήσεις συμμετοχής που ισχύουν σε αυτά.

Στο πέμπτο κεφάλαιο γίνεται μια εκτενής αναφορά στα νευρο-ασαφή συστήματα και ιδιαίτερα στο προσαρμοστικό νευρο-ασαφές σύστημα ANFIS το οποίο χρησιμοποιούμε.

Τέλος στο έκτο κεφάλαιο, το κυριότερο κεφάλαιο αυτής της διπλωματικής εργασίας, καθώς σε αυτό εφαρμόζεται και αναλύεται όλη η διαδικασία που ακολουθούμε για την πρόβλεψη της τάσης του γενικού δείκτη του Χρηματιστηρίου Αθηνών και γίνεται παρουσίαση των αποτελεσμάτων μας.

2. Προβλέψεις και σχετική βιβλιογραφία.

Σε αυτό το κεφάλαιο προχωρούμε σε μια ανασκόπηση ορισμένων επιστημονικών άρθρων της διεθνούς και εγχώριας βιβλιογραφίας τα οποία έχουν συναφή σκοπό με αυτόν της παρούσας διπλωματικής εργασίας ή χρησιμοποιούν ταυτόσημη μεθοδολογία. Σημειώνεται ότι έγινε επιλεκτική επιλογή τους καθώς η βιβλιογραφία πάνω στις προβλέψεις της χρηματιστηριακής αγοράς αλλά και με την χρήση νευρο-ασαφών μεθόδων είναι άφθονη.

Ο Wong (1992) περιγράφει ένα σύστημα έξυπνης επιλογής μετοχών (intelligent stock selection-ISS) που επεκτείνει την προσέγγιση των νευρωνικών δικτύων για να χειριστεί ασαφείς, πιθανολογικές και πληροφορίες μητρών Boolean. Ένα ISS συνδυάζει τα διάφορα πλεονεκτήματα των συστημάτων εμπειρογνωμόνων, των τεχνητών νευρωνικών δικτύων και της ασαφούς λογικής. Σχεδιάστηκε ως μια ολοκληρωμένη αρχιτεκτονική δικτύου, βασισμένη σε ένα δομικό στοιχείο που ονομάζεται νευρωνική πύλη. Για να δοκιμάσει το σύστημα χρησιμοποίησε μια βάση δεδομένων που περιείχε περίπου 800 μετοχές με δεδομένα τριών χρόνων σχετικά με το βήτα, τη σχέση τιμής προς λογιστική αξία, την τριετή μέση τιμή προς τη λογιστική αξία, τον λόγο τιμής προς κέρδος, τον κύκλο εργασιών, τον τριετή μέσο κύκλο εργασιών, την ανάπτυξη των κερδών, την τιμή του μοντέλου προεξόφλησης μερισμάτων (DDM), το περιθώριο κέρδους, το μέσο περιθώριο κέρδους τριών ετών και την απόδοση του τρέχοντος έτους. Τα παραπάνω δεδομένα χρησιμοποιήθηκαν ως είσοδοι του μοντέλου μαζί με μια βάση κανόνων που περιέχει 32 κανόνες εταιρειών. Αυτοί οι κανόνες παρέχονται από τους ειδικούς του τομέα, αντί να δημιουργούνται αυτόματα. Τα αρχικά αποτελέσματα για την πρόβλεψη της απόδοσης του επόμενου έτους ήταν αρκετά ικανοποιητικά.

Οι Chang and Liu (2008) ανέπτυξαν, για την πρόβλεψη των τιμών των μετοχών, ένα ασαφές σύστημα τύπου Takagi-Sugeno-Kang (TSK). Το ασαφές σύστημα TSK χρησιμοποιεί έναν τεχνικό δείκτη ως μεταβλητή εισόδου και το επακόλουθο μέρος είναι ένας γραμμικός συνδυασμός των μεταβλητών εισόδου. Ο τεχνικός δείκτης υπολογίζεται βάσει της διακύμανσης της τιμής των μετοχών, του όγκου συναλλαγών και του χρόνου μετά από επεξεργασία ώστε να αντικατοπτρίζουν την τρέχουσα τάση των διακυμάνσεων των τιμών των μετοχών. Το μοντέλο βασισμένο στο ασαφές σύστημα ελέγχεται πάνω σε ηλεκτρονικές μετοχές από το Χρηματιστήριο της Ταϊβάν (TSE). Μέσω των πειραματικών δοκιμών, το μοντέλο προέβλεψε επιτυχώς τη

διακύμανση των τιμών για μετοχές από διάφορους τομείς με ακρίβεια κοντινή στο 97,6% για το δείκτη TSE.

Οι Tan, Quek and Cheng (2011) στηριζόμενοι στις αρχές της τεχνικής ανάλυσης, πρότειναν ένα μοντέλο ANFIS που συμπληρώθηκε με την ενδυναμωμένη μάθηση (RL) για τον εντοπισμό των τάσεων και την πραγματοποίηση επενδυτικών αποφάσεων. Η ενδυναμωμένη μάθηση χρησιμοποιείται για να διαμορφώσει μια αυτοματοποιημένη διαδικασία για τον προσδιορισμό των κύκλων των μετοχών ρυθμίζοντας τον ρυθμό και τις μέσες περιόδους. Τα αρχικά πειραματικά τους αποτελέσματα που βασίζονται σε πέντε αμερικανικές μετοχές ήταν θετικά. Κατά μέσο όρο, οι συνολικές αποδόσεις από τις πέντε μετοχές ήταν σε θέση να κερδίσουν την αγορά (τον γενικό δείκτη Dow Jones) κατά περίπου 50 ποσοστιαίες μονάδες.

Οι Atsalakis, Dimitrakakis and Zopounidis, (2011) παρουσίασαν το σύστημα WASP (Wave Analysis Stock Prediction), ένα σύστημα ANFIS βασισμένο στην θεωρία κυμάτων του Elliot (Elliot Wave Theory). Αυτή η θεωρία έχει βρεθεί ότι είναι εξαιρετικά χρήσιμη και ακριβής, ιδιαίτερα σε προβλήματα πρόβλεψης. Μια τεχνική νευρο-ασαφούς λογικής χρησιμοποιήθηκε για την πρόβλεψη της τάσης των τιμών των μετοχών. Το προτεινόμενο σύστημα τους δεν ήταν ένα ενιαίο μοντέλο, αλλά μια επαναλαμβανόμενη μέθοδος επιλογής εννέα διαφορετικών υπο-μοντέλων ANFIS, ο συνδυασμός των οποίων δίνει την τελική πρόβλεψη. Αυτή η μέθοδος επελέγη λόγω του γεγονότος ότι διάφορα μοντέλα (ANFIS με διαφορετικές παραμέτρους τύπων συναρτήσεων συμμετοχών, αριθμών συναρτήσεων συμμετοχής, μεγεθών βημάτων και αριθμών εποχών-επαναλήψεων) έδωσαν πολύ καλά αποτελέσματα σε ορισμένες περιόδους, αλλά όχι συνεχώς, ενώ άλλα σύνολα παραμέτρων έδωσαν πολύ καλά αποτελέσματα για μεταγενέστερες περιόδους. Τα δεδομένα που χρησιμοποιούνται είναι 2060 ημερήσιες παρατηρήσεις. Οι τελευταίες 60 εγγραφές χρησιμοποιούνται για τη δοκιμή δεδομένων και τα υπόλοιπα 2000 δεδομένα χρησιμοποιούνται για την εκπαίδευση των νευρο-ασαφών υποσυστημάτων. Στα αποτελέσματά τους οι τρεις ερευνητές βρήκαν ότι μερικά υπο-μοντέλα επιτυγχάνουν ποσοστό επιτυχίας άνω του 75% για ένα δείγμα 60 ημερών διαπραγμάτευσης. Αυτό αποδεικνύει πόσο αποτελεσματικές μπορούν να είναι οι νευρο-ασαφείς αρχιτεκτονικές στην πρόβλεψη των χρηματιστηριακών αγορών. Το σύστημα έδειξε επίσης μια τάση να επιτυγχάνονται ποσοστά επιτυχίας κοντά στο 60%, κάτι που είναι σημαντικά καλύτερο από την πρόβλεψη με τη βοήθεια ενός νομίσματος.

Οι Cheng *et al.* (2013) χρησιμοποίησαν το ANFIS για να προβλέψουν τις τιμές των μετοχών στις χρηματιστηριακές αγορές της Ταϊβάν. Υποστήριξαν ότι η πραγματοποίηση προβλέψεων με βάση αρκετές παρελθούσες περιόδους των τιμών των μετοχών είναι πολύ καλύτερη από τη χρήση μιας μόνο προηγούμενης περιόδου και παρατήρησαν ότι είναι δύσκολο να βρεθεί το βέλτιστο βάρος για κάθε περίοδο. Ενσωμάτωσαν δεδομένα υψηλής τάξης στις τιμές των μεμονωμένων ιδιοτήτων χρησιμοποιώντας τη μέθοδο του διατεταγμένου σταθμισμένου μέσου όρου (OWA).

Οι Svalina *et al.* (2013) παρουσιάζουν ένα μοντέλο πρόβλεψης για το κλείσιμο των τιμών του δείκτη Crobex του Χρηματιστηρίου του Ζάγκρεμπ. Το μοντέλο πρόβλεψης δημιουργείται με τέτοιο τρόπο ώστε για κάθε 5 ημέρες προβλέπει την τιμή κλεισίματος του Crobex. Το μοντέλο πρόβλεψης παράγεται με βάση τα ίδια σύνολα δεδομένων εισόδου / εξόδου μέσω ενός προσαρμοστικού νευρο-ασαφούς συστήματος (ANFIS). Για κάθε ημέρα δημιουργείται ένα ξεχωριστό σύστημα ασαφούς συμπερασμού μέσω του ANFIS με βάση το ίδιο σύνολο δεδομένων εισόδου / εξόδου, με τη μόνη διαφορά ότι για κάθε ξεχωριστό ασαφές σύστημα χρησιμοποιούνται διαφορετικά υποσύνολα για εκπαίδευση και έλεγχο, έτσι ώστε να δημιουργούνται διαφορετικές μεταβλητές εισόδου. Το σύνολο δεδομένων εισόδου / εξόδου αντιπροσωπεύει τα ιστορικά στοιχεία της τιμής κλεισίματος του δείκτη Crobex από τις 4 Νοεμβρίου 2010 έως τις 24 Ιανουαρίου 2012 και η τιμή κλεισίματος του δείκτη Crobex προβλέπεται για τις επόμενες 5 ημέρες, ενώ η πρώτη ημέρα πρόβλεψης είναι η 25η Ιανουαρίου 2012. Στη συνέχεια, το προαναφερόμενο σύνολο δεδομένων εισόδου / εξόδου μετατοπίζεται 5 ημέρες νωρίτερα και η τιμή κλεισίματος του δείκτη Crobex προβλέπεται εκ των προτέρων για τις επόμενες 5 ημέρες ξεκινώντας από την τελευταία ημέρα του συνόλου δεδομένων εισόδου / εξόδου. Με αυτόν τον τρόπο οι τιμές κλεισίματος του δείκτη Crobex προβλέπεται μέχρι τις 19 Οκτωβρίου 2012 με βάση τα ιστορικά στοιχεία της τιμής κλεισίματος του δείκτη Crobex. Το μέσο σχετικό σφάλμα και ο μέσος συντελεστής μεταβολής του μέσου τετραγωνικού σφάλματος ρίζας χρησιμοποιήθηκαν για την αξιολόγηση των επιδόσεων του μοντέλου. Τα αποτελέσματα που προκύπτουν δείχνουν ότι κατά τη φάση ελέγχου η προσέγγιση του μοντέλου για την τιμή κλεισίματος του δείκτη Crobex είναι αρκετά ικανοποιητική. Σε οποιαδήποτε από τις 450 ημέρες πρόβλεψης το μέσο σχετικό σφάλμα είναι μικρότερο από 1,5% και ο μέσος συντελεστής μεταβολής του μέσου σφάλματος ρίζας είναι μικρότερος από 2,5%.

3. Θεωρία Νευρωνικών Δικτύων.

3.1 Εισαγωγή στα τεχνητά νευρωνικά δίκτυα.

Τα τεχνητά νευρωνικά δίκτυα αντιπροσωπεύουν μια τεχνολογία που έχει τις ρίζες της σε πολλούς κλάδους όπως τα μαθηματικά, η στατιστική, η ιατρική, η φυσική, η επιστήμη των ηλεκτρονικών υπολογιστών και η μηχανική. Τα τεχνητά νευρωνικά δίκτυα βρίσκουν εφαρμογές σε ποικίλα πεδία όπως η μοντελοποίηση, η ανάλυση χρονοσειρών, η αναγνώριση προτύπων, η επεξεργασία σήματος, χάρη σε μια σημαντική ιδιότητα: την ικανότητα να μαθαίνουν από δεδομένα εισόδου με ή χωρίς επίβλεψη.

Οι εργασίες σχετικά με τα τεχνητά νευρωνικά δίκτυα, που συνήθως αναφέρονται ως “νευρωνικά δίκτυα”, έχουν παρακινηθεί από την έναρξή τους με την αναγνώριση ότι ο ανθρώπινος εγκέφαλος υπολογίζει εντελώς διαφορετικά από τον συμβατικό ηλεκτρονικό υπολογιστή. Ο εγκέφαλος είναι ένας πολύπλοκος, μη γραμμικός και παράλληλος υπολογιστής (με την έννοια ότι ο ανθρώπινο εγκέφαλος είναι ένα σύστημα επεξεργασίας πληροφοριών). Έχει την ικανότητα να οργανώνει τα δομικά συστατικά του, γνωστά ως νευρώνες, ώστε να εκτελεί ορισμένους υπολογισμούς (π.χ. αναγνώριση προτύπων, αντίληψη) πολλές φορές πιο γρήγορα από τον ταχύτερο ψηφιακό υπολογιστή που υπάρχει σήμερα. Κατά τη γέννηση, ο εγκέφαλος έχει μεγάλη δομή και την ικανότητα να δημιουργήσει τους δικούς του κανόνες μέσω αυτού που συνήθως αναφέρεται ως “εμπειρία”. Πράγματι, η εμπειρία δημιουργείται με την πάροδο του χρόνου, με την πιο δραματική εξέλιξη του ανθρώπινου εγκεφάλου να συμβαίνει κατά τα πρώτα δύο χρόνια από τη γέννηση, αλλά η ανάπτυξη συνεχίζεται πολύ πέρα από αυτό το στάδιο.

Ένας “αναπτυσσόμενος” νευρώνας είναι συνώνυμος με έναν “πλαστικό” εγκέφαλο: η πλαστικότητα επιτρέπει στο αναπτυσσόμενο νευρικό σύστημα να προσαρμοστεί στο περιβάλλον του. Η πλαστικότητα του εγκεφάλου αναφέρεται στην ικανότητα του νευρικού συστήματος να αλλάζει τη δομή και τη λειτουργία του καθ’ όλη τη ζωή του, ως αντίδραση στην ποικιλομορφία του περιβάλλοντος (Kolb, Muhammad and Gibb, 2011). Ακριβώς όπως η πλαστικότητα φαίνεται να είναι απαραίτητη για τη λειτουργία των νευρώνων ως μονάδες επεξεργασίας πληροφοριών στον ανθρώπινο εγκέφαλο, έτσι είναι και με τα νευρωνικά δίκτυα που αποτελούνται από τεχνητούς νευρώνες. Στην πιο γενική μορφή του ένα νευρωνικό δίκτυο είναι σχεδιασμένο να μοντελοποιεί τον τρόπο

με τον οποίο ο εγκέφαλος πραγματοποιεί μια συγκεκριμένη εργασία ή λειτουργία. Για την επίτευξη καλών επιδόσεων, τα νευρωνικά δίκτυα χρησιμοποιούν μια μαζική διασύνδεση απλών υπολογιστικών κυττάρων που αναφέρονται ως “νευρώνες” ή “μονάδες επεξεργασίας”. Σύμφωνα με τον Haykin (1998), “Ένα νευρωνικό δίκτυο είναι ένας μαζικά παράλληλος κατανεμημένος επεξεργαστής που αποτελείται από απλές μονάδες επεξεργασίας, το οποίο έχει μια φυσική τάση για την αποθήκευση βιωματικής γνώσης και τη διάθεσή της για χρήση. Αναπαριστά τον εγκέφαλο σε δύο διαδικασίες:

1. Η γνώση αποκτάται από το δίκτυο από το περιβάλλον του μέσα από μια διαδικασία μάθησης.
2. Οι δυνάμεις σύνδεσης στο διαδίκτυο, γνωστές ως συναπτικά βάρη, χρησιμοποιούνται για την αποθήκευση των γνώσεων που αποκτήθηκαν”.

Η διαδικασία που χρησιμοποιείται για τη διεξαγωγή της μαθησιακής διαδικασίας ονομάζεται αλγόριθμος μάθησης, η λειτουργία της οποίας είναι να τροποποιήσει τα συναπτικά βάρη του δικτύου κατά τρόπο ομαλό ώστε να επιτευχθεί ο επιθυμητός σχεδιαστικός στόχος.

3.2 Ιστορική Αναδρομή

Η σύγχρονη εποχή των νευρωνικών δικτύων ξεκίνησε με το πρωτοποριακό έργο των McCulloch και Pitts (1943). Στο κλασσικό τους έγγραφο περιγράφουν λογικούς υπολογισμούς των νευρωνικών δικτύων που ενώνουν τις μελέτες της νευροφυσιολογίας και της μαθηματικής λογικής. Το επίσημο μοντέλο ενός νευρώνα θεωρήθηκε ότι θα ακολουθούσε έναν νόμο “όλα ή τίποτα”. Με έναν επαρκή αριθμό από αυτές τις απλές μονάδες και τις συναπτικές συνδέσεις που λειτουργούν συγχρόνως και έχουν ρυθμιστεί σωστά, οι McCulloch και Pitts έδειξαν ότι ένα τέτοιο δίκτυο θα υπολογίζει, θεωρητικά, οποιαδήποτε υπολογίσιμη συνάρτηση. Αυτό ήταν ένα πολύ σημαντικό αποτέλεσμα και με αυτό, κατά γενική ομολογία, γεννήθηκαν οι κλάδοι των νευρωνικών δικτύων και της τεχνητής νοημοσύνης.

Η επόμενη σημαντική εξέλιξη στα νευρωνικά δίκτυα ήρθε το 1949 με τη δημοσίευση του βιβλίου του Hebb «Η οργάνωση της συμπεριφοράς» (Hebb, 1949), στο οποίο παρουσιάστηκε για πρώτη φορά μια ρητή δήλωση ενός φυσιολογικού κανόνα μάθησης για συναπτική τροποποίηση (τροποποίηση των βαρών μέσω του κανόνα).

Συγκεκριμένα, ο Hebb πρότεινε ότι η συνδεσιμότητα του εγκεφάλου μεταβάλλεται διαρκώς καθώς ο οργανισμός μαθαίνει διαφορετικά λειτουργικά καθήκοντα και ότι οι νευρικές συναθροίσεις δημιουργούνται από αυτές τις αλλαγές. Ο Hebb εισήγαγε το πλέον διάσημο του *αξίωμα της μάθησης*, το οποίο δηλώνει ότι η αποτελεσματικότητα μιας μεταβλητής συνάψεως μεταξύ δύο νευρών αυξάνεται από την επαναλαμβανόμενη ενεργοποίηση ενός νευρώνα από το άλλο κατά τη διάρκεια αυτής της συνάψεως.

Το βιβλίο του Hebb αποτέλεσε πηγή έμπνευσης για την ανάπτυξη υπολογιστικών μοντέλων εκμάθησης και προσαρμοστικών συστημάτων. Η εργασία των Rochester, Holland, Haibt and Duda (1956), είναι ίσως η πρώτη προσπάθεια να χρησιμοποιηθεί προσομοίωση υπολογιστή για να δοκιμαστεί μια καλά διαμορφωμένη νευρωνική θεωρία βασισμένη στο αξίωμα μάθησης του Hebb, τα αποτελέσματα προσομοίωσης που αναφέρθηκαν σε αυτή δείχνουν σαφώς ότι πρέπει να προστεθεί έλεγχος για να λειτουργήσει η θεωρία στην πράξη. Την ίδια χρονιά, ο Uttley (1959) απέδειξε ότι ένα νευρικό δίκτυο με τροποποιήσιμες συνάψεις μπορεί να μάθει να ταξινομεί απλά σύνολα δυαδικών μοτίβων σε αντίστοιχες τάξεις.

Ένα θέμα ιδιαίτερου ενδιαφέροντος για τα νευρωνικά δίκτυα είναι αυτό της σχεδίασης ενός αξιόπιστου δικτύου με νευρώνες που μπορούν να θεωρηθούν ως μη αξιόπιστα στοιχεία το οποίο λύθηκε από τον von Neumann το 1958. Δεκαπέντε χρόνια μετά την έκδοση της εργασίας των McCulloch and Pitts, μια νέα προσέγγιση πάνω στο θέμα της αναγνώρισης προτύπων έγινε από τον Rosenblatt (1958) στην εργασία του πάνω στον αισθητήρα (Perceptron). Το ιδιαίτερο επίτευγμα του ήταν το λεγόμενο Θεώρημα Σύγκλισης Αισθητήρα (Perceptron Convergence Theorem). Είναι ένα πολύ απλό μοντέλο, που έχει μόνο δύο επίπεδα, της εισόδου και της εξόδου. Το σήμα προχωρά μονοδρομικά, από την είσοδο στην έξοδο (τεχνητό νευρωνικό δίκτυο ενός αισθητήρα). Το μοντέλο αυτό στην αρχή είχε πολλές επιτυχίες, δημιούργησε μεγάλο ενθουσιασμό, και μάλιστα ήδη αρχίζει να συζητείται η ιδέα ότι πιθανόν τα νευρωνικά δίκτυα να είναι η πιο ανώτερη τεχνική που λύνει όλα τα προβλήματα που μέχρι τότε παρέμεναν άλυτα. Η ανατροπή έγινε όταν εκδόθηκε το βιβλίο των Minsky και Papert (1969) οι οποίοι με την βοήθεια των μαθηματικών απέδειξαν ότι υπάρχουν όρια όσον αφορά στο τι μπορεί να υπολογιστεί από τον αισθητήρα.

Το 1960, οι Widrow and Hoff παρουσίασαν τον αλγόριθμο ελαχιστοποίησης του μέσου τετραγωνικού σφάλματος και τον χρησιμοποίησαν για να κατασκευάσουν το μοντέλο Adaline (προσαρμοστικό γραμμικό στοιχείο). Η διαφορά μεταξύ του αισθητήρα και

του Adaline βρίσκεται στη διαδικασία της εκπαίδευσης. Ένα από τα πρώτα στρωματοποιημένα νευρικά δίκτυα με πολλαπλά προσαρμοστικά στοιχεία και την δυνατότητα εκπαίδευσης ήταν το μοντέλο Madaline (πολλαπλών-Adaline) που προτάθηκε από τον Widrow και τον φοιτητή του (1962). Μάλιστα αυτά τα μοντέλα ήταν τα πρώτα μοντέλα που χρησιμοποιήθηκαν επιτυχώς για πρακτικά προβλήματα: Χρησιμοποιήθηκαν ως φίλτρα για να εξαλείψουν την ηχώ σε τηλεφωνικές γραμμές.

Το 1982 ο Hopfield χρησιμοποίησε την ιδέα μιας συνάρτησης ενεργοποίησης για να φτιάξει ένα νέο τρόπο κατανόησης του υπολογισμού που γίνεται από τα δίκτυα με συμμετρικές συναπτικές συνδέσεις, δηλαδή συμμετρικές συνδέσεις μεταξύ των νευρώνων. Σε μία εργασία του, μόλις 5 σελίδων, ο Hopfield έδειξε με αυστηρά μαθηματική απόδειξη πως ένα νευρωνικό δίκτυο μπορεί να χρησιμοποιηθεί ως αποθηκευτικός χώρος (storage device), και πως επίσης μπορεί ένα δίκτυο να επανακτήσει όλη την πληροφορία ενός συστήματος έστω και αν του δοθούν μερικά τμήματα μόνο, και όχι ολόκληρο το σύστημα.

Το 1985 αναπτύχθηκε η μέθοδος της οπισθοδιάδοσης (back-propagation) από τους Rumelhart, Hinton and Williams (1985), η οποία κατέληξε να είναι η πιο χρήσιμη σήμερα τεχνική εκπαίδευσης δικτύων. Την ίδια χρονιά κυκλοφόρησε το φημισμένο βιβλίο δύο μερών, Distributed Processing: Exploration in the Microstructures of Cognition, που επεξεργάστηκαν οι Rumelhart and McClelland (1987), το οποίο άνοιξε νέους δρόμους στην εκπαίδευση των νευρωνικών δικτύων. Παρουσιάζεται η ιδέα πως ένα νευρωνικό δίκτυο μπορεί να θεωρηθεί και χρησιμοποιηθεί ως παράλληλος επεξεργαστής. Το έργο αυτό κάνει ένα σημαντικό βήμα πέραν από τον αισθητήρα (perceptron), με το να επιτρέπει την ύπαρξη και άλλων επιπέδων νευρώνων, εκτός από την είσοδο και την έξοδο, που αποτελούν την εσωτερική δομή του δικτύου.

Μετά το 1985 πραγματοποιούνται τα πρώτα συνέδρια που είναι αφιερωμένα αποκλειστικά σε νευρωνικά δίκτυα από την American Physical Society και από την IEEE. Ταυτόχρονα δημιουργούνται ειδικές επαγγελματικές εταιρίες νευρωνικών δικτύων με χιλιάδες μέλη, όπως η International Neural Network Society με τρεις πόλους: Αμερική (Grossberg), Ευρώπη (Kohonen) και Ιαπωνία (Amari). Προς τα τέλη της δεκαετίας του ογδόντα παρουσιάζονται τουλάχιστον πέντε νέα περιοδικά αφιερωμένα αποκλειστικά στα νευρωνικά δίκτυα, ενώ πριν λίγα χρόνια δεν υπήρχε ούτε ένα. Τα τελευταία χρόνια μετά το 1990 εκδίδονται και άλλα 3–4 νέα, με συνέπεια να υπάρχουν σήμερα περίπου 10 επιστημονικά περιοδικά αφιερωμένα στα νευρωνικά


δίκτυα. Φυσικά, και τα γνωστά περιοδικά της Επιστήμης Υπολογιστών, της Φυσικής και των Ηλεκτρολόγων Μηχανικών επίσης περιλαμβάνουν πλειάδα άρθρων με νέα αποτελέσματα στα νευρωνικά δίκτυα. Κάθε μήνα πλέον δημοσιεύονται εκατοντάδες εργασίες με αποκλειστικό θέμα κάποια άποψη των νευρωνικών δικτύων. Μερικά από τα εξειδικευμένα περιοδικά είναι:

- Neural Networks: The Official Journal of the International Neural Network Society (Pergamon Press).
- Network: Computation in Neural Systems (Institute of Physics Publishing).
- International Journal of Neural Systems (World Scientific).
- Neural Computation.
- Connection Science: Journal of Neural Computing, Artificial Intelligence and Cognitive Research (Carfax Publishing).
- Neural Network World: Neural and Massively Parallel Computing and Information Systems (Computer World, Prague) (Αργυράκης, 2002).

3.3 Θεωρία νευρωνικών δικτύων.

3.3.1 Μοντέλα νευρώνων.

Ένας νευρώνας είναι μία μονάδα επεξεργασίας πληροφορίας, που είναι θεμελιακή για την λειτουργία ενός νευρωνικού δικτύου. Το σχήμα 3.3.1 δείχνει το μοντέλο ενός τεχνητού νευρώνα, ο οποίος αποτελεί τη βάση για την σχεδίαση ενός τεχνητού νευρωνικού δικτύου.



Σχήμα 3.3.1: Η μορφή του τεχνητού νευρώνα. (Πηγή: Haykin, 1998)

Τα τρία βασικά στοιχεία αυτού του μοντέλου είναι:

1. Ένα σύνολο από συνάψεις ή συνδετικούς κρίκους, κάθε μία από τις οποίες χαρακτηρίζεται από ένα βάρος ή δύναμη. Συγκεκριμένα, ένα σήμα x_m στην είσοδο της σύναψης m που συνδέεται στον νευρώνα k , πολλαπλασιάζεται με το συναπτικό βάρος w_{km} . Ο πρώτος υποδείκτης αναφέρεται στον εν λόγω νευρώνα και ο δεύτερος στην είσοδο της σύναψης όπου αναφέρεται το βάρος. Το βάρος w_{km} είναι θετικό αν η σύναψη είναι διεγερτική δηλαδή ωθεί τον νευρώνα να αποκριθεί στη διέγερση ενώ αρνητικό αν η σύναψη είναι απαγορευτική δηλαδή αποτρέπει τον νευρώνα να παράγει μία απόκριση.
2. Ένας αθροιστικός κόμβος για την πρόσθεση των σημάτων εισόδου, που παίρνουν βάρος από την αντίστοιχη σύναψη. Αυτές οι λειτουργίες αποτελούν το γραμμικό συνδυαστή u_k .
3. Μια συνάρτηση ενεργοποίησης για τη μείωση του εύρους της εξόδου του νευρώνα.

Το μοντέλο επίσης περιλαμβάνει μια εξωτερικά εφαρμοζόμενη πόλωση (κατώφλι) b_k , που έχει επίδραση στην ελάττωση της εισόδου στην εφαρμοζόμενη συνάρτηση ενεργοποίησης που ακολουθεί. Αντίθετα, η είσοδος του δικτύου μπορεί να αυξηθεί με την χρήση ενός όρου μεροληψίας, ο οποίος είναι ο αντίθετος από τη πόλωση (bias) (Haykin, 1998).

Σε μαθηματικούς όρους μπορούμε να περιγράψουμε το μοντέλο ενός τεχνητού νευρώνα με τις παρακάτω εξισώσεις:

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

και


$$y_k = f(u_k + b_k)$$

Όπου x_1, x_2, \dots, x_m είναι τα σήματα εισόδου, $w_{k1}, w_{k2}, \dots, w_{km}$ είναι τα συναπτικά βάρη του νευρώνα k , u_k είναι ο γραμμικός συνδυαστής εξόδου λόγω των σημάτων εισόδου, b_k είναι η πόλωση, $f(\cdot)$ είναι η συνάρτηση ενεργοποίησης και y_k είναι η έξοδος του σήματος του νευρώνα.

3.3.2 Τύποι συναρτήσεων ενεργοποίησης.

Η συνάρτηση ενεργοποίησης, η οποία συμβολίζεται ως $f(u)$, ορίζει την έξοδο ενός νευρώνα από την άποψη του προκαλούμενου τοπικού πεδίου u . Παρακάτω αναφέρουμε τρεις βασικούς τύπους συναρτήσεων ενεργοποίησης:

1. Βηματικές συναρτήσεις ή συναρτήσεις κατωφλίου (threshold functions).



Σχήμα 3.3.2: Βηματική συνάρτηση ενεργοποίησης. (Πηγή: Haykin, 1998)

Για αυτόν τον τύπο ενεργοποίησης έχουμε:

$$f(u) = \begin{cases} 0, & \text{αν } u \geq 0 \\ 1, & \text{αν } u < 0 \end{cases}$$

Στην βιβλιογραφία των μηχανικών, αυτή η μορφή λειτουργίας κατωφλίου αναφέρεται συνήθως ως λειτουργία Heaviside. Αντίστοιχα, η έξοδος του νευρώνα k που χρησιμοποιεί αυτή τη συνάρτηση κατωφλίου εκφράζεται ως:


$$y_k = \begin{cases} 0, & \text{αν } u \geq 0 \\ 1, & \text{αν } u < 0 \end{cases}$$

όπου u_k είναι το επαγόμενο τοπικό πεδίο του νευρώνα, το οποίο είναι,

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

Ένας τέτοιος νευρώνας αναφέρεται στη βιβλιογραφία ως το μοντέλο McCulloch-Pitts, σε αναγνώριση της πρωτοποριακής εργασίας των McCulloch and Pitts (1943). Σε αυτό το μοντέλο, η έξοδος ενός νευρώνα λαμβάνει την τιμή 1 εάν το προκαλούμενο τοπικό πεδίο αυτού του νευρώνα είναι μη αρνητικό, και 0 διαφορετικά. Αυτή η δήλωση περιγράφει την ιδιότητα “όλα ή τίποτα” του μοντέλου McCulloch-Pitts.

2. Η γραμμική συνάρτηση.




Σχήμα 3.3.3: Γραμμική συνάρτηση ενεργοποίησης (Πηγή: Haykin ,1998)

Για την γραμμική συνάρτηση ενεργοποίησης έχουμε:

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

Αυτή η μορφή μιας συνάρτησης ενεργοποίησης μπορεί να θεωρηθεί ως προσέγγιση σε έναν μη γραμμικό ενισχυτή. Οι ακόλουθες δύο καταστάσεις μπορούν να θεωρηθούν ως ειδικές μορφές της τμηματικής γραμμικής συνάρτησης:

- ένας γραμμικός συνδυασμός προκύπτει εάν η γραμμική περιοχή λειτουργίας διατηρηθεί χωρίς να γίνει κορεσμός
 - η γραμμική συνάρτηση μειώνεται σε μια συνάρτηση κατωφλίου αν ο συντελεστής ενίσχυσης της γραμμικής περιοχής γίνει απείρως μεγάλος.
3. Σιγμοειδής συνάρτηση (sigmoid). Αποτελεί την πιο κοινή μορφή συνάρτησης ενεργοποίησης που χρησιμοποιείται στην κατασκευή τεχνητών νευρωνικών δικτύων.



Σχήμα 3.3.4: Σιγμοειδής συνάρτηση ενεργοποίησης (Πηγή: Haykin ,1998)

Ορίζεται αυστηρά ως αύξουσα συνάρτηση και λαμβάνει τιμές από ένα συνεχές πεδίο τιμών, από 0 έως 1 και είναι διαφορίσιμη σε αντίθεση με την βηματική συνάρτηση. Η λογιστική σιγμοειδής συνάρτηση είναι:


$$f(u) = \frac{1}{1 + e^{-bu}}$$

3.3.3 Αρχιτεκτονική τεχνητών νευρωνικών δικτύων.


Τα νευρωνικά δίκτυα χαρακτηρίζονται από την αρχιτεκτονική τους, τη λειτουργία που επιτελούν και την μέθοδο εκπαίδευσής τους. Η αρχιτεκτονική του δικτύου καθορίζει τη διάταξη των συνδέσεων των νευρώνων καθώς και τον αριθμό και τον τύπο των νευρώνων. Γενικά μπορούμε να αναγνωρίσουμε τρεις θεμελιωδώς διαφορετικές κατηγορίες αρχιτεκτονικών δικτύων:

1. Δίκτυα πρόσθιας τροφοδότησης ενός επιπέδου (feedforward): αποτελούν την πιο απλή μορφή ενός δικτύου. Περιέχουν ένα επίπεδο εισόδου αποτελούμενο από πηγαίους κόμβους, το οποίο δείχνει στο επόμενο επίπεδο νευρώνων εξόδου (υπολογιστικοί κόμβοι) και όχι αντίστροφα. Το σήμα ρέει από το επίπεδο εισόδου προς το επίπεδο εξόδου.

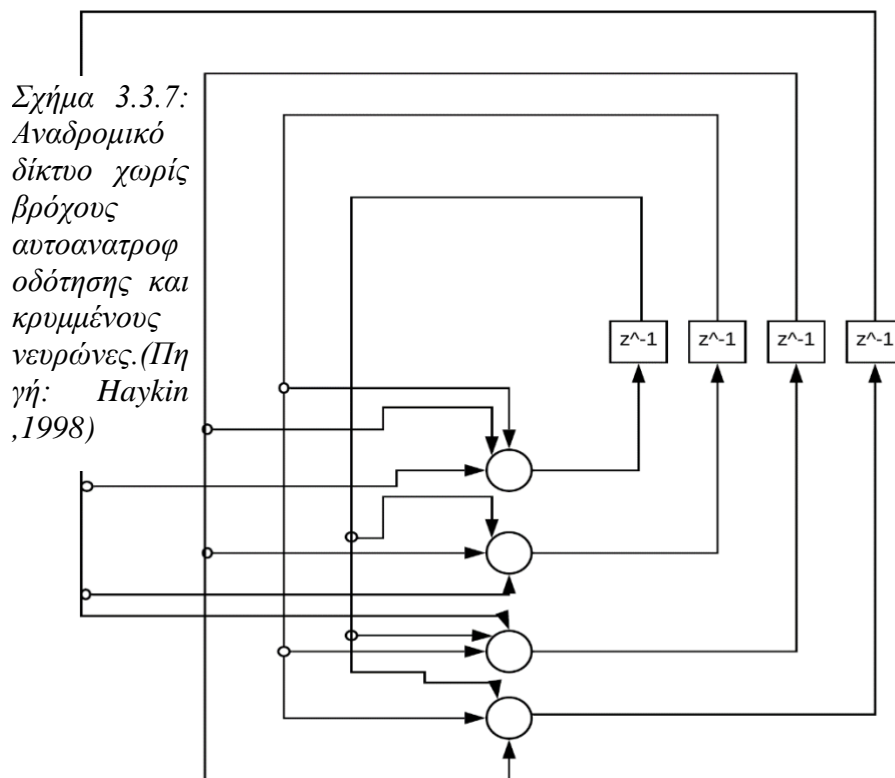
Σχήμα 3.3.5: Δίκτυο πρόσθιας τροφοδότησης ενός επιπέδου. (Πηγή: Haykin, 1998)



2. Πολυεπίπεδα δίκτυα πρόσθιας τροφοδότησης: υπάρχουν ένα ή περισσότερα κρυφά επίπεδα, των οποίων οι νευρώνες ονομάζονται κρυφοί νευρώνες. Οι νευρώνες σε κάθε επίπεδο έχουν σαν εισόδους τα σήματα εξόδου μόνο του προηγούμενου επιπέδου. Το σήμα ρέει από το επίπεδο εισόδου προς το επίπεδο εξόδου μέσω των κρυφών επιπέδων. Δηλαδή και εδώ οι νευρώνες εισόδου απλά μεταφέρουν το σήμα στο επόμενο επίπεδο χωρίς να κάνουν καμία επεξεργασία, ενώ οι κρυφοί νευρώνες και οι νευρώνες εξόδου είναι υπολογιστικοί νευρώνες που ακολουθούν το μοντέλο του νευρώνα. Ένα τέτοιο επίπεδο με ένα κρυφό επίπεδο φαίνεται στο σχήμα 3.3.6.



3. Αναδρομικά δίκτυα (recurrent neural network): σε αυτή την κατηγορία δικτύων υπάρχει τουλάχιστον ένας βρόχος ανάδρασης. Η έξοδος κάθε νευρώνα του δικτύου ανατροφοδοτεί την είσοδο των άλλων νευρώνων του ίδιου επιπέδου και σε μερικές περιπτώσεις ακόμα και τη δική του είσοδο (αυτό-ανάδραση). Η παρουσία βρόχων ανάδρασης επηρεάζει τη δυνατότητα μάθησης του δικτύου και την απόδοσή του. Οι κλάδοι των βρόχων ανάδρασης περιέχουν στοιχεία μοναδιαίας χρονικής καθυστέρησης που συμβολίζονται ως z^{-1} . Ένα αναδρομικό δίκτυο χωρίς αυτό-ανάδραση και κρυφούς νευρώνες φαίνεται στο σχήμα 3.3.7.



3.3.4 Εκπαίδευση νευρωνικών δικτύων.

Όπως αναφέρθηκε και προηγουμένως τα νευρωνικά δίκτυα έχουν την ικανότητα να μαθαίνουν από δεδομένα εισόδου. Η μάθηση ή εκπαίδευση είναι μια θεμελιώδης ικανότητα των τεχνητών νευρωνικών δικτύων, η οποία τους επιτρέπει να εξάγουν πληροφορία από το περιβάλλον τους και να βελτιώνουν την συμπεριφορά τους (Haykin, 1998). Ένα νευρωνικό δίκτυο μπορεί να εκπαιδευτεί ώστε να επιτελεί μια συγκεκριμένη λειτουργία. Τούτο επιτυγχάνεται με κατάλληλη προσαρμογή των συναπτικών βαρών. Η προσαρμογή αυτή των συναπτικών βαρών που θα επιτρέψει στο δίκτυο να επιτελέσει μια συγκεκριμένη λειτουργία ονομάζεται εκπαίδευση του δικτύου (training).

Η εκπαίδευση (training) των νευρωνικών δικτύων μπορεί να χωριστεί σε δύο μεγάλες κατηγορίες (παρόλο που με την τεράστια ανάπτυξη που έχουν γνωρίσει υπάρχουν καινούργιες κατηγορίες δεν θα αναφερθούμε εκτενώς σε αυτές):

- Εκπαίδευση με επίβλεψη (Supervised Learning).
- Εκπαίδευση χωρίς επίβλεψη (Unsupervised Learning).

3.3.4.1 Εκπαίδευση με επίβλεψη.

Τα νευρωνικά δίκτυα εκπαιδεύονται –προσαρμόζονται κατά τρόπο ώστε μια συγκεκριμένη είσοδος (δηλαδή ένα συγκεκριμένο διάνυσμα εισόδου) να δίνει μια συγκεκριμένη-επιθυμητή τιμή στην έξοδο (target output) (Werbos, 1974). Ένα διάνυσμα εισόδου εφαρμόζεται, η έξοδος του δικτύου υπολογίζεται και συγκρίνεται με το αντίστοιχο διάνυσμα στόχο και η διαφορά (λάθος) τροφοδοτείται πίσω διαμέσου του δικτύου. Τα βάρη αλλάζουν σύμφωνα με ένα αλγόριθμο που τείνει να ελαττώσει το λάθος. Τα διανύσματα εισόδου εφαρμόζονται συνεχώς, τα λάθη υπολογίζονται και τα βάρη προσαρμόζονται για το κάθε διάνυσμα μέχρι το λάθος να είναι σε ένα αποδεκτά χαμηλό επίπεδο (G. Barto, S. Sutton and W. Anderson, 1983).

3.3.4.2 Εκπαίδευση χωρίς επίβλεψη.

Η εκπαίδευση χωρίς επίβλεψη είναι πολύ περισσότερο εύλογη σαν μοντέλο μάθησης στα βιολογικά συστήματα. Στην εκπαίδευση χωρίς επίβλεψη παρέχονται στο δίκτυο οι είσοδοι όχι όμως και οι επιθυμητές έξοδοι. Το σύστημα πρέπει έπειτα από μόνο του να αποφασίσει ποια χαρακτηριστικά γνωρίσματα θα χρησιμοποιήσει για να ομαδοποιήσει τα δεδομένα εισόδου. Αυτό αναφέρεται συχνά ως αυτο-οργάνωση ή προσαρμογή (selforganization ή adaption). Το σύνολο των δεδομένων εκπαίδευσης αποτελείται

μόνο από διανύσματα εισόδου. Ο αλγόριθμος εκπαίδευσης αλλάζει τα βάρη του δικτύου για να παράγονται διανύσματα εξόδου που να είναι συνεπή, δηλαδή είτε η εφαρμογή ενός από τα διανύσματα εκπαίδευσης είτε η εφαρμογή ενός διανύσματος που είναι αρκετά όμοιο με αυτό, θα παράγει το ίδιο πρότυπο εξόδου. Η διαδικασία εκπαίδευσης βγάζει της στατιστικές ιδιότητες του συνόλου εκπαίδευσης και ομαδοποιεί τα παρόμοια διανύσματα σε τάξεις. Εφαρμόζοντας ένα διάνυσμα από δοσμένη τάξη στη είσοδο, θα παράγει συγκεκριμένο διάνυσμα εξόδου, αλλά δεν υπάρχει κανένας τρόπος ώστε να καθοριστεί πριν από την εκπαίδευση ποιο συγκεκριμένο πρότυπο εξόδου θα παραχθεί από δοσμένη τάξη διανύσματος εισόδου. Γι' αυτό οι έξοδοι ενός τέτοιου δικτύου πρέπει γενικά να μετατραπούν σε μια κατανοητή μορφή που είναι επακόλουθο της διαδικασίας εκπαίδευσης. Αυτό δεν είναι ένα σοβαρό πρόβλημα. Είναι συνήθως απλό το θέμα της αναγνώρισης της σχέσης εισόδου-εξόδου που έχει εγκαθιδρυθεί από το δίκτυο.

3.4 Πλεονεκτήματα των τεχνητών νευρωνικών δικτύων.

Είναι προφανές ότι ένα νευρικό δίκτυο αποκτά την υπολογιστική του δύναμη μέσω, πρώτον, της μαζικά παράλληλης κατανεμημένης δομής του και, δεύτερον, της ικανότητάς του να μαθαίνει και επομένως να γενικεύει. Η γενίκευση αναφέρεται στο νευρωνικό δίκτυο που παράγει εύλογα αποτελέσματα για εισόδους που δεν συναντήθηκαν κατά τη διάρκεια της εκπαίδευσης (μάθηση). Αυτές οι δύο δυνατότητες επεξεργασίας πληροφοριών καθιστούν δυνατό για τα νευρικά δίκτυα να λύσουν πολύπλοκα (μεγάλης κλίμακας) προβλήματα που είναι επί του παρόντος δύσχρηστα. Σύμφωνα με τον Haykin (1998), τα νευρωνικά δίκτυα παρουσιάζουν τα παρακάτω πλεονεκτήματα:

1. Μη-γραμμικότητα. Αυτή οφείλεται στο γεγονός ότι ένα νευρωνικό δίκτυο δομείται από τη σύνδεση νευρώνων, οι οποίοι είναι μη-γραμμικές συσκευές. Η μη-γραμμικότητα είναι πολύ σημαντική ιδιότητα, ιδιαίτερα αν ο φυσικός μηχανισμός για την παραγωγή των σημάτων εισόδου είναι μη-γραμμικός.
2. Αντιστοίχιση Εισόδου-Εξόδου. Ένα συνηθισμένο παράδειγμα μάθησης, η μάθηση με εκπαιδευτή ή επιβλεπόμενη μάθηση, εμπλέκει τη μεταβολή των συναπτικών βαρών του νευρωνικού δικτύου, εφαρμόζοντας ένα σύνολο δειγμάτων εξάσκησης ή παραδείγματα έργων. Κάθε παράδειγμα αποτελείται από ένα μοναδικό σήμα εισόδου και την επιθυμητή απόκριση. Τα συναπτικά βάρη τροποποιούνται έτσι ώστε να ελαχιστοποιηθεί η διαφορά μεταξύ της επιθυμητής απόκρισης και της

πραγματικής απόκρισης του δικτύου. Η εξάσκηση του δικτύου επαναλαμβάνεται για πολλά παραδείγματα, μέχρι το δίκτυο να φτάσει σε μια σταθερή κατάσταση, όπου πλέον δεν γίνονται αλλαγές στα βάρη. Αν και τα τεχνητά νευρωνικά δίκτυα δεν είναι τα μόνα συστήματα με ικανότητα μάθησης μέσω παραδειγμάτων, εντούτοις διακρίνονται για την ικανότητά τους να οργανώνουν την πληροφορία των δεδομένων εισόδου σε χρήσιμες μορφές. Αυτές οι μορφές αποτελούν στην ουσία ένα μοντέλο που αναπαριστά τη σχέση που ισχύει μεταξύ των δεδομένων εισόδου και εξόδου.

3. Προσαρμοστικότητα. Τα τεχνητά νευρωνικά δίκτυα έχουν την έμφυτη δυνατότητα να προσαρμόζουν τα συναπτικά τους βάρη ανάλογα με τις μεταβολές που γίνονται στο περιβάλλον τους. Ένα τεχνητό νευρωνικό δίκτυο εκπαιδευμένο να λειτουργεί σε συγκεκριμένο περιβάλλον, μπορεί εύκολα να επανεκπαιδευτεί ώστε να μπορεί να χειρίζεται τις όποιες μεταβολές στο νέο περιβάλλον λειτουργίας του.
4. Αποδεικτική απόκριση. Στα πλαίσια της κατηγοριοποίησης μοτίβων, ένα τεχνητό νευρικό δίκτυο μπορεί να σχεδιαστεί να παρέχει πληροφορία όχι μόνο για πιο συγκεκριμένο μοτίβο να επιλεγεί αλλά και για την εμπιστοσύνη στην απόφαση που θα ληφθεί. Αυτή η πληροφορία μπορεί να χρησιμοποιηθεί να για απορριφθούν διφορούμενα μοτίβα, εάν προκύψουν, βελτιώνοντας έτσι τις επιδόσεις ταξινόμησης του δικτύου.
5. Συναφής πληροφορίες. Η γνώση αντιπροσωπεύεται από την ίδια τη δομή και την κατάσταση ενεργοποίησης ενός νευρικού δικτύου. Κάθε νευρώνας στο δίκτυο επηρεάζεται ενδεχομένως από τη δραστηριότητα των άλλων νευρώνων στο δίκτυο. Συνεπώς, οι πληροφορίες με βάση τις συναφής πληροφορίες αντιμετωπίζονται φυσικά από ένα νευρικό δίκτυο.
6. Ανοχή σε σφάλματα. Τα τεχνητά νευρωνικά δίκτυα έχουν μεγάλη ανοχή σε δομικά σφάλματα, υπό την έννοια ότι η απόδοσή τους μειώνεται βαθμιαία και ομαλά υπό αντίξοες συνθήκες λειτουργίας. Αν ένας νευρώνας ή οι συνδέσεις του καταστραφούν, η ποιότητα της εξόδου θα μειωθεί, ωστόσο επειδή η πληροφορία που αποθηκεύεται στο δίκτυο είναι κατανεμημένη σε όλη την δομή του, η βλάβη θα πρέπει να λάβει μεγάλη έκταση για να αρχίσει να μειώνεται σοβαρά η συνολική απόκριση του δικτύου.
7. Υλοποιησιμότητα σε VLSI (Very-large-scale integration). Η συμπαγής παράλληλη φύση του νευρωνικού δικτύου, κάνει δυνατή την υλοποίηση του σε VLSI τεχνολογία (επί της ουσίας με χρήση ηλεκτρονικού υπολογιστή), έτσι ώστε τα

νευρωνικά δίκτυα να μπορούν να χρησιμοποιηθούν σε εφαρμογές πραγματικού χρόνου.

8. Ομοιομορφία ανάλυσης και σχεδίασης. Τα τεχνητά νευρωνικά δίκτυα απολαμβάνουν καθολικής αποδοχής ως επεξεργαστές πληροφοριών, υπό την έννοια ότι χρησιμοποιείται η ίδια σημειογραφία σε όλα τα πεδία εφαρμογής τους. Οι νευρώνες αντιπροσωπεύουν ένα κοινό συστατικό σε όλα τα νευρωνικά δίκτυα και αυτό καθιστά εφικτή τη χρήση των ίδιων θεωριών και αλγορίθμων μάθησης σε διαφορετικές εφαρμογές των νευρωνικών δικτύων.
9. Η ικανότητά τους για αναγνώριση προτύπων (pattern recognition). Τέλος, τα τεχνητά νευρωνικά δίκτυα έχουν εξαιρετική ικανότητα αναγνώρισης προτύπων καθώς δεν επηρεάζονται από ελλιπή ή/και με θόρυβο δεδομένα. Από τη στιγμή που ένα τεχνητό νευρωνικό δίκτυο εκπαιδεύει στο να αναγνωρίζει συνθήκες και καταστάσεις, απαιτείται ένας μόνο κύκλος λειτουργίας τους για να προσδιορίσουν μια συγκεκριμένη κατάσταση.

4. Ασαφή Σύνολα.

4.1 Εισαγωγή στα ασαφή σύνολα.

Η Ασαφής Λογική (Fuzzy Logic) είναι μια επέκταση της κλασικής παραδοσιακής δίτιμης Αριστοτέλειας λογικής, που μας εφοδιάζει με έναν αποτελεσματικό μαθηματικό σκελετό, για την έκφραση γλωσσικών εννοιών και για την παράσταση γνώσεων και πληροφοριών σε περιβάλλον ασάφειας και αβεβαιότητας. Πιο απλά, κατά μια έννοια η «Θεωρία των Ασαφών Συνόλων» μπορεί να θεωρηθεί ότι στοχεύει να μαθηματικοποιήσει, δηλαδή να μοντελοποιήσει, τη φυσική-καθομιλουμένη γλώσσα και την κοινή λογική.

Η κλασική-παραδοσιακή δίτιμη Αριστοτέλεια λογική είναι γνωστή από την Αρχαιότητα (500 π.Χ.), θεμελιώθηκε από τους αρχαίους Έλληνες φιλόσοφους (Αριστοτέλης, Πυθαγόρας, Στωικοί-Χρύσιππος, κ.λπ.) και αποτελεί τη βάση της λεγόμενης δυτικής σκέψης και του δυτικού πολιτισμού. Σύμφωνα με την κλασική δίτιμη λογική μια λογική πρόταση μπορεί να πάρει μόνον δύο τιμές, δηλαδή μπορεί να είναι αληθής ή ψευδής (1 ή 0), αποκλείοντας τρίτη λύση (Αρχή της Απόκλισης του Τρίτου). Έτσι αν μια λογική πρόταση δεν είναι αληθής (άσπρη-1) τότε θα είναι αναγκαία ψευδής (μαύρη-0), ενώ αν δεν είναι ψευδής (μαύρη) τότε θα είναι αναγκαία αληθής (άσπρη). Η δίτιμη Αριστοτέλεια λογική επικράτησε πλήρως από τον 10ο αιώνα στον δυτικό πολιτισμό, για δύο κυρίως λόγους: πρώτον γιατί απλουστεύει κατά πολύ τη συλλογιστική των προβλημάτων, και δεύτερον γιατί αποδίδει απόλυτη «βεβαιότητα» στην απόδειξη και αποδοχή της «αλήθειας» (Θεοδώρου, 2010).

Πολλές όμως από τις αποφάσεις, στον πραγματικό κόσμο, λαμβάνονται σε ένα περιβάλλον στο οποίο οι στόχοι, οι περιορισμοί και οι συνέπειες πιθανόν πράξεων δεν είναι γνωστά επακριβώς. Με πιο απλά λόγια στον πραγματικό κόσμο δεν επικρατεί το ασπρόμαυρο μοντέλο, καθώς οι παράμετροι των προβλημάτων είναι πιο πολύπλοκοι. Μέχρι την ανάπτυξη, και καθιέρωση, των ασαφών συνόλων για να ασχοληθούμε ποσοτικά με την ανακρίβεια, συνήθως χρησιμοποιούσαμε τις έννοιες και τις τεχνικές της θεωρίας των πιθανοτήτων και, ειδικότερα, τα εργαλεία που παρέχονται από τη θεωρία των αποφάσεων, τη θεωρία ελέγχου και τη θεωρία των πληροφοριών. Με αυτόν τον τρόπο, αποδεχόμασταν σιωπηρά την προϋπόθεση ότι η αβεβαιότητα, ανεξάρτητα από το φυσικό της, μπορεί να εξομοιωθεί με τυχαιότητα. Σύμφωνα όμως με τους Bellman and Zadeh (1970), αυτή ήταν μια αμφισβητήσιμη παραδοχή.

Συγκεκριμένα, οι δύο ερευνητές ισχυρίστηκαν πως υπάρχει ανάγκη διαφοροποίησης μεταξύ τυχαιότητας και ασάφειας, με την τελευταία να αποτελεί σημαντική πηγή ανακρίβειών σε πολλές διαδικασίες λήψης αποφάσεων. Με τον όρο ασάφεια, εννοούσαν έναν τύπο ανακρίβειας που σχετίζεται με ασαφή σύνολα, δηλαδή τάξεις στις οποίες δεν υπάρχει έντονη μετάβαση από την ιδιότητα μέλους σε μη μέλος. Είναι αυτός ο τύπος ασάφειας που προκύπτει όταν κάποιος μιλάει, για παράδειγμα, για την τάξη πραγματικών αριθμών που είναι πολύ μεγαλύτεροι από το δέκα, αφού οι πραγματικοί αριθμοί δεν μπορούν να χωριστούν διχοτομικά σε εκείνους που είναι πολύ μεγαλύτεροι από το δέκα και εκείνοι που δεν είναι. Το ίδιο ισχύει για μαθήματα όπως "ψηλοί άνδρες", "καλές στρατηγικές για το παιχνίδι σκακιού", "ζευγάρια αριθμών που είναι περίπου ίσοι μεταξύ τους", "συστήματα που είναι σχεδόν γραμμικά", κλπ. Στην πραγματικότητα, οι περισσότερες κατηγορίες που συναντήσαμε στον πραγματικό κόσμο είναι αυτού του ασαφούς, ασαφώς καθορισμένου είδους. Αυτό που θέτει τέτοιες τάξεις εκτός από τάξεις που είναι καλά καθορισμένες με τη συμβατική μαθηματική έννοια είναι η ασάφεια των ορίων τους. Στην πραγματικότητα, στην περίπτωση μιας τάξης με ένα ασαφές όριο, ένα αντικείμενο μπορεί να έχει έναν βαθμό συμμετοχής σε αυτό που βρίσκεται μεταξύ της πλήρους ένταξης και της μη ένταξης. Μια τάξη που παραδέχεται τη δυνατότητα μερικής συμμετοχής σ' αυτήν, ονομάζεται ασαφές σύνολο (fuzzy set) . Με αυτή την έννοια, η τάξη των ψηλών ανδρών, για παράδειγμα, είναι ένα ασαφές σύνολο, όπως και η τάξη των πραγματικών αριθμών που είναι πολύ μεγαλύτεροι από το δέκα. Μιλούμε για μια ασαφή δήλωση ή ισχυρισμό όταν μερικές από τις λέξεις που εμφανίζονται στη δήλωση ή τον ισχυρισμό εν προκειμένω είναι ονόματα για ασαφή σύνολα. Αυτό ισχύει, για παράδειγμα, από δηλώσεις όπως "το x είναι περίπου ίσο με πέντε", "το y είναι πολύ μεγαλύτερο από δέκα", κλπ. Σε αυτές τις δηλώσεις, οι πηγές ασάφειας είναι οι υπογραμμισμένες λέξεις, οι οποίες, στην πραγματικότητα, είναι ετικέτες για ασαφή σύνολα (Zadeh L.A, 1969).

Τις τελευταίες δεκαετίες παρατηρήθηκε μια ραγδαία ανάπτυξη στον τομέα των ασαφών συνόλων, και ιδιαίτερα στην εφαρμογή τους πάνω στον έλεγχο συστημάτων. Το γεγονός αυτό οφείλεται κατά κύριο λόγο στην αποτελεσματικότητα που έχει επιδείξει η χρήση τους σε έναν σημαντικό αριθμό εφαρμογών κεντρίζοντας έτσι το ενδιαφέρον αρκετών ερευνητών.

4.2 Ιστορική αναδρομή ασαφών συνόλων.

Τα ασαφή σύνολα επινοήθηκαν το 1965 από τον Ρωσοπερσικής καταγωγής καθηγητή του Πανεπιστημίου του Berkeley, Lotfi Zadeh. Ο Zadeh παρατήρησε ότι ο παραδοσιακός τρόπος περιγραφής ενός συστήματος που στηρίζεται στην αυστηρή λογική ότι μια κατάσταση μπορεί να έχει δύο μόνο μορφές, ύπαρξη ή απουσία συνεπάγεται απώλεια πληροφορίας καθώς η πολυπλοκότητα του συστήματος αυξάνεται. Οι πρώτες αντιδράσεις της επιστημονικής κοινότητας απέναντι στην ασαφή θεωρία ήταν αρνητικές, καθώς θεωρήθηκε ότι η «ασάφεια» ήταν είτε αντίθετη στις βασικές επιστημονικές αρχές είτε περιττή, εφόσον υπήρχε η άποψη ότι η πιθανοτική θεωρία ήταν σε θέση να επιλύσει οποιοδήποτε πρόβλημα επέλυε η ασαφής θεωρία κατά τρόπο εξίσου επαρκή, ένα όχι επαρκέστερο.

Αν και πλήθος επιστημόνων άρχισαν να συνεισφέρουν στην κατάστρωση μίας στέρεας μαθηματικής θεωρίας της ασαφούς λογικής και ήδη από τα τέλη της δεκαετίας του 1960 εμφανίστηκαν έννοιες όπως ο ασαφής αριθμός (fuzzy number), ήταν η επιμονή και αφοσίωση του Zadeh που επέτρεψε την επιβίωση της ασαφούς θεωρίας κατά τη διάρκεια της αμφισβήτησής της. Το 1968 πρότεινε την έννοια του ασαφούς αλγορίθμου (fuzzy algorithm), το 1970 μαζί με τον Bellman την έννοια των ασαφούς λήψης αποφάσεων (fuzzy decision making), το 1971 την ασαφή διάταξη (fuzzy ordering), το 1972 τη λεκτική μεταβλητή (linguistic variable) και το 1975 τους ασαφείς κανόνες (fuzzy if-then rules). Σύντομα ακολούθησαν και οι τεχνολογικές εφαρμογές της Ασαφούς Λογικής, κυρίως στα δυναμικά μη-γραμμικά συστήματα ελέγχου (non-linear control systems), όπου συνήθως τα συμβατικά μαθηματικά μοντέλα δεν ισχύουν πια.

Τα συστήματα ελέγχου που βασίζονται στη Fuzzy Logic (Fuzzy Control Systems- Ασαφή Συστήματα Ελέγχου), συνήθως καταφέρνουν να εξομοιώσουν καλύτερα την ανθρώπινη συμπεριφορά-νοημοσύνη καθώς και τις φυσικές γλωσσικές έννοιες, και έτσι συχνά αναφέρονται ως ένα είδος συστημάτων με τεχνητή νοημοσύνη. Ένας από τους πρώτους που χρησιμοποίησε την ασαφή λογική για την κατασκευή ενός Ασαφούς Συστήματος Ελέγχου στη λειτουργία μιας ατμομηχανής, ήταν ο Βρετανός μηχανικός Ebrahim Mamdani κατά τη δεκαετία του 1970. Σήμερα είναι πολυάριθμες σε όλο τον κόσμο οι τεχνολογικές και θεωρητικές εφαρμογές της Ασαφούς Λογικής, ενώ πολλές απ' αυτές μπορούν να χαρακτηριστούν πραγματικά ως τεχνολογικά και επιστημονικά «επαναστατικές». Αναφέρουμε ενδεικτικά την αυτόματη λειτουργία μέσω Ασαφούς Συστήματος Ελέγχου: του μετρό της γιαπωνέζικης πόλης Sendai (από το 1987), μη

επανδρωμένων οχημάτων και αεροσκαφών, τσιμεντοβιομηχανιών, κλιματιστικών, ρομπότ, πλυντηρίων, ιατρικής διάγνωσης και αναισθησίας, αυτόματων καμερών, κ.ά. (Θεοδώρου, 2010).

4.3 Θεωρία ασαφών συνόλων.

Έστω X ένα υπερσύνολο αναφοράς (πεδίο ορισμού) του οποίου τα στοιχεία συμβολίζονται με x . Το ασαφές σύνολο A ορίζεται ως το σύνολο των διατεταγμένων ζευγών $A = \{(x, \mu_A(x)) | x \in X\}$, όπου $\mu_A(x) \in [0,1]$ είναι η συνάρτηση συμμετοχής (βλέπε 4.3.1) του x στο A . Για παράδειγμα, αν $X = \text{“όλοι οι γνωστοί μου”}$, $A = \text{“ψηλός”}$ και $x = \text{“Νίκος”}$ τότε με $\mu_A(x) = 0.8$ δηλώνουμε ότι ο Νίκος είναι ψηλός με βαθμό αληθείας 0.8.

Προφανώς, ο ορισμός ενός ασαφούς συνόλου είναι μια απλή επέκταση του ορισμού ενός κλασικού συνόλου στο οποίο η χαρακτηριστική λειτουργία επιτρέπεται να έχει οποιοσδήποτε τιμές μεταξύ μηδέν και ένα. Εάν η τιμή της συνάρτησης συμμετοχής περιοριστεί σε οποιαδήποτε από τις τιμές μηδέν ή ένα, τότε το σύνολο A “υποβαθμίζεται” σε κλασικό σύνολο και η $\mu_A(x)$ είναι η χαρακτηριστική συνάρτηση του A . Συνεπώς τα κλασικά σύνολα μπορούν να θεωρηθούν σαν μερικές περιπτώσεις των ασαφών συνόλων. Με παρόμοιο συλλογισμό προκύπτει ότι η ασαφής λογική μπορεί να θεωρηθεί ως γενίκευση της κλασσικής λογικής.

4.3.1 Κατηγορίες ασαφών συνόλων.


Όπως τα κλασσικά σύνολα έτσι και τα ασαφή διακρίνονται σε δύο κατηγορίες: (a) τα διακριτά ασαφή σύνολα, τα οποία αναπτύσσονται σε διακριτό πεδίο ορισμού (discrete universe of discourse) τα οποία χωρίζονται σε διατεταγμένα ή μη και (b) τα συνεχή ασαφή σύνολα, τα οποία έχουν συνεχές πεδίο ορισμού (continuous universe of discourse). Θα χρησιμοποιήσουμε τρία παραδείγματα για την καλύτερη κατανόηση των παραπάνω.

Παράδειγμα 4.1: Διακριτό, μη διατεταγμένο, πεδίο ορισμού.

Ορίζουμε ως $X = \{Αθήνα, Θεσσαλονίκη, Χανιά\}$ το σύνολο από πόλεις που μπορεί κάποιος να διαλέξει να ζήσει. Το ασαφές σύνολο $A = \text{“Προτιμητέα πόλη να ζήσεις”}$ μπορεί να διατυπωθεί ως εξής:

$$A = \{(Αθήνα, 0.6), (Θεσσαλονίκη, 0.9), (Χανια, 0.5)\}.$$

Προφανώς το πεδίο ορισμού X είναι διακριτό και περιέχει μη διατεταγμένα στοιχεία, στην περίπτωση μας τρεις μεγάλες πόλεις της Ελλάδας. Ακόμη, είναι εύκολα κατανοητό ότι οι βαθμονομήσεις των πόλεων είναι τελείως υποκειμενικές και ο καθένας μπορεί να θέσει τρεις τελείως διαφορετικές αλλά νόμιμες τιμές για να δείξει τις προτιμήσεις του. Η συνάρτηση συμμετοχής για το συγκεκριμένο ασαφές σύνολο αποτυπώνεται στο σχήμα 4.1.



Σχήμα 4.1: Συνάρτηση συμμετοχής σε ένα διακριτό, μη διατεταγμένο, σύνολο.

Παράδειγμα 4.2: Διακριτό, διατεταγμένο, πεδίο ορισμού.

Ορίζουμε ως $X = \{0, 1, 2, 3, 4, 5, 6\}$ το σύνολο του αριθμού των παιδιών που μπορεί να επιλέξει μια οικογένεια να έχει. Τότε το ασαφές σύνολο $B =$ "λογικός αριθμός παιδιών σε μια οικογένεια" μπορεί να διατυπωθεί ως εξής:

$$B = \{(0, 0.1), (1, 0.3), (2, 0.7), (3, 1), (4, 0.7), (5, 0.3), (6, 0.1)\}$$


Εδώ έχουμε ένα διακριτό διατεταγμένο πεδίο ορισμού. Η συνάρτηση συμμετοχής για το συγκεκριμένο ασαφές σύνολο αποτυπώνεται στο σχήμα 4.2. Και σε αυτήν την περίπτωση, οι βαθμοί συμμετοχής αυτού του ασαφούς συνόλου είναι υποκειμενικοί.

Παράδειγμα 4.3: Συνεχές πεδίο ορισμού.

Ορίζουμε ως $X = \mathbb{R}^+$ το σύνολο των πιθανών ηλικιών που μπορούν να έχουν οι άνθρωποι. Τότε το ασαφές σύνολο $C =$ "περίπου 50 χρονών" μπορεί να διατυπωθεί ως εξής:


$$C = \{x, \mu_C(x) | x \in X\},$$

Όπου, $\mu_B(x) = \frac{1}{1+(\frac{x-50}{10})^4}$.



Η συνάρτηση συμμετοχής για το συγκεκριμένο ασαφές σύνολο αποτυπώνεται στο σχήμα 4.3.

Από τα παραπάνω παραδείγματα γίνεται κατανοητό ότι η κατασκευή ενός ασαφούς



συνόλου εξαρτάται από δύο πράγματα: την αναγνώριση του κατάλληλου πεδίου ορισμού και του καθορισμού της κατάλληλης συνάρτησης συμμετοχής. Ο προσδιορισμός της συνάρτησης συμμετοχής είναι υποκειμενικός γεγονός που οδηγεί σε μεγάλες διαφοροποιήσεις όταν σε ίδια «προβλήματα» η συνάρτηση ορίζεται από διαφορετικά άτομα. Η υποκειμενικότητα προέρχεται από τις προσωπικές

ιδιαιτερότητες του καθενός ως προς την αντίληψη ή έκφραση αφηρημένων εννοιών και ελάχιστη σχέση έχει με την τυχαιότητα. Επομένως, η υποκειμενικότητα και η μη τυχαιότητα των ασαφών συνόλων είναι η κύρια διαφορά μεταξύ της μελέτης αυτών με τη θεωρία της πιθανότητας, η οποία ασχολείται με την αντικειμενική μελέτη τυχαίων γεγονότων (Jang, Sun and Mizutani, 1997).

4.3.2 Ορισμοί – χαρακτηριστικά των ασαφών συνόλων.

4.3.2.1 Λεκτικές μεταβλητές - λεκτικές τιμές.


Στην πράξη όταν το πεδίο ορισμού X είναι συνεχές (ο άξονας των πραγματικών αριθμών (R) ή κάποιο υποσύνολο του), χωρίζεται σε διαφορετικά ασαφή σύνολα των οποίων οι συναρτήσεις συμμετοχής καλύπτουν το X σε κατά έναν περισσότερο ή λιγότερο ομοιόμορφο τρόπο. Αυτά τα ασαφή σύνολα τα οποία συνήθως φέρουν ονόματα που προσαρμόζονται με επίθετα που εμφανίζονται στην καθημερινή γλωσσική μας χρήση, όπως το “μεγάλο”, το “μεσαίο” ή το “μικρό”, ονομάζονται λεκτικές τιμές. Έτσι, το πεδίο ορισμού X συχνά αποκαλείται λεκτική ή γλωσσική μεταβλητή (linguistic variable).

Έστω $X = \text{"Ηλικία"}$. Τότε μπορούμε να ορίσουμε τα ασαφή σύνολα “νέος”, “μεσήλικας” και “ηλικιωμένος” τα οποία χαρακτηρίζονται από τις συναρτήσεις συμμετοχής $\mu_{\text{νέος}}(x)$, $\mu_{\text{μεσήλικας}}(x)$ και $\mu_{\text{ηλικιωμένος}}(x)$ αντίστοιχα. Ακριβώς όπως οι μεταβλητές μπορούν να έχουν διάφορες τιμές, έτσι και η λεκτική μεταβλητή “Ηλικία” μπορεί να έχει διαφορετικές λεκτικές τιμές όπως “νέος”, “μεσήλικας” και “ηλικιωμένος” σε αυτήν την περίπτωση. Εάν η “Ηλικία” πάρει την τιμή “νέος” τότε έχουμε την έκφραση “η ηλικία είναι νέος” και ούτω καθεξής. Τυπικές συναρτήσεις συμμετοχής για τις λεκτικές τιμές του παραδείγματος αποτυπώνονται στο σχήμα 4.4, όπου το πεδίο ορισμού καλύπτεται πλήρως από τα τρία ασαφή σύνολα, δηλαδή για κάθε ηλικία υπάρχει ένα τουλάχιστον ασαφές σύνολο με μη μηδενικό βαθμό συμμετοχής και η μετάβαση από το ένα ασαφές σύνολο στο άλλο γίνεται βαθμιαία.

4.3.2.2 Σύνολο υποστήριξης.

Το σύνολο υποστήριξης ή ενεργός περιοχή ή στήριγμα ή φορέας (support) ενός ασαφούς συνόλου A είναι ένα κλασσικό (σαφές) σύνολο, το οποίο περιέχει όλα τα στοιχεία x του X για τα οποία ισχύει $\mu_A(x) > 0$ (Θεοδώρου, 2010).

$$\text{Support}(A) = \{x \in X | \mu_A > 0\}$$



Πηγή:
Jang,
Sun and
Mizutani
(1997).

4.3.2.2 Ύψος.

Το ύψος (height) ενός ασαφούς συνόλου A είναι η μέγιστη τιμή της συνάρτησης συμμετοχής $\mu_A(x)$ στο δεδομένο πεδίο ορισμού X (Θεοδώρου, 2010).

$$\text{Height}(A) = \sup(\mu_A | x \in X) = \max(\mu_A | x \in X)$$

4.3.2.3 Κανονικό ασαφές σύνολο.

Ένα ασαφές σύνολο καλείται κανονικό ή κανονικοποιημένο (normal – normalized fuzzy set) εάν το ύψος του είναι μονάδα, δηλαδή, $\text{Height}(A) = 1$. Εάν το ύψος είναι μικρότερο της μονάδας, το ασαφές σύνολο καλείται υποκανονικό (subnormal).

4.3.2.4 Πυρήνας.

Πυρήνας ή κόρος (core ή kernel) ενός ασαφούς συνόλου A είναι ένα κλασσικό (σαφές) σύνολο, το οποίο περιέχει όλα τα στοιχεία x του X , για τα οποία ισχύει $\mu_A(x) = 1$. Τα

κανονικά ασαφή σύνολα έχουν κόρο ένα μη κενό σύνολο. Δηλαδή, υπάρχει τουλάχιστον μία τιμή του x για την οποία ισχύει $\mu_A(x) = 1$.

4.3.2.5 Σημείο καμπής.

Ένα σημείο x του πεδίου ορισμού X καλείται σημείο καμπής (crossover point) εφόσον η τιμή της συνάρτησης συμμετοχής στο σημείο αυτό έχει τιμή 0.5:

$$Crossover(A) = \{x \in X | \mu_A(x) = 0.5\}$$


Τα σημεία καμπής του ασαφούς συνόλου για τη λεκτική τιμή “μεσήλικας” που είδαμε προηγουμένως είναι τα 30 και 60. Τα ανωτέρω χαρακτηριστικά των ασαφών συνόλων για το σύνολο για τη λεκτική τιμή «μεσήλικας» απεικονίζονται στο σχήμα 4.5.

4.3.2.6 Σύνολο τομής- α .

Το σύνολο τομής- α (α -cut set) ενός ασαφούς συνόλου A συμβολίζεται με A_α και είναι ένα κλασσικό σύνολο, το οποίο περιέχει όλα τα στοιχεία του πεδίου ορισμού για τα οποία ισχύει:

$$\mu_a \geq \alpha$$

$$A_\alpha = \{x \in X | \mu_A(x) \geq \alpha\}, 0 < \alpha \leq 1$$



4.3.3 Πράξεις Ασαφών Συνόλων.

4.3.3.1 Τομή Ασαφών Συνόλων.

Η τομή (intersection) δύο ασαφών συνόλων A και B , που ορίζονται στο ίδιο πεδίο ορισμού X , είναι ένα ασαφές σύνολο C , το οποίο συμβολίζεται με $C = A \cap B$. Η

συνάρτηση συμμετοχής του C προκύπτει από τις συναρτήσεις συμμετοχής των A και B με χρήση του τελεστή τομής:

$$\mu_c(x) = \mu_A(x) \cap \mu_B(x), \forall x \in X$$

Εναλλακτικά, η τομή δύο ασαφών συνόλων μπορεί να παρασταθεί με μια δυαδική απεικόνιση T που αθροίζει (aggregates) τις δύο συναρτήσεις συμμετοχής ως εξής:

$$\mu_{A \cap B} = T(\mu_A(x), \mu_B(x))$$

Για παράδειγμα ο δυαδικός τελεστής T μπορεί να αντιπροσωπεύει τον πολλαπλασιασμό των $\mu_A(x)$ και $\mu_B(x)$. Αυτού του είδους οι τελεστές τομής αναφέρονται συνήθως ως τ-νόρμες (τριγωνική νόρμα, triangular norm) και πρέπει να ικανοποιούν τις παρακάτω προϋποθέσεις:

1. Οριακές συνθήκες: $T(0,0) = 0, T(a, 1) = T(1, a) = a$.

Η οποία επιβάλλει τη γενίκευση σε σύνολα διακριτών τιμών.

2. Μονοτονία: $T(a, b) \leq T(c, d)$ αν $a \leq c$ & $b \leq d$.

Υπονοεί ότι μια μείωση του βαθμού συμμετοχής στο A ή στο B δεν μπορεί να οδηγήσει σε αύξηση του βαθμού συμμετοχής στην τομή των A και B.

3. Αντιμεταθετικότητα: $T(a, b) = T(b, a)$.

Δείχνει ότι ο τελεστής είναι αδιάφορος στον τρόπο διάταξης με τον οποίο τέμνονται τα δύο σύνολα A και B.

4. Προσεταιριστικότητα: $T(a, T(b, c)) = T(T(a, b), c)$.

Μας επιτρέπει να παίρνουμε την τομή οποιουδήποτε αριθμού συνόλων σε οποιαδήποτε διάταξη ζευγών.

Η τομή δύο ασαφών συνόλων σχετίζεται στην ασαφή λογική με τη λογική πράξη AND («και»), ενώ οι παραπάνω εξισώσεις μπορούν να γενικευθούν σε τομές περισσότερων των δύο ασαφών συνόλων. Στο σχήμα 4.6 βλέπουμε την τομή δύο συνόλων.


4.3.3.2 Ένωση Ασαφών Συνόλων.

Η ένωση δύο ασαφών συνόλων A και B (union), που ορίζονται στο ίδιο πεδίο ορισμού X, είναι ένα ασαφές σύνολο C, το οποίο συμβολίζεται με $C = A \cup B$. Η συνάρτηση συμμετοχής του C προκύπτει από τις συναρτήσεις συμμετοχής των A και B με χρήση του τελεστή ένωσης:

$$\mu_c(x) = \mu_A(x) \cup \mu_B(x), \forall x \in X$$


Όπως η ασαφής τομή έτσι και η ασαφής ένωση εναλλακτικά προσδιορίζεται με μια δυαδική απεικόνιση S .

$$\mu_{A \cup B} = S(\mu_A(x), \mu_B(x))$$



Σχήμα 4.6: Τομή δύο συνόλων A και C .

Για παράδειγμα ο δυαδικός τελεστής S μπορεί να αντιπροσωπεύει το άθροισμα των $\mu_A(x)$ και $\mu_B(x)$. Οι ασαφείς τελεστές ένωσης αναφέρονται συνήθως ως σ-νόρμες και πρέπει να πληρούν τις ίδιες προϋποθέσεις με τις τ-νόρμες. Στο σχήμα 4.7 βλέπουμε την ένωση δύο συνόλων.



Σχήμα 4.7: Ένωση η δύο συνόλων A και B .

4.3.4 Τύποι συναρτήσεων συμμετοχής.

Η μαθηματική περιγραφή των ασαφών συνόλων γίνεται μέσω των συναρτήσεων συμμετοχής (membership functions, MF). Για τις συνεχείς συναρτήσεις συμμετοχής είναι πρακτικά αδύνατη η περιγραφή μέσω των ζευγών ασαφών στοιχείων. Κατά συνέπεια, χρησιμοποιούνται συνεχείς συναρτήσεις, οι οποίες είναι παραμετροποιημένες (parameterized functions). Καθορίζοντας τις παραμέτρους μίας


συνάρτησης συμμετοχής, μεταβάλλονται τα χαρακτηριστικά της (Θεοδώρου, 2010). Υπάρχουν διάφορες συναρτήσεις συμμετοχής, οι οποίες λειτουργούν καλύτερα για διαφορετικά προβλήματα. Οι πιο συνηθισμένες από τις οποίες είναι η τριγωνική, η τραπεζοειδής, η γκαουσιανή και η καμπανοειδής συνάρτηση συμμετοχής.

4.3.4.1 Τριγωνική συνάρτηση συμμετοχής.

Η τριγωνική συνάρτηση συμμετοχής απαιτεί τρεις παραμέτρους (a, b, c) σύμφωνα με την ακόλουθη σχέση, που προτάθηκε από τους Jang, Sun and Mizutani (1997).

$$\text{triangle}(x; a, b, c) = \max \left(\min \left(\frac{x-a}{b-a}, \frac{c-x}{c-d}, 0 \right) \right)$$


Οι παράμετροι $\{a, b, c\}$ (με $a < b < c$) καθορίζουν τις συντεταγμένες x των τριών γωνιών της υποκείμενης τριγωνικής συνάρτησης συμμετοχής την ακόλουθη σχέση, που προτάθηκε από τους Jang, Sun and Mizutani (1997).



4.3.4.2 Τραπεζοειδής συνάρτηση συμμετοχής.

Η τραπεζοειδής συνάρτηση συμμετοχής (trapezoidal membership function) αποτελεί μία τμηματικά γραμμική συνάρτηση (piecewise-linear function). Περιγράφεται από μία τετράδα παραμέτρων $\{a, b, c, d\}$, οι οποίες καθορίζουν την ενεργό περιοχή και τον πυρήνα της, καθώς παρέχουν τις συντεταγμένες των τεσσάρων κορυφών του τραπεζίου.

$$\text{trapezoid}(x; a, b, c, d) = \max \left(\min \left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-x}, 0 \right) \right)$$




Σχήμα 4.9: Τραπεζοειδής συνάρτηση συμμετοχής. Πηγή: Jang, Sun and Mizutani (1997).

4.3.4.3 Γκαουσιανή συνάρτηση συμμετοχής.

Η γκαουσιανή συνάρτηση συμμετοχής (Gaussian membership function) έχει δύο παραμέτρους $\{c, \sigma\}$ και περιγράφεται από τη συνάρτηση:

$$gaussian(x; a, \sigma) = e^{-\frac{1}{2}(\frac{x-c}{\sigma})^2}$$

Η γραφική απεικόνισή της δίνεται στο σχήμα 4.10, όπου οι παράμετροι λαμβάνουν τις τιμές $\{c, \sigma\} = \{50, 20\}$.



Σχήμα 4.10: Γκαουσιανή συνάρτηση συμμετοχής. Πηγή: Jang, Sun and Mizutani (1997).

Η παραπάνω συνάρτηση είναι παρόμοια με τη συνάρτηση πυκνότητας πιθανότητας, η οποία προσδιορίζει τις γκαουσιανές πιθανοτικές κατανομές (Gaussian distributions). Η συνάρτηση είναι συμμετρική, με κέντρο συμμετρίας το c . Η παράμετρος σ είναι η


τυπική απόκλιση της κατανομής και ελέγχει τη διασπορά, δηλαδή το «εύρος» της συνάρτησης συμμετοχής.

4.3.4.4 Γενικευμένη καμπανοειδής συνάρτηση συμμετοχής.

Η γενικευμένη καμπανοειδής ή κωδωνοειδής συνάρτηση συμμετοχής (generalized bell-shaped membership function) παραμετροποιείται από τρεις παραμέτρους $\{a, b, c\}$ και έχει την ακόλουθη μορφή:

$$bell(x; a, b, c) = \frac{1}{1 + \left| \frac{x - c}{a} \right|^{2b}}$$

Η γραφική απεικόνισή της δίνεται στο σχήμα 4.11, όπου οι παράμετροι λαμβάνουν τις τιμές $\{a, b, c\} = \{20, 4, 50\}$.




Η συνάρτηση είναι συμμετρική, με κέντρο συμμετρίας την τιμή της παραμέτρου c . Το σημείο αυτό αποτελεί και τον κόρο της συνάρτησης. Η παράμετρος a ελέγχει το «εύρος» της συνάρτησης, καθώς όσο το a αυξάνει τόσο αυξάνει το «εύρος» της συνάρτησης συμμετοχής, ενώ η παράμετρος b ελέγχει την κλίση της στον ανερχόμενο (αριστερό) και τον κατερχόμενο (δεξιό) κλάδο. Η κλίση στα σημεία καμπής είναι $-\frac{b}{2a}$, κατά συνέπεια, η παράμετρος b ελέγχει τον ρυθμό πτώσης της συνάρτησης από τη μονάδα στο μηδέν. Όσο αυξάνει το b τόσο αυξάνει ο ρυθμός πτώσης και η μετάβαση από τους υψηλούς βαθμούς συμμετοχής στους χαμηλούς βαθμούς συμμετοχής γίνεται πιο απότομη. Για μεγάλες τιμές του b το ασαφές σύνολο παρουσιάζει μεγάλες τιμές συμμετοχής (κοντά στην μονάδα) για όλα τα στοιχεία του συνόλου υποστήριξης και το ασαφές σύνολο τείνει να γίνει σαφές.

4.3.4.5 Σιγμοειδής συνάρτηση συμμετοχής.

Η σιγμοειδής συνάρτηση συμμετοχής έχει δύο παραμέτρους $\{a, c\}$ και περιγράφεται από την ακόλουθη συνάρτηση:

$$\text{sigmoid}(x; a, c) = \frac{1}{1 + \exp(-a)x - c)}$$

Η σιγμοειδής συνάρτηση χρησιμοποιείται ευρέως και ως συνάρτηση ενεργοποίησης (activation function) στα νευρωνικά δίκτυα. Το σημείο $x = c$ είναι το σημείο καμπής. Η παράμετρος a λαμβάνει τόσο θετικές όσο και αρνητικές τιμές. Για $a > 0$ η σιγμοειδής είναι ανοικτή από δεξιά και χρησιμοποιείται για να περιγράψει την περιοχή του πεδίου ορισμού που βρίσκεται στο δεξί όριο, υλοποιώντας την έννοια «πολύ μεγάλο». Για $a < 0$ η συνάρτηση είναι ανοικτή από αριστερά και χρησιμοποιείται για να περιγράψει την περιοχή του πεδίου ορισμού που βρίσκεται στο αριστερό όριο, υλοποιώντας την έννοια «πολύ μικρό». Η τιμή της παραμέτρου a καθορίζει τον ρυθμό μεταβολής της καμπύλης, παίζοντας τον ρόλο του «ασαφοποιητή», κατ' αντιστοιχία με την παράμετρο b της γενικευμένης καμπανοειδούς συνάρτησης



Σχήμα 4.12: Σιγμοειδής συνάρτηση συμμετοχής. (α) Δύο σιγμοειδής συναρτήσεις. (β) Μία κλειστή συνάρτηση συμμετοχής. (γ) Δύο σιγμοειδής συναρτήσεις. (δ) Μία κλειστή συνάρτηση συμμετοχής από τον συνδυασμό των $y1, y2$. Πηγή: Jang, Sun and Mizutani (1997).

4.3.5 Ασαφή συστήματα.

Τα ασαφή συστήματα είναι συστήματα βασισμένα στη γνώση ή βάσει κανόνων. Η καρδιά ενός ασαφούς συστήματος είναι μια βάση γνώσεων που αποτελείται από τους λεγόμενους ασαφείς κανόνες EAN-TOTE (EAN-TOTE). Ένας ασαφής κανόνας EAN-TOTE είναι μια δήλωση EAN-TOTE στην οποία ορισμένες λέξεις χαρακτηρίζονται

από συνεχείς λειτουργίες προσχώρησης. Παραδείγματος χάριν, τα παρακάτω είναι ένας ασαφής κανόνας EAN-TOTE: EAN η ταχύτητα ενός αυτοκινήτου είναι υψηλή, TOTE εφαρμόστε λιγότερη δύναμη στον επιταχυντή. Οι λέξεις υψηλή και λιγότερη χαρακτηρίζονται από μία συνάρτηση ενεργοποίησης (Wang, 1997).

Σύμφωνα με τους Jang, Sun and Mizutani (1997), ένα ασαφές σύστημα αποτελείται από τρία μέρη:

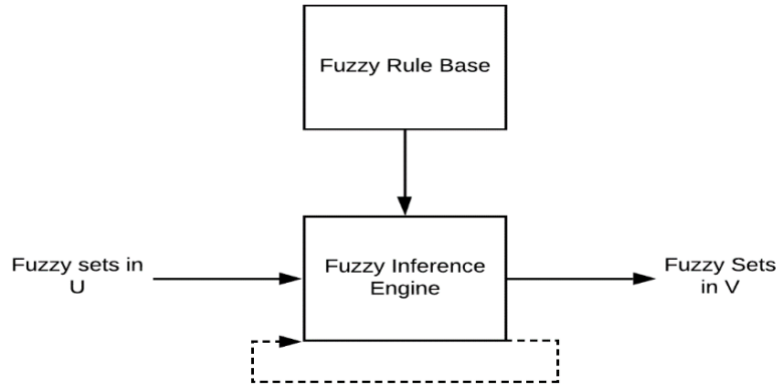
1. τη βάση κανόνων.
2. τη βάση δεδομένων ή το λεξικό που περιλαμβάνει τις συναρτήσεις συμμετοχής.
3. τον μηχανισμό συλλογισμού.

Το σημείο εκκίνησης της κατασκευής ενός ασαφούς συστήματος είναι να αποκτηθεί μια συλλογή ασαφών κανόνων EAN-TOTE από εμπειρογνώμονες ή με βάση τις γνώσεις του τομέα. Το επόμενο βήμα είναι να συνδυάσουμε αυτούς τους κανόνες σε ένα ενιαίο σύστημα. Τα διαφορετικά ασαφή συστήματα χρησιμοποιούν διαφορετικές αρχές γι' αυτούς του συνδυασμούς. Υπάρχουν τέσσερις τύποι ασαφών συστημάτων που χρησιμοποιούνται συνήθως στη βιβλιογραφία:

- i. καθαρά ασαφή συστήματα,
- ii. τα ασαφή συστήματα Mamdani,
- iii. τα ασαφή συστήματα Takagi-Sugeno-Kang (TSK), και
- iv. τα ασαφή συστήματα Tsukamoto.

4.3.5.1 Καθαρά ασαφή συστήματα.

Η βασική διαμόρφωση ενός καθαρού ασαφούς συστήματος φαίνεται στο σχήμα 4.13. Η βάση των ασαφών κανόνων αντιπροσωπεύει τη συλλογή των ασαφών κανόνων EAN-TOTE. Ο μηχανισμός ασαφούς συμπερασμού συνδυάζει αυτούς τους ασαφείς κανόνες EAN-TOTE σε χαρτογράφηση από ασαφή σύνολα στον χώρο εισόδου $U \subset R^n$ σε ασαφή σύνολα στον χώρο εξόδου $V \subset R$ με βάση αρχές ασαφούς λογικής. Εάν υπάρχει η διακεκομμένη γραμμή ανατροφοδότησης που υπάρχει στο σχήμα 4.13, το σύστημα γίνεται το λεγόμενο ασαφές δυναμικό σύστημα.



Σχήμα 4.13: Βασική διαμόρφωση των καθαρών ασαφών συστημάτων. Πηγή: Wang (1997).


4.3.5.2 Τα συστήματα Mamdani.

Το ασαφές σύστημα Mamdani προτάθηκε ως η πρώτη προσπάθεια ελέγχου ενός συνδυασμού ατμομηχανών και λέβητα με ένα σύνολο λεκτικών κανόνων ελέγχου που λήφθηκαν από έμπειρους χειριστές. Το σχήμα 4.14 απεικονίζει ένα σύστημα Mamdani, όπου η τιμή x είναι μέρος τόσο του ασαφούς συνόλου A_1 όσο και του A_2 , η τιμή y ανήκει στα ασαφή σύνολα B_1 και B_2 και η έξοδος Z εκφράζεται από δύο ασαφή σύνολα, C_1 και C_2 . Το σύστημα αυτό έχει βασικά δύο κανόνες:

ΕΑΝ το x είναι στο A_1 και το y στο B_1 ΤΟΤΕ το Z είναι στο C_1 .

ΕΑΝ το x είναι στο A_2 και το y στο B_2 ΤΟΤΕ το Z είναι στο C_2 .


Τα τελικά αποτελέσματα C' χρησιμοποιούνται χρησιμοποιώντας τον χειριστή \max . Μπορεί επίσης να χρησιμοποιηθεί διαφορετικός χειριστής. Όπως αναφέρθηκε



Σχήμα 4.14: Η μέθοδος Mamdani. Πηγή: Atsalakis, Dimitrakakis and Zopounidis (2011).

προηγουμένως, το Mamdani σύστημα παράγει μια ασαφή έξοδο, η οποία πρέπει να από-ασαφοποιηθεί (defuzzified).

Υπάρχουν πέντε διαφορετικές μέθοδοι που πρέπει να χρησιμοποιηθούν: (α) το μικρότερο από το μέγιστο, (β) το μεγαλύτερο από το μέγιστο, (c) το κέντρο της περιοχής (δ) η διχοτόμος της περιοχής και (ε) ο μέσος όρος του μέγιστου. Οι παραπάνω μέθοδοι μπορούν να φανούν στο σχήμα 4.15 (Atsalakis, Dimitrakakis and Zorounidis, 2011).



Σχήμα 4.15: Μέθοδοι από-ασαφοποίησης. Πηγή: Atsalakis, Dimitrakakis and Zorounidis (2011).

4.3.4.3 Τα συστήματα τύπου Sugeno.

Τα ασαφή συστήματα τύπου Sugeno είναι διαφορετικά από τα Mamdani, με την έννοια ότι χρησιμοποιούν μια λειτουργία ως έξοδο και επομένως η έξοδος είναι ήδη ένας σαφής αριθμός και όχι ένα ασαφές σύνολο. Το ίδιο παράδειγμα χρησιμοποιείται όπως και στο σύστημα Mamdani και απεικονίζεται στο σχήμα 4.16. Σε αυτή την μέθοδο οι κανόνες έχουν την εξής μορφή:


ΕΑΝ το x είναι στο A_1 και το y στο B_1 ΤΟΤΕ το $z_1 = p_1 * x + q_1 * r_1$

ΕΑΝ το x είναι στο A_2 και το y στο B_2 ΤΟΤΕ το $z_2 = p_2 * x + q_2 * r_2$


Η τελική έξοδος Z υπολογίζεται χρησιμοποιώντας σταθμισμένο μέσο όρο των z_1 και z_2 . Τα συστήματα τύπου Sugeno είναι λιγότερο απαιτητικά σε υπολογιστική ισχύ, αλλά όχι τόσο ευέλικτα όπως τα συστήματα Mamdani.

4.3.5.4 Τα συστήματα Tsukamoto.

Τα συστήματα Tsukamoto χρησιμοποιούνται λιγότερο συχνά από τα συστήματα τύπου Mamdani και Sugeno. Η διαφορά βρίσκεται πάλι στον τρόπο με τον οποίο υπολογίζεται η έξοδος. Το σύστημα Tsukamoto χρησιμοποιεί μία μονοτονική λειτουργία όπως απεικονίζεται στο σχήμα 4.17.



Σχήμα 4.16: Η μέθοδος Sugeno. Πηγή: Jang, Sun and Mizutani (1997)



Σχήμα 4.17: Η μέθοδος Tsukamoto. Πηγή: Atsalakis, Dimitrakakis and Zopounidis (2011).

5. ΠΡΟΣΑΡΜΟΣΤΙΚΑ ΝΕΥΡΟ-ΑΣΑΦΗ ΣΥΣΤΗΜΑΤΑ (ANFIS).


5.1 Νευρο-ασαφή συστήματα.

Οι Hayashi and Buckley (1994) έδειξαν ότι ένα νευρωνικό δίκτυο πρόσθιας τροφοδότησης θα μπορούσε να προσεγγίσει οποιοδήποτε σύστημα βασισμένο σε ασαφής κανόνες και οποιοδήποτε πρόσθιας τροφοδότησης δίκτυο μπορεί να προσεγγιστεί με ένα σύστημα ασαφούς συμπερασμού βασισμένο σε κανόνες. Ο συνδυασμός των Τεχνητών Νευρωνικών Δικτύων (ANN) και των Ασαφών Συστημάτων Αναφοράς (FIS) έχουν προσελκύσει το αυξανόμενο ενδιαφέρον των ερευνητών σε διάφορους επιστημονικούς και μηχανικούς τομείς λόγω της αυξανόμενης ανάγκης για προσαρμοστικά ευφυή συστήματα για την επίλυση πραγματικών προβλημάτων. Ένα νευρικό δίκτυο μαθαίνει από το μηδέν, ρυθμίζοντας τις διασυνδέσεις μεταξύ των στρωμάτων. Το σύστημα ασαφούς συμπερασμού είναι ένα δημοφιλές πλαίσιο υπολογισμών βασισμένο στην έννοια της ασαφούς θεωρίας των συνόλων, των ασαφών κανόνων EAN-TOTE και της ασαφούς λογικής. Τα πλεονεκτήματα ενός συνδυασμού νευρωνικών δικτύων και συστημάτων ασαφούς συμπερασμού είναι προφανή.

Τα νευρωνικά δίκτυα εισάγουν τα υπολογιστικά τους χαρακτηριστικά της μάθησης στα ασαφή συστήματα και λαμβάνουν από αυτά την ερμηνεία και τη σαφήνεια της αντιπροσώπευσης των συστημάτων. Έτσι, τα μειονεκτήματα των ασαφών συστημάτων αντισταθμίζονται από τις ικανότητες των νευρικών δικτύων. Αυτές οι τεχνικές είναι συμπληρωματικές, πράγμα που δικαιολογεί τη χρήση τους μαζί (Vieira, Dias and Mota, 2004). Ο στόχος των νευρο-ασαφών συστημάτων είναι να συνδυάσουν συλλογικά τα οφέλη τόσο των νευρωνικών δικτύων όσο και της ασαφούς λογικής. Απλά, η λειτουργία του συστήματος εκφράζεται ως γλωσσικές ασαφείς εκφράσεις και τα μαθησιακά σχήματα των νευρωνικών δικτύων χρησιμοποιούνται για να μάθουν το σύστημα. Επιπλέον, τα νευρο-ασαφή συστήματα επιτρέπουν την ενσωμάτωση τόσο των αριθμητικών όσο και των γλωσσικών δεδομένων στο σύστημα. Το νευρο-ασαφές σύστημα είναι επίσης ικανό να εξαγάγει ασαφή γνώση από αριθμητικά δεδομένα.

5.2.2 Παράλληλα νευρο-ασαφή συστήματα.

Ένα παράλληλο σύστημα δεν είναι ένα νευρο-ασαφές σύστημα με τη στενή έννοια, επειδή το νευρωνικό δίκτυο συνεργάζεται με το ασαφές σύστημα (λειτουργούν συνεχώς μαζί). Αυτό σημαίνει ότι οι εισόδους εισέρχονται στο ασαφές σύστημα, προεξεργάζονται και κατόπιν το νευρικό δίκτυο επεξεργάζεται τις εξόδους του ταυτόχρονου συστήματος ή με αντίστροφο τρόπο (τα νευρωνικά δίκτυα προεξεργάζονται τις εισόδους) του ασαφούς συστήματος. Στα παράλληλα νευρο-ασαφή συστήματα, τα αποτελέσματα δεν είναι πλήρως ερμηνεύσιμα, αυτό που μπορεί να θεωρηθεί μειονέκτημα.



Σχήμα 5.2: Παράλληλο νευρο-ασαφές σύστημα.

5.2.3 Υβριδικά νευρο-ασαφή συστήματα.


Σύμφωνα με τους Nauck, Klawonn and Kruse (1997): " Ένα υβριδικό νευρο-ασαφές σύστημα είναι ένα ασαφές σύστημα που χρησιμοποιεί έναν αλγόριθμο μάθησης βασισμένο σε μεθόδους κατάβασης ή εμπνευσμένο από τη θεωρία των νευρωνικών δικτύων για να καθορίσει τις παραμέτρους του (ασαφή σύνολα και ασαφής κανόνες) και την επεξεργασία προτύπων (είσοδος και έξοδος) ". Ένα νευρο-ασαφές σύστημα μπορεί να ερμηνευτεί ως ένα σύνολο ασαφών κανόνων. Αυτό το σύστημα μπορεί να δημιουργηθεί συνολικά από δεδομένα εξόδου εισόδου ή να αρχικοποιηθεί με την εκ των προτέρων γνώση με τον ίδιο τρόπο των ασαφών κανόνων. Το σύστημα που προκύπτει με το συνδυασμό ασαφών συστημάτων και νευρωνικών δικτύων έχει τα πλεονεκτήματα της μάθησης μέσω των προτύπων και την εύκολη ερμηνεία της λειτουργικότητάς του. Υπάρχουν διαφορετικοί τρόποι ανάπτυξης των υβριδικών νευρο-ασαφών συστημάτων, ως εκ τούτου, όντας πρόσφατο ερευνητικό θέμα, κάθε ερευνητής έχει καθορίσει τα δικά του συγκεκριμένα μοντέλα. Αυτά τα μοντέλα είναι παρόμοια στην ουσία τους, αλλά παρουσιάζουν βασικές διαφορές (Vieira, Dias and Mota, 2004).

Πολλοί τύποι νευρο-ασαφούς συστήματος αντιπροσωπεύονται από νευρωνικά δίκτυα που υλοποιούν λογικές λειτουργίες. Αυτό δεν είναι απαραίτητο για την εφαρμογή ενός αλγορίθμου μάθησης σε ένα ασαφές σύστημα, ωστόσο η αναπαράσταση μέσω νευρωνικών δικτύων είναι πιο βολική επειδή επιτρέπει την απεικόνιση της ροής δεδομένων μέσω του συστήματος και των σημάτων σφάλματος που χρησιμοποιούνται για την ενημέρωση των παραμέτρων. Το πρόσθετο όφελος είναι πως επιτρέπει τη σύγκριση των διαφόρων μοντέλων και να απεικονίζει τις δομικές διαφορές του.

5.2.4 Γνωστές νευρο-ασαφείς αρχιτεκτονικές.

Τα τεράστια οφέλη από την χρήση των νευρο-ασαφών συστημάτων έχουν οδηγήσει στην δημιουργία διάφορων μοντέλων με διαφορετικές αρχιτεκτονικές. Στην συνέχεια αναλύουμε μερικές από αυτές επιγραμματικά.


Το Fuzzy Adaptive Learning Control Network (FALCON) (Lin and Lin, 1997). Έχει μια αρχιτεκτονική πέντε επιπέδων. Υπάρχουν δύο γλωσσικοί κόμβοι για κάθε μεταβλητή εξόδου. Ο ένας αφορά τα δεδομένα εκπαίδευσης (επιθυμητή έξοδο) και ο άλλος αφορά την πραγματική έξοδο του FALCON. Το πρώτο κρυφό επίπεδο είναι υπεύθυνο για την ασαφοποίηση κάθε μεταβλητής εισόδου. Κάθε κόμβος μπορεί να είναι ένας μοναδικός κόμβος που αντιπροσωπεύει μια απλή συνάρτηση συμμετοχής (membership function) ή να αποτελείται από κόμβους πολλαπλών στρώσεων που υπολογίζουν μία πολύπλοκη συνάρτηση συμμετοχής. Το δεύτερο κρυφό επίπεδο ορίζει τις προϋποθέσεις του κανόνα, και ακολουθούν οι συνέπειες των κανόνων στο τρίτο κρυφό στρώμα. Το FALCON χρησιμοποιεί έναν αλγόριθμο υβριδικής μάθησης που



περιλαμβάνει μάθηση χωρίς επίβλεψη για τον εντοπισμό αρχικών συναρτήσεων συμμετοχής / βάσης κανόνων και μια εκμάθηση βαθμωτής κατάβασης για τη βέλτιστη

προσαρμογή των παραμέτρων της συνάρτησης συμμετοχής για την παραγωγή των επιθυμητών εξόδων.


Το FuNe I από τους Halgamuge and Glesner (1994). Πρόκειται για ένα ειδικό πολυεπίπεδο δίκτυο τροφοδότησης το οποίο χρησιμοποιώντας δεδομένα εκπαίδευσης και με μια διαδικασία εκπαίδευσης με επίβλεψη μπορεί να εξαγάγει ασαφείς κανόνες από ένα δεδομένο σύνολο δεδομένων εισόδου / εξόδου. Στην πρώτη φάση εξάγονται τυχαίοι κανόνες και στην δεύτερη φάση με τη χρήση των δεδομένων εκπαίδευσης οι κανόνες βελτιστοποιούνται. Δεν υπάρχουν περιορισμοί στον αριθμό των μεταβλητών εισόδου και εξόδου, ενώ κάθε μεταβλητή μπορεί να έχει μέχρι τρεις ασαφείς εισόδους. Επιπρόσθετα, δίνεται η δυνατότητα της περαιτέρω βελτιστοποίησης της βάσης γνώσεων, συμπεριλαμβανομένης της ρύθμισης των συναρτήσεων συμμετοχής.



Το Generalized Approximate Reasoning based Intelligent Control (GARIC) (Berenji and Khedkar, 1992). Εφαρμόζει έναν νευρο-ασαφή ελεγκτή χρησιμοποιώντας δύο μοντέλα ενός νευρωνικού δικτύου, το ASN (Δίκτυο επιλογής δράσης) και το Δίκτυο Αξιολόγησης της Δράσης (AEN). Το AEN είναι ένας προσαρμοστικός κριτικός που αξιολογεί τις ενέργειες του του ASN. Το δίκτυο επιλογής φράσης του GARIC είναι δίκτυο πρόσθιας τροφοδότησης με πέντε επίπεδα. Οι συνδέσεις μεταξύ των στρώσεων δεν είναι σταθμισμένες. Το πρώτο κρυφό επίπεδο αποθηκεύει τις γλωσσικές τιμές όλων


των μεταβλητών εισόδου. Κάθε μονάδα εισόδου συνδέεται μόνο με εκείνες τις μονάδες του πρώτου κρυμμένου επιπέδου, οι οποίες αντιπροσωπεύουν τις σχετικές γλωσσικές τιμές. Το δεύτερο κρυφό επίπεδο αντιπροσωπεύει τους κόμβους των ασαφών κανόνων, οι οποίοι καθορίζουν το βαθμό εκπλήρωσης ενός κανόνα χρησιμοποιώντας μια λειτουργία softmin. Το τρίτο κρυφό επίπεδο αντιπροσωπεύει τις γλωσσικές τιμές της μεταβλητής εξόδου. Τα συμπεράσματα του κανόνα υπολογίζονται ανάλογα με τη δύναμη των κανόνων που υπολογίζεται από το επίπεδο των ασαφών κανόνων. Το GARIC χρησιμοποιεί τη μέθοδο μέσου όρου των μεγίστων (mean-of-maximum, MoM) για τον υπολογισμό των εξόδων του κανόνα. Αυτή η μέθοδος χρειάζεται μια καθαρή τιμή εξόδου από κάθε κανόνα. Συνεπώς, τα συμπεράσματα πρέπει να εφαρμόζεται από-ασαφοποίηση (defuzzification) πριν συσσωρευθούν στην τελική τιμή εξόδου. Το GARIC χρησιμοποιεί ένα μείγμα της μεθόδου βαθμωτής κατάβασης (gradient descent) και ενδυναμωμένης μάθησης (reinforcement learning) για την τελειοποίηση των παραμέτρων των κόμβων.

Το Neuro-Fuzzy Controller (NEFCON) το οποίο δημιουργήθηκε από τους Nauck, Klawonn and Kruse (1994) είναι σχεδιασμένο να εφαρμόζει ασαφή συστήματα τύπου Mamdani. Οι συνδέσεις στο NEFCON σταθμίζονται με ασαφή σύνολα και κανόνες με την ίδια προηγούμενη χρήση που ονομάζονται κοινά βάρη, τα οποία



αντιπροσωπεύονται από ελλείψεις που σχεδιάζονται γύρω από τις συνδέσεις. Εξασφαλίζεται έτσι η ακεραιότητα της βάσης κανόνων. Οι μονάδες εισόδου αναλαμβάνουν την εργασία ασαφοποίησης, η λογική συμπερασμάτων αντιπροσωπεύεται από τις συναρτήσεις διάδοσης και η μονάδα εξόδου είναι η εφαρμογή της από-ασαφοποίησης. Η διαδικασία μάθησης του μοντέλου βασίζεται σε ένα μείγμα της ενδυναμωμένης μάθησης και της μεθόδου της οπισθοδιάδοσης. Το NEFCON μπορεί να χρησιμοποιηθεί για την μάθηση μιας αρχικής βάσης κανόνων, εάν

δεν είναι διαθέσιμες προηγούμενες γνώσεις σχετικά με το σύστημα ή ακόμα και για την βελτιστοποίηση μια βάσης κανόνων που καθορίζεται με το χέρι. Το NEFCON έχει δύο παραλλαγές: NEFPROX (για προσέγγιση των λειτουργιών) και NEFCLASS (για εργασίες ταξινόμησης).



Σχήμα 5.6: Ένα σύστημα NEFCON με δύο εισόδους, πέντε κανόνες και μία έξοδο. Πηγή: Nauck and Kruse (1997)

5.3 Προσαρμοστικό νευρο-ασαφές σύστημα (ANFIS).

Τα μοντέλα που βασίζονται στο ANFIS χρησιμοποιούν έναν αλγόριθμο υβριδικής εκμάθησης που συνδυάζει τη μέθοδο βαθμωτής κατάβασης (gradient descent) και τις ελάχιστες τετραγωνικές μεθόδους για να δημιουργήσει ένα σύστημα ασαφούς συμπερασμού με συναρτήσεις συμμετοχής που προσαρμόζονται επανειλημμένα σύμφωνα με τα δοσμένα δεδομένα εκπαίδευσης εισόδου / εξόδου. Ένα ANFIS έχει σταθερό αριθμό επιπέδων που αντιπροσωπεύουν τη δομή του συστήματος ασαφούς συμπερασμού. Σε σύγκριση με άλλα νευρο-ασαφή συστήματα, ένα ANFIS έχει γρήγορη φάση εκπαίδευσης και απαιτεί ένα απλό λογισμικό για την υλοποίησή του.


5.3.1 Αρχιτεκτονική του ANFIS.

Υποθέτουμε ότι η βάση κανόνων περιέχει δύο ασαφείς κανόνες EAN-TOTE του τύπου Sugeno όπως εξετάσαμε στο κεφάλαιο 4.3.4.3.

Κανόνας 1: EAN το x είναι στο A_1 και το y στο B_1 TOTE το $f_1 = p_1 * x + q_1 * r_1$

Κανόνας 2: EAN το x είναι στο A_2 και το y στο B_2 TOTE το $f_2 = p_2 * x + q_2 * r_2$

Το αντίστοιχο ισοδύναμο της αρχιτεκτονικής του ANFIS, που φαίνεται στο σχήμα 5.7, είναι μία κλάση των προσαρμοστικών δικτύων που είναι λειτουργικά ισοδύναμα με τα FIS. Το ANFIS είναι ένα πολύ-επίπεδο μονόδρομο δίκτυο, όπου κάθε κόμβος εκτελεί μία ειδική λειτουργία στα εισερχόμενα σήματα ανάλογα με ένα σύνολο παραμέτρων συσχετιζόμενων με αυτόν τον κόμβο. Το είδος της λειτουργίας του κάθε κόμβου μπορεί να ποικίλει από κόμβο σε κόμβο, και η επιλογή της λειτουργίας ενός κόμβου εξαρτάται από τη συνολική επεξεργασία πάνω στις εισόδους και την έξοδο που το προσαρμοστικό δίκτυο πρέπει να εκτελέσει. Σημειώνεται ότι οι συνδέσεις σε ένα προσαρμοστικό δίκτυο υποδεικνύουν μόνο την κατεύθυνση ροής των σημάτων μεταξύ των κόμβων και κανένα βάρος δεν συσχετίζεται με αυτές (Jang, 1993).



Σχήμα 5.7: Η αρχιτεκτονική του ANFIS. Πηγή: Jang, Sun and Mizutani (1997)

Για την απεικόνιση των διαφορετικών ικανοτήτων προσαρμοστικότητας χρησιμοποιούνται τόσο κυκλικοί όσο και τετράγωνοι κόμβοι στην αναπαράσταση του δικτύου. Ένας τετράγωνος κόμβος περιλαμβάνει παραμέτρους (adaptive node), ενώ ο κυκλικός κόμβος δεν έχει καμία παράμετρο (fixed node). Το σύνολο των παραμέτρων ενός προσαρμοστικού δικτύου είναι η ένωση των συνόλων των παραμέτρων του κάθε ενός προσαρμοστικού κόμβου. Οι παράμετροι αυτοί ενημερώνονται κατάλληλα, σύμφωνα με τα δοσμένα δεδομένα εκπαίδευσης και μία μέθοδο βαθμωτής κατάβασης,

προκειμένου να επιτευχθεί μία επιθυμητή αντιστοίχιση μεταξύ των δεδομένων εισόδου-εξόδου (Jang, 1993).

Παρουσιάζουμε την αρχιτεκτονική, με βάση το σχήμα 5.7, του ANFIS επίπεδο προς επίπεδο.

Επίπεδο 1: Κάθε κόμβος i σε αυτό το επίπεδο είναι ένας προσαρμοστικός (τετράγωνος-adaptive node) κόμβος που περιλαμβάνει παραμέτρους.

$$O_{1,i} = \mu_{A_i}(x), \text{ for } i = 1, 2, \text{ or}$$

$$O_{1,i} = \mu_{B_{i-2}}(y), \text{ for } i = 3, 4.$$

όπου το x (ή y) είναι η είσοδος στον κόμβο i και το A_i (ή το B_{i-2}) είναι μια γλωσσική τιμή (όπως "μικρή" ή "μεγάλη") που σχετίζεται με αυτόν τον κόμβο. Με άλλα λόγια, $O_{1,i}$ είναι ο βαθμός προσχώρησης ενός ασαφούς συνόλου A ($= A_1, A_2, B_1$ ή B_2) και καθορίζει το βαθμό στον οποίο η δεδομένη είσοδος x (ή y) ικανοποιεί τον ποσοτικό παράγοντα A . Η συνάρτηση για το A μπορεί να είναι οποιαδήποτε κατάλληλη παραμετροποιημένη συνάρτηση συμμετοχής, όπως είδαμε στην ενότητα 4.3.3, όπως η γενικευμένη καμπανοειδής συνάρτηση (βλέπε 4.3.3.4):

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b}}$$

όπου το $\{a_i, b_i, c_i\}$ είναι το σύνολο παραμέτρων. Καθώς αλλάζουν οι τιμές αυτών των παραμέτρων, η γενικευμένη καμπανοειδής συνάρτηση ποικίλλει αναλόγως, παρουσιάζοντας έτσι διάφορες μορφές συναρτήσεων συμμετοχής για το ασαφές σύνολο A . Οι παράμετροι σ' αυτό το επίπεδο αναφέρονται ως παράμετροι προαίρεσης (premise parameters).

Επίπεδο 2: Κάθε κόμβος σε αυτό το επίπεδο είναι ένας σταθερός κόμβος, με την ένδειξη Π, του οποίου η έξοδος είναι προϊόν όλων των εισερχομένων σημάτων:

$$O_{2,i} = w_i = \mu_{A_i}(x) \mu_{B_i}(y), i = 1, 2$$

Επίπεδο 3: Κάθε κόμβος σε αυτό το επίπεδο είναι ένας σταθερός κόμβος με την ένδειξη Ν. Ο κόμβος i th υπολογίζει τον λόγο της ισχύς (δύναμη πυροδότησης-firing strength) του κανόνα i (μετρά τον βαθμό στον οποίο ο κανόνας ταιριάζει με τις εισόδους) ως προς το άθροισμα ισχύς όλων των κανόνων:

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1,2$$

Για λόγους ευκολίας, οι έξοδοι αυτού του στρώματος ονομάζονται κανονικοποιημένες δυνάμεις πυροδότησης.

Επίπεδο 4: Κάθε κόμβος i σε αυτό το επίπεδο είναι ένας προσαρμοστικός (τετράγωνος-adaptive node) κόμβος που περιλαμβάνει παραμέτρους.

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i)$$

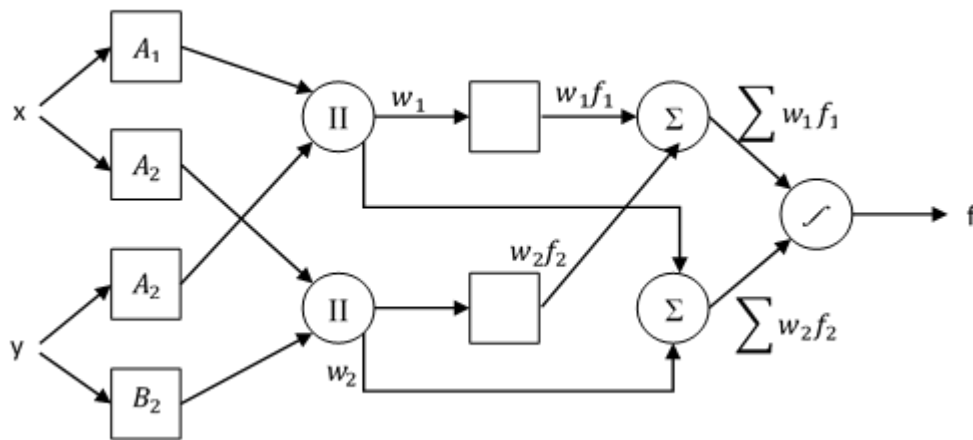
Όπου \bar{w}_i είναι η κανονικοποιημένη δύναμη πυροδότησης του επιπέδου 3 και $\{p_i, q_i, r_i\}$ είναι το σύνολο παραμέτρων αυτού του κόμβου. Οι παράμετροι σ 'αυτό το επίπεδο αναφέρονται ως επακόλουθοι παράμετροι.

Επίπεδο 5: Ο μοναδικός κόμβος σε αυτό το στρώμα είναι ένας σταθερός κόμβος με την ένδειξη Σ , ο οποίος υπολογίζει τη συνολική έξοδο ως άθροιση όλων των εισερχομένων σημάτων:

$$overall\ output = O_{5,1} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

Παρουσιάστηκε πως κατασκευάζεται ένα προσαρμοστικό δίκτυο που είναι λειτουργικά ισοδύναμο με ένα μοντέλο ασαφούς Sugeno. Σημειώνεται ότι η δομή αυτού του προσαρμοστικού δικτύου δεν είναι μοναδική. Συνδυάζοντας τα επίπεδα 3 και 4 είναι δυνατόν να αποκτήσουμε ένα ισοδύναμο δίκτυο με μόνο τέσσερα στρώματα. Με τον ίδιο τρόπο, η κανονικοποίηση των βαρών μπορεί να εκτελεστεί στο τελευταίο επίπεδο, όπως παρουσιάζεται στο σχήμα 5.8. Στην ακραία περίπτωση, γίνεται να συρρικνωθεί ολόκληρο το δίκτυο σε έναν ενιαίο προσαρμοστικό κόμβο με το ίδιο σύνολο παραμέτρων. Προφανώς, η αντιστοίχιση των λειτουργιών κόμβου και της

διαμόρφωσης δικτύου είναι αυθαίρετες, εφόσον κάθε κόμβος και κάθε στρώμα εκτελούν ουσιαστικές και αρθρωτές λειτουργίες (Jang, Sun and Mizutani, 1997b).



Σχήμα 5.8: Η αρχιτεκτονική ANFIS για το ασαφές μοντέλο Sugeno, όπου η κανονικοποίηση των βαρών εκτελείται στο τελευταίο επίπεδο. Πηγή: Jang, Sun and Mizutani (1997)

5.3.2 Εκπαίδευση του ANFIS.

Η εκπαίδευση του συστήματος απαιτεί τον καθορισμό των παραμέτρων των συναρτήσεων ενεργοποίησης και των παραμέτρων των συναρτήσεων εξόδου του ασαφούς συστήματος τύπου Sugeno $\{p_i, q_i, r_i\}$. Τα τελευταία βρίσκονται στα επίπεδα 4 και 5 του συστήματος ANFIS. Ο Jang (1993) πρότεινε μια υβριδική μέθοδο για τη βελτιστοποίηση του συστήματος ANFIS, χρησιμοποιώντας δύο φάσεις, ένα πέρασμα προς τα εμπρός και ένα πέρασμα προς τα πίσω (βλέπε πίνακα 1). Το μπροστινό πέρασμα (forward pass) χρησιμοποιεί τη μέθοδο των ελαχίστων τετραγώνων για να βελτιστοποιήσει τις επακόλουθες παραμέτρους $\{p_i, q_i, r_i\}$ στα επίπεδα τέσσερα και πέντε, ενώ το πίσω πέρασμα (backward pass) χρησιμοποιεί μία μέθοδο βαθμωτής κατάβασης όπως ο αλγόριθμος οπισθοδιάδοσης, για να βελτιστοποιήσει τις παραμέτρους προαίρεσης των συναρτήσεων συμμετοχής που χρησιμοποιούνται ως εισροές στα επίπεδα ένα έως τρία. Οι παράμετροι του ANFIS βελτιστοποιούνται σε δύο ομάδες (παράμετροι προαίρεσης και επακόλουθες) για τη μείωση της υπολογιστικής ισχύος, καθώς οι επακόλουθες παράμετροι είναι γραμμικές και συνεπώς μπορεί να χρησιμοποιηθεί μια γραμμική μέθοδος όπως η μέθοδος των ελαχίστων τετραγώνων, ενώ οι παράμετροι προαίρεσης είναι μη γραμμικές.

Πίνακας 5.1: Δύο περάσματα στην μέθοδο υβριδικής μάθησης για το ANFIS. Πηγή: Jang (1993)

-	Μπροστινό Πέρασμα	Πίσω Πέρασμα
Παράμετροι Προαίρεσης	Σταθερές	Βαθμωτή Κατάβαση
Επακόλουθες Παράμετροι	Μέθοδος Ελαχίστων Τετραγώνων	Σταθερές
Σήματα	Έξοδοι Κόμβων	Ρυθμός Σφάλματος

5.3.2.1 Μπροστινό πέρασμα.

Στο μπροστινό πέρασμα, παρέχονται δεδομένα εισόδου και λειτουργικά σήματα προχωρούν προς τα εμπρός για να υπολογίσουν την έξοδο κάθε κόμβου. Η τελική έξοδος του συστήματος ANFIS είναι συνάρτηση των παραμέτρων p , q , r :

$$O_{5,1} = \sum_i \bar{w}_i f_i = (\bar{w}_1 x_1) p_1 + (\bar{w}_1 x_2) q_1 + (\bar{w}_1) r_1 + (\bar{w}_2 x_1) p_2 + (\bar{w}_2 x_2) q_2 + (\bar{w}_2) r_2$$

5.3.2.2 Πίσω πέρασμα.

Κατά τη διάρκεια του περάσματος προς τα πίσω, οι παράμετροι των συναρτήσεων συμμετοχής βελτιστοποιούνται. Η μέθοδος βαθμωτής κατάβασης βασίζεται στην ελαχιστοποίηση μιας συνάρτησης κόστους. Η συνάρτηση κόστους προκύπτει από το άθροισμα του τετραγώνου των σφαλμάτων. Υποθέτοντας ότι τα δεδομένα έχουν p εισόδους τότε:

$$J_p = \sum_{i=1}^L (T_{i,p} - O_{i,p}^L)^2$$

Όπου $T_{i,p}$ είναι το i -στο στοιχείο του p -οστού διανύσματος που παράγεται από την p -ιστή είσοδο και L το επίπεδο του συστήματος. Το συνολικό σφάλμα είναι:

$$J = \sum_{p=1}^p J_p$$

Για να χρησιμοποιηθεί η μέθοδος βαθμωτής κατάβασης, πρέπει να υπολογιστεί ο ρυθμός σφάλματος $\frac{\partial J_p}{\partial o}$ του p -οστού σετ εισόδου των δεδομένων εκπαίδευσης. Το ποσοστό σφάλματος για τον κόμβο εξόδου στο επίπεδο L και το στοιχείο προέρχονται από την προηγούμενη συνάρτηση χρησιμοποιώντας τη παράγωγο:

$$\frac{\partial J_p}{\partial O_{i,p}^L} = -2(T_{i,p} - O_{i,p}^L)$$

για τον εσωτερικό κόμβο ο ρυθμός σφάλματος είναι:

$$\frac{\partial J_p}{\partial O_{i,p}^k} = \sum_{m=1}^{(k+1)} \frac{\partial J_p}{\partial O_{m,p}^{k+1}} \frac{\partial O_{m,p}^{k+1}}{\partial O_{i,p}^k}$$

Όπου $1 \leq k \leq L - 1$. Συμπερασματικά, το ποσοστό σφάλματος ενός εσωτερικού κόμβου είναι μια γραμμική συνάρτηση των ποσοστών σφάλματος των κόμβων των επόμενων επιπέδων. Έτσι, συνδυάζοντας τις προηγούμενες λειτουργίες, μπορεί να υπολογιστεί κάθε σφάλμα. Για την παράμετρο “a” μιας συνάρτησης ενεργοποίησης:

$$\frac{\partial J_p}{\partial a} = \sum_{O \in S} \frac{\partial J_p}{\partial O} \frac{\partial O}{\partial a}$$

όπου το S υποδεικνύει τους κόμβους που περιλαμβάνουν την παράμετρο “a”. Η παράγωγος του συνολικού κόστους (σφάλματος) J για την παράμετρο είναι:

$$\frac{\partial J}{\partial a} = \sum_{p=1}^p \frac{\partial J_p}{\partial a}$$

Σε κάθε επανάληψη (εποχή-epoch), η παράμετρος a βελτιστοποιείται ανάλογα με τη συνάρτηση:

$$\Delta a = -\eta \frac{\partial J}{\partial a}$$

όπου η είναι ο ρυθμός εκμάθησης που αλλάζει κατά τις επαναλήψεις του αλγορίθμου σύμφωνα με την ακόλουθη σχέση:

$$\eta = \frac{k}{\sqrt{\sum_a (\frac{\partial J}{\partial a})^2}}$$

όπου το k είναι το μέγεθος βήματος, μια πολύ σημαντική παράμετρος ώστε να βρεθεί το βέλτιστο. Ένα πολύ μικρό k μπορεί να παγιδεύσει τον αλγόριθμο σε ένα τοπικό βέλτιστο αντί για ένα ολικό βέλτιστο. Από την άλλη πλευρά, ένα υψηλότερο μέγεθος βήματος μπορεί να προσπεράσει το τοπικό ή ολικό βέλτιστο. Η τιμή k επηρεάζει επίσης την ταχύτητα του αλγορίθμου με τις μεγαλύτερες τιμές να οδηγούν σε ταχύτερη εκτέλεση του αλγορίθμου.

Οι παράμετροι που χρειάζεται το ANFIS είναι:

1. Ο τύπος των συναρτήσεων συμμετοχής.
2. Ο αριθμός των συναρτήσεων συμμετοχής για κάθε είσοδο.
3. Οι εποχές-επαναλήψεις του αλγόριθμου εκπαίδευσης.
4. Το μέγεθος βήματος.

6. Εφαρμογή του ANFIS για την πρόβλεψη της τάσης του γενικού δείκτη του Χρηματιστηρίου Αθηνών.

Σκοπός της παρούσας εργασίας είναι η ανάπτυξη ενός συνολικού νευρο-ασαφούς συστήματος που αποτελείται από έναν ελεγκτή (Adaptive Neuro-Fuzzy Inference System – ANFIS), για την πρόβλεψη με όσο το δυνατόν πιο ακριβή τρόπο της τάσης της χρηματιστηριακής αγοράς της επόμενης ημέρας χρησιμοποιώντας ιστορικά δεδομένα για τις τιμές κλεισίματος των μετοχών.

6.1 Δεδομένα.

Ξεκινήσαμε συλλέγοντας τις τιμές κλεισίματος του συνόλου των μετοχών καθώς και του γενικού δείκτη, του ελληνικού Χρηματιστηρίου Αθηνών από την ιστοσελίδα της Ναυτεμπορικής. Η περίοδος που καλύψαμε είναι από τις 2/1/2009 μέχρι και τις 31/12/2018 και περιλαμβάνει 2466 ημέρες, το ενδιαφέρον μας εστιάζεται σε βραχυπρόθεσμη πρόβλεψη (τάση) γι' αυτό τα δεδομένα λαμβάνονται σε καθημερινή βάση. Σημειώνεται ότι παρότι ο αριθμός των μετοχών δεν είναι ίδιος για κάθε ημέρα στα δεδομένα δεν επηρεάζεται η ποιότητα του δείγματός μας, καθώς οι όποιες αλλαγές στο σύνολο αποτυπώνονται από τον δείκτη που θα κατασκευαστεί αλλά και από τον ίδιο τον γενικό δείκτη. Μάλιστα, το γεγονός αυτό συμβάλει στην σημαντικότητα της παρούσας εφαρμογής διότι το μοντέλο λαμβάνει υπόψιν όλες τις διαφοροποιήσεις και αλλαγές που επιτελούνται.

Προχωρήσαμε στην μορφοποίηση των δεδομένων μας ώστε να είναι άμεσα αξιοποιήσιμα. Για τον σκοπό αυτό για κάθε ημέρα του δείγματός μας βρήκαμε το σύνολο των ανοδικών και καθοδικών μετοχών αλλά και την μεταβολή του γενικού δείκτη. Τέλος, κωδικοποιούμε την μεταβολή του γενικού με σκοπό να κλιμακωθούν μεταξύ των ορίων [0 1] μιας συνάρτησης μεταφοράς.

6.2 Κατασκευή του δείκτη.


Στην συνέχεια κατασκευάζουμε τον εξής δείκτη με βάση τα σύνολα που εντοπίσαμε κατά την μορφοποίηση:

$$\text{Δείκτης Τάσης} = \frac{\text{Σύνολο Ανοδικών Μετοχών}}{\text{Σύνολο Καθοδικών Μετοχών}}$$

Ο Δείκτης Τάσης είναι η είσοδος του συστήματος μας και με βάση αυτόν θα γίνει η εκπαίδευση και ο έλεγχος του.

6.3 Εφαρμογή στα δεδομένα.


Για την κατασκευή του μοντέλου και την εφαρμογή του χρησιμοποιούμε το λογισμικό της Matlab έκδοση R2018b. Πρωταρχικά χωρίζουμε τα δεδομένα μας σε δεδομένα εκπαίδευσης (training data) και δεδομένα ελέγχου (checking data) με αναλογία 75% (1849 εγγραφές) και 25% (617 εγγραφές) αντίστοιχα. Στην εικόνα 6.1 παρουσιάζονται τα διαγράμματα διασποράς των δεδομένων εκπαίδευσης και ελέγχου. Τα δεδομένα της μεταβολής του γενικού δείκτη (Ratio of FTSE, άξονας y) παρουσιάζονται με βάση την κωδικοποίηση [0 1] που εφαρμόζουμε με το 0 να αντιπροσωπεύει τον δείκτη όταν είναι καθοδικός και 1 όταν είναι ανοδικός. Ενώ ο δείκτης τάσης (Ratio, άξονας x) δεν κωδικοποιείται.



Σχήμα 6. Error! Use the Home tab to apply 0 to the text that you want to appear
Στην συνέχεια προχωρούμε στην δημιουργία του μοντέλου FIS τύπου Sugeno που χρησιμοποιείται ως αρχικές συνθήκες (αρχικοποίηση των παραμέτρων συνάρτησης συμμετοχής) για την κατάρτιση του μοντέλου ANFIS. Σε αυτό το σημείο πρέπει να ορίσουμε τις παραμέτρους που αναλύσαμε στο τέλος του κεφαλαίου [5.3.2](#). Επί της ουσίας σε αυτό το σημείο για να βρούμε τις καλύτερες ρυθμίσεις ώστε να έχουμε το καλύτερο αποτέλεσμα του μοντέλου ως προς την προβλεπτική του ικανότητα χρησιμοποιούμε ως επί τον πλείστον την μέθοδο δοκιμής και λάθους (trial and error).

Σημειώνεται ότι για τις εποχές-επαναλήψεις του αλγόριθμου εκπαίδευσης μπορούμε να βρούμε σε κάθε συνάρτηση συμμετοχής, προσεγγιστικά και θεωρώντας τις

υπόλοιπες παραμέτρους σταθερές, τις ελάχιστες που απαιτούνται. Με βάση το διάγραμμα της ρίζας της μέσης τετραγωνικής απόκλισης σε σχέση με τις εποχές-επαναλήψεις για τα δεδομένα ελέγχου, ένα παράδειγμα του οποίου παρουσιάζεται στο σχήμα 6.2, βρίσκουμε μετά από πόσες επαναλήψεις ο αλγόριθμος δεν παίρνει παραπάνω γνώση (δεν αλλάζει το αποτέλεσμα προς το καλύτερο ως προς την προβλεπτική ικανότητα του μοντέλου). Είναι σημαντικό να επισημάνουμε ότι το σφάλμα της ρίζας της μέσης τετραγωνικής απόκλισης υπολογίζεται σε σχέση με τη πραγματική και τη προβλεπόμενη τιμή και όχι με βάση την τάση, επομένως στην



εκπαίδευσης και
ελέγχου.

περίπτωσή μας αποτελεί μια ένδειξη για τον βέλτιστο αριθμό επαναλήψεων και δεν μπορεί να χρησιμοποιηθεί για να εντοπιστεί αυτός.

Στο σχήμα 6.2 χρησιμοποιούμε τις εξής ρυθμίσεις: αριθμός επαναλήψεων 1000, ο αριθμός των συναρτήσεων συμμετοχής για κάθε είσοδο είναι 2, ο τύπος των συναρτήσεων ενεργοποίησης είναι η τριγωνική συνάρτηση και το μέγεθος βήματος είναι 0.01. Βλέπουμε ότι τυπικά (ρεαλιστικά και με μικρότερο αριθμό) μετά τις 100 επαναλήψεις δεν υπάρχει ριζική αλλαγή ως προς το σφάλμα επομένως για την εν λόγω συνάρτηση συμμετοχής αρκούν 100 επαναλήψεις. Με τον ίδιο τρόπο βρίσκουμε τον ελάχιστο αριθμό επαναλήψεων και για τις υπόλοιπες συναρτήσεις συμμετοχής. Σημειώνεται ότι οι γενικευμένη καμπανοειδής και η γκαουσιανή είναι οι μόνες που χρειάζονται, θεωρητικά, πάνω από 100 επαναλήψεις αλλά καμία πάνω από 150, επομένως σε καμία από τις δοκιμές μας δεν θα ξεπεράσουμε τις 200 εποχές-επαναλήψεις.

6.4 Μεθοδολογία αξιολόγησης του μοντέλου.

Υπάρχουν πολλές μετρήσεις που μπορούν να χρησιμοποιηθούν για τη μέτρηση της απόδοσης ενός προβλεπτικού ή ταξινομικού μοντέλου. Διαφορετικά πεδία έχουν διαφορετικές προτιμήσεις για συγκεκριμένες μετρήσεις λόγω διαφορετικών στόχων. Η εξαρτημένη μεταβλητή, την ορίζουμε ως y , ταξινομείται ως 1 εάν δείκτης είχε ανοδική πορεία και 0 εάν είχε καθοδική. Στο σύνολο των δεδομένων μας έχουμε 1236 μέρες όπου ο γενικό δείκτης είχε ανοδική πορεία και 1230 μέρες στις οποίες ήταν καθοδικός.

Στην προκειμένη περίπτωση θα χρησιμοποιήσουμε τις ίδιες μετρήσεις για τη δοκιμή της απόδοσης του προτεινόμενου μοντέλου με τις μετρήσεις που προτείνουν οι Atsalakis, Atsalaki and Zopounidis (2018):

- Ψευδώς θετικό (False Positive - FP) ή σφάλμα τύπου I, λαμβάνει χώρα όταν η εξαρτημένη μεταβλητή έχει λανθασμένη επισήμανση ως 1 (ανοδική τάση), με $y = 1$ όταν $y = 0$. Στην πραγματικότητα, μια καθοδική τάση κατατάσσεται ως ανοδική όταν $[Rate\ of\ FP = (\text{αριθμός ψευδών θετικών} / \text{αριθμός δειγμάτων δεδομένων εκπαίδευσης της κλάσης 0}) * 100]$.
- Ψευδώς αρνητικό (False Negative - FN) ή σφάλμα τύπου II, λαμβάνει χώρα όταν η εξαρτημένη μεταβλητή έχει λανθασμένη επισήμανση ως 0 (καθοδική τάση), με $y = 0$ όταν $y = 1$. Στην πραγματικότητα, μια ανοδική τάση κατατάσσεται ως καθοδική όταν $[Rate\ of\ FN = (\text{αριθμός ψευδώς αρνητικών} / \text{αριθμός δειγμάτων δεδομένων εκπαίδευσης της κλάσης 1}) * 100]$.
- Το ψευδώς σταθμισμένο μέσο σφάλμα είναι το ποσοστό του μέσου όρου των δύο παραπάνω σφαλμάτων, με το βάρος να είναι 0,5 $[(\text{ψευδώς θετικό} * 0,5 + \text{ψευδώς αρνητικό} * 0,5) * 100]$.
- Τα πραγματικά θετικά (True Positives - TP) ή η ακρίβεια της κλάσης 1 είναι $[Rate\ of\ TP = (\text{σωστές ταξινομήσεις κλάσης 1} / \text{αριθμός δειγμάτων δεδομένων εκπαίδευσης της κλάσης 1}) * 100]$.
- Τα πραγματικά αρνητικά (True Negatives - TN) ή η ακρίβεια της κλάσης 0 είναι $[Rate\ of\ TN = (\text{σωστές ταξινομήσεις κλάσης 0} / \text{αριθμός δειγμάτων δεδομένων εκπαίδευσης της κλάσης 0}) * 100]$.
- Η ακρίβεια και των δύο κλάσεων είναι το σταθμισμένο άθροισμα $[(\text{πραγματικά θετικά κλάσης 1} * 0.5 + \text{πραγματικά αρνητικά κλάσης 0} * 0.5) * 100]$.

- Η συνολική ακρίβεια είναι $[(\text{ακρίβεια κλάσης 1} + \text{ακρίβεια κλάσης 0} / \text{συνολικός αριθμός δεδομένων εκπαίδευσης}) * 100]$ που μετρά το κλάσμα όλων των τάσεων που έχουν κατηγοριοποιηθεί σωστά.


6.5 Αποτελέσματα του μοντέλου.

Χρησιμοποιώντας την μέθοδο δοκιμής και λάθους καταλήγουμε στο καλύτερο, ως προς την προβλεπτική του ικανότητα, μοντέλο. Είναι σημαντικό να επισημάνουμε ότι εκτός από της ρυθμίσεις αυτού του μοντέλου υπάρχουν μοντέλα κα με διαφορετικές ρυθμίσεις τα οποία έχουν τα ίδια αποτελέσματα αλλά με περισσότερες επαναλήψεις ή/και περισσότερο αριθμό συναρτήσεων συμμετοχής για κάθε είσοδο. Το μεγαλύτερο μέρος των δοκιμών περιλαμβάνονται στο Παράρτημα Α όπου φαίνονται οι εναλλακτικές επιλογές με το ίδιο αποδοτικά αποτελέσματα. Παρουσιάζουμε το μοντέλο που επιλέχθηκε στον πίνακα 6.1. Ακολουθούν κάποια σημαντικά διαγράμματα για την περιγραφή του μοντέλου που επιλέξαμε.

Πίνακας 6.1: Παράμετροι και στοιχεία του μοντέλου ANFIS.

ANFIS info:	
Number of nodes: 12	Number of checking data pairs: 617
Number of linear parameters: 4	Number of fuzzy rules: 2
Number of nonlinear parameters: 6	Epoch Number: 100
Total number of parameters: 10	Step Size: 0.01
Number of training data pairs: 1849	Type of fuzzy rules: Triangle


Παρουσιάζουμε στο σχήμα 6.3 το σύστημα FIS που δημιουργείται με βάση τις παραμέτρους που θέτουμε. Παρατηρούμε ότι έχουν εισαχθεί δύο γλωσσικές



Σχήμα 6.3: Το σύστημα FIS του μοντέλου.


μεταβλητές και έχει γίνει χρήση συστήματος Sugeno και η έξοδος εκφράζεται σε μια συνάρτηση, όπως φαίνεται και στο σχήμα.

Ενώ στο σχήμα 6.4 παρουσιάζονται οι αρχικές, πριν την εκπαίδευση του μοντέλου, και οι τελικές συναρτήσεις συμμετοχής (τριγωνικές) στο οποίο παρατηρούμε ότι υπάρχει μια τροποποίηση των παραμέτρων της μίας εκ των δύο τριγωνικών συναρτήσεων συμμετοχής που χρησιμοποιούμε.



Σχήμα 6.4: Αρχικές και τελικές συναρτήσεις συμμετοχής.


Στη συνέχεια στο σχήμα 6.5 παρουσιάζουμε τα σφάλματα των δεδομένων εκπαίδευσης και ελέγχου (α) αλλά και το μέγεθος βήματος (β) σε σχέση με τον αριθμό των επαναλήψεων του μοντέλου. Από το σχήμα 6.6 (α) παρατηρούμε ότι το ελάχιστο



Σχήμα 6.5: (α) Σφάλματα εκπαίδευσης και ελέγχου και (β) μέγεθος βήματος σε σχέση με τον αριθμό των επαναλήψεων.

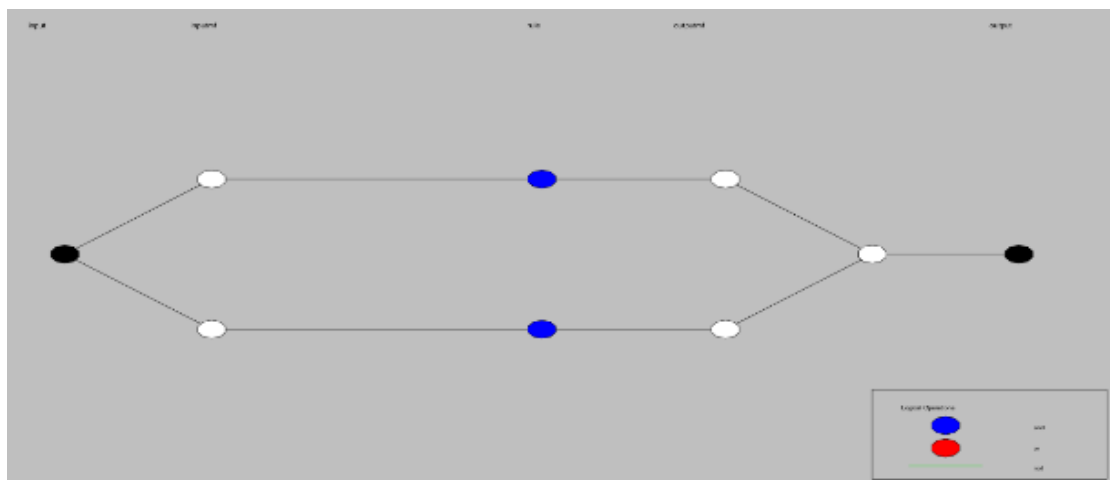
σφάλμα βρίσκεται στην επανάληψη 94 με τιμή 0.374131 και επομένως μετά την 94ή επανάληψη δεν υπάρχει βελτίωση του μοντέλου μας. Ή διαφορετικά το μοντέλο συγκλίνει στην 94ή επανάληψη. Στο σχήμα 6.5 (β) βλέπουμε ότι το μέγεθος βήματος

φτάνει στην ανώτατη τιμή του στην 74ή επανάληψη και παραμένει σταθερό μέχρι την 80ή στην τιμή 0.0556 και στην συνέχεια αρχίζει να μειώνεται. Στο σχήμα 6.6 απεικονίζονται οι πραγματικές έναντι των προβλεπόμενων τιμών της μεταβολής του γενικού δείκτη. Είναι εύκολα διακριτό ότι ενώ το μοντέλο δεν προσεγγίζει ικανοποιητικά τις πραγματικές τιμές (δεν είναι άλλωστε αυτός και ο σκοπός του), μπορεί και αναγνωρίζει σχεδόν τέλεια την τάση του γενικού δείκτη.



Σχήμα 6.6: Πραγματικές και προβλεπόμενες τιμές του γενικού δείκτη.

Εν τέλει παρουσιάζουμε στο σχήμα 6.7 την αρχιτεκτονική του τελικού μοντέλου ANFIS. Οι μεταβλητές εισόδου έχουν μετατραπεί σε ασαφής μεταβλητές. Η έξοδος όμως είναι μιας σαφής συνάρτησης. Η συνάρτηση εξόδου είναι ένα πολυώνυμο πρώτου βαθμού, και για το λόγο αυτό το μοντέλο Sugeno είναι πρώτου βαθμού. Το κάθε σύστημα δημιουργεί τους 2 κανόνες, όπως φαίνονται στο σχήμα.



Σχήμα 6.7: Αρχιτεκτονική του μοντέλου ANFIS.

Τα αποτελέσματα της μεθοδολογίας αξιολόγησης που δείξαμε στο κεφάλαιο 6.4 παρουσιάζονται στον πίνακα 6.2 για το μοντέλο το οποίο δημιουργήσαμε.

Πίνακας 6.2: Αξιολόγηση του μοντέλου ANFIS.

Τύπος συναρτήσεων ενεργοποίησης	Επαναλήψεις	Αριθμός συναρτήσεων ενεργοποίησης	Μέγεθος Βήματος
Τριγωνική	100	2	0,01
	Κλάση 1 (Θετικά)	Κλάση 0 (Αρνητικά)	Σύνολο
Κλάση 1 (Ανοδική/Θετικά)	329	1	330
Κλάση 0 (Καθοδική/Αρνητικά)	0	287	287
Σύνολο	329	288	617
Ρυθμός Σφάλματος	0.304	0.3472	0.3256
Ακρίβεια Κλάσης 1 (%)	Ακρίβεια Κλάσης 0 (%)	Ακρίβεια του σταθμισμένου μέσου όρου (%)	Συνολική Ακρίβεια (%)
99.696	99.6528	99.6744	99.8379

Παρατηρούμε ότι το μοντέλο έχει εξαιρετική προβλεπτική ικανότητα της τάξης του 99.8379% προβλέποντας λανθασμένα μόλις μία μεταβολή του γενικού δείκτη του Χρηματιστηρίου Αθηνών, κατηγοριοποιώντας μια καθοδική τάση ως ανοδική.

Είναι σημαντικό να αναφέρουμε ότι στο σύνολο των δοκιμών μας, με μέγιστο αριθμό εποχών-επαναλήψεων τις 200, με μέγιστο αριθμό συναρτήσεων τις 9 και μέγεθος βήματος 0.01 κανένα μοντέλο δεν είχε συνολική ακρίβεια μικρότερη του 97% γεγονός που υποδεικνύει ότι το προσαρμοστικό νευρο-ασαφές σύστημα ANFIS είναι από τα πλέον κατάλληλα εργαλεία για την πρόβλεψη της τάσης ενός γενικού δείκτη.

Ακόμη, όπως μπορεί να δει κανείς στο Παράρτημα Α, η γκαουσιανή συνάρτηση συμμετοχής παρουσιάζει με τις ίδιες παραμέτρους και αυτή το ίδιο ποσοστό ακρίβειας και θα μπορούσε να επιλεγεί αντί της τριγωνικής. Όμοια, και η τραπεζοειδής συνάρτηση με τροποποίηση των παραμέτρων μπορεί να επιτύχει την ίδια ακρίβεια, ενώ για όλες τις συναρτήσεις πλην της γενικευμένης καμπανοειδής υπάρχουν διαφορετική συνδυασμοί παραμέτρων που δίνουν την μέγιστη ακρίβεια.

7. Συμπεράσματα.

Στην παρούσα διπλωματική εργασία προχωρήσαμε στην κατασκευή ενός προσαρμοστικού νευρο-ασαφούς συστήματος ANFIS για την πρόβλεψη της τάσης του Γενικού Δείκτη του Χρηματιστηρίου Αθηνών της επόμενης μέρας. Αρχικά προχωρήσαμε σε μια ανάλυση της σημαντικότητας των προβλέψεων και παρουσιάσαμε σχετικά με τον σκοπό μας εγχώρια και διεθνή επιστημονικά άρθρα. Στα επόμενα δύο κεφάλαια γίνεται η παρουσίαση του θεωρητικού πλαισίου των ασαφών συνόλων και των τεχνητών νευρωνικών δικτύων, τα οποία χρησιμοποιούνται για την κατασκευή ενός προσαρμοστικού νευρο-ασαφούς συστήματος AMFIS. Στη συνέχεια παρουσιάζονται διάφορα νευρο-ασαφή συστήματα και δίνεται ιδιαίτερη έμφαση στο χρησιμοποιούμενο σύστημα ANFIS.

Πριν την κατασκευή του συστήματός μας προχωρούμε στην κατάλληλη μορφοποίηση των δεδομένων μας κατασκευάζοντας και τον κατάλληλο δείκτη. Έπειτα, χρησιμοποιώντας το λογισμικό Matlab και τον κώδικα που προμηθευτήκαμε από τον επιβλέποντα καθηγητή προχωρήσαμε στον διαχωρισμό των δεδομένων σε δύο ομάδες, τα δεδομένα εκπαίδευσης και τα δεδομένα ελέγχου, και κατασκευάσαμε το σύστημα Anfis. Με την μέθοδο δοκιμής και λάθους εντοπίσαμε τις παραμέτρους του συστήματος που δίνουν το καλύτερο αποτέλεσμα. Αυτές είναι η τριγωνική συνάρτηση ενεργοποίησης, οι εκατό επαναλήψεις, ο αριθμός των συναρτήσεων ενεργοποίησης είναι δύο και το μέγεθος βήματος είναι 0.01.

Το σύστημα που επιλέχθηκε έχει προβλεπτική ικανότητα της τάξης του 99.8379% γεγονός που μας οδηγεί στο συμπέρασμα ότι το σύστημα Anfis επιτυγχάνει να προβλέψει την τάση του Γενικού Δείκτη του Χρηματιστηρίου Αθηνών με πάρα πολύ μεγάλη ακρίβεια και αποτελεί ένα ενδεδειγμένο σύστημα για την πρόβλεψη της τάσης ενός Γενικού Δείκτη.

Βιβλιογραφία.

Altug, S., Trussell, H. J. and Chow, M. Y. (1999) ‘A “mutual update” training algorithm for fuzzy adaptive logic control/decision network (FALCON)’, *IEEE Transactions on Neural Networks*, 10(1), pp. 196–199. doi: 10.1109/72.737508.

Atsalakis, G. S., Atsalaki, I. G. and Zopounidis, C. (2018) ‘Forecasting the success of a new tourism service by a neuro-fuzzy technique’, *European Journal of Operational Research*. Elsevier B.V., 268(2), pp. 716–727. doi: 10.1016/j.ejor.2018.01.044.

Atsalakis, G. S., Dimitrakakis, E. M. and Zopounidis, C. D. (2011) ‘Elliott Wave Theory and neuro-fuzzy systems, in stock market prediction: The WASP system’, *Expert Systems with Applications*, 38(8), pp. 9196–9206. doi: 10.1016/j.eswa.2011.01.068.

Atsalakis, G. S. and Valavanis, K. P. (2009) ‘Surveying stock market forecasting techniques - Part II: Soft computing methods’, *Expert Systems with Applications*. Elsevier Ltd, 36(3 PART 2), pp. 5932–5941. doi: 10.1016/j.eswa.2008.07.006.

Bellman, R. . and Zadeh, L. . (1970) ‘Decision-Making in a Fuzzy Environment’, *Management Science*, 17(4). doi: 10.1142/9789812819789_0004.

Berenji, H. R. and Khedkar, P. (1992) ‘Learning and Tuning Fuzzy Logic Controllers Through Reinforcements’, *IEEE Transactions on Neural Networks*, 3(5), pp. 724–740. doi: 10.1109/72.159061.

Chang, P. C. and Liu, C. H. (2008) ‘A TSK type fuzzy rule based system for stock price prediction’, *Expert Systems with Applications*, 34(1), pp. 135–144. doi: 10.1016/j.eswa.2006.08.020.

Cheng, C. H. *et al.* (2013) ‘OWA-based ANFIS model for TAIEX forecasting’, *Economic Modelling*, 30(1), pp. 442–448. doi: 10.1016/j.econmod.2012.09.047.

G. Barto, A., S. Sutton, R. and W. Anderson, C. (1983) ‘Neuronlike Adaptive Elements That Can Solve Difficult Learning Control Problems’, *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-13, pp. 834–846.

Halgamuge, S. K. and Glesner, M. (1994) ‘Neural networks in designing fuzzy systems for real world applications’, *Fuzzy Sets and Systems*, 65(1), pp. 1–12. doi: 10.1016/0165-0114(94)90242-9.

- Hayashi, Y. and Buckley, J. J. (1994) 'Approximations between fuzzy expert systems and neural networks', *International Journal of Approximate Reasoning*, 10(1), pp. 63–73. doi: 10.1016/0888-613X(94)90009-4.
- Haykin, S. (1998) *Neural Networks - A Comprehensive Foundation*. Second Edi. Pearson Prentice-Hall.
- Hebb, D. O. (1949) 'The Organization of Behavior; A Neuropsychological Theory', *The American Journal of Psychology*, 63(4), p. 633. doi: 10.2307/1418888.
- Hopfield, J. J. (1982) 'Neural networks and physical systems with emergent collective computational abilities.', *Proceedings of the National Academy of Sciences of the United States of America*, 79(8), pp. 2554–2558. doi: 10.1073/pnas.79.8.2554.
- Jang, J.-S. R., Sun, C.-T. and Mizutani, E. (1997a) *Neuro-Fuzzy And Soft Computing: a computational approach to learning and machine intelligence*. Prentice-Hall, Inc.
- Jang, J.-S. R., Sun, C.-T. and Mizutani, E. (1997b) *Neuro-Fuzzy and Soft Computing*. Edited by J. Robbins, Tom Scordato. Prentice-Hall, Inc.
- Jang, J. S. R. (1993) 'ANFIS: Adaptive-Network-Based Fuzzy Inference System', *IEEE Transactions on Systems, Man and Cybernetics*, 23(3), pp. 665–685. doi: 10.1109/21.256541.
- Kolb, B., Muhammad, A. and Gibb, R. (2011) 'Searching for factors underlying cerebral plasticity in the normal and injured brain', *Journal of Communication Disorders*. Elsevier Inc., 44(5), pp. 503–514. doi: 10.1016/j.jcomdis.2011.04.007.
- Lin, C. J. and Lin, C. T. (1997) 'An ART-based fuzzy adaptive learning control network', *IEEE Transactions on Fuzzy Systems*, 5(4), pp. 477–496. doi: 10.1109/91.649900.
- Mcculloch, W. S. and Pitts, W. (1943) 'A logical calculus nervous activity', *Bulletin of Mathematical Biology*, 52(1), pp. 99–115. doi: 10.1007/BF02478259.
- Minsky, M. and Papert, S. (1969) *Perceptrons; an introduction to computational geometry*. MIT Press.
- Nauck, D., Klawonn, F. and Kruse, R. (1994) 'Das NEFCON-Modell', in *Neuronale Netze und Fuzzy-Systeme*. Wiesbaden: Vieweg+Teubner Verlag, pp. 315–354. doi: 10.1007/978-3-322-85993-8_19.

- Nauck, D., Klawonn, F. and Kruse, R. (1997) *Foundations of neuro-fuzzy systems*.
- Nauck, D. and Kruse, R. (1997) 'A neuro-fuzzy development tool for fuzzy controllers under MATLAB/SIMULINK', *Proc. of the 5th European*, (2). Available at: <http://fuzzy.cs.uni-magdeburg.de/nefcon> (Accessed: 17 December 2019).
- Von Neumann, J. (1958) *The computer and the brain*. Yale Univ. Press.
- Rochester, N. *et al.* (1956) 'Tests on a cell assembly theory of the action of the brain, using a large digital computer', *IRE Transactions on Information Theory*, 2(3), pp. 80–93. doi: 10.1109/TIT.1956.1056810.
- Rosenblatt, F. (1958) 'The perceptron: A probabilistic model for information storage and organization in the brain', *Psychological Review*, 65(6), pp. 386–408. doi: 10.1037/h0042519.
- Rumelhart, David E ; Hinton, Geoffrey E ; Williams, R. J. (1985) *Learning internal representations by error propagation*.
- Rumelhart, D. E. and McClelland, J. L. (1987) *Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations*. MITP. Available at: <http://ieeexplore.ieee.org/document/6302925> (Accessed: 5 December 2019).
- Svalina, I. *et al.* (2013) 'An adaptive network-based fuzzy inference system (ANFIS) for the forecasting: The case of close price indices.', *Expert Systems with Applications*, 40(15), pp. 6055–6063. doi: 10.1016/j.eswa.2013.05.029.
- Tan, Z., Quek, C. and Cheng, P. Y. K. (2011) 'Stock trading with cycles: A financial application of ANFIS and reinforcement learning', *Expert Systems with Applications*. Elsevier Ltd, 38(5), pp. 4741–4755. doi: 10.1016/j.eswa.2010.09.001.
- Uttley, A. M. (1959) 'The design of conditional probability computers', *Information and Control*, 2(1), pp. 1–24. doi: 10.1016/S0019-9958(59)90058-0.
- Vieira, J., Dias, F. and Mota, A. (2004) 'Neuro-fuzzy systems: a survey', ... *on Neural Networks and Applications*, Udine ..., pp. 1–6. Available at: <http://dme.uma.pt/people/faculty/fernando.morgado/Down/483-343.pdf>.
- Wang, L.-X. (1997) *A COURSE IN 'FUZZY A Course in Fuzzy Systems and Control, Design*. Available at: <http://portal.acm.org/citation.cfm?id=248374&dl=>.

Werbos, P. J. (1974) *Beyond regression: new tools for prediction and analysis in the behavioral sciences*. Harvard. Available at: citeseerx.ist.psu.edu/viewdoc/download;jsessionid...?doi=10.1.1.41.8085...

Widrow, B. and Hoff, M. E. (1960) 'Adaptive Switching Circuits', in *Adaptive Switching Circuits*, pp. 96–104.

Widrow, B. and Hoff, M. E. (1962) 'Associative Storage and Retrieval of Digital Information in Networks of Adaptive "Neurons"', in *Biological Prototypes and Synthetic Systems*. Springer US, pp. 160–160. doi: 10.1007/978-1-4684-1716-6_25.

Zadeh, L. A. (1972) 'A fuzzy-set-theoretic interpretation of linguistic hedges', *Journal of Cybernetics*, 2(3), pp. 4–34. doi: 10.1080/01969727208542910.

Zadeh L.A (1969) 'Toward a Theory of Fuzzy Systems', *NASA Contractor Reports*, pp. 469–490. doi: 10.1142/9789814261302_0007.

Αργυράκης, Π. (2002) *Νευρωνικά Δίκτυα και Εφαρμογές, Известия Алтайского Государственного Университета*. ΠΑΤΡΑ.

Θεοδώρου, Γ. Α. (2010) *Εισαγωγή στην ασαφή λογική (fuzzy logic) : βασικές αρχές της ασαφούς λογικής με εφαρμογές στην τεχνολογία*. Τζιόλα. Available at: <http://search.lib.auth.gr/Record/994324>.

Παράρτημα Α.

	Epoch	mf_n	ss
Mf_Type	100	2	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	7	336
Class 0 (Down/Negatives)	0	281	281
Sum	329	288	617
Error Rate	2.1277	2.4306	2.27915

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.8723 97.5694 97.72085 98.86547812

trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	1	330
Class 0 (Down/Negatives)	0	287	287
Sum	329	288	617
Error Rate	0.304	0.3472	0.3256

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
99.696 99.6528 99.6744 99.8379

gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	1	330
Class 0 (Down/Negatives)	0	287	287
Sum	329	288	617
Error Rate	0.304	0.3472	0.3256

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
99.696 99.6528 99.6744 99.8379

trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	7	336
Class 0 (Down/Negatives)	0	281	281
Sum	329	288	617
Error Rate	2.1277	2.4306	2.27915

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.8723 97.5694 97.72085 98.8655

	Epoch	mf_n	ss
Mf_Type	200	2	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	7	336
Class 0 (Down/Negatives)	0	281	281
Sum	329	288	617
Error Rate	2.1277	2.4306	2.27915

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.8723 97.5694 97.72085 98.86547812

trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	1	330
Class 0 (Down/Negatives)	0	287	287
Sum	329	288	617
Error Rate	0.304	0.3472	0.3256

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
99.696 99.6528 99.6744 99.8379

gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	7	336
Class 0 (Down/Negatives)	0	281	281
Sum	329	288	617
Error Rate	2.1277	2.4306	2.27915

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.8723 97.5694 97.72085 98.8655

trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	7	336
Class 0 (Down/Negatives)	0	281	281
Sum	329	288	617
Error Rate	2.1277	2.4306	2.27915

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.8723 97.5694 97.72085 98.8655

	Epoch	mf_n	ss
Mf_Type	100	3	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	9	338
Class 0 (Down/Negatives)	0	279	279
Sum	329	288	617
Error Rate	2.7356	3.125	2.9303

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.2644 96.875 97.0697 98.54132901

trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	1	330
Class 0 (Down/Negatives)	0	287	287
Sum	329	288	617
Error Rate	0.304	0.3472	0.3256

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
99.696 99.6528 99.6744 99.8379

gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	7	336
Class 0 (Down/Negatives)	0	281	281
Sum	329	288	617
Error Rate	2.1277	2.4306	2.27915

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.8723 97.5694 97.72085 98.8655

trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	1	330
Class 0 (Down/Negatives)	0	287	287
Sum	329	288	617
Error Rate	0.304	0.3472	0.3256

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
99.696 99.6528 99.6744 99.8379

	Epoch	mf_n	ss
Mf_Type	200	3	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	9	338
Class 0 (Down/Negatives)	0	279	279
Sum	329	288	617
Error Rate	2.7356	3.125	2.9303

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.2644 96.875 97.0697 98.54132901

trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	1	330
Class 0 (Down/Negatives)	0	287	287
Sum	329	288	617
Error Rate	0.304	0.3472	0.3256

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
99.696 99.6528 99.6744 99.8379

gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	7	336
Class 0 (Down/Negatives)	0	281	281
Sum	329	288	617
Error Rate	2.1277	2.4306	2.27915

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.8723 97.5694 97.72085 98.8655

trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	1	330
Class 0 (Down/Negatives)	0	287	287
Sum	329	288	617
Error Rate	0.304	0.3472	0.3256

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
99.696 99.6528 99.6744 99.8379

	Epoch	mf_n	ss
Mf_Type	100	4	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	9	338
Class 0 (Down/Negatives)	0	279	279
Sum	329	288	617
Error Rate	2.7356	3.125	2.9303

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.2644 96.875 97.0697 98.54132901

trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	1	330
Class 0 (Down/Negatives)	0	287	287
Sum	329	288	617
Error Rate	0.304	0.3472	0.3256

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
99.696 99.6528 99.6744 99.8379

gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	8	337
Class 0 (Down/Negatives)	0	280	280
Sum	329	288	617
Error Rate	2.4316	2.7778	2.6047

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.5684 97.2222 97.3953 98.70340357

trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	17	346
Class 0 (Down/Negatives)	0	271	271
Sum	329	288	617
Error Rate	5.1672	5.9028	5.535

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
94.8328 94.0972 94.465 97.2447

	Epoch	mf_n	ss
Mf_Type	200	4	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	9	338
Class 0 (Down/Negatives)	0	279	279
Sum	329	288	617
Error Rate	2.7356	3.125	2.9303

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.2644 96.875 97.0697 98.54132901

trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	1	330
Class 0 (Down/Negatives)	0	287	287
Sum	329	288	617
Error Rate	0.304	0.3472	0.3256

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
99.696 99.6528 99.6744 99.8379

gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	8	337
Class 0 (Down/Negatives)	0	280	280
Sum	329	288	617
Error Rate	2.4316	2.7778	2.6047

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.5684 97.2222 97.3953 98.70340357

trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	17	346
Class 0 (Down/Negatives)	0	271	271
Sum	329	288	617
Error Rate	5.1672	5.9028	5.535

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
94.8328 94.0972 94.465 97.2447

	Epoch	mf_n	ss
Mf_Type	100	5	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	14	343
Class 0 (Down/Negatives)	0	274	274
Sum	329	288	617
Error Rate	4.2553	4.8611	4.5582

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
95.7447 95.1389 95.4418 97.73095624

trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	7	336
Class 0 (Down/Negatives)	0	281	281
Sum	329	288	617
Error Rate	2.1277	2.4306	2.27915

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.8723 97.5694 97.72085 98.86547812

gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	14	343
Class 0 (Down/Negatives)	0	274	274
Sum	329	288	617
Error Rate	4.2553	4.8611	4.5582

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
95.7447 95.1389 95.4418 97.73095624

trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	16	345
Class 0 (Down/Negatives)	0	272	272
Sum	329	288	617
Error Rate	4.8632	5.5556	5.2094

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
95.1368 94.4444 94.7906 97.4068

	Epoch	mf_n	ss
Mf_Type	200	5	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	16	345
Class 0 (Down/Negatives)	0	271	271
Sum	329	287	616
Error Rate	4.8632	5.5556	5.2094

Accuracy class 1 % 95.1368 Accuracy class 0 % 94.4444 Accuracy weighted average % 94.7906 Overall Accuracy % 97.4025974

trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	9	338
Class 0 (Down/Negatives)	0	279	279
Sum	329	288	617
Error Rate	2.7356	3.125	2.9303

Accuracy class 1 % 97.2644 Accuracy class 0 % 96.875 Accuracy weighted average % 97.0697 Overall Accuracy % 98.54132901

gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	14	343
Class 0 (Down/Negatives)	0	274	274
Sum	329	288	617
Error Rate	4.2553	4.8611	4.5582

Accuracy class 1 % 95.7447 Accuracy class 0 % 95.1389 Accuracy weighted average % 95.4418 Overall Accuracy % 97.73095624

trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	16	345
Class 0 (Down/Negatives)	0	272	272
Sum	329	288	617
Error Rate	4.8632	5.5556	5.2094

Accuracy class 1 % 95.1368 Accuracy class 0 % 94.4444 Accuracy weighted average % 94.7906 Overall Accuracy % 97.4068

	Epoch	mf_n	ss
Mf_Type	100	6	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	16	345
Class 0 (Down/Negatives)	0	272	272
Sum	329	288	617
Error Rate	4.8632	5.5556	5.2094

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
95.1368 94.4444 94.7906 97.40680713

trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	10	339
Class 0 (Down/Negatives)	0	278	278
Sum	329	288	617
Error Rate	3.0395	3.4722	3.25585

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
96.9605 96.5278 96.74415 98.37925446

gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	15	344
Class 0 (Down/Negatives)	0	273	273
Sum	329	288	617
Error Rate	4.5593	5.2083	4.8838

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
95.4407 94.7917 95.1162 97.56888169

trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	16	345
Class 0 (Down/Negatives)	0	272	272
Sum	329	288	617
Error Rate	4.863221884	5.555555556	5.20938872

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
95.13677812 94.44444444 94.79061128 97.4068

	Epoch	mf_n	ss
Mf_Type	200	6	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	16	345
Class 0 (Down/Negatives)	0	272	272
Sum	329	288	617
Error Rate	4.8632	5.5556	5.2094

Accuracy class 1 % 95.1368 Accuracy class 0 % 94.4444 Accuracy weighted average % 94.7906 Overall Accuracy % 97.40680713

trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	14	343
Class 0 (Down/Negatives)	0	274	274
Sum	329	288	617
Error Rate	4.2553	4.8611	4.5582

Accuracy class 1 % 95.7447 Accuracy class 0 % 95.1389 Accuracy weighted average % 95.4418 Overall Accuracy % 97.73095624

gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	15	344
Class 0 (Down/Negatives)	0	273	273
Sum	329	288	617
Error Rate	4.5593	5.2083	4.8838

Accuracy class 1 % 95.4407 Accuracy class 0 % 94.7917 Accuracy weighted average % 95.1162 Overall Accuracy % 97.56888169

trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	15	344
Class 0 (Down/Negatives)	0	273	273
Sum	329	288	617
Error Rate	4.559270517	5.208333333	4.883801925

Accuracy class 1 % 95.44072948 Accuracy class 0 % 94.79166667 Accuracy weighted average % 95.11619807 Overall Accuracy % 97.5689

	Epoch	mf_n	ss
Mf_Type	100	7	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	16	345
Class 0 (Down/Negatives)	0	272	272
Sum	329	288	617
Error Rate	4.863221884	5.555555556	5.20938872
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
95.13677812	94.44444444	94.79061128	97.40680713
trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	319	0	319
Class 0 (Down/Negatives)	10	288	298
Sum	329	288	617
Error Rate	3.039513678	3.472222222	3.25586795
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
96.96048632	96.52777778	96.74413205	98.37925
gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	15	344
Class 0 (Down/Negatives)	0	273	273
Sum	329	288	617
Error Rate	4.559270517	5.208333333	4.883801925
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
95.44072948	94.79166667	95.11619807	97.56888
trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	14	343
Class 0 (Down/Negatives)	0	274	274
Sum	329	288	617
Error Rate	4.255319149	4.861111111	4.55821513
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
95.74468085	95.13888889	95.44178487	97.73096

	Epoch	mf_n	ss
Mf_Type	200	7	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	16	345
Class 0 (Down/Negatives)	0	272	272
Sum	329	288	617
Error Rate	4.863221884	5.555555556	5.20938872

Accuracy class 1 % 95.13677812 Accuracy class 0 % 94.44444444 Accuracy weighted average % 94.79061128 Overall Accuracy % 97.40680713

trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	319	0	319
Class 0 (Down/Negatives)	10	288	298
Sum	329	288	617
Error Rate	3.039513678	3.472222222	3.25586795

Accuracy class 1 % 96.96048632 Accuracy class 0 % 96.52777778 Accuracy weighted average % 96.74413205 Overall Accuracy % 98.3793

gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	15	344
Class 0 (Down/Negatives)	0	273	273
Sum	329	288	617
Error Rate	4.559270517	5.208333333	4.883801925

Accuracy class 1 % 95.44072948 Accuracy class 0 % 94.79166667 Accuracy weighted average % 95.11619807 Overall Accuracy % 97.56888

trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	13	342
Class 0 (Down/Negatives)	0	275	275
Sum	329	288	617
Error Rate	3.951367781	4.513888889	4.232628335

Accuracy class 1 % 96.04863222 Accuracy class 0 % 95.48611111 Accuracy weighted average % 95.76737166 Overall Accuracy % 97.89303

	Epoch	mf_n	ss
Mf_Type	100	8	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	17	346
Class 0 (Down/Negatives)	0	271	271
Sum	329	288	617
Error Rate	5.167173252	5.902777778	5.534975515
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
94.83282675	94.09722222	94.46502448	97.24473258
trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	1	330
Class 0 (Down/Negatives)	0	287	287
Sum	329	288	617
Error Rate	0.303951368	0.347222222	0.325586795
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
99.69604863	99.65277778	99.6744132	99.83793
gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	15	344
Class 0 (Down/Negatives)	0	273	273
Sum	329	288	617
Error Rate	4.559270517	5.208333333	4.883801925
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
95.44072948	94.79166667	95.11619807	97.56888
trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	13	342
Class 0 (Down/Negatives)	0	275	275
Sum	329	288	617
Error Rate	3.951367781	4.513888889	4.232628335
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
96.04863222	95.48611111	95.76737166	97.89303

	Epoch	mf_n	ss
Mf_Type	200	8	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	16	345
Class 0 (Down/Negatives)	0	272	272
Sum	329	288	617
Error Rate	4.863221884	5.555555556	5.20938872
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
95.13677812	94.44444444	94.79061128	97.40680713
trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	7	336
Class 0 (Down/Negatives)	0	281	281
Sum	329	288	617
Error Rate	2.127659574	2.430555556	2.279107565
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
97.87234043	97.56944444	97.72089243	98.86548
gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	15	344
Class 0 (Down/Negatives)	0	273	273
Sum	329	288	617
Error Rate	4.559270517	5.208333333	4.883801925
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
95.44072948	94.79166667	95.11619807	97.56888
trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	14	343
Class 0 (Down/Negatives)	0	274	274
Sum	329	288	617
Error Rate	4.255319149	4.861111111	4.55821513
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
95.74468085	95.13888889	95.44178487	97.73096

	Epoch	mf_n	ss
Mf_Type	100	9	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	17	346
Class 0 (Down/Negatives)	0	271	271
Sum	329	288	617
Error Rate	5.167173252	5.902777778	5.534975515
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
94.83282675	94.09722222	94.46502448	97.24473258
trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	9	338
Class 0 (Down/Negatives)	0	279	279
Sum	329	288	617
Error Rate	2.73556231	3.125	2.930281155
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
97.26443769	96.875	97.06971884	98.54133
gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	14	343
Class 0 (Down/Negatives)	0	274	274
Sum	329	288	617
Error Rate	4.255319149	4.861111111	4.55821513
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
95.74468085	95.13888889	95.44178487	97.73096
trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	7	336
Class 0 (Down/Negatives)	0	281	281
Sum	329	288	617
Error Rate	2.127659574	2.430555556	2.279107565
Accuracy class 1 %	Accuracy class 0 %	Accuracy weighted average %	Overall Accuracy %
97.87234043	97.56944444	97.72089243	98.86548

	Epoch	mf_n	ss
Mf_Type	200	9	0.01
gbellmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	18	347
Class 0 (Down/Negatives)	0	270	270
Sum	329	288	617
Error Rate	5.47112462	6.25	5.86056231

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
94.52887538 93.75 94.13943769 97.08265802

trimf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	9	338
Class 0 (Down/Negatives)	0	279	279
Sum	329	288	617
Error Rate	2.73556231	3.125	2.930281155

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.26443769 96.875 97.06971884 98.54133

gaussmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	13	342
Class 0 (Down/Negatives)	0	275	275
Sum	329	288	617
Error Rate	3.951367781	4.513888889	4.232628335

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
96.04863222 95.48611111 95.76737166 97.89303

trapmf	Class 1 (Positives)	Class 0 (Negatives)	Total
Class 1 (Up/Positives)	329	7	336
Class 0 (Down/Negatives)	0	281	281
Sum	329	288	617
Error Rate	2.127659574	2.430555556	2.279107565

Accuracy class 1 % Accuracy class 0 % Accuracy weighted average % Overall Accuracy %
97.87234043 97.56944444 97.72089243 98.86548