



ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ

ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΑΡΑΓΩΓΗΣ ΚΑΙ ΔΙΟΙΚΗΣΗΣ

Διπλωματική Εργασία

Προβλέψεις πωλήσεων κατοικιών στις Ηνωμένες
Πολιτείες Αμερικής μέσω ANFIS

Επιβλέπων καθηγητής : Ατσαλάκης Γεώργιος
Επιμέλεια : Τσουβαλάκης Γεώργιος

ΧΑΝΙΑ 2021

ΠΡΟΛΟΓΟΣ

Η παρούσα διπλωματική εργασία εκπονήθηκε κατά την διάρκεια του προπτυχιακού κύκλου σπουδών του τμήματος Μηχανικών Παραγωγής και Διοίκησης του Πολυτεχνείου Κρήτης, με επιβλέποντα Καθηγητή τον κ. Ατσαλάκη Γεώργιο. Σε αυτό το σημείο θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή μου καταρχάς για την άρτια συνεργασία σε όλη την διάρκεια εκτέλεσης της διπλωματικής μου καθώς και για τις πολύτιμες πληροφορίες και συμβουλές που έπαιξαν καταλυτικό ρόλο στην ολοκλήρωση της εργασίας. Επίσης ένα μεγάλο ευχαριστώ στην οικογένεια μου και τους φίλους μου για την αγάπη τους και τη συμπαράσταση τους καθ' όλη την διάρκεια φοίτησης μου στο Πολυτεχνείο Κρήτης.

ΠΙΝΑΚΑΣ ΕΙΚΟΝΩΝ

Εικόνα 1: Νευρωνικό δίκτυο	18
Εικόνα 2: Διάταξη ενός νευρώνα	22
Εικόνα 3: Σύνδεση νευρώνων μεταξύ τους	23
Εικόνα 4: Συνάρτηση κατώφλι	26
Εικόνα 5: Συνάρτηση προσήμου	26
Εικόνα 6: Γραμμική συνάρτηση	27
Εικόνα 7: Βαθμωτή γραμμική συνάρτηση	27
Εικόνα 8: Λογιστική συνάρτηση	28
Εικόνα 9: Υπερβολική εφαιπτομενική συνάρτηση	28
Εικόνα 10: Δίκτυο πρόσθιας τροφοδότησης ενός επιπέδου	29
Εικόνα 11: Δίκτυο πρόσθιας τροφοδότησης 2 κρυφών επιπέδων	30
Εικόνα 12: Αναδρομικό δίκτυο	31
Εικόνα 13: Δισδιάστατη δικτυωτή δομή με νευρώνες 2 x 2	31
Εικόνα 14: Ο αλγόριθμος Perceptron	35
Εικόνα 15: Αναπαράσταση διανυσμάτων σε μοντέλο Perceptron	38
Εικόνα 16: Μοντέλο Adaline	39
Εικόνα 17: Αποτελέσματα ενός μοντέλου Adaline	40
Εικόνα 18: Διακριτό ασαφές σύνολο	44
Εικόνα 19: Συνεχί ασαφές σύνολο	44
Εικόνα 20: Συνάρτηση συμμετοχής και σύνολο διατομής α	48
Εικόνα 21: Ένωση ασαφών συνόλων	49
Εικόνα 22: Τομή ασαφών συνόλων	50
Εικόνα 23: Συμπλήρωμα ασαφών συνόλων	50
Εικόνα 24: Καρτεσιανό γινόμενο κλασσικών συνόλων	51
Εικόνα 25: Σχηματική απεικόνιση ασαφούς σχέσης R	51
Εικόνα 26: λειτουργία ασαφούς συμπερασματολογίας	53
Εικόνα 27: Υβριδικός νευροασαφής ελεγκτής	60
Εικόνα 28: Μοντέλο ANFIS	62
Εικόνα 29: ANFIS editor	65
Εικόνα 30: Μοντέλο ANFIS (Housedata)	66
Εικόνα 31: Δομή Μοντέλου	67
Εικόνα 32: Συνάρτηση συμμετοχής της εισόδου πριν την εκμάθηση του συστήματος	69
Εικόνα 33: Συνολική επιφάνεια εισόδου-εξόδου	70
Εικόνα 34: Γράφημα διασποράς δεδομένων εκπαίδευσης	71
Εικόνα 35: Γράφημα διασποράς δεδομένων ελέγχου	72
Εικόνα 36: Υπολογισμοί του ANFIS	73
Εικόνα 37: Membership Function Editor	75
Εικόνα 38: Σύνολο παραμέτρων για very small	77
Εικόνα 39: Σύνολο παραμέτρων για small	78
Εικόνα 40: Σύνολο παραμέτρων για large	79
Εικόνα 41: Σύνολο παραμέτρων για very large	80
Εικόνα 42: Σφάλμα εκπαίδευσης ελέγχου και μέγεθος βήματος	86
Εικόνα 43: Δομή μοντέλου ANFIS με input αρχικής συνάρτησης συμμετοχής	87
Εικόνα 44: Δομή μοντέλου ANFIS με input τελικής συνάρτησης συμμετοχής	88
Εικόνα 45: Αρχικές συναρτήσεις συμμετοχής για την gbellmf	89
Εικόνα 46: Τελικές συναρτήσεις συμμετοχής για την gbellmf	90
Εικόνα 47: Γράφημα διασποράς των δεδομένων εκπαίδευσης	91
Εικόνα 48: Γράφημα διασποράς των δεδομένων ελέγχου	92
Εικόνα 49: Γράφημα λάθους πρόβλεψης	93
Εικόνα 50: Σύγκριση αρχικών πωλήσεων δεδομένων ακινήτων στις Η.Π.Α.	98
Εικόνα 51: Δεδομένα σειράς εκπαίδευσης χρονοσειρών	99
Εικόνα 52: Δεδομένα σειράς αξιολόγησης χρονοσειρών	101
Εικόνα 53: Σύγκριση πραγματικών τιμών και τιμών πρόβλεψης που αφορούν τις πωλήσεις ακινήτων	103
Εικόνα 54: Επιφάνεια εισόδου-εξόδου πώλησης ακινήτων στις Η.Π.Α.	104
Εικόνα 55: Επιφάνεια εισόδου-εξόδου πώλησης ακινήτων στις Η.Π.Α.	105

ΣΥΝΤΟΜΟΓΡΑΦΙΕΣ

MATLAB: Matrix Laboratory
ANFIS: Adaptive Neuro Fuzzy Inference System
APFM: Air Pollution Forecasting Model
ASTU: Assam Science and Technology University
STLF: Short Term Load Forecasting
ANN: Artificial Neural Network
FNN: Feedforward Neural Network
MLR: Multiple Linear Regression
ATM: Automated Teller Machine
AEMO: Australian Energy Market Operator
IT2FLS: Interval Type 2 Fuzzy Logic System
IT2IFLS: Interval Type 2 Intuitionistic Fuzzy Logic Systems
FBPN: Fuzzy Back Propagation Network
PCB: Printed Circuit Board
IPM: Integrated Pest Management
TSK: Takagi - Sugeno – Kang
MOP: Monthly Oil Prize
DGP: Daily Gas Prize
AIR: Annual Interest Rate
RMSE: Root Mean Square Error
GFS: Genetic Fuzzy Systems
MAPE: Mean Absolute Percentage Error
ARIMA: AutoRegressive Integrated Moving Average
CBR: Case Based Reasoning
AI: Artificial Intelligence
FCBR: Forecast Case Based Reasoning
GFNN: Gaussian Fuzzy Neural Network

Περιεχόμενα

ΠΡΟΛΟΓΟΣ.....	2
ΠΙΝΑΚΑΣ ΕΙΚΟΝΩΝ.....	3
ΣΥΝΤΟΜΟΓΡΑΦΙΕΣ.....	4
1. ΕΙΣΑΓΩΓΗ.....	6
2. ΑΝΑΣΚΟΠΗΣΗ ΒΙΒΛΙΟΓΡΑΦΙΑΣ	7
3. ΠΡΟΤΕΙΝΟΜΕΝΕΣ ΠΡΟΣΕΓΓΙΣΕΙΣ	18
3.1 Τεχνητά Νευρωνικά Δίκτυα.....	18
3.1.1 Ορισμός Νευρωνικού Δικτύου	18
3.1.2 Ιστορικά Στοιχεία	19
3.1.3 Από τα Βιολογικά Νευρωνικά Δίκτυα στα Τεχνητά	21
3.1.4 Χρήση Νευρωνικών Δικτύων και Εφαρμογές.....	24
3.1.5 Αρχιτεκτονική Νευρωνικών Δικτύων	25
3.1.6 Είδη Αρχιτεκτονικών Δομών	28
3.1.7 Λειτουργία Νευρωνικών Δικτύων.....	31
3.1.8 Εκπαίδευση Νευρωνικών Δικτύων	33
3.1.9 Ο Αλγόριθμος Μάθησης του Perceptron (Αισθητήρα)	35
3.1.10 Ο Αλγόριθμος Ελαχίστου Μέσου Τετραγωνικού (EMT) Σφάλματος	39
3.1.11 Ο Αλγόριθμος Πίσω Διάδοσης (Π.Δ) του λάθους.....	40
3.2 Ασαφής Λογική (Fuzzy Logic)	42
3.2.1 Συναρτήσεις Συμμετοχής	44
3.2.2 Ιδιότητες των Ασαφών Συνόλων.....	47
3.2.3 Λογικές Πράξεις στα Ασαφή Σύνολα	49
3.2.4 Ασαφείς Σχέσεις.....	50
3.2.5 Ασαφής Συλλογιστική.....	52
3.3 Συστήματα Ασαφούς Συλλογιστικής – Νευροασαφή Συστήματα	52
3.3.1 Κανόνες αν – τότε (if – then rules).....	55
3.3.2 Συστήματα Ασαφούς Συλλογιστικής (Fuzzy Inference Systems).....	56
3.3.3 Νευροασαφή Συστήματα.....	58
3.4 ANFIS (Adaptive Neuro – Fuzzy Inference System)	61
3.4.1 Εισαγωγή - Ορισμός.....	61
3.4.2 Δομή Αρχιτεκτονικής του ANFIS	63
3.4.3 Περιγραφή του Μοντέλου	65
3.4.4 Αριθμητικό Παράδειγμα Μοντέλου	73
4. ΜΕΛΕΤΗ ΠΕΡΙΠΤΩΣΗΣ (case study)	82
4.1 Εισαγωγή	82
4.2 Επεξεργασία	82
4.3 Διαδικασία	84
4.4 Αποτελέσματα	94
5. ΣΥΜΠΕΡΑΣΜΑΤΑ.....	106
6. ΒΙΒΛΙΟΓΡΑΦΙΑ.....	108

1. ΕΙΣΑΓΩΓΗ

Τα τελευταία χρόνια παρατηρούμε ότι πολλές μεγάλες εταιρείες real estates και πολυεθνικές έχουν ρίξει την προσοχή τους στον τομέα κατασκευής των ακινήτων. Η ανάγκη αυτή έχει δημιουργηθεί λόγω της μεγάλης αγοράς και ζήτησης κατοικιών. Αξίζει να σημειωθεί, ότι η αγορά των ακινήτων έχει αυξηθεί λόγω την μεγάλης αύξησης του πληθυσμού, της αστικοποίησης των ανθρώπων και της μεγάλης τεχνολογικής εξέλιξης (οπού κάποιες εργασίες γίνονται αυτοματοποιημένα και έτσι πετυχαίνουν ταχύτερο χρόνο παράδοσης). Επίσης ένας ακόμα μεγάλος παράγοντας που παρατηρείται τα τελευταία χρόνια και παίζει μεγάλο ρόλο στην πώληση των ακινήτων είναι το Airbnb οπού πολλοί ιδιοκτήτες βάζουν την κατοικία τους στην πλατφόρμα έναντι ημερήσιου ενοικίου. Επιπρόσθετα πολλές εταιρίες έχουν κάνει αισθητή την παρουσία τους στο χρηματιστήριο γεγονός που δείχνει ότι η πωλήσεις και οι αγορές των ακινήτων έχουν επηρεάσει την παγκόσμια οικονομία. Για τους λόγους αυτούς έχουν αναπτυχθεί διάφορες τεχνικές με στόχο την πρόβλεψη των πωλήσεων. Όσο πιο αποτελεσματική είναι η πρόβλεψη αυτή, τόσο πιο επιτυχημένη είναι η επιχειρηματική δραστηριότητα. Οι περισσότερες διαδικασίες στον επιχειρηματικό τομέα είναι δυναμικές και μη-γραμμικές, γεγονός που σημαίνει πως δεν μπορούν να προσεγγιστούν με συμβατικές τεχνικές.

Για την διεκπεραίωση της διπλωματικής χρησιμοποιήσαμε μία εναλλακτική τεχνική η οποία βασίζεται σε προγραμματισμό με το λογισμικό της MATLAB και συγκεκριμένα στην πρόβλεψη των μηνιαίων πωλήσεων ακινήτων στις Ηνωμένες Πολιτείες της Αμερικής χρησιμοποιώντας τις πωλήσεις προηγούμενων μηνών (τα δεδομένα χρονολογούνται από τις 01-1-1963 έως 12-01-2019) και το ANFIS, όπου εμπεριέχει χαρακτηριστικό δείγμα των νευρωνικών δικτύων και της ασαφούς λογικής. Στα πρώτα κεφάλαια γίνεται μία αναφορά στη βιβλιογραφία ώστε να γνωρίζουμε την πρόοδο που έχει επιτευχθεί μέχρι και σήμερα. Έπειτα καταγράφεται η θεωρητική βάση που είναι απαραίτητη για την κατανόηση του αντικειμένου και αναλύεται η περίπτωση μελέτης μας. Τέλος, εξάγονται συμπεράσματα και παρατίθεται η βιβλιογραφία και ο κώδικας που χρησιμοποιήθηκε.

1. ABSTRACT

In recent years we have noticed that many large companies real estates and multinationals have turned their attention to the real estate sector. This need has arisen due to the large market and demand for housing. It is worth noting that the real estate market has grown due to large population growth, urbanization of people and great technological development (where some work is done automatically and thus achieve faster delivery time). Also another big factor that you notice in recent years and plays a big role in the sale of real estate is Airbnb ,where many homeowners put their home on the platform for a daily rent. In addition, many companies have made their presence felt in the stock market, a fact that shows that sales and purchases of real estate have affected the global economy. For these reasons, various techniques have been developed to forecast sales. The more effective this forecast is, the more successful the business .The processes are dynamic and non-linear, which means that they cannot be approached with conventional techniques.

For the project we used an alternative technique which is based on programming with matlab software and specifically in forecasting the monthly sales of real estate in the United States of America using the sales of previous months (data dating from 01-1-1963 to 12 -01-2019) and ANFIS, where it contains a typical sample of neural networks and fuzzy logic. In the first chapters a reference is made to the literature so that we know the progress that has been made to date. Then the theoretical basis that is necessary for the understanding of the subject is recorded and the case of our study is analyzed. In conclusion, are drawn and the bibliography and code used are listed.

2. ΑΝΑΣΚΟΠΗΣΗ ΒΙΒΛΙΟΓΡΑΦΙΑΣ

Για να γίνουν σαφέστερες κάποιες έννοιες που θα χρησιμοποιηθούν κατά την διάρκεια της διπλωματικής, κρίνεται σκόπιμο να γίνει μία βιβλιογραφική αλλά και πειραματική αναφορά στις μέχρι τώρα προσπάθειες που έχουν γίνει κατά καιρούς για τα μοντέλα πρόβλεψης αλλά και την αποτελεσματικότητά τους.

The fuzzy logic in air pollution with forecasting model APFM

Το συγκεκριμένο άρθρο από τον F. Abbasi, πραγματεύεται ένα μοντέλο για την πρόβλεψη των συγκεντρώσεων σωματιδίων PM10, PM2.5, SO2, NO, CO και O3 για έναν επιλεγμένο αριθμό ωρών. Η συγκεκριμένη μέθοδος απαιτεί ιστορικά δεδομένα πρόγνωσης καιρού και ρύπανσης.

Το μοντέλο προβλέπει συγκεντρώσεις ρύπανσης, για οποιαδήποτε επιλεγμένη ημέρα ή ώρα και υπό συνθήκες εξετάζει τις καιρικές προβλέψεις για εκείνη την ημέρα. Οι συγκεντρώσεις διαδραματίζουν σημαντικό ρόλο τόσο κοινωνικής άποψης όσο και από βιομηχανικής.

Τα μοντέλα που χρησιμοποιήθηκαν, εφαρμόζουν μια τεράστια βάση δεδομένων και μπορούν να χρησιμοποιηθούν για την ευκολότερη πρόβλεψη. Ο στόχος του μοντέλου APFM είναι να προβλέψει τυχόν συγκεντρώσεις ρύπανσης και μπορεί εύκολα να προσαρμοστεί σε διαφορετικές περιοχές ανά τον κόσμο.

Load forecasting of Adama University by implementing fuzzy logic controller

Η πρόβλεψη για την αξιοποίηση της ισχύος σε αναπτυσσόμενες χώρες όπως η Ινδία, η Αιθιοπία, η Γκάνα όπου υπάρχει μεγάλη σπατάλη στη δημιουργία, τη μετάδοση και την διανομή της ενέργειας, κρίνεται απαραίτητη. Σε αυτό το άρθρο οι Sunil Kumar, Arun Kumar, Sultan F. Meko, Dawitleykuen, Milkias Berhanu, πραγματοποιούν ένα πρακτικό πείραμα για την εκτίμηση της ζήτησης φορτίου του Adama Science and Technology University, Αιθιοπία. Συλλέγονται δεδομένα από το ASTU του προηγούμενου έτους και για την ανάλυση των αποτελεσμάτων χρησιμοποιείται το Μοντέλο Mamdani στις μεθόδους της ασαφούς λογικής. Για τη μείωση του σφάλματος χρησιμοποιείται το Τεχνητό Νευρωνικό Δίκτυο. Το εύρος σφαλμάτων μειώνεται σχεδόν στο 3% και τα προγράμματα έχουν κατασκευαστεί σε Matlab περιβάλλον.

Τα αποτελέσματα της έρευνας έδειξαν ότι το προβλεπόμενο φορτίο σε σύγκριση με το πραγματικό φορτίο δίνει το μέγιστο ποσοστό σφάλματος 4,04814% και το ελάχιστο ποσοστό υπολογισμού σφάλματος είναι -0.38425%.

Συμπερασματικά αποδείχθηκε ότι μία τεχνική από μόνη της δεν είναι βέβαιο ότι θα έχει καλά αποτελέσματα, αλλά αν συγχωνευθεί ή συμπληρωθεί και με μία άλλη μέθοδο, τα αποτελέσματα θα είναι πιο έγκυρα.

Short-Term Load Forecasting by using Ann, Fuzzy Logic and Fuzzy Neural Network

Η πρόβλεψη ηλεκτρικού φορτίου παίζει καθοριστικό ρόλο τόσο στον σχεδιασμό, όσο και στην λειτουργία αλλά και τον έλεγχο ενός συστήματος ισχύος. Η ακρίβεια των προβλεπόμενων τιμών είναι καίρια για την οικονομική αποδοτική λειτουργία. Μια σωστή πρόβλεψη μπορεί να οδηγήσει σε αποτελεσματική παραγωγή με την βέλτιστη λειτουργία ασφαλείας. Στο συγκεκριμένο άρθρο οι Girraj Singh, D. S. Chauhan, Aseem Chandel, χρησιμοποιούν τη μέθοδο STLF. Αυτό το μοντέλο είναι χρήσιμο για τη βελτίωση της ασφάλειας και για την οικονομική επίδραση στα συστήματα ισχύος. Σε αυτή τη μελέτη παρουσιάζεται η έρευνα για βραχυπρόθεσμο φορτίο (μία ημέρα έως

επτά ημέρες) πρόβλεψης της ζήτησης φορτίου για το Ηνωμένο Βασίλειο, χρησιμοποιώντας τεχνητό νευρικό δίκτυο, ασαφή λογική, και ασαφές νευρωνικό δίκτυο.

Χρησιμοποιείται το πρόγραμμα επεξεργασίας ANFIS και το μοντέλο SIMULINK. Η δυνατότητα εφαρμογής διαφορετικών μεθόδων για μια μέρα και επτά ημέρες δείχνει ότι οι μέθοδοι ANN και FNN είναι πιο ακριβείς και αξιόπιστες από την παραδοσιακή μέθοδο MLR.

Water level forecasting through fuzzy logic and artificial neural network approaches

Σε αυτήν τη μελέτη οι S. Alvisi, G. Mascellani, M. Franchini, and A. B'ardossy παρουσιάζουν τρία μοντέλα πρόβλεψης στάθμης νερού βάση δεδομένων. Το ένα βασίζεται στην προσέγγιση των τεχνητών νευρικών δικτύων, ενώ τα άλλα δύο βασίζονται στις ασαφείς λογικές προσεγγίσεις Mamdani και Takagi-Sugeno.

Η ανάλυση πραγματοποιείται χρησιμοποιώντας τις ίδιες μεταβλητές εισόδου και εξόδου και για τις τρεις μεθόδους. Το πρώτο χαρακτηρίζεται από σημαντικές χωρικές και χρονικές συγκεντρωτικές πληροφορίες βροχόπτωσης, ενώ το τελευταίο θεωρεί ότι οι πληροφορίες για τις βροχοπτώσεις είναι πιο κατανοημένες στο χώρο και το χρόνο. Η μελέτη αφορά τον ποταμό Reno στο Casalecchio di Reno (Μπολόνια, Ιταλία). Φαίνεται ότι τα δύο μοντέλα που βασίζονται στις ασαφείς λογικές προσεγγίσεις αποδίδουν καλύτερα όταν τα εξεταζόμενα φυσικά φαινόμενα συντίθενται και από έναν περιορισμένο αριθμό μεταβλητών και λογικών δηλώσεων IF-THEN, ενώ η προσέγγιση ANN αυξάνει την απόδοσή της όταν χρησιμοποιούνται πιο λεπτομερείς πληροφορίες. Όσον αφορά την αξιοπιστία, η μελέτη έδειξε ότι τα μοντέλα που βασίζονται στις ασαφείς λογικές προσεγγίσεις ενδέχεται να αποτύχουν στη πρόβλεψη της στάθμης του νερού, βασιζόμενα στο γεγονός ότι κατά τη φάση δοκιμής, κάποιος συνδυασμός εισόδου δεν αναγνωρίζεται από το σύστημα και επομένως δεν πραγματοποιείται πρόβλεψη.

Neuro-Fuzzy Logic Model for Breakup Forecasting at Fort McMurray, AB

Σε αυτήν την έρευνα, ασαφή λογικά μοντέλα αναπτύχθηκαν από τους Chandra Mahabir, Faye Hicks, Aminah Robinson Fayek, με σκοπό την πρόβλεψη στάθμης νερού για τη διάσπαση του πάγου ποταμού χρησιμοποιώντας δύο προσεγγίσεις για την ανάπτυξη βάσης κανόνων: γνώσεις εμπειρογνομόνων και ανάλυση ANN ιστορικών δεδομένων. Τα αποτελέσματα αυτής της έρευνας έδειξαν το πλεονέκτημα της χρήσης της μεθόδου ANN καθώς το μοντέλο που προέκυψε δεν ήταν μόνο σημαντικά ανώτερο από το μοντέλο γνώσης των εμπειρογνομόνων, ήταν επίσης ανταγωνιστικό με το μοντέλο MLR που ενσωματώνει δύο φορές περισσότερες μεταβλητές. Ενώ το MLR απαιτούσε δεδομένα από τρεις σεζόν το νευρο-ασαφές μοντέλο βασίστηκε μόνο σε δεδομένα φθινοπώρου και χειμώνα διευκολύνοντας μια μακροχρόνια πρόβλεψη χρόνου περίπου 3 εβδομάδων.

An Approach to Improve Forecasting Cash Demand at ATMs Using Fuzzy Logic

Τα ATM είναι μια από τις πιο άμεσες τραπεζικές συναλλαγές και η διαθεσιμότητα του δικτύου ATM είναι μία από τις πιο σημαντικές παραμέτρους στις επιχειρηματικές υπηρεσίες. Το σήμα (ζήτηση ανάληψης χρημάτων από ATM) είναι μη γραμμικό και εξαρτάται από πολλούς παράγοντες, όπως την ημέρα της εβδομάδας, την ημέρα του μήνα, διακοπές κ.α. Οι συμβατικές μέθοδοι αναγνώρισης δεν έχουν καλές τεχνικές απόκρισης και θα πρέπει να χρησιμοποιείται η ασαφής λογική και τα νευρωνικά δίκτυα για την επίλυση αυτού του προβλήματος.

Η τρέχουσα έρευνα χρησιμοποιεί τη μελέτη μιας μεθόδου πρόβλεψης με βάση τον κανόνα έναντι της διαχείρισης μετρητών χρησιμοποιώντας χρονοσειρές. Η μέθοδος χρονοσειρών έχει, λιγότερους υπολογισμούς, υψηλότερη ταχύτητα και μεγαλύτερο εύρος εφαρμογών, αλλά η ακρίβεια της πρόβλεψης δεν είναι εγγυημένη για την κάλυψη αναγκών σε μετρητά και δεν διαθέτει προσαρμοστική ικανότητα μάθησης. Η προτεινόμενη μέθοδος συνδυάζει, το πλεονεκτήματα του νευρικού δικτύου - τη μέθοδο επίλυσης μη γραμμικού προβλήματος που δεν μπορούν να επιλυθούν με συμβατικές μεθόδους – και τους ασαφείς ελεγκτές τύπου II.

Interval Type-2 Intuitionistic Fuzzy Logic System for Forecasting the Electricity Load

Αυτή η μελέτη από τους Imo Eyoh, Jeremiah Eyoh, Ini Umoeka, παρουσιάζει την ανάλυση της πρόβλεψης φορτίου χρησιμοποιώντας IT2IFLS. Λήφθηκαν δεδομένα ηλεκτρικού φορτίου το 2018 από το AEMO και για την αντικειμενική αξιολόγηση του μοντέλου, γίνεται σύγκριση με παραδοσιακά μοντέλα όπως το ANN και το IT2FLS στις ίδιες παρουσίες προβλήματος. Τα αποτελέσματα της μελέτης δείχνουν ότι οι προβλέψεις του IT2FLS τείνουν να πλησιάζουν αυτά του IT2IFLS με ελάχιστες εξαιρέσεις. Ωστόσο, συνολικά, η μέθοδος IT2IFLS με ιδιότητα μέλους συνάρτησης και συναρτήσεις μη μελών που είναι ασαφείς και με δείκτες δισταγμού υπερτερούν των ANN και IT2FLS.

Spatial Load Forecasting Using Fuzzy Logic

Τις τελευταίες τέσσερις δεκαετίες έχουν δημιουργηθεί διάφορες μέθοδοι πρόβλεψης φορτίων. Ωστόσο, αυτές οι μέθοδοι έχουν το μειονέκτημα ότι σε περίπτωση έλλειψης δεδομένων δε μπορούν να μας δώσουν έγκυρα δεδομένα. Αυτό το άρθρο από τον Shahram Javadi, προτείνει και περιγράφει τη γενική μεθοδολογία για τη χρήση ασαφούς λογικής για την πρόβλεψη χωρικού φορτίου. Μια νέα μέθοδος πρόβλεψης χωρικού φορτίου η οποία βασίζεται στη χρήση μη ομοιόμορφων περιοχών. Το αποτέλεσμα είναι η μέθοδος να απαιτεί ουσιαστικά λιγότερο ανθρώπινο δυναμικό και δεδομένα από τις υπάρχουσες μεθόδους που βασίζονται στο πλέγμα να αποδώσει καλύτερα αποτελέσματα. Ο αλγόριθμος έχει δοκιμαστεί στην πόλη Ghaen (βορειοανατολικά του IRAN), στην επαρχία Khurasan ως σημείο αναφοράς για τρέχουσες και προβλεπόμενες χρήσεις γης.

Τα αποτελέσματα του προτεινόμενου σχεδίου είναι ότι μπορεί να παρέχει προγραμματιστές διανομής άλλες και εναλλακτικές λύσεις για τη συγκέντρωση των πληροφοριών για πρόβλεψη χωρικού φορτίου.

Load forecasting using fuzzy logic

Το πρόβλημα της πρόβλεψης φορτίου περιορίζεται σε βραχυπρόθεσμες προβλέψεις φορτίου και εκφράζεται ως ασαφές γραμμικό πρόβλημα εκτίμησης. Ο κύριος στόχος

είναι να ελαχιστοποιηθεί το σφάλμα μεταξύ της πραγματικής τιμής φόρτωσης και της προβλεπόμενης τιμής των διαθέσιμων δεδομένων.

Σε αυτή τη μελέτη χρησιμοποιείται η MATLAB για φορτίο πρόβλεψης χρησιμοποιώντας ασαφή λογική. Μια διατύπωση της ασαφούς λογικής είναι το σύστημα (FLS) που χρησιμοποιείται για την κατασκευή μη παραμετρικών μοντέλων με δεδομένα εισόδου – εξόδου.

Το σημαντικό χαρακτηριστικό της προτεινόμενης μεθοδολογίας από τους Sagar R. Kamble, Samadhan D. Deokar, Sumit M. Latke, Manik M. Hapse, είναι η επέκταση της ασαφούς λογικής προσέγγισης για την επίλυση πρόβλεψης προβλήματος με ασάφεια δεδομένων όπως τύποι ημέρας θερμοκρασίας και μοτίβο φόρτωσης κ.λπ. Η μελέτη δείχνει ότι η ασαφής προσέγγιση δίνει την καλύτερη πρόβλεψη απόδοσης.

Fuzzy Back-Propagation Network for PCB Sales Forecasting

Η αξιόπιστη πρόβλεψη πωλήσεων μπορεί να βελτιώσει την ποιότητα της επιχείρησης. Σε αυτήν την έρευνα οι Pei-Chann Chang, Yen-Wen Wang, and Chen-Hao Liu, ασχολούνται με την ασαφής λογική και το τεχνητό νευρικό δίκτυο ενσωματώνοντας στο ασαφές δίκτυο, οπίσθια διάδοση (FBPN).

Το ασαφές πίσω δίκτυο διάδοσης έχει κατασκευαστεί για να ενσωματώνει κρίσεις εμπειρογνομόνων για τον έλεγχο της παραγωγής και τη βελτίωση της απόδοσης του μοντέλου. Οι παράμετροι που επιλέγονται ως εισοδοί στο FBPN δεν θεωρούνται πλέον ισοδύναμης σημασίας. Το προτεινόμενο σύστημα αξιολογείται μέσω πραγματικών δεδομένων που παρέχονται από εταιρεία τυπωμένων κυκλωμάτων.

Τα πειραματικά αποτελέσματα απέδειξαν ότι η αποτελεσματικότητα του FBPN είναι ανώτερη από άλλες παραδοσιακές προσεγγίσεις. Η προσέγγιση FBPN παρέχει επίσης μια ενημέρωση στον υπεύθυνο λήψης αποφάσεων στις βιομηχανίες PCB.

Temperature Sensitive Short Term Load Forecasting: Fuzzy Logic Approach

Αυτό το άρθρο από τον Dharati Kulkarni, παρουσιάζει τη βραχυπρόθεσμη μεθοδολογία πρόβλεψης φορτίου χρησιμοποιώντας ασαφή λογική, η οποία λαμβάνει υπόψη τον χρόνο και τη θερμοκρασία ως εισόδους. Συνιστάται το προτεινόμενο ασαφές λογικό μοντέλο για βραχυπρόθεσμη πρόβλεψη φόρτωσης, καθώς λαμβάνει υπόψη τις ασαφείς εκφράσεις των εισόδων και παρέχει εύλογες ακριβείς προβλέψεις για το φορτίο, το

οποίο είναι αρκετά ευαίσθητο στη θερμοκρασία και ποικίλλει από το πρωί έως αργά το βράδυ. Οι προβλεπόμενες θερμοκρασίες και τα πιθανά φορτία για τον ίδιο οδηγούν τους μηχανικούς ελέγχου να λειτουργούν αποτελεσματικά το σύστημα ισχύος.

Weather Based Plant Diseases Forecasting Using Fuzzy Logic

Η ολοκληρωμένη διαχείριση επιβλαβών οργανισμών (IPM) είναι μια προσέγγιση που ενσωματώνει μια ποικιλία πρακτικών εφαρμογών για την ελαχιστοποίηση της απώλειας των παραγωγικών εκμεταλλεύσεων λόγω παρασίτων και παθογόνων με τη βέλτιστη χρήση φυτοφαρμάκων.

Το άρθρο από τους Vidita Tilva, Jignesh Patel, Chetan Bhatt, προτείνει ασαφή λογική δομή για την ασθένεια των φυτών σαν σύστημα πρόβλεψης. Αποδείχθηκε ότι η προτεινόμενη μέθοδος είναι αποτελεσματική για την πρόβλεψη τέτοιων προβλημάτων.

Fuzzy logic coupled with exhaustive search algorithm for forecasting of petroleum economic parameters

Στον τομέα τόσο του πετρελαίου όσο και του φυσικού αερίου, πολλά από τα αναπτυξιακά σχέδια και τις στρατηγικές αποφάσεις βασίζονται σχεδόν κατά κόρον σε οικονομικούς υπολογισμούς. Επομένως, κρίνεται αναγκαίο να δημιουργηθούν νέα μοντέλα για την ακριβή πρόβλεψη οικονομικών μεταβλητών με ελαχιστοποιημένο σφάλμα.

Σε αυτήν τη μελέτη των Meysam Naderi, Ehsan Khomehchi, αναλύονται δύο συστήματα ασαφών συμπερασμάτων τα οποία είναι βασισμένα στα μοντέλα Mamdani και TSK και σε συνδυασμό με έναν αλγόριθμο αναζήτησης εφαρμόζονται στην πρόβλεψη μηνιαίας τιμής πετρελαίου (MOP), ημερήσιας τιμής φυσικού αερίου (DGP) και ετήσιου επιτοκίου (AIR). Όλα τα απαιτούμενα δεδομένα συλλέχθηκαν από την Κεντρική Τράπεζα της Ισλαμικής Δημοκρατίας του Ιράν.

Τα αποτελέσματα δείχνουν ότι ο τύπος Mamdani ξεπερνά τα ARIMA και TSK στις προβλέψεις MOP, DGP και AIR ενώ παράλληλα ο βελτιστοποιημένος τύπος Mamdani μειώνει το RMSE κατά 69,19% στην πρόβλεψη MOP, κατά 84,37% στην πρόβλεψη DGP και κατά 93,67% στην πρόβλεψη AIR έναντι της μεθόδου αναφοράς.

An improved sales forecasting approach by the integration of genetic fuzzy systems and data clustering: Case study of printed circuit board

Η επιτυχής πρόβλεψη και ανάλυση των πωλήσεων για συγκεκριμένα αγαθά ή υπηρεσίες μπορεί να σημαίνει τη διαφορά μεταξύ κέρδους και ζημίας για μια λογιστική περίοδο η οποία όμως τελικά μπορεί να οδηγήσει στην επιτυχία ή την αποτυχία της ίδιας της επιχείρησης. Επομένως, η αξιόπιστη πρόβλεψη των πωλήσεων αποτελεί σημαντικό έργο.

Σε αυτό το άρθρο από τους Esmaeil Hadavandi, Hassan Shavandi, Arash Ghanbari, παρουσιάζεται μια νέα προσέγγιση πρόβλεψης πωλήσεων με την ενσωμάτωση γενετικών ασαφών συστημάτων (GFS) και ομαδοποίησης δεδομένων για την κατασκευή ενός συστήματος ειδικών πωλήσεων πρόβλεψης. Συγκρίνεται η απόδοση ενός εξαγόμενου εξειδικευμένου συστήματος με προηγούμενες μεθόδους πρόβλεψης πωλήσεων χρησιμοποιώντας μέσο απόλυτο ποσοστό σφάλματος (MAPE) και ριζικό μέσο τετραγωνικό σφάλμα (RMSE). Τα πειραματικά αποτελέσματα δείχνουν ότι η προτεινόμενη προσέγγιση ξεπερνά τις άλλες προηγούμενες προσεγγίσεις.

Using adaptive network-based fuzzy inference system to forecast automobile sales

Η βελτίωση της ακρίβειας των προβλέψεων πωλήσεων έχει καταστεί πρωταρχικό μέλημα της αυτοκινητοβιομηχανίας. Σε αυτό το άρθρο γίνεται εστίαση μόνο στις νέες πωλήσεις αυτοκινήτων στην Ταϊβάν. Το σύνολο δεδομένων βασίζεται σε μηνιαίες πωλήσεις και τα δεδομένα μπορούν να χωριστούν σε τρεις μορφές πωλήσεων αυτοκινήτων. Το μοντέλο πρόβλεψης πωλήσεων από τους Fu-Kwun Wang, Ku-Kuang Chang, Chih-Wei Tzeng, λαμβάνει υπόψη διάφορες μεταβλητές, όπως τη τρέχουσα ποσότητα πωλήσεων αυτοκινήτων, το δείκτη σύμπτωσης, το δείκτης κορυφής, το δείκτης τιμών χονδρικής και τέλος τα έσοδα. Οι πιο σημαντικές μεταβλητές ορίζονται ως μεταβλητές εισόδου. Στη συνέχεια αυτές οι μεταβλητές εισάγονται σε προσαρμοστικό σύστημα fuzzy inference system (ANFIS). Τέλος, γίνεται σύγκριση του συγκεκριμένου μοντέλου με δύο μοντέλα πρόβλεψης: Το μοντέλο αυτόματου επιθετικού ενσωματωμένου κινούμενου μέσου (ARIMA) και το τεχνητό νευρικό δίκτυο (ANN). Τα εμπειρικά αποτελέσματα δείχνουν ότι η εφαρμογή του μοντέλου ANFIS ξεπερνά τα άλλα δύο μοντέλα.

A fuzzy case-based reasoning model for sales forecasting in print circuit board industries

Η αξιόπιστη πρόβλεψη πωλήσεων μπορεί να βελτιώσει την ποιότητα της επιχειρηματικής στρατηγικής. Η συλλογιστική βάσει περιπτώσεων (CBR), μία από τις γνωστές τεχνικές τεχνητής νοημοσύνης (AI), έχει ήδη αποδείξει την αποτελεσματικότητά της σε διάφορες εξαχθείσες μελέτες. Ωστόσο, λόγω της αβεβαιότητας στην αναπαράσταση γνώσης, στην περιγραφή των χαρακτηριστικών και στα μέτρα ομοιότητας στην CBR, είναι πολύ δύσκολο να βρεθούν παρόμοιες περιπτώσεις από τις βάσεις δεδομένων. Προκειμένου να αντιμετωπιστεί αυτό το πρόβλημα, οι ασαφείς θεωρίες έχουν ενσωματωθεί στο CBR επιτρέποντας πιο ευέλικτα και ακριβή μοντέλα.

Αυτή η έρευνα από τους Pei-Chann Chang, Chen-Hao Liu, Robert K. Lai, αναπτύσσει μια ασαφή συλλογιστική βάσει περιπτώσεων (FCBR) και διερευνά την πιθανή χρήση της στην διαδικασία πρόβλεψης μελλοντικών πωλήσεων ενός εργοστασίου τυπωμένων κυκλωμάτων. Συλλέγονται αριθμητικά δεδομένα διαφόρων παραγόντων που επηρεάζουν την ζήτηση των τελευταίων 5 ετών του εργοστασίου και εισάγονται στο FCBR για μελλοντικές μηνιαίες προβλέψεις πωλήσεων. Τα πειραματικά αποτελέσματα δείχνουν την αποτελεσματικότητα του μοντέλου FCBR κατά τη σύγκριση του με άλλες προσεγγίσεις.

A sales forecasting system based on fuzzy neural network with initial weights generated by genetic algorithm

Η πρόβλεψη πωλήσεων είναι συνήθως πολύ περίπλοκη λόγω της επίδρασης των εσωτερικών και των εξωτερικών περιβαλλόντων. Ωστόσο, η αξιόπιστη πρόβλεψη μπορεί να βελτιώσει κατά πολύ την ποιότητα μιας επιχειρηματικής στρατηγικής. Τεχνικά νευρωνικά δίκτυα (ANN) έχουν εφαρμοστεί για προβλέψεις πωλήσεων λόγω της πολλά υποσχόμενης απόδοσής τους στους τομείς ελέγχου και αναγνώρισης προτύπων. Ωστόσο, απαιτείται περαιτέρω βελτίωση, καθώς σε ορισμένες περιστάσεις όπως η προώθηση μπορούν να προκαλέσουν ξαφνικές αλλαγές στα πρότυπα πωλήσεων. Η παρούσα μελέτη από τον R.J. Kuo, χρησιμοποιεί το ασαφές νευρωνικό δίκτυο από γενετικό αλγόριθμο (GFNN) για χάρη της εκμάθησης ασαφών κανόνων IF – THEN και προώθησης από ειδικούς μάρκετινγκ.

Τα μοντέλα αποτελεσμάτων αξιολόγησης για μια εταιρεία ψιλικών ειδών (CVS) δείχνουν ότι το προτεινόμενο σύστημα μπορεί να αποδώσει με μεγαλύτερη ακρίβεια από τη συμβατική στατιστική μέθοδο και ένα ενιαίο ANN.

Development of a fuzzy sales forecasting system for vending machines

Τα μηχανήματα αυτόματης πώλησης λειτουργούν 24 ώρες την ημέρα, επιτρέποντας στους καταναλωτές να λαμβάνουν προϊόντα οποιαδήποτε στιγμή της ημέρας αλλά και της νύχτας. Ωστόσο η κατανάλωση ηλεκτρικής ενέργειας είναι τόσο μεγάλη που ισοδυναμεί με τη συνολική παραγωγή ισχύος δύο πυρηνικών αντιδραστήρων στην Ιαπωνία. Σε αυτή την έρευνα οι Hidetaka Sakai, Hideki Nakajima, Minoru Higashihara, Masashi Yasuda, Masato Oosumi, προσπαθούν να πραγματοποιήσουν ένα σύστημα το οποίο θα μείωνε την ενέργεια που χρησιμοποιείται για την ψύξη των μηχανημάτων αυτόματης πώλησης κονσερβοποιημένων ποτών. Στην συγκεκριμένη έρευνα γίνεται πρόβλεψη του αριθμού των δοχείων που διανέμονται καθημερινά, έτσι ώστε η ηλεκτρική ενέργεια που θα χρησιμοποιείται για την ψύξη, να αφορά μόνο τον απαιτούμενο αριθμό δοχείων. Χρησιμοποιείται ασαφή λογική και ένα μοντέλο πολλαπλών παλινδρομήσεων έτσι ώστε να διορθωθεί η προηγούμενη τιμή πρόβλεψης για βελτιωμένη ακρίβεια. Τα αποτελέσματα επιβεβαιώνουν το γεγονός ότι η ενέργεια ψύξης θα μπορούσε να μειωθεί σε περίπου 1/10.

A two stage fuzzy piecewise logistic model for penetration forecasting

Είναι αναμφισβήτητο σημαντικό για μια εταιρεία να μπορεί να κάνει μια πρόβλεψη σχετικά με τον όγκο των πωλήσεων νέων προϊόντων. Ωστόσο, αυτή η διαδικασία εμπεριέχει πάντα αβέβαιους παράγοντες και ταχείες διακυμάνσεις όπου οι υπεύθυνοι λήψης αποφάσεων πρέπει να εξαγάγουν συμπεράσματα από ελάχιστα δεδομένα. Προηγούμενες μελέτες συνδυάζουν ανάλυση σεναρίων και μοντέλα υποκατάστασης τεχνολογίας για να προβλέψουν το μερίδιο αγοράς των πολυεθνικών τεχνολογιών. Ωστόσο, ένα τέτοιο μοντέλο δεν ταιριάζει πάντα καλά στην καμπύλη S. Επομένως, με βάση τα ιστορικά δεδομένα και τα δεδομένα που προβλέπονται από τις γνωστές μεθόδους, οι Fang-Mei Tsenga, Jing-Rung Yu, προτείνουν ένα δύο σταδίων ασαφές κομμάτι λογιστικής ανάπτυξης με πολλαπλούς αντικειμενικούς προγραμματισμούς. Προκειμένου να αποδειχθεί η απόδοση του μοντέλου, αντιμετωπίζονται δύο

περιπτώσεις στις βιομηχανίες Τηλεόρασης και Τηλεπικοινωνιών χρησιμοποιώντας την προτεινόμενη μέθοδο και το μοντέλο υποκατάστασης τεχνολογίας ή το μοντέλο διάχυσης Norton και Bass. Μια σύγκριση των αποτελεσμάτων δείχνει ότι το προτεινόμενο μοντέλο ξεπερνά το μοντέλο υποκατάστασης τεχνολογίας και το μοντέλο διάχυσης Norton και Bass.

A neuro-fuzzy based forecasting approach for rush order control applications


Αυτό το άρθρο από τους Wen-Pai Wang, Ze Chen, προτείνει ένα προσαρμοστικό σύστημα νευρο-ασαφών συμπερασμάτων (ANFIS) και ένα σύστημα KERNEL για την επίλυση του προβλήματος της πρόβλεψης βιαστικών παραγγελιών για τη ρύθμιση του μηχανισμού κράτησης χωρητικότητας εκ των προτέρων. Πιο συγκεκριμένα γίνεται σύγκριση αποτελεσμάτων με την παραδοσιακή ανάλυση παλινδρόμησης και λαμβάνονται οι προτιμώμενες προβλέψεις. Τα αποτελέσματα της έρευνας δείχνουν ότι η ορθότητα των προβλέψεων είναι 83% από την ANFIS, η οποία είναι ανώτερη από τον τρόπο παλινδρόμησης με 63%. Αναφέρονται επίσης προκαταρκτικά αποτελέσματα για την εφαρμογή των προτεινόμενων μεθόδων.

3. ΠΡΟΤΕΙΝΟΜΕΝΕΣ ΠΡΟΣΕΓΓΙΣΕΙΣ

3.1 Τεχνητά Νευρωνικά Δίκτυα

Τα τεχνητά νευρωνικά δίκτυα μιμούνται ουσιαστικά την λειτουργία του κεντρικού νευρικού συστήματος του εγκεφάλου. Αποτελούνται από διασυνδεδεμένα υπολογιστικά στοιχεία και δέχονται κάποιο ερέθισμα στην είσοδό τους.

Η λειτουργία του εγκεφάλου βασίζεται στους νευρώνες ή νευρικά κύτταρα τα οποία επικοινωνούν συνεχώς μεταξύ τους. Έτσι αυτός ο κλάδος ασχολείται με την κατασκευή μοντέλου που θα μιμείται αυτή την διαδικασία. Στη πράξη όμως τα μοντέλα που δημιουργούνται είναι πολύ πιο απλοποιημένα και έχουν ελάχιστα χαρακτηριστικά από αυτά των βιολογικών νευρώνων.



Εικόνα 1: Νευρωνικό δίκτυο

3.1.1 Ορισμός Νευρωνικού Δικτύου

Το νευρωνικό δίκτυο είναι ένα δίκτυο το οποίο αποτελείται από υπολογιστικούς κόμβους (νευρώνες, νευρώνια), που είναι διασυνδεδεμένοι μεταξύ τους. Στη πράξη κανένας νευρώνας δεν είναι ολόιδιος με κάποιον άλλον.

Κάθε τέτοιος κόμβος δέχεται ένα σύνολο εισόδων από διαφορετικές πηγές όπως είναι το περιβάλλον ή άλλοι νευρώνες και με βάσει αυτές τις πληροφορίες παράγει μία έξοδο. Η συγκεκριμένη έξοδος είτε οδηγείται στο περιβάλλον, είτε αποτελεί την είσοδο σε κάποιο άλλο νευρώνα του δικτύου. Μπορούμε να πούμε ότι χωρίζονται σε τρεις τύπους

Νευρώνες εισόδου

Οι νευρώνες εισόδου δεν επιτελούν κάποιο είδος υπολογισμού. Ουσιαστικά μεσολαβούν ανάμεσα από τις περιβαλλοντικές εισόδους του δικτύου και στους υπολογιστικούς νευρώνες.

Υπολογιστικοί νευρώνες

Οι υπολογιστικοί νευρώνες παίρνοντας σήματα εισόδου, κάνουν ο πολλαπλασιασμό με το αντίστοιχο συναπτικό βάρος και υπολογίζουν το ολικό άθροισμα των γινομένων. Τα σήματα που επεξεργάζεται ένας νευρώνας είναι ηλεκτρικής μορφής, και είναι της τάξης μερικών mV.

Νευρώνες εξόδου

Οι νευρώνες εξόδου οδηγούν στο περιβάλλον τις τελικές τιμές εξόδου που έχουν υπολογιστεί από τους αντίστοιχους υπολογιστικούς νευρώνες.

3.1.2 Ιστορικά Στοιχεία

Ιστορικά η θεωρία των νευρωνικών δικτύων είναι σχετικά καινούργια και μετράει περίπου 50 χρόνια.

Η πρώτη προσπάθεια κατασκευής ενός τέτοιου μοντέλου έγινε από τους McCulloch και Pitts το 1943. Παρουσίασαν για πρώτη φορά ένα μοντέλο νευρωνικού δικτύου το οποίο θα αποτελούνταν από ένα μεγάλο αριθμό νευρώνων τα οποία θα μπορούσαν να λειτουργήσουν και να συνεργαστούν μεταξύ τους.

Ο McCulloch ήταν νευροφυσιολόγος και ο Pitts ένας πρωτοετής φοιτητής των Μαθηματικών. Το 1947 βελτίωσαν το αρχικό τους μοντέλο σε ένα πιο εξελιγμένο το οποίο θα μπορούσε αυτή τη φορά να αναγνωρίζει και σχήματα. Σε αυτό το μοντέλο ο νευρώνας είναι σε θέση να δέχεται πολλές εισόδους αλλά μπορεί να δώσει μόνο μία έξοδο. Συνεπώς οι έξοδοι από κάθε νευρώνα είναι ανεξάρτητοι αλλά πρέπει υποχρεωτικά να αποτελούν είσοδο ενός άλλου νευρώνα.

Οι απολήξεις των νευρώνων μπορεί να είναι:

- Διεγερτικές
- Ανασταλτικές

Επίσης η πληροφορία στον νευρώνα ελέγχεται από πύλες οι οποίες μπορούν να είναι και αυτές αντίστοιχα ή διεγερτικές ή ανασταλτικές. Με αυτούς τους δύο όρους εννοούμε ότι είτε θα πυροδοτείται ένας νευρώνας είτε θα βρίσκεται σε ηρεμία.

Οι λειτουργίες θεωρούμε ότι γίνονται σε διακριτό χρόνο και ότι όλοι οι νευρώνες ανταποκρίνονται ταυτόχρονα. Η γενική ιδέα στηρίζεται σε ένα μηχανισμό ανάδρασης (feedback) το οποίο μεταφράζεται ως μόνιμη κατάσταση ηρεμίας έως ότου εισαχθεί νέο εξερχόμενο σήμα στο σύστημα.

Δύο χρόνια αργότερα το 1949 κυκλοφόρησε το βιβλίο “The organisation of behavior” του D. Hebb. Το μοντέλο του Hebb έχει ως κεντρική ιδέα την σύνδεση μεταξύ των νευρώνων. Μετά από διάφορα πειράματα έβγαλε το συμπέρασμα ότι κάθε φορά που το δίκτυο χρησιμοποιεί τις νευρωνικές του συνδέσεις, αυτές ενισχύονται και το δίκτυο πλησιάζει περισσότερο στο να μάθει το πρότυπο το οποίο παρουσιάζεται. Μαθηματικά αυτό εκφράζεται ως ο νευρώνας i που διεγείρει επανειλημμένα τον νευρώνα j δημιουργεί μια σύνδεση μεταξύ τους και αν w_{ij} είναι το βάρος της σύνδεσής τους, x_i είναι η είσοδος στον νευρώνα j από τον νευρώνα i και y_i είναι ή έξοδος τότε ισχύει:

$$w_{ij(new)} = w_{ij(old)} + ax_i x_j$$

Όπου a είναι μια θετική παράμετρος και ονομάζεται ρυθμός εκπαίδευσης

Το 1957 παρουσιάστηκε το πρώτο δίκτυο με hardware από τον F. Rosenblatt. Αποτελούνταν μόνο από το επίπεδο της εισόδου και το επίπεδο της εξόδου. Αρχικά το συγκεκριμένο μοντέλο βρήκε μεγάλη απήχηση και επιτυχία και θεωρήθηκε ότι θα λύνει όλα τα προβλήματα που μέχρι τότε ήταν άλυτα. Στη συνέχεια όμως φάνηκε ότι το μοντέλο αυτό είχε και πολλούς περιορισμούς. Μια καλή εικόνα του συγκεκριμένου μοντέλου παρουσιάστηκε στο βιβλίο "Perceptrons" των Minsky και Papert το 1969. Σε αυτό το βιβλίο γίνεται μια συνολική εκτίμηση του μοντέλου και με αναλυτικά μαθηματικά δείχνεται ότι υπάρχουν ορισμένοι περιορισμοί όπως π.χ. να λύσει ένα από πρόβλημα X-OR.

Το 1959 οι Widrow και Hoff ανέπτυξαν δύο νέα μοντέλα το Adaline και το Madaline. Βρήκαν πρακτική εφαρμογή ως φίλτρα εξάλειψης της ηχώ στις τηλεφωνικές γραμμές. Μέχρι και το 1980 δεν υπήρξε κάποιος σημαντικός σταθμός για τα νευρωνικά δίκτυα τα οποία πλέον θεωρούνταν κάπως παρωχημένα και ο επιστημονικός κόσμος είχε ήδη αρχίσει να στρέφεται προς την τεχνητή νοημοσύνη.

Το 1982 ο J. Hopfield παρουσίασε μια ολιγοσέλιδη εργασία στην οποία απέδειξε με αυστηρά μαθηματικά ότι ένα νευρωνικό δίκτυο μπορεί να χρησιμοποιηθεί ως αποθηκευτικός χώρος και πως επίσης μπορεί ένα δίκτυο να επανακτήσει όλη την πληροφορία ενός συστήματος έστω και αν του δοθούν μόνο μερικά τμήματα και όχι ολόκληρο το σύστημα.

Η παραπάνω εργασία φέρνει και πάλι στο προσκήνιο τα νευρωνικά δίκτυα και το 1986 δημοσιεύεται ένα άλλο σημαντικό έργο από τους McClelland και Rumelhart, το "Parallel Distributed Processing. Σε αυτό το έργο παρουσιάζεται η ιδέα ότι ένα νευρωνικό δίκτυο μπορεί να θεωρηθεί και χρησιμοποιηθεί ως παράλληλος επεξεργαστής. Σε αντίθεση με το μοντέλο Perceptron, εκτός από την είσοδο και έξοδο υπάρχουν και άλλα επίπεδα νευρώνων τα οποία αποτελούν την εσωτερική δομή του δικτύου. Προτείνουν μια νέα διαδικασία εκπαίδευσης, την οπισθοδιάδοση (back-propagation), η οποία χρησιμοποιείται ακόμα και σήμερα.

Μετά την δεύτερη άνθηση που βρήκαν τα νευρωνικά δίκτυα κατά την δεκαετία του 80 αποκτούν ένα ανεξάρτητο πεδίο στην επιστήμη και τα πρώτα συνέδρια που αφορούν τα νευρωνικά δίκτυα αρχίζουν να εμφανίζονται το 1985 από την American Physical Society και από την IEEE. Αρχίζουν επίσης παράλληλα να δημιουργούνται εταιρίες νευρωνικών δικτύων όπως η International Neural Network Society.

Από το 1990 και έπειτα παρουσιάζονται και άλλα επιστημονικά περιοδικά τα οποία ασχολούνται με τα νευρωνικά δίκτυα μέχρι και σήμερα.

3.1.3 Από τα Βιολογικά Νευρωνικά Δίκτυα στα Τεχνητά


Ο εγκέφαλος του ανθρώπου έχει μία από τις πιο περίπλοκες δομές που γνωρίζει ο άνθρωπος και μέχρι και σήμερα μπορούμε να πούμε ότι γνωρίζουμε πολύ λίγα σχετικά με την λειτουργία του. Αυτό συμβαίνει διότι ουσιαστικά μπορούμε να εξηγήσουμε πολύ λίγα πράγματα από τις λειτουργίες του.

Όσο αναφορά τη δομή του γνωρίζουμε αρκετά πράγματα όπως ότι χωρίζεται σε δύο ημισφαίρια και ότι ορισμένες λειτουργίες γίνονται από συγκεκριμένα τμήματα. Στις μέρες μας γίνονται ακόμα και εγχειρήσεις σε διάφορα τμήματα του εγκεφάλου που είναι ελάχιστου μεγέθους. Παρόλα αυτά γνωρίζουμε ελάχιστα όσο αναφορά τις γενικές του λειτουργίες. Η δυσκολία έγκειται στο γεγονός ότι ο εγκέφαλος αναπτύσσει ευφυΐα, συναισθήματα κλπ, κάτι το οποίο δε μπορεί να πορβλέψει ένα τεχνητό μοντέλο.

Βασική μονάδα δόμησης του εγκεφάλου είναι ένα κύτταρο που ονομάζεται νευρώνας, και το οποίο λειτουργεί όπως και τα άλλα κύτταρα του οργανισμού. Όλοι οι νευρώνες είναι διαφορετικοί μεταξύ τους και δεν υπάρχουν δύο ολόιδιοι παρόλη τη τεράστια ποσότητα που υπάρχουν. Υπάρχουν περίπου 100 διαφορετικού τύποι νευρώνων, αλλά και ο αριθμός αυτός εξαρτάται από το πως ορίζουμε την κατηγορία. Κάθε νευρώνας συνδέεται με πολλούς άλλους νευρώνες και οι συνδέσεις ονομάζονται συνάψεις. Ο

αριθμός των συνάψεων δεν είναι σταθερός και ποικίλλει ανάλογα τη θέση στην οποία βρίσκονται. Ένας αριθμός νευρώνων με τις διασυνδέσεις τους αποτελούν ένα νευρωνικό δίκτυο (neural net). Το σύνολο όλων των νευρωνικών δικτύων στον ανθρώπινο οργανισμό αποτελεί το Κεντρικό Νευρικό Σύστημα.

Ο ρόλος του νευρώνα σε ένα νευρωνικό δίκτυο είναι να δέχεται σήματα που έρχονται από άλλους νευρώνες, να τα επεξεργάζεται, και να τα μεταδίδει σε άλλους νευρώνες, ούτως ώστε ένα σήμα να διαδίδεται μέσω ενός τεραστίου αριθμού νευρώνων. Τα σήματα που επεξεργάζεται ένας νευρώνας είναι ηλεκτρικής μορφής, και είναι της τάξης μερικών mV. Ένας νευρώνας αποτελείται από το κυρίως σώμα, τον άξονα, και τους δενδρίτες όπως φαίνεται και στην παρακάτω εικόνα:



Εικόνα 2: Διάταξη ενός νευρώνα


Οι συνδέσεις μεταξύ των νευρώνων, με τους άξονες και τους δενδρίτες, γίνονται στις επαφές που ονομάζονται συνάψεις. Η δομή της σύναψης είναι αρκετά περίπλοκη όπως και οι διεργασίες που επιτελεί. Ο άξονας έχει πολλές διακλαδώσεις και στέλνει πολλά σήματα σε διαφορετικά σημεία. Στα σημεία που εφάπτονται οι δενδρίτες δημιουργείται μία σύναψη. Η μεμβράνη του νευρώνα που στέλνει το σήμα ονομάζεται προ-συναπτική, ενώ αυτή του δεύτερου νευρώνα (δέκτη) ονομάζεται μετα-συναπτική.

Τα συναπτικά κυστίδια που βρίσκονται στην άκρη του άξονα ελευθερώνουν τους νευρομεταβιβαστές. Οι νευρομεταβιβαστές διαπερνούν το συναπτικό χάσμα και έτσι φθάνουν στον δενδρίτη του άλλου νευρώνα. Μερικοί νευρομεταβιβαστές είναι διεγερτικοί, ενώ άλλοι είναι ανασταλτικοί. Όταν ελευθερώνονται οι μεταβιβαστές από ένα νευρώνα και φθάνουν σε έναν άλλο μέσω της σύναψης τότε επηρεάζεται η μεμβράνη του αποδέκτη-νευρώνα και αλλάζει η κατάσταση του ως προς το σήμα που θα στείλει, επομένως επηρεάζεται και αυτός ο νευρώνας.

Κάθε νευρώνας μπορεί να έχει δύο δυνατές καταστάσεις:

- Ενεργός
- Μη ενεργός

Όταν ο νευρώνας είναι ενεργός λέμε ότι πυροδοτεί, ενώ όταν είναι μη-ενεργός λέμε ότι είναι αδρανής. Επομένως δεν υπάρχουν ενδιάμεσες καταστάσεις. Θα λέγαμε ότι ο νευρώνας συμπεριφέρεται σαν ένα δυαδικό (binary) στοιχείο, και μοιάζει στο σημείο αυτό με τους ηλεκτρονικούς υπολογιστές. Όταν ο νευρώνας πυροδοτεί, παράγει ένα ηλεκτρικό σήμα (παλμό), το οποίο κάθε φορά έχει τα ίδια χαρακτηριστικά. Η δημιουργία ηλεκτρικών σημάτων γίνεται μεταξύ διαφοράς δυναμικού μεταξύ της εσωτερικής και της εξωτερικής επιφάνειας, όπως δηλαδή γίνεται και σε έναν πυκνωτή.



Εικόνα 3: Σύνδεση νευρώνων μεταξύ τους

Οι αριθμοί των μονάδων των νευρώνων κυμαίνονται από 10^9 – 10^{11} αριθμός τάξης μεγέθους πολύ μεγαλύτερος από αυτόν που μπορεί να χειριστεί σήμερα ένας υπολογιστής. Τα τεχνητά νευρωνικά δίκτυα (ΤΝΔ) υπολείπονται κατά πολύ στο σημείο αυτό, και δεν μπορούν να κάνουν πράγματα που ο εγκέφαλος ακόμα και ενός παιδιού επιτελεί με μεγάλη ευκολία. Ένα ΤΝΔ μπορεί να έχει εκατοντάδες ή χιλιάδες νευρώνες αλλά όχι την τάξη μεγέθους που έχει ο εγκέφαλος.

Μια άλλη χαρακτηριστική διαφορά μεταξύ βιολογικού και νευρικού δικτύου είναι οι συνάψεις. Στα βιολογικά δίκτυα είναι ιδιαίτερα περίπλοκες και αναλαμβάνουν να επιτελέσουν πληθώρα έργων ενώ στα τεχνητά νευρικά δίκτυα είναι πολύ πιο απλές.

Παρότι η ταχύτητα διάδοσης του σήματος στα τεχνητά νευρωνικά δίκτυα είναι πολύ πιο γρήγορη από ότι η ταχύτητα διάδοσης στα βιολογικά, το φάσμα που υπάρχει στη πολυπλοκότητα των βιολογικών συνάψεων σε σχέση με τα τεχνητά, δεν μπορεί να υπερκαλυφθεί μόνο από την ταχύτητα.

Ενώ ο ανθρώπινος εγκέφαλος μαθαίνει, καταλαβαίνει πολύ γρήγορα, η μάθηση σε ένα τεχνητό νευρωνικό δίκτυο αυτό παίρνει πολύ χρόνο, ακόμα και σε ένα σύγχρονο και γρήγορο υπολογιστή. Τέλος, ο εγκέφαλος μπορεί να κάνει σύγχρονη ή ασύγχρονη ενημέρωση των μονάδων του ενώ το ΤΝΔ κάνει μόνον σύγχρονη ενημέρωση, δηλαδή σε διακριτό χρόνο.

3.1.4 Χρήση Νευρωνικών Δικτύων και Εφαρμογές

Τα τεχνητά νευρωνικά δίκτυα χρησιμοποιούνται ευρέως στις μέρες μας σε διάφορους τομείς εξαιτίας την μεγάλης υπολογιστικής τους ταχύτητας, την αντιμετώπιση μη γραμμικών προβλημάτων και την αναγνώριση σχέσεων ποσοτικών μεγεθών οι οποίες είναι δύσκολο να μοντελοποιηθούν. Οι πιο συνηθισμένες εφαρμογές των νευρωνικών δικτύων είναι οι ακόλουθες:

- Βιολογία: Χρησιμοποιούνται για την κατανόηση της λειτουργίας του εγκεφάλου καθώς και για την δημιουργία μοντέλων όρασης.
- Γεωλογία: Χρησιμοποιούνται για την ανάλυση πιθανοτήτων ύπαρξης πετρελαίου σε πετρώματα καθώς και στην ανάλυση πετρωμάτων σε ορυχεία.
- Ιατρική: Χρησιμοποιείται για την κατασκευή ακουστικών βοηθημάτων, παρακολούθηση εγχείρησης, ανάγνωση ακτινογραφιών, αυτόματη διάγνωση και θεραπεία συμπτωμάτων, προβλέψεις για αντιδράσεις οργανισμών στη λήψη φαρμάκων, όπως και μοντέλα πρόβλεψης αναπνευστικών προβλημάτων.
- Βιομηχανία: Αυτοματοποίηση ρομπότ και συστημάτων ελέγχου, έλεγχος χημικών διεργασιών, έλεγχος γραμμής παραγωγής, επιλογή ορθών ανταλλακτικών κατά την συναρμολόγηση, ρύθμιση ηλεκτρικού φορτίου, Παρακολούθηση της κατάστασης των μηχανημάτων ώστε να διακρίνει από

τους ήχους τους οποίους παράγει μια μηχανή αν εκτελεί κανονικά τις λειτουργίες ή βρίσκεται στα πρόθυρα εμφάνισης οποιασδήποτε δυσλειτουργίας, καθώς και σε διάφορες εφαρμογές οχημάτων.

- Χημική ανάλυση: Χρησιμοποιούνται σε περιπτώσεις που πρέπει να ληφθούν γρήγορες αποφάσεις και δεν υπάρχει χρόνος για λεπτομερείς και χρονοβόρες αναλύσεις. Ένα χαρακτηριστικό παράδειγμα είναι ο έλεγχος των αποσκευών για εκρηκτικές ή εύφλεκτες ύλες.
- Επεξεργασία σημάτων: Χρησιμοποιείται για αφαίρεση παράσιτων σε μία τηλεφωνική γραμμή καθώς και στην ενίσχυση σήματος.
- Υπολογιστές: Χρησιμοποιείται για αναγνώριση προτύπων όπως αναγνώριση χειρόγραφων χαρακτήρων, αναγνώριση προσώπου και φωνής, σε εφαρμογές αναγνώρισης τραγουδιών(Shazam), στην αναγνώριση ανεπιθύμητων μηνυμάτων (spam detection) καθώς και σε ηλεκτρονικά παιχνίδια.
- Αεροπορία: Χρησιμοποιείται για την δημιουργία αυτόματων πιλότων και προγραμμάτων προσομοίωσης πτήσης, σε συστήματα ελέγχου πτήσης καθώς και στην ανίχνευση ελαττωμάτων σε διάφορα τμήματα του αεροπλάνου.
- Μετεωρολογία: Χρησιμοποιείται για την πρόγνωση του καιρού και την ανάλυση καιρικών συνθηκών.
- Άμυνα: Χρησιμοποιείται για την αναγνώριση σημάτων ραντάρ
- Οικονομία: Χρησιμοποιείται για την πρόβλεψη τιμών μετοχής, ανάλυσης επικινδυνότητας δανείων, αξιολόγηση επενδύσεων, ανίχνευση απάτης σε ηλεκτρονικές συναλλαγές καθώς και στην εκτίμηση αξίας ακινήτων.

3.1.5 Αρχιτεκτονική Νευρωνικών Δικτύων


Όπως αναφέρθηκε και στις προηγούμενες παραγράφους ένα τεχνητό νευρωνικό δίκτυο είναι ένας τεράστιος αριθμός από νευρώνες αλληλοσυνδεδεμένοι μεταξύ τους. Οι νευρώνες ενός ΤΝΔ οργανώνονται σε μορφή επίπεδων και ο τρόπος με τον οποίο είναι δομημένοι, εξαρτάται από τον αλγόριθμο μάθησης που χρησιμοποιείται για την εκπαίδευση αυτού του δικτύου.

Ο νευρώνας υπολογίζει το σήμα εισόδου του δικτύου (net) και στη συνέχεια χρησιμοποιεί τη συνάρτηση ενεργοποίησης για να υπολογίσει το σήμα εξόδου του νευρώνα, με βάση το σήμα εισόδου που δέχτηκε. Η ένταση του σήματος εξόδου του νευρώνα επηρεάζεται επίσης και από την τιμή της παραμέτρου μεροληψίας (bias), η οποία θεωρείται μίας επιπλέον είσοδος στο νευρώνα και συνήθως παίρνει τη σταθερή τιμή 1.

Ο υπολογισμός του σήματος εισόδου του νευρώνα γίνεται με τον υπολογισμό του αθροίσματος των σημάτων εισόδου προς τον νευρώνα. Η συνάρτηση ενεργοποίησης του νευρώνα δέχεται το σήμα εισόδου του δικτύου και επιστρέφει την τιμή εξόδου του νευρώνα. Οι συναρτήσεις ενεργοποίησης που μπορούν να χρησιμοποιηθούν είναι πολλές και η επιλογή τους εξαρτάται συνήθως από τη φύση του προβλήματος. Συνήθεις τύποι συναρτήσεων ενεργοποίησης νευρώνα είναι:

Κατώφλι (threshold)


Η συνάρτηση αυτή λειτουργεί σαν δυαδική πύλη, που είτε επιτρέπει την ενεργοποίηση του νευρώνα αν η τιμή της εισόδου είναι μεγαλύτερη ή ίση του 0 και επιστρέφει την τιμή 1, είτε επιστρέφει 0. Οι νευρώνες αυτού του είδους είναι τύπου McCulloch-Pits, που αναφέρθηκε στις παραπάνω παραγράφους.



Εικόνα 4: Συνάρτηση κατώφλι

Συνάρτηση προσήμου (Signum)


Ουσιαστικά αποτελεί μια παραλλαγή της παραπάνω συνάρτησης και επιστρέφει τις τιμές 1, -1 και 0, ενδεικτικές του προσήμου.



Εικόνα 5: Συνάρτηση προσήμου

Γραμμική (Linear)


Η είσοδος και η έξοδος νευρώνων που χρησιμοποιούν αυτού του είδους συνάρτηση ενεργοποίησης είναι γραμμικά εξαρτημένες μεταξύ τους.



Εικόνα 6: Γραμμική συνάρτηση

Βαθμωτή Γραμμική (Piecewise-Linear)

Η βαθμωτή γραμμική συνάρτηση είναι μία πιο σύνθετη μορφή της συνάρτησης κατώφλι. Η συνάρτηση για τιμές της μεγαλύτερες του $1/2$ ή μικρότερες του $-1/2$ λειτουργεί με τρόπο παρόμοιο με αυτή της συνάρτησης κατώφλι ενώ για τις ενδιάμεσες τιμές επιστρέφει την ίδια την τιμή λειτουργώντας σαν γραμμική συνάρτηση. Η βαθμωτή γραμμική συνάρτηση μπορεί να χρησιμοποιηθεί και ως προσέγγιση των πιο πολύπλοκων μη γραμμικών σιγμοειδών συναρτήσεων ενεργοποίησης που χρησιμοποιούνται στα νευρωνικά δίκτυα, μιας και έχει μικρότερο υπολογιστικό κόστος.




Εικόνα 7: Βαθμωτή γραμμική συνάρτηση

Σιγμοειδείς συναρτήσεις (Sigmoid)


Οι σιγμοειδείς συναρτήσεις είναι αυτές που χρησιμοποιούνται εκτενέστερα για την ενεργοποίηση ενός νευρώνα. Είναι γνησίως αύξουσες και διαφορίσιμες συναρτήσεις και επιπλέον κινούνται ασυμπτωτικά στο άπειρο. Ένα κλασσικό παράδειγμα είναι η λογιστική συνάρτηση όπου η παράμετρος a είναι η παράμετρος κλίσης της καμπύλης

της σιγμοειδούς συνάρτησης και η συνάρτηση υπερβολικής εφαπτομένης (hyperbolic tangent) η οποία κινείται στο διάστημα $(-1, 1)$.

Η ιδιότητα μιας σιγμοειδούς συνάρτησης όπως η υπερβολική εφαπτομένη να επιστρέφει και αρνητικές τιμές, θεωρείται αναλυτικό πλεονέκτημα της συνάρτησης. Τέλος πειραματικές έρευνες στη Νευροφυσιολογία έχουν δείξει ότι η συνάρτηση υπερβολικής εφαπτομένης θεωρείται η καλύτερη μαθηματική προσομοίωση της διαδικασίας ενεργοποίησης των νευρώνων.



Εικόνα 8: Λογιστική συνάρτηση



Εικόνα 9: Υπερβολική εφαπτομενική συνάρτηση


3.1.6 Είδη Αρχιτεκτονικών Δομών

Δίκτυο πρόσθιας τροφοδότησης ενός επιπέδου (Single Layer Feedforward Networks)

Αποτελούν ουσιαστικά την πιο απλή μορφή δικτύου. Έχουν ένα επίπεδο εισόδου που αποτελείται από κόμβους και μεταφέρει την πληροφορία στο επόμενο επίπεδο νευρώνων εξόδου αλλά όχι αντίστροφα. Δηλαδή το σήμα κινείται από το επίπεδο εισόδου στο επίπεδο εξόδου. Με απλά λόγια το σήμα που εισέρχεται στην είσοδο απλά μεταφέρεται στην έξοδο χωρίς καμία επεξεργασία.

Ο υπολογισμός γίνεται στο επίπεδο των νευρώνων και το σύνολο των εξόδων των νευρώνων αυτού του επιπέδου αποτελεί το διάνυσμα εξόδου από το δίκτυο. Ακριβώς

λόγω της ιδιότητας αυτής της μορφής των δικτύων να μεταβιβάζεται η υπολογιστική διαδικασία από την είσοδο του δικτύου προς την έξοδο, τα δίκτυα αυτά ονομάζονται δίκτυα πρόσθιας τροφοδότησης (Feedforward Networks). Χαρακτηριστική εφαρμογή αυτού του τύπου νευρωνικών δικτύων είναι οι συσχετιστικές μνήμες. Σε αυτού του είδους τις εφαρμογές, το δίκτυο συσχετίζει ένα διάνυσμα εξόδου με ένα διάνυσμα εισόδου.



Εικόνα 10: Δίκτυο πρόσθιας τροφοδότησης ενός επιπέδου


Δίκτυο πρόσθιας τροφοδότηση πολλών επιπέδων (Multilayer Feedforward Networks)

Η κύρια διαφορά σε αυτό τον τύπο νευρωνικών δικτύων είναι η ύπαρξη περισσότερων από ένα επιπέδων νευρώνων. Τα επιπλέον επίπεδα ονομάζονται κρυφά επίπεδα και οι νευρώνες που τα αποτελούν, κρυφοί νευρώνες. Η λειτουργία τους βασίζεται στο γεγονός ότι επεμβαίνουν μεταξύ της εξωτερικής εισόδου στο δίκτυο και της εξόδου του δικτύου.

Το κυριότερο πλεονέκτημα αυτού του τύπου νευρωνικών δικτύων είναι το γεγονός ότι η ύπαρξη ενός ή περισσότερων επιπέδων δίνει τη δυνατότητα στο δίκτυο να απορροφά περισσότερες πληροφορίες για τα δεδομένα εισόδου λόγω των περισσότερων συνάψεων που υπάρχουν. Το αποτέλεσμα είναι να επεξεργάζεται μεγαλύτερης πολυπλοκότητας δεδομένα και με μεγαλύτερη ταχύτητα.

Η διαδικασία υπολογισμού είναι ίδια με πριν δηλαδή οι κόμβοι του επιπέδου εισόδου του δικτύου παρέχουν το διάνυσμα εισόδου του δικτύου στους κόμβους του 1ου κρυφού επιπέδου. Εκτελείται ο υπολογισμός στους κόμβους του 1ου επιπέδου και στη συνέχεια η έξοδος του 1ου κρυφού επιπέδου παρέχεται σαν είσοδος στους νευρώνες του 2ου κρυφού επιπέδου. Αφού εκτελεστεί ο υπολογισμός η έξοδος μεταφέρεται στο

επόμενο επίπεδο νευρώνων, και η διαδικασία συνεχίζεται, με το ένα επίπεδο να χρησιμοποιεί σαν είσοδο την έξοδο του προηγούμενου, μέχρι να γίνει ο υπολογισμός της απάντησης του δικτύου από το τελευταίο επίπεδο.




Εικόνα 11: Δίκτυο πρόσθιας τροφοδότησης 2 κρυφών επιπέδων

Αναδρομικά Δίκτυα (Recurrent Networks)

Η Κύρια διαφορά αυτού του τύπου νευρωνικών δικτύων με τα παραπάνω δύο είναι η ύπαρξη ενός τουλάχιστον βρόχου ανάδρασης (feedback loop). Με τον όρο ανάδραση εννοούμε ότι η ροή μπορεί να κινηθεί και ως προς την αντίθετη κατεύθυνση από αυτήν που είδαμε στα παραπάνω δύο νευρωνικά δίκτυα.

Πιο συγκεκριμένα ένα αναδρομικό νευρωνικό δίκτυο έχει την δυνατότητα να αποτελείται από ένα ή περισσότερα επίπεδα νευρώνων όπου κάθε επίπεδο τροφοδοτεί στην έξοδό του όλους τους νευρώνες του δικτύου. Μπορεί επίσης ένας νευρώνας να δέχεται σαν είσοδο την ίδια του την έξοδο (αυτοανάδραση).


Η ύπαρξη βρόχων ανάδρασης σε ένα νευρωνικό δίκτυο παίζει καθοριστικό ρόλο στην ικανότητα ενός δικτύου να μαθαίνει καθώς και στην γενική του απόδοσή. Επίσης οι βρόχοι ανάδρασης καθιστούν δυνατό τη χρήση στοιχείων καθυστέρησης (unit delay units) σε κάποιες διασυνδέσεις, κάτι που επιτρέπει στο δίκτυο να αποκτήσει μη γραμμική δυναμική συμπεριφορά. Το παραπάνω σε αρκετές εφαρμογές είναι απαραίτητο.



Εικόνα 12: Αναδρομικό δίκτυο

Δίκτυα με Δικτυωτές Δομές (Lattice Structures Networks)

Τα νευρωνικά δίκτυα με δικτυωτές δομές μπορούν να είναι μονοδιάστατα, δισδιάστατα ή πολυδιάστατα. Αποτελούνται από συστοιχίες νευρώνων, όπου ο κάθε νευρώνας συνδέεται με τους κόμβους εισόδου στο δίκτυο. Ουσιαστικά είναι feedforward δίκτυα με τους νευρώνες εξόδου να είναι διατεταγμένοι σε γραμμές και στήλες.



Εικόνα 13: Δισδιάστατη δικτυωτή δομή με νευρώνες 2×2

3.1.7 Λειτουργία Νευρωνικών Δικτύων

Η λειτουργία των νευρωνικών δικτύων βασίζεται στην διαδικασία της μάθησης. Τα αντικείμενα της μάθησης που επηρεάζουν την λειτουργία των νευρωνικών δικτύων είναι:

Προσέγγιση (Aproximation)

Στόχος του συγκεκριμένου ζητούμενου είναι η σχεδίαση ενός νευρωνικού δικτύου το οποίο να προσεγγίζει μία μη γραμμική απεικόνιση εισόδου – εξόδου.

Συσχέτιση (Association)

Αφορά την αυτοσυσχέτιση όπου το δίκτυο πρέπει να αποθηκεύει ένα σύνολο προτύπων και να τα παρουσιάζει επαναληπτικά και η ετεροσυσχέτιση όπου ένα αυθαίρετο σύνολο προτύπων εισόδου συνεργάζεται με ένα αυθαίρετο σύνολο προτύπων εξόδου.

Ταξινόμηση Προτύπων (Pattern Classification)

Σκοπός του συγκεκριμένου αντικείμενου είναι η ταξινόμηση των ερεθισμάτων σε κλάσεις. Όταν ο αριθμός των κλάσεων είναι σταθερός και γνωστός από πριν στο σύστημα, τότε έχουμε ένα πρόβλημα μάθησης με επίβλεψη. Σε περιπτώσεις όπου δεν είναι γνωστός ο αριθμός των κλάσεων τότε χρησιμοποιείται μάθηση χωρίς επίβλεψη.

Πρόβλεψη (Prediction)

Είναι ίσος το πιο σημαντικό αντικείμενο μάθησης. Δίνεται ένα σύνολο παλαιών δειγμάτων τα οποία συνήθως είναι ομοιόμορφα μοιρασμένα στο χρόνο και ζητείται η πρόβλεψη του δείγματος.

Έλεγχος (Control)

Ο έλεγχος αποτελεί και αυτός ένα αντικείμενο μάθησης. Στο θέμα του ελέγχου ο εγκέφαλος αποδεικνύει ότι είναι δυνατόν να χτιστεί ένα γενικευμένος ελεγκτής που πλεονεκτεί του hardware. Μπορεί να χειριστεί χιλιάδες ενεργοποιητές παράλληλα, μη γραμμικότητα και θόρυβο. Τέτοιος έλεγχος ονομάζεται και νευροέλεγχος.

Διαμόρφωση Δέσμης (Beamforming)

Στοχεύει στον εντοπισμό σήματος το οποίο βρίσκεται μέσα σε ένα υπόβαθρο προσθετικών παρεμβολών.

Σε περιβάλλοντα radar και sonar η διαμόρφωση δέσμης περιπλέκεται από δύο παράγοντες:

- Το σήμα που μας ενδιαφέρει πηγάζει από άγνωστη κατεύθυνση
- Δεν υπάρχει εκ των προτέρων στατική πληροφορία διαθέσιμη για την παρεμβολή

Για την επιτυχή αντιμετώπιση μιας τέτοιας κατάστασης θα πρέπει να καταφύγουμε στη χρήση ενός προσαρμοστικού διαμορφωτή δέσμης ο οποίος αποτελείται από μία συστοιχία κεραιών. Μια τέτοια λειτουργία προϋποθέτει τη χρήση νευρωνικού δικτύου

Επομένως για να λυθεί το πρόβλημα του προσαρμοστικού διαμορφωτή δέσμης, χρειαζόμαστε μία συστοιχία με δύο ή περισσότερους δέκτες.

3.1.8 Εκπαίδευση Νευρωνικών Δικτύων

Η εκπαίδευση των νευρωνικών δικτύων είναι ένα βασικό χαρακτηριστικό που διέπει αυτού του είδους τα συστήματα. Μέσω της εκπαίδευσης ένα νευρωνικό δίκτυο μαθαίνει από το περιβάλλον του και βελτιώνει την απόδοσή του. Αυτή η διαδικασία είναι επαναληπτική και πραγματοποιείται μέσω συνεχούς διέγερσης του νευρωνικού δικτύου από το περιβάλλον και ο τύπος της εκπαίδευσης καθορίζεται από τον ορισμό των παραμέτρων. Ένα τέτοιο σύνολο ονομάζεται αλγόριθμος μάθησης. Όπως γίνεται αντιληπτό δεν υπάρχει μόνο ένας αλγόριθμος ο οποίος να ικανοποιεί όλους τους μαθησιακούς στόχους. Οι αλγόριθμοι διαφέρουν μεταξύ τους κυρίως ως προς τον τρόπο μεταβολής του βάρους των συνάψεων. Σε γενικές γραμμές όμως η μάθηση περιλαμβάνει τα εξής:

- Το τεχνητό νευρωνικό δίκτυο διεγείρεται από το περιβάλλον
- Το τεχνητό νευρωνικό δίκτυο υφίσταται αλλαγές των παραμέτρων ως συνέπεια αυτής της διέγερσης
- Το τεχνητό νευρωνικό δίκτυο αντιδρά με ένα νέο τρόπο στο περιβάλλον λόγω των αλλαγών που έγιναν στο εσωτερικό του

Οι κατηγορίες αλγορίθμων μάθησης είναι οι παρακάτω:

Μάθηση με επίβλεψη (supervised learning)

Σε αυτούς τους είδους εκπαίδευσης κάθε διάνυσμα που εισάγεται στο δίκτυο από το περιβάλλον συνοδεύεται και από ένα διάνυσμα εξόδου, που είναι και η επιθυμητή απάντηση του δικτύου για το διάνυσμα εισόδου. Οπότε θεωρούμε ότι έχουμε ένα δάσκαλο ο οποίος γνωρίζει το περιβάλλον που αναπαρίσταται από το σύνολο των διανυσμάτων εισόδου και εξόδου. Έτσι μπορεί να δώσει στο δίκτυο την επιθυμητή απόκριση για την βέλτιστη συμπεριφορά του δικτύου. Σε κάθε επανάληψη της διαδικασίας τα βάρη ανανεώνονται μειώνοντας το σφάλμα απόκρισης του δικτύου και της επιθυμητής απόκρισης. Η εκπαίδευση μπορεί να γίνει με δύο τρόπους:

α) Ασύγχρονη εκπαίδευση κατά την οποία ο δάσκαλος σχεδιάζει την εκπαίδευση του δικτύου και μόλις επιτευχθεί η επιθυμητή απόδοση του, σταματάει την διαδικασία και το δίκτυο λειτουργεί σε αυτήν την απόκριση λόγω μνήμης.

β) Σύγχρονη εκπαίδευση η διαδικασία απόκτησης της απαιτούμενης γνώσης γίνεται εντός του συστήματος χωρίς την ύπαρξη δασκάλου. Συνεπώς σε αυτή την μέθοδο η εκπαίδευση είναι δυναμική καθώς γίνεται σε πραγματικό χρόνο.

Η ασύγχρονη μάθηση είναι ευκολότερη στην υλοποίησή της καθώς τα μοντέλα που πρέπει να κατασκευαστούν σε σχέση με την σύγχρονη μάθηση είναι πολύ πιο απλά.

Το μειονέκτημα που θα μπορούσαμε να πούμε ότι έχει αυτός ο τύπος μάθησης είναι η υποχρεωτική ύπαρξη δασκάλου.

Μάθηση χωρίς επίβλεψη (unsupervised learning)

Σε αυτού του είδους μάθησης η απόκριση του δικτύου βασίζεται στην αυτό-οργάνωση του. Αυτή η εσωτερική οργάνωση του δικτύου γίνεται έτσι ώστε σε συγκεκριμένο σύνολο εισόδων να αντιδρά ισχυρά ένας συγκεκριμένος νευρώνας.

Πιο απλά, στόχος μιας διαδικασίας εκπαίδευσης αυτής της μορφής είναι να καταφέρει το δίκτυο να εντοπίσει ομοιότητες ανάμεσα στα δείγματα που του παρέχονται, χωρίς να διαθέτει εκ των προτέρων γνώση για αυτές. Συνεπώς δεν υπάρχει κάποιος δάσκαλος ο οποίος να δίνει την επιθυμητή απόκριση και να επιβλέπει την διαδικασία.

Τα δείγματα αποτελούνται μόνο από την είσοδο και το δίκτυο προσπαθεί να τρόπο έτσι ώστε η έξοδος να έχει τα ίδια χαρακτηριστικά με την είσοδο. Άρα το δίκτυο ουσιαστικά ελέγχει τον εαυτό του και διορθώνει τα σφάλματα με έναν μηχανισμό αυτοανάδρασης. Όταν το δίκτυο σταματήσει να αλλάζει τιμές στα βάρη τότε η διαδικασία έχει ολοκληρωθεί.

Μάθηση με ενίσχυση

Σε αυτού του είδους μάθησης η έξοδος χαρακτηρίζεται ως καλή ή κακή με βάση μια αριθμητική κλίμακα από την οποία αντλούνται δεδομένα από τα βάρη τα οποία προσαρμόζονται ανάλογα με το σήμα που δέχονται κάθε φορά. Όπως και στην προηγούμενη μέθοδο τα δείγματα προέρχονται μόνο από την είσοδο μη γνωρίζοντας την επιθυμητή απόκριση του συστήματος.

Αυτού του είδους μάθησης προέρχεται από το νόμο του Thornlike ο οποίος διατυπώνεται ως εξής:

<< Εάν μια ενέργεια ενός συστήματος μάθησης ακολουθείται από μία ικανοποιητική κατάσταση ή συμπεριφορά, τότε η τάση του συστήματος αυτού να παράγει την συγκεκριμένη ενέργεια ενισχύεται. Διαφορετικά, η τάση του συστήματος να παράγει την ενέργεια αυτή αποδυναμώνεται >>.

Η ενισχυτική μάθηση διακρίνεται σε:

- Συσχετική
- Μη συσχετική


Στην πρώτη περίπτωση το περιβάλλον τροφοδοτεί εκτός από το ενισχυτικό σήμα και άλλες μορφές πληροφορίας ενώ στην δεύτερη δίνεται μόνο το ενισχυτικό σήμα.

Συγκεντρωτικά το νευρικό σύστημα αξιολογεί την έξοδο και το ενισχυτικό σήμα τροφοδοτείται στο δίκτυο. Γίνεται ανανέωση των βαρών με βάση την τιμή του ενισχυτικού σήματος αυξάνοντας τις τιμές των βαρών που είχαν καλή συμπεριφορά και αντίστοιχα μειώνοντας τις τιμές των βαρών που είχαν κακή.

3.1.9 Ο Αλγόριθμος Μάθησης του Perceptron (Αισθητήρα)

Όπως αναφέρθηκε και στα ιστορικά στοιχεία αυτό το μοντέλο πρωτοεμφανίστηκε το 1958 από τον Αμερικάνο Frank Rosenblatt και αναλύθηκε με μεγαλύτερη λεπτομέρεια το 1969 από τους Minsky και Papert.

Το μοντέλο του Perceptron είναι ένα υπολογιστικό μοντέλο καθώς εισάγει την έννοια των αριθμητικών βαρών για τις εισόδους καθώς και ένα μηχανισμό εκπαίδευσης των βαρών αυτών. Σαν είσοδο μπορούμε να εισάγουμε και διαφορετικά δεδομένα εκτός από δυαδικές τιμές πράγμα που το καθιστά ιδιαίτερα χρήσιμο και αρκετά γενικευμένο έτσι ώστε να χρησιμοποιείται σε μια πληθώρα εφαρμογών και να μην περιορίζεται σε ορισμένες λειτουργίες.



Εικόνα 14: Ο αλγόριθμος Perceptron

$$y = 1 \quad \text{if} \sum_{i=1}^n w_i * x_i - \theta \geq 0$$

$$= 0 \quad \text{if} \sum_{i=1}^n w_i * x_i - \theta < 0$$

Αυτό που γίνεται δηλαδή είναι ότι παίρνουμε άθροισμα των εισόδων και ορίζουμε μία μόνο έξοδο όταν το άθροισμα είναι περισσότερο από ένα όριο θ το οποίο το έχουμε ορίσει εμείς αυθαίρετα.

Ένα μόνο Perceptron μπορεί να χρησιμοποιηθεί για γραμμικά προβλήματα. Μπορεί να πάρει όπως είπαμε και παραπάνω τόσο πραγματικές τιμές όσο και δυαδικές. Οι τιμές αυτές συνδέονται σε ένα σύνολο βαρών και ισχύουν οι παραπάνω περιορισμοί ως προς το θ . Παρακάτω φαίνεται πως λειτουργεί η μέθοδος Perceptron σε μια συνάρτηση OR:

x_1	x_2	OR	
0	0	0	$w_0 + \sum_{i=1}^2 w_i x_i < 0$
1	0	1	$w_0 + \sum_{i=1}^2 w_i x_i \geq 0$
0	1	1	$w_0 + \sum_{i=1}^2 w_i x_i \geq 0$
1	1	1	$w_0 + \sum_{i=1}^2 w_i x_i \geq 0$

$$w_0 + w_1 \cdot 0 + w_2 \cdot 0 < 0 \implies w_0 < 0$$


$$w_0 + w_1 \cdot 0 + w_2 \cdot 1 \geq 0 \implies w_2 > -w_0$$

$$w_0 + w_1 \cdot 1 + w_2 \cdot 0 \geq 0 \implies w_1 > -w_0$$

$$w_0 + w_1 \cdot 1 + w_2 \cdot 1 \geq 0 \implies w_1 + w_2 > -w_0$$

One possible solution is

$$w_0 = -1, w_1 = 1.1, w_2 = 1.1$$



Ορίσαμε ως αρχικές συνθήκες το σταθμισμένο άθροισμα να είναι μεγαλύτερο ή ίσο με το 0 όταν ή έξοδος θα είναι 1. Η έξοδος της συνάρτησης OR μας έδωσε μια λύση που χωρίζει τέλεια τις θετικές εισροές από τις αρνητικές.

Από την γραμμική άλγεβρα γνωρίζουμε ότι ένα διάνυσμα μπορεί να οριστεί με διάφορους τρόπους. Ένας ορισμός για παράδειγμα είναι: διάνυσμα είναι οτιδήποτε είναι ορισμένο με ένα μέγεθος και μία κατεύθυνση. Ένας άλλος ορισμός είναι: διάνυσμα είναι απλώς μία δομή δεδομένων που χρησιμοποιείται για την αποθήκευση ορισμένων δεδομένων όπως ακέραιοι αριθμοί, συμβολοσειρές κλπ.

Στόχος ενός μοντέλου Perceptron είναι να βρεθεί διάνυσμα w το οποίο θα μπορεί να ταξινομήσει τέλεια τις θετικές εισόδους και τις αρνητικές εισόδους. Ένα τέτοιο παράδειγμα δίνεται στο παρακάτω σχήμα:

```

P ← inputs with label 1;
N ← inputs with label 0;
Initialize w randomly;
while !convergence do
    Pick random  $x \in P \cup N$  ;
    if  $x \in P$  and  $w \cdot x < 0$  then
        |  $w = w + x$  ;
    end
    if  $x \in N$  and  $w \cdot x \geq 0$  then
        |  $w = w - x$  ;
    end
end

```

Αφού δώσουμε στον αλγόριθμο κάποιο τυχαίο w , στην συνέχεια επαναλαμβάνουμε όλα τα παραδείγματα στα δεδομένα, τόσο τα θετικά όσο και τα αρνητικά.

```

while !convergence do
    Pick random  $x \in P \cup N$  ;
    if  $x \in P$  and  $w \cdot x < 0$  then
        |  $w = w + x$  ;
    end
    if  $x \in N$  and  $w \cdot x \geq 0$  then
        |  $w = w - x$  ;
    end
end

```

Από τα παραπάνω προκύπτουν δύο περιπτώσεις:

- 1) Όταν το x ανήκει στο P τότε τα $w \cdot x < 0$
- 2) Όταν το x ανήκει στο N τότε τα $w \cdot x > 0$

Συνεπώς όταν ισχύουν αυτές οι δύο περιπτώσεις ενημερώνουμε το αυθαίρετο τυχαίο x που επιλέξαμε αρχικά. Εάν δεν ισχύει καμία από τις δύο παραπάνω περιπτώσεις δεν αγγίζουμε το w .

Η υπόθεση αυτή στηρίζεται στο γεγονός ότι η γωνία μεταξύ w και x θα πρέπει να είναι μικρότερη των 90 μοιρών.

$$\cos \alpha = \frac{\mathbf{w}^T \mathbf{x}}{\|\mathbf{w}\| \|\mathbf{x}\|}$$

$$\cos \alpha \propto \mathbf{w}^T \mathbf{x}$$


Δηλαδή αν:

$$\mathbf{w}^T \mathbf{x} > 0 \Rightarrow \cos \alpha > 0 \Rightarrow \alpha < 90$$

και αντίστοιχα αν:

$$\mathbf{w}^T \mathbf{x} < 0 \Rightarrow \cos \alpha < 0 \Rightarrow \alpha > 90$$

Από τα παραπάνω βγαίνει το συμπέρασμα ότι δεν μας ενδιαφέρει η αρχική ποσότητα γι αυτό και ορίζεται τυχαία αρκεί να δημιουργείται γωνία μικρότερη των 90 μοιρών με τα θετικά διανύσματα και γωνία μεγαλύτερη των 90 μοιρών με τα αρνητικά διανύσματα. Ένα χαρακτηριστικό παράδειγμα δίνεται στο παρακάτω σχήμα:



Εικόνα 15: Αναπαράσταση διανυσμάτων σε μοντέλο Perceptron

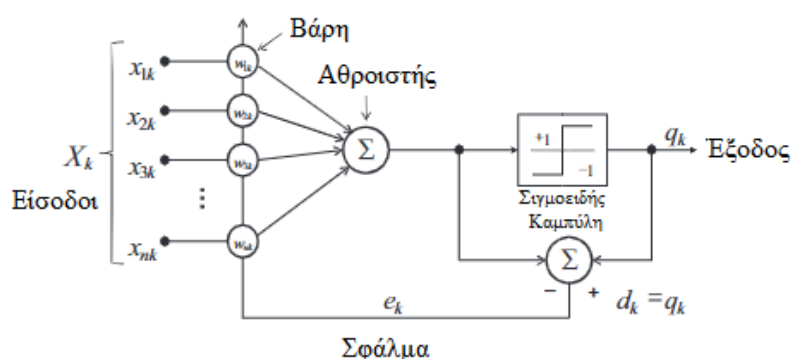
3.1.10 Ο Αλγόριθμος Ελαχίστου Μέσου Τετραγωνικού (EMT) Σφάλματος

Ο συγκεκριμένος τύπος αλγορίθμου εφευρέθηκε το 1959 από τους Widrow και Hoff ως επέκταση του παρθενικού βιβλίου του Hebb. Μέχρι και σήμερα είναι από τους πιο διαδεδομένους μαθησιακούς αλγορίθμους. Βρίσκει εφαρμογή σε τεχνολογίες του διαδικτύου, στην ασύρματη επικοινωνία και στα ψηφιακά σήματα.

Τα πρώτα πειράματα μάθησης έγιναν με το μοντέλο Adaline εκπαιδεύοντας για κατάταξη μοτίβων. Για να μπορεί να γίνει εκπαίδευση σε ένα μοντέλο Adaline θα πρέπει να είναι γνωστή ή επιθυμητή τιμή απόκρισης για κάθε είσοδο. Στα πρώτα πειράματα που έγιναν ορίστηκαν τυχαία βάρη για αρχικές συνθήκες. Εάν η απόκριση σε ένα δεδομένο πρότυπο εισόδου ήταν θετική, η επιθυμητή απόκριση θα ήταν +1. Αντίστοιχα αν η απόκριση ήταν < 1 τότε πραγματοποιούνταν προσαρμογή από το μοντέλο για να ανέβει η τιμή στο +1. Τέλος αν η απόκριση ήταν > 1 τότε πραγματοποιούνταν και πάλι διόρθωση από το μοντέλο αυτή τη φορά όμως ανάποδα, δηλαδή μείωνε την τιμή για να φτάσει στο +1.

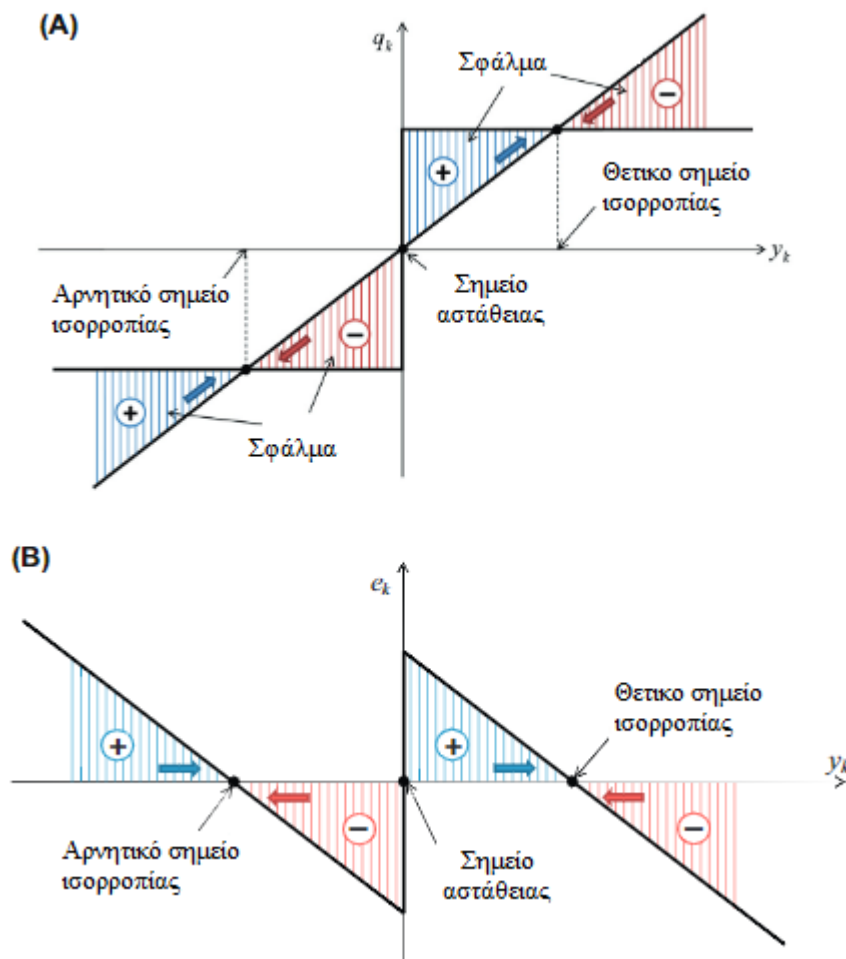
Σε ένα διαφορετικό μοντέλο όπου η απόκριση ήταν αρνητική, η επιθυμητή τιμή θεωρούνταν ακριβώς 1. Εάν η απόκριση ήταν > 1 τότε πραγματοποιούνταν προσαρμογή από το μοντέλο για να μειωθεί η απόκριση στο 1. Αντίστοιχα αν η απόκριση ήταν < 1 τότε πραγματοποιούνταν προσαρμογή ώστε να διορθωθεί η τιμή στο 1.

Συνεπώς σε μοντέλα που είχαν αρχικοποιηθεί θετικά, θα μπορούσαν τελικά να δώσουν αρνητικές απαντήσεις και το αντίστροφο δηλαδή αρνητικές αρχικές αποκρίσεις να δώσουν θετικές απαντήσεις. Τα παραπάνω είναι εφικτά όμως στις περισσότερες περιπτώσεις τα πρότυπα που ανταποκρίνονται ως θετικά είναι πιθανότερο να παραμείνουν θετικά και το αντίστροφο. Τέλος όταν η διαδικασία σταθεροποιηθεί και οι τιμές αρχίζουν να συγκλίνουν, μερικές τιμές κυμαίνονται στο +1 και οι υπόλοιπες στο 1. Παρακάτω δίνεται ένα παράδειγμα από το μοντέλο Adaline.



Εικόνα 16: Μοντέλο Adaline

Οι πολικότητες ενός τέτοιου συστήματος φαίνονται στο σχήμα 17. Όταν το σφάλμα είναι 0 δεν πραγματοποιείται προσαρμογή. Εκεί που πραγματοποιείται προσαρμογή είναι στα σημεία ισορροπίας. Μερικά από τα μοτίβα εισόδου θα δώσουν αθροίσματα που έλκονται προς το σημείο θετικής ισορροπίας ενώ άλλα θα δώσουν αθροίσματα που θα έλκονται από το σημείο αρνητικής ισορροπίας. Τα βέλη δείχνουν προς πια κατεύθυνση θα είχε η αλλαγή στο άθροισμα που ως αποτέλεσμα της προσαρμογής.



Εικόνα 17: Αποτελέσματα ενός μοντέλου Adaline

3.1.11 Ο Αλγόριθμος Πίσω Διάδοσης (Π.Δ) του λάθους

Ένας τέτοιος αλγόριθμος αποτελείται από ένα σύνολο αισθητήρων, ένα ή περισσότερα κρυφά επίπεδα και ένα επίπεδο νευρώνων εξόδου και το σήμα μεταφέρεται από επίπεδο σε επίπεδο. Οι αλγόριθμοι πίσω διάδοσης έχουν εφαρμοστεί για επίλυση δύσκολων προβλημάτων εκπαιδεύοντας το δίκτυο με επιβλεπόμενο τρόπο.

Η διαδικασία που ακολουθείται είναι το πέρασμα μέσα από τα διάφορα επίπεδα του δικτύου, τη μία φορά προς τα εμπρός ενώ την άλλη προς τα πίσω. Κατά το εμπρόσθιο πέρασμα ένα διάνυσμα εισόδου εφαρμόζεται στους νευρώνες εισόδου και το σήμα μεταφέρεται σε όλο το δίκτυο από επίπεδο σε επίπεδο. Οπότε ένα σύνολο από εξόδους παράγει την πραγματική απόκριση του δικτύου. Να αναφερθεί ότι τα βάρη του δικτύου είναι σταθερά. Κατά την αντίθετη κατεύθυνση δηλαδή στο οπίσθιο πέρασμα τα βάρη δεν είναι σταθερά και προσαρμόζονται με βάση τον κανόνα διόρθωσης λάθους. Πιο συγκεκριμένα αφαιρείται η πραγματική απόκριση του δικτύου από την επιθυμητή και παράγεται ένα σήμα σφάλματος το οποίο μεταφέρεται προς το πίσω σε όλο το δίκτυο από επίπεδο σε επίπεδο.

Η κατασκευή ενός τέτοιου αλγορίθμου πίσω διάδοσης δεν είναι εύκολη υπόθεση. Οι συνήθεις συμβολισμοί που χρησιμοποιούνται είναι:

- i, j, k : είναι ο συμβολισμός των διαφορετικών νευρώνων και τα σήματα διαδίδονται από αριστερά προς τα δεξιά στο δίκτυο.
- Η επανάληψη n αντιστοιχεί στο n – οστό διάνυσμα εκπαίδευσης που δόθηκε σαν είσοδος δικτύου.
- $E(n)$ είναι το στιγμιαίο άθροισμα των τετραγωνικών λαθών στην επανάληψη n και ο μέσος όρος του $E(n)$ είναι το μέσο τετραγωνικό λάθος E_{av} .
- $e_j(n)$ είναι το σήμα λάθους στην έξοδο του νευρώνα j για την επανάληψη n .
- $d_j(n)$ είναι η επιθυμητή τιμή της απόκρισης για τον νευρώνα j
- $y_j(n)$ είναι το σήμα εξόδου του νευρώνα j για την επανάληψη n .
- $w_{ij}(n)$ είναι το συναπτικό βάρος που συνδέει τον νευρώνα i , με τον νευρώνα j κατά την επανάληψη n . Η ποσότητα διόρθωσης στη επανάληψη n συμβολίζεται με $\Delta w_{ij}(n)$.
- v_j είναι η τιμή ενεργοποίησης του νευρώνα j στην n επανάληψη.
- $\phi_j(\cdot)$ είναι η συνάρτηση ενεργοποίησης του νευρώνα j
- $x_i(n)$ είναι το i -οστο στοιχείο του διανύσματος εισόδου
- $o_k(n)$ είναι το k -οστο στοιχείο του συνολικού διανύσματος εξόδου
- η είναι η παράμετρος μάθησης.

Τα βάρη ιδανικά ενημερώνονται και προσαρμόζονται με βάση τα αντίστοιχα σφάλματα που υπολογίζονται για κάθε πρότυπο που παρουσιάζεται στην είσοδο. Ο μέσος όρος αυτών των αλλαγών στα ατομικά βάρη είναι μια εκτίμηση της πραγματικής αλλαγής στα βάρη που θα συνέβαινε από την μεταβολή των βαρών για την ελαχιστοποίηση της συνάρτησης κόστους. Με παρόμοιο τρόπο με αυτόν του Αλγόριθμου Ελαχίστου Μέσου Τετραγωνικού, ο αλγόριθμος πίσω διάδοσης εφαρμόζει μια διόρθωση στο συναπτικό βάρος η οποία είναι ανάλογη της στιγμιαίας κλίσης του βάρους. Η κλίση μπορούμε να πούμε ότι αντιπροσωπεύει ένα παράγοντα ευαισθησίας και καθορίζει την κατεύθυνση των βαρών.

3.2 Ασαφής Λογική (Fuzzy Logic)

Τα ασαφή σύνολα πρωτοεμφανίστηκαν το 1965 από τον Ρώσο καθηγητή πανεπιστημίου τον Lotfi Zadeh. Η θεωρία του πυροδότησε την είσοδο μιας εναλλακτικής λογικής η οποία δε θα έμενε μόνο σε θεωρητικό επίπεδο αλλά θα εφαρμοζόταν και σε πραγματικές βιομηχανίες και θα συνείσφεραν στην γενική εξέλιξη και πρόοδο. Τα ασαφή σύνολα εκφράζουν μια διαφορετική αντίληψη του ψέματος και της αλήθειας. Αυτό έγινε αντικαθιστώντας την έννοια της υπαγωγής ενός στοιχείου σε ένα σύνολο με την έννοια της συμμετοχής του στοιχείου στο σύνολο.

Η πρώτη προσέγγιση από την επιστημονική κοινότητα ήταν αρνητική καθώς ο όρος ασάφεια δε συνάδει με τις επιστημονικές αρχές και ήδη υπήρχε ο κλάδος των πιθανοτήτων ο οποίος μπορούσε να επιλύσει με εξίσου επάρκεια τα όποια προβλήματα εμφανίζονταν.

Παρόλα αυτά προσπάθειες συνεχίζονταν να γίνονται όπως η εμφάνιση της έννοιας του ασαφούς αλγορίθμου (fuzzy algorithm) το 1968, η έννοια της ασαφούς λήψης αποφάσεων (fuzzy decision making) το 1970, της ασαφής διάταξης (fuzzy ordering) το 1971, τη λεκτική μεταβλητή (linguistic variable) το 1973 καθώς και τους ασαφείς κανόνες (fuzzy if – then rules) το 1975.

Η σταδιακή αποδοχή της θεωρίας της ασαφούς λογικής από την επιστημονική κοινότητα ξεκίνησε το 1975 όπου οι Άγγλοι Mamdani και Assilian παρουσίασαν έναν ασαφή ελεγκτή για τον έλεγχο μιας ατμομηχανής. Ακολούθησαν και άλλοι όπως ο Tong ο οποίος πρότεινε έναν ασαφή ελεγκτή για την διαδικασία παραγωγής χάλυβα το 1976 και οι Δανοί Holmblad και Ostergaard που δημιούργησαν έναν ασαφή ελεγκτή για καμίνι τσιμέντου το 1978. Στην συνέχεια άρχισαν να βρίσκουν εφαρμογή σε

διάφορους κλάδους όπως είναι η ρομποτική, η βιομηχανία οχημάτων, τα καταναλωτικά αγαθά, το διαδίκτυο κ.α. Τα μοντέλα σήμερα σαφώς είναι πιο ανεπτυγμένα από τα αρχικά όμως ορισμένες λειτουργίες εξακολουθούν να είναι ίδιες.

Τα συμβατικά σύνολα αποτελούν συλλογές στοιχείων (x) τα οποία ορίζονται σε ένα πεδίο ορισμού U και έχουν όλα την ίδια ιδιότητα. Κατά συνέπεια ένα στοιχείο είτε θα ανήκει είτε δε θα ανήκει στο σύνολο δηλαδή ή θα ανήκει 100% ή δεν θα ανήκει καθόλου άρα 0%. Αυτό μπορεί να εκφραστεί από την χαρακτηριστική συνάρτηση ως:

$$\chi_A(x) = \begin{cases} 1, & \text{iff } x \in A \\ 0, & \text{iff } x \notin A \end{cases}$$


όπου iff σημαίνει if and only if

Από τα παραπάνω μπορούμε να πούμε ότι στα συμβατικά σύνολα οι ομάδες που ανήκουν και δεν ανήκουν στο σύνολο A είναι αμοιβαία αποκλειόμενες. Για το λόγο αυτό τα συμβατικά σύνολα ονομάζονται και σαφή ή προσδιορισμένα σύνολα. Άρα η χρήση των κλασσικών συνόλων είναι ενδεδειγμένη εφόσον υπάρχει λύση που δεν μπορεί να αμφισβητηθεί. Υπάρχουν όμως περιπτώσεις στις οποίες μια ιδιότητα δεν ερμηνεύεται ξεκάθαρα και παρουσιάζεται κάποια μορφή ασάφειας ή απροσδιοριστίας. Σε μια τέτοια περίπτωση ασάφειας θα πρέπει να θέσουμε ένα σύνολο ώστε να μπορούμε να εξάγουμε συμπεράσματα για μια συγκεκριμένη ιδιότητα ενός συνόλου. Εδώ ξεκινάμε και τα προβλήματα διότι ο προσδιορισμός του συνόρου πολλές φορές δεν είναι απόλυτος. Παράδειγμα εάν σε ένα σύνολο ανθρώπων θέλουμε να εξάγουμε συμπεράσματα ως προς το ποσοστό των νέων ανθρώπων, η έννοια του συνόρου είναι κάτι το οποίο δεν είναι απόλυτο και εξαρτάται από το πως θεωρεί ο καθένας κάποιον άνθρωπο ως νέο.


Σε αυτό το πρόβλημα έρχεται να δώσει λύση η έννοια της σταδιακής ή βαθμιαίας μετάβασης. Δηλαδή κάθε στοιχείο έχει διαφορετική συμμετοχή στην τελική κατάσταση του συνόλου. Αυτό δίνει καλύτερη ευελιξία στο σύστημα και καλύτερα αποτελέσματα.

Από τα παραπάνω μπορούμε να πούμε ότι το ασαφές σύνολο είναι ουσιαστικά μια γενίκευση του συμβατικού συνόλου εφόσον μεταβαίνει από την δυαδική λογική στην πλειοτική λογική το οποίο αποφέρει καλύτερα αποτελέσματα στα προβλήματα του πραγματικού κόσμου. Ο αρχικός όρος γενίκευση στηρίζεται στο γεγονός ότι αν η συνάρτηση που περιγράφει την συμμετοχή στο σύστημα περιοριστεί στις τιμές 0 και 1 τότε τα αποτελέσματα που θα πάρουμε από το συμβατικό και το ασαφές σύνολο θα συμπίπτουν.

Τα ασαφή σύνολα διακρίνονται σε δύο κατηγορίες, τα διακριτά τα οποία αναπτύσσονται σε διακριτό πεδίο ορισμού και τα συνεχή ασαφή τα οποία έχουν συνεχές πεδίο ορισμού.



Εικόνα 18: Διακριτό ασαφές σύνολο



Εικόνα 19: Συνεχή ασαφές σύνολο

3.2.1 Συναρτήσεις Συμμετοχής

Οι συναρτήσεις συμμετοχής είναι αυτές που δίνουν το βαθμό συμμετοχής των στοιχείων στο σύνολο. Έστω διακριτό σύνολο αναφοράς X με στοιχεία x_i . Αν το A ανήκει στο X τότε αυτό μπορεί να αναπαρασταθεί με ζευγάρια των στοιχείων και του αντίστοιχου βαθμού συμμετοχής, δηλαδή:

$$A = \left\{ \frac{\mu_A(x_1)}{x_1} + \frac{\mu_A(x_2)}{x_2} + \dots \right\}$$

Το σύμβολο '+' στην παραπάνω εξίσωση, αναπαριστά την ένωση και όχι την μαθηματική πρόσθεση και αντίστοιχα το κλάσμα, δε σημαίνει διαίρεση, αλλά είναι ο προσδιορισμός ποιου στοιχείου του X , αντιστοιχεί ο κάθε βαθμός συμμετοχής.


Οι λειτουργίες μελών (MF) είναι ζωτικής σημασίας για την συνολική απόδοση και αναπαράσταση ενός ασαφούς συστήματος. Αυτό γίνεται καλύτερα κατανοητό αν αναλογιστούμε ότι τα MF είναι τα δομικά στοιχεία της ασαφούς θεωρίας οπότε

ουσιαστικά καθορίζεται σε μεγάλο βαθμό από αυτά. Τα MF μπορούν να πάρουν διαφορετικές μορφές ή σχήματα με την μόνη προϋπόθεση να κυμαίνεται μεταξύ 0 και 1. Η επιλογή των MF γίνεται με γνώμονα τη σωστή ανάγνωση του βαθμού συμμετοχής κάθε στοιχείου στο σύνολο. Η ίδια η συνάρτηση θα μπορεί να είναι ακόμα και μια αυθαίρετη καμπύλη της οποίας το σχήμα της θα είναι τέτοιο ώστε να μας εξυπηρετεί από άποψη απλότητας, ευκολίας, ταχύτητας και αποδοτικότητας.

Όπως αναφέρθηκε παραπάνω το σχήμα που θα έχουν τα MF μπορεί να ποικίλλει και δεν υπάρχει κάποια άμεση συσχέτιση με την απόδοση καθώς κάθε σύνολο και ιδιότητα που θέλουμε να εξετάσουμε είναι διαφορετική. Αυτό που έχει μεγαλύτερη σημασία είναι ο αριθμός των MF καθώς επηρεάζει τον υπολογιστικό χρόνο. Συνεπώς για την εξαγωγή ενός βέλτιστου μοντέλου θα πρέπει να μεταβληθεί ο αριθμός με τον τύπο των MF για την επίτευξη καλύτερης απόδοσης. Σε γενικές γραμμές υπάρχουν ορισμένα σχήματα συναρτήσεων τα οποία έχουν μελετηθεί εκτενέστερα και παρουσιάζονται τα χαρακτηριστικά τους.


Τριγωνική MF

Ορίζονται πλήρως από μία τριάδα παραμέτρων $\{a, b, c\}$. και η γραφική παράσταση της συνάρτησης είναι της μορφής:



Τραπεζοειδείς MF

Για τον ορισμό της χρειάζονται τεσσάρων ειδών παράμετροι $\{a, b, c, d\}$ και η γραφική της παράσταση αποτυπώνεται στο παρακάτω σχήμα:



Gaussian MF

Ορίζεται μέσω του τύπου:


$$\mu(x) = e^{-\frac{(x-c)^2}{2\sigma^2}}$$

Όπου

c είναι η μέση τιμή

Σ είναι το εύρος

Η γραφική της παράσταση είναι της μορφής:




Καμπανοειδές MF

Η καμπανοειδής συνάρτηση συμμετοχής χαρακτηρίζεται από τις τρεις παραμέτρους {a, b, c}, ως εξής:

$$\frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}}$$

Η γραφική της μορφή είναι η εξής:




Σιγμοειδής MF

Η σιγμοειδή συνάρτηση συμμετοχής χαρακτηρίζεται από τις δύο παραμέτρους $\{a, c\}$, ως εξής:

$$\frac{1}{1 + e^{-a(x-c)}}$$

Η γραφική της παράσταση είναι η παρακάτω:



3.2.2 Ιδιότητες των Ασαφών Συνόλων

Τα ασαφή σύνολα ακολουθούν παρόμοιες ιδιότητες με αυτές των κλασσικών συνόλων. Αυτό στηρίζεται στο γεγονός ότι οι τιμές μέλους των κλασσικών συνόλων βρίσκονται στο διάστημα $[0,1]$ οπότε μπορούν να θεωρηθούν μια υποπερίπτωση των ασαφών συνόλων. Τα ασαφή σύνολα εκτός από τις αναλυτικές συναρτήσεις συμμετοχής $\mu_A(x)$ μπορούν να αναλυθούν και να περιγραφούν με βάση τα σύνολα της διατομής a .

Η ανάλυση των ασαφών συνόλων ονομάζεται αρχή της ανάλυσης ενώ η σύνθεση και η περιγραφή ονομάζεται αρχή της αναπαράστασης.


Θεωρούμε ένα πεδίο ορισμού U με ορισμένο ασαφές σύνολο A . Η συνάρτηση συμμετοχής του A με βάση τα συναρτήσεις των συνόλων διατομής είναι:

$$\mu_A(x) = \bigvee_{0 \leq a \leq 1} (a \wedge \mu_{A_a}(x)) \quad \forall x \in U$$

όπου A_a και μ_{A_a} είναι το σύνολο διατομής a και η χαρακτηριστική συνάρτησή του είναι:

$$\mu_{A_a}(x) = \begin{cases} 1, & \text{iff } x \in A_a \\ 0, & \text{iff } x \notin A_a \end{cases}$$

όπου το \wedge είναι ο τελεστής \min και το \vee ο τελεστής \max .



Εικόνα 20: Συνάρτηση συμμετοχής και σύνολο διατομής α

Το κλασσικό σύνολο ${}_aA$ ορίζεται ως η χαρακτηριστική συνάρτηση και συμβολίζεται με $\mu_{{}_aA}(x)$ η οποία ταυτίζεται με την χαρακτηριστική συνάρτηση του συνόλου διατομής α με την μόνη διαφορά ότι βρίσκεται σε ύψος α .

$$\mu_{{}_aA}(x) = \mu_{A_\alpha}(x) = \begin{cases} \alpha, & \text{iff } x \in A_\alpha \\ 0, & \text{iff } x \notin A_\alpha \end{cases}$$

Επομένως από τον ορισμό του ${}_aA$, ένα ασαφές σύνολο A θα ικανοποιείται από την εξής σχέση:

$$A = \bigcup_{0 \leq \alpha \leq 1} {}_aA$$

και η συνάρτηση συμμετοχής του θα είναι:

$$\mu_A(x) = \bigcup_{0 \leq \alpha \leq 1} (\mu_{{}_aA}(x))$$

Πυρήνας ασαφούς συνόλου

Πυρήνας ενός ασαφούς συνόλου ονομάζεται το σύνολο όλων των στοιχείων x στο \aleph για τα οποία έχουμε $\mu_A(x) = 1$

$$Core(A) = \{x \in \aleph \mid \mu_A(x) = 1\}$$

Ύψος ασαφούς συνόλου

Ύψος ενός ασαφούς συνόλου A είναι η μέγιστη τιμή που μπορεί να πάρει το $\mu_A(x)$ που συμβαίνει πάνω σε όλο το \aleph

$$Height(A) = \sup_x \mu_A(x) = \max_x \mu_A(x)$$

Κανονικότητα ασαφούς συνόλου

Κανονικό ασαφές σύνολο έχουμε όταν το ύψος ισούται με 1 και ο πυρήνας είναι μη κενά σύνολα.

Υποσύνολο ασαφούς συνόλου

Ένα ασαφές σύνολο A μπορούμε να πούμε ότι είναι υποσύνολο ενός ασαφούς συνόλου B , ή το A περιέχεται στο B αν:

$$\mu_A(x) \leq \mu_B(x) \text{ για όλα τα } x \in \mathfrak{X}$$

3.2.3 Λογικές Πράξεις στα Ασαφή Σύνολα

Ένωση ασαφών συνόλων

Η ένωση δύο ασαφών συνόλων A και B αποτελεί το άθροισμα ενός ασαφούς συνόλου C , δηλαδή:


$$C = A \cup B$$

Η συνάρτηση συμμετοχής του C προκύπτει από τις συναρτήσεις συμμετοχής των A και B και είναι:

$$\mu_C(x) = \max[\mu_A(x), \mu_B(x)] = \mu_A(x) \vee \mu_B(x), \forall x \in \mathfrak{X}$$

Στη γλώσσα των ασαφών συνόλων το παραπάνω περιγράφεται με την λογική πράξη OR, δηλαδή:

$$C = A \cup B = A \text{ OR } B$$



Εικόνα 21: Ένωση ασαφών συνόλων

Τομή ασαφών συνόλων


Η τομή δύο ασαφών συνόλων A και B περιγράφονται από ένα ασαφές σύνολο C της μορφής: $C = A \cap B$

Η συνάρτηση συμμετοχής του C προκύπτει από τις συναρτήσεις συμμετοχής των A και B και είναι:

$$\mu_C(x) = \min[\mu_A(x), \mu_B(x)] = \mu_A(x) \wedge \mu_B(x), \forall x \in \mathfrak{X}$$

Στη γλώσσα των ασαφών συνόλων η τομή γίνεται με την λογική πράξη AND, δηλαδή:

$$C = A \cap B = A \text{ AND } B$$



Εικόνα 22: Τομή ασαφών συνόλων

Συμπλήρωμα ενός ασαφούς συνόλου


Το συμπληρωματικό ενός ασαφούς συνόλου A είναι ουσιαστικά άλλο ένα ασαφές σύνολο και συμβολίζεται με \bar{A}

Η συνάρτηση συμμετοχής του προκύπτει:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x), \forall x \in \mathfrak{X}$$

Στη γλώσσα των ασαφών συνόλων το συμπληρωματικό ενός ασαφούς συνόλου περιγράφεται με την εντολή NOT, δηλαδή:

$$\bar{A} = \text{NOT } A$$




Εικόνα 23: Συμπλήρωμα ασαφών συνόλων

3.2.4 Ασαφείς Σχέσεις

Στις κλασσικές σχέσεις έχουμε την αναπαράσταση μιας σύνδεσης στοιχείων δύο ή περισσότερων συνόλων. Τα στοιχεία είναι διατεταγμένα με τέτοιο τρόπο ώστε το πρώτο στοιχείο ανήκει στο πρώτο σύνολο και το δεύτερο στοιχείο ανήκει στο δεύτερο σύνολο.

Τα κλασσικά σύνολα ορίζονται πάνω σε ένα καρτεσιανό σύστημα. Αν έχουμε γινόμενο δύο συνόλων A και B τότε το σύνολο των στοιχείων (x,y) με το $x \in A$ και το $y \in B$ έχουμε: $A \times B = (x, y)$.



Εικόνα 24: Καρτεσιανό γινόμενο κλασσικών συνόλων


Όπου R είναι μία κλασσική σχέση και εκφράζει την ιδιότητα ότι η μεταβλητή x ισούται με το y .

Στα ασαφή σύνολα καρτεσιανών γινομένων το c είναι ένα θετικός πραγματικός αριθμός ο οποίος επιλέγεται έτσι ώστε να ικανοποιεί κατά το δυνατόν την ασαφή σχέση R .

Η σχέση R μεταξύ δύο υπερσυνόλων U και V μπορεί να οριστεί ως:

$$R = \{(x, y), \mu_R(x, y), (x, y) \in U \times V\}$$

$$\mu_R(x, y) = \mu_{A \times B}(x, y) = \min(\mu_A(x), \mu_B(y))$$



Εικόνα 25: Σχηματική απεικόνιση ασαφούς σχέσης R

3.2.5 Ασαφής Συλλογιστική

Με τον όρο ασαφής συλλογιστική εννοούμε την εξαγωγή συμπερασμάτων από κάποια ή κάποιες μεταβλητές εξόδου με βάση κάποια ή κάποιες μεταβλητές εισόδου. Η διαδικασία που ακολουθείτε είναι η εξής:

- 1) Μετατρέπονται οι είσοδοι σε ασαφή σύνολα
- 2) Γίνεται ανάπτυξη βάσης κανόνων ασαφούς συλλογιστικής
- 3) Γίνεται σύνθεση εισόδων σε κάθε κανόνα
- 4) Πραγματοποιείται συνδυασμός συμπερασμάτων σε κάθε κανόνα
- 5) Πραγματοποιείται αποσαφήνιση

Για να γίνουν πιο κατανοητά ας δώσουμε ένα παράδειγμα. Έστω έχουμε έναν γερανό κοντέινερ σε ένα λιμάνι.

Μεταβλητές εισόδου: απόσταση από την τελική θέση και γωνία απόκλισης από την κατακόρυφο

Μεταβλητές εξόδου: Ισχύς στο μοτέρ κίνησης

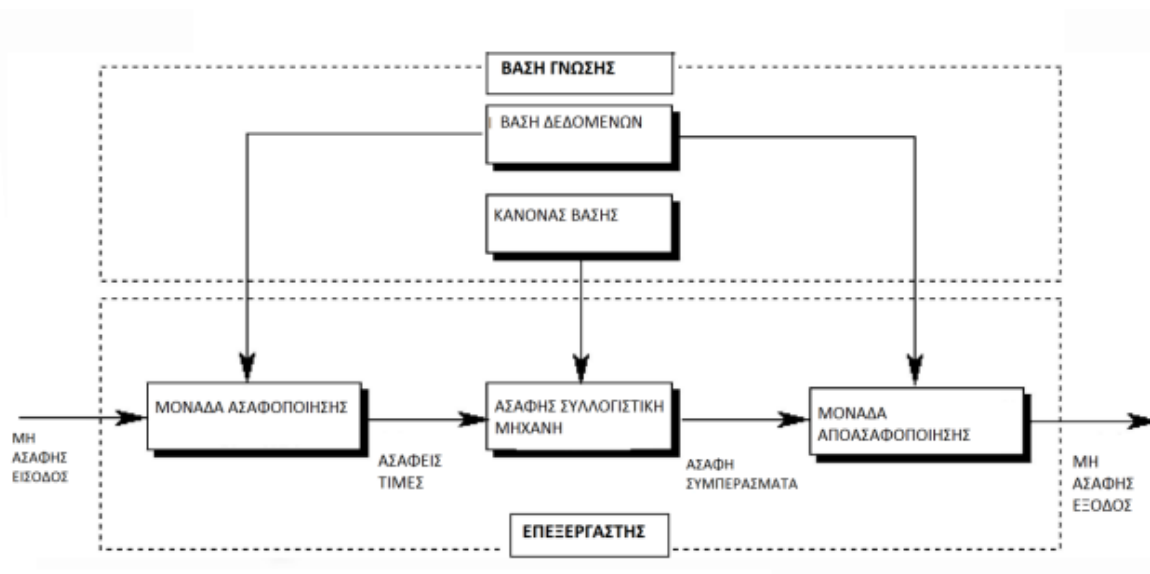
Ζητούμενο: Η γρήγορη εκφόρτωση

3.3 Συστήματα Ασαφούς Συλλογιστικής – Νευροασαφή Συστήματα

Τα συστήματα ασαφούς συλλογιστικής είναι διαδικασία από την οποία μπορούμε να εξάγουμε ασαφή συμπεράσματα. Λειτουργεί με κανόνες if και then με τους οποίους κάνει διάφορους υπολογισμούς.

Το πιο διαδεδομένο σύστημα ασαφούς λογικής είναι το σύστημα ασαφούς συμπερασματολογίας. Ένα τέτοιο σύστημα αποτελείται από την βάση γνώσης και το στάδιο της επεξεργασίας.

Η βάση γνώσης περιλαμβάνει τις συναρτήσεις συμμετοχής και τους ασαφείς κανόνες ενώ στο στάδιο επεξεργασίας εισάγονται στο σύστημα μεταβλητές οι οποίες αποτελούνται από αριθμούς. Αυτές οι μεταβλητές μέσω ενός ασαφοποιητή μετατρέπονται σε ασαφείς ποσότητες. Δηλαδή από κλασσικοί αριθμοί παίρνουν την μορφή γλωσσικών μεταβλητών οι οποίοι αναπαρίστανται από την χρήση ασαφών συνόλων γι αυτό και ονομάζονται ασαφείς μεταβλητές. Στην συνέχεια αυτές οι ασαφείς μεταβλητές στο σύστημα συμπερασματολογίας όπου με βάση τους ασαφείς λογικούς κανόνες παράγονται τα ασαφή συμπεράσματα. Κατά το τελευταίο στάδιο τα ασαφή συμπεράσματα περνάμε από μια διαδικασία αποασαφοποίησης έτσι ώστε να μετατραπούν και πάλι από γλωσσικές μεταβλητές σε αριθμητικές μεταβλητές.



Εικόνα 26: λειτουργία ασαφούς συμπερασματολογίας

Η είσοδος του συστήματος είναι το ασαφές σύνολο ενώ η έξοδος είναι ένας αριθμός. Η διαδικασία της αποσαφήνισης είναι απαραίτητη διότι το αποτέλεσμα που θα λάβουμε θα πρέπει να είναι αριθμός έτσι ώστε να μας επιτρέψει να πάρουμε σωστές και συγκεκριμένες αποφάσεις. Γενικά υπάρχουν πολλοί και διάφοροι τρόποι για την διαδικασία της αποσαφήνισης, παρακάτω παρουσιάζονται οι πιο δημοφιλείς.

Αποασαφοποίηση μεγίστου

Κατά την διαδικασία αυτής της τεχνικής ο ελεγκτής ασαφούς λογικής υπολογίζει αρχικά την τυπική αριθμητική τιμή κάθε συνάρτησης συμμετοχής. Αυτή η τιμή αποτελεί και τον μέσο όρο αριθμητικών τιμών που αντιστοιχούν στο βαθμό συμμετοχής που η κάθε συνάρτηση έχει τοποθετηθεί. Περιγράφεται από την παρακάτω εξίσωση:

$$y_{max} = \max \mu(y)$$

Όπου y είναι η τιμή στην οποία η συνάρτηση $\mu(y)$ γίνεται μέγιστη. Η μέθοδος αυτή δεν δίνει πολύ ικανοποιητικά αποτελέσματα και ειδικά σε περιπτώσεις όπου υπάρχουν παραπάνω από ένα μέγιστα.

Αποασαφοποίηση μέσου όρου μεγίστου

Σε αυτού του είδους αποασαφοποίησης ο ελεγκτής ασαφούς λογικής αναγνωρίζει την συνάρτηση συμμετοχής με τον μεγαλύτερο βαθμό συσχέτισης. Στην συνέχεια αφού καθορίσει την τυπική τιμή της συνάρτησης συμμετοχής, αυτή αποτελεί το μέσο όρο

των τυπικών τιμών κάθε συνάρτησης συμμετοχής στο βαθμό συμμετοχής. Περιγράφεται από την παρακάτω εξίσωση:

$$y_{MOM} = \frac{1}{m} \sum_{j=1}^m \max \mu(y_i)$$

Αυτή η μέθοδος δίνει την ίδια προσέγγιση με την παραπάνω μέθοδο σε προβλήματα όπου υπάρχει μόνο ένα μέγιστο, όμως σε περιπτώσεις όπου υπάρχουν πάνω από ένα μέγιστα τότε σε αντίθεση με την προηγούμενη δίνει έγκυρα αποτελέσματα.

Σε περίπτωση που υπάρχει μόνο ένα μέγιστο, τότε η τεχνική αυτή είναι ίδια με την προηγούμενη. Σε περίπτωση που υπάρχει πλήθος τιμών με μέγιστη τιμή, τότε υπολογίζεται το πλήθος κανονικά.

Αποασαφοποίηση κεντρώου

Κατά την διαδικασία της τεχνικής αυτής ο ελεγκτής ασαφούς λογικής υπολογίζει το κέντρο του εμβαδού της σύνθετης συνάρτησης συμμετοχής της εξόδου $\mu(y)$, η οποία θεωρείται ότι είναι και η τελική αριθμητική τιμή της εξόδου. Μαθηματικά αυτό εκφράζεται ως εξής:

$$y_{COA} = \frac{\int_S y_i \cdot \mu(y_i)}{\int_S \mu(y_i)}$$

Όπου S είναι το σύνολο στήριξης της συνάρτησης $\mu(y)$.

Η εγκυρότητα των αποτελεσμάτων σε αυτή τη μέθοδο εξαρτάται σε μεγάλο βαθμό από τα σχήματα συναρτήσεων συμμετοχής.

Αποασαφοποίηση κέντρου βάρους

Στην τεχνική αυτή αρχικά υπολογίζεται το κέντρο βάρους όλων των συναρτήσεων συμμετοχής των I κανόνων που έχουν ενεργοποιηθεί και είναι σταθμισμένοι με το βαθμό εκπλήρωσης σί κάθε κανόνα. Η εξίσωση που χαρακτηρίζει αυτής της μορφής τη μέθοδο, στην περίπτωση όπου οι συναρτήσεις είναι συμμετρικές, είναι:

$$y_{COG} = \frac{\sum_{i=1}^I \sigma_i \cdot \mu^i(y_i)}{\sum_{i=1}^I \mu^i(y_i)}$$

3.3.1 Κανόνες αν – τότε (if – then rules)

Οι λέξεις if και then χρησιμοποιούνται έτσι ώστε να μπορούν να περιγράψουν ένα πρόβλημα με την γλώσσα της ασαφής λογικής.

Για να κατασκευάσουμε έναν τέτοιο κανόνα χρειαζόμαστε δύο διαφορετικές γλωσσικές μεταβλητές της μορφής A και B. Θεωρούμε ότι αυτές οι μεταβλητές προσδιορίζονται από ασαφή σύνολα με χώρο αναφοράς x και y αντίστοιχα. Οπότε αυτό θα πάει την μορφή:

if x is A then y is B

όπου το πρώτο κομμάτι ονομάζεται υπόθεση ενώ το δεύτερο ονομάζεται συμπέρασμα.

Ας δώσουμε κάποια παραδείγματα έτσι ώστε τα παραπάνω να γίνουν πιο κατανοητά.

Έστω ότι θέλουμε να ελέγξουμε την ταχύτητα ενός ανεμιστήρα. Μπορούμε να κάνουμε μια δήλωση ως εξής:

IF temperature > 30°

THEN fan speed is high

Το μειονέκτημα αυτού του κανόνα είναι ότι χρησιμοποιεί μια αυστηρή θερμοκρασία ως κατώφλι, με αποτέλεσμα ο ανεμιστήρας να εξακολουθεί να λειτουργεί με χαμηλή ταχύτητα ακόμα και στους 29,9° , κάτι που θα δυσαρεστήσει τον χρήστη.

Μια άλλη μορφή που θα μπορούσε να έχει η δήλωση, είναι η εξής:

IF temperature is hot

THEN fan speed is fast

όπου το ζεστό και το κρύο περιγράφονται από ασαφή ζευγάρια.

Ένα άλλο παράδειγμα θα μπορούσε να ήταν η εξάρτηση μεταξύ οδοστρώματος και ορίου ταχύτητας. Συνεπώς σε μια εθνική όπου το οδόστρωμα είναι σε κακή κατάσταση και το όριο ταχύτητας είναι υψηλό, τότε ο δρόμος αυτός θεωρείται υψηλής επικινδυνότητας. Όπου:

- Μεταβλητές εισόδου είναι το οδόστρωμα και το όριο ταχύτητας
- Μεταβλητή εξόδου είναι η επικινδυνότητα
- Γλωσσικές μεταβλητές είναι οι όροι παλιό, υψηλό και αυξημένης

3.3.2 Συστήματα Ασαφούς Συλλογιστικής (Fuzzy Inference Systems)

Σε ένα πραγματικό πρόβλημα, ένας και μόνο κανόνας δεν μπορεί να αντιμετωπίσει με ορθότητα μια κατάσταση. Οπότε αυτό που γίνεται στην πράξη είναι η αλληλεπίδραση πολλών και διαφορετικών κανόνων μεταξύ τους. Η έξοδος κάθε κανόνα θα αποτελεί και ένα ασαφές σύνολο. Το σύνολο των ασαφών συνόλων αποτελεί ένα υπερσύνολο εξόδου το οποίο μετά από την διαδικασία της αποσαφήνισης θα μετατρέψει τις γλωσσικές μεταβλητές σε αριθμητικές και τελικά στην έξοδο θα πάρουμε μία μοναδική τιμή.

Τα μοντέλα που έχουν δημιουργηθεί με βάση την ασαφή λογική είναι πάρα πολλά όπως Kleene – Dienes, Lukasiewicz, EarlyZaden, Godel, Gaines – Rescher, Willmott κ.α, όμως στην παρούσα πτυχιακή θα αναφερθούν στα πιο σημαντικά που είναι το μοντέλο Mamdani, το μοντέλο Sugeno και το μοντέλο Tsukamoto.

Μοντέλο Mamdani

Το ασαφές μοντέλο Mamdani προτάθηκε για πρώτη φορά σαν μια προσπάθεια ελέγχου ενός συστήματος ατμομηχανής – λέβητα με ένα σύνολο ασαφών κανόνων. Αρχικά εκτελείται ασαφοποίηση των τιμών εισόδου, στη συνέχεια γίνεται εκτίμηση των κανόνων που ακολουθείται από συνάθροιση των συμπερασμάτων και τελικά την αποασαφοποίηση τους.

Συγκεκριμένα ισχύουν τα εξής:

$R_M: \text{EAN } X = A \text{ TOTE } Y = B \text{ ή}$

$R_M: (X = A) \rightarrow (Y = B) \text{ ή}$

$R_M: A \rightarrow B.$

Στον κανόνα R_M η πρόταση «το υποκείμενο X είναι A » αποτελεί το αίτιο, ενώ η πρόταση «το υποκείμενο Y είναι B » αποτελεί το αποτέλεσμα. Ή, ισοδύναμα, η ισότητα « $X = A$ » αποτελεί το αίτιο, ενώ η ισότητα « $Y = B$ » αποτελεί το αποτέλεσμα του κανόνα R_M .

Ένα τέτοιο σύστημα περιλαμβάνει ένα σύνολο κανόνων κατηγορηματικών προτάσεων της μορφής:

«EAN (X είναι A) TOTE (Y είναι B)»

ή συμβολικά « $A(x) \rightarrow B(y)$ »

όπου τα $A(x)$ και $B(y)$ είναι ασαφείς αριθμοί

Τα ορίσματα x και y των ασαφών αριθμών $A(x)$ και $B(y)$, αντίστοιχα, αναφέρονται σε διαφορετικά σύνολα αναφοράς και αντιστοιχούν σε διαφορετικές ασαφείς μεταβλητές.

Έστω ότι έχουμε σύστημα Mamdani τριών κανόνων με δύο εισόδους και μια έξοδο. Αυτές οι εισόδους και η έξοδος θα πρέπει να ικανοποιούν τις παρακάτω εκφράσεις:

- E1: EAN (η είσοδος 1 είναι μικρή) ΚΑΙ (η είσοδος 2 είναι κανονική) ΤΟΤΕ (η έξοδος είναι λίγη)
- E2: EAN (η είσοδος 1 είναι μεγάλη) ΚΑΙ (η είσοδος 2 είναι χαμηλή) ΤΟΤΕ (η έξοδος είναι αρκετή)
- E3: EAN (η είσοδος 1 είναι μεσαία) ΚΑΙ (η είσοδος 2 είναι υψηλή) ΤΟΤΕ (η έξοδος είναι πολλή)

Από τα παραπάνω η είσοδος 1,2 και η έξοδος αποτελούν ασαφείς μεταβλητές.

Μοντέλο Sugeno

Η μέθοδος Sugeno εμφανίστηκε για πρώτη φορά το 1985 και έχει αρκετές ομοιότητες με την μέθοδο Mamdani. Τα πρώτα δύο βήματα της διαδικασίας δηλαδή η ασαφοποίηση των εισόδων και η εφαρμογή των τελεστών είναι ίδια. Η βασική διαφορά ανάμεσα στα δύο συστήματα είναι ότι οι συναρτήσεις συμμετοχής στην έξοδο των συστημάτων Sugeno, είναι γραμμικές ή σταθερές συναρτήσεις.

Τα μοντέλα αυτά που είναι γνωστά και ως TSK επειδή προτάθηκαν από τους Takagi, Sugeno και Kang. Ένας τέτοιος τύπος ασαφούς κανόνα έχει την παρακάτω μορφή:

IF x is A and y is B THEN $z = f(x, y)$,

όπου A και B είναι τα ασαφή σύνολα

$z = f(x, y)$ η ασαφής συνάρτηση του συμπεράσματος

Συνήθως το $f(x, y)$ είναι ένα χαρακτηριστικό πολυώνυμο από το οποίο εξαρτάται ο βαθμός του μοντέλου διότι ουσιαστικά ισούται με το βαθμό του πολυωνύμου. Στην ειδική περίπτωση όπου το πολυώνυμο είναι μηδενικού βαθμού μπορούμε να πούμε ότι το μοντέλο Sugeno θα συμπεριφερθεί με τον ίδιο τρόπο με το μοντέλο Mamdani. Η έξοδος του μοντέλου αυτού αποτελείται από μια συνάρτηση μεταβλητών εισόδου.

Μοντέλο Tsukamoto

Αυτό το μοντέλο έχει παρόμοιο τρόπο επεξεργασίας κανόνων με το μοντέλο Mamdani. Πιο συγκεκριμένα τα τμήματα συνθηκών και ενεργειών ενός κανόνα είναι ασαφείς προτάσεις. Ο μόνος περιορισμός που υπάρχει είναι ότι το συμπερασματικό μέρος σε κάθε ασαφή σύνολο πρέπει να περιγράφεται από μονότονες συναρτήσεις συμμετοχής. Αυτό έχει ως αποτέλεσμα το συμπέρασμα που αποτελεί ουσιαστικά και την έξοδο του

κάθε κανόνα, να έχει μια σαφή τιμή η οποία προσδιορίζεται από τον βαθμό εκπλήρωσής της. Η τελική έξοδος προκύπτει ως ο σταθμισμένος μέσος όρος των συμπερασμάτων του κάθε κανόνα. Το πλεονέκτημα αυτής της μεθόδου είναι ότι λόγω της μη αναγκαιότητας ύπαρξης σαφών εξόδων, αποφεύγονται οι χρονοβόροι υπολογισμοί που εκτελούνται κατά την διάρκεια της αποασαφοποίησης. Παρά το θετικό όμως αυτό γεγονός, λόγω των μη ξεκάθαρων αποτελεσμάτων, δεν χρησιμοποιείται σε τόσο μεγάλη κλίμακα όσο τα παραπάνω δύο μοντέλα.

3.3.3 Νευροασαφή Συστήματα

Τα συστήματα αυτά είναι ουσιαστικά μια υποκατηγορία του ευφυούς ελέγχου. Στόχος ενός τέτοιου συστήματος δεν είναι η μοντελοποίηση του προβλήματος με ένα μαθηματικό μοντέλο που να είναι κατάλληλο να το περιγράψει, αλλά η αξιοποίηση αυτών των γνώσεων για την κατασκευή ενός συστήματος ελέγχου το οποίο θα είναι πλήρως ελέγξιμο από τον χρήστη.

Η ασαφής λογική αναπαράγει τους μηχανισμούς της ανθρώπινης σκέψης και την ικανότητα συλλογισμού ενώ τα νευρωνικά δίκτυα προσπαθούν να μιμηθούν τους μηχανισμούς του ανθρώπινου εγκεφάλου.

Συνεπώς οι δύο μέθοδοι διαφέρουν τόσο στην δομή όσο και στον τρόπο με τον οποίο επεξεργάζονται τα δεδομένα. Η πιο χαρακτηριστική ιδιότητα των νευρωνικών δικτύων είναι η ικανότητα μάθησης μέσω αλγορίθμων όπου εκπαιδεύονται να επεξεργάζονται ένα σύνολο δεδομένων. Το μεγαλύτερο ίσως μειονέκτημα των νευρωνικών δικτύων είναι η ανικανότητα απόδειξης ότι το δίκτυο έχει εκπαιδευτεί σωστά. Αυτό σημαίνει ότι εάν το νευρωνικό δίκτυο έχει μία γνώση, αυτή δεν μπορεί να μεταφερθεί στο χρήστη.

Στα ασαφή συστήματα υπάρχει η παραπάνω δυνατότητα καθώς εκτελούνται διαδοχικά βήματα μέχρι το τελικό συμπέρασμα με πλήρη επεξήγηση του τι συμβαίνει σε κάθε βήμα. Το κυριότερο όμως μειονέκτημα είναι ότι δεν μπορούν να ρυθμιστούν μέσω αλγορίθμου μάθησης. Δημιουργούνται από σαφείς εντολές οι οποίες έχουν την μορφή γλωσσικών κανόνων οι οποίες όμως πολλές φορές δεν καθιστούν δυνατό τον πλήρη και ακριβή καθορισμό όλων των παραμέτρων. Σε περίπτωση όπου το συμπέρασμα που προκύπτει δεν δίνει ικανοποιητικά αποτελέσματα, πολλές φορές είναι αναγκαία η χειροκίνητη ρύθμιση των παραμέτρων. Αυτή η διαδικασία όμως είναι αρκετά χρονοβόρα και υπάρχει μεγάλη πιθανότητα σφάλματος. Άρα γίνεται αντιληπτό ότι εάν

μπορούσε να εφαρμοστεί ένας αλγόριθμός εκμάθησης παρόμοιος με αυτόν των νευρωνικών δικτύων, θα παίρναμε πολύ καλύτερα αποτελέσματα τόσο από πλευράς ταχύτητας όσο και από πλευράς εγκυρότητας.

Οι δύο συνδυασμοί των παραπάνω μοντέλων που μπορούν να υπάρξουν είναι το ασαφές σύστημα να δουλεύει ανεξάρτητα από το νευρωνικό ενώ η δεύτερη περίπτωση είναι το υβριδικό ασαφές σύστημα.

Στην πρώτη περίπτωση το νευρωνικό σύστημα καθορίζει διάφορες παραμέτρους για το ασαφές σε πραγματικό ή μη πραγματικό χρόνο.

Στην δεύτερη περίπτωση ο όρος υβριδικό χρησιμοποιείται για να δείξει ότι το σύστημα που προκύπτει είτε είναι ασαφές είτε νευρωνικό όμως αντιμετωπίζεται σαν ομογενές σύστημα το οποίο δεν αποτελείται από δύο διαφορετικά.

Παρακάτω γίνεται μια αναφορά και με τις δύο διαφορετικές περιπτώσεις.

Νευροασαφή συστήματα συνεργασίας

Αυτή η περίπτωση μπορεί να διαιρεθεί σε περισσότερες υποπεριπτώσεις όπως φαίνονται και σχολιάζονται παρακάτω:


- Το νευρωνικό δίκτυο ρυθμίζει τις συναρτήσεις συμμετοχής του ασαφούς δικτύου χρησιμοποιώντας τα δεδομένα εκπαίδευσης τα οποία πρέπει να αφορούν βαθμούς συμμετοχής που αντιστοιχούν σε συγκεκριμένες τιμές εισόδων. Η διαδικασία γίνεται σε μη πραγματικό χρόνο.
- Το νευρωνικό δίκτυο σχηματίζει τους ασαφείς κανόνες που προκύπτουν από τις συναρτήσεις συμμετοχής από τα δεδομένα εκπαίδευσης. Η διαδικασία πραγματοποιείται σε μη πραγματικό χρόνο.
- Η διαδικασία πραγματοποιείται σε πραγματικό χρόνο όπου και πρέπει να δοθούν εκ των προτέρων οι ασαφείς κανόνες και οι συναρτήσεις σχήματος. Επίσης πρέπει να οριστεί και ένα μέγεθος σφάλματος από το οποίο εξαρτάται και η διαδικασία εκπαίδευσης.
- Η διαδικασία μπορεί να πραγματοποιηθεί είτε σε πραγματικό χρόνο είτε σε μη πραγματικό οπότε και σε αυτή την περίπτωση πρέπει να δοθούν εξ αρχής οι ασαφείς κανόνες και οι συναρτήσεις σχήματος.

Υβριδικά νευροασαφή συστήματα

Στην εικόνα 27 βλέπουμε ένα παράδειγμα υβριδικού νευροασαφούς ελεγκτή. Παρατηρούμε ότι έχει ένα δίκτυο πολλών στρωμάτων και είναι πρόσθιας

τροφοδότησης. Τα αίτια αντιστοιχούν στους κόμβους εισόδου ενώ τα συμπεράσματα στους κόμβους εξόδου. Στα κρυφά στρώματα εκτελούνται οι λειτουργίες υπολογισμού των συναρτήσεων συμμετοχής και της βάσης κανόνων από τους νευρώνες. Κάθε στρώμα αποτελεί και ένα στάδιο της μεθόδου.

Οι κόμβοι εισόδου τροφοδοτούν τα επόμενα στρώματα μέχρι την έξοδο του ελεγκτή. Στο πρώτο στρώμα έχουμε τις συναρτήσεις συμμετοχής, στο δεύτερο στρώμα έχουμε την βάση κανόνων, στο τρίτο στρώμα έχουμε την λειτουργία του μηχανισμού συμπεράσματος και στο τέταρτο και τελευταίο στρώμα έχουμε τον κόμβο εξόδου.



Εικόνα 27: Υβριδικός νευροασαφής ελεγκτής

Η σχέση που χαρακτηρίζει την είσοδο και έξοδο κάθε νευρώνα είναι:

$$\omega = f(\sigma), \text{ με } \sigma = \sum_{i=1}^p w_i u_i$$

όπου

ω : είναι η έξοδος

u_i : οι είσοδοι του νευρώνα

σ : το σταθμισμένο άθροισμα

w_i : τα βάρη

f : η συνάρτηση μεταφοράς

3.4 ANFIS (Adaptive Neuro – Fuzzy Inference System)

Το μοντέλο ANFIS προτάθηκε για πρώτη φορά από τον Jang το 1992. Έχει μη γραμμικές προηγούμενες παραμέτρους και γραμμικές επακόλουθες παραμέτρους. Ουσιαστικά ανήκει στα προσαρμοσμένα δίκτυα τα οποία μοιάζουν αρκετά με τα νευρωνικά δίκτυα. Χρησιμοποιώντας ένα σύνολο εισόδων και επιθυμητών εξόδων, κατασκευάζουμε ένα σύστημα ασαφούς συλλογιστικής στο οποίο οι παράμετροι των συναρτήσεων συμμετοχής προσαρμόζονται από έναν αλγόριθμο μάθησης.

Το μεγαλύτερο πλεονέκτημα της μεθόδου είναι το γεγονός ότι αν έχουμε ζευγάρια δεδομένων εισόδου και εξόδου και θέλουμε να τα χρησιμοποιήσουμε για την κατασκευή ενός μοντέλου, χωρίς να έχουμε αποφασίσει εκ των προτέρων τι δομή θα έχει, οι συναρτήσεις συμμετοχής και οι παράμετροι τους σχηματίζονται με βάση τα δεδομένα αυτά.


3.4.1 Εισαγωγή - Ορισμός

Το μοντέλο ANFIS αποτελείται από τους προσαρμοστικούς και τους μη προσαρμοστικούς κόμβους. Κάθε κόμβος εκτελεί και μία συγκεκριμένη λειτουργία που βασίζεται από το σύνολο των παραμέτρων. Οι κόμβοι συνδέονται με κατευθυντήριων συνδέσμων και μερικοί ή μπορεί και όλοι να είναι προσαρμόσιμοι. Αυτό σημαίνει ότι το αποτέλεσμα σχετίζεται άμεσα από τις παραμέτρους του κόμβου και ο κανόνας μάθησης προσδιορίζει τις παραμέτρους ελαχιστοποιώντας το μέγεθος του σφάλματος. Το είδος αλλά και η λειτουργία κάθε κόμβου μπορεί να αλλάζει από κόμβο σε κόμβο και αυτό εξαρτάται από τις εισόδους και τις εξόδους που μπορεί να εκτελέσει ένα προσαρμοστικό δίκτυο.

Οι κόμβοι ενός προσαρμοστικού δικτύου μπορούν να εμφανίζονται σε μία απεικόνιση είτε ως κύκλοι είτε ως τετράγωνα. Ο τετραγωνικός κόμβος περιλαμβάνει παραμέτρους ενώ ο κυκλικός κόμβος δεν έχει παραμέτρους. Ως σύνολο παραμέτρων ορίζεται η ένωση των συνόλων των παραμέτρων όλων των κόμβων που αποτελούν ένα προσαρμοστικό δίκτυο. Οι κόμβοι ενημερώνονται με μοντέλα μάθησης με σκοπό την επίτευξη της αντιστοίχισης των δεδομένων εισόδου με αυτές των δεδομένων εξόδου. Στο δίκτυο ANFIS χρησιμοποιείται το ασαφές μοντέλο μάθησης Sugeno. Το μοντέλο ANFIS λειτουργεί με κανόνες if / then με ζευγάρια εισόδου – εξόδου. Οπότε το μοντέλο αποκτά ένα σύνολο δεδομένων εισερχομένων και εξερχομένων και τα χωρίζει σε σύνολα δεδομένων τα οποία πηγαίνουν για εκπαίδευση και έλεγχο.

Οι κυριότεροι λόγοι όπου το μοντέλο ANFIS έχει βρει ιδιαίτερη απήχηση είναι:

- Εύκολη στην εφαρμογή
- Γρήγορη και αποτελεσματική εκμάθηση
- Μεγάλες ικανότητες γενίκευσης
- Τέλειες παροχές στην Αιτιολόγησης μέσω ασαφών κανόνων
- Εύκολη στην ενσωμάτωση γλωσσικής και αριθμητικής γνώσης για την επίλυση Προβλημάτων



Εικόνα 28: Μοντέλο ANFIS

Τα δεδομένα που στέλνονται για εκπαίδευση διαμορφώνουν ένα σύνολο διανυσμάτων εισόδου και εξόδου. Η πληροφορία αυτή μετατρέπεται έτσι ώστε να γίνει σε μορφή όπου μπορεί να εκπαιδευτεί. Αυτό πραγματοποιείται μεταφράζοντας κάθε όρο με 0 και 1 και χρησιμοποιώντας τη μέθοδο Min – Max. Στην συνέχεια τα δεδομένα χρησιμοποιούνται ως τιμές εισόδου και εξόδου με σκοπό την εκπαίδευση του μοντέλου ANFIS. Προκύπτουν δύο διανύσματα εκπαίδευσης τα οποία είναι:

- Διάνυσμα εισόδου
- Διάνυσμα εξόδου

Τα διανύσματα εκπαίδευσης χρησιμοποιούνται ώστε να βρουν τις αρχικές παραμέτρους στις συναρτήσεις συμμετοχής. Οι παράμετροι που προκύπτουν υπολογίζονται με την μέθοδο των ελαχίστων τετραγώνων και στην συνέχεια υπολογίζεται ένα σφάλμα για κάθε ζευγάρι δεδομένων. Αν το σφάλμα είναι μεγαλύτερο από αυτό που έχει θέσει ο χρήστης ως αποδεκτή τιμή, οι αρχικές παράμετροι ενημερώνονται με την χρήση της μεθόδου βαθμωτής καθόδου. Όταν το σφάλμα φτάσει σε μέγεθος μικρότερο από την αποδεκτή τιμή, θεωρείται ότι το δίκτυο εκπαιδεύτηκε και η διαδικασία μάθησης τερματίζεται.

3.4.2 Δομή Αρχιτεκτονικής του ANFIS

Ο αλγόριθμος του ANFIS αποτελείται από πέντε διαφορετικά στάδια που από εδώ και πέρα θα τα αποκαλούμε στρώματα.

Υποθέτουμε πως έχουμε ένα ασαφές σύστημα το οποίο αποτελείται από δύο εξόδους x και y αντίστοιχα και μία έξοδο f . Το μοντέλο αυτό με τους κανόνες if / then θα περιγράφεται ως εξής:

Κανόνας 1: If x is A_1 and y is B_1 , then $f_1 = p_1 x + q_1 y + r_1$

Κανόνας 2: If x is A_2 and y is B_2 , then $f_2 = p_2 x + q_2 y + r_2$

Όπου A_i και B_i είναι οι γλωσσικές παράμετροι οι οποίες συνεργάζονται με την συνάρτηση συμμετοχής των κόμβων

Στρώμα 1 (κόμβος εισόδου)

Οι κόμβοι σε αυτό το επίπεδο που είναι και το πρώτο, περιέχουν τις συναρτήσεις συμμετοχής. Οι παράμετροι μπορούν να θεωρηθούν και ως υποθετικοί. Κάθε κόμβος I παρουσιάζεται με έναν κόμβο τετραγωνικής μορφής και είναι προσαρμοζόμενος κόμβος. Η συνάρτηση συμμετοχής του είναι:

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

Όπου x είναι η είσοδος για τον κόμβο i και A_i είναι η γλωσσική παράμετρος η οποία συνδέεται με την συγκεκριμένη συνάρτηση συμμετοχής του κόμβου.

Η συνάρτηση συμμετοχής μπορεί να είναι οποιαδήποτε κατάλληλα παραμετροποιημένη συνάρτηση, όπως είναι η γενικευμένη συνάρτηση bell ή η Gaussian.

Στρώμα 2 (κόμβος κανόνων)

Οι κόμβοι σε αυτό το επίπεδο είναι κυκλικής μορφής και η έξοδος του αντιπροσωπεύει την δύναμη ενός κανόνα. Κατά την διάρκεια αυτού του επιπέδου γίνεται η επιλογή ελάχιστης τιμής βαρών των δύο εισόδων και εφαρμόζεται ο κανόνας AND/OR για να πάρουμε μία έξοδο που αντιπροσωπεύει τα αποτελέσματα του προηγούμενου κόμβου για ένα ασαφή κανόνα. Ο κόμβος παράγει μία έξοδο η οποία προκύπτει από τον πολλαπλασιασμό όλων των εισόδων και είναι της μορφής:

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

Στρώμα 3 (μέσος όρος κόμβων)

Σε αυτό το επίπεδο κάθε κόμβος είναι κυκλικός. Ο κόμβος i υπολογίζει τον λόγο μεταξύ της δύναμης του i κανόνα και του αθροίσματός όλων των δυνάμεων από όλους τους κανόνες. Κάθε κόμβος του επιπέδου αυτού κάνει υπολογισμό του βάρους με βάση την παρακάτω εξίσωση:

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

Στρώμα 4 (προκύπτοντες κόμβοι)

Στο επίπεδο αυτό περιλαμβάνονται οι γραμμικές συναρτήσεις οι οποίες εξαρτώνται άμεσα από τα δεδομένα εισόδου. Πρακτικά αυτό που συμβαίνει είναι ο υπολογισμός της συνεισφοράς του κανόνα i σε σχέση με την συνολική έξοδο του μοντέλου. Οι κόμβοι αυτού του επιπέδου είναι τετραγωνικής μορφής και η συνάρτηση του κόμβου περιγράφεται από την παρακάτω εξίσωση:

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

Όπου w_i είναι η έξοδος του επιπέδου 3 και τα p_i , q_i , και r_i είναι το σύνολο όλων των παραμέτρων του συγκεκριμένου κόμβου αυτού. Αυτοί οι παράμετροι συχνά ονομάζονται και προκύπτοντες παράμετροι.

Στρώμα 5 (κόμβος εξόδου)


Το στρώμα 5 είναι το τελευταίο στρώμα και αποτελεί την έξοδο του συστήματος. Είναι ένας μονός κόμβος ο οποίος υπολογίζει την συνολική έξοδο αθροίζοντας όλα τα εισερχόμενα σήματα. Μαθηματικά περιγράφεται ως εξής:

$$O_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

3.4.3 Περιγραφή του Μοντέλου

Το μοντέλο του ANFIS όπως έχει αποδειχθεί περιγράφεται καλύτερα με προγραμματισμό Matlab. Μέσω της εντολής `anfis edit` είναι δυνατή η γραφική αναπαράσταση των αποτελεσμάτων ενός μοντέλου ANFIS.

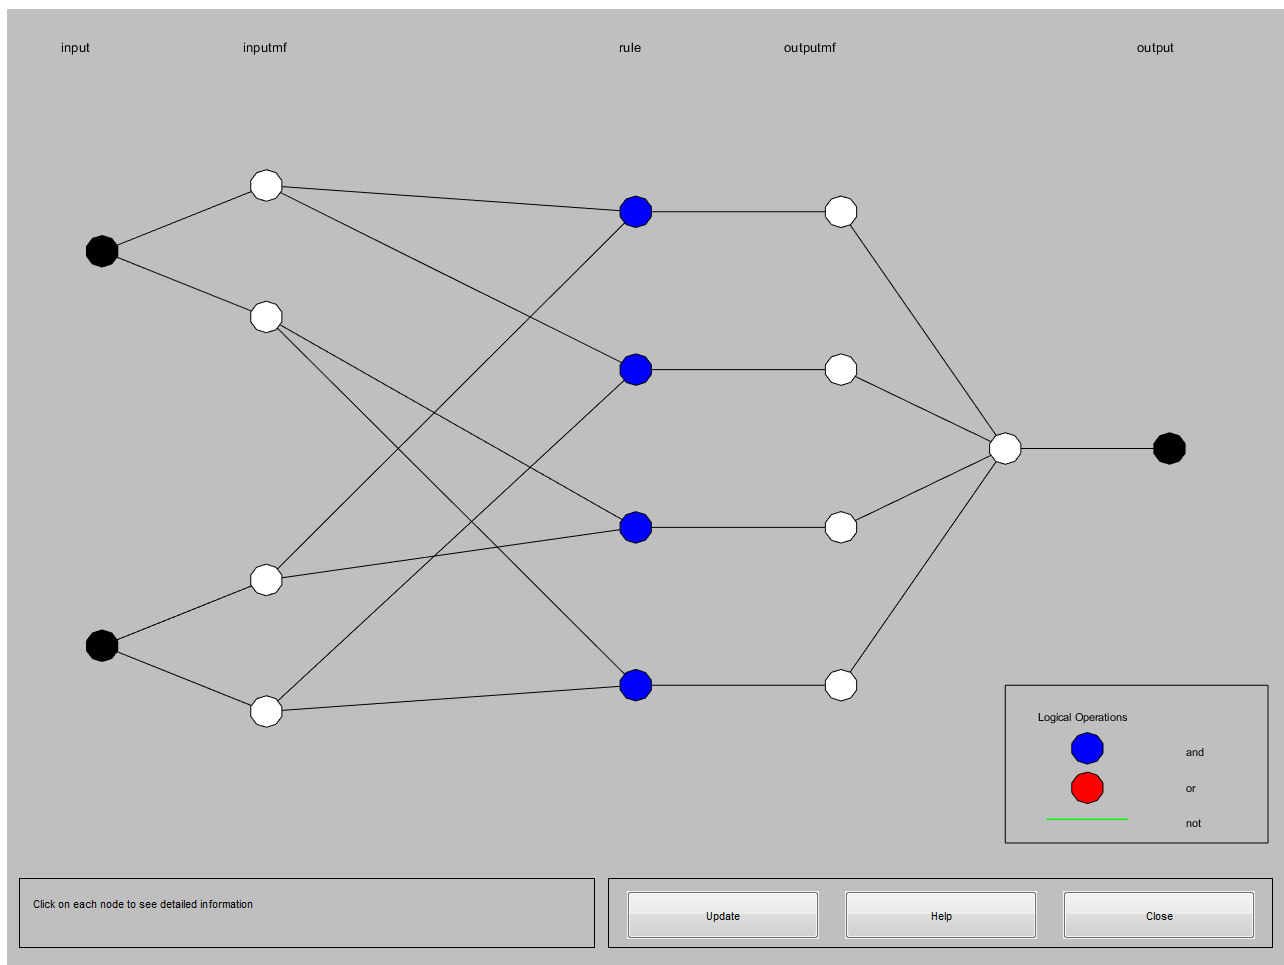
Ο χρήστης μπορεί να χρησιμοποιήσει είτε προγράμματα `m – file` είτε το περιβάλλον γραμμής εντολών για να εισάγει δεδομένα στον αλγόριθμο. Υπάρχουν επίσης συναρτήσεις οι οποίες εκπαιδεύουν και ελέγχουν αυτά τα συστήματα.



Εικόνα 29: ANFIS editor

Τα βήματα που ακολουθούνται για τον προγραμματισμό σε περιβάλλον Matlab είναι:

- Προετοιμασία
- Εκπαίδευση
- Έλεγχος
- Χρήση



Εικόνα 30: Μοντέλο ANFIS (Housedata)

Παρατήρηση

Επιπρόσθετα, στην (εικόνα 30) παρουσιάζεται το μοντέλο ANFIS που μελετήσαμε. Διακρίνουμε δυο εισόδους όπως έχουμε προαναφέρει ονομάζονται στρώμα 1 (κομβοί εισόδου) όπου το input 1 παίρνει δεδομένα $x(k-1)$ δηλαδή για το σήμερα και το input 2 για $x(k-2)$ δηλαδή για το χθες. Στην συνέχεια στο στρώμα 2 (κανόνες κόμβων) παρουσιάζονται 4 κομβοί όπου εκεί γίνεται η επεξεργασία των συναρτήσεων συμμετοχής. Στο στρώμα 3 (μέσος όρος κόμβων) και παρουσιάζονται οι κανόνες, εν συνεχεία στο στρώμα 4 (προκύπτοντες κόμβοι) όπου εκεί βρίσκονται οι μηχανισμοί συμπερασμού. Τέλος στο στρώμα 5 (κόμβος εξόδου) όπου εκεί γίνεται η εξαγωγή του αποτελέσματος και μας παρουσιάζει το $x(k)$ δηλαδή το αύριο.

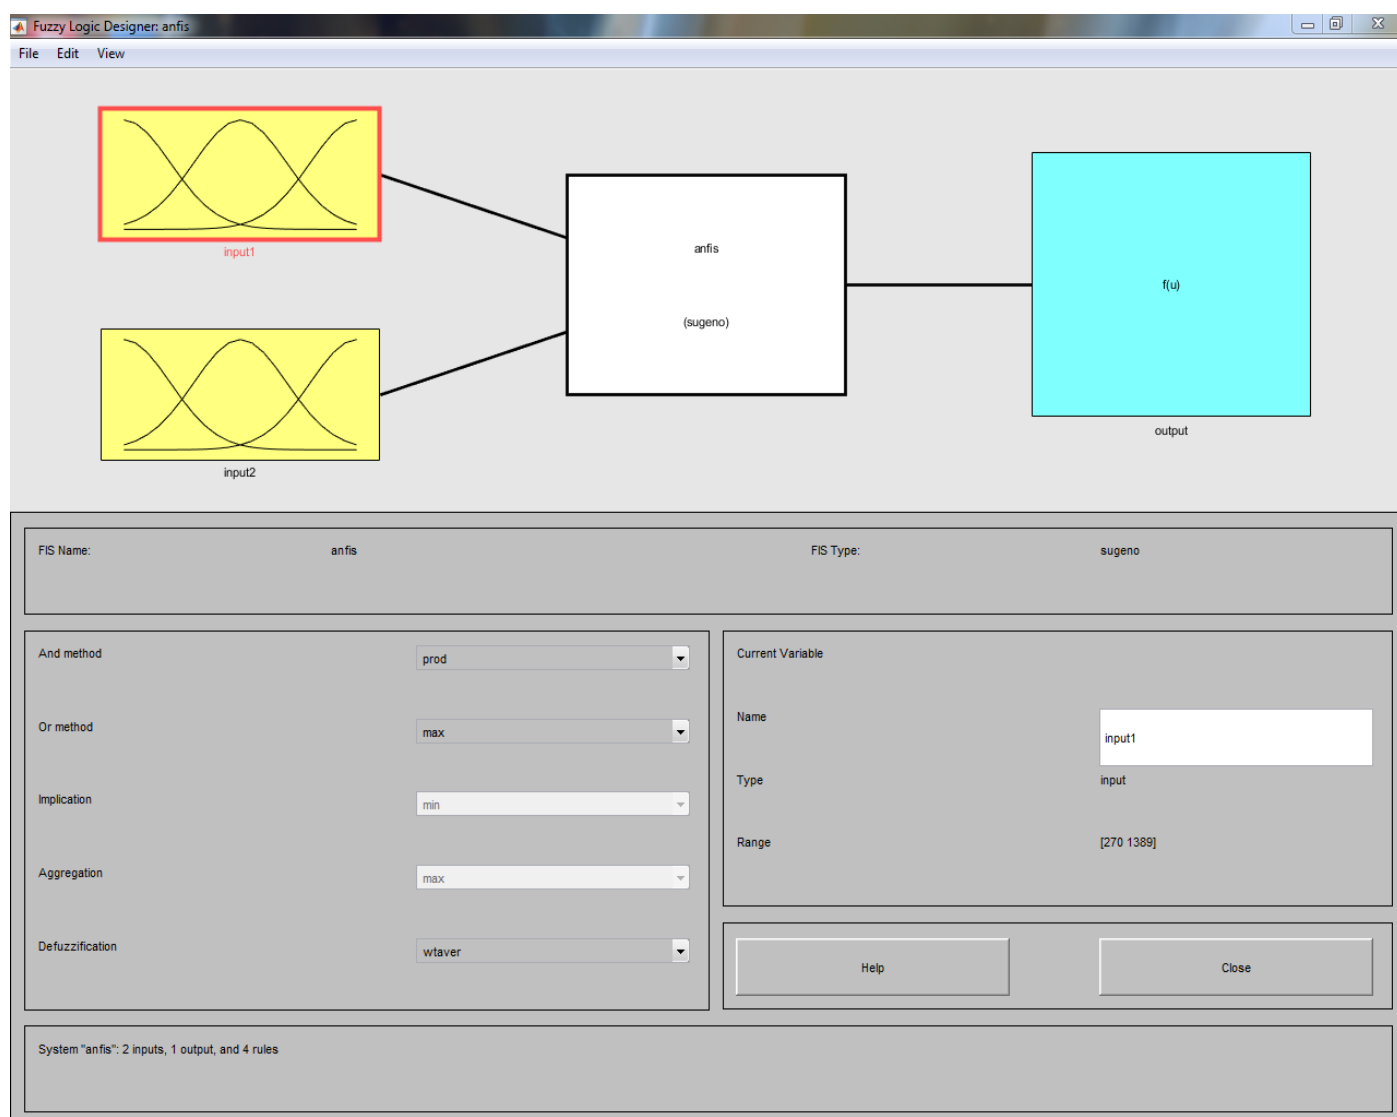
Σημείωση

Το ANFIS υποστηρίζει μόνο συστήματα τύπου Sugeno και αυτά θα πρέπει να έχουν τις ακόλουθες ιδιότητες :

- Να είναι πρώτης ή μηδενικής τάξης συστήματα τύπου Sugeno
- Να έχουν μια μόνο έξοδο η οποία λαμβάνεται χρησιμοποιώντας σταθμισμένο μέσο όρο από-ασαφοποίησης. Όλες οι συναρτήσεις συμμετοχής εξόδου πρέπει να είναι του ίδιου τύπου και είναι είτε γραμμικές ή σταθερές.

- Δεν έχουν καμία ανταλλαγή κανόνα. Διαφορετικοί κανόνες δεν μπορούν να μοιράζονται την ίδια συνάρτηση συμμετοχής εξόδου, δηλαδή ο αριθμός των συναρτήσεων συμμετοχής εξόδου πρέπει να είναι ίσος με τον αριθμό των κανόνων.
 - Να έχει ενωτικό βάρος για κάθε κανόνα
- Εάν η δομή μας δεν συμμορφώνεται με αυτούς τους περιορισμούς, τότε είναι πολύ πιθανό να οδηγηθούμε σε σφάλμα μοντελοποίησης.

Στην συνέχεια παρουσιάζεται η δομή του μοντέλου, το μοντέλο αποτελείται από δυο εισόδους και μια έξοδο. Στην είσοδο παίρνει τις πωλήσεις ακινήτων μιας τυχαίας ημέρας (t) και τις πωλήσεις της ακριβώς προηγούμενης ημέρας ($t-1$), επίσης σαν έξοδο παίρνει την πρόβλεψη του ANFIS για την πώληση των ακινήτων την επόμενη τυχαία ημέρα ($t+1$). Η δομή του μοντέλου απεικονίζεται στο επόμενο σχήμα :



Εικόνα 31: Δομή Μοντέλου

Επιπρόσθετα όπως παρατηρούμε από το σχήμα ANFIS είναι τύπου Sugeno. Αξίζει να σημειωθεί ότι το ασαφές μοντέλο τύπου Sugeno προτάθηκε από τους Tagaki, Sugeno και Kang ώστε να αναπτύξουν μια συστηματική προσέγγιση που θα τους επιτρέψει την

παραγωγή ασαφών κανόνων από ένα συγκεκριμένο σύνολο δεδομένων εισόδου-εξόδου. Εν συνεχεία παρατίθεται ένας τυπικός ασαφής κανόνας για εάν ασαφές μοντέλο τύπου Sugeno :

$$\text{αν } x \text{ είναι } A \text{ και } y \text{ είναι } B \text{ τότε } z = f(x,y)$$

όπως παρατηρούμε τα ασαφή σύνολα στα αίτια (antecedent) χαρακτηρίζονται τα A και B , επίσης το $z = f(x,y)$ είναι μια σαφής (crisp) συνάρτηση στο συμπέρασμα (consequent). Συνήθως το $f(x,y)$ είναι ένα πολυώνυμο των μεταβλητών εισόδου x και y . Επιπρόσθετα μπορεί να είναι οποιαδήποτε συνάρτηση αρκεί να μπορεί να περιγράψει κατάλληλα την έξοδο του μοντέλου εντός της ασαφούς περιοχής που καθορίζεται από τα αίτια του κανόνα. Αξίζει να σημειωθεί ότι το μοντέλο ANFIS που μελετήσαμε είναι πρώτου βαθμού ασαφές μοντέλο τύπου Sugeno δηλαδή το $f(x,y)$ είναι ένα πολυώνυμο πρώτου βαθμού. Στην συνέχεια παρουσιάζονται οι κανόνες που ισχύουν για το μοντέλο που μελετήσαμε:

Αν (t) είναι small και $(t-1)$ είναι small τότε $(t+1)$ είναι very small

Αν (t) είναι small και $(t-1)$ είναι large τότε $(t+1)$ είναι small

Αν (t) είναι large και $(t-1)$ είναι small τότε $(t+1)$ είναι large

Αν (t) είναι large και $(t-1)$ είναι large τότε $(t+1)$ είναι very large

Οι συναρτήσεις συμμετοχής των εισόδων (t) και $(t-1)$ είναι οι ίδιες, αφού και οι δύο συναρτήσεις είναι τύπου gbellmf. Η εξίσωση των συναρτήσεων τύπου gbellmf είναι:

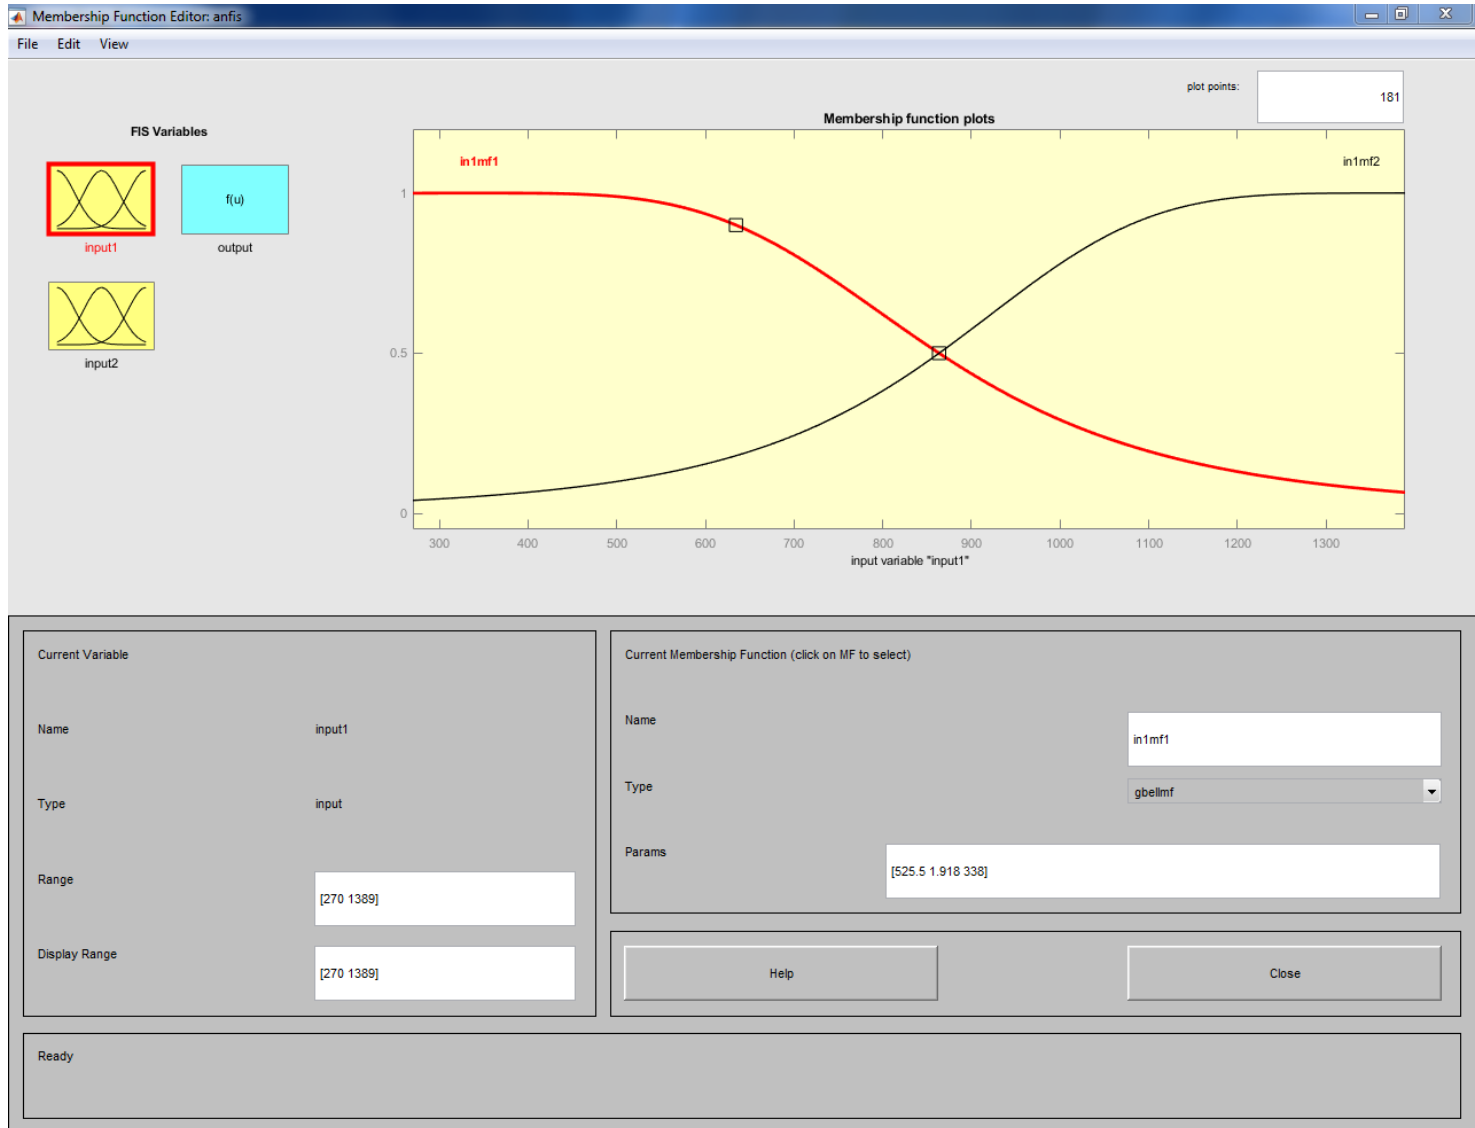
$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}}$$

όπου τα a_i, b_i, c_i είναι το σύνολο των παραμέτρων. Επίσης στο ακόλουθο σχήμα στην (εικόνα 32) παρουσιάζεται η συνάρτηση συμμετοχής των εισόδων (t) και $(t-1)$.

Αξίζει να σημειωθεί ότι χρησιμοποιήθηκαν δυο συναρτήσεις συμμετοχής. Η καμπύλη in1mf1 και η in1mf2 που είναι καμπανοειδείς μορφής, επίσης in1mf1 αντιστοιχεί στο (λίγο) ενώ in1mf2 αντιστοιχεί στο (πολύ) . Οι συναρτήσεις έχουν επιλεχθεί ώστε να εκπαιδεύσουν τα εισερχόμενα και τα εξερχόμενα δεδομένα. Εν συνέχεια είναι από τα σημαντικότερα βήματα είναι ο καθορισμός της ασαφούς συνάρτησης συμμετοχής των αντίστοιχων τιμών. Οι συναρτήσεις τύπου bell είναι οι πιο δημοφιλείς επιλογή λόγω των καθορισμών των ασαφών συνόλων και της ομαλότητας του επίσης έχουν πλεονέκτημα να είναι ομαλές και μη μηδενικές σε κάθε σημείο. Αξίζει να σημειωθεί ότι και οι Γκαουσιανές έχουν τα αντίστοιχα πλεονεκτήματα. Επιπρόσθετα η συνάρτηση τύπου bell διαθέτει μια επιπλέον παράμετρο σε σχέση με την Γκαουσιανή, μπορεί να προσεγγίσει ένα σύνολο όταν η ελεύθερη επιφάνεια είναι ήδη προσαρμοσμένη. Επίσης τα αποτελέσματα μας,

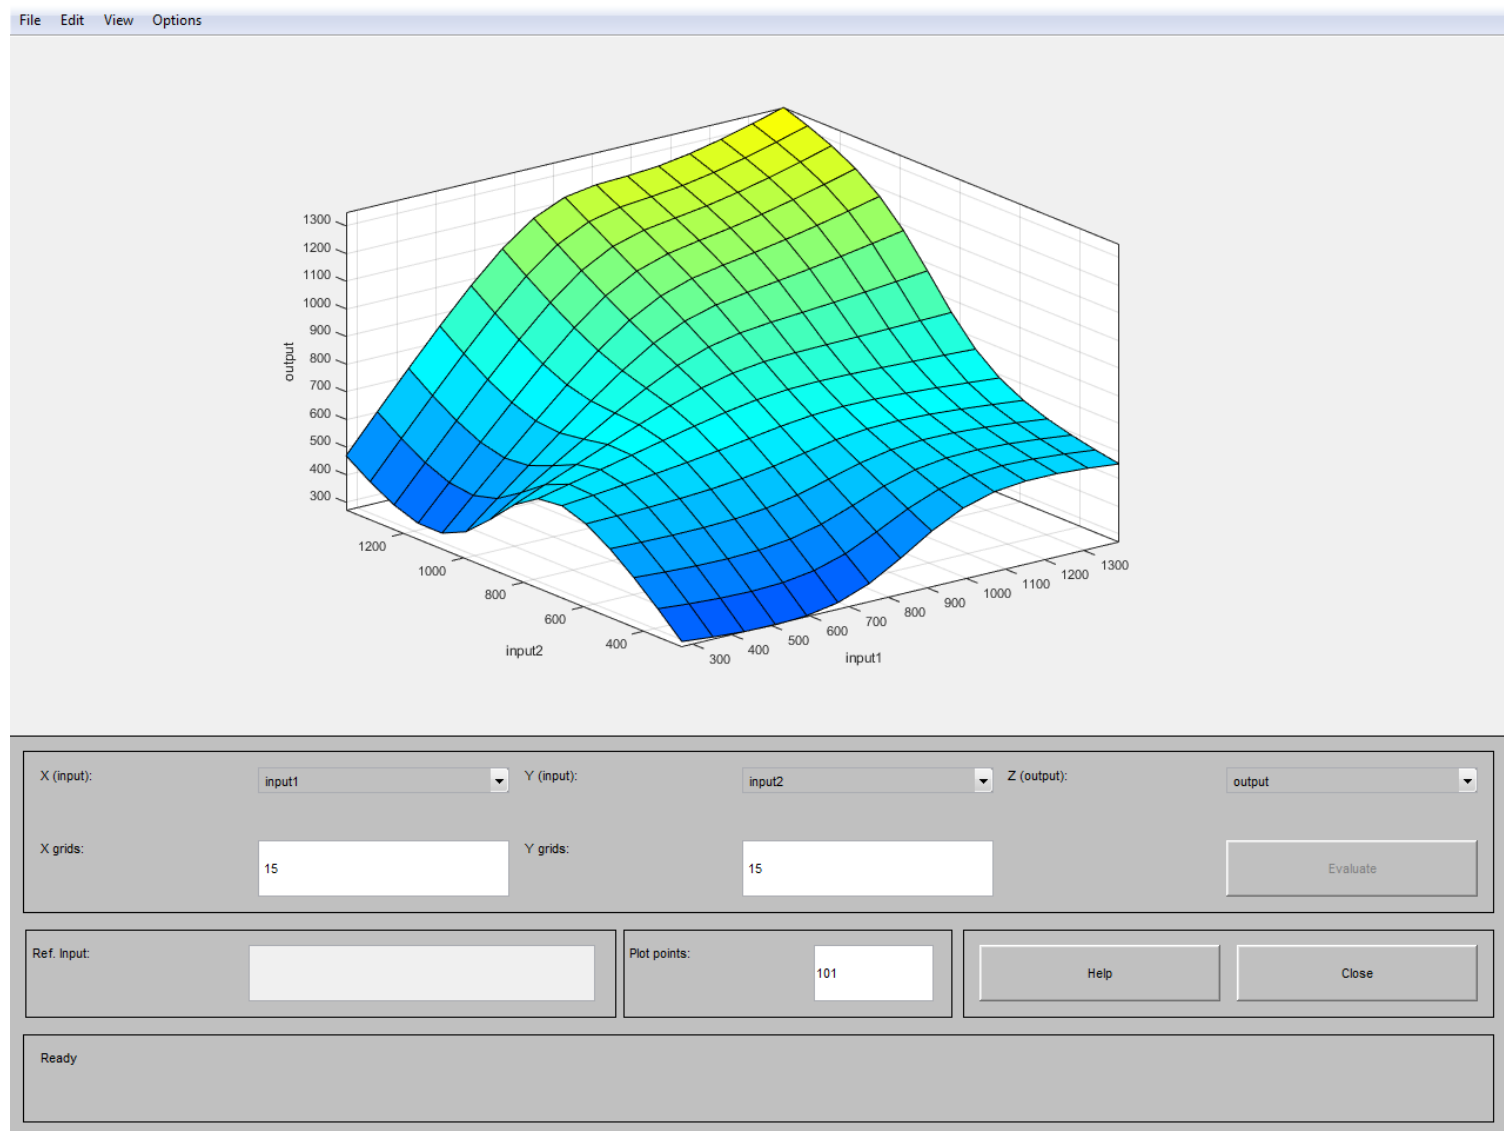
υποδεικνύουν μια καθυστέρηση στην λειτουργία της in1mf2 η οποία επιβεβαιώνει την φυσιολογική κατανόηση.

Τέλος, στην (εικόνα 33) απεικονίζεται η προσπίπτουσα επιφάνεια εισόδου- εξόδου σε τρισδιάστατη μορφή.



Εικόνα 32: Συνάρτηση συμμετοχής της εισόδου πριν την εκμάθηση του συστήματος


- **In1mf1=λίγο**
- **In1mf2=πολύ**



Εικόνα 33: Συνολική επιφάνεια εισόδου- εξόδου

Παρατήρηση

Στην (εικόνα 33) παρουσιάζεται μια τρισδιάστατη επιφάνεια ασαφούς μοντέλου. Όπως μπορούμε να παρατηρήσουμε η επιφάνεια είναι αρκετά ομαλή, γεγονός που μας υποδηλώνει ότι έχουμε πάρει ικανοποιητικούς αριθμό δεδομένων και τα αποτελέσματα που θα συλλέξουμε από την χρήση του μοντέλου που κατασκευάσαμε θα είναι αρκετά καλά. Επιπρόσθετα, παρατηρείται στην πάνω και κάτω αριστερή γωνία του σχήματος μια ανωμαλία, γεγονός που μας υποδηλώνει ότι υπάρχει διασπορά των άκρων. Αυτή η ανωμαλία μπορεί να εξηγηθεί περεταίρω με την εξέταση την γραφημάτων διασποράς που απεικονίζεται στα επόμενα σχήματα :



Εικόνα 34: Γράφημα διασποράς δεδομένων εκπαίδευσης

Παρατήρηση


Εν συνεχεία στην (εικόνα 34) παρουσιάζονται τα γραφήματα διασποράς δεδομένων εκπαίδευσης, στο αριστερό γράφημα παρουσιάζεται τα δεδομένα εκπαίδευσης όπου στον y άξονα απεικονίζονται τα output τα δεδομένα εξόδου k δηλαδή το αύριο. Ενώ στον x άξονα παρουσιάζονται τα input ($k-2$) τα δεδομένα εισόδου δηλαδή το χθες.

Τα δεδομένα εκπαίδευσης εκτείνονται για $k-2$ από 350 έως 1400.

Αντίστοιχα στο δεξί γράφημα παρουσιάζονται τα δεδομένα εκπαίδευσης όπου στον y άξονα απεικονίζονται τα output τα δεδομένα εξόδου k δηλαδή το αύριο, ενώ στον x άξονα παρουσιάζονται τα input ($k-1$) τα δεδομένα εισόδου δηλαδή το σήμερα.

Επίσης, τα δεδομένα εκπαίδευσης εκτείνονται για $k-1$ από 350 έως 1400.

Αξίζει να σημειωθεί ότι τα δεδομένα που κάνει εκπαίδευση το πρόγραμμα ANFIS είναι τα 4/5 δηλαδή 545. Τέλος, όπως παρατηρούμε στην περιοχή από 1100 έως 1400 και στην περιοχή 300 έως 400 αντίστοιχα, παρατηρείται διασπορά δεδομένων γεγονός που επηρεάζει εκείνη η περιοχή την ομαλότητα της μεθόδου όπως αποδεικνύεται και στην (εικόνα 33).



Εικόνα 35: Γράφημα διασποράς δεδομένων ελέγχου

Παρατήρηση

Στην (εικόνα 35) παρουσιάζονται τα γραφήματα διασποράς δεδομένων ελέγχου στον αριστερό άξονα απεικονίζονται τα δεδομένα ελέγχου όπου στον y άξονα παρουσιάζονται τα output (k) τα δεδομένα εξόδου δηλαδή το αύριο, ενώ στον x άξονα παρουσιάζονται τα δεδομένα εισόδου input (k-2) δηλαδή το χθες.

Τα δεδομένα ελέγχου εκτείνονται για k-2 από 260 έως 740.

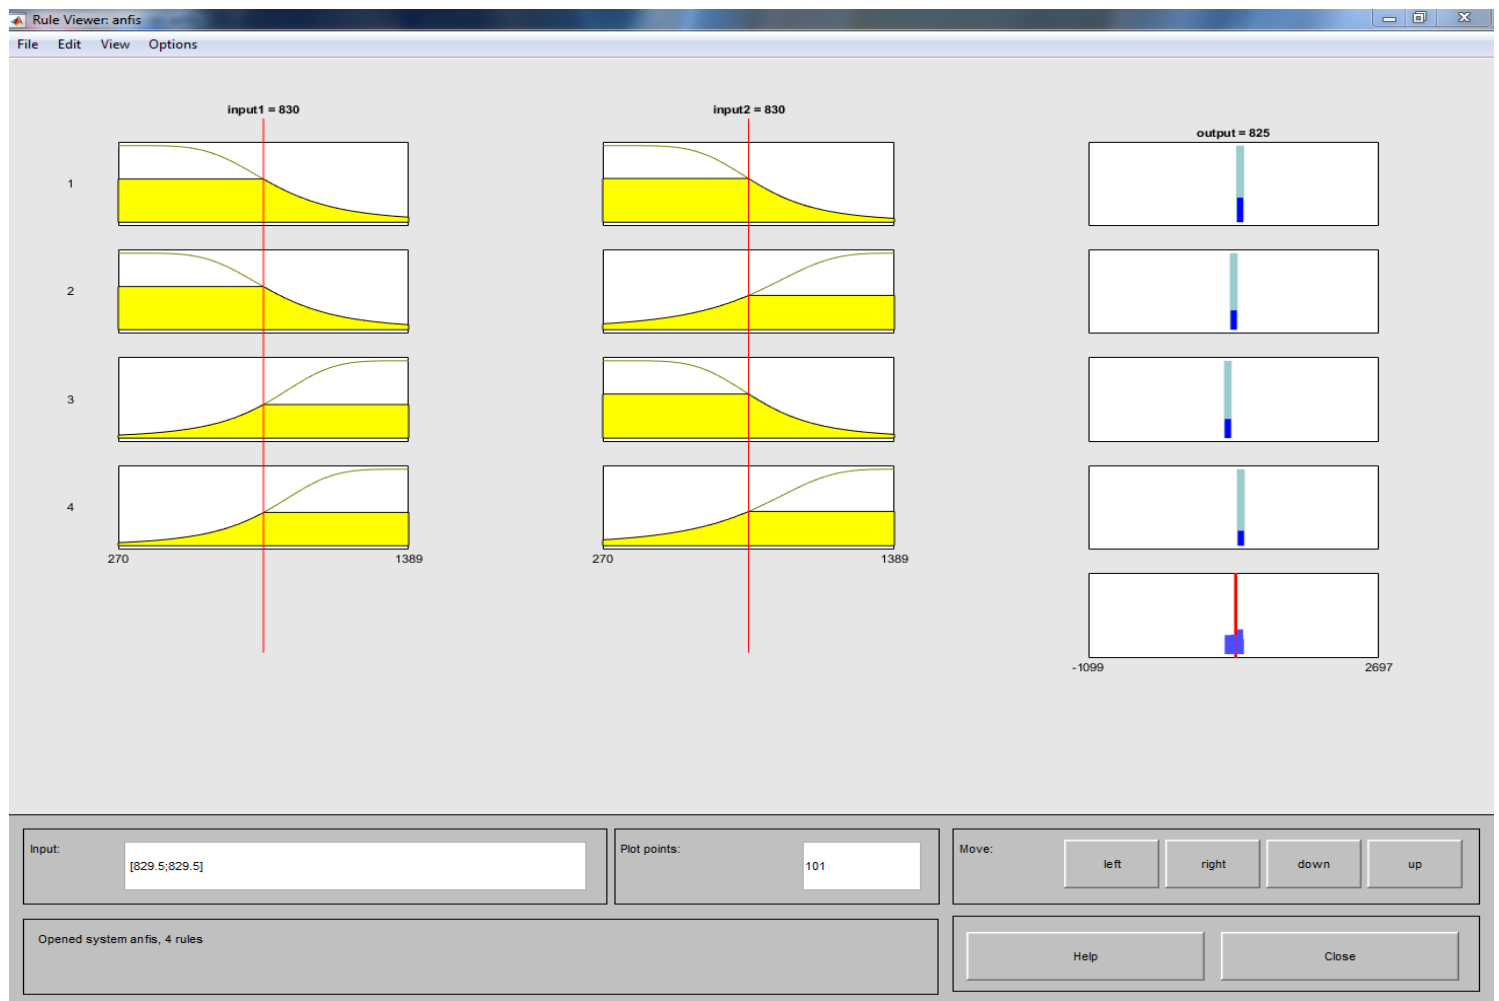
Αντίστοιχα στο δεξί άξονα παρουσιάζονται τα δεδομένα εκπαίδευσης όπου στον y άξονα απεικονίζονται τα output τα δεδομένα εξόδου k δηλαδή το αύριο, ενώ στον x άξονα παρουσιάζονται τα input (k-1) τα δεδομένα εισόδου δηλαδή το σήμερα.

Τα δεδομένα ελέγχου εκτείνονται για k-1 από 260 έως 740.

Επιπρόσθετα ,τα δεδομένα που κάνει έλεγχο το πρόγραμμα ANFIS είναι το 1/5 δηλαδή 135 .Εν κατακλείδι, όπως είχαμε προαναφερθεί και στην (εικόνα 34) παρατηρούμε στην περιοχή από 1100 έως 1400 και στην περιοχή 300 έως 400 αντίστοιχα, παρατηρείται διασπορά δεδομένων γεγονός που επηρεάζει εκείνη η περιοχή την ομαλότητα της μεθόδου όπως αποδεικνύεται και στην (εικόνα 33).

3.4.4 Αριθμητικό Παράδειγμα Μοντέλου

Στην παρούσα ενότητα παρουσιάζεται το αριθμητικό παράδειγμα του μοντέλου. Στην ακόλουθη εικόνα παρατηρούμε πως το μοντέλο ANFIS βρίσκει το αποτέλεσμα που προκύπτει για δυο τυχαίες τιμές t και $t-1$ αντίστοιχα:



Εικόνα 36: Υπολογισμοί του ANFIS

Όπως παρατηρούμε στο σχήμα αν $t = 830$ και $t-1 = 830$ τότε $t+1 = 825$. Στην συνέχεια παρουσιάζεται η ακόλουθη μεθοδολογία ώστε υποδειχθεί πως υπολογίζεται το αποτέλεσμα.

Στρώμα 1: Αρχικά χρησιμοποιήθηκε η τη συνάρτηση συμμετοχής Gaussian2 για να υπολογίσουμε το O_i^j για τον εκάστοτε κόμβο. Το σύνολο παραμέτρων παρουσιάζεται στον membership function editor και υπολογίζεται αυτόματα. Έτσι έχουμε:

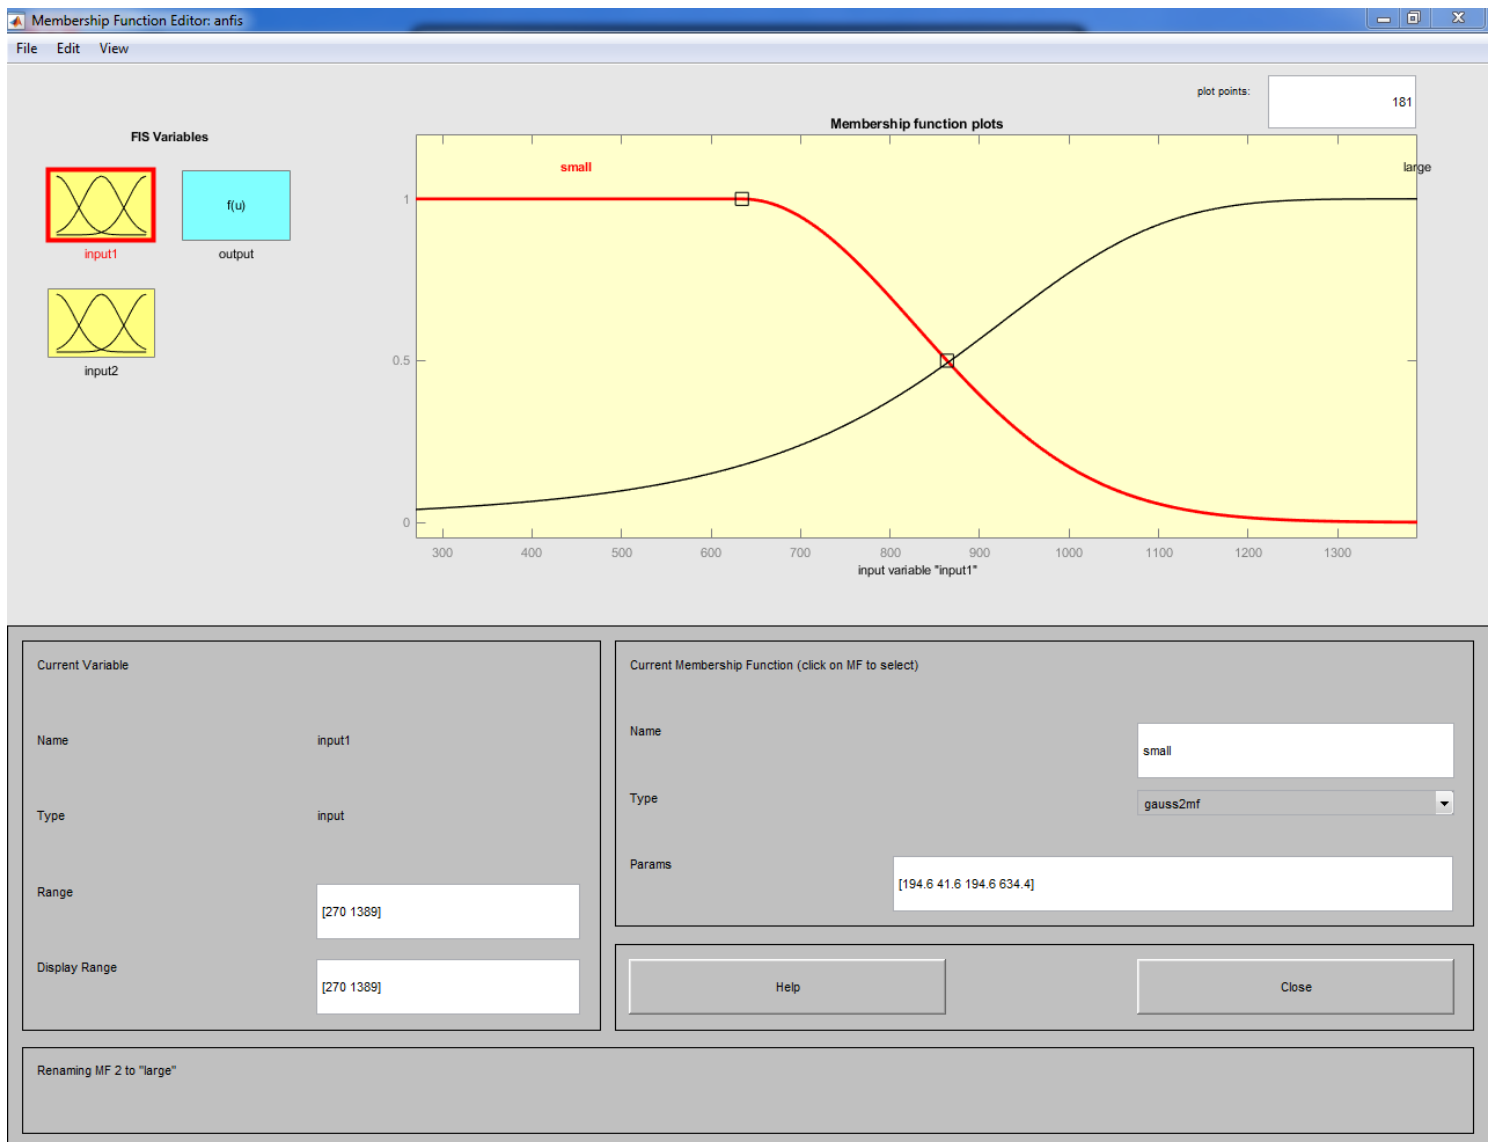
$$[a_1, c_1, a_2, c_2] = [194.6, 41.6, 194.6, 634.4]$$

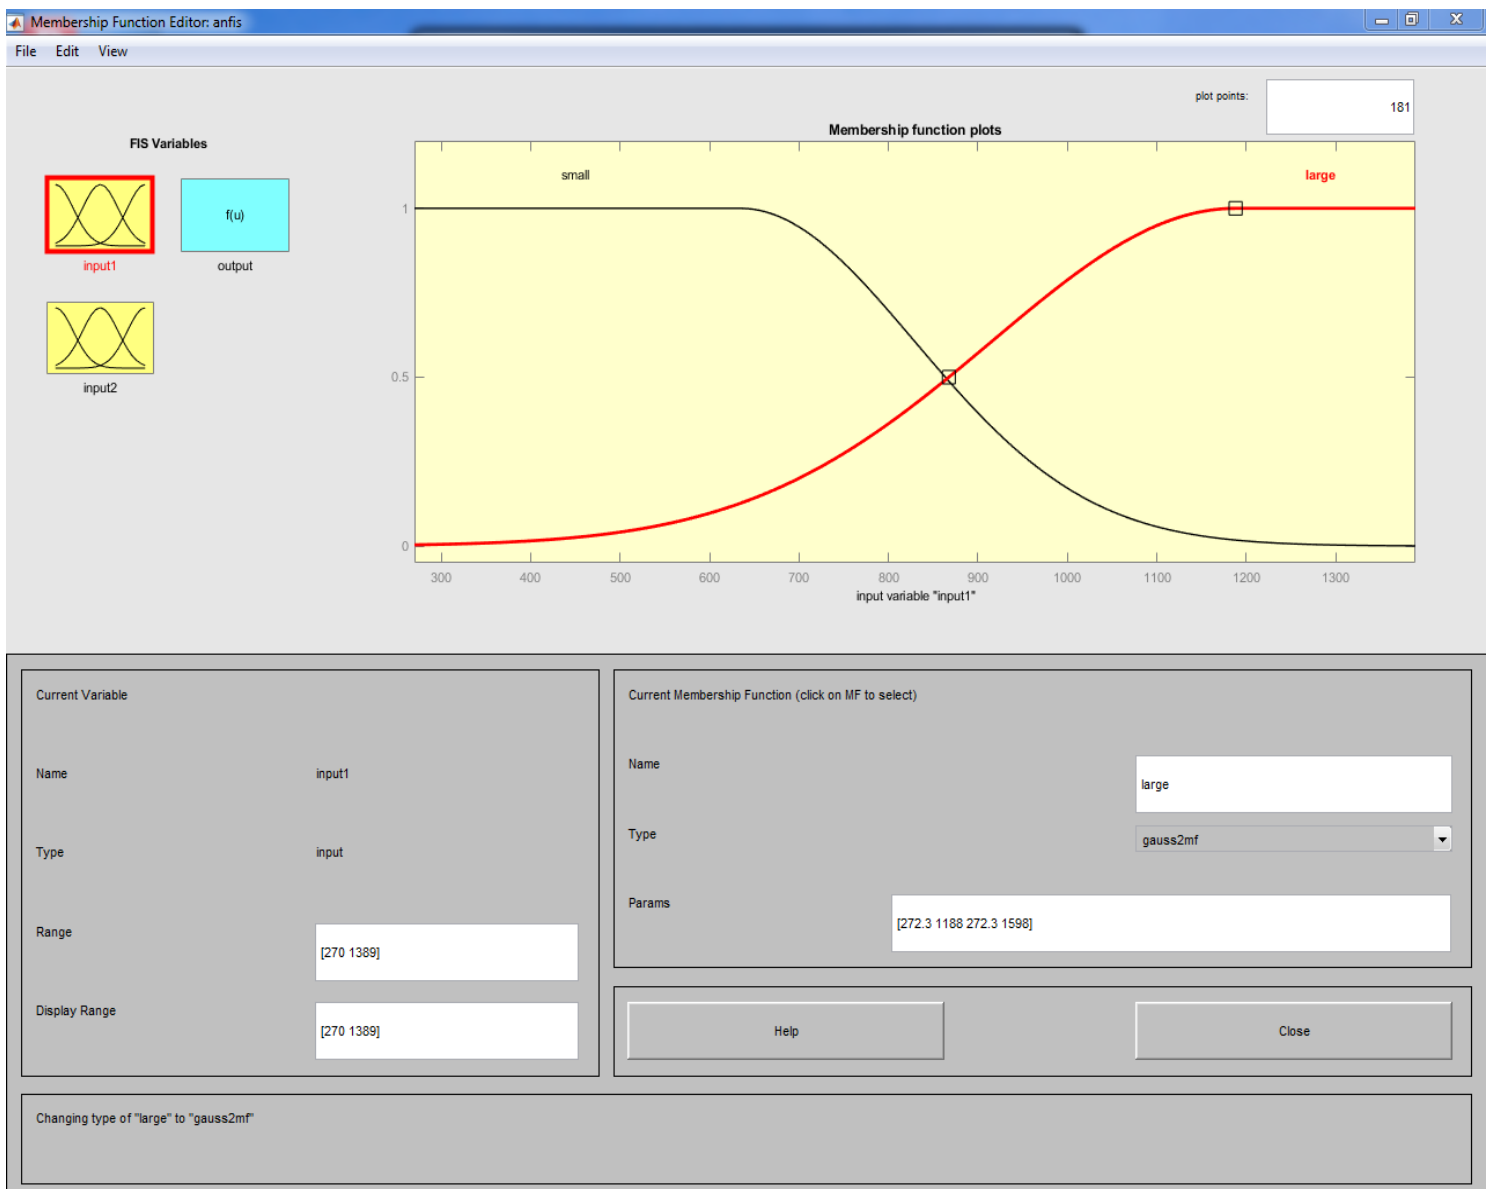
αν η γλωσσική μεταβλητή είναι small και

$$[a_1, c_1, a_2, c_2] = [272.3, 1188, 272.3, 1598]$$

αν η γλωσσική μεταβλητή είναι large

όπου a_1, c_1 είναι για την αριστερή καμπύλη της συνάρτησης Gaussian2 και a_2, c_2 είναι για την δεξιά καμπύλη, a είναι το πλάτος της καμπύλης και c το κέντρο της καμπύλης. Επιπρόσθετα, επειδή και οι δύο εισοδοί είναι ίδιου τύπου, το σύνολο παραμέτρων είναι το ίδιο και για τις δύο εισόδους.





Εικόνα 37: Membership Function Editor

Από την εικόνα 36 παρατηρούμε ότι τα $A1$ και $B1$ είναι **small** και στη **δεξιά** καμπύλη, ενώ τα $A2$ και $B2$ είναι **large** και στην **αριστερή** καμπύλη. Αυτό σημαίνει ότι για τα $A1$ και $B1$ θα χρησιμοποιήσουμε το σύνολο παραμέτρων [194.6, 41.6, 194.6, 634.4] και για τα $A2$ και $B2$ το σύνολο παραμέτρων [272.3, 1188, 272.3, 1598].

Τώρα χρησιμοποιώντας όλα αυτά και για $x = 830$ και $y = 830$ παίρνουμε:

$$\begin{aligned}O_1^1(x) &= \mu_{A_1}(x) \\O_2^1(x) &= \mu_{A_2}(x) \\O_3^1(x) &= \mu_{B_2}(y) \\O_4^1(x) &= \mu_{B_2}(y)\end{aligned}$$

Στρώμα 2: Εδώ κάνουμε τους υπολογισμούς χρησιμοποιώντας τις εξισώσεις που αναφέρθηκαν παραπάνω και έχουμε:

$$\begin{aligned}O_1^2 &= w_1 = \mu_{A_1}(x) * \mu_{B_1}(y) \\O_2^2 &= w_2 = \mu_{A_1}(x) * \mu_{B_2}(y) \\O_3^2 &= w_3 = \mu_{A_2}(x) * \mu_{B_1}(y) \\O_4^2 &= w_4 = \mu_{A_2}(x) * \mu_{B_2}(y)\end{aligned}$$

Στρώμα 3: Όπως και στο στρώμα 2 εδώ κάνουμε τους υπολογισμούς χρησιμοποιώντας την εξίσωση που αναφέρθηκε παραπάνω:

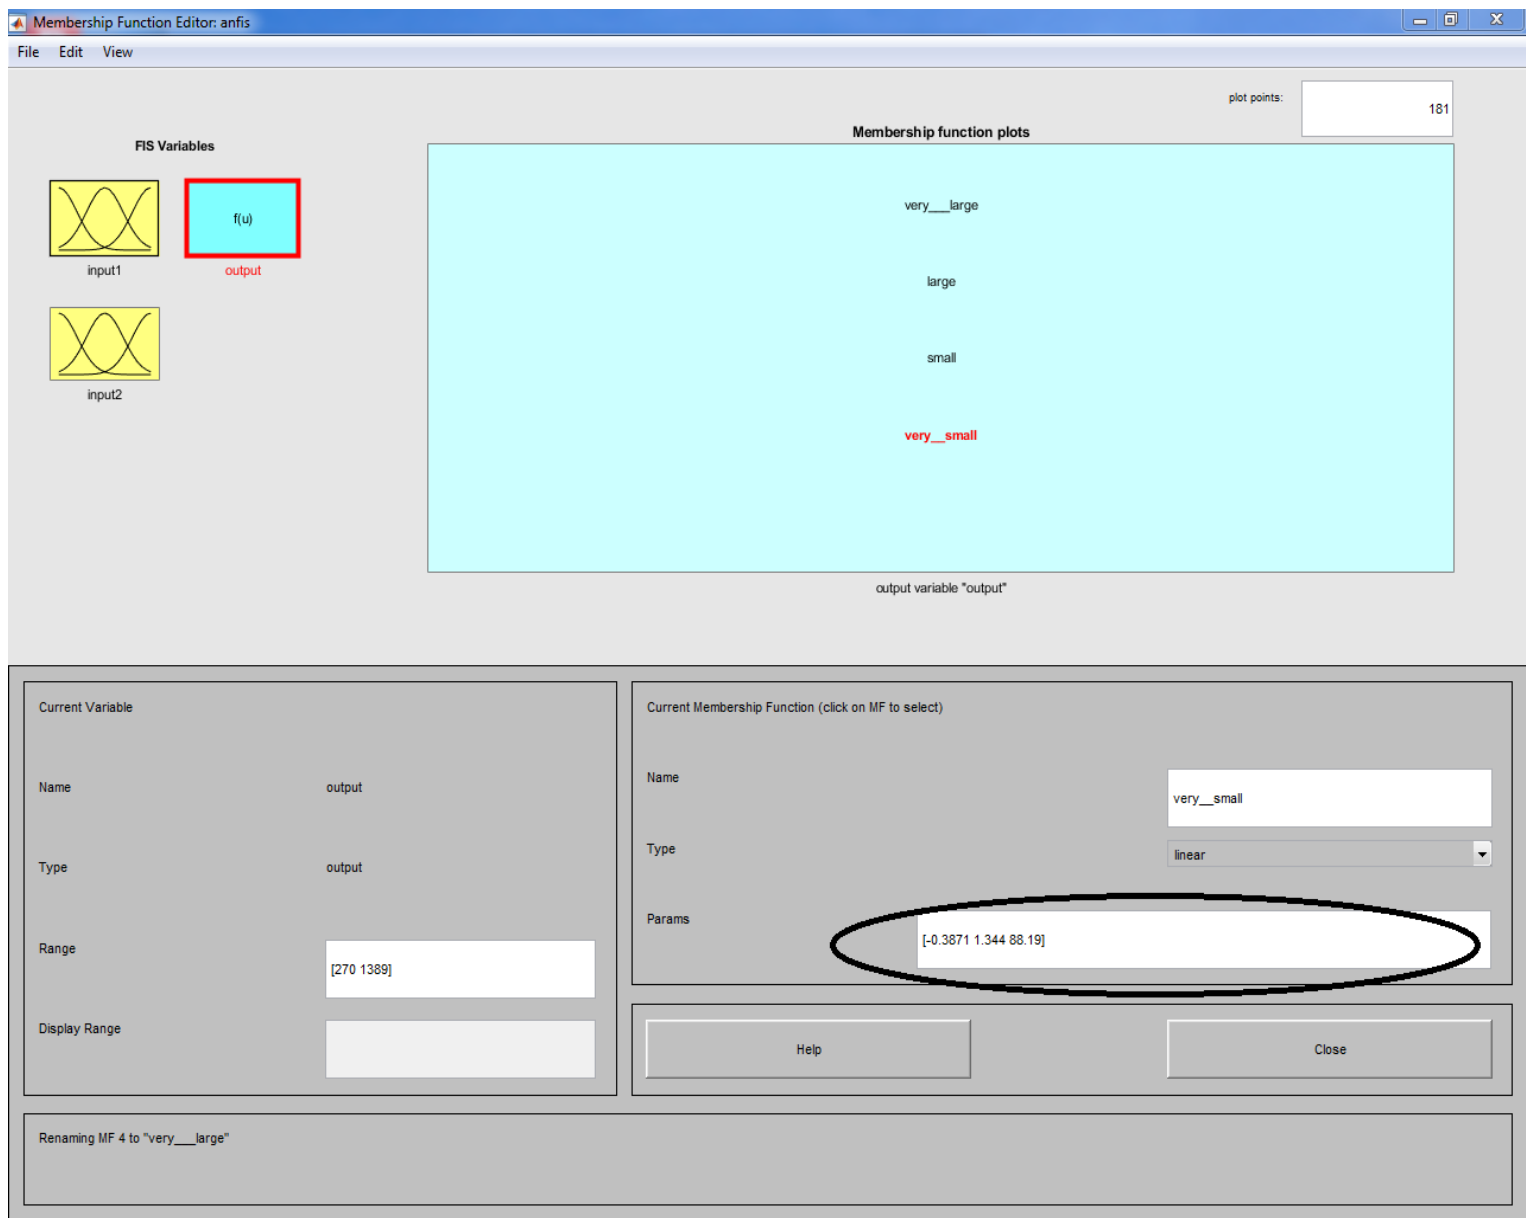
$$\begin{aligned}O_1^3 &= \bar{w}_1 = \frac{w_1}{w_1 + w_2 + w_3 + w_4} \\O_2^3 &= \bar{w}_2 = \frac{w_2}{w_1 + w_2 + w_3 + w_4} \\O_3^3 &= \bar{w}_3 = \frac{w_3}{w_1 + w_2 + w_3 + w_4} \\O_4^3 &= \bar{w}_4 = \frac{w_4}{w_1 + w_2 + w_3 + w_4}\end{aligned}$$

Στρώμα 4: Για να μπορέσουμε να πραγματοποιήσουμε τους απαραίτητους υπολογισμούς σε αυτό το επίπεδο χρειαζόμαστε το σύνολο παραμέτρων για κάθε κόμβο. Αυτές οι παράμετροι φαίνονται στον membership function editor επιλέγοντας t+1 και είναι:

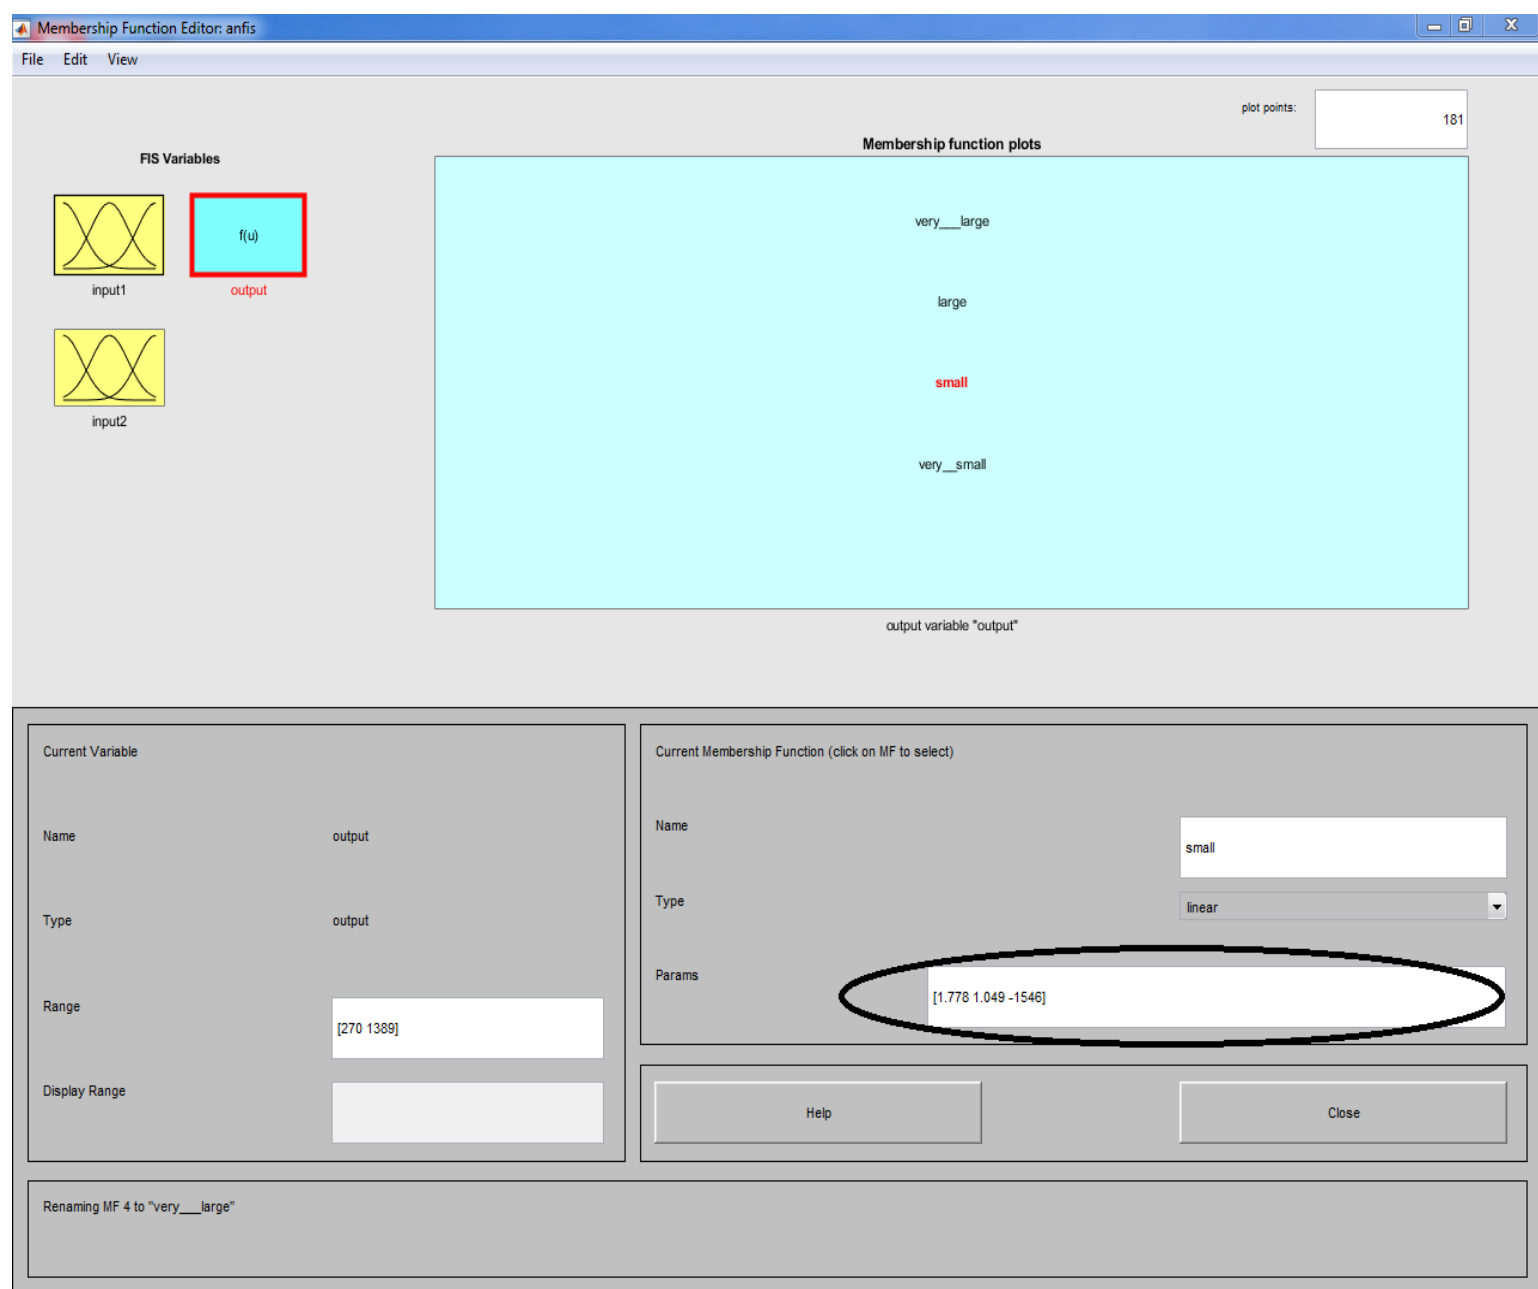
$$\begin{aligned}[p_1, q_1, r_1] &= [-0.3871, 1.344, 88.19] && \text{αν η γλωσσική μεταβλητή είναι very small} \\[p_2, q_2, r_2] &= [1.778, 1.049, -1546] && \text{αν η γλωσσική μεταβλητή είναι small} \\[p_3, q_3, r_3] &= [-0.3504, -0.03892, 1046] && \text{αν η γλωσσική μεταβλητή είναι large} \\[p_4, q_4, r_4] &= [0.5969, 0.1752, 251.6] && \text{αν η γλωσσική μεταβλητή είναι very large}\end{aligned}$$

Σημείωση

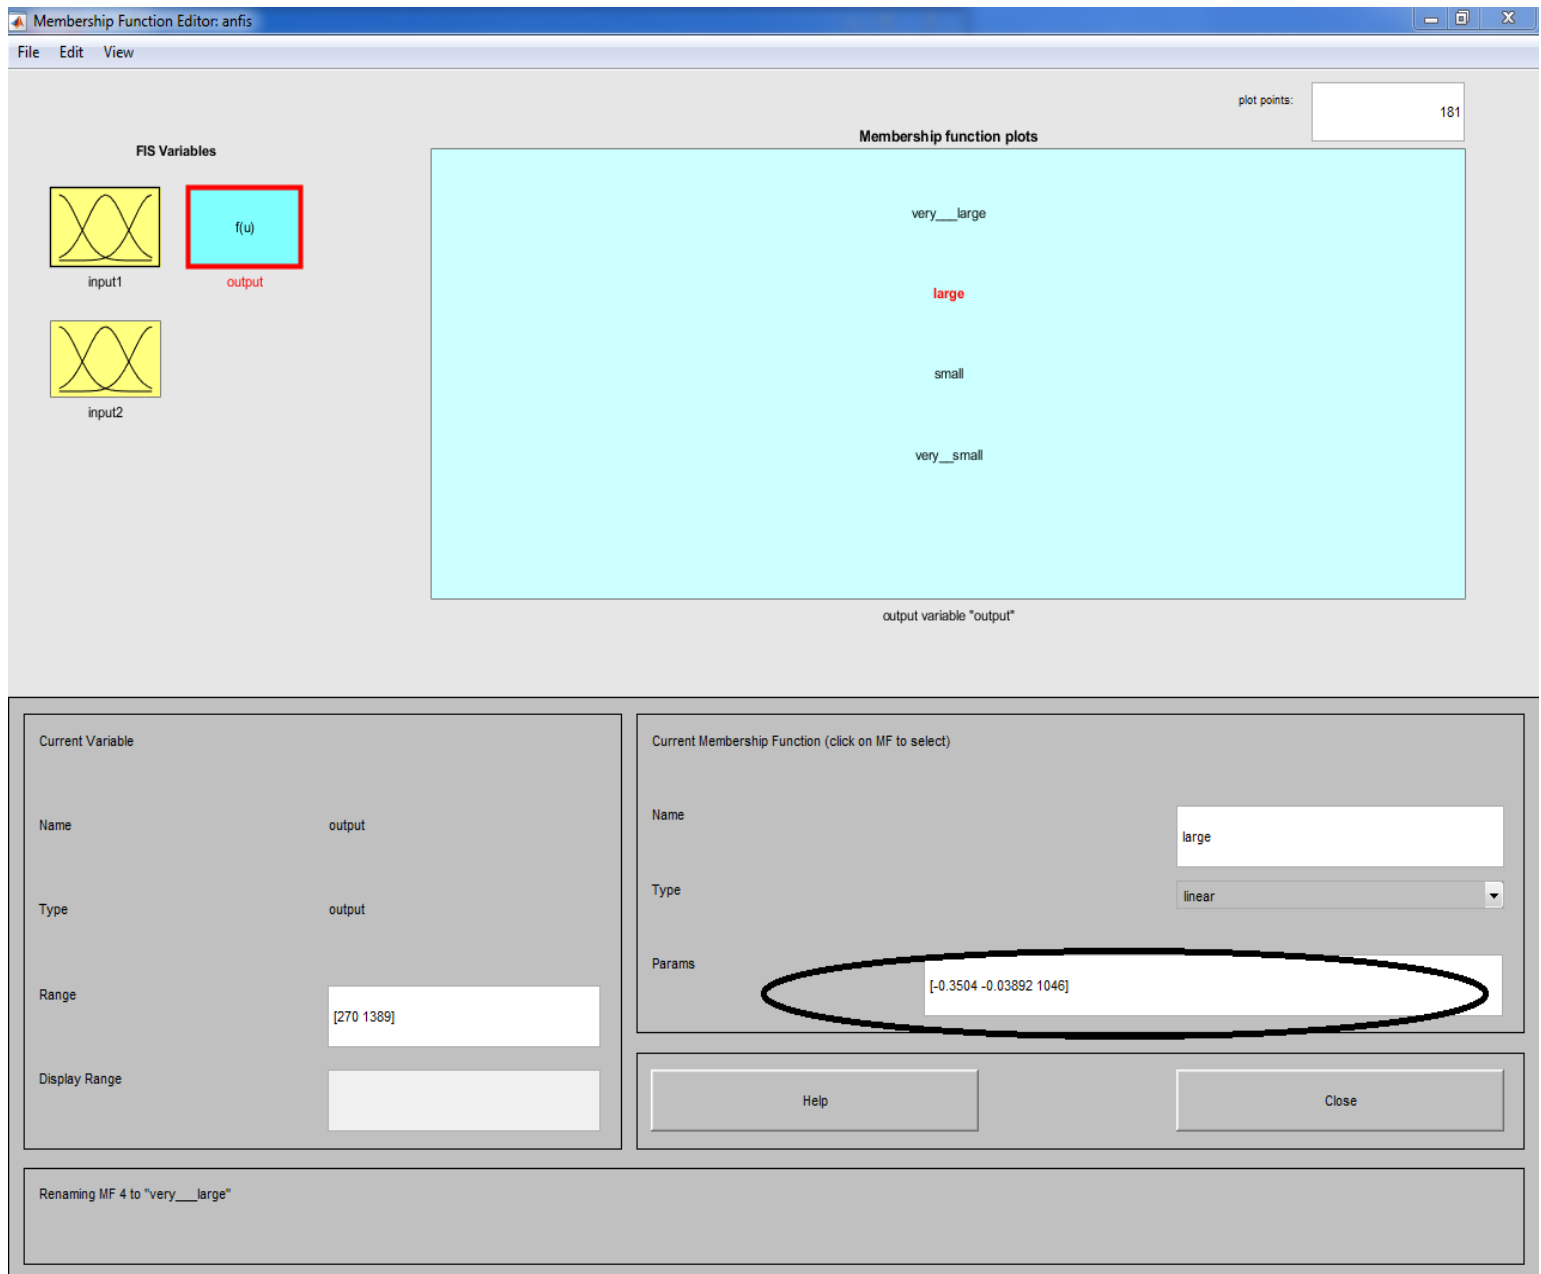
Στις ακόλουθες εικόνες(37,38,39,40) παρουσιάζονται οι γλωσσικές μεταβλητές ,το range και οι παράμετροι (οι παράμετροι έχουν σημειωθεί για την ευκολότερη εύρεση τους) που μας βοήθησαν για τον υπολογισμό των τεσσάρων κόμβων στην συνέχεια.



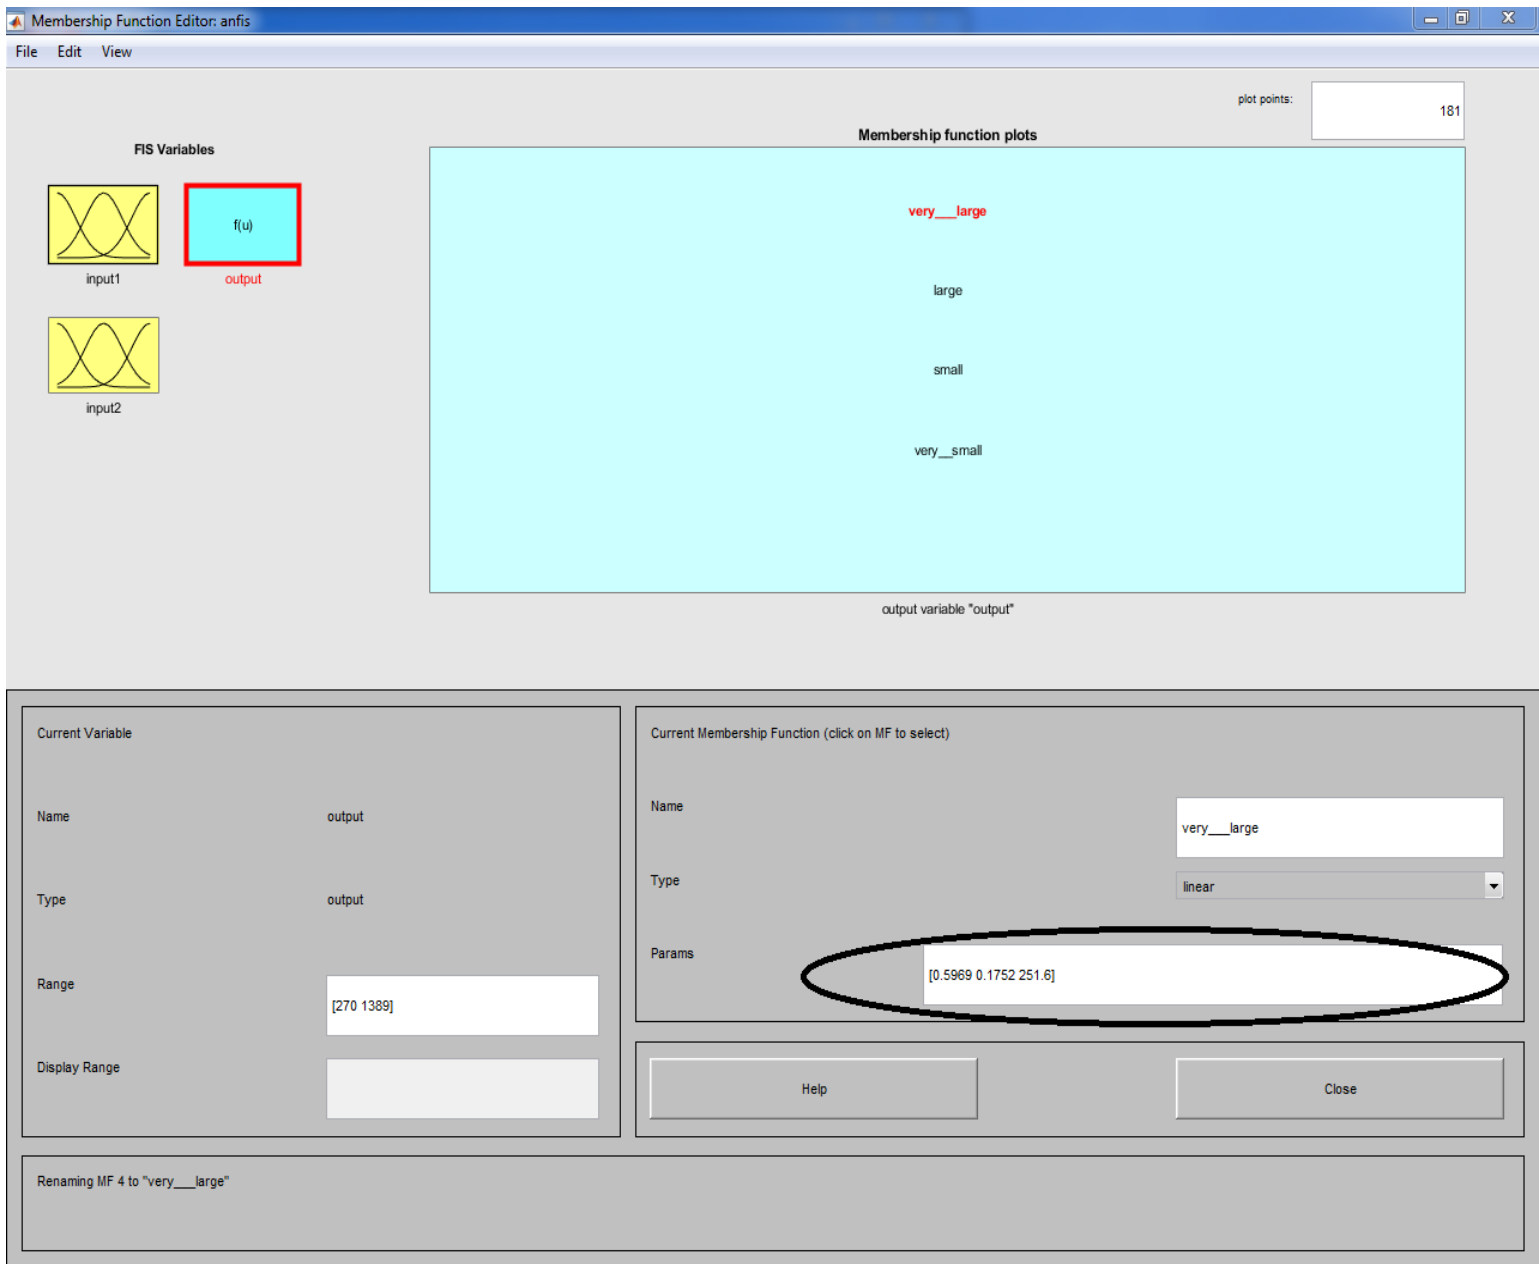
Εικόνα 38: Σύνολο παραμέτρων για very small



Εικόνα 39: Σύνολο παραμέτρων για small



Εικόνα 40: Σύνολο παραμέτρων για large



Εικόνα 41: Σύνολο παραμέτρων για very large

Χρησιμοποιώντας τα σύνολα παραμέτρων έχουμε :

$$\begin{aligned}O_1^4 &= \bar{w}_1 * (p_1 * x + q_1 * y + r_1) \\O_2^4 &= \bar{w}_2 * (p_2 * x + q_2 * y + r_2) \\O_3^4 &= \bar{w}_3 * (p_3 * x + q_3 * y + r_3) \\O_4^4 &= \bar{w}_4 * (p_4 * x + q_4 * y + r_4)\end{aligned}$$

Στρώμα 5: Στο τελευταίο στρώμα βρίσκουμε την τιμή για t+1 χρησιμοποιώντας την εξίσωση που αναφέρθηκε στη θεωρία:

$$O_i^5 = \sum_i \bar{w}_i * f_i = 825$$

4. ΜΕΛΕΤΗ ΠΕΡΙΠΤΩΣΗΣ (case study)

4.1 Εισαγωγή

Τα τελευταία χρόνια παρατηρούμε μεγάλη πρόοδο στον τομέα της πρόβλεψης πωλήσεων, με την βοήθεια πολύπλοκων αλγορίθμων πρόβλεψης, έχουν αναπτυχθεί μοντέλα που ακολουθούν τις μεθοδολογίες πρόβλεψης, ώστε να έχουμε την καλύτερη προσέγγιση του μοντέλου που μελετάμε.

Σήμερα είμαστε σε θέση να κάνουμε προβλέψεις ακινήτων για τους επομένους μήνες ή και χρόνια. Αξιολογώντας τις πιθανότητες σφάλματος ώστε η λήψη της απόφασης να είναι έγκυρη και επιτυχημένη, για κάθε επένδυση με όσο δυνατόν μικρότερο σφάλμα ώστε να ελαχιστοποιήσουμε τον κίνδυνο. Όπως έχουμε προαναφέρει και στα προηγούμενα κεφάλαια, οι προβλέψεις θεωρούνται αναγκαίο εργαλείο για την λήψη μιας ορθής απόφασης και την χάραξη της πολιτικής πωλήσεων. Επιπρόσθετα στα πλαίσια της πρόβλεψης ακινήτων, με την βοήθεια της MATLAB επιχειρούμε να εφαρμόσουμε το μοντέλο ANFIS(Adaptive Neuro-Fuzzy Inference System) στις μηνιαίες πωλήσεις ακινήτων στις Ηνωμένες Πολιτείες Αμερικής. Μελετάμε για κάθε μήνα το ποσοστό σφάλματος, αλλάζοντας τις παραμέτρους του μοντέλου μας σε (epoch=5,10,100,250,500,1000,5000 και 10.000).

Εν κατακλείδι, εξετάζουμε την συμπεριφορά και την αποτελεσματικότητα τους, σχολιάζουμε και καταγράφουμε τα αποτελέσματα των προβλέψεων

4.2 Επεξεργασία

Τα δεδομένα της μελέτης αντλήθηκαν από το site (Μέσες τιμές σπιτιών στην Αμερική): <https://fred.stlouisfed.org/series/HSN1F> και την πηγή (monthly sales new one family houses in the usa since 1973) <https://fred.stlouisfed.org/series/HSN1F>. Οι οποίες περιέχουν ένα μεγάλο όγκο στατιστικών δεδομένων, όσων αφορά τα στατιστικά στοιχεία πωλήσεων ακινήτων στις Ηνωμένες Πολιτείες Αμερικής.

Τα δεδομένα των πωλήσεων που έχουν συλλεχθεί και καταγραφεί, αφορούν τις μηνιαίες πωλήσεις από την χρονική περίοδο 01 Ιανουαρίου 1963 μέχρι 01 Δεκεμβρίου 2019 και πρόκειται για 684 καταγεγραμμένες μετρήσεις.

Η συλλογή και η αποθήκευση των δεδομένων έγιναν σε φύλλο excel ώστε να γίνει ευκολότερη η επεξεργασία από το μοντέλο ANFIS που προγραμματίστηκε μέσω του προγράμματος της matlab και στην συνέχεια αντλήσαμε τα αποτελέσματα μας.

Τέλος, ακολουθεί ο πίνακας με τις πρώτες 36 μετρήσεις συγκεντρωτικά.

(ΠΙΝΑΚΑΣ 4.2.1)

ΠΙΝΑΚΑΣ

Observation Date	New One Family Houses Sold: United States, Thousands, Monthly, Seasonally Adjusted Annual Rate
1963-Ιανουάριος-01	591
1963-Φεβρουάριος-01	464
1963-Μάρτιος-01	461
1963-Απρίλιος-01	605
1963-Μάιος-01	586
1963-Ιούνιος-01	526
1963-Ιούλιος-01	665
1963-Αύγουστος-01	570
1963-Σεπτέμβριος-01	590
1963-Οκτώβριος-01	567
1963-Νοέμβριος-01	579
1963-Δεκέμβριος-01	514
1964-Ιανουάριος-01	549
1964-Φεβρουάριος-01	609
1964-Μάρτιος-01	562
1964-Απρίλιος-01	559
1964-Μάιος-01	523
1964-Ιούνιος-01	580
1964-Ιούλιος-01	575
1964-Αύγουστος-01	582
1964-Σεπτέμβριος-01	590
1964-Οκτώβριος-01	583
1964-Νοέμβριος-01	548
1964-Δεκέμβριος-01	540
1965-Ιανουάριος-01	533
1965-Φεβρουάριος-01	559
1965-Μάρτιος-01	556
1965-Απρίλιος-01	555
1965-Μάιος-01	544
1965-Ιούνιος-01	614
1965-Ιούλιος-01	554
1965-Αύγουστος-01	615
1965-Σεπτέμβριος-01	587
1965-Οκτώβριος-01	555
1965-Νοέμβριος-01	616
1965-Δεκέμβριος-01	609
1966-Ιανουάριος-01	599
1966-Φεβρουάριος-01	541
1966-Μάρτιος-01	557
1966-Απρίλιος-01	545

4.3 Διαδικασία

Αρχικά αφού προγραμματίσαμε τον κώδικα στην matlab,εισήγαμε το φύλλο excel 'Housedata' ώστε να παίρνει τα δεδομένα από τον πίνακα του excel, στην συνέχεια τρέξαμε τον κώδικα ώστε να αποκομίσουμε τα αποτελέσματα της πρόβλεψης πωλήσεων κατοικιών.

Οι παράμετροι που μετατρέπαμε ώστε να βρούμε την βέλτιστη πρόβλεψη με το μικρότερο RMSE(σφάλμα δηλαδή το μικρότερο σφάλμα είναι :

- n =βήμα (χωρίζει τα δεδομένα εκπαίδευσης και τα δεδομένα αξιολόγησης) _
- epoch=εποχές (αύξηση των αριθμών των εποχών και μας υποδεικνύει τον αριθμό των επαναλήψεων).
- ss=step size ή μέγεθος δείγματος (το μέγεθος δείγματος το κρατήσαμε σταθερό).

Και η συνάρτηση συμμετοχής γενικευμένης καμαροειδής (gbellmf).

Επιπρόσθετα, αφού εκτελέσαμε το πρόγραμμα με τις ρυθμίσεις που έχουμε προαναφέρει, αποθηκεύσαμε τα αποτελέσματα σε ένα πίνακα word και επαναλάβουμε την διαδικασία για (5,10,100,250,500,1.000,5.000,10.000) εποχές αντίστοιχα ,κρατώντας ως συνάρτηση συμμετοχής το (gbellmf). Ανακεφαλαιώνοντας τρέξαμε πάλι τις αντίστοιχες εποχές χρησιμοποιώντας ,όλες τις διαθέσιμες συναρτήσεις συμμετοχής gaussmf, gauss2mf (γκουσσισιανή συνάρτηση συμμετοχής),trimf (συνάρτηση τριγωνικής μορφής), smf (σιγμοειδής συνάρτηση συμμετοχής), trapmf (τραπεζοειδής συνάρτηση συμμετοχής),zmf (συνάρτηση συμμετοχής σχήματος Z) και pimmf(συνάρτηση συμμετοχής σχήματος Π).

Παρατηρήσαμε ότι κάθε φορά που τρέχαμε τις συναρτήσεις συμμετοχής smf και zmf μας έβγαζε ο κώδικας error. Επιπρόσθετα, διαπιστώσαμε ότι όσο μεγάλωνα τις εποχές epoch τα σφάλματα σταθεροποιούνταν μέχρι που έφταναν στο σημείο που παρέμεναν σταθερά (συνήθως για epoch 5.000 και 10.000 αντίστοιχα).Στην συνέχεια, τρέξαμε τις συναρτήσεις συμμετοχής για mf_n=2,3,4,5,6 και κρατήσαμε το μικρότερο RMSE απ' όλες τις προβλέψεις που είναι και το βέλτιστο.

Τέλος, εξετάστηκαν τα μοντέλα πρόβλεψης και καταλήξαμε ότι το μοντέλο με το μικρότερο σφάλμα μας το έδωσε η συνάρτηση συμμετοχής pimmf (συνάρτηση συμμετοχής σχήματος Π) με epoch=5, mf_n=2 και ss=0.1 ,αντίστοιχα και το μικρότερο RMSE παρατηρείται στο gbellmf με τις αντίστοιχες ρυθμίσεις.

Εν συνεχεία ,παρουσιάζονται τα σημαντικότερα γραφήματα που προκύπτουν από το πρόγραμμα της MATLAB ,που έχουν ως στόχο την κατανόηση του τρόπου λειτουργίας του ANFIS.


Ο ακόλουθος πίνακας μας δίνει χρήσιμες πληροφορίες σχετικά με τον ANFIS κατά την επεξεργασία πωλήσεων κατοικιών που έχουν μελετηθεί :

ΠΙΝΑΚΑΣ 4.3.1

Χρήσιμες Πληροφορίες του ANFIS

Name (Όνομα)	ANFIS
Type (Τύπος ασαφούς μηχανισμού συμπερασμού)	Sugeno
Number of nodes (Αριθμός κόμβων)	21
Number of linear parameters (Αριθμός γραμμικών παραμέτρων)	12
Number of nonlinear parameters (Αριθμός μη-γραμμικών παραμέτρων)	12
Total number of parameters (Συνολικός αριθμός παραμέτρων)	24
Number of training data pairs (Αριθμός εκπαιδευόμενων ζευγαριών δεδομένων)	545
Number of checking data pairs (Αριθμός ελεγχόμενων ζευγαριών δεδομένων)	135
Number of fuzzy rules (Αριθμός ασαφών κανόνων)	4
NumInputs (Αριθμός εισόδων)	2
NumOutputs (Αριθμός εξόδων)	1

Στο σχήμα που ακολουθεί, παρουσιάζονται οι καμπύλες σφάλματος και μεγέθους βήματος:




Εικόνα 42: Σφάλμα εκπαίδευσης ελέγχου και μέγεθος βήματος

Παρατήρηση

Όπως παρατηρούμε στην (εικόνα 42), παρουσιάζεται στο πάνω διάγραμμα οι καμπύλες σφάλματος ενώ στο κάτω το μέγεθος βήματος. Όσον αφορά τις καμπύλες σφάλματος διακρίνουμε δυο διάγραμμα που είναι αλληλένδετα μεταξύ τους με την μπλε γραμμή παρουσιάζονται τα σφάλματα εκπαίδευσης ενώ με την πορτοκαλί τα σφάλματα ελέγχου. Παρατηρούμε ότι η συνάρτηση συμμετοχής για gbellmf για membership function=2 και step size=0.1, συμπεραίνουμε ότι τα σφάλματα εκπαίδευση παραμένουν σταθερά χωρίς κάποια αύξηση ή πτώση όσο περνάνε οι εποχές στο 46,8 περίπου. Αντίστοιχα για τα σφάλματα ελέγχου παρατηρείται μια απότομη αύξηση συναρτησή με τα epoch περίπου στο 37.8 για epoch=5, στην συνέχεια καθώς το epoch=10 παρατηρείται μια στιγμιαία πτώση στο 37.6. Τέλος παρατηρείται μια σταδιακή αύξηση οπού για epoch=10.000 καταλήγει στο 38.2 και μια σταθερότητα στα σφάλματα ελέγχου.


Στον δεύτερο διάγραμμα απεικονίζεται το μέγεθος βήματος παρατηρείται ότι για epoch =0 παρουσιάζεται ένα ολικό μέγιστο μεγέθους 0.148, στην συνέχεια για epoch=5 παρατηρείται μια απότομη πτώση στο 0.22. Επίσης καθώς τρέχουν τα epoch παρατηρούνται τοπικά μέγιστα και ελάχιστα που συνολικά έχουν πτωτική τάση. Καθώς

προχωράνε τα epoch παρατηρείται μια συνολική πτώση αλλά τα τοπικά μέγιστα και ελάχιστα παρουσιάζουν μεγαλύτερο εύρος περιόδου γεγονός που καταλήγουμε για epoch=10.000 να είναι περίπου ευθεία. Αυτό μας φέρνει στο συμπέρασμα ότι για epoch περίπου 9.000 και μετά το μέγεθος βήματος τείνει να σταθεροποιηθεί.



System anfis: 2 inputs, 1 outputs, 4 rules

Εικόνα 43: Δομή μοντέλου ANFIS με input αρχικής συνάρτησης συμμετοχής



System anfis: 2 inputs, 1 outputs, 4 rules


Εικόνα 44: Δομή μοντέλου ANFIS με input τελικής συνάρτησης συμμετοχής

Παρατήρηση

Στις (εικόνες 44, 45) παρουσιάζεται η δομή του μοντέλου ANFIS το οποίο χρησιμοποιήθηκε για την εκτέλεση των προβλέψεων. Η είσοδος του μοντέλου γίνεται από αριστερά προς τα δεξιά με τις συναρτήσεις συμμετοχής, επίσης απεικονίζεται ο μηχανισμός εξαγωγής συμπεράσματος τύπου Sugeno με δυο κανόνες και τέλος παρουσιάζεται η έξοδος του συστήματος.

Επιπρόσθετα στην (εικόνα 43) παρουσιάζονται τα δυο input των αρχικών συναρτήσεων συμμετοχής, ενώ αντίστοιχα η (εικόνα 44) εισάγει τα δυο input των τελικών συναρτήσεων συμμετοχής.

Στην συνέχεια, παρατίθενται οι αρχικές συναρτήσεις συμμετοχής οι οποίες είναι καμπανοειδείς:



Εικόνα 45: Αρχικές συναρτήσεις συμμετοχής για την gbellmf


Παρατήρηση

Στην (εικόνα 43) παρουσιάζονται οι αρχικές συναρτήσεις συμμετοχής για την gbellmf, όπως είχαμε προαναφερθεί οι συναρτήσεις συμμετοχής είναι καμπανοειδούς μορφής. Στο πρώτο διάγραμμα ο y άξονας εκφράζει το(Degree of Membership) δηλαδή τον βαθμό συμμετοχής που είναι από το 0 μέχρι το 1 και ο x άξονας το input1 δηλαδή το σήμερα.

Αντίστοιχα στο δεύτερο διάγραμμα ο y άξονας παρουσιάζει το (Degree of membership) δηλαδή τον βαθμό συμμετοχής ενώ ο x άξονας το input 2 δηλαδή το χθες. Όπως έχουμε προαναφερθεί έχουν παραχθεί δυο συναρτήσεις συμμετοχής για κάθε είσοδο.

Τέλος παρατηρούμε ότι και τα δυο διαγράμματα παρουσιάζουν ταυτόσημες καμπύλες με την ίδια χρονική καθυστέρηση γεγονός που μας παρουσιάζει τα δεδομένα που θα συλλέξουμε είναι πολύ καλά.

Κατ' εξακολούθηση ακολουθούν οι τελικές συναρτήσεις συμμετοχής οι οποίες είναι καμπανοειδείς:





Εικόνα 46: Τελικές συναρτήσεις συμμετοχής για την *gbellmf*

Παρατήρηση

Εν συνεχεία στην (εικόνα 44) παρουσιάζονται οι τελικές συναρτήσεις συμμετοχής που προέκυψαν μετά την εκπαίδευση του μοντέλου όπως είχαμε προαναφερθεί.

Παρατηρούμε ότι το πρώτο διάγραμμα έχει μια μικρή μετατόπιση σε σχέση με την αρχική συνάρτηση συμμετοχής (εικόνα 45), δηλαδή μια μετακίνηση προς τα δεξιά.



Αντίστοιχα στο δεύτερο διάγραμμα παρατηρείται μια μικρή μετακίνηση των συναρτήσεων συμμετοχής προς τα δεξιά σε σχέση με το αρχικό διάγραμμα συμμετοχής. Επίσης τα αποτελέσματα μας υποδεικνύουν μια καθυστέρηση στην λειτουργία της δεύτερης συνάρτησης συμμετοχής η οποία επιβεβαιώνει την φυσιολογική κατανόηση της .



Εικόνα 47: Γράφημα διασποράς των δεδομένων εκπαίδευσης

Παρατήρηση

Στα δυο απεικονιζόμενα διαγράμματα παρουσιάζονται τα γραφήματα διασποράς των δεδομένων εκπαίδευσης. Εν συνεχεία, τα δεδομένα εκπαίδευσης εκτείνονται για $k-2$ (όπου το $k-2$ υποδηλώνει δεδομένα του χθες) από 350 έως 1400, για $k-1$ (το $k-1$ υποδηλώνει τα δεδομένα του σήμερα) από 350 έως 1400. Η θεωρία και η επεξήγηση έχει προαναφερθεί στην σελίδα 71 στην (Εικόνα 34).




Εικόνα 48: Γράφημα διασποράς των δεδομένων ελέγχου

Παρατήρηση

Στην (εικόνα 48) παρουσιάζονται τα γραφήματα διασποράς των δεδομένων ελέγχου. Επίσης τα δεδομένα ελέγχου διευρύνονται για $k-2$ από 260 έως 740 και για $k-1$ από 260 έως 740. Η θεωρία και η επεξήγηση έχει προαναφερθεί στην σελίδα 72 στην (Εικόνα 35).

Τέλος, το τελευταίο γράφημα παρουσιάζει συνολικά τη διακύμανση της λάθους πρόβλεψης του μοντέλου μας.



Εικόνα 49: Γράφημα λάθους πρόβλεψης

Παρατήρηση

Στην (εικόνα 49) παρουσιάζεται το γράφημα λάθους πρόβλεψης. Το γράφημα μας απεικονίζει στον y άξονα τα errors δηλαδή τις τιμές των σφαλμάτων και έχει εύρος από (-50 έως 100). Επίσης, στον άξονα x μας παρουσιάζει τον χρόνο (time) που έχει εύρος (0 έως 700). Αξίζει να σημειωθεί ότι παρουσιάζονται τοπικά μέγιστα και ελάχιστα σε όλο τον άξονα (x,y). Επιπλέον παρουσιάζεται ολικό ελάχιστο σε χρόνο 505 με σφάλμα -20 ,αντίθετα παρουσιάζεται ολικό μέγιστο σε χρόνο 530 με 85 τιμή σφάλματος.

Εν κατακλείδι, από την διαφορά των πραγματικών τιμών και τιμών πρόβλεψης μοντέλου δημιουργείται το σφάλμα πρόβλεψης. Είναι σαφής η πολύ καλή επίδοση του μοντέλου ANFIS για την πρόβλεψη των μελλοντικών πωλήσεων ακινήτων στις Ηνωμένες Πολιτείες Αμερικής σε σχέση με τις πραγματικές τιμές.

4.4 Αποτελέσματα

Αφού επαναλήφθηκε η μέθοδος για epoch (5,10,100,250,500,1.000,5.000,10.000) αντίστοιχα, δοκιμάστηκαν διαφορετικοί παράμετροι ώστε να βρεθεί το μικρότερο RMSE (Root Mean Square Error).Αξίζει να σημειωθεί ότι τα αποτελέσματα που συλλέχθηκαν από το ANFIS(Adaptive Neural Fuzzy Inference System) συγκεντρώθηκαν σε ένα συγκεντρωτικό πίνακα ώστε να εξετασθούν. Επιπρόσθετα ,ο RMSE είναι ο δείκτης που καταγραφεί πόσο αποτελεσματικό είναι το μοντέλο μας, δηλαδή πόσο επιτυχημένη είναι η πρόβλεψη μας. Εν συνεχεία ,ακολουθεί ο μαθηματικός τύπος του RMSE:

$$RMSE = \sqrt{\frac{\sum_{t=1}^N e_t^2}{N}}$$

Επιπρόσθετα, παρατίθενται τα εξαγόμενα αποτελέσματα για την εκάστοτε περίπτωση που δοκιμάσαμε:

ΠΙΝΑΚΑΣ 4.4.1

Παρουσίαση RMSE (Root Mean Square Error) ανά Συνάρτηση Συμμετοχής

Συνάρτηση Συμμετοχής	mf_n=2, ss=0.1							
	Epoch=5	Epoch=10	Epoch=100	Epoch=250	Epoch=500	Epoch=1000	Epoch=5000	Epoch=10.000
	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE
gbellmf	13,2565	13,9251	15,0715	15,1009	15,1423	15,2158	15,5036	15,7090
trimf	669,3065	268,3747	113,4182	111,7034	152,6385	151,9670	151,9460	151,9460
gauss2mf	13,0478	13,0534	13,5513	15,3593	15,3872	15,4046	15,4939	15,4939
gaussmf	14,1888	14,2001	14,9017	14,9525	15,0802	15,6810	17,3704	19,9893
smf	error	error	error	error	error	error	error	error
trapmf	13,0426	13,0565	13,5448	13,5804	13,5803	13,5803	13,5803	13,5803
zmf	error	error	error	error	error	error	error	error
pimf	12,6346	12,6387	13,0163	14,4945	14,7151	14,8657	14,9624	14,9897

Συνάρτηση Συμμετοχής	mf_n=3, ss=0.1							
	Epoch= 5	Epoch= 10	Epoch= 100	Epoch= 250	Epoch= 500	Epoch= 1000	Epoch= 5000	Epoch= 10.000
	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE
gbellmf	18,0328	17,6347	17,3662	17,3186	16,9617	16,9540	17,5269	17,6233
trimf	226,7455	105,2586	114,8750	173,0368	269,4147	392,6324	426,1960	426,1960
gauss2mf	17,5502	17,5608	17,5358	19,5389	19,3229	19,3024	19,2060	19,2060
gaussmf	21,0933	21,0958	19,7985	17,9911	18,6253	18,8005	18,8005	18,8005
smf	error	error	error	error	error	error	error	error
trapmf	16,5149	16,5299	17,6255	17,8654	17,9579	17,9591	17,9592	17,9592
zmf	error	error	error	error	error	error	error	error
pimf	16,2268	16,2326	16,7576	20,0221	20,0832	20,1604	20,2686	20,2781

Συνάρτηση Συμμετοχής	mf_n=4, ss=0.1							
	Epoch= 5	Epoch= 10	Epoch= 100	Epoch= 250	Epoch= 500	Epoch= 1000	Epoch= 5000	Epoch= 10.000
	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE
gbellmf	18,3292	19,4664	23,1886	23,7431	25,3797	25,1450	24,7703	24,7703
trimf	430,5044	404,8349	549,6383	575,7798	602,4460	644,9048	796,6828	796,6585
gauss2mf	18,0495	18,0713	19,0762	20,3078	20,3078	20,3078	20,3078	20,3078
gaussmf	18,5449	18,5399	18,5506	19,4297	19,3290	19,2455	19,2121	19,2121
smf	error	error	error	error	error	error	error	error
trapmf	17,7107	17,7260	18,3505	18,2937	18,5212	18,5232	18,5233	18,5233
zmf	error	error	error	error	error	error	error	error
pimf	17,4136	17,4223	17,8097	20,8147	21,5343	21,9832	21,9894	21,9894

Συνάρτηση Συμμετοχής	mf_n=5, ss=0.1							
	Epoch=5	Epoch=10	Epoch=100	Epoch=250	Epoch=500	Epoch=1000	Epoch=5000	Epoch=10.000
	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE
gbellmf	23,8769	24,8803	23,8470	23,3384	23,0155	22,8802	22,8992	22,8992
trimf	442,2185	346,5906	352,9024	559,5294	861,1972	1.0997e+03	1.12353e+03	1.1235e+03
gauss2mf	21,1024	21,1510	21,8455	22,7285	22,7285	22,7285	22,7285	22,7285
gaussmf	21,7455	21,7002	21,2717	22,8176	22,9192	22,8821	22,8821	22,8821
smf	error	error	error	error	error	error	error	error
trapmf	18,9866	18,9984	19,9451	21,1232	21,0989	21,0968	21,0971	21,0971
zmf	error	error	error	error	error	error	error	error
pimf	19,8170	19,7850	19,7602	20,2703	22,4888	22,8208	22,8490	22,8490

Συνάρτηση Συμμετοχής	mf_n=6, ss=0.1							
	Epoch=5	Epoch=10	Epoch=100	Epoch=250	Epoch=500	Epoch=1000	Epoch=5000	Epoch=10.000
	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE	RMSE
gbellmf	23,4188	23,6898	29,2815	145,9260	90,9351	90,9351	90,9351	90,9351
trimf	686,0448	487,4231	171,4718	174,7179	173,8010	173,7573	173,7548	173,7548
gauss2mf	19,7960	19,8645	22,1738	24,4657	25,1301	22,7285	22,72852	22,7285
gaussmf	21,1312	21,1615	22,6943	26,8322	26,3678	25,4013	25,3610	25,3610
smf	error	error	error	error	error	error	error	error
trapmf	19,1114	19,1246	19,7007	22,1327	23,0251	23,0492	23,0551	23,0551
zmf	error	error	error	error	error	error	error	error
pimf	19,1308	19,1444	19,7833	21,6715	22,8928	22,9218	22,9699	22,9699

Σημείωση: Οι χαμηλότερες τιμές του RMSE έχουν τονιστεί με **bold** ανά κατηγορία συνάρτησης συμμετοχής, ανάλογα τις εποχές που έχουν οριστεί.

Παρατήρηση

Στον πίνακα 4.4.1 παρουσιάζονται τα εξαγόμενα αποτελέσματα ώστε να βρεθεί το μικρότερο σφάλμα RMSE (Root Mean Square Error) ανά συνάρτηση συμμετοχής, αξίζει να σημειωθεί ότι το μικρότερο RMSE μας παρουσιάζει τον βέλτιστο τύπο.

Οι τύποι των συναρτήσεων συμμετοχής που δοκιμάστηκαν είναι: gbellmf, trimf, gauss2mf, gaussmf, smf, trapmf, zmf, pimf αντίστοιχα. Επίσης έγιναν πολλές δοκιμές αλλάζοντας το membership function (από 2 μέχρι 6) με σταθερό step size στο 0.1. Επιπρόσθετα τρέξαμε το πρόγραμμα στην matlab για κάθε membership function και step size τον εκάστοτε τύπο συναρτήσεως συμμετοχής που έχουμε προαναφέρει, αλλάζοντας κάθε φορά την εποχή (epoch) σε κάθε τύπο ώστε να βρεθεί το μικρότερο σφάλμα, έγιναν δοκιμές για epoch=(5,10,100,250,500,1.000,5.000 και 10.000 αντίστοιχα). Επίσης αρκετές δοκιμές έγιναν αλλάζοντας τις εποχές ώστε να υποδείξουμε ότι το σφάλμα μετά από ένα εύρος δοκιμών σταθεροποιείται, παρατηρήθηκε ότι το σφάλμα RMSE τις περισσότερες φορές σταθεροποιούταν μεταξύ 5.000 και 10.000 εποχές αντίστοιχα. Επιπλέον παρατηρήθηκε ότι οι τύποι των συναρτήσεων συμμετοχής που έβγαζαν error σε κάθε δοκιμή είναι smf και zmf.


Επιπρόσθετα το μικρότερο RMSE παρουσιάστηκε για membership function=2 και step size=0.1 με τύπο συνάρτησης συμμετοχής pimf και epoch=5 αντίστοιχα το μικρότερο σφάλμα RMSE με συνάρτηση συμμετοχής gbellmf παρουσιάστηκε για membership function=2, step size=0.1 και epoch=5, Αξίζει να σημειωθεί ότι το ο τύπος της συνάρτησης συμμετοχής που παρουσιάζει το μικρότερο σφάλμα RMSE θεωρείται και ο βέλτιστος.

Εν κατακλείδι όπως έχουμε προαναφέρει στην συνέχεια μελετήσαμε τα διαγράμματα για βέλτιστο gbellmf λόγω του καθορισμού των ασαφών συνόλων, της ομαλότητας του και επειδή είναι μη μηδενικές σε κάθε σημείο.

Σημείωση

Στην συνέχεια, παρουσιάζονται τα γραφήματα των αρχικών πωλήσεων δεδομένων, τον έλεγχο δεδομένων εκπαίδευσης και αξιολόγησης χρονοσειρών, σύγκριση πραγματικών τιμών και τιμών πρόβλεψης που αφορούν τις πωλήσεις ακινήτων και τέλος επιφάνεια εισόδου-εξόδου πώλησης ακινήτων.

Αξίζει να σημειωθεί ότι η επιλογή των γραφημάτων, έγινε με την χαμηλότερη τιμή του RMSE(Root Mean Square Error) που προέκυψε από τον πίνακα αποτελεσμάτων ANFIS. Στα ακόλουθα σχήματα παρουσιάζονται τα γραφήματα ώστε να έχουμε μια πιο ολοκληρωμένη εικόνα για την αποδοτικότητα του μοντέλου.




Εικόνα 50: Σύγκριση αρχικών πωλήσεων δεδομένων ακινήτων στις Ηνωμένες Πολιτείες Αμερικής

Παρατήρηση

Στην (εικόνα 50) παρουσιάζονται τα original data (house sales) δηλαδή τα αρχικά δεδομένα των πωλήσεων ακινήτων. Στο διάγραμμα στον y άξονα απεικονίζονται οι πωλήσεις με εύρος από (400 έως 750) και αντίστοιχα στον x άξονα απεικονίζονται οι μήνες με εύρος από (610 έως 690).

Επιπρόσθετα, στο διάγραμμα παρουσιάζονται τοπικά μέγιστα και ελάχιστα αντίστοιχα γεγονόσ που μας υποδεικνύει την σταδιακή αύξηση και πτώση των πωλήσεων κατά την πάροδο των μηνών. Επίσης παρατηρείται ολικό μέγιστο με μηνά 678 και πωλήσεις 750 αντίστοιχα, Επιπλέον παρατηρούνται δυο ολικά ελάχιστα με μηνά 613 και πωλήσεις 400 ενώ το δεύτερο τοπικό ελάχιστο με μήνα 618 και πωλήσεις 400.

Εν κατακλείδι τα αποτελέσματα των πωλήσεων που παρουσιάζονται είναι πολύ ενθαρρυντικά διότι παρατηρείται συνολικά μια γραμμική αύξηση των πωλήσεων από τον μήνα 620 έως τον 690 .



Εικόνα 5129: Δεδομένα σειράς εκπαίδευσης χρονοσειρών


Παρατήρηση

Στην (εικόνα 51) παρουσιάζονται δεδομένα σειράς εκπαίδευσης ,απεικονίζονται τα τρία διαγράμματα σειράς εκπαίδευσης όπου κάνει εκπαίδευση στα τελευταία 50 δείγματα. Τα πρώτα δυο διαγράμματα απεικονίζουν τις δυο εισόδους δηλαδή τα δυο input, για $x(k-2)$ παρουσιάζονται τα δείγματα εκπαίδευσης του χθες και για $x(k-1)$ παρουσιάζονται τα δείγματα εκπαίδευσης του σήμερα. Επίσης το τελευταίο διάγραμμα παρουσιάζει το output δηλαδή την έξοδο των τελευταίων 50 δειγμάτων $x(k)$ δηλαδή το αύριο.

Επιπρόσθετα ,όσον αφορά το πρώτο διάγραμμα στον y άξονα απεικονίζεται το $x(k-2)$ δηλαδή το χθες με εύρος από (400 έως 1400) ενώ στον x άξονα παρουσιάζεται ο χρόνος με εύρος από (630 έως 685). Αντίστοιχα στο δεύτερο διάγραμμα παρουσιάζεται στον y άξονα $x(k-1)$ το σήμερα και με x άξονα τον χρόνο με τα αντίστοιχα εύρη (x,y) του πρώτου διαγράμματος .Στο τελευταίο διάγραμμα απεικονίζεται στο y άξονα το $x(k)$ δηλαδή το αύριο ενώ στον x άξονα ο χρόνος με τα αντίστοιχα εύρη όπως του πρώτου και δευτέρου διαγράμματος. Στο πρώτο διάγραμμα παρατηρούνται ότι τα δείγματα εκπαίδευσης ξεκινούν με αφετηρία το 1200 και παρουσιάζουν τοπικά μέγιστα και ελάχιστα με την πάροδο του χρόνου ,επίσης παρατηρείται ολικό μέγιστο με input 1400

και χρόνο 651 στην συνέχεια καθώς ξεπερνάει το 651 παρατηρείται σταδιακή πτώση των δεδομένων με παρουσία τοπικών μέγιστων και ελάχιστων μέχρι που καταλήγει σε χρόνο 685 με input 400 που είναι και το ολικό ελάχιστο. Αντίστοιχα στο δεύτερο διάγραμμα για $x(k-1)$ δηλαδή το σήμερα παρατηρείται μια μικρή μετατόπιση προς τα αριστερά τα δείγματα εκπαίδευσης ξεκινούν από το 1200 ,στην συνέχεια με παρουσία ολικού μέγιστου με input 1400 και χρόνο 649 εν συνεχεία παρατηρείται πτώση των δεδομένων μέχρι που καταλήγει σε χρόνο 685 με input 400. Στο τελευταίο διάγραμμα για $x(k)$ δηλαδή το αύριο παρατηρείται μια μικρή μετατόπιση προς τα αριστερά τα δείγματα εκπαίδευσης ξεκινούν με αφετηρία το 1200,στην συνέχεια παρατηρείται ολικό μέγιστο με output 1400 και χρόνο 648 έπειτα όπως και στα προηγούμενα διαγράμματα παρατηρείται πτώση μέχρι που καταλήγει σε χρόνο 685 και output 400.

Αξίζει να σημειωθεί ότι τα δεδομένα εκπαίδευσης που παρουσιάζονται και στα 3 διαγράμματα μας παρουσιάζουν την ομαλή λειτουργία του μοντέλου ANFIS. Τέλος χρησιμοποιεί ένα τμήμα δεδομένων και το κάνει (in sample) για την εκπαίδευση του ,επίσης το μοντέλο ANFIS συλλεγεί τα 4/5 και τα κάνει training δηλαδή τα εκπαιδεύει ,στην περίπτωση μας τις 545 μετρήσεις τις εκπαιδεύει και τις υπόλοιπες τις αξιολογεί όπως θα αναφερθούμε παρακάτω.



Εικόνα 52: Δεδομένα σειράς αξιολόγησης χρονοσειρών


Παρατήρηση

Στην (εικόνα 52) παρουσιάζονται δεδομένα σειράς αξιολόγησης ή ελέγχου ,απεικονίζονται τα τρία διαγράμματα σειράς εκπαίδευσης όπου κάνει έλεγχο στα τελευταία 12 δείγματα. Τα πρώτα δυο διαγράμματα απεικονίζουν τις δυο εισόδους δηλαδή τα δυο input, για $x(k-2)$ παρουσιάζονται τα δείγματα ελέγχει το χθες και για $x(k-1)$ παρουσιάζονται τα δείγματα ελέγχει του σήμερα. Επίσης το τελευταίο διάγραμμα παρουσιάζει το output δηλαδή την έξοδο για $x(k)$ δηλαδή το αύριο.

Όσον αφορά το πρώτο διάγραμμα στον y άξονα απεικονίζεται το $x(k-2)$ δηλαδή το χθες με εύρος από (550 έως 750) ενώ στον x άξονα παρουσιάζεται ο χρόνος με εύρος από (672 έως 684). Αντίστοιχα στο δεύτερο διάγραμμα παρουσιάζεται στον y άξονα $x(k-1)$ το σήμερα και με x άξονα τον χρόνο με τα αντίστοιχα εύρη (x,y) του πρώτου διαγράμματος. Στο τελευταίο διάγραμμα απεικονίζεται στο y άξονα το $x(k)$ δηλαδή το αύριο ενώ στον x άξονα ο χρόνος με τα αντίστοιχα εύρη όπως του πρώτου και δευτέρου διαγράμματος. Στο πρώτο διάγραμμα που παρουσιάζεται το $x(k-2)$ δηλαδή το χθες τα δείγματα ελέγχου ξεκινούν για input 672 όπου είναι και το ολικό ελάχιστο εν συνεχεία

παρατηρούνται τοπικά μέγιστα και ελάχιστα κατά την πάροδο του χρόνου ,επίσης για input 750 παρατηρείται ολικό μέγιστο με χρόνο 680. Επιπλέον για $x(k-1)$ δηλαδή το σήμερα ,τα δείγματα ελέγχου ξεκινούν για input 620 ,στην συνέχεια παρουσιάζεται με input 550 και χρόνο 673 ολικό ελάχιστο και ολικό μέγιστο αντίστοιχα με input 750 και χρόνο 679,επιπροσθετα παρατηρείται μια μετακίνηση του πρώτου διαγράμματος προς τα αριστερά γεγονός που αποδεικνύει την ομαλή λειτουργία του. Τέλος για $x(k)$ δηλαδή το αύριο ,τα δείγματα ελέγχου ξεκινούν για output 672 που παρουσιάζει και ολικό ελάχιστο, επίσης για output 750 και χρόνο 678 παρουσιάζεται ολικό μέγιστο .

Επιπρόσθετα ότι τα δεδομένα ελέγχου που παρουσιάζονται και στα 3 διαγράμματα μας παρουσιάζουν την ομαλή λειτουργία του μοντέλου ANFIS. Τέλος χρησιμοποιεί ένα τμήμα δεδομένων και το κάνει (out of sample) για τον έλεγχο της πρόβλεψης ,επίσης το μοντέλο ANFIS συλλεγεί τα 1/5 και τα κάνει checking δηλαδή το αξιολογεί ,στην περίπτωση μας τις 135 μετρήσεις τις αξιολογεί.



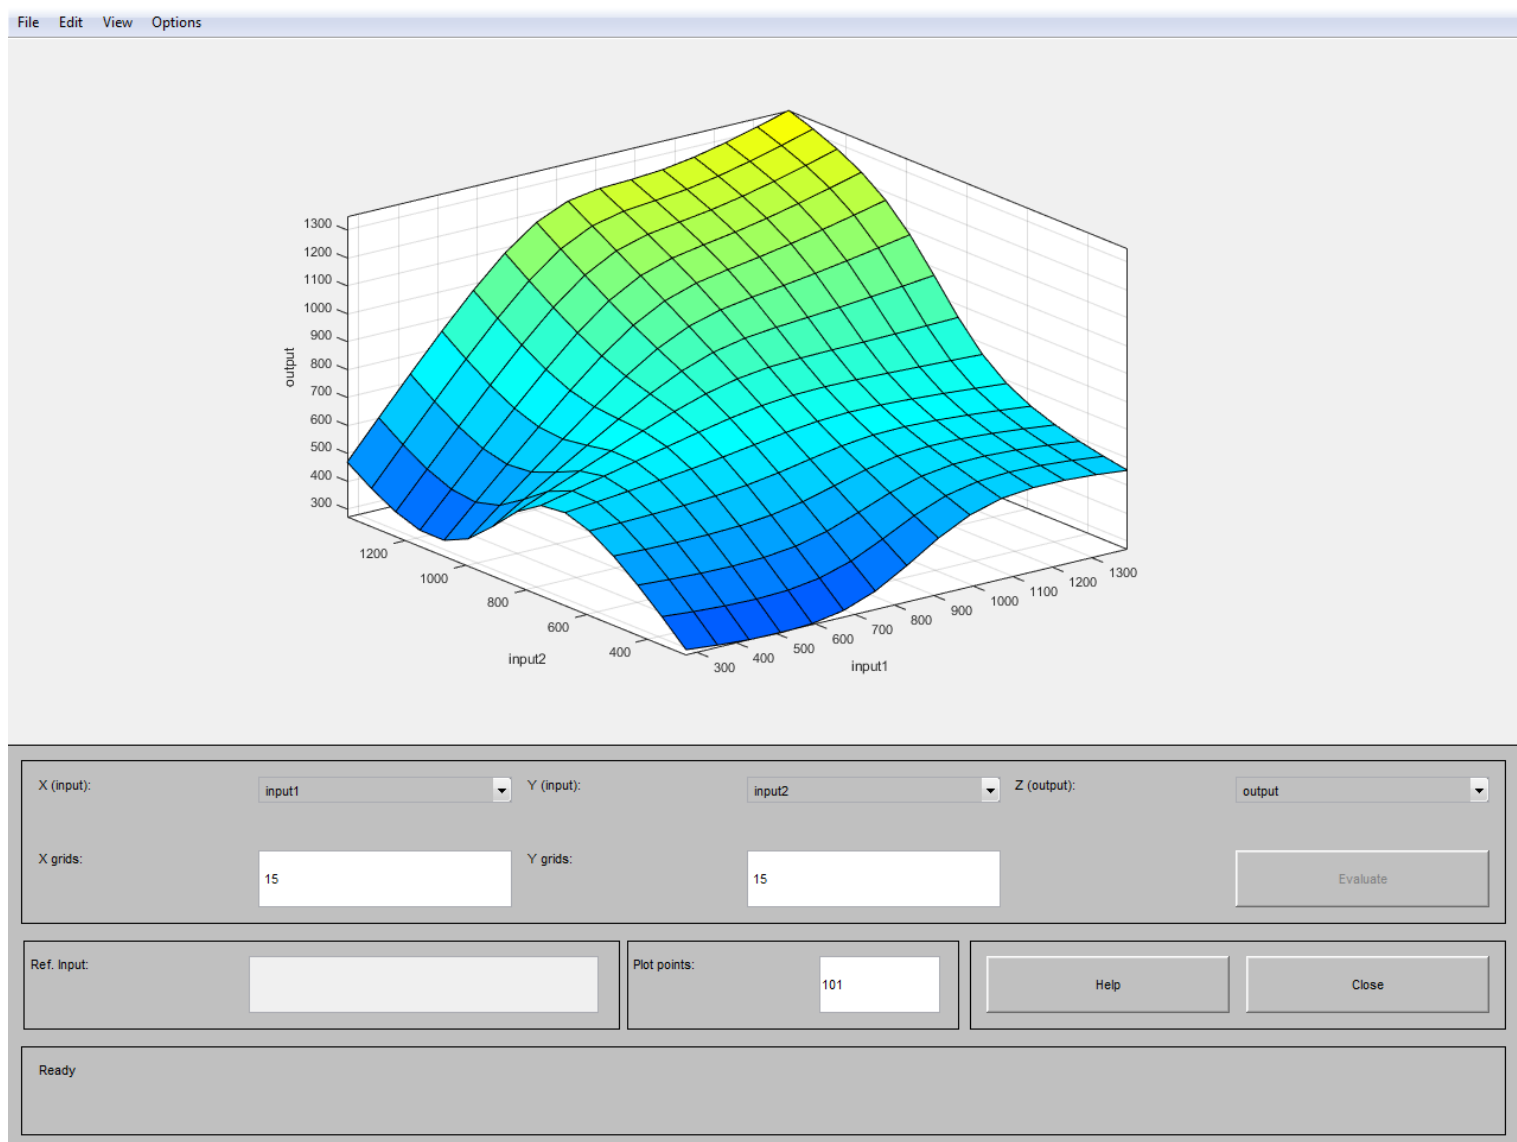
Εικόνα 53: Σύγκριση πραγματικών τιμών και τιμών πρόβλεψης που αφορούν τις πωλήσεις ακινήτων

Παρατήρηση

Στην (εικόνα 53) παρουσιάζεται το διάγραμμα σύγκρισης πραγματικών τιμών και τιμών πρόβλεψης που αφορούν τις πωλήσεις ακινήτων. Αξίζει να σημειωθεί ότι στον άξονα y απεικονίζονται τα values δηλαδή οι αξίες με εύρος από (540 έως 740) ενώ στον άξονα x ο χρόνος (time) με εύρος από (0 έως 35) αντίστοιχα.

Εν συνεχεία αξιολογούμε το νευρωνικό δίκτυο συγκρίνοντας τα αποτελέσματα του ως προς τις πραγματικές τιμές και οπτικοποιούμε το αποτέλεσμα με την κοινή τους παρουσίαση. Η μπλε γραμμή απεικονίζει τις πραγματικές τιμές ενώ η κόκκινη γραμμή τις τιμές πρόβλεψης ANFIS. Η διαγραμματική σύγκριση των πραγματικών τιμών με των τιμών πρόβλεψης παρουσιάζεται οπτικά μέσα από το διάγραμμα. Επιπρόσθετα, παρατηρούμε ότι οι πραγματικές τιμές με τις τιμές πρόβλεψης παρουσιάζουν μια μικρή απόκλιση σε κάποια σημεία ενώ σε κάποια άλλα ταυτίζονται μεταξύ τους.

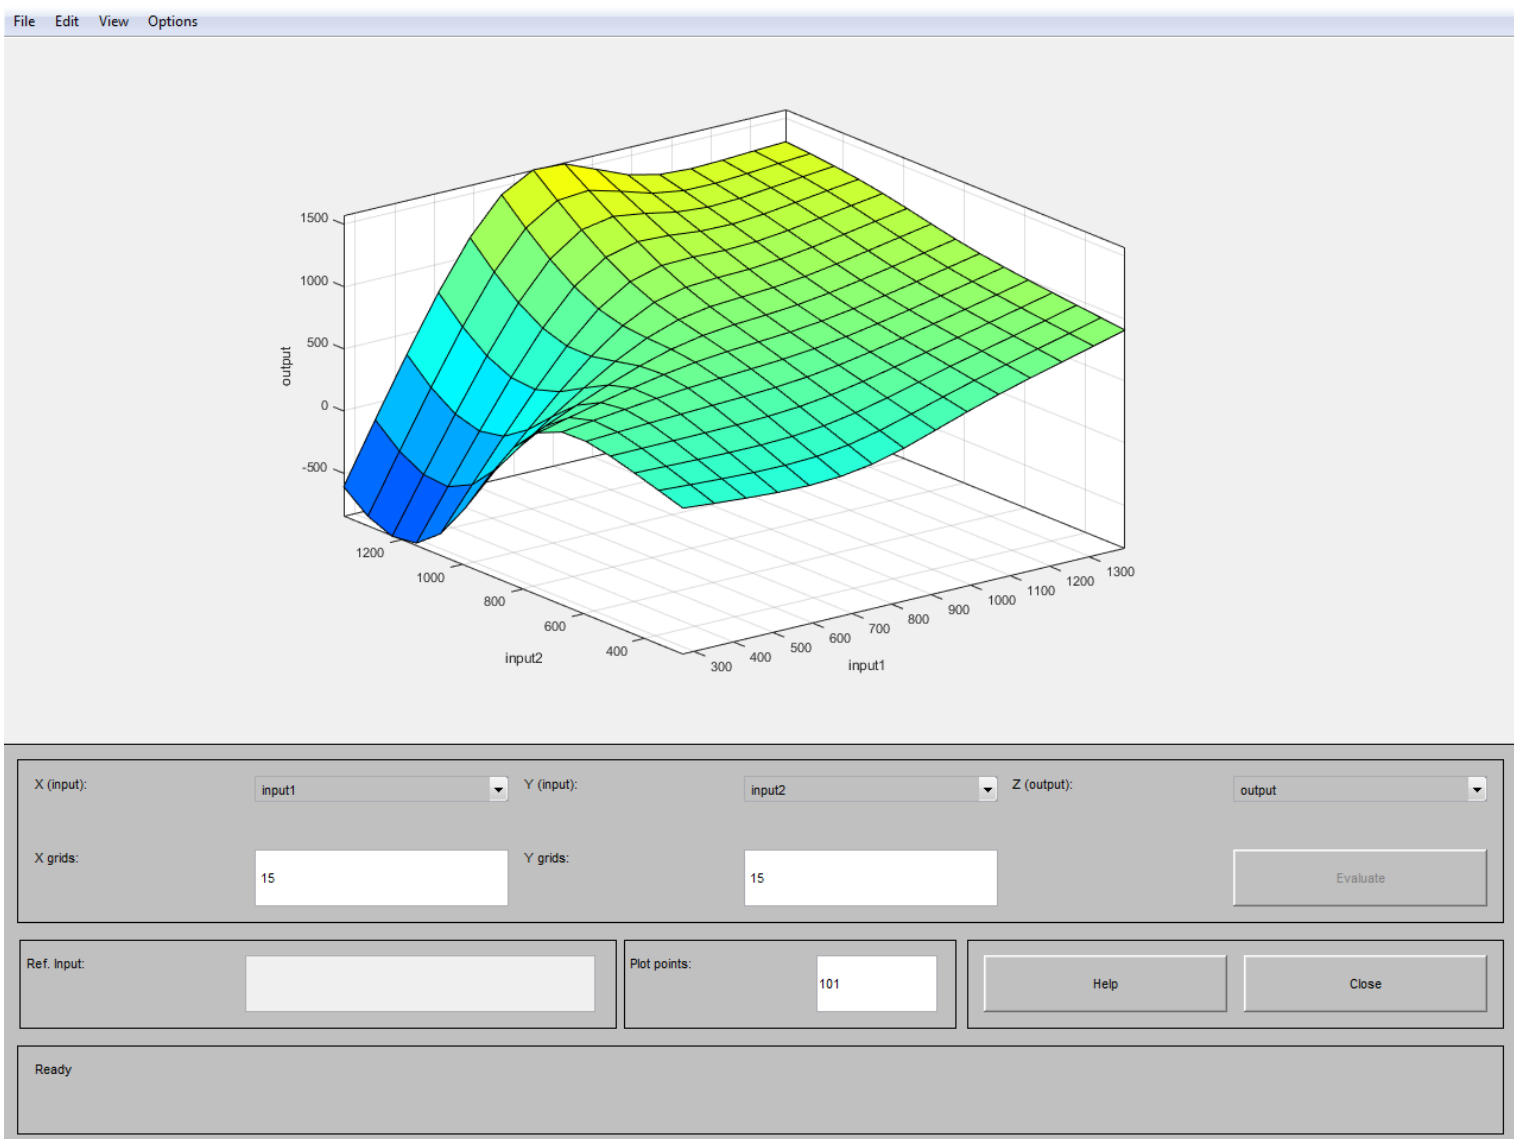
Εν κατακλείδι, η πρόβλεψη του νευρωνικού δικτύου για τις πωλήσεις ακινήτων θεωρείται αρκετά ικανοποιητική, καθώς τα σημεία των πραγματικών τιμών και των τιμών πρόβλεψης βρίσκονται σε καλά επίπεδα μεταξύ τους με και εμφανίζουν πολύ καλό fit.



Εικόνα 54: Επιφάνεια εισόδου-εξόδου πώλησης ακινήτων στις Ηνωμένες Πολιτείες Αμερικής

Παρατήρηση

Στην (εικόνα 54) παρουσιάζεται μια τρισδιάστατη επιφάνεια ασαφούς μοντέλου. Όπως μπορούμε να παρατηρήσουμε η επιφάνεια είναι αρκετά ομαλή, γεγονός που μας υποδηλώνει ότι έχουμε πάρει ικανοποιητικούς αριθμό δεδομένων και τα αποτελέσματα που θα συλλέξουμε από την χρήση του μοντέλου που κατασκευάσαμε θα είναι αρκετά καλά. Επιπρόσθετα, παρατηρείται στην πάνω και κάτω αριστερή γωνία του σχήματος μια ανωμαλία, γεγονός που μας υποδηλώνει ότι υπάρχει διασπορά των άκρων.



Εικόνα 55: Επιφάνεια εισόδου-εξόδου πώλησης ακινήτων στις Ηνωμένες Πολιτείες Αμερικής

Παρατήρηση

Αντίστοιχα στην (Εικόνα 55) παρουσιάζεται μια τρισδιάστατη επιφάνεια ασαφούς μοντέλου. Τρέξαμε το μοντέλο για epoch=10.000 όπως μπορούμε να παρατηρήσουμε η επιφάνεια είναι αρκετά ομαλή, γεγονός που μας υποδηλώνει ότι έχουμε πάρει ικανοποιητικοί αριθμό δεδομένων και τα αποτελέσματα που θα συλλέξουμε από την χρήση του μοντέλου που κατασκευάσαμε θα είναι αρκετά καλά. Επίσης παρουσιάζεται μια αύξηση στο τρισδιάστατο μοντέλο γεγονός που αποδεικνύει μια αύξηση σε σχέση με την (Εικόνα 54), παρατηρείται ότι στον x άξονα δέχεται το input1 δηλαδή δεδομένα (k-1) του σήμερα, στον y άξονα εισάγει input 2 δηλαδή (k-2) δεδομένα του χθες και στον z άξονα δέχεται τα output δηλαδή (k) τα δεδομένα του αύριο. Εν κατακλείδι, στο πάνω αριστερά παρατηρείται μια απότομη πτώση γεγονός που μας υποδεικνύει ότι υπάρχει διασπορά των ακρών.

5. Συμπεράσματα

Συμπερασματικά όπως έχουμε προαναφερθεί, το μοντέλο μας αντλεί δεδομένα από τους πίνακες ακινήτων. Χρησιμοποιεί ένα τμήματα δεδομένων μας (in sample) για την εκπαίδευση του και ένα τμήμα (out of sample) για τον έλεγχο της πρόβλεψης. Αξίζει να σημειωθεί το μοντέλο ANFIS που χρησιμοποιήσαμε συλλέγει τα 4/5 των δεδομένων και τα κάνει training (δηλαδή εκπαίδευση) και το 1/5 checking (δηλαδή αξιολόγησή δεδομένων). Στην περίπτωση μας τις 545 μετρήσεις τις εκπαιδεύει και τις υπόλοιπες 135 μετρήσεις τις αξιολογεί, τα διαγράμματα στις (εικόνες 51,52)μας υποδεικνύουν τα δεδομένα σειράς εκπαίδευσης και αξιολόγησης αντίστοιχα. Επιπρόσθετα για να γίνει η αξιολόγηση του μοντέλου εστιάσαμε στα εξαγόμενα διαγράμματα της matlab όπως και τις τιμές του σφάλματος που προέκυψαν. Εν συνεχεία οι δυο τύποι του σφάλματος είναι RMSE(Root Mean Square Error) και MSE(Mean Square Error) αντίστοιχα. Το σφάλμα RMSE υποδηλώνει την ρίζα του μέσου τετραγωνικού σφάλματος, το σφάλμα αυτό στην παρούσα διπλωματική αξιολογήθηκε και μας βοήθησε στην επιλογή του βέλτιστου μοντέλου. Επίσης προέκυψε και το μέσο τετραγωνικό σφάλμα MSE, το οποίο προκύπτει παίρνοντας μια μέση τιμή του τετραγώνου του σφάλματος, δηλαδή την διαφορά της πραγματικής από την προβλεπόμενη τιμή κατά μήκος των δύο, είτε είναι το δείγμα εκπαίδευσης ή πρόβλεψής αντίστοιχα.

Επίσης από τον πίνακα αποτελεσμάτων του ANFIS (Πίνακας 4.4.1) παρατηρούμε ότι σε κάποιους κλάδους τα αποτελέσματα είναι πολύ ακριβή ενώ σε κάποιους άλλους λιγότερο. Αξίζει να σημειωθεί ότι για $mf_n=2$ και $ss=0.1$ με συνάρτηση συμμετοχής pimf και $\text{epoch}=5$ παρατηρήθηκε το μικρότερο RMSE. Επιπρόσθετα στην (εικόνα 50) παρατηρούμε το διάγραμμα των αρχικών πωλήσεων ακινήτων και μας δίνει μια αρχική εικόνα των πωλήσεων. Στον x άξονα παρουσιάζονται οι μήνες ενώ στον y οι πωλήσεις. Εν συνεχεία παρατηρούμε συνολικά, ότι με την πάροδο των χρόνων έχουμε αύξηση των πωλήσεων. Αξίζει να σημειωθεί ότι μελετώντας τμηματικά το διάγραμμα παρουσιάζονται τοπικά ελάχιστα και μέγιστα όπου μας πληροφορούν στην πτώση των πωλήσεων ή την αύξηση τους σε ένα εύρος κάποιων μηνών ή και χρόνων αντίστοιχα.

Η επιτυχία της πρόβλεψης φαίνεται στο διάγραμμα σύγκρισης πραγματικών τιμών με τιμών πρόβλεψης (εικόνα 53). Παρατηρούμε ότι οι τιμές είναι πάρα πολύ κοντά κατά μήκος του διαγράμματος και κάποιες από αυτές είναι σχεδόν ταυτόσημες. Στην συνεχεία στην (εικόνα 54) εισόδου-εξόδου πώλησης ακινήτων παρατηρούμε μια πολύ ομαλή καμπύλη δεδομένων εισόδου-εξόδου, αυτό έχει ως αποτέλεσμα ότι τα δεδομένα εισόδου είναι ικανοποιητικά ώστε να μας δώσουν μια καλή πρόβλεψη. Η μικρή ανωμαλία στις δυο κάτω άκρες μας υποδεικνύει ότι υπάρχει διασπορά των άκρων. Αντίστοιχα για την (εικόνα 55) μελετήσαμε το μοντέλο για $\text{epoch}=10.000$ παρατηρείται μια ουσιαστική αύξηση σε σχέση με την (εικόνα 54), επίσης παρουσιάζεται μια πολύ ομαλή καμπύλη δεδομένων εισόδου-εξόδου, αυτό έχει ως αποτέλεσμα ότι τα δεδομένα εισόδου είναι ικανοποιητικά ώστε να μας δώσουν μια καλή πρόβλεψη. Η μικρή ανωμαλία στην πάνω αριστερή άκρη γεγονός που μας υποδεικνύει ότι υπάρχει διασπορά των άκρων όπως και στην (εικόνα 54) αντίστοιχα.

Μέσα από την διπλωματική παρουσιάσαμε την δυναμική των καθημερινών πωλήσεων των ακινήτων, όπου μπορεί να εκληφθεί από ένα σύστημα ANFIS και να μας βοηθήσει να προβλέψουμε την βραχυπρόθεσμη τάση των πωλήσεων. Τα αποτελέσματα που μελετήσαμε είναι πολύ ενθαρρυντικά και υπάρχει μια συνολική αύξηση των πωλήσεων ακινήτων σε σχέση με τα πρώτα χρόνια που μελετήσαμε. Αξίζει να σημειωθεί ότι το μοντέλο ANFIS θεωρείται ένα αξιόλογο μοντέλο πρόβλεψης και αποδίδει καλύτερα από άλλες μεθόδους. Επίσης μπορεί να μελετήσει και να προβλέψει

με επιτυχία οικονομικά και στρατηγικά προβλήματα που θα βοηθήσουν στην λήψη μιας απόφασης για την αγορά ,την πώληση ,την ενοικίαση ή ακόμα και την επένδυση.

Εν κατακλείδι, οι προβλέψεις έχουν γίνει βασικοί πυλώνες στην ανάπτυξη του οικονομικού και στρατηγικού προγραμματισμού κατά την διάρκεια της τελευταίας εικοσαετίας ,δεδομένου ότι βρίσκουν εφαρμογή οι τεχνικές πρόβλεψης στις εμπορικές και βιομηχανικές αγορές. Επίσης παρατηρείται ένα συνεχώς αυξανόμενο ενδιαφέρον και σε άλλους τομείς της επιστήμης και βρίσκουν εφαρμογή σε καθημερινά προβλήματα, όπως για παράδειγμα η πρόβλεψη μετεωρολογικών μεταβλητών και η πρόγνωση του καιρού.

BIBΛΙΟΓΡΑΦΙΑ

- F. Abbasi, "The fuzzy logic in air pollution forecasting model", Vol. 9, No. 1, 2017 Article ID IJIM-00857.
- J. S. Armstrong, Principles of forecasting (hdbk), Kluwer Academic Publisher, (2001).
- Sunil Kumar, Arun Kumar, Sultan F. Meko, Dawitleyken, Milkias Berhanu, "Load Forecasting of Adama University by Implementing Fuzzy Logic Controller", International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering, Vol. 2, Issue 12, December 2013.
- S. H. Ling, F. H. F. Leung and P. K. S. Tam, "Daily load forecasting with a Fuzzy-Input-Neural Network in an intelligent Home," in Proc. 2001 IEEE, Fuzzy Systems Conf., pp. 449-452.
- Girraj Singh, D. S. Chauhan, Aseem Chandel, "Short-Term Load Forecasting by using ANN, Fuzzy Logic and Fuzzy Neural Network", Vol. 6 Issue 01, January-2017.
- S. Alvisi, G. Mascellani, M. Franchini, and A. B'ardossy, "Water level forecasting through fuzzy logic and artificial neural network approaches", 2, 1107–1145, 2005.
- Chandra Mahabir, Faye Hicks, Aminah Robinson Fayek, "Neuro-Fuzzy Logic Model for Breakup Forecasting at Fort McMurray, AB", 13th Workshop on the Hydraulics of Ice Covered Rivers Hanover, NH, September 15-16, 2005.
- Mahdi Javanmard, "An Approach to Improve Forecasting Cash Demand at ATMs Using Fuzzy Logic", Vol. 14, No. 11, November 2016.
- Imo Eyoh, Jeremiah Eyoh, Ini Umoeka, "Interval Type-2 Intuitionistic Fuzzy Logic System for Forecasting the Electricity Load", Volume 6, Issue 10 October – 2020.

- Shahram Javadi, "Spatial Load Forecasting Using Fuzzy Logic", Azad University – Tehran Central Branch Electrical Engineering Department.
- Sagar R. Kamble, Samadhan D. Deokar, Sumit M. Latke, Manik M. Hapse, "Load forecasting using fuzzy logic", Volume: 05 Issue: 06 | JUNE 2018.
- Pei-Chann Chang, Yen-Wen Wang, and Chen-Hao Liu, "Fuzzy Back-Propagation Network for PCB Sales Forecasting", Department of Industrial Engineering and Management, Yuan-Ze University.
- Dharati Kulkarni, "Temperature Sensitive Short Term Load Forecasting: Fuzzy Logic Approach", 2018 IJSRCSEIT | Volume 3 | Issue 6 | ISSN: 2456-3307.
- Vidita Tilva, Jignesh Patel, Chetan Bhatt, "Weather Based Plant Diseases Forecasting Using Fuzzy Logic", 2013 Nirma University International Conference on Engineering (NUiCONE).
- Meysam Naderi, Ehsan Khamnehchi, "Fuzzy logic coupled with exhaustive search algorithm for forecasting of petroleum economic parameters", Volume 176, May 2019, Pages 291-298.
- Esmaeil Hadavandi, Hassan Shavandi, Arash Ghanbari, "An improved sales forecasting approach by the integration of genetic fuzzy systems and data clustering: Case study of printed circuit board", Expert Systems with Applications Volume 38, Issue 8, August 2011, Pages 9392-9399.
- Fu-Kwun Wang, Ku-Kuang Chang, Chih-Wei Tzeng, "Using adaptive network-based fuzzy inference system to forecast automobile sales", Expert Systems with Applications Volume 38, Issue 8, August 2011, Pages 10587-10593.
- Pei-Chann Chang, Chen-Hao Liu, Robert K. Lai, "A fuzzy case-based reasoning model for sales forecasting in print circuit board industries", Expert Systems with Applications Volume 34, Issue 3, April 2008, Pages 2049-2058.
- <https://www.sciencedirect.com/science/articles>
- <https://www.researchgate.net>

- R.J. Kuo, ‘‘A sales forecasting system based on fuzzy neural network with initial weights generated by genetic algorithm’’, *European Journal of Operational Research* Volume 129, Issue 3, 16 March 2001, Pages 496-517.
- Hidetaka Sakai, Hideki Nakajima, Minoru Higashihara, Masashi Yasuda, Masato Oosumi, ‘‘Development of a fuzzy sales forecasting system for vending machines’’, *Computers & Industrial Engineering* Volume 36, Issue 2, April 1999, Pages 427-449.
- Fang-Mei Tsenga, Jing-Rung Yu, ‘‘A two stage fuzzy piecewise logistic model for penetration forecasting’’, *Applied Soft Computing* Volume 21, August 2014, Pages 149-158.
- Wen-Pai Wang, Ze Chen, ‘‘A neuro-fuzzy based forecasting approach for rush order control applications’’, *Expert Systems with Applications* Volume 35, Issues 1–2, July–August 2008, Pages 223-234.
- W. S. McCulloch and W. Pitts, A logical calculus of ideas immanent in nervous activity, *Bullettin of Mathematical Biophysics*, 5, 115(1943).
- B. Widrow and M. E. Hoff, Adaptive Switching Circuits, 1960 WESCON Convention, Record Part 4, pp. 96-104; *Human Neurobiology*, 4,229(1985)
- Θεοδόση – Κοκκίνου Λάουρα, ‘‘Τεχνητά Νευρωνικά Δίκτυα και εφαρμογές στα Συστήματα Αυτομάτου Ελέγχου’’, Πάτρα, Ιούνιος 2013.
- Γρηγόριος Τσούλος, ‘‘Δικτυακή Εφαρμογή για Κατασκευαζόμενα Νευρωνικά Δίκτυα’’, Άρτα-Ήπειρος, Σεπτέμβριος, 2018.
- A. L. Hodgkin and A. F. Huxley, A quantitative description of membrane current and its applications to conduction and excitation in nerve, *J. Physiology (London)*117,500 (1952).
- Δημήτριος Α. Τσορτανίδης, ‘‘Αρχιτεκτονική και Εκπαίδευση Νευρωνικών Δικτύων με Γενετικούς Αλγορίθμους στην Πρόγνωση Οικονομικών Δεδομένων’’, Πανεπιστήμιο Πατρών, 2005.

- Θωμάς Αμοργιανιώτης, ‘‘Χρήση γενετικού αλγορίθμου για βελτιστοποίηση δομής, παραμέτρων τεχνητών νευρωνικών δικτύων και εφαρμογή της υβριδικής μεθόδου σε προβλήματα από τον χώρο της οικονομίας’’, Πάτρα, Οκτώβριος 2011.
- F. Rosenblatt, Principles of Neuodynamics, Spartan (N.Y), 1962.
- <https://towardsdatascience.com/perceptron-learning-algorithm>
- Βακούλη Αντιγόνη, ‘‘ Ασυνέπειες της ασαφούς λογικής’’, Χανιά, 2005
- <http://eclass.teipir.gr/openeclass/modules/document/file.php/>
- L. Wang, A Course in Fuzzy Systems and Control, Prentice Hall, 1997.
- Καραμπελα Αικατερίνη, ‘‘Ασαφής λογική και εφαρμογές στην ασφάλιση’’, Πανεπιστήμιο Πειραιώς.
- Θεοχαρίδης Γεώργιος, ‘‘ Αλγόριθμοι Ανάπτυξης Ταξινομητών Βασισμένων σε Ασαφείς Κανόνες, για την Ταξινόμηση Προτύπων’’, Θεσσαλονίκη, Ιούλιος 2009.
- Κακάλου Χριστίνα – Ασημίνα, Κοσβυρά Αλεξάνδρα, ‘‘ Βελτιστοποίηση της λειτουργίας του κεντρικού λεβητοστασίου του ΑΠΘ με τη χρήση γενετικών αλγορίθμων και κανόνων ασαφούς λογικής’’, Θεσσαλονίκη, Ιούνιος 2014.
- Ανδρούτσου Παναγιώτη, ‘‘Αναγνώριση μη Γραμμικού Μοντέλου για Την Καρδιαγγειακή Ρύθμιση’’, Πάτρα, Δεκέμβριος 2013.
- Ιωάννου Σοφία-Ευαγγελία, ‘‘ Πρόβλεψη Εισαγωγής Φυσικού Αεριού Με Νευροασαφή Συστήματα (ANFIS) Και Νευρωνικά Δίκτυα’’, ΧΑΝΙΑ 2013.