

ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ  
ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ

Τμήμα Ηλεκτρολόγων & Ηλεκτρονικών Μηχανικών

[www.eee.uniwa.gr](http://www.eee.uniwa.gr)

Θηβών 250, Αθήνα-Αιγάλεω 12244

Τηλ. +30 210 538-1225, Fax. +30 210 538-1226



UNIVERSITY of WEST ATTICA  
FACULTY OF ENGINEERING  
Department of Electrical & Electronics Engineering

[www.eee.uniwa.gr](http://www.eee.uniwa.gr)

250, Thivon Str., Athens, GR-12244, Greece

Tel:+30 210 538-1225, Fax:+30 210 538-1226


Πρόγραμμα Μεταπτυχιακών Σπουδών  
*Ηλεκτρικές & Ηλεκτρονικές Επιστήμες μέσω Έρευνας*

Master of Science By Research in  
*Electrical & Electronics Engineering*

## ΜΕΤΑΠΤΥΧΙΑΚΗ ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**«Προηγμένες Μέθοδοι Εκτίμησης Λειτουργικής Κατάστασης Εξοπλισμού  
Συστημάτων Ηλεκτρικής Ενέργειας με χρήση τεχνικών Τεχνητής Νοημοσύνης  
και Ασαφούς Λογικής»**

**(Διάγνωση Βλαβών Μετασχηματιστών Ισχύος)**



Μεταπτυχιακή Φοιτήτρια: Βασιλική Ροκάνη, AM 0015

Επιβλέπων : Καμινάρης Σταύρος, Αναπλ. Καθηγητής

ΑΙΓΑΛΕΩ, 20 Σεπτεμβρίου 2020

ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ  
ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ  
Τμήμα Ηλεκτρολόγων & Ηλεκτρονικών Μηχανικών  
[www.eee.uniwa.gr](http://www.eee.uniwa.gr)

Θηβών 250, Αθήνα-Αιγάλεω 12244  
Τηλ. +30 210 538-1225, Fax. +30 210 538-1226



UNIVERSITY of WEST ATTICA  
FACULTY OF ENGINEERING  
Department of Electrical & Electronics Engineering  
[www.eee.uniwa.gr](http://www.eee.uniwa.gr)

250, Thivon Str., Athens, GR-12244, Greece  
Tel:+30 210 538-1225, Fax:+30 210 538-1226

Πρόγραμμα Μεταπτυχιακών Σπουδών  
*Ηλεκτρικές & Ηλεκτρονικές Επιστήμες μέσω Έρευνας*

Master of Science By Research in  
*Electrical & Electronics Engineering*

## MSc Thesis

### Power Transformers Fault Diagnosis



Student: Rokani Vasiliki

MSc Thesis Supervisor: : Kaminaris Stavros, Associate Professor

ATHENS-EGALEO, 20<sup>th</sup> September 2020

Η Μεταπτυχιακή Διπλωματική Εργασία έγινε αποδεκτή, εξετάστηκε και βαθμολογήθηκε από την εξής τριμελή εξεταστική επιτροπή:

Επιβλέπων	Μέλος	Μέλος
Καμινάρης Σταύρος	Αλεξανδρίδης Αλέξανδρος	Φαμέλης Ιωάννης
Καθηγητής	Καθηγητής	Καθηγητής

## ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΜΕΤΑΠΤΥΧΙΑΚΗΣ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

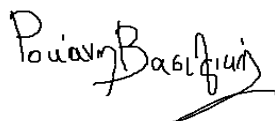
Η κάτωθι υπογεγραμμένη Ροκάνη Βασιλική του Αντωνίου, με αριθμό μητρώου 0015 φοιτήτρια του Προγράμματος Μεταπτυχιακών Σπουδών Ηλεκτρικές και Ηλεκτρονικές Επιστήμες μέσω Έρευνας του Τμήματος Ηλεκτρολόγων και Ηλεκτρονικών Μηχανικών της Σχολής Μηχανικών του Πανεπιστημίου Δυτικής Αττικής, δηλώνω ότι:

«Είμαι η συγγραφέας αυτής της μεταπτυχιακής διπλωματικής εργασίας και κάθε βοήθεια την οποία είχα για την προετοιμασία της, είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του τίτλου μου».

/

Η Δηλούσα



Ροκάνη Βασιλική

**Copyright ©** Με επιφύλαξη παντός δικαιώματος. All rights reserved.

**ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ και Ροκάνη Βασιλική,**

**Ιανουάριος , 2022**

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας Μεταπτυχιακής Διπλωματικής Εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον/την συγγραφέα.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον/την συγγραφέα του και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις θέσεις του επιβλέποντος μέλους ΔΕΠ, της επιτροπής εξέτασης ή τις επίσημες θέσεις του Τμήματος και του Ιδρύματος.

## ΠΕΡΙΛΗΨΗ

Η **Τεχνητή Νοημοσύνη (AI)** είναι ένας νέος κλάδος στην επιστήμη και τη μηχανική. Οι τεχνικές AI αποτελούν μια πρωτοποριακή μέθοδο για την διάγνωση των βλαβών Μετασχηματιστών (Μ/Σ) Ισχύος ( Power Transformers Fault Diagnosis). Όταν σε έναν μετασχηματιστή παρουσιαστεί κάποια βλάβη τότε λαμβάνει χώρα έκλυση συγκεκριμένων αερίων στο μονωτικό του λάδι. Η ανάλυση αυτών των αερίων, χρησιμοποιείται στον καθορισμό του τύπου των βλαβών στο εσωτερικό του Μ/Σ.

Η μέθοδος που χρησιμοποιείται για αυτή την ανάλυση καλείται Αεριοχρωματογραφία και πρόκειται για μια τεχνική διαχωρισμού, ταυτοποίησης και ποσοτικού προσδιορισμού μιγμάτων αερίων. Η συμβατική μέθοδος που χρησιμοποιείται ευρέως είναι η Ανάλυση Διαλυμένων Αερίων (Dissolved Gas Analysis , DGA).

Όλες οι συμβατικές μέθοδοι έχουν περιορισμούς επειδή δεν μπορούν να αναλύσουν με ακρίβεια όλα τα σφάλματα. Συνήθως αυτό συμβαίνει όταν υπάρχουν περισσότερα από ένα σφάλματα σε έναν Μ/Σ ή όταν η συγκέντρωση των αερίων είναι κοντά σε κάποιο όριο .Για την αντιμετώπιση αυτού του προβλήματος και για τη βελτίωση της αξιοπιστίας και της ακρίβειας της διάγνωσης σφαλμάτων, προτείνονται διάφορες τεχνικές Τεχνητής Νοημοσύνης.

Στην παρούσα εργασία μελετώνται τρεις μέθοδοι AI : Ασαφές Σύστημα Συμπερασμού (Fuzzy Inference System, FIS), Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks, ANN) και Προσαρμοστικό Νευροασαφές Σύστημα (Adaptive Neuro-Fuzzy Inference System, ANFIS), προκειμένου να ενισχυθεί η ακρίβεια της συμβατικής μεθόδου Rogers Ratio, η οποία αξιολογεί την DGA.

Όλες οι τεχνικές προσομοιώνονται με τη βοήθεια του λογισμικό MATLAB. Για την επίτευξη του πειράματος χρησιμοποιούνται πραγματικά δείγματα διαλυμένων αερίων που έχουν παραχθεί σε Μ/Σ που έχουν υποστεί βλάβες. Τέλος, γίνεται μια συγκριτική παρουσίαση των FIS, ANN, ANFIS και της συμβατικής μεθόδου Rogers Ratio.

**ΛΕΞΕΙΣ – ΚΛΕΙΔΙΑ:** *Ανάλυση Διαλυμένων Αερίων, Ασαφές Σύστημα, Διάγνωση Βλαβών Μ/Σ ισχύος, Μέθοδος Rogers, Μετασχηματιστές Ισχύος, MATLAB, Νεύρο-ασαφές Σύστημα, Νευρωνικά Δίκτυα.*

## ABSTRACT

Artificial Intelligence (AI) is a novel branch in science and engineering. AI techniques constitute the most cutting- edge method in Power Transformers Fault Diagnosis. When a transformer fails, some gases are produced and dissolved in the insulating oil, and Gas Chromatography detects them. It is a technique of separation, identification, and quantification of mixtures of gases. The analysis of these gases helps to identify the incipient fault types.

The conventional method widely adopted is the Dissolved Gas Analysis (DGA). All the conventional methods have limitations because they cannot analyze all faults accurately. It usually happens when more than one fault occurs in a transformer or when the concentration of gases is near the threshold.

To deal with this problem, and to improve the reliability and the accuracy of fault diagnosis, various Artificial Intelligence techniques are proposed. In this paper are employed three AI methods, a Fuzzy Inference System (FIS), an Artificial Neural Network (ANN), and an Adaptive Neuro-Fuzzy Inference System (ANFIS), in order to enhance the accuracy of conventional Rogers Ratio method, that evaluates the DGA.

All the techniques are simulated using MATLAB software. Real samples of dissolved gases that have been generated in failure transformers are used. A comparison of the FIS, ANN, ANFIS, and the conventional Rogers Ratio method is presented.

### KEYWORDS:

*Adaptive Neuro-Fuzzy Inference System, Artificial Neural Networks, Dissolved Gas Analysis, Fuzzy Logic System, MATLAB, Rogers Ratio Method, Transformer Fault Diagnosis.*

## Περιεχόμενα

ΕΙΣΑΓΩΓΗ: Αντικείμενο, ερευνητικά ερωτήματα και διάρθρωση της εργασίας .....	10
ΚΕΦΑΛΑΙΟ 1: Θεωρητικό πλαίσιο του θέματος – Ανασκόπηση του πεδίου .....	13
1.1 Η θέση του Μετασηματιστή στο ΣΗΕ .....	13
1.2 Είδη καταπονήσεων και εμφάνιση σφαλμάτων σε Μ/Σ Ισχύος ελαίου .....	16
1.3 Μέθοδοι διάγνωσης σφαλμάτων .....	18
1.4 Χημικές μέθοδοι.....	21
1.4.1 Ανίχνευση Αερίων Διαλυμένων στο λάδι (Dissolved Gas Analysis, DGA). .....	21
1.5 Γενικά περί Τεχνητής Νοημοσύνης.....	28
1.5.1 Εφαρμογή μεθόδων Τεχνητής Νοημοσύνης στην DGA .....	29
1.6. Ασαφής Λογική (Fuzzy Logic) .....	29
1.6.1 Έμπειρα Συστήματα (Expert Systems) .....	36
1.6.2 Ασαφή Συστήματα Συμπερασμού-Fuzzy Inference System.....	37
1.7 Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks, ANN) .....	38
1.7.1 Δίκτυα οπισθοδιάδοσης σφάλματος -Backpropagation FF .....	48
1.7.2 Πλεονεκτήματα-μειονεκτήματα ANN .....	53
1.8 Προσαρμοστικό Σύστημα Νευρο-ασαφούς Συμπερασμού -Adaptive Network based Fuzzy Inference System (ANFIS).....	54
1.8.1 Λειτουργία ANFIS, αρχιτεκτονικής πέντε επιπέδων.....	56
ΚΕΦΑΛΑΙΟ 2: Μεθοδολογία της έρευνας.....	58
2.1 Το πρόγραμμα MATLAB.....	58
ΚΕΦΑΛΑΙΟ 3: Η προτεινόμενη μέθοδος – Θεμελίωση, Σχεδίαση, Ανάπτυξη .....	60
3.1 Μεθοδολογία διάγνωσης σφαλμάτων με τη μέθοδο Ασαφούς Συστήματος Συμπερασμού (FIS).....	60
3.1.1 Δημιουργία στο MATLAB Συστήματος Ασαφούς Συμπερασμού - Fuzzy Inference System (FIS).....	60
3.2 Μεθοδολογία διάγνωσης σφαλμάτων με τη μέθοδο Τεχνητών Νευρωνικών Δικτύων (ANN).....	67
3.2.1 Το Neural Network toolbox του MATLAB.....	68
3.3 Μεθοδολογία διάγνωσης σφαλμάτων με την μέθοδο Προσαρμοστικού Συστήματος Νευρο-ασαφούς Συμπερασμού- ANFIS.....	75
3.3.1 Προσομοίωση του Νευρο-Ασαφούς Συστήματος μέσω της εφαρμογής Neuro-Fuzzy Designer του MATLAB .....	76
ΚΕΦΑΛΑΙΟ 4: Εφαρμογή και Αποτελέσματα .....	84



4.1 Εφαρμογή Ασαφούς Λογικής -Fuzzy Logic στην ερμηνεία των αποτελεσμάτων της DGA με τη μέθοδο Rogers. ....	84
4.1.2 Μεθοδολογία διάγνωσης σφαλμάτων με τη μέθοδο TDCG .....	91
4.1.3 Αλλαγή συναρτήσεων συμμετοχής .....	106
4.2 Εφαρμογή Τεχνητών Νευρωνικών Δικτύων στην ερμηνεία των αποτελεσμάτων της DGA με τη μέθοδο Rogers. ....	110
4.3 Εφαρμογή Προσαρμοστικών Συστημάτων Νευρο-ασαφούς Συμπερασμού (ANFIS) στην ερμηνεία των αποτελεσμάτων της DGA με τη μέθοδο Rogers.....	120
ΚΕΦΑΛΑΙΟ 5: Ανάλυση Αποτελεσμάτων – Συζήτηση .....	124
ΚΕΦΑΛΑΙΟ 6: Συμπεράσματα – Προτάσεις.....	128
ΒΙΒΛΙΟΓΡΑΦΙΑ - ΠΗΓΕΣ.....	130
ΠΑΡΑΡΤΗΜΑΤΑ .....	132
Πίνακες Δεδομένων .....	132

## ΕΙΣΑΓΩΓΗ:

### Αντικείμενο, ερευνητικά ερωτήματα και διάρθρωση της εργασίας

---

Η παρούσα εργασία είναι μια παρουσίαση των προηγμένων μεθόδων εκτίμησης λειτουργικής κατάστασης εξοπλισμού Συστημάτων Ηλεκτρικής Ενέργειας με χρήση τεχνικών Τεχνητής Νοημοσύνης. Σε συνέχεια μιας ενδελεχούς αναζήτησης σε δημοσιευμένες μελέτες, παρουσιάζονται τρία είδη τέτοιων τεχνικών. Επιχειρείται η χρήση αυτών στο αντικείμενο της διάγνωσης βλαβών Μετασχηματιστών (Μ/Σ) Ισχύος, μέσω κατάλληλης προσομοίωσης με χρήση του λογισμικού περιβάλλοντος στο πρόγραμμα MATLAB.

Στην εποχή μας που η εξάρτηση από την ηλεκτρική ενέργεια αυξάνεται ολοένα και περισσότερο, τα συστήματα ηλεκτρικής ενέργειας είναι ένας από τους σημαντικότερους τομείς προς μελέτη. Το Σύστημα Ηλεκτρικής Ενέργειας (ΣΗΕ) είναι ένα δίκτυο που αποτελείται από ένα σύνολο διατάξεων, συσκευών και εξοπλισμού που απαιτούνται για την παραγωγή, μεταφορά, διανομή και κατανάλωση ηλεκτρικής ενέργειας. Οι συνθήκες λειτουργίας του συστήματος επηρεάζονται σε πολύ μεγάλο βαθμό από τις διαταραχές της συμπεριφοράς των Μετασχηματιστών (Μ/Σ) Ισχύος. Οι Μετασχηματιστές Ισχύος είναι ένα από τα σημαντικότερα και πλέον κοστοβόρα εξαρτήματα του ΣΗΕ. Μια βλάβη στον Μ/Σ μπορεί να επηρεάσει την σταθερότητα, την αξιοπιστία του συστήματος, και να επιφέρει μεγάλο οικονομικό κόστος προκειμένου να διορθωθεί η βλάβη. Συνεπώς κρίνεται απαραίτητο να γίνεται συνεχής έλεγχος της λειτουργικής κατάστασής τους προκειμένου να αποφευχθούν αστοχίες ή βλάβες τους.

Επιπρόσθετα η ανάπτυξη της Τεχνητής Νοημοσύνης μας προσφέρει τη δυνατότητα δημιουργίας μοντέλων, μέσω των οποίων δύναται να εκτιμηθεί η λειτουργική κατάσταση του εξοπλισμού ενός ΣΗΕ.

*Για τους παραπάνω λόγους επιλέχθηκε, από όλο τον εξοπλισμό ενός ΣΗΕ, στην εργασία αυτή να ασχοληθούμε με την Εκτίμηση Λειτουργικής Κατάστασης των Μ/Σ ισχύος.*

Η εργασία αυτή εξειδικεύεται στη μελέτη:

- ✚ *Εφαρμογής Ασαφούς-Λογικής (F.L.)*
- ✚ *Νευρωνικών Δικτύων (ANN)*
- ✚ *Προσαρμοστικών Συστημάτων Νευρο-ασαφούς Συμπερασμού (ANFIS)*  
*Για τη Διάγνωση σφαλμάτων Μετασχηματιστών Ισχύος.*

**Ειδικότερα στην ερμηνεία των αποτελεσμάτων**, μέσω της ευρέως διαδεδομένης και πλέον αξιόπιστης μεθόδου αναγνώρισης σφαλμάτων, Ανάλυσης Διαλυμένων Αερίων στα έλαια Μ/Σ, ( Dissolved Gas Analysis, DGA). Ο βασικός προβληματισμός, που προκύπτει μελετώντας τα παραπάνω, έγκειται στο γεγονός ότι η συμβατική αυτή μέθοδος (DGA), παρουσιάζει αρκετούς περιορισμούς κατά την εφαρμογή της, καθώς δεν παρέχει ακριβή ανάλυση όλων των σφαλμάτων και απόλυτη αξιοπιστία. Αυτό συμβαίνει συνήθως όταν λαμβάνουν χώρα στον Μ/Σ περισσότερα του ενός σφάλματα ή όταν οι συγκεντρώσεις των εκλυόμενων αερίων είναι κοντά στα όρια τιμών κατωφλίου τους. **Οπότε κρίνεται αναγκαία η χρησιμοποίηση τεχνικών Τεχνητής Νοημοσύνης προκειμένου να αντιμετωπιστούν τα προβλήματα αυτά και να βελτιωθεί η αξιοπιστία της μεθόδου.**

**Στο πρώτο κεφάλαιο** παρουσιάζεται το θεωρητικό πλαίσιο, μέσα στο οποίο θα αναπτυχθεί η εργασία. Στην πρώτη ενότητα περιγράφεται η θέση του Μ/Σ στο δίκτυο, τα είδη των καταπονήσεων, στα οποία υπόκειται ο Μ/Σ και τα σφάλματα που λαμβάνουν χώρα σε αυτόν, ως συνέπεια των παραπάνω καταπονήσεων. Στη συνέχεια δίδονται οι συμβατικές μέθοδοι διάγνωσης σφαλμάτων και ταξινομούνται σε κατηγορίες. Τέλος, περιγράφονται οι χημικές μέθοδοι και ειδικά η Ανάλυση Διαλυμένων Αερίων στο λάδι.

Ακολουθεί η δεύτερη ενότητα, με μια θεωρητική ανασκόπηση περί Τεχνητής Νοημοσύνης.

Η πρώτη τεχνική, που επιλέχθηκε να μελετηθεί και να παρουσιασθεί στην τρίτη ενότητα, αναφέρεται στη χρήση της θεωρίας της Ασαφούς Λογικής, για την ανάπτυξη ενός Ασαφούς Συστήματος Συμπερασμού - Fuzzy Inference System (FIS).

Η τέταρτη ενότητα αναφέρεται στη θεωρητική ανασκόπηση των Τεχνητών Νευρωνικών Δικτύων (ANN). Το πρώτο κεφάλαιο ολοκληρώνεται με την πέμπτη ενότητα, στην οποία περιγράφεται ένα Προσαρμοστικό Σύστημα Νευρο-ασαφούς Συμπερασμού- Adaptive Network based Fuzzy Inference System (ANFIS )

**Στο δεύτερο κεφάλαιο** γίνεται αναφορά στο πρόγραμμα MATLAB, που θα χρησιμοποιηθεί για την προσομοίωση του κάθε μοντέλου ξεχωριστά.

**Στο τρίτο κεφάλαιο** περιγράφεται η προτεινόμενη μέθοδος, που αντιμετωπίζει το υπό διερεύνηση θέμα και δίνονται τα βήματα της σχεδίασης και ανάπτυξης ενός FIS, ANN και ANFIS .

**Στο τέταρτο κεφάλαιο** περιγράφεται η υλοποίηση της προτεινόμενης μεθόδου, δηλαδή η ανάπτυξη των τριών μεθόδων ΑΙ. Παρουσιάζονται τα διαγράμματα και οι πίνακες που εξήχθησαν από την αντίστοιχη προσομοίωση στο MATLAB.

**Στο πέμπτο κεφάλαιο** πραγματοποιείται η ανάλυση και ο σχολιασμός των προαναφερθέντων αποτελεσμάτων και η συγκριτική παρουσίαση των FIS, ANN, ANFIS, που αναπτύχθηκαν και της συμβατικής μεθόδου Rogers Ratio.

**Στο έκτο κεφάλαιο** διατυπώνονται τα συμπεράσματα, που εξάγονται από την παραπάνω μελέτη.

# ΚΕΦΑΛΑΙΟ 1:

## Θεωρητικό πλαίσιο του θέματος – Ανασκόπηση του πεδίου

---

### 1.1 Η θέση του Μετασχηματιστή στο ΣΗΕ

*Το Σύστημα Ηλεκτρικής Ενέργειας (ΣΗΕ)* είναι ένα δίκτυο, που αποτελείται από ένα σύνολο διατάξεων, συσκευών και εξοπλισμού που απαιτούνται για την παραγωγή, μεταφορά, διανομή και κατανάλωση ηλεκτρικής ενέργειας. Ένα συμβατικό ΣΗΕ συνοπτικά αποτελείται από τα εξής κύρια μέρη:

#### *Παραγωγή*

- Περιλαμβάνει τις μονάδες ηλεκτροπαραγωγής, που ηλεκτροδοτούν το σύστημα. Ορισμένα παραδείγματα μονάδων παραγωγής ενέργειας είναι οι θερμικοί, υδροηλεκτρικοί και πυρηνικοί σταθμοί.

#### *Μεταφορά*

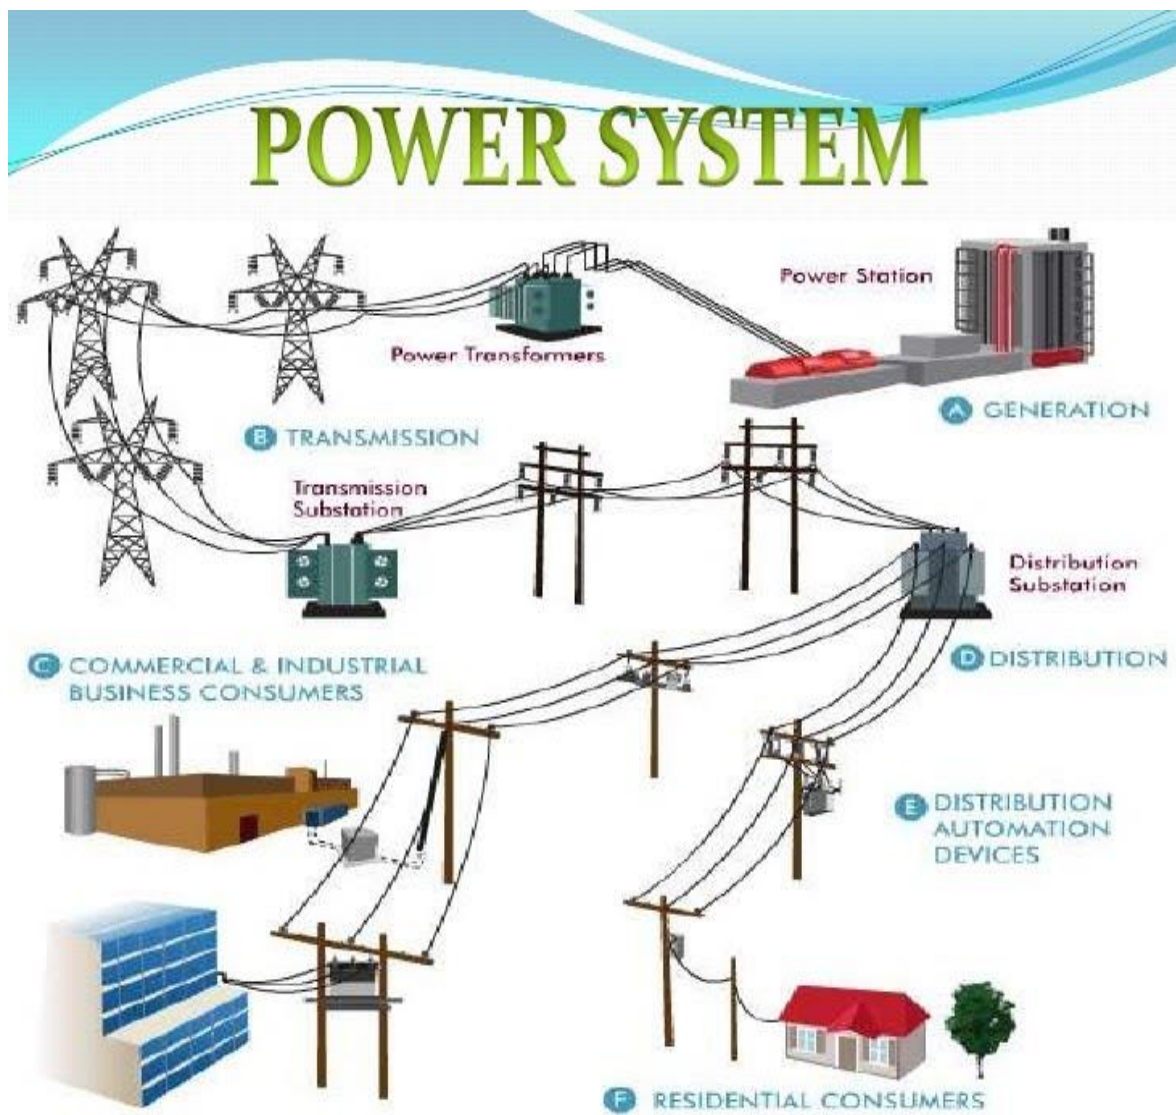
- Αποτελείται από γραμμές μεταφοράς, που μεταφέρουν την ισχύ από τις μονάδες ηλεκτροπαραγωγής στο σύστημα διανομής.

#### *Διανομή*

- Είναι το δίκτυο που τροφοδοτεί με ηλεκτρική ισχύ του καταναλωτές

#### *Κατανάλωση*

- Το φορτίο αντιπροσωπεύει την κατανάλωση ισχύος του συστήματος. Περιλαμβάνει νοικοκυριά, νοσοκομεία, εμπορικά κτίρια και βιομηχανίες μικρού και μεσαίου μεγέθους, κτλ.



Σχήμα 1.1. Σύστημα Ηλεκτρικής Ενέργειας

Οι κυριότεροι τύποι εξοπλισμού ενός ΣΗΕ είναι:

- Οι γεννήτριες παραγωγής ηλεκτρικής ενέργειας
- Οι γραμμές μεταφοράς και διανομής
- Οι μετασχηματιστές ισχύος
- Οι μετασχηματιστές μέτρησης ( τάσης, ρεύματος)
- Τα μέσα προστασίας που προσφέρουν ασφάλεια και αδιάλειπτη λειτουργία ακόμα και σε περίπτωση βλάβης
- Ο εξοπλισμός ρύθμισης τάσης, που χρησιμοποιείται για να διατηρεί την τάση μέσα σε επιτρεπτά όρια, καθώς το φορτίο μεταβάλλεται (πυκνωτές αντιστάθμισης, ρυθμιστές τάσης)

- Τα συστήματα γείωσης
- Λοιπός βοηθητικός εξοπλισμός

Η ανύψωση ή ο υποβιβασμός της τάσης από το ένα σύστημα ισχύος στο άλλο επιτελείται κυρίως μέσω Μετασχηματιστών Ισχύος (Μ/Σ) :

- Για την ανύψωση της τάσης στα εργοστάσια παραγωγής (20kV/150 kV ή 20kV/400 kV).
- Για τον υποβιβασμό της τάσης στα δίκτυα διανομής (150 kV/20kV ή 400 kV/20kV)
- Για τον υποβιβασμό της τάσης και τη διανομή της ενέργειας στους καταναλωτές (20kV/400V).

Μια βλάβη σε έναν Μ/Σ Ισχύος μπορεί να επηρεάσει την σταθερότητα και αξιοπιστία του συστήματος, και να επιφέρει μεγάλο οικονομικό κόστος προκειμένου να διορθωθεί η βλάβη, καθώς είναι ένα από τα σημαντικότερα και ακριβότερα εξαρτήματα του.

Συνεπώς κρίνεται απαραίτητο να γίνεται συνεχής έλεγχος της λειτουργικής κατάστασής τους προκειμένου να αποφευχθούν αστοχίες ή βλάβες τους.

***Το θέμα που αναλύεται, ακολούθως, είναι η διάγνωση σφαλμάτων Μετασχηματιστών Ισχύος Ελαίου.***

Η προσέγγιση γίνεται μέσω της ευρέως διαδεδομένης και πλέον αξιόπιστης μεθόδου αναγνώρισης σφαλμάτων της Ανάλυσης Διαλυμένων Αερίων στο λάδι (Dissolved Gas Analysis, DGA). Παρουσιάζονται οι τέσσερις πιο διαδεδομένοι τρόποι ανάλυσης της DGA.

- Μέθοδος ερμηνείας μέσω του κύριου αερίου, (Key Gas Method)
- Μέθοδος Doernenburg
- Μέθοδος Rogers
- Μέθοδος του τριγώνου Duval

Γίνεται περιγραφή για τη λειτουργία της κάθε μεθόδου προκειμένου να αναγνωρίσει το εκάστοτε σφάλμα και συνοπτικά, αναφέρονται τα θετικά και αρνητικά χαρακτηριστικά τους. Ο βασικός προβληματισμός, που προκύπτει μελετώντας τα παραπάνω, έγκειται στο γεγονός ότι οι συμβατικές αυτές μέθοδοι παρουσιάζουν αρκετούς περιορισμούς. Οπότε κρίνεται αναγκαία η χρησιμοποίηση κάποιων άλλων τεχνικών που θα παρέχουν αξιόπιστα αποτελέσματα. Οι προηγμένες αυτές μέθοδοι αναπτύσσονται ολοένα και περισσότερο και χρησιμοποιούν την Τεχνητή Νοημοσύνη και την Ασαφή Λογική.

## 1.2 Είδη καταπονήσεων και εμφάνιση σφαλμάτων σε Μ/Σ Ισχύος ελαίου

Τα κυριότερα είδη καταπονήσεων που υφίσταται ένας Μ/Σ ισχύος κατατάσσονται σε μία ή και περισσότερες από τις επόμενες τρεις κατηγορίες:

- Μηχανικές: Περιλαμβάνουν καταπονήσεις μεταξύ των αγωγών, ακροδεκτών και τυλιγμάτων εξαιτίας υπερεντάσεων βραχείας διάρκειας και ρευμάτων βραχυκύκλωσης. Τα τελευταία οφείλονται σε βραχυκυκλώματα και ρεύματα εισροής υπό συνθήκες ηλεκτρίσης.
- Θερμικές: Περιλαμβάνουν καταπονήσεις που οφείλονται στη θερμότητα ή σε τοπικές υπερθερμάνσεις, που έχουν σχέση με τις υπερεντάσεις και τη ροή σκέδασης κατά τη φόρτιση πέραν της ονομαστικής τιμής ή λόγω δυσλειτουργίας του συστήματος ψύξης.
- Διηλεκτρικές: Περιλαμβάνουν καταπονήσεις που οφείλονται σε υπερτάσεις του συστήματος, παροδικές κρουστικές τάσεις ή εσωτερική αντήχηση στα τυλίγματα.

Οι βλάβες είναι συνήθως αποτέλεσμα :

- βραχυκυκλωμάτων
- τοπικών υπερθερμάνσεων
- σφαλμάτων του συστήματος μόνωσης (σφάλματα διηλεκτρικού)
- βλαβών στον εξοπλισμό (μονωτήρες διέλευσης, μεταγωγείς λήψεων, σύστημα ψύξεως, αλεξικέραυνα, κλπ)
- γήρανση του εξοπλισμού.

Η χρονική διάρκεια εξέλιξης ενός σφάλματος εξαρτάται από το αίτιο, που την προκάλεσε. Μια βλάβη μπορεί να δημιουργηθεί σε δευτερόλεπτα ή και να αναπτύσσεται σταδιακά, σε χρονικό διάστημα που μπορεί να φτάνει και χρόνια. Σφάλματα που εμφανίζονται σε πολύ μικρό χρονικό διάστημα, της τάξης των μερικών δευτερολέπτων, μπορεί να οφείλονται σε βραχυκυκλώματα, υπερτάσεις ή κεραυνικά πλήγματα. Τα τοπικά σφάλματα αναπτύσσονται σε βδομάδες ή και μήνες. Η υποβάθμιση της μόνωσης των τυλιγμάτων υψηλής τάσης πραγματοποιείται σε διάστημα μηνών ή και ετών.

Στον παρακάτω Πίνακα παρουσιάζεται η κατηγοριοποίηση των σφαλμάτων των Μ/Σ Ισχύος ελαίου.



Πίνακας 1.1. Κατηγοριοποίηση σφαλμάτων Μ/Σ Ισχύος ελαίου.

<i>Διηλεκτρικές</i>	<i>Θερμικές</i>	<i>Μηχανικές</i>
<ul style="list-style-type: none"> <li>○ Μερικές εκκενώσεις (Partial Discharge)</li> <li>○ Φαινόμενο Κορώνα (Corona)</li> <li>○ Ηλεκτρικά Τόξα (Arcing)</li> <li>○ Διάσπαση του μονωτικού λαδιού (Break down voltage of oil )</li> </ul>	<ul style="list-style-type: none"> <li>○ Υπερθέρμανση ελαίου (Oil Overheating)</li> <li>○ Υπερθέρμανση κυτταρίνης (Cellulose Overheating)</li> </ul>	<ul style="list-style-type: none"> <li>○ Καταπονήσεις Τυλιγμάτων και Πυρήνα (Winding and Core Deformations)</li> </ul>

Η παρακολούθηση, η εκτίμηση και η διάγνωση της κατάστασης των Μ/Σ Ισχύος είναι πρωταρχικής σημασίας. Τα δεδομένα της παρακολούθησης λαμβάνονται σε πραγματικό χρόνο μέσω κατάλληλων συσκευών. Η επεξεργασία αυτών των δεδομένων γίνεται είτε τοπικά από τις ίδιες τις συσκευές, είτε απομακρυσμένα από ηλεκτρονικούς υπολογιστές.

Πίνακας 1.2. Συσχέτιση σφάλματος- αιτίας

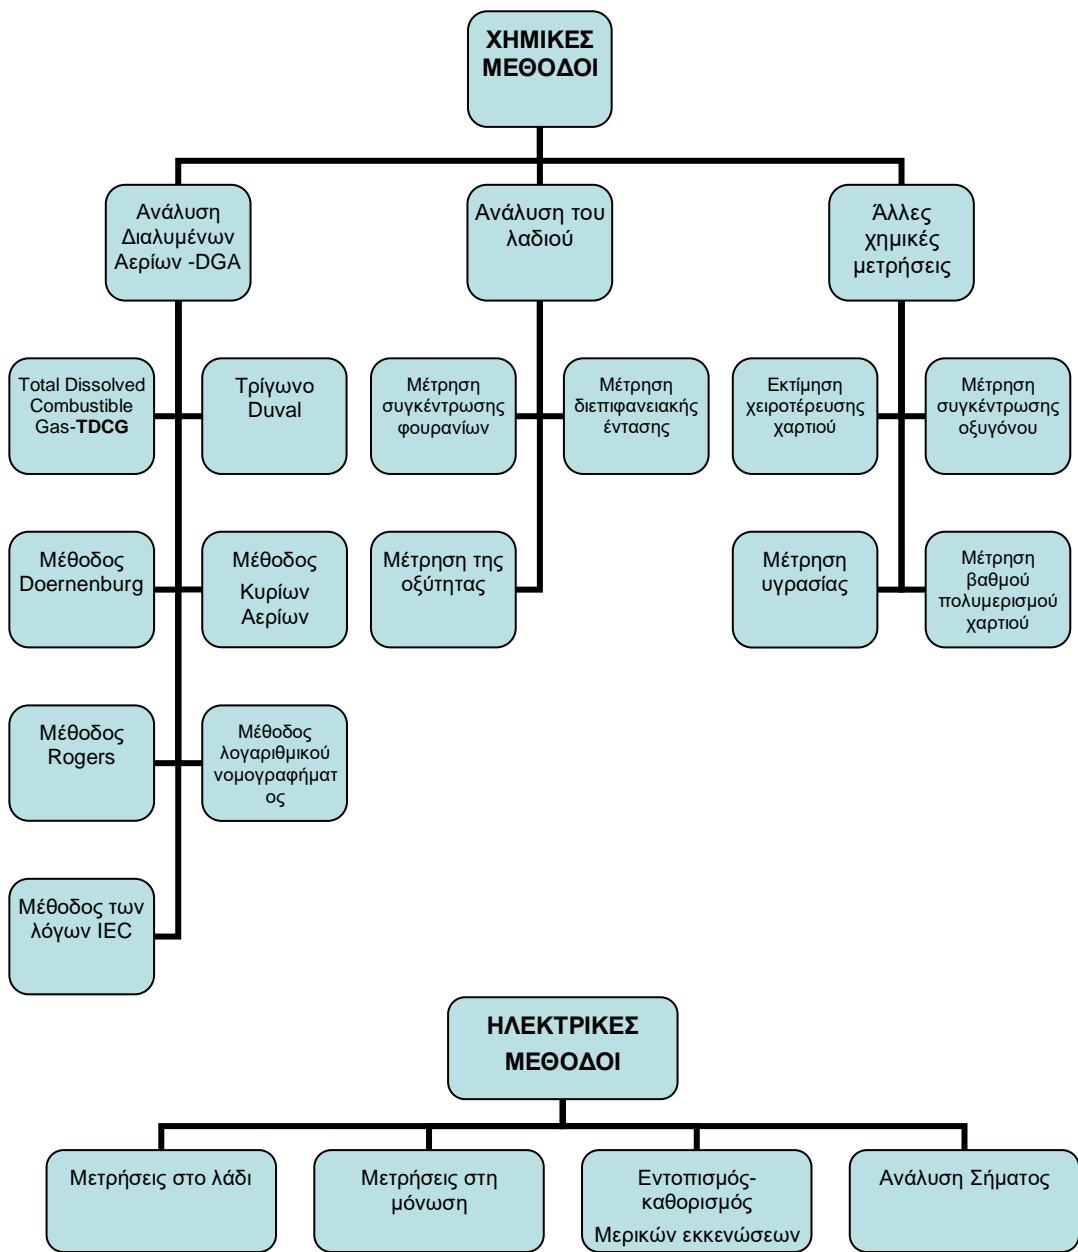
CAUSES	FAULTS			
	Arcing	Corona	Overheating of cellulose	Overheating of oil
Winding turn-to turn short-circuit	X		X	
Winding open circuit	X		X	
Operation of build-in LTC	X			
Winding distortion or displacement		X	X	
Lead distortion or displacement		X	X	

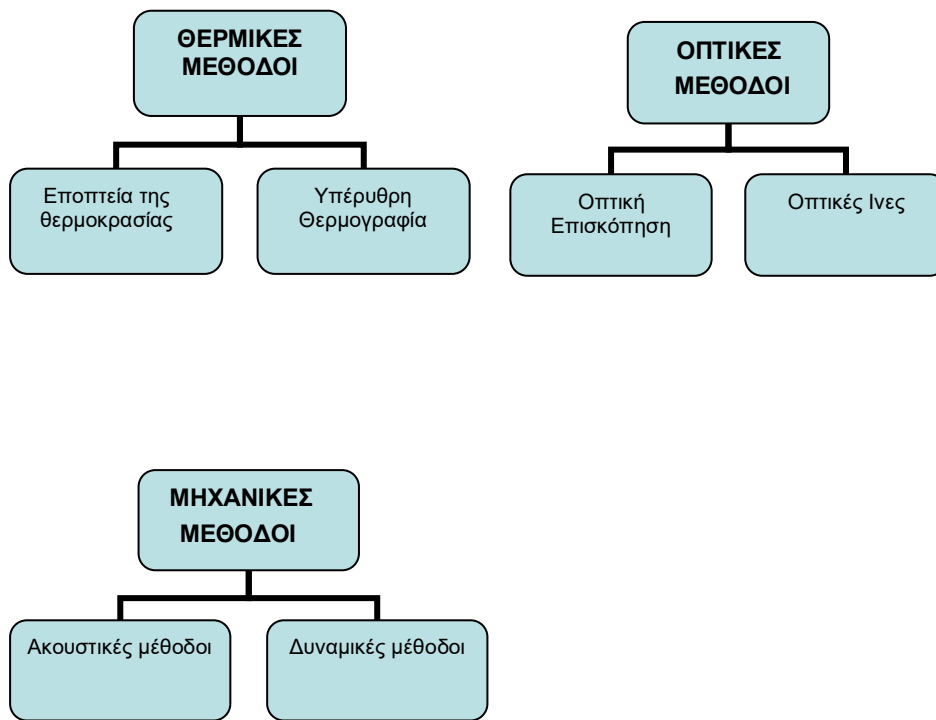
Loose connection to bushing terminals, tap leads, terminal boards	X	X	X	
Free water or excessive moisture in oil	X	X		
Floating metal particles	X	X		
Loose connection to corona shields		X		
Loose collars, spacers, core ground straps		X		
Through fault			X	
Overloading			X	X
Damaged yoke bolt insulation				X
Rust or other damage on core				X
Damaged shunt packs of tank				X
Jammed oil circulating path				X
Cooling system malfunction				X

### 1.3 Μέθοδοι διάγνωσης σφαλμάτων

Οι συμβατικές διαγνωστικές μέθοδοι που χρησιμοποιούνται για τον εντοπισμό και τη διάγνωση σφαλμάτων στους μεγάλους Μ/Σ Ισχύος ελαίου χωρίζονται στις εξής κατηγορίες:

- Χημικές
- Ηλεκτρικές
- Θερμικές
- Οπτικές
- Μηχανικές





Σχήμα 1.2. Συμβατικές διαγνωστικές μέθοδοι Σφαλμάτων Μ/Σ Ισχύος

Οι πιο σημαντικές είναι οι χημικές και κάποιες από τις ηλεκτρικές μεθόδους. Στην παρούσα φάση θα ασχοληθούμε με τις χημικές διαγνωστικές μεθόδους, οι οποίες είναι και οι πιο αξιόπιστες. Ένας από τους λόγους της ακρίβειάς τους είναι η ανάπτυξη της τεχνολογίας των αισθητήρων. Κατά τις χημικές μεθόδους ελέγχεται κατά πόσο είναι ικανοποιητική η κατάσταση των μονώσεων του Μ/Σ Ισχύος.

Η μόνωση του Μ/Σ αποτελείται από: **το ηλεκτρομονωτικό χαρτί**, για τη μόνωση των αγωγών των τυλιγμάτων, και **το μονωτικό λάδι**, το οποίο παρέχει ηλεκτρική μόνωση μεταξύ των τυλιγμάτων και τυλιγμάτων-γης και συντελεί στη μεταφορά της θερμότητας από τον πυρήνα και τα τυλίγματα, προς το εξωτερικό σύστημα ψύξης. Τόσο το έλαιο όσο και το υλικό στερεάς μόνωσης υπόκεινται σε χημικές διεργασίες κατά τη λειτουργία του μετασχηματιστή εξαιτίας της υγρασίας, του οξυγόνου και της θερμοκρασίας.

## 1.4 Χημικές μέθοδοι

### 1.4.1 Ανίχνευση Αερίων Διαλυμένων στο λάδι (*Dissolved Gas Analysis, DGA*).

Η μέθοδος των Διαλυμένων Αερίων (DGA) αποτελεί ένα από τα σημαντικότερα εργαλεία εκτίμησης της κατάστασης ενός Μ/Σ Ισχύος ελαίου. Το μονωτικό έλαιο του Μ/Σ αποσυντίθεται λόγω υπερθέρμανσης ή λόγω ηλεκτρικής καταπόνησης. Η διάσπαση αυτή οφείλεται στη διάσπαση των δεσμών υδρογόνου-άνθρακα και άνθρακα-άνθρακα. Τα αέρια που ανιχνεύονται διαλυμένα στο λάδι είναι: CO, CO<sub>2</sub>, CH<sub>4</sub> (Μεθάνιο), C<sub>2</sub>H<sub>2</sub> (Ακετυλένιο), C<sub>2</sub>H<sub>4</sub> (Αιθυλένιο) και C<sub>2</sub>H<sub>6</sub> (Αιθάνιο).

Η χημική μέθοδος DGA σε γενικές γραμμές περιγράφεται ως εξής : Κατά τη διαδικασία διαμόρφωσης σφαλμάτων παράγονται διάφορα αέρια. Οι μετρήσεις των αερίων μπορούν να ερμηνευτούν με διάφορες μεθόδους, ώστε να ταυτοποιήσουν το εκάστοτε σφάλμα. Μπορεί να ανιχνεύσει υποβαθμισμένη μόνωση, υπερθέρμανση, θερμά σημεία, μερικές εκκενώσεις και ηλεκτρικά τόξα. Η μέθοδος εφαρμόζεται χωρίς να απαιτείται διακοπή της λειτουργίας του μετασχηματιστή.

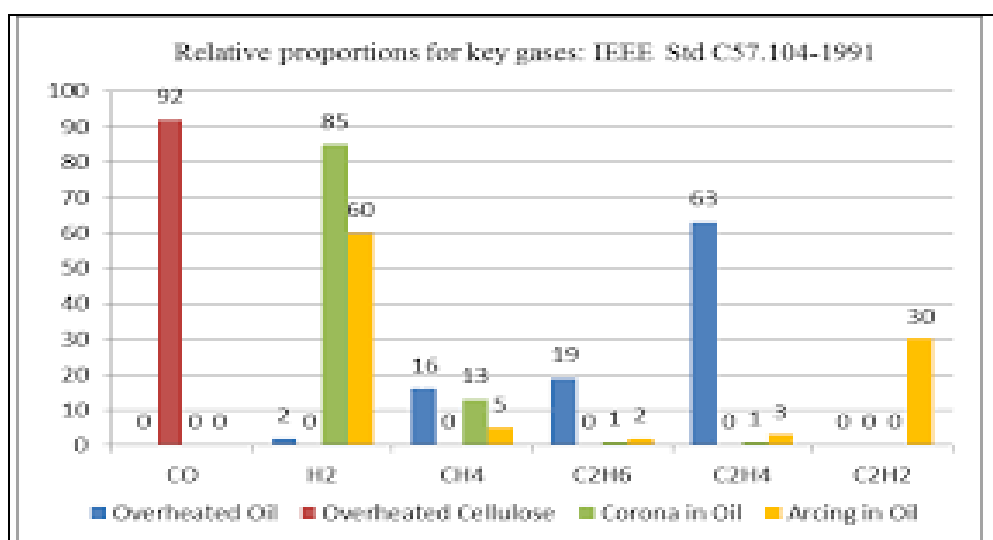
#### 1.4.1.α Μέθοδος ερμηνείας μέσω του Κύριου Αερίου (*key Gas Method*)

Κάθε είδος καταπόνησης παράγει ορισμένα αέρια σε μεγαλύτερη ποσότητα από άλλα. Το αέριο το οποίο έχει τη μεγαλύτερη συγκέντρωση σε parts per million (ppm), ονομάζεται κύριο αέριο. Η συσχέτιση των διαφορών αερίων με το είδος της καταπόνησης είναι η εξής:

- Μονοξείδιο του άνθρακα και διοξείδιο του άνθρακα (CO και CO<sub>2</sub>): Υποδηλώνει θερμική γήρανση του χαρτιού.
- Μεθάνιο, Αιθάνιο και Αιθυλένιο (CH<sub>4</sub>, C<sub>2</sub>H<sub>6</sub> και C<sub>2</sub>H<sub>4</sub>) : Υποδηλώνει θερμική διάσπαση του μονωτικού λαδιού. Συγκεκριμένοι λόγοι αυτών των αερίων δείχνουν υπερθέρμανση.
- Υδρογόνο (H<sub>2</sub>): Μερικές εκκενώσεις χαμηλής ενέργειας ( φαινόμενο Corona)
- Ακετυλένιο (C<sub>2</sub>H<sub>2</sub>): Μερικές εκκενώσεις υψηλής ενέργειας ή ηλεκτρικά τόξα.

Πίνακας 1.3. Συσχέτιση αερίων με το είδος Σφαλμάτων

ΣΦΑΛΜΑΤΑ	ΑΕΡΙΑ
Υπερθέρμανση Λαδιού	C <sub>2</sub> H <sub>4</sub> , C <sub>2</sub> H <sub>6</sub>
Υπερθέρμανση Κυτταρίνης	CO, CO <sub>2</sub>
Μερικές Εκκενώσεις	H <sub>2</sub> and CH <sub>4</sub>
Τόξα	All gases, traceable amount of C <sub>2</sub> H <sub>2</sub>



Σχήμα 1.3. Συγκέντρωση Διαλυμένων Αερίων (ppm) και αντίστοιχη αστοχία.

Γενικά χαρακτηριστικά μεθόδου:

- ✓ Είναι μια ταχεία προσεγγιστική μέθοδος, εύκολα εφαρμόσιμη.
- ✓ Καθορίζει εάν υπάρχει σφάλμα ή όχι στον Μ/Σ.
- ✓ Παρέχει χαμηλή αξιοπιστία καθώς καθορίζει μόνο τέσσερις τύπους γενικών σφαλμάτων και δεν προσδίδει λεπτομερή ταυτοποίηση του σφάλματος.
- ✓ Παρόλο που συχνά διαγιγνώσκει εσφαλμένα αποτελέσματα χρησιμοποιείται ευρέως λόγω της ταχύτητας και ευκολίας στην εφαρμογή της.

#### 1.4.1.β Μέθοδος Doernenburg

Επειδή η προέλευση του κάθε αερίου δεν είναι αποκλειστικά από μία μόνο αιτία, για την εκτίμηση των σφαλμάτων χρησιμοποιούνται οι παρακάτω λόγοι μεταξύ των αερίων:

$$R1 = CH_4/H_2$$

$$R2 = C_2H_2/C_2H_4$$

$$R3 = C_2H_2/CH_4$$

$$R4 = C_2H_6 / C_2H_2$$

Η μέθοδος Doernenburg μπορεί να αναγνωρίσει τρεις τύπους σφαλμάτων:

- Θερμική αποσύνθεση λαδιού
- Μερικές Εκκενώσεις χαμηλής στάθμης ενέργειας, φαινόμενο corona
- Μερικές Εκκενώσεις υψηλής στάθμης ενέργειας, arcing

Πρόβλημα στον Μ/Σ υπάρχει αν οι συγκεντρώσεις των εκλυόμενων αερίων υπερβαίνουν τα όρια σύμφωνα με τον Πίνακα 1.4 του Doernenburg.

Τότε ακολουθούνται τα επόμενα βήματα για την ανίχνευση της βλάβης:

- ❖ **Βήμα πρώτο:** ελέγχουμε από τον Πίνακα 1.4 αν υπάρχει κάποιο αέριο με συγκέντρωση διπλάσια και πλέον αυτής που αναγράφεται στον πίνακα και η συγκέντρωση των υπολοίπων είναι μεγαλύτερη αυτής του πίνακα.
- ❖ **Βήμα δεύτερο:** από τον Πίνακα 1.5 πρέπει ένας τουλάχιστον λόγος αερίων να υπερβαίνει τα όρια του πίνακα, ειδάλλως ανατρέχουμε σε άλλη μέθοδο εκτίμησης.
- ❖ **Βήμα τρίτο:** συγκρίνονται οι λόγοι R1,R2,R3,R4 με τους αντίστοιχους του Πίνακα 1.5. Για να ισχύει ένα σφάλμα πρέπει και οι τέσσερις λόγοι να βρίσκονται ανάμεσα στα όρια των τιμών του εκάστοτε σφάλματος.

Πίνακας 1.4. Συγκεντρώσεις Κύριων Αερίων

Κύρια Αέρια	H <sub>2</sub>	CO	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
Συγκεντρώσεις Αερίων (ppm)	100	350	120	35	50	65

Πίνακας 1.5. Λόγοι Αερίων

Ratios for Key Gases – Doernenburg Ratio Method								
Suggested Fault Diagnosis	Ratio 1 (R1) CH <sub>4</sub> /H <sub>2</sub>		Ratio 2 (R2) C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub>		Ratio 3 (R3) C <sub>2</sub> H <sub>2</sub> /CH <sub>4</sub>		Ratio 4 (R4) C <sub>2</sub> H <sub>6</sub> /C <sub>2</sub> H <sub>2</sub>	
	Oil	Gas space	Oil	Gas space	Oil	Gas space	Oil	Gas space
Thermal Decomposition	>1.0	>0.1	<0.75	<1.0	<0.3	<0.1	>0.4	>0.2
Corona (Low Intensity PD)	<0.1	<0.01	Not Significant		<0.3	<0.1	>0.4	>0.2
Arching (High Intensity PD)	>0.1 <0.1	>0.01 <0.1	>0.75	>1.0	>0.3	>0.1	<0.4	<0.2

Τα αρνητικά της μεθόδου είναι:

- ✓ Διαγιγνώσκει μόνο τρεις τύπους σφαλμάτων

- ✓ Δεν μπορεί να γίνει διάγνωση σε σημαντικό αριθμό περιπτώσεων λόγω του ότι κάποιες φορές δημιουργούνται λόγοι που δεν ανήκουν στο εύρος των σφαλμάτων του πίνακα της μεθόδου.
- ✓ Είναι μια περίπλοκη μέθοδος.

#### 1.4.1.γ Μέθοδος Rogers

Κατά τη μέθοδο **Rogers** χρησιμοποιούνται τέσσερις λόγοι συγκέντρωσης αερίων (λόγοι του Rogers):

$$X_1 = \text{CH}_4/\text{H}_2$$

$$X_2 = \text{C}_2\text{H}_4/\text{C}_2\text{H}_6$$

$$X_3 = \text{C}_2\text{H}_2/\text{C}_2\text{H}_4$$

$$X_4 = \text{C}_2\text{H}_6/\text{CH}_4$$

Για να είναι έγκυρη η μέθοδος πρέπει να έχει παραχθεί μια μεγάλη ποσότητα αερίων. Ειδικά πρέπει η ποσότητα των αερίων όλων των λόγων να είναι μεγαλύτερη από το δεκαπλάσιο της ποσότητας που μπορεί να ανιχνεύσει ο αεριοχρωματογράφος. Αυτό για να αποφευχθεί να υπεισέλθουν σφάλματα στους λόγους αερίων από τις ανακρίβειες της συσκευής. Το εύρος κάθε λόγου αερίου αντιστοιχεί σε ένα συγκεκριμένο σφάλμα. Μπορούν να ανιχνευθούν 12 τύποι σφαλμάτων: Τα παραπάνω απεικονίζονται στον Πίνακα 1. 7.

Πίνακας 1.6. Κωδικοί Roger's Ratio <sup>14</sup>

Ratio Code	Range	Code
MH ( CH <sub>4</sub> /H <sub>2</sub> )	x < 0.1	5
	0.1 ≤ x ≤ 1.0	0
	1.0 ≤ x ≤ 3.0	1
	x > 3.0	2
EM ( C <sub>2</sub> H <sub>6</sub> / CH <sub>4</sub> )	x < 1.0	0
	x ≥ 1.0	1
EE ( C <sub>2</sub> H <sub>4</sub> / C <sub>2</sub> H <sub>6</sub> )	x < 1.0	0
	1.0 ≤ x ≤ 3.0	1
	x > 3.0	2
AE ( C <sub>2</sub> H <sub>2</sub> / C <sub>2</sub> H <sub>4</sub> )	x < 0.1	0



	$0.1 \leq x \leq 3.0$	1
	$x > 3.0$	2

Ως περιορισμοί της μεθόδου μπορούν να αναφερθούν τα εξής:

- ✓ Πρέπει πρώτα μέσω άλλης μεθόδου να αναγνωρισθεί η ύπαρξη σφάλματος και μετά η μέθοδος να καθορίσει το είδος του.
- ✓ Κάποιες φορές δημιουργούνται λόγοι, που δεν ανήκουν στο εύρος των σφαλμάτων του πίνακα της μεθόδου.
- ✓ Γενικά η μέθοδος αυτή χρειάζεται συνεργασία με άλλες μεθόδους, προκειμένου να διεξάγει ένα έγκυρο και ξεκάθαρο αποτέλεσμα.

**Πίνακας 1.7.** Συσχέτιση Κωδικών με είδος βλάβης

No.	CH <sub>4</sub> /H <sub>2</sub>	C <sub>2</sub> H <sub>6</sub> /CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub>	Fault Type
1	0	0	0	0	No Fault
2	1-2	0	0	0	<150 °C Thermal Fault
3	1-2	1	0	0	150–200 °C Thermal Fault
4	0	1	0	0	200–300 °C Thermal Fault
5	0	0	1	0	General Conductor Overheating
6	1	0	1	0	Winding Circulating Currents
7	1	0	2	0	Core and Tank Circulating Currents Overheated Joints
8	5	0	0	0	Partial Discharge
9	5	0	0	1-2	Partial Discharge With Tracking
10	0	0	0	1	Flashover Without Power Follow-Through
11	0	0	1-2	1-2	Arc with power follow-through

12	0	0	2	2	Continuous sparking to floating potential
----	---	---	---	---	---

#### 1.4.1.δ Το τρίγωνο Duval

Κατά μέθοδο του τριγώνου Duval λαμβάνονται οι συγκεντρώσεις τριών αερίων:

- Μεθανίου ( $\text{CH}_4$ ),
- Αιθυλενίου ( $\text{C}_2\text{H}_4$ )
- Ακετυλενίου ( $\text{C}_2\text{H}_2$ )

Τα αέρια αυτά εκφράζονται σαν εκατοστιαία ποσοστά του αθροίσματος ( $\text{CH}_4 + \text{C}_2\text{H}_4 + \text{C}_2\text{H}_2$ ). Στη συνέχεια σχεδιάζονται σε ένα τριγωνικό σύστημα συντεταγμένων τα σημεία ( $\% \text{CH}_4$ ,  $\% \text{C}_2\text{H}_4$ ,  $\% \text{C}_2\text{H}_2$ ) μέσα σε έναν τριγωνικό χάρτη ,που χωρίζεται σε ζώνες σφαλμάτων.

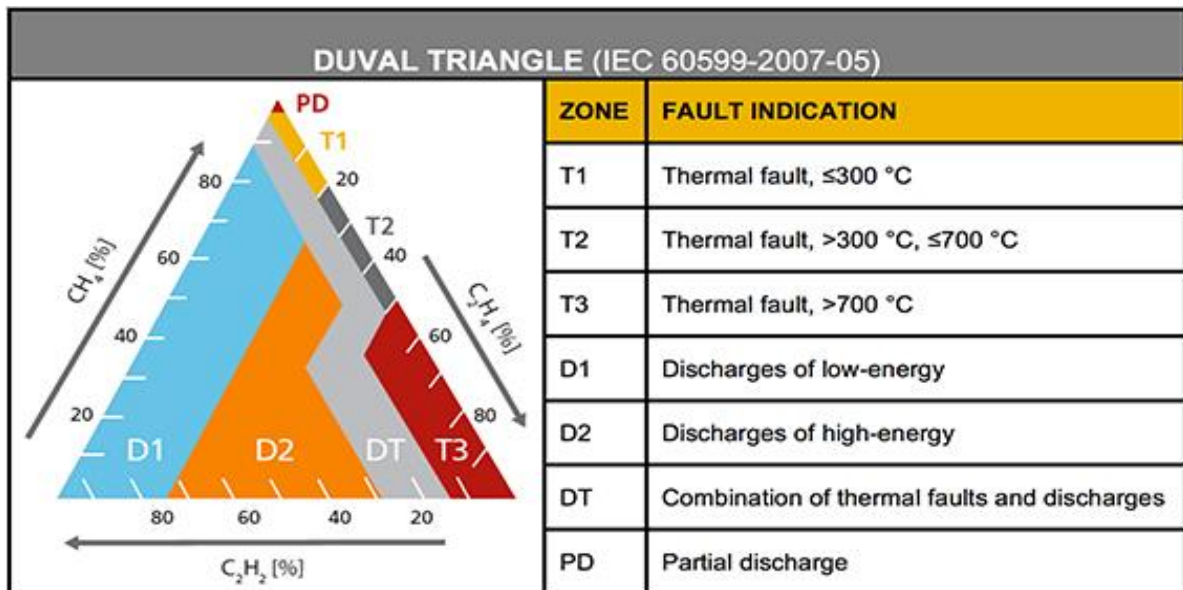
Η ζώνη σφάλματος στην οποία εμπίπτει το κάθε σημείο μας δίνει τον τύπο του σφάλματος που παρήγαγε τον συνδυασμό των τριών αερίων.

Μπορούν να ανιχνευθούν τρεις τύποι σφαλμάτων (συνολικά 7 ζώνες σφαλμάτων) :

- Μερικές Εκκενώσεις (partial discharge)
- Ηλεκτρικές Βλάβες (high and low energy arcing)
- Θερμικές Βλάβες (hot spots of various temperature ranges).

Στο Πίνακα 1.8 απεικονίζεται ένα τρίγωνο Duval όπου μπορούν να διακριθούν οι ζώνες σφαλμάτων.

Πίνακας 1. 8. IEC 60599: Duval triangle <sup>7</sup>



Η μέθοδος Duval χαρακτηρίζεται από τα ακόλουθα :

- ✓ είναι μια ακριβής και αξιόπιστη μέθοδος ανίχνευσης σφαλμάτων.
- ✓ είναι σχετική απλή στην εφαρμογή της.
- ✓ μπορεί να ανιχνεύσει μέχρι έξι σφάλματα.
- ✓ διαγιγνώσκει το σφάλμα αλλά δεν το εντοπίζει, πρέπει να έχει επιβεβαιωθεί πριν η ύπαρξη σφάλματος από τα IEEE standards.
- ✓ Όλες οι περιοχές του τριγώνου περιγράφουν σφάλματα οπότε αν η μέθοδος διενεργηθεί για έναν Μ/Σ χωρίς βλάβη και σε αυτόν θα δείξει σφάλμα.

## 1.5 Γενικά περί Τεχνητής Νοημοσύνης

Η **Τεχνητή Νοημοσύνη** είναι ένας κλάδος της πληροφορικής, ο οποίος ασχολείται με τη σχεδίαση και την υλοποίηση υπολογιστικών συστημάτων, που μιμούνται στοιχεία της ανθρώπινης συμπεριφοράς, τα οποία υπονοούν έστω και στοιχειώδη ευφυΐα: μάθηση, προσαρμοστικότητα, εξαγωγή συμπερασμάτων, κατανόηση από συμφραζόμενα, επίλυση προβλημάτων κλπ.

Ο όρος Τεχνητή Νοημοσύνη (Artificial Intelligence-AI) αναφέρεται συνήθως στη διαχείριση μιας ευφυούς μηχανής μέσω υπολογιστή. Χρησιμοποιείται για τη μετατροπή της ανθρώπινης εμπειρίας και λογικής σε μορφή τέτοια ώστε να είναι κατανοητή από τη μηχανή - computer.

*Οι τεχνικές της Τεχνητής Νοημοσύνης λέγονται και Ευφυή Συστήματα. Οι τεχνικές αυτές «μεταφράζουν» τη λογική του ανθρώπου στις μηχανές.*

Ο συνδυασμός της τεχνητής νοημοσύνης και της θεωρίας των συστημάτων δημιούργησε ένα νέο επιστημονικό κλάδο αυτό της Υπολογιστικής Νοημοσύνης (Computational Intelligence).

Η Υπολογιστική Νοημοσύνη εμπεριέχει τρία βασικά επιστημονικά πεδία :

- ✚ τα Συστήματα Ασαφούς Λογικής (Fuzzy Logic Systems)
- ✚ τα Νευρωνικά Δίκτυα (Neural Networks)
- ✚ τους Γενετικούς Αλγόριθμους (Genetic Algorithms)

Τεχνητή Νοημοσύνη (Πληροφορική)  $\cap$  Θεωρία Συστημάτων



Υπολογιστική Νοημοσύνη



Συστήματα Ασαφούς Λογικής  $\cup$  Νευρωνικά Δίκτυα  $\cup$  Γενετικούς Αλγόριθμους

Σχήμα 1.4. AI

### 1.5.1 Εφαρμογή μεθόδων Τεχνητής Νοημοσύνης στην DGA

Όπως προαναφέρθηκε, η συμβατική χημική μέθοδος DGA παρουσιάζει περιορισμούς κατά την εφαρμογή της, καθώς δεν παρέχει ακριβή ανάλυση όλων των σφαλμάτων και απόλυτη αξιοπιστία όπως θα χρειαζόταν. Προκειμένου να αντιμετωπιστούν οι παραπάνω περιορισμοί, τα δεδομένα που λαμβάνονται από αυτή συνδυάζονται με μεθόδους Τεχνητής Νοημοσύνης ούτως ώστε να εξαγονται πιο αξιόπιστα συμπεράσματα.

## 1.6. Ασαφής Λογική (Fuzzy Logic)

**Ασαφής Λογική (Fuzzy Logic)** με απλά λόγια είναι η προσπάθεια να εκφραστεί μαθηματικά η φυσική γλώσσα και ο τρόπος σκέψης του ανθρώπου.

Στην κλασσική θεωρία συνόλων, ένα σύνολο αποτελείται από ένα πεπερασμένο αριθμό ή άπειρο αριθμό στοιχείων, και μπορεί να αναπαρασταθεί από την αρίθμηση των στοιχείων. Τα στοιχεία όλων των συνόλων υπό μελέτη ανήκουν σε ένα υπερσύνολο αναφοράς. Τα στοιχεία ενός υπερσυνόλου αναφοράς που περιέχει το σύνολο υπό μελέτη, ανήκουν ή όχι στο υπό μελέτη σύνολο  $A$ . Αυτό εκφράζεται μέσω της χαρακτηριστικής συνάρτησης :

$$f_a(\mathbf{X}) = \begin{cases} 1, & \text{αν } \mathbf{x} \in A \\ 0, & \text{αν } \mathbf{x} \in A' \end{cases} \quad (1)$$

**Ασαφές σύνολο** ορίζεται αυτό το σύνολο, το οποίο επιτρέπει στα μέλη του να έχουν διαφορετικούς βαθμούς συμμετοχής στο διάστημα  $[0,1]$  και εκφράζεται ως ένα σύνολο διατεταγμένων ζευγών με τον εξής τρόπο:


$$A = \{ \mu_a(\mathbf{x})/\mathbf{x} \} = \Sigma \{ \mu_a(\mathbf{x})/\mathbf{x} \} \text{ για } \mathbf{x} \in \mathbf{X} \quad (2)$$

για την συνεχή και την διακριτή περίπτωση αντίστοιχα.

Για τα ασαφή σύνολα μπορεί επίσης να οριστεί μια συνάρτηση, η **συνάρτηση συμμετοχής (Membership function)**. Αυτή μας δείχνει το βαθμό κατά τον οποίο το σύνολο  $x$  ανήκει στο σύνολο  $A$ , δηλαδή:

$$\mu_a(\mathbf{x}): \mathbf{X} \rightarrow [0, 1] \quad (3)$$

Στη θεωρία των συνόλων η συνάρτηση συμμετοχής  $\mu_a(\mathbf{x})$  παίρνει μόνο τιμές 0 και 1. Αυτού του είδους τα σύνολα ονομάζονται crisp sets ενώ σύνολα τα οποία παίρνουν και άλλες τιμές ονομάζονται ασαφή.



Σχήμα 1.5. Χαρακτηριστική συνάρτηση συμμετοχής ενός κλασσικού ή crisp συνόλου (αριστερά) και ενός ασαφούς συνόλου (δεξιά)

Σε μια απλούστερη μορφή η συνάρτηση συμμετοχής μπορεί να γραφτεί ως εξής:  $\mu_a(\mathbf{x}) = \{\mu_1(\mathbf{x})/\mathbf{x}_1, \mu_2(\mathbf{x})/\mathbf{x}_2, \dots, \mu_n(\mathbf{x})/\mathbf{x}_n\}$  (4)


### Συναρτήσεις συμμετοχής

Τα ασαφή σύνολα αναπαρίστανται μέσω διαφόρων τύπων συναρτήσεων συμμετοχής.

Οι πιο σημαντικές από αυτές είναι:

1. *Τριγωνική*: Αυτή εκφράζεται μέσω των 3 παραμέτρων a,b,c και δίνεται από την σχέση:

$$\text{triangle}(x; a, b, c) = \begin{cases} 0, & x \leq a \text{ ή } x \geq c \\ x-a/b-a, & a \leq x \leq b \\ c-x/c-b, & b \leq x \leq c \end{cases}$$




Σχήμα 1.6. Παράδειγμα τριγωνικής συνάρτησης συμμετοχής

2. Τραπεζοειδής:

Εκφράζεται με 4 παραμέτρους και ο τύπος της είναι ο εξής:

$$\text{Trapezoid}(x;a,b,c,d)=\max(\min((x-a)/(b-a),1,(d-x)/(d-c)),0)$$




Σχήμα 1.7. Παράδειγμα Τραπεζοειδούς συνάρτησης συμμετοχής

3. Καμπανοειδής:

Η συνάρτηση αυτή εκφράζεται με 3 παραμέτρους και δίνεται από την παρακάτω σχέση:

$$\text{bell}(x; a, b, c) = 1/(1+(x-c)^2b/a)$$

## Generalized Bell Function




Σχήμα 1.8. Παράδειγμα Καμπανοειδούς συνάρτησης συμμετοχής

### 4. Γκαουσιανή:

Μια Γκαουσιανή συνάρτηση συμμετοχής εκφράζεται από τις παραμέτρους  $\sigma$  και  $c$  όπου το  $\sigma$  καθορίζει το πλάτος και το  $c$  το κέντρο της συνάρτησης συμμετοχής. Ορίζεται από την σχέση:

$$\text{Gaussian}(x; \sigma, c) = e^{-(x-c/\sigma)^2}$$



Σχήμα 1.9 Παράδειγμα Γκαουσιανής συνάρτησης συμμετοχής




### 5. Σιγμοειδής:

Είναι η συνάρτηση που την χαρακτηρίζουν οι παράμετροι  $a, c$  και ορίζεται ως:

$$\text{Sigmoid}(x; a, c) = 1 / (1 + e^{-a(x-c)})$$

Όπου το  $a$  ελέγχει την κλίση στο σημείο διασταύρωσης  $x=c$ .



Σχήμα 1.10. Παράδειγμα Σιγμοειδούς συνάρτησης συμμετοχής

### Οι Πράξεις μεταξύ ασαφών συνόλων

- Κενό σύνολο  $A$  είναι εκείνο για το οποίο η συνάρτηση συμμετοχής του είναι παντού 0. ( $\mu_A(x)=0$ )

*Πράξεις μεταξύ δύο ασαφών συνόλων  $A$  και  $B$*

Η συνάρτηση του συμπληρώματος ενός ασαφούς συνόλου ορίζεται ως:

- Συμπλήρωμα (complement)

$$\mu_{A^c}(x) = 1 - \mu_A(x) \forall x \in X$$

*Σαφή σύνολα:* ποιο στοιχείο δεν ανήκει στο σύνολο.

*Ασαφή σύνολα:* κατά πόσο τα στοιχεία δεν ανήκουν στο σύνολο.

- Ένωση (union)

$$\mu_{A \cup B}(x) = \mu_A(x) \vee \mu_B(x) = \max[\mu_A(x), \mu_B(x)] \quad \forall x \in X$$

*Σαφή σύνολα:* ποιο στοιχείο ανήκει σε οποιοδήποτε από τα δύο σύνολα .

*Ασαφή σύνολα:* πόσο από το στοιχείο υπάρχει σε οποιοδήποτε από τα δύο σύνολα.

- Τομή (intersection)

$$\mu_{A \cap B}(x) = \mu_A(x) \wedge \mu_B(x) = \min[\mu_A(x), \mu_B(x)] \quad \forall x \in X$$

*Σαφή σύνολα:* ποιο στοιχείο ανήκει και στα δύο σύνολα .

*Ασαφή σύνολα:* πόσο από το στοιχείο υπάρχει και στα δύο σύνολα.

- Περιεκτικότητα (containment)

*Σαφή σύνολα:* ποια σύνολα ανήκουν σε ποια άλλα σύνολα.

*Ασαφή σύνολα:* ποια σύνολα ανήκουν σε άλλα σύνολα.

- Υποσύνολο (subset)

Αν η συνάρτηση συμμετοχής ενός ασαφούς συνόλου A είναι μικρότερη ή ίση με τη συνάρτηση συμμετοχής ενός ασαφούς συνόλου B, τότε το ασαφές σύνολο A είναι υποσύνολο (subset) του ασαφούς συνόλου B:

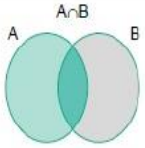
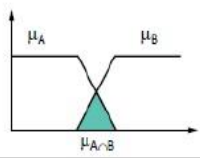
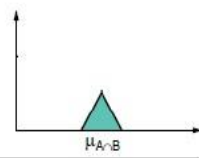
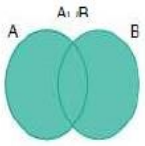
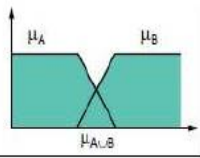
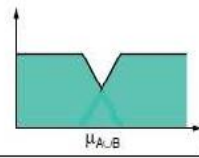
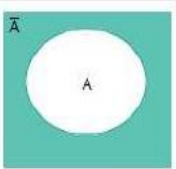
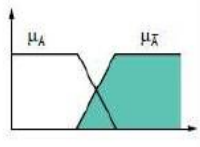
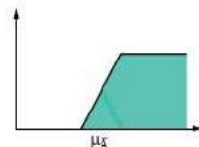
$$(A \subseteq B) \text{ αν } \mu_A(x) \leq \mu_B(x) \quad \forall x \in X$$



- Ισότητα ασαφή σύνολα

Όταν λέμε ισότητα ασαφή σύνολα A και B, αναφερόμαστε σε εκείνα των οποίων οι συναρτήσεις συμμετοχής είναι όμοιες.

$$A=B \text{ αν } \mu_A(x) = \mu_B(x) \quad \forall x \in X$$

# Fuzzy Logic Operations

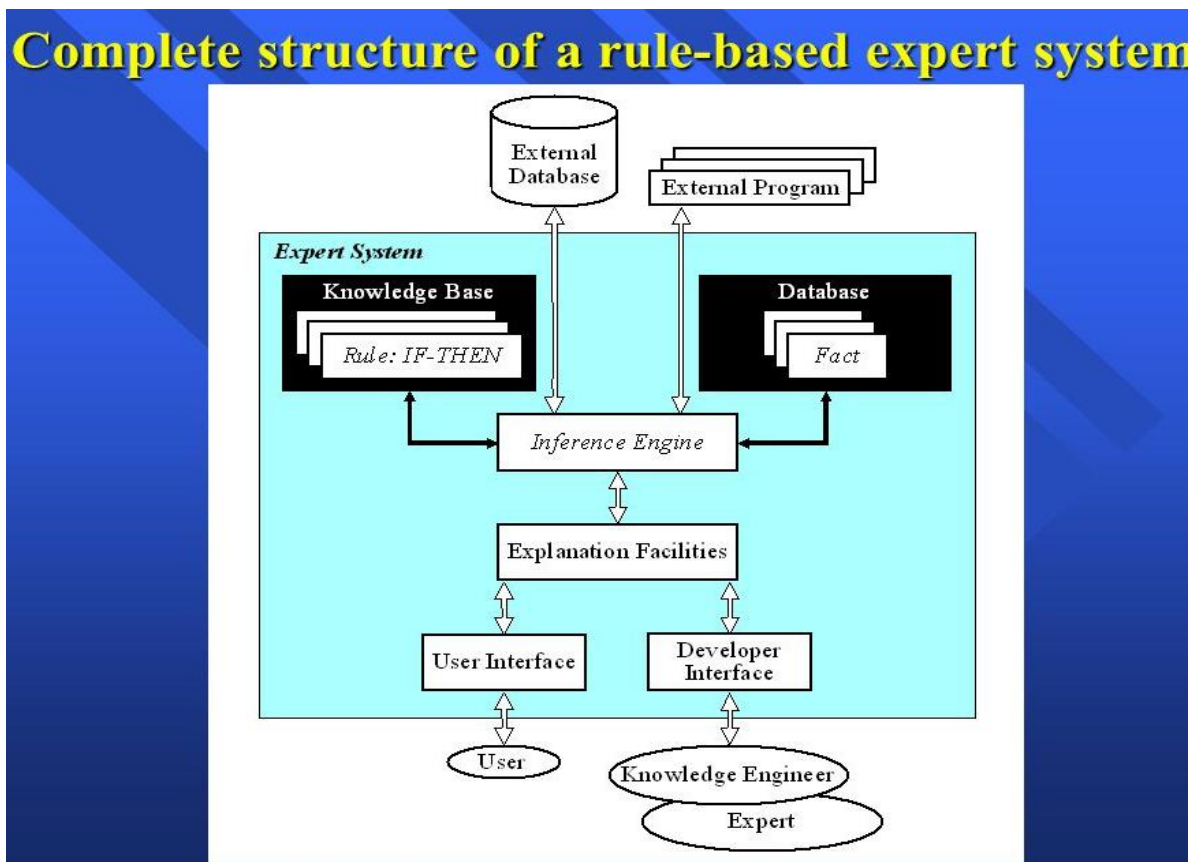
		ZADEH operator	Logic operation		
Intersection		$\mu_{A \cap B} = \text{MIN}(\mu_A, \mu_B)$	AND		
Union		$\mu_{A \cup B} = \text{MAX}(\mu_A, \mu_B)$	OR		
Negation		$\mu_{\bar{A}} = 1 - \mu_A$	NOT		



Σχήμα 1.11. Πράξεις μεταξύ Ασαφών Συνόλων

### 1.6.1 Έμπειρα Συστήματα (Expert Systems)

Έμπειρο Σύστημα (ΕΣ) χαρακτηρίζεται ένα σύστημα το οποίο αξιοποιεί τις ειδικές εμπειρίες και γνώσεις των εμπειρογνομώνων με σκοπό να επιλύσει ή να συμβουλευτεί τον χρήστη στην επίλυση πολύπλοκων προβλημάτων μιας καθορισμένης περιοχής ενδιαφέροντος, που θα ήταν δύσκολο αν όχι αδύνατο να επιλυθούν με συμβατικά συστήματα λογισμικού. Τα παραπάνω επιτυγχάνονται με χρήση γνωσιακών κανόνων. Βασικό χαρακτηριστικό των ΕΣ είναι η δυνατότητα λήψης αποφάσεων σε περιπτώσεις ανακριβούς/ασαφούς/ελλιπούς γνώσης ή σε εξαιρέσεις των κανόνων, καθώς και η αιτιολόγηση της ληφθείσας απόφασης.



Σχήμα 1.12. Δομή Έμπειρου Συστήματος

Τα Έμπειρα Συστήματα υποστήριξης αποφάσεων, εφαρμόζονται και για διάγνωση βλαβών και συντήρηση των Μ/Σ. Εξελίσσουν τη μέθοδο DGA και χρησιμοποιούν τα αποτελέσματά της για να δημιουργηθούν διαγνωστικοί κανόνες. Η αποτελεσματικότητά τους εξαρτάται από την ακρίβεια της βάσης γνώσεως τους, που συνήθως είναι αρκετά περίπλοκη και πρέπει να κατασκευαστεί πολύ προσεκτικά. Ένα τέτοιο Έμπειρο

Σύστημα δεν μπορεί να αποκτήσει γνώσεις από νέα δείγματα δεδομένων, μέσω διαδικασίας self-learning ούτε να προσαρμόσει αυτομάτως τους διαγνωστικούς κανόνες του. Πρέπει να προστεθούν νέοι κανόνες στη βάση δεδομένων τους.

### **1.6.2 Ασαφή Συστήματα Συμπερασμού-Fuzzy Inference System**

Η μέθοδος αυτή είναι κατάλληλη για τον έλεγχο μη γραμμικών συστημάτων καθώς είναι ικανή να χειριστεί τις κατά προσέγγιση πληροφορίες με έναν συστηματικό τρόπο. Επιπρόσθετα, επιλέγεται η χρήση της κατά τη μοντελοποίηση πολυσύνθετων συστημάτων όπου υπάρχει ένα ανακριβές πρότυπο. Ο σχεδιασμός ενός ασαφούς ελεγκτή είναι δυνατός εφόσον ο έλεγχος της διαδικασίας μπορεί να εκφραστεί με λεκτικούς κανόνες, οι οποίοι συνδέουν τις διάφορες συνθήκες λειτουργίας της διαδικασίας, με τις απαιτούμενες δράσεις που θα πρέπει να επιβληθούν. Οι κανόνες ελέγχου σε ένα ασαφή ελεγκτή εκφράζονται από ένα σύνολο εξαρτημένων σχέσεων της μορφής:

**IF** (κατάσταση της φυσικής διαδικασίας)

**THEN** (δράση ελέγχου της διαδικασίας)

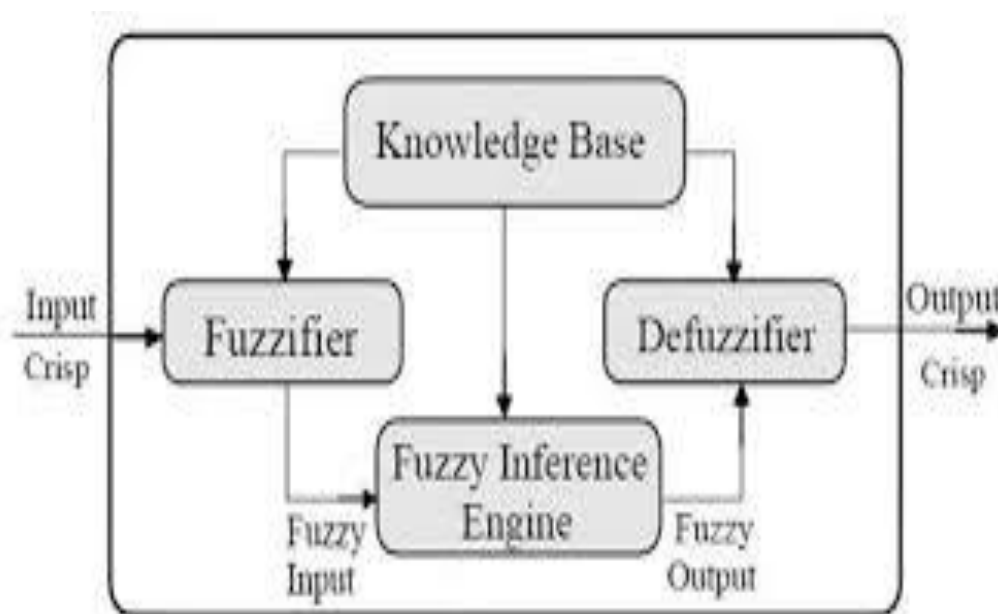
*Υλοποιούνται ως λογικές συνεπαγωγές χρησιμοποιώντας τη θεωρία των ασαφών συνόλων.*

Τα απαραίτητα δομικά στοιχεία ενός ασαφούς ελεγκτή που φαίνονται στο Σχήμα 1.13 είναι τα εξής:

- 1. Βάση δεδομένων πραγματικού χρόνου (real-time data base).** Όπου μετά από εξομάλυνση, καταχωρούνται οι τιμές των μεταβλητών που συλλέγονται από τη φυσική διαδικασία από τις διάφορες τοπικές μονάδες ελέγχου (TME), καθώς και οι έξοδοι του ελεγκτή (δηλαδή οι δράσεις ελέγχου) που κατά τακτά χρονικά διαστήματα μεταφέρονται και πάλι στις TME. Η βάση δεδομένων πραγματικού χρόνου συνεπώς μπορεί να θεωρηθεί ως ο κρίκος μεταξύ της φυσικής διαδικασίας και του ελεγκτή.
- 2. Βάση γνώσης (knowledge base),** Στην οποία είναι καταχωρημένη η κωδικοποιημένη γνώση (δηλαδή οι κανόνες ελέγχου) για τον έλεγχο της διαδικασίας.
- 3. Ασαφή σύνολα (fuzzy sets),** Που είναι καταχωρημένα είτε σε αναλυτική ή διακριτή μορφή σε ειδικό αρχείο. Ο μηχανισμός συμπερασμού χρησιμοποιεί τα σύνολα αυτά για να αποδώσει τις πράξεις ελέγχου στη διαδικασία.
- 4. Σύστημα ανάπτυξης (development system),** Με το οποίο ο μηχανικός γνώσης επικοινωνεί με το περιβάλλον του ελεγκτή.
- 5. Ασαφοποιητής (fuzzifier),** Όπου οι φυσικές μεταβλητές της διαδικασίας μετατρέπονται στην γλώσσα των ασαφών συνόλων.

6. **Μηχανισμός συμπερασμού (inference engine).** Όπου συμπεραίνονται οι αποφάσεις ελέγχου βάσει των διαθέσιμων κανόνων σε μορφή ασαφών συνόλων.

7. **Απο-ασαφοποιητής (defuzzifier).** Όπου τα ασαφή σύνολα των εξόδων του ελεγκτή μετατρέπονται σε σαφείς δράσεις ελέγχου, προς μετάδοση στους ενεργοποιητές της διαδικασίας μέσω των τοπικών μονάδων ελέγχου.



Σχήμα 1.13. Δομικά στοιχεία Ασαφούς Ελεγκτή

## 1.7 Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks, ANN)

Τα Τεχνητά Νευρωνικά Δίκτυα αποτελούν μια προσπάθεια προσέγγισης της λειτουργίας του ανθρώπινου εγκεφάλου από μια μηχανή και έχουν την ικανότητα να εκτελούν υπολογισμούς με μαζικό παράλληλο τρόπο (Hopfield,1985)

Το Νευρωνικό Δίκτυο είναι ένα δίκτυο από απλούς υπολογιστικούς κόμβους, νευρώνες, διασυνδεδεμένους μεταξύ τους και προσπαθεί να προσομοιώσει το Κεντρικό Νευρικό Σύστημα. Η αρχιτεκτονική τους βασίζεται στην αρχιτεκτονική του Κεντρικού Νευρικού Συστήματος.

Ορισμός σύμφωνα με τους Aleksander και Morton (Aleksander,1990):

**Τεχνητό Νευρωνικό Δίκτυο** είναι ένας παράλληλος καταναμημένος επεξεργαστής που έχει μια φυσική κλίση στην αποθήκευση και απόδοση εμπειρικής γνώσης.

Μοιάζει με τον εγκέφαλο στα εξής: 1. Η γνώση λαμβάνεται από το δίκτυο μέσω μιας διαδικασίας εκπαίδευσης. 2. Η αποθήκευση της γνώσης γίνεται μέσω των βαρών που υπάρχουν στις συνδέσεις μεταξύ των νευρώνων (Amit,1989).

Η απλούστερη μορφή νευρωνικού δικτύου καλείται Perceptron, αποτελείται από έναν μόνο νευρώνα, είναι μια μονάδα επεξεργασίας πληροφορίας, που είναι θεμελιώδης για την λειτουργία ενός νευρωνικού δικτύου και παρουσιάζεται στο Σχήμα 1.14 .

Ένα τυπικό νευρωνικό δίκτυο αποτελείται από:

- ❖ Νευρώνες (επεξεργαστές)
- ❖ Στοιβάδες (layers) νευρώνων που συνδέονται μεταξύ τους
- ❖ Συνδέσεις (connections): επιτελούν την επικοινωνία από τον νευρώνα-πομπό στο νευρώνα-δέκτη του σήματος.
- ❖ Οι συνδέσεις, μαζί με τα συναπτικά βάρη που τις συνοδεύουν, καθορίζουν τη διάδοση-προσαγωγή του σήματος μέσα στο δίκτυο.

Η εύρεση των κατάλληλων βαρών γίνεται δυνατή μέσω μιας διαδικασίας “εκπαίδευσης” (**training phase**). Κατά τη διάρκεια της εκπαίδευσης, οι τιμές των συναπτικών βαρών συνεχώς μεταβάλλονται με βάση τον **κανόνα εκμάθησης (learning rule)**

### **ΟΙ ΝΕΥΡΩΝΕΣ**

*Οι νευρώνες είναι τα δομικά στοιχεία του δικτύου.* Κάθε τέτοιος κόμβος δέχεται ένα σύνολο αριθμητικών εισόδων από διαφορετικές πηγές (είτε από άλλους νευρώνες, είτε από το περιβάλλον), επιτελεί έναν υπολογισμό με βάση αυτές τις εισόδους και παράγει μία έξοδο. Η έξοδος αυτή είτε κατευθύνεται στο περιβάλλον, είτε τροφοδοτείται ως είσοδος σε άλλους νευρώνες του δικτύου.

Η σύνδεση των νευρώνων υλοποιείται με «**βάρη**», σε κάθε νευρώνα οι τιμές εισόδου πολλαπλασιάζονται με μια τυχαία τιμή που αποκαλείται βάρος. Στο αποτέλεσμα αυτό προστίθεται ένα άλλο βάρος, το πολωμένο, το οποίο αρχικά λαμβάνει τιμή 1.

Το άθροισμα αυτό διοχετεύεται σε μια συνάρτηση που ονομάζεται **συνάρτηση μεταφοράς (transfer function)** και οδηγεί στην κανονικοποίησή του. Το τελικό αποτέλεσμα αποστέλλεται μέσω των συνάψεων σε άλλους νευρώνες. Οι τιμές των βαρών διαφοροποιούνται σε κάθε κύκλο λειτουργίας του νευρωνικού δικτύου με τη βοήθεια των αλγόριθμων εκπαίδευσης, ώστε να υλοποιηθεί η επιθυμητή μετατροπή των διανυσμάτων εισόδου σε διανύσματα εξόδου .

Υπάρχουν τρεις τύποι νευρώνων ή μονάδες επεξεργασίας (nodes) ή και κύτταρα (cells)

- *Νευρώνες εισόδου.*
- *Νευρώνες εξόδου.*
- *Υπολογιστικοί νευρώνες ή κρυμμένοι νευρώνες.*

Οι *νευρώνες εισόδου* δεν επιτελούν κανέναν υπολογισμό, μεσολαβούν απλώς ανάμεσα στις περιβαλλοντικές εισόδους του δικτύου και στους υπολογιστικούς νευρώνες. Ο αριθμός των νευρώνων του στρώματος εισόδου είναι ίσος με τον αριθμό των μεταβλητών εισόδου ενός προβλήματος πρόβλεψης.

Οι *νευρώνες εξόδου* διοχετεύουν στο περιβάλλον τις τελικές αριθμητικές εξόδους του δικτύου. ο αριθμός των νευρώνων του στρώματος εξόδου είναι ίσος με τον αριθμό των μεταβλητών εξόδου του προβλήματος πρόβλεψης.

Οι *υπολογιστικοί νευρώνες* πολλαπλασιάζουν κάθε είσοδό τους με το αντίστοιχο *συναπτικό βάρος* και υπολογίζουν το ολικό άθροισμα των γινομένων. Το άθροισμα αυτό τροφοδοτείται ως όρισμα στη *συνάρτηση ενεργοποίησης*, την οποία υλοποιεί εσωτερικά κάθε κόμβος. Η τιμή που λαμβάνει η συνάρτηση για το εν λόγω όρισμα είναι και η έξοδος του νευρώνα για τις τρέχουσες εισόδους και βάρη. Στον ισοστό νευρώνα υπάρχει ένα συναπτικό βάρος το οποίο καλείται *πόλωση* ή *κατώφλι* (bias, threshold). Η τιμή της εισόδου του είναι *πάντα μονάδα*. Εάν το συνολικό άθροισμα από τις υπόλοιπες εισόδους του νευρώνα είναι μεγαλύτερο από την τιμή αυτή, τότε ο *νευρώνας ενεργοποιείται*. Εάν είναι μικρότερο, τότε ο *νευρώνας παραμένει ανενεργός*. Ο αριθμός των νευρώνων του κρυφού στρώματος, καθορίζεται με επαναλαμβανόμενες δοκιμές, διότι δεν μπορούν να προσδιοριστούν βάση κάποιων κανόνων. Αν ο αριθμός τους είναι αρκετά μικρός τότε το ANN μπορεί να αντιμετωπίσει πρόβλημα σύγκλισης κατά τη διάρκεια της εκπαίδευσης του καθώς δεν μπορεί να μάθει τις πολύπλοκες σχέσεις μεταξύ εισόδων και εξόδων (under-fitting). Αν ο αριθμός των κρυφών νευρώνων είναι υπερβολικά μεγάλος, τότε θα διαρκέσει περισσότερο η διαδικασία εκπαίδευσης και ενδεχομένως να επηρεάσει αρνητικά την ικανότητα γενίκευσης του ANN (“over-fitting”).

#### ***TA ΒΑΡΗ:***

- Σταθμίζουν την έξοδο του νευρώνα.
- Τοποθετούνται πάνω στις συνάψεις.
- Αποτελούν τη μνήμη του νευρωνικού δικτύου.
- Εκφράζουν το βαθμό που ένα στοιχείο εισόδου επηρεάζει την τελική διαμόρφωση του αποτελέσματος.
- Οι τιμές που λαμβάνουν τα βάρη κυμαίνονται είτε από 0 ως 1 είτε από -1 ως 1.
- Όσο πιο μεγάλη είναι η τιμή του βάρους τόσο περισσότερο το συγκεκριμένο στοιχείο εισόδου επηρεάζει το αποτέλεσμα (αντιστοιχία με συντελεστή)

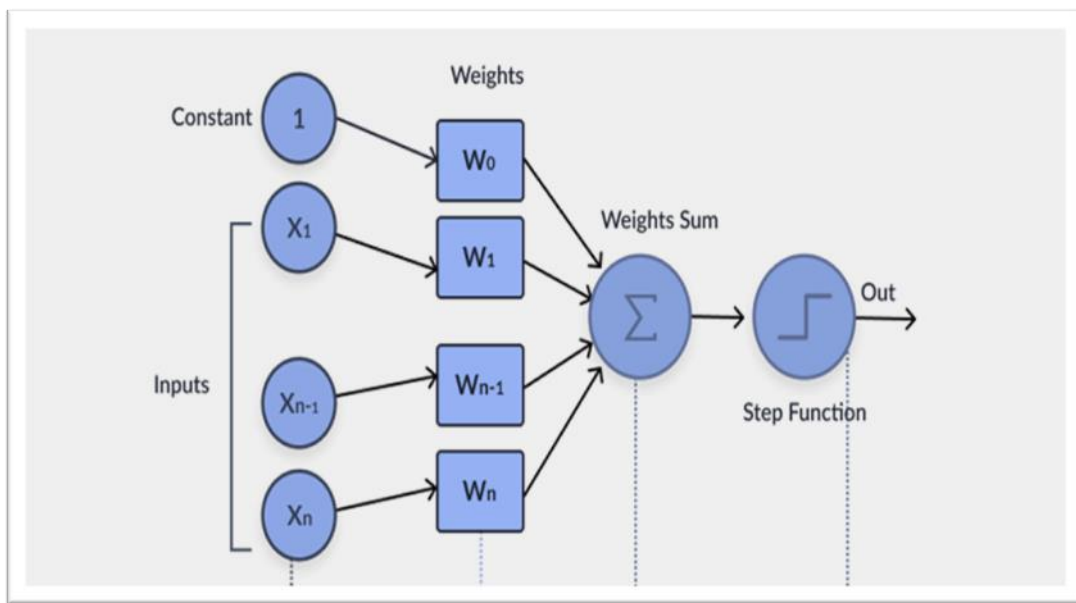


## ΟΙ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΕΓΕΡΣΗΣ ΚΑΙ ΜΕΤΑΦΟΡΑΣ

Μόλις τα “ζυγισμένα” δεδομένα εισόδου (το γινόμενο τους με τα αντίστοιχα βάρη) εισέλθουν στο νευρώνα, αθροίζονται για να μας δώσουν το αποτέλεσμα της συνάρτησης διέγερσης η οποία είναι θεμελιώδης για όλα τα δίκτυα:

$$\text{Net}_i = \sum_{j=1}^n w_{ij} * X_j$$

Το καθαρό (net) αποτέλεσμα του εξερχομένου σήματος (output) από το νευρώνα  $i$ , ισούται με το άθροισμα του γινομένου των βαρών επί των αντίστοιχων σημάτων (inputs) που δέχεται ο νευρώνας  $i$  από το νευρώνα  $j$ . Συνεπώς, το αποτέλεσμα της συνάρτησης διέγερσης είναι το άθροισμα των “ζυγισμένων” εισερχόμενων σημάτων σε μία δεδομένη χρονική στιγμή. Οι χρησιμοποιούμενες τιμές είναι  $-1$  και  $+1$ , όπου η πρώτη σημαίνει “ανενεργός” και η δεύτερη “ενεργός” νευρώνας. Η παραπάνω τιμή εισάγεται στη συνάρτηση μεταφοράς η οποία τελικά μας δίνει το πραγματικό αποτέλεσμα εξόδου (actual output).



Σχήμα 1.14. Σχηματικό διάγραμμα Perceptron

### Συναρτήσεις μεταφοράς

Το δίκτυο χρησιμοποιεί την κατάλληλη συνάρτηση μεταφοράς  $f(x)$  για να μεταδίδει το σήμα σε όλη τη δομή του, από την είσοδο ως την έξοδο.

I) Η Γραμμική Συνάρτηση (*linear*), η οποία χαρακτηρίζεται από σταθερή κλίση (*slope*) και αντιστοιχεί στο γραμμικό μοντέλο παλινδρόμησης.


II) Η Συνάρτηση Ορίου Διέγερσης (*threshold*), η οποία μπορεί να περιγραφεί από τη φράση «όλα ή τίποτα». Δηλαδή, αν η τιμή διέγερσης είναι μεγαλύτερη από το όριο (*threshold*) συστηματικό σφάλμα (*bias*), ο νευρώνας θα δώσει τιμή ίση με 1, ειδάλλως το αποτέλεσμα θα είναι 0.

III) Η Σιγμοειδής ή Λογιστική (*sigmoid or logistic*), η οποία πρόκειται για μία συνεχή και μονότονη καμπύλη και είναι η πλέον χρησιμοποιούμενη στις κρυμμένες στοιβάδες πολυστοιβαδικών ANN.

IV) Η Υπερβολική Συνάρτηση Εφαπτομένης (*hyperbolic tangment*), η οποία είναι ουσιαστικά ίδιας μορφής με την προηγούμενη και διαθέτει τις ίδιες ιδιότητες. Ωστόσο, δίνοντας τιμές στα αποτελέσματα εξόδου από -1 έως 1, έχει καλύτερες δυνατότητες.

$$F = \tanh(x/2)$$

V) Η Συνάρτηση κατά Gauss (*Gaussian*), η οποία διαθέτει τη χαρακτηριστική κωδωνοειδή μορφή και αποτελεί σπάνια επιλογή για τη μετατροπή της τιμής διέγερσης.



### Σχήμα 1.15. Συναρτήσεις μεταφοράς

Τα στοιχεία που χαρακτηρίζουν ένα Τεχνητό Νευρωνικό Δίκτυο είναι :

- Η αρχιτεκτονική του μοντέλου Τ.Ν.Δ.
- Ο αλγόριθμος εκπαίδευσης.
- Η ικανότητα γενίκευσης.
- Οι εφαρμογές του

#### A. Αρχιτεκτονική του μοντέλου ANN

Η αρχιτεκτονική του ANN καθορίζει τη διάταξη των συνδέσεων των νευρώνων του , τον αριθμό και τον τύπο των νευρώνων.

Η αρχιτεκτονική έχει βασικό ρόλο στη λειτουργία και στην απόδοση ενός δικτύου. Τα πιο διαδεδομένα δίκτυα κατηγοριοποιούνται ανάλογα με την αρχιτεκτονική τους στις παρακάτω γενικές κατηγορίες

- a. Μονοεπίπεδα προς τα εμπρός τροφοδοτούμενα δίκτυα (Single Layer Feedforward networks/ Single Layer Perceptron)
- b. Πολυεπίπεδα προς τα εμπρός τροφοδοτούμενα δίκτυα (Multilayer Feedforward Networks/Multilayer Perceptrons MLP)
- c. Αναδρομικά δίκτυα (Recurrent Networks)
- d. Συνελικτικά δίκτυα (Convolutional networks)

#### B. Ο αλγόριθμος εκπαίδευσης

Το κύριο χαρακτηριστικό των νευρωνικών δικτύων είναι η *ικανότητα μάθησης* ή εκπαίδευσης. Ως **μάθηση** μπορεί να οριστεί η σταδιακή βελτίωση της ικανότητας του δικτύου να επιλύει κάποιο πρόβλημα. Ο ορισμός της μάθησης των Mendel και McClaren:

«Μάθηση είναι μια διαδικασία με την οποία προσαρμόζονται οι ελεύθερες παράμετροι ενός Νευρωνικού Δικτύου μέσω μίας συνεχούς διαδικασίας διέγερσης από το περιβάλλον στο οποίο βρίσκεται το δίκτυο. Το είδος της μάθησης καθορίζεται από τον τρόπο με τον οποίο πραγματοποιούνται οι αλλαγές των παραμέτρων».

Ο παραπάνω ορισμός της μάθησης ακολουθεί τα επόμενα βήματα:

- α. Το ANN δέχεται πληροφορίες από το περιβάλλον και ενεργοποιείται.

β. Σαν συνέπεια αυτής της ενεργοποίησης το ANN υφίσταται αλλαγές.

γ. Το ANN απαντά με ένα νέο τρόπο στο περιβάλλον, λόγω των αλλαγών που έγιναν στην εσωτερική δομή του (Kohonen 1989).

Αλγόριθμος και στην προκειμένη περίπτωση **αλγόριθμος μάθησης** είναι μια καλώς ορισμένη ακολουθία βημάτων – κανόνων για την λύση ενός προβλήματος μάθησης. Για τον σχεδιασμό Νευρωνικών Δικτύων δεν υπάρχει μοναδικός τέτοιος αλγόριθμος, χρησιμοποιούνται διάφοροι ο καθένας από τους οποίους έχει διαφορετικά πλεονεκτήματα. Γενικά οι αλγόριθμοι διαφέρουν στον τρόπο με τον οποίο προσαρμόζεται το βάρος κάθε σύναψης, αλλά και με το τρόπο με τον οποίο το Νευρωνικό Δίκτυο επικοινωνεί με το περιβάλλον. Επιπρόσθετα, ο κανόνας εκπαίδευσης υποδεικνύει στο δίκτυο πώς ακριβώς να κάνει την μεταβολή-προσαρμογή των συναπτικών βαρών (εκπαίδευση), μεταξύ δύο επιτυχημένων κύκλων εκπαίδευσης (epochs).

Ένας καλός αλγόριθμος εκπαίδευσης :

- Έχει γρήγορη σύγκλιση
- Δίνει μικρό σφάλμα
- Το εκπαιδευμένο ANN έχει μεγάλη ικανότητα γενίκευσης.

### Κανόνες Εκμάθησης

- Κανόνας Δέλτα (Delta Rule Learning)
- Αλγόριθμος ανάστροφης μετάδοσης λάθους (Back Propagation)
- Ανταγωνιστική μάθηση (Competitive Learning)
- Τυχαία μάθηση (Random Learning)

Κατά τη διάρκεια της εκπαίδευσης, οι τιμές των συναπτικών βαρών συνεχώς μεταβάλλονται με βάση τον κανόνα εκμάθησης (learning rule). Αναλόγως της αρχιτεκτονικής των δικτύων απαντώνται διαφορετικές διαδικασίες εκμάθησης

#### ○ Εκπαίδευση με επίβλεψη (supervised learning )

Όταν η έξοδος είναι εκ των προτέρων γνωστή. Το δίκτυο τροφοδοτείται με μια σειρά από πρότυπα που έχουν αντιστοιχιστεί με κάποιο στόχο. Προσαρμόζονται οι παράμετροι ώστε να μπορεί να προβλέψει την «σωστή» έξοδο σε άγνωστα πρότυπα.

Εφαρμογές: Ταξινόμηση (Classification), Παλινδρόμηση (Regression)

Είδη δικτύων: Perceptron, ADALINE/MADALINE, Multi-Layer Perceptron (Back Propagation), Recursive Back Propagation, Radial Basis Function.

#### ○ Εκπαίδευση χωρίς επίβλεψη (unsupervised learning)

Το δίκτυο τροφοδοτείται μόνο από τα δεδομένα εισόδου, χωρίς τα αντίστοιχα επιθυμητά αποτελέσματα. Δηλαδή με μια σειρά από πρότυπα, τα οποία προσπαθεί να ομαδοποιήσει βάσει κοντινών χαρακτηριστικών. Η ιδιότητα αυτή ονομάζεται αυτοοργάνωση (self-organization) ή προσαρμογή (adaptation)

Εφαρμογές: Μείωση Διαστάσεων (Dimensionality Reduction), Συσταδοποίηση (Clustering)

Είδη δικτύων: Self Organizing Maps (Kohonen Network), Adaptive Resonance Theory (ART).

*Στην εκπαίδευση ενός Νευρωνικού Δικτύου, χρησιμοποιούνται τρία είδη δεδομένων:*

**1. Εκπαίδευσης (Training Dataset) :** Περιέχει τα “πρότυπα” δείγματα για την εκμάθηση/εκπαίδευση. Τα δεδομένα εκπαίδευσης, συμβάλλουν στον υπολογισμό της κλίσης η οποία μειώνεται σταδιακά με την εκπαίδευση και για τις αλλαγές των βαρών των νευρώνων του δικτύου. Η διαφορά μεταξύ των τιμών της πραγματικής εξόδου με την επιθυμητή έξοδο καλείται *σφάλμα εκπαίδευσης* και πρέπει να μειώνεται. Η σταδιακή μείωση του σφάλματος αυτού, εκφράζει την αποτελεσματικότητα στην εκπαίδευση του δικτύου.

**2. Επαλήθευσης (Validation Dataset) :** Τα δεδομένα αυτά, καθορίζουν το τέλος της εκπαίδευσης του δικτύου και χρησιμοποιούνται για τη βελτιστοποίηση των παραμέτρων του. Το δίκτυο σταματάει την μάθηση του όταν το σφάλμα επαλήθευσης δεν έχει μειωθεί μετά από κάποιες επαναλήψεις. Το σφάλμα επαλήθευσης υπολογίζεται σε κάθε κύκλο της εκπαίδευσης και επαληθεύει την σωστή εκπαίδευση του ANN. Το δίκτυο αποθηκεύει στην εσωτερική του δομή, τις τιμές των παραμέτρων με τις οποίες παρουσιάζει το μικρότερο δυνατό σφάλμα επαλήθευσης. Δηλαδή αυτές είναι και οι τελικές τιμές του.

**3. Ελέγχου (Test Dataset) :** Τα δεδομένα αυτά συμβάλλουν στον έλεγχο, προκειμένου το δίκτυο να είναι ικανό να γενικεύει. Δεν επηρεάζουν την προσαρμογή των βαρών, αλλά ελέγχουν την επίδοση του δικτύου σε νέα πρότυπα, τα οποία δεν έχουν δοθεί στο δίκτυο για εκπαίδευση. Αντίθετα από την εκπαίδευση, στον έλεγχο το δίκτυο δεν τροφοδοτείται με διανύσματα εξόδου και αφήνεται να αποφασίσει μόνο του για τις τιμές εξόδου με βάση αυτά που έχει μάθει στην εκπαίδευση.

## **Γ. Η ικανότητα γενίκευσης**

Η **ικανότητα γενίκευσης** είναι η ικανότητα που έχει το ANN να αντιμετωπίζει σωστά, «άγνωστα» δεδομένα του προβλήματος που επιλύει. Ή με άλλα λόγια, είναι η

ικανότητα παραγωγής επιθυμητών εξόδων, για εισόδους που δε συμπεριλαμβάνονταν στα δεδομένα εκπαίδευσης.

Οι παράγοντες οι οποίοι επηρεάζουν την ικανότητα γενίκευσης ενός Νευρωνικού Δικτύου είναι :

- Τα παραδείγματα εκπαίδευσης.
- Η πολυπλοκότητα του προβλήματος.
- Το μέγεθος του Νευρωνικού Δικτύου

**Υπερπροσαρμογή** (“over-fitting” ή “over-training”): Ένα ANN με πολλά βάρη άρα και εισόδους απομνημονεύει την ομάδα εκμάθησης και όχι την γενικότερη σχέση. Για τα δεδομένα εκπαίδευσης το σφάλμα του δικτύου τότε είναι πάρα πολύ μικρό, αλλά για δεδομένα στα οποία το δίκτυο δεν έχει εκπαιδευτεί γίνεται πολύ μεγάλο. Είναι τότε λιγότερο ικανό να γενικεύσει σε άλλα εισερχόμενα (άγνωστα) δείγματα. Αρχικά όσο η εκπαίδευση του μοντέλου συνεχίζεται, το σφάλμα πρόβλεψης μειώνεται για την ομάδα εκπαίδευσης και την ομάδα επικύρωσης. Η υπέρ-προσαρμογή του δικτύου παρουσιάζεται όταν το σφάλμα στην ομάδα επικύρωσης αρχίζει να αυξάνεται και σταματήσει η ελάττωσή του. Ως λύση του παραπάνω προβλήματος χρησιμοποιούμε αλγόριθμους εκπαίδευσης που δεν έχουν μοναδικό κριτήριο το σφάλμα, αλλά χρησιμοποιούν και άλλες παραμέτρους στην εκπαίδευση.

**Υποπροσαρμογή** (under-fitting), όταν ένα δίκτυο διαθέτει αρκετά μικρό αριθμό βαρών και γενικά είναι πολύ απλοϊκό σε σχέση με το πρόβλημα, τότε δεν είναι ικανό να ξεχωρίζει τις κατηγορίες δεδομένων μεταξύ τους. Συνέπεια αυτού είναι η αδυναμία επιτυχίας των στόχων της εκπαίδευσης και η αστοχία στο να γενικεύσει σε άγνωστα πρότυπα.

#### **Δ. Εφαρμογές**

Οι εφαρμογές που μπορεί να έχει ένα Νευρωνικό Δίκτυο εξαρτώνται από το μοντέλο του και μάλιστα η διαδικασία επιλογής λειτουργεί αντίστροφα, δηλ. το μοντέλο του ANN αναπτύσσεται σύμφωνα με την εφαρμογή που θέλουμε να έχει. Μερικές από αυτές είναι:

- Αναγνώριση εικόνων, κειμένων και γενικά προτύπων (pattern recognition).
- Έλεγχος παραγωγικής διαδικασίας
- Αυτοματοποίηση ρομπότ και συστημάτων ελέγχου
- Πρόβλεψη πωλήσεων
- Πρόβλεψη οικονομικών στοιχείων, Επενδύσεις
- Ιατρική (Νευρολογικά μοντέλα νοσημοσύνης , Διάγνωση ασθενιών)
- Ηλεκτρονικά παιχνίδια
- Αναγνώριση και παρακολούθηση στόχων

- Κωδικοποίηση σημάτων ραντάρ
- Αναγνώριση φωνής στις τηλεπικοινωνίες
- Αναγνώριση στις τηλεπικοινωνίες σφαλμάτων λογισμικού
- Μετάφραση
- Ανάλυση υφής, χαρακτήρων και προσώπων
- Πρόβλεψη φυσικών φαινομένων

Τα Τεχνητά Νευρωνικά Δίκτυα διακρίνονται – όπως έχει ήδη αναφερθεί – σε 'διάδοσης προς τα εμπρός' (Feed Forward) όταν το σήμα εισόδου μεταδίδεται προς μία φορά και σε ανατροφοδοτούμενα όταν αυτά περιλαμβάνουν τουλάχιστον μία ανάδραση. Στην παρούσα εργασία θα ασχοληθούμε με τα **Feed Forward (FF) Backpropagation Neural Networks**.

### 1.7.1 Δίκτυα οπισθοδιάδοσης σφάλματος -Backpropagation FF


Η διάδοση του σήματος γίνεται μόνο από τη μία στοιβάδα στην επόμενη και όχι αντίστροφα. Αυτός είναι ο λόγος για τον οποίο χαρακτηρίζονται ως “διάδοσης προς τα εμπρός” (feedforward). Η μέθοδος οπισθοδιάδοσης του λάθους (error backpropagation) είναι η πλέον δημοφιλής μέθοδος για την εκπαίδευση ενός δικτύου που αποτελείται από πολλά επίπεδα.

Τα πλεονεκτήματά του είναι τα ακόλουθα:

- ❖ Εύκολο στη χρήση
- ❖ Λίγες παράμετροι προς ρύθμιση
- ❖ Αλγόριθμος εύκολος σε υλοποίηση
- ❖ Μπορεί να εφαρμοσθεί σε ευρεία περιοχή δεδομένων
- ❖ Πολύ δημοφιλής μέθοδος εκπαίδευσης


Τα μειονεκτήματά του είναι:

- ❖ Αργή εκμάθηση
- ❖ Τα νέα στοιχεία θα υπερκαλύπτουν τα παλιά εκτός αν συνεχίσουν να παρέχονται
- ❖ Δύσκολο να διατηρηθεί το δίκτυο ενημερωμένο
- ❖ Το δίκτυο συμπεριφέρεται σαν μαύρο κουτί (black box ), καθώς μετά την εισαγωγή των δεδομένων επιλέγει μόνο του ποιές μεταβλητές είναι σημαντικότερες για την ανάπτυξη του μοντέλου
- ❖ Δεν είναι σίγουρη η γενίκευση έστω και αν το σφάλμα είναι ελάχιστο





Σχήμα 1.16. Αλγόριθμος Backpropagation



Σχήμα 1.17. ANN τριών επιπέδων FF Backpropagation

### FF Backpropagation Learning Process

**Initialization** (Αρχικοποίηση) — αρχικά βάρη εφαρμόζονται σε όλους τους νευρώνες

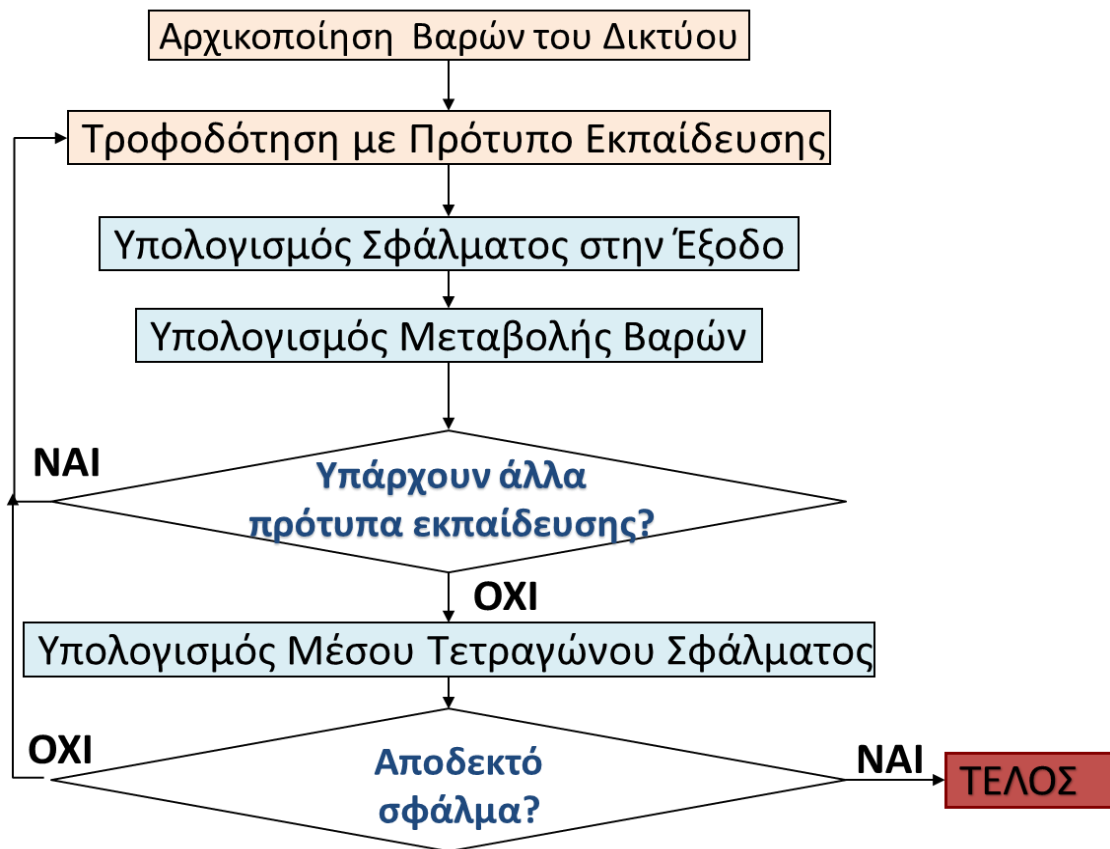
**Forward propagation** (Εμπρόσθια μετάδοση) — οι είσοδοι από το σετ εκπαίδευσης περνούν μέσω του ANN και υπολογίζεται μια έξοδος.

**Error function** (Συνάρτηση Σφάλματος) — η διαφορά μεταξύ της σωστής εξόδου και της πραγματικής εξόδου υπολογίζεται από μια *συνάρτηση σφάλματος* δεδομένου του τρέχοντος βάρους του μοντέλου. Ο αλγόριθμος backpropagation βελτιώνει (fine-tunes) τα βάρη για να φέρει τη συνάρτηση σφάλματος στον ελάχιστο βαθμό.

**Backpropagation** (Οπισθοδιάδοση) — οι διαφορές μεταξύ του υπολογιζόμενου και του επιθυμητού αποτελέσματος λαμβάνονται υπ' όψιν και προπαγανδίζονται προς τα πίσω στις κρυμμένες μονάδες έτσι ώστε να καθορίσουν τις **απαραίτητες αλλαγές (κανόνες εκμάθησης)** στα βάρη σύνδεσης μεταξύ των μονάδων.

**Weight update** (Βελτίωση βαρών) — τα βάρη αλλάζουν στις βέλτιστες τιμές σύμφωνα με τα αποτελέσματα του αλγορίθμου backpropagation.

**Iterate until convergence** (Επανάληψη έως τη σύγκλιση) - Το δίκτυο απαιτεί αρκετές επαναλήψεις για τη μάθηση. Μετά από κάθε επανάληψη, η μέθοδος *gradient descent* (η συνάρτηση εκμάθησης), ενημερώνει τα βάρη για να επιτύχει το μικρότερο σφάλμα.




Σχήμα 1.18. Η διαδικασία εκπαίδευσης FF Backpropagation

### Το Δίκτυο Οπισθοδιάδοσης σφάλματος (Back-Propagation):

- Αποτελείται από το στρώμα εισόδου με  $n$  εισόδους  $X_1, X_2, \dots, X_n$ , συν την εξωτερική διέγερση  $X_0 = 1$
- Ένα τουλάχιστον κρυφό στρώμα με  $p$  νευρώνες και
- Ένα στρώμα εξόδου με  $k$  νευρώνες
- Χρησιμοποιεί συνεχείς Συναρτήσεις Ενεργοποίησης, όπως τη Σιγμοειδή, τη Γραμμική ή την Υπερβολική Εφαπτομένη.
- Μπορεί να διαχωρίζει πρότυπα 2 ή περισσότερων κλάσεων οι οποίες είναι γραμμικά ή μη γραμμικά διαχωρίσιμες.

- Εκτός από τα πρότυπα χρειάζονται και στόχοι ( στην περίπτωση 2 κλάσεων 0 για την πρώτη κλάση, 1 για τη δεύτερη )
- Είναι ένα δίκτυο που εκπαιδεύεται με επίβλεψη.

### ΔΙΑΔΙΚΑΣΙΑ ΕΚΠΑΙΔΕΥΣΗΣ



Σχήμα 1.19. Διαδικασία Εκπαίδευσης

1. Εισάγονται τα πρότυπα με τη σειρά ( για κάθε εποχή ), πρώτα στο κρυφό στρώμα, απ' το οποίο η **έξοδος** χρησιμοποιείται σαν **είσοδος** στο στρώμα εξόδου, απ' το οποίο βγαίνει και η **τελική έξοδος**.

Πιο αναλυτικά :

2. Υπολογίζεται η διέγερση και η έξοδος κάθε νευρώνα  $i$  του κρυφού στρώματος όπου:

$$i = 1, 2, \dots, p$$

$$\tilde{y}_i = \sum_j x_j w^1_{ij}, y_i = f(\tilde{y}_i), \quad i = 1, 2, \dots, p \quad (1)$$

3. Υπολογίζεται η διέγερση και η έξοδος κάθε νευρώνα  $k$ , του στρώματος εξόδου όπου  $k = 1, 2, \dots, m$ :

$$\tilde{O}_k = \sum_{i=0}^p y_i w^2_{ki}, O_k = f(\tilde{O}_k), \quad k = 1, 2, \dots, m. \quad (2)$$

4. Υπολογίζονται τα Δέλτα του στρώματος εξόδου και μετά τα Δέλτα του κρυφού στρώματος σύμφωνα με τους τύπους :

$$\delta_k = (d_k - o_k) \cdot f'(\tilde{O}_k), \quad (3)$$

$k = 1, 2, \dots, m$ , τα Δέλτα του στρώματος εξόδου

$$\delta'_i = \left[ \sum_{k=1}^m \delta_k w_{ki}^2 \right] \cdot f'(\tilde{y}_i), \quad (4)$$

$i = 1, 2, \dots, p$ , τα Δέλτα του κρυφού στρώματος

5. Τροποποιούνται οι συνάψεις του στρώματος εξόδου και μετά του κρυφού στρώματος σύμφωνα με τους τύπους:

$$w_{ki}^2 = w_{ki}^2 + \beta \cdot \delta_k \cdot y_i = w_{ki}^2 + \beta \cdot (d_k - o_k) \cdot f'(\tilde{O}_k) \cdot y_i \quad (5)$$

$k = 1, 2, \dots, m$ ,  $i = 1, 2, \dots, p$

$$w_{ij}^1 = w_{ij}^1 + \beta \cdot \delta'_i \cdot x_j = w_{ij}^1 + \beta \cdot \left[ \sum_{k=1}^m \delta_k w_{ki}^2 \right] \cdot f'(\tilde{y}_i) \cdot x_j \quad (6)$$

$i = 1, 2, \dots, p$  και  $j = 1, 2, \dots, n$

6. Η εκπαίδευση τελειώνει, όταν το Μέσο Τετραγωνικό Σφάλμα των Προτύπων πάρει μια επιθυμητή τιμή.

Το Μέσο Τετραγωνικό Σφάλμα ορίζεται σαν :

$$mse = 1 / \# \text{ of patterns} \sum_{pat=1}^{\# \text{ of patterns}} \sum_{i=1}^m (d_i^{(pat)} - o_i^{(pat)})^2 \quad (7)$$

7. Στην ανάκληση : Εισάγονται τα πρότυπα με τη σειρά πρώτα στο κρυφό στρώμα, απ' το οποίο η έξοδος χρησιμοποιείται σαν είσοδος στο στρώμα εξόδου, απ' το οποίο βγαίνει και η τελική έξοδος, οπότε εμφανίζει το πρότυπο και την κλάση στην οποία κατατάσσεται.

### 1.7.2 Πλεονεκτήματα-μειονεκτήματα ANN

#### ➤ Πλεονεκτήματα των νευρωνικών δικτύων.

1. *Γραμμικότητα/μη γραμμικότητα.* Έχουν τη δυνατότητα να δουλεύουν και σε γραμμικές και σε μη γραμμικές σχέσεις και να ξεχωρίζουν αυτές τις σχέσεις άμεσα από τα στοιχεία που διαμορφώνονται
2. *Προσαρμοστικότητα.* Τα Νευρωνικά Δίκτυα έχουν τη δυνατότητα να προσαρμόζουν τα βάρη τους σε οποιαδήποτε αλλαγή
3. *Αυτό-οργάνωση.* Έχουν τη δυνατότητα να οργανώνονται με την πάροδο του χρόνου και με βάση τα δεδομένα που τους παρουσιάζονται.
4. *Αντοχή σε σφάλματα.* Ένα νευρωνικό δίκτυο, υλοποιημένο σε υλικό (hardware) έχει τη σημαντική ιδιότητα να είναι ανεκτικό σε σφάλματα. Σε περίπτωση που δεν ανταποκριθεί ένας νευρώνας ενός δικτύου, το δίκτυο συνεχίζει τη λειτουργία του με μειωμένη απλώς απόδοση
5. *Επεξεργασία σε συνθήκες πραγματικού χρόνου.* Η παράλληλη φύση του Νευρωνικού Δικτύου, κάνει δυνατή την υλοποίηση του σε VLSI τεχνολογία, έτσι ώστε τα νευρωνικά δίκτυα να μπορούν να χρησιμοποιηθούν σε εφαρμογές πραγματικού χρόνου.
6. *Ομοιομορφία ανάλυσης και σχεδιασμού.* Τα δίκτυα που χρησιμοποιούνται στις διάφορες εφαρμογές είναι βασισμένα σε κοινές αρχιτεκτονικές και αλγόριθμους εκπαίδευσης. Αυτό κάνει εύκολη και πιο προσιτή την εφαρμογή τους.
7. *Αναλογία με Νευροβιολογία.* Τα ANN προσομοιάζουν τη λειτουργία του εγκεφάλου συνεπώς οι μηχανικοί βρίσκουν επίλυση σε πολύπλοκα προβλήματα βάση αυτής της επιστήμης. Αντίστοιχα οι νευροβιολόγοι βλέπουν τα νευρωνικά δίκτυα σαν αντικείμενο έρευνας για την εξήγηση νευροβιολογικών φαινομένων.

#### ➤ Μειονεκτήματα των νευρωνικών δικτύων

1. Το *βασικότερο μειονέκτημα* τους είναι ότι η αποτελεσματική υλοποίησή τους απαιτεί πολύ μεγάλο όγκο δεδομένων σε σύγκριση με άλλους αλγόριθμους όπως τα δένδρα αποφάσεων και οι ταξινομητές Naive Bayes, οι οποίοι αποδίδουν ικανοποιητικά με λιγότερα δεδομένα. Ο όγκος υπολογισμών που επιτελούν κατά την διάρκεια της εκπαίδευσής τους είναι πολύ μεγάλος συνεπώς καταναλώνουν πολύ μεγάλη υπολογιστική ισχύ.
2. Το *πρόβλημα της Υπερεκπαίδευσης*, κατά την οποία το δίκτυο αποστηθίζει τα πρότυπα εκπαίδευσης συμπεριλαμβανομένου του θορύβου που αυτά περιέχουν. Συνεπώς η ικανότητα γενίκευσης του μοντέλου ελαττώνεται σημαντικά.

3. Υπάρχει μεγάλη πιθανότητα κατά την εκπαίδευση να παγιδευτούν σε τοπικό ελάχιστο της επιφάνειας σφάλματος.
4. Θεωρούνται ως μαύρο κουτί (*black box*), διότι δεν δύναται να εξηγήσουν τη διαδικασία λήψης της απόφασης για ένα πρόβλημα και ειδικά για προβλήματα ταξινόμησης. Έτσι η εξαγωγή γνώσης από ένα εκπαιδευμένο ANN είναι αρκετά δύσκολη.
5. Η λειτουργία τους και κατά συνέπεια η απόδοσή τους στηρίζονται σε μαθηματικό υπόβαθρο το οποίο είναι ακόμα ανολοκλήρωτο και χρειάζεται περαιτέρω ανάπτυξη.
6. Σε μεγάλου εύρους προβλήματα παρουσιάζουν μεγάλη αστάθεια. Τέτοιου είδους εφαρμογές είναι οι πυρηνικές και διαστημικές στις οποίες δεν μπορούν να δώσουν ικανοποιητικά αποτελέσματα.

## 1.8 Προσαρμοστικό Σύστημα Νευρο-ασαφούς Συμπερασμού -Adaptive Network based Fuzzy Inference System (ANFIS)

Το Adaptive Network based Fuzzy Inference System (ANFIS) δημιουργήθηκε από τον J.-S.R. Jang (Jang, 1993). Το ANFIS ανήκει στα προσαρμοστικά δίκτυα (*adaptive networks*) και συσχετίζει τα FIS Sugeno με τα Multi-Layer Feed-Forward Networks . Πρόκειται για έναν υβριδικό αλγόριθμο εκμάθησης, ο οποίος ρυθμίζει τις παραμέτρους της συνάρτησης συμμετοχής του Fuzzy Inference System σύμφωνα με τον συνδυασμό της μεθόδου Least Square και της Backpropagation Gradient Descent Method. Με άλλα λόγια το FIS βελτιστοποιεί τις συναρτήσεις συμμετοχής που του έχουν δοθεί στην αρχή χρησιμοποιώντας τον αλγόριθμο εκμάθησης του ANN.

Η μάθηση στα ANFIS παρουσιάζεται ως λεκτικοί κανόνες της μορφής

**Εάν (if) <συνθήκες (conditions) > τότε (then) <αποτελέσματα (consequents)>.**

Οι κανόνες αυτής της μορφής, επιτρέπουν τη χρησιμοποίηση ποιοτικών αλλά και ποσοτικών δεδομένων.

Τα δεδομένα εισόδου είναι ασαφοποιημένα συνεπώς , οι μεταβλητές εισόδου στο νευρο-ασαφές σύστημα παίρνουν μερικές ασαφοποιημένες τιμές (π.χ. μικρό, μεσαίο, μεγάλο), αντί για μια μεγάλο εύρος πραγματικών αριθμητικών τιμών. Ως συνέπεια τούτου είναι η μεγάλη μείωση του χρόνου μάθησης για το νευρο-ασαφές σύστημα.

Τα ANN παρέχουν μεγάλη υπολογιστική δύναμη για την επίλυση ενός προβλήματος και έχουν την ικανότητα να μαθαίνουν από δεδομένα. Ωστόσο, επειδή λειτουργούν σαν μαύρα κουτιά , ο χρήστης είναι αρκετά δύσκολο να εμπλακεί στη λογική της επίλυσης τους .


Από την άλλη μεριά, τα FIS έχουν το πλεονέκτημα να χρησιμοποιούν κανόνες και να κατηγοριοποιούν τα δεδομένα ανάλογα με τις δοσμένες ιδιότητες τους. Σε αυτή την περίπτωση ο χρήστης, εν αντιθέσει με τα ANN, έχει τη δυνατότητα να επικοινωνεί με το

σύστημα εκχωρώντας τη γνώση του για κάποιο πρόβλημα αλλά και ελέγχοντας τη λειτουργία του. Όμως τα μοντέλα ασαφούς λογικής δεν έχουν την ικανότητα να μάθουν από τα δεδομένα έτσι ο συνδυασμός τους με νευρωνικά δίκτυα λύνει αυτό το πρόβλημα.

Εν κατακλείδι το ANFIS συνδυάζει τα πλεονεκτήματα τόσο από τα νευρωνικά δίκτυα όσο και από την ασαφή λογική κατέχοντας την υπολογιστική δύναμη των Νευρωνικών Δικτύων και την επικοινωνία υψηλού επιπέδου με τον χρήστη των Ασαφών Συστημάτων. Έτσι το μοντέλο αυτό χρησιμοποιεί δυο είδη δεδομένων, αυτά που δημιουργούνται από παραδείγματα εκμάθησης και αυτά που καθορίζονται από τον εμπειρογνώμονα ως υποδείξεις για σκοπούς ταξινόμησης.

### Περιορισμοί του Anfis

1. Η επιλογή των συναρτήσεων μεταφοράς είναι καθοριστική καθώς μπορούν να αλλάξουν, μόνο οι τιμές των κανόνων και όχι οι συναρτήσεις συμμετοχής κάθε κόμβου
2. Το ANFIS δίνει τη δυνατότητα για μία μόνο έξοδο, λόγω των ιδιοτήτων των ασαφών κανόνων που αναπαριστά, και έτσι περιορίζεται σε εφαρμογές που απαιτείται μία μοναδική έξοδος. Ένα τέτοιο παράδειγμα είναι η πρόγνωση μη γραμμικών συστημάτων.
3. Οι τεχνικές βελτιστοποίησης περιορίζονται στην υβριδική μέθοδο δηλ. (συνδυασμό Least Square και της Backpropagation Gradient Descent Method) ή μόνο στην Backpropagation Gradient Descent Method. Επιλέγοντας την υβριδική μέθοδο, το ANFIS εφαρμόζεται μόνο σε μοντέλα Task-Sugeno-Kang (TSK)



## Σχήμα 1.20. ANFIS structure

Εν γένει, είναι ένα πολύ-επίπεδο δίκτυο πρόσθιας τροφοδότησης (Multi-Layer Feed-Forward Network), στο οποίο κάθε κόμβος εκτελεί μία συγκεκριμένη λειτουργία για τα εισερχόμενα σήματα και για το σύνολο των παραμέτρων που αντιστοιχούν στο συγκεκριμένο κόμβο. Οι κόμβοι συνδέονται μέσω κατευθυντήριων συνδέσμων (directional links). Υπάρχουν δύο είδη κόμβων ανάλογα με τη λειτουργία τους οι προσαρμοστικοί και οι σταθεροί. Στους σταθερούς κόμβους η έξοδος τους εξαρτάται από την έξοδο του προηγούμενου επιπέδου, ενώ στους προσαρμοστικούς η έξοδος τους εξαρτάται από τροποποιησιμες παραμέτρους που δεν είναι η έξοδος του προηγούμενου επιπέδου. Παρακάτω αναλύεται η λειτουργία ενός δικτύου που αποτελείται από μια αρχιτεκτονική πέντε επιπέδων.

### 1.8.1 Λειτουργία ANFIS, αρχιτεκτονικής πέντε επιπέδων.

Σε ένα δίκτυο ANFIS με  $n$  εισόδους, το Layer 1 αποτελείται από  $n^2$  κόμβους. Έτσι, το δίκτυο δύο εισόδων στο Σχήμα 1.20 έχει τέσσερις κόμβους:  $A_1$ ,  $A_2$ ,  $B_1$ , και  $B_2$ . Η αρχιτεκτονική ANFIS χρησιμοποιείται για την εφαρμογή των ακόλουθων κανόνων:

**Rule(1): IF  $x$  is  $A_1$  AND  $y$  is  $B_1$ ; THEN  $f_1 = p_1x + q_1y + r_1$**

**Rule(2): IF  $x$  is  $A_2$  AND  $y$  is  $B_2$ ; THEN  $f_2 = p_2x + q_2y + r_2$**

όπου:

$x, y$ : inputs,

$A_i, B_i$ : fuzzy sets,

$f_i$ : outputs within the fuzzy area specified by the fuzzy rule,

$p_i, q_i, r_i$ : parameters that are determined during the training process.

Κάθε σταθερός κόμβος (fixed) απεικονίζεται με έναν κύκλο.

Κάθε προσαρμοστικός κόμβος (adaptive) απεικονίζεται με ένα τετράγωνο.

#### Layer 1: Ασαφοποίηση.

Όλοι οι κόμβοι είναι προσαρμοστικοί. Οι έξοδοι του επιπέδου 1 είναι η fuzzy membership class των εισόδων και δίνονται από τις εξισώσεις:

$$O_{1,i} = \mu_{A_i}(x), \quad i = 1, 2 \quad O_{1,i} = \mu_{B_{i-2}}(y), \quad i = 3, 4 \quad (8)$$

Όπου:

$x$  και  $y$  inputs to node  $i$ ,

$A_i$  and  $B_i$  linguistic labels (high, low, etc.) associated with this node function.

$\mu_{A_i}(x)$  and  $\mu_{B_{i-2}}(y)$  can be any fuzzy membership function.



### **Layer 2: Δημιουργία Κανόνων.**

Σταθεροί κόμβοι που εκτελούν τη λειτουργία γινομένου για τις εισόδους. Αντιπροσωπεύει έναν κανόνα του οποίου η έξοδος είναι το γινόμενο των συναρτήσεων συμμετοχής της εισόδου του. Η έξοδος του επιπέδου 2 ονομάζεται firing strengths of the rules και είναι:

$$O_{2,i} = w_i = \mu_{A_i}(x) * \mu_{B_{i-2}}(y), \quad i=1, 2 \quad (9)$$

### **Layer 3: Κανονικοποίηση**

Οι κόμβοι είναι σταθεροί και σχηματίζουν την normalization function των firing strengths του Layer 2. Υπολογίζεται ο λόγος του βαθμού ενεργοποίησης ( $w_i$ ) κάθε κανόνα προς το άθροισμα των βαθμών ενεργοποίησης όλων των κανόνων (κανονικοποίηση). Η έξοδος του επιπέδου 3 ονομάζεται normalized firing strengths και είναι:

$$O_{3,i} = \bar{w}_i = w_i / (w_1 + w_2), \quad i = 1, 2 \quad (10)$$

**Layer 4:** οι κόμβοι είναι προσαρμοστικοί και η έξοδος του καθενός είναι το γινόμενο των normalized firing strength και ενός πρώτου βαθμού πολυώνυμου του Sugeno model. Η έξοδος του παρόντος επιπέδου είναι :

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad i = 1, 2 \quad (11)$$

Όπου  $\bar{w}_i$  output of Layer 3

$p_i, q_i, r_i$  are the consequent parameters.

### **Layer 5: Συνολική Έξοδος.**

Το πέμπτο επίπεδο αποτελείται από έναν σταθερό κόμβο, ο οποίος εκτελεί το άθροισμα όλων των εισερχόμενων σημάτων. Η ακόλουθη εξίσωση υπολογίζει τη συνολική έξοδο του μοντέλου :

$$O_{5,i} = \sum \bar{w}_i f_i. \quad (12)$$

---

## ΚΕΦΑΛΑΙΟ2:

### Μεθοδολογία της έρευνας

---

Όπως ειπώθηκε παραπάνω η συμβατική μέθοδος DGA παρουσιάζει περιορισμούς κατά την εφαρμογή της, καθώς δεν παρέχει ακριβή ανάλυση όλων των σφαλμάτων και απόλυτη αξιοπιστία. Αυτό συμβαίνει συνήθως όταν λαμβάνουν χώρα στον Μ/Σ περισσότερα του ενός σφάλματα, ή όταν οι συγκεντρώσεις των εκλυόμενων αερίων είναι κοντά στα όρια κατωφλίου τους. Προκειμένου να αντιμετωπιστούν τα προβλήματα αυτά και να βελτιωθεί η αξιοπιστία της μεθόδου εφαρμόζονται τρεις μέθοδοι τεχνητής νοημοσύνης *Ασαφής Λογική, Νευρωνικά Δίκτυα και Νευρο-ασαφές Σύστημα για τη διάγνωση σφαλμάτων μετασχηματιστών ισχύος.*

Στο προηγούμενο κεφάλαιο περιεγράφηκε το θεωρητικό υπόβαθρο των μοντέλων αυτών. Η μέθοδος που θα ακολουθηθεί είναι η προσομοίωση των προαναφερθέντων μοντέλων στο πρόγραμμα MATLAB. Θα εξαχθεί η ακρίβεια της κάθε μεθόδου και τέλος θα γίνει μια συγκριτική παρουσίαση των FIS, ANN, ANFIS και της συμβατικής μεθόδου Rogers Ratio . Τελικός στόχος της μελέτης αυτής είναι να εξαχθεί το μοντέλο με την βέλτιστη απόδοση για την πρόβλεψη βλαβών μετασχηματιστών ισχύος.

Για την έρευνα αυτή χρησιμοποιήθηκαν περίπου 200 δείγματα αερίων που έχουν συλλεχθεί από μετασχηματιστές με γνωστά σφάλματα. Τα μοντέλα εκπαιδεύτηκαν, με τον απαιτούμενο για κάθε μοντέλο, αριθμό από αυτά τα δεδομένα και η απόδοσή τους κρίνεται σύμφωνα με το πόσο σωστά προέβλεψαν τα σφάλματα των υπόλοιπων δειγμάτων.

#### 2.1 Το πρόγραμμα MATLAB.

Το λογισμικό MATLAB, MATrix LABoratory, είναι ένα σύγχρονο ολοκληρωμένο μαθηματικό πακέτο που χρησιμοποιείται στα πανεπιστήμια και στη βιομηχανία. Είναι ένα διαδραστικό πρόγραμμα για αριθμητικούς υπολογισμούς, απεικόνιση και προγραμματισμό σε υψηλού επιπέδου γλώσσα. Περιλαμβάνει εργαλείοι που επιτρέπουν συμβολικούς υπολογισμούς. Μπορούν να αναλυθούν δεδομένα, να αναπτυχθούν αλγόριθμοι καθώς και να δημιουργηθούν μοντέλα και εφαρμογές. Χρησιμοποιείται για ένα ευρύ φάσμα εφαρμογών, όπως: η επεξεργασία σήματος και επικοινωνιών, τα συστήματα ελέγχου, δοκιμών και μετρήσεων, η επεξεργασία εικόνας και βίντεο, τα υπολογιστικά οικονομικά και η υπολογιστική βιολογία.

**A. Η προσομοίωση του Ασαφούς Συστήματος** πραγματοποιείται μέσω του Fuzzy Toolbox, το οποίο παρέχει τα εργαλεία για τη δημιουργία ασαφών συστημάτων στα πλαίσια του Matlab. Το **Fuzzy Toolbox του Matlab** χρησιμοποιεί πέντε βασικά εργαλεία γραφικής διεπαφής με τον χρήστη (Graphical User Interface-GUI) για να *δημιουργεί, να αλλάζει* και να *απεικονίζει* τα Ασαφή Συστήματα:

- Σύστημα Ασαφούς Συνεπαγωγής (Fuzzy Inference System-FIS Editor),
- Συντάκτη Συναρτήσεων Συμμετοχής (Membership Function Editor),
- Συντάκτη Κανόνων (Rule Editor),
- Επισκόπηση Κανόνων (Rule Viewer)
- Επισκόπηση Επιφανειών (Surface Viewer).

**B. Η προσομοίωση των Νευρωνικών Δικτύων** πραγματοποιείται μέσω **Neural Networks Toolbox** το οποίο έχει τα εξής χαρακτηριστικά:

- Δημιουργία και εκπαίδευση μοντέλων μέσω εντολών ή με τη βοήθεια γραφικού περιβάλλοντος (GUI).
- Διάθεση μεγάλης γκάμας αρχιτεκτονικών, τοπολογιών και τεχνικών εκπαίδευσης Νευρωνικών Δικτύων.
- Μεταφορά γνώσης με τη χρήση προπαιδευμένων μοντέλων για τη γρήγορη ανάπτυξη εφαρμογών. Δυνατότητα χρήσης CPUs/GPUs, σε προσωπικούς υπολογιστές, συστοιχίες και νέφη, για την επιτάχυνση της εκπαίδευσης και της ανάκλησης.
- Αυτόματη παραγωγή κώδικα για Matlab και δημιουργία blocks που μπορούν να ενσωματωθούν στο Simulink.

**Γ. Η προσομοίωση του Νευρο-Ασαφούς Συστήματος** πραγματοποιείται μέσω της εφαρμογής **Neuro-Fuzzy Designer** .

Η εφαρμογή Neuro-Fuzzy Designer επιτρέπει τον σχεδιασμό, την εκπαίδευση και την δοκιμή (ANFIS) χρησιμοποιώντας δεδομένα εκπαίδευσης εισόδου / εξόδου. Ανοίγοντας το APP Neuro-Fuzzy Designer εμφανίζεται το παράθυρο Anfis Editor από το οποίο γίνονται όλες οι ενέργειες για τη δημιουργία του μοντέλου ANFIS. Περιλαμβάνει τα πλαίσια:

- ✓ Load data
- ✓ Generate FIS
- ✓ Train FIS
- ✓ Test FIS

## ΚΕΦΑΛΑΙΟ 3:

### Η προτεινόμενη μέθοδος – Θεμελίωση, Σχεδίαση, Ανάπτυξη

---

#### 3.1 Μεθοδολογία διάγνωσης σφαλμάτων με τη μέθοδο Ασαφούς Συστήματος Συμπερασμού (FIS).

Όπως ειπώθηκε παραπάνω η συμβατική μέθοδος Ανάλυσης Διαλυμένων Αερίων σε λάδι (DGA) παρουσιάζει περιορισμούς κατά την εφαρμογή της καθώς δεν παρέχει ακριβή ανάλυση όλων των σφαλμάτων και απόλυτη αξιοπιστία. Προκειμένου να αντιμετωπιστούν τα προβλήματα αυτά και να βελτιωθεί η αξιοπιστία της μεθόδου, μελετάται-σχεδιάζεται ένα Ασαφές Σύστημα Συμπερασμού- Fuzzy Inference System (FIS).

Η προσομοίωση της παρούσας εργασίας πραγματοποιείται μέσω του *Fuzzy Toolbox του Matlab* . Αυτό χρησιμοποιεί πέντε βασικά εργαλεία γραφικής διεπαφής με τον χρήστη (Graphical User Interface-GUI) για να δημιουργεί, να αλλάζει και να απεικονίζει τα Ασαφή Συστήματα:

- Σύστημα Ασαφούς Συνεπαγωγής (Fuzzy Inference System-FIS Editor). Εδώ εισάγονται ο αριθμός των μεταβλητών εισόδου και εξόδου και επιλέγεται η ονομασία τους.
- Συντάκτη Συναρτήσεων Συμμετοχής (Membership Function Editor), ο οποίος χρησιμοποιείται για να καθορισθούν οι μορφές όλων των συναρτήσεων συμμετοχής που σχετίζονται με κάθε μεταβλητή.
- Συντάκτη Κανόνων (Rule Editor), με βάση τις μεταβλητές εισόδου και τις μεταβλητές εξόδου διαμορφώνονται οι κανόνες.
- Επισκόπηση Κανόνων (Rule Viewer)
- Επισκόπηση Επιφανειών (Surface Viewer).

##### 3.1.1 Δημιουργία στο MATLAB Συστήματος Ασαφούς Συμπερασμού - *Fuzzy Inference System (FIS)*.

Κατά τη μέθοδο **Rogers** χρησιμοποιούνται τέσσερις λόγοι συγκέντρωσης διαλυμένων αερίων (λόγοι του Rogers):

$$MH = CH_4/H_2$$

$$EE = C_2H_4/C_2H_6$$

$$AE = C_2H_2/C_2H_4$$

$$EM = C_2H_6/CH_4$$

➤ Από τον Πίνακα 1.6 βρίσκω τους λόγους για Roger's Ratio Method.

### *ΒΗΜΑ ΠΡΩΤΟ*

#### *Fuzzification (Ασαφοποίηση)*

Η ασαφοποίηση είναι η διαδικασία της μετατροπής των αρχικών δεδομένων σε ασαφείς αριθμούς, μέσω των συναρτήσεων συμμετοχής.

**Καθορισμός εισόδων και εξόδων.** Δηλ. καθορισμός των συγκεντρώσεων των σχηματιζόμενων αερίων ως Ασαφών Μεταβλητών, Fuzzy Variables Determination.

Το σύστημα αποτελείται από :

#### 4 INPUTS

INPUT 1 MH

INPUT 2 EM

INPUT 3 EE

INPUT 4 AE

Και μια έξοδο

OUTPUT 1 DIAGNOSIS 1

Όπως παρατίθενται στον Πίνακα 3.1 οι τέσσερις κωδικοί 0,1,2,5 ορίζονται ως 4 λεκτικοί όροι, χωρίς τον στενό περιορισμό της αριθμητικής έκφρασης, των συναρτήσεων συμμετοχής και ταξινομούνται ως:

Πίνακας 3.1. Κωδικοί λόγων Roger' s <sup>8</sup>

Λόγος Roger' s	Εύρος	Κωδικός
EM	$x < 1.0$	0(L)
	$x \geq 1.0$	1(H)
AE	$x < 0.1$	0(L)
	$0.1 \leq x \leq 3.0$	1(M)
	$x > 3.0$	2(H)
MH	$x < 0.1$	5(L)
	$0.1 \leq x \leq 1.0$	0(M)
	$1.0 \leq x \leq 3.0$	1(H)
	$x > 3.0$	2(VH)
EE	$x < 0.1$	0(L)
	$0.1 \leq x \leq 3.0$	1(M)
	$x > 3.0$	2(H)

- ✓ Χαμηλής σημασίας (LOW)
- ✓ Μεσαίας (MED)
- ✓ Υψηλής (Hi)
- ✓ Πολύ Υψηλής (VH)

Ο Πίνακας 3.1 δείχνει τα διαστήματα συμμετοχής για κάθε λόγο.

### FIS Editor ή Fuzzy Logic Designer

Από την γραμμή των εντολών του MATLAB πληκτρολογώντας fuzzy ή ανοίγοντας το FUZZY APP καλείται ο **FIS Editor** ή ο **Fuzzy Logic Designer** και ορίζεται το ασαφές σύστημα. Οι επιλογές της μπάρας εργαλείων επιτρέπουν να ανοιχθούν τα σχετικά GUI εργαλεία. Ο προκαθορισμένος τύπος ασαφούς συστήματος είναι ο τύπος Mamdani μπορεί όμως να καθοριστεί και ασαφές σύστημα τύπου TSK, από το menu\file\new fis.

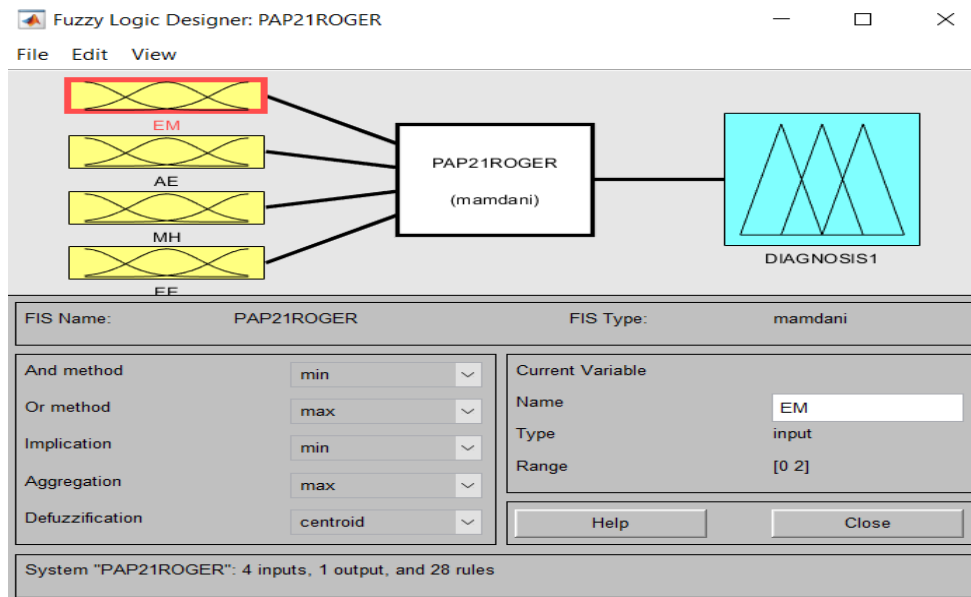
Στο επάνω μέρος του FIS Editor εμφανίζεται ένα block diagram

- Στο δεξιό μέρος απεικονίζονται οι μεταβλητές εξόδου
- Στο μέσον εμφανίζεται το όνομα και ο τύπος του FIS (FIS Name, FIS type)
- Στο αριστερό μέρος απεικονίζονται οι μεταβλητές εισόδου .

Κάτω από το FIS Name υπάρχει ένας Πίνακας με pop-up menus που μας επιτρέπουν να ορίσουμε επί μέρους διαδικασίες του FIS.

Κάτω από το FIS type ορίζονται το όνομα των μεταβλητών εξόδου ή εισόδου, τις σχετιζόμενες με αυτές βαθμούς συμμετοχής, και το εύρος τιμών τους.

Στο Σχήμα 3.1 φαίνεται ο ορισμός του ασαφούς συστήματος “ROGER” με τον **Fuzzy Logic Designer**.



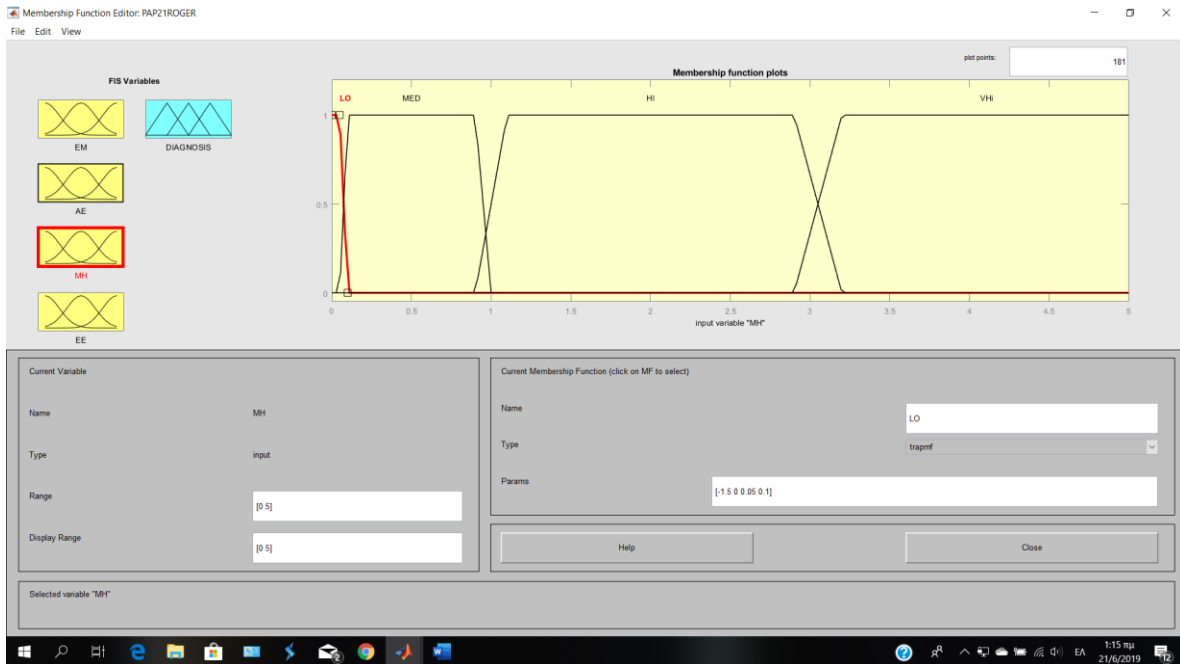
Σχήμα 3.1. Fuzzy Logic Designer

**Καθορισμός Συναρτήσεων Συμμετοχής.** Το επόμενο βήμα στην ανάπτυξη του Ασαφούς Συστήματος είναι ο ορισμός του αριθμού των ασαφών συνόλων για κάθε μεταβλητή εισόδου και εξόδου - η μορφή της συναρτήσεως συμμετοχής που επιλέγεται είναι η τραπεζοειδής. Από τον Πίνακα 4.2 δημιουργώ τις συναρτήσεις συμμετοχής για τις 4 εισόδους MH , EM, EE, AE

Χρησιμοποιούμε **τραπεζοειδή** συνάρτηση συμμετοχής και οι συναρτήσεις δεν παρουσιάζουν επικαλύψεις στο 50% σύμφωνα με τη μέθοδο συντονισμού.

### Membership Function Editor

Επιλέγουμε Edit/Membership Functions έτσι καλείται ο Membership Function Editor από τον οποίο καθορίζονται οι μορφές των συναρτήσεων συμμετοχής για κάθε μεταβλητή εισόδου /εξόδου.



Σχήμα 3.2. Γραφικό περιβάλλον Membership Function Editor

## ΒΗΜΑ ΔΕΥΤΕΡΟ

### Knowledge Representation (Δημιουργία Ασαφών κανόνων)

Οι κανόνες που είναι ένα σύνολο προτάσεων, συνδέουν το σύνολο των εισαγόμενων δεδομένων με τα αποτελέσματα. Καθορίζονται έτσι ώστε το σύστημα να μπορεί να μετατρέπει οποιαδήποτε εισερχόμενη τιμή σε κάποιο αποτέλεσμα, καλύπτοντας όλους τους δυνατούς συνδυασμούς δεδομένων-αποτελεσμάτων. Οι γλωσσικοί αυτοί κανόνες προσομοιώνουν την διαδικασία συλλογισμού ενός έμπειρου μηχανικού.


### Rule Editor

Στη συνέχεια εκτελούμε στο Matlab την εντολή Edit-Rules, και με βάση τις μεταβλητές εισόδου και τις μεταβλητές εξόδου διαμορφώνονται οι κανόνες. Η δημιουργία των κανόνων με τον Rule Editor είναι μία εμπειρική διαδικασία. Οι κανόνες αυτοί έπειτα εισάγονται στο παράθυρο Rule Editor που προσφέρει το γραφικό περιβάλλον του FIS Editor.

Η διαμόρφωση ενός κανόνα γίνεται με την επιλογή μίας ή περισσότερων λεκτικών μεταβλητών εισόδου και μίας μεταβλητής εξόδου, ώστε να έχουν την παρακάτω μορφή:  
 ΕΑΝ η είσοδος 1 είναι MF1 (η πρώτη συνάρτηση της μεταβλητής εισόδου 1)  
 ΚΑΙ η είσοδος 2 είναι MF1



ΤΟΤΕ η έξοδος 1 θα είναι MF1 (η πρώτη συνάρτηση συμμετοχής της εξόδου 1)  
 κ η έξοδος 2 θα είναι MF1 (η πρώτη συνάρτηση συμμετοχής της εξόδου 2)



Σχήμα 3.3. Rule Editor -Διαμόρφωση Κανόνα

### ***ΒΗΜΑ ΤΡΙΤΟ***

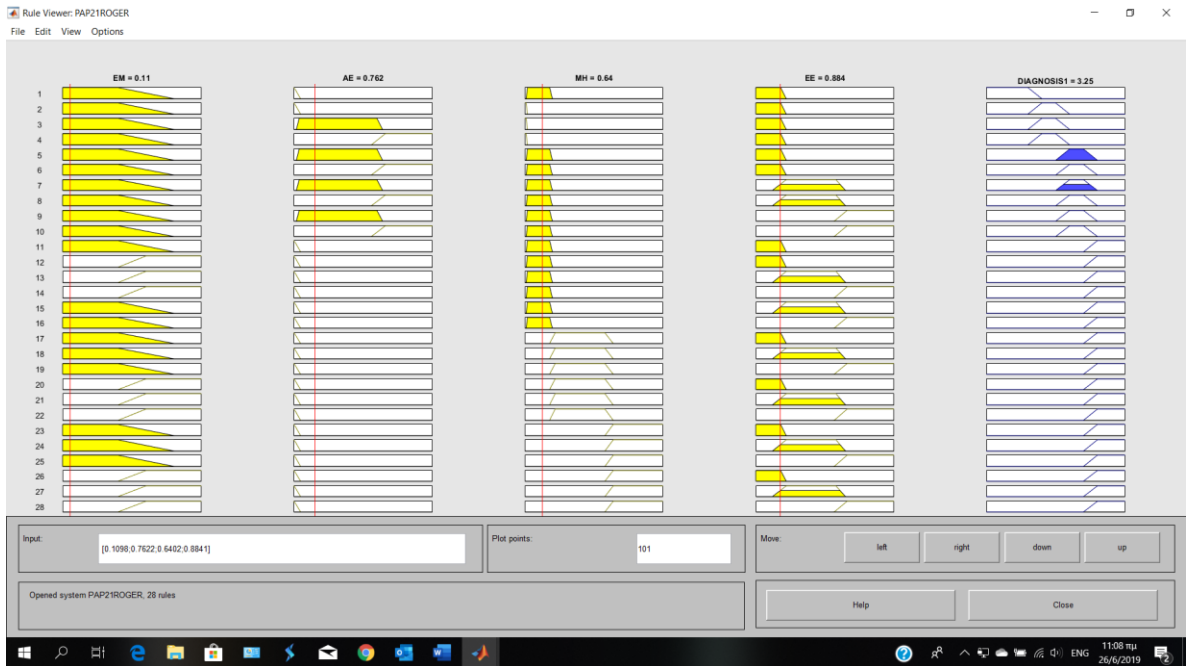
Σύστημα συμπερασμάτων (Inference scheme)

#### ***Επεξεργασία κανόνων***

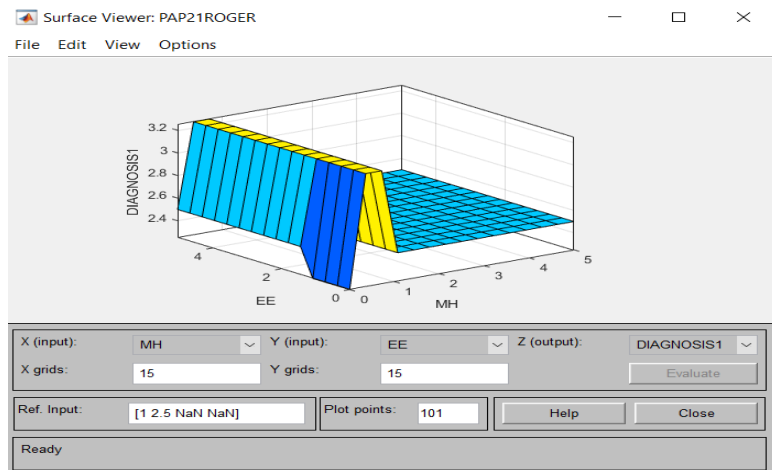
Σε αυτό το βήμα πραγματοποιείται ο μηχανισμός της απόφασης κατά τον οποίο αξιολογούνται όλοι οι κανόνες και μετά τη διαδικασία συνεπαγωγής, ανάλογα με το βαθμό εκπλήρωσης ή συμμετοχής του καθενός, το σύστημα βγάζει ένα συμπέρασμα. Ο μηχανισμός συμπερασμού βασίζεται στη **συνεπαγωγή Mamdani**.

Μέσω του FIS Editor παρέχεται η δυνατότητα για δύο “οπτικές πιστοποιήσεις” του FIS επιλέγοντας View Rules, και View Surface.

#### Επισκόπηση Κανόνων (Rule Viewer)



Σχήμα 3.4. Rule Viewer - Επισκόπηση Κανόνων



Σχήμα 3.5. Surface Viewer-Επισκόπηση Επιφανειών

## ΒΗΜΑ ΤΕΤΑΡΤΟ

### Defuzzification (Αποασαφοποίηση)

Το τελευταίο μέρος ενός συστήματος Ασαφούς Λογικής είναι η αποασαφοποίηση της ασαφούς εξόδου σε σαφή τιμή. Υπάρχουν διάφορες τεχνικές αποασαφοποίησης, δεν υπάρχει θεωρητική βάση για καμία από αυτές, το βασικό κριτήριο επιλογής μιας κατάλληλης τεχνικής είναι η υπολογιστική απλότητα. Συνήθως επιλέγεται η *Αποασαφοποίηση Κέντρου Βάρους*.

Συνεχίζοντας και εκτελώντας την εντολή View-Rules, εμφανίζονται τα αποτελέσματα του Ασαφούς Συστήματος Συμπερασμού στα οποία επεμβαίνουμε εμείς, εισάγοντας Αριθμητικά δεδομένα εισόδου. Μεταβάλλοντας κάθε φορά τις τιμές των εισόδων είτε μετακινώντας τις κόκκινες κατακόρυφες γραμμές με το ποντίκι, είτε εισάγοντας τα αριθμητικά δεδομένα, βλέπουμε τις αντίστοιχες εξόδους (Σχήμα 3.4).

Τα αποτελέσματα του κάθε μοντέλου καταγράφονται σε πίνακες και επεξηγούνται στο κεφάλαιο 4.

### 3.2 Μεθοδολογία διάγνωσης σφαλμάτων με τη μέθοδο Τεχνητών Νευρωνικών Δικτύων (ANN)

Η διάγνωση σφαλμάτων Μ/Σ ισχύος μέσω Τεχνητών Νευρωνικών Δικτύων είναι ένα πρόβλημα ταξινόμησης.

**Ταξινόμηση (Classification)** είναι το πρόβλημα της αναγνώρισης της κατηγορίας στην οποία ανήκει ένα πρότυπο, δεδομένου ενός συνόλου εκπαιδευτικών προτύπων που περιέχουν παρατηρήσεις των οποίων η ιδιότητα μέλους είναι γνωστή.

Το Neural Network toolbox είναι ένα λογισμικό ευρείας χρήσης που χρησιμοποιείται στο σχεδιασμό και την ανάπτυξη των νευρωνικών δικτύων. Είναι φιλικό προς το χρήστη και επιτρέπει την αλληλεπίδραση με άλλα toolbox.

Όπως αναφέρθηκε και στα προηγούμενα κεφάλαια η υλοποίηση του μοντέλου για την διάγνωση σφαλμάτων Μ/Σ ισχύος μέσω της μεθόδου Roger's Ratio πραγματοποιείται με

ένα Multilayer Feed Forward Back Propagation Neural Network. Ο Πίνακας 1 και ο Πίνακας 2 απεικονίζουν το σύνολο δεδομένων εκπαίδευσης του δικτύου.

### **3.2.1 To Neural Network toolbox του MATLAB**

Σε γενικές γραμμές η διαδικασία που πραγματοποιείται από το πρόγραμμα είναι η ακόλουθη:

Σε κάθε βήμα της εκπαίδευσης τα συναπτικά βάρη διορθώνονται από τον αλγόριθμο εκπαίδευσης ώστε οι στόχοι να συμπίπτουν με την πρόβλεψη (έξοδο) του δικτύου για κάθε πρότυπο. Κατά την ανάκληση το δίκτυο τροφοδοτείται με άγνωστα πρότυπα ώστε να αναγνωριστεί η κατηγορία κάθε προτύπου. Ο κανόνας εκμάθησης δηλαδή ο μαθηματικός αλγόριθμος που χρησιμοποιούνται για να ανανεώσει τα βάρη των συνδέσεων είναι ο Back Propagation.

**Είσοδοι δικτύου :** Οι τέσσερις λόγοι αερίων

**Έξοδοι - στόχοι δικτύου :** Τα 12 είδη σφαλμάτων των μετασχηματιστών (από Πίνακα 1.7).

Τα δεδομένα ταξινομούνται από το MATLAB σε training, validation, and testing sets. Το σύνολο train data αποτελείται από το 70% των συνολικών 100 data sample δηλαδή έχουμε 88 δείγματα προκειμένου να εκπαιδευτεί το δίκτυο, και το υπόλοιπα 30% είναι τα validation και test data. Αυτά εισάγονται στο MATLAB, παρακάτω αναπτύσσεται η διαδικασία που ακολουθήθηκε βήμα-βήμα προκειμένου να επιτευχθεί η σχεδίαση του νευρωνικού δικτύου και να ληφθούν τα αποτελέσματα της παρούσας μελέτης τα οποία παρουσιάζονται στο επόμενο κεφάλαιο.

### **Ταξινόμηση -κωδικοποίηση κατηγοριών**

#### **ΒΗΜΑ 1:**

**Κωδικοποίηση των κατηγοριών:** Αντιστοιχίζεται κάθε κατηγορία σε διάνυσμα (ή τιμή) εξόδου. Με αυτόν τον τρόπο το πρόβλημα ταξινόμησης μετατρέπεται σε πρόβλημα προσέγγισης προκειμένου να εισαχθούν τα αρχικά σύνολα εκπαίδευσης από ζεύγη της μορφής:

δεδομένο – κατηγορία  $\Rightarrow$  δεδομένο - διάνυσμα στόχος

Ισχύει γενικά :

Κάθε διάνυσμα-στόχος έχει  $p$  συνιστώσες  $(t_1, \dots, t_p)$  και η κατηγορία  $C_k$  κωδικοποιείται θέτοντας  $t_k=1$  και  $t_i=0$  για  $i \neq k$ .

*Στο παρόν πρόβλημα ορίζονται οι μεταβλητές:*

- **Διανύσματα εισόδου** είναι *οι 4 κωδικοί των λόγων των αερίων :  $X_1, X_2, X_3, X_4$*  που λαμβάνονται από τον Πίνακα 1.6.
- **Διανύσματα εξόδου** είναι οι 12 βλάβες που εμφανίζονται σε έναν Μ/Σ ισχύος  $Y_1, Y_2, Y_3, Y_4, \dots, Y_{10}, Y_{11}, Y_{12}$  και αναγράφονται στον Πίνακα 1.7. Δηλαδή έχουμε ένα πρόβλημα με δώδεκα κατηγορίες.

Σύμφωνα με τον Πίνακα 1.7, κάθε συνδυασμός των 4 διανυσμάτων εισόδου κατατάσσεται σε ένα από τα 12 διανύσματα εξόδου.

Γενικά η ταξινόμηση ενός προτύπου γίνεται εφαρμόζοντας το πρότυπο ως είσοδο στο δίκτυο και επιλέγοντας την κατηγορία που αντιστοιχεί στην έξοδο με τη μεγαλύτερη τιμή. – Όσο πιο κοντά στο 1 είναι αυτή η έξοδος και κοντά στο μηδέν οι υπόλοιπες έξοδοι, τόσο πιο **αξιόπιστη** είναι η ταξινόμηση. ( Παράδειγμα Πίνακας 4).

## **ΒΗΜΑ 2**

Εισαγωγή των δεδομένων στο **Neural Network toolbox του MATLAB**

Κάθε μεταβλητή είναι ένας Πίνακας ενώ η είσοδος μπορεί να είναι πολυδιάστατος Πίνακας.

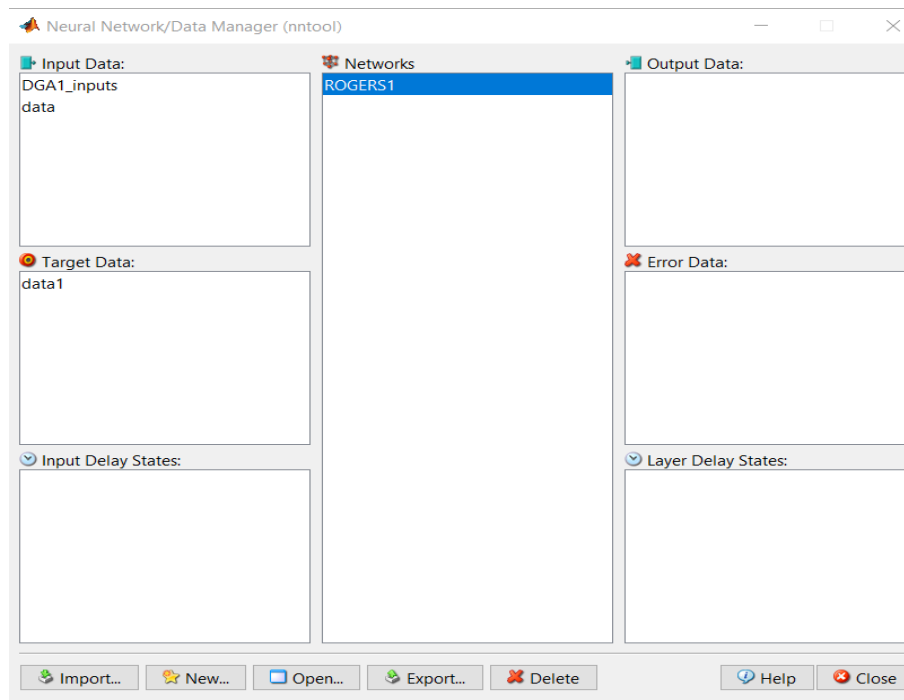
Τα διανύσματα εισόδου και εκπαίδευσης αποθηκεύονται σε δύο μεταβλητές (πίνακες) **Η είσοδος στην μεταβλητή “input”**

**Η επιθυμητή έξοδος στην “target”.**

**Η πραγματική έξοδος του μοντέλου αποθηκεύεται στην μεταβλητή “output”**

### *3.2.1.α To GUI για το nntool*

Στο Command Window του MATLAB πληκτρολογούμε την εντολή : `>> nntool` και εμφανίζεται στην οθόνη ο **NN Network/Data Manager**.



Σχήμα 3.6. NN Network/Data Manager

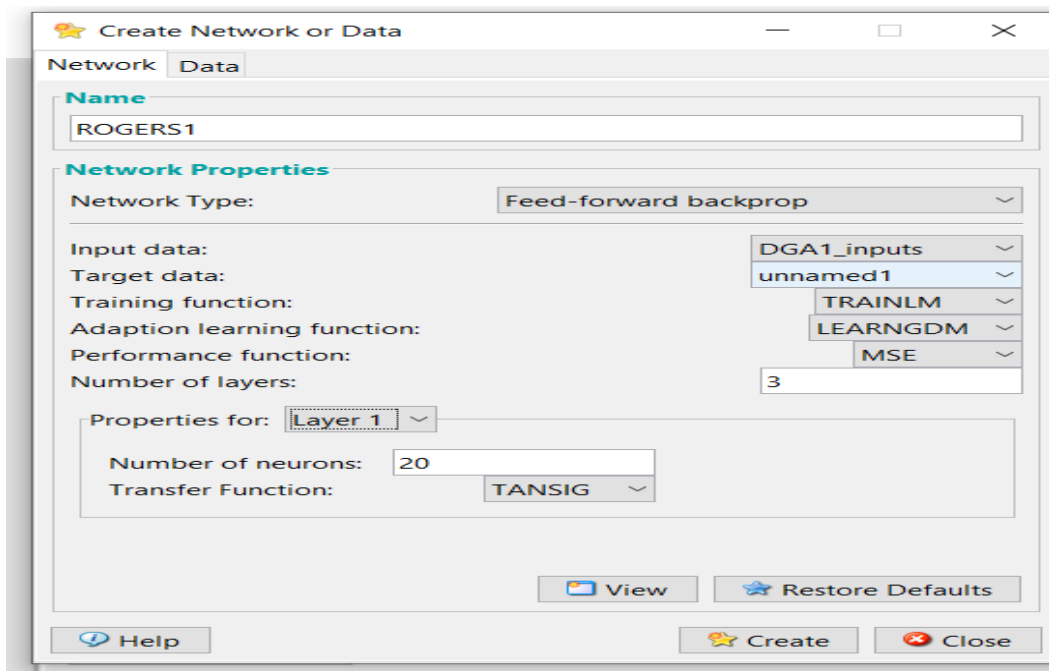
Από την επιλογή import εισάγονται τα “input data” υπό μορφή πίνακα  $[4 \times 88]$  και τα “target data” υπό μορφή πίνακα  $[12 \times 88]$ .

Πραγματική έξοδος του μοντέλου στη μεταβλητή “output”.

### ΒΗΜΑ 3

#### Δημιουργία του Νευρωνικού Δικτύου

Επιλέγοντας “new” στο παράθυρο “Network/Data Manager”, ανοίγει το παράθυρο “create Network or data”. (Σχήμα 3.7)



Σχήμα 3.7. Παράθυρο δημιουργίας νευρωνικού δικτύου “create network or data”

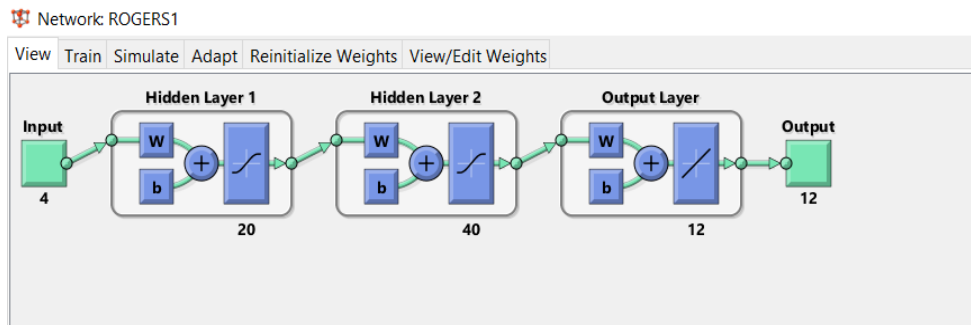
- Δηλώνεται το όνομα του δικτύου “ROGERS 1”.
- Στην επιλογή Network Type Επιλέγεται ο τύπος του νευρωνικού δικτύου “feed-forward backprop”,
- Δηλώνονται ο Πίνακας των δεδομένων εισόδου (input data) και των επιθυμητών στόχων (target data).
- Καθορίζεται ο αλγόριθμος-συνάρτηση εκπαίδευσης training function: TRAIN LM

Και ορίζονται:

- Εκπαίδευση κατά εποχές (batch training)
- Κριτήριο απόδοσης (performance function) MSE
- Αριθμός των επιπέδων (number of layers) στον οποίον συμπεριλαμβάνονται τα κρυφά επίπεδα και το επίπεδο εξόδου: 3
- Αριθμός νευρώνων (number of neurons) κάθε επιπέδου (properties for : layer x) 20,40,12
- Συνάρτηση ενεργοποίησης τους (transfer function), TANSIG, TANSIG, PURELIN  
Και επιλέγεται το κουμπί “create

# Παράθυρο Network

## 1. View

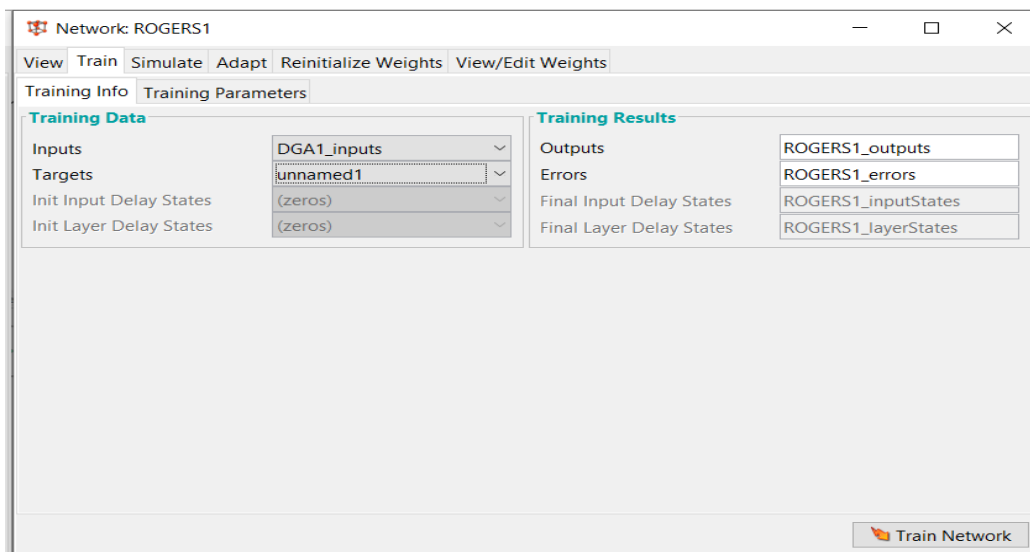


Σχήμα 3.8. Παράθυρο ANN 2 κρυφών επιπέδων στο MATLAB

## 2. Train

### Καθορισμός παραμέτρων εκπαίδευσης από την καρτέλα “training info”

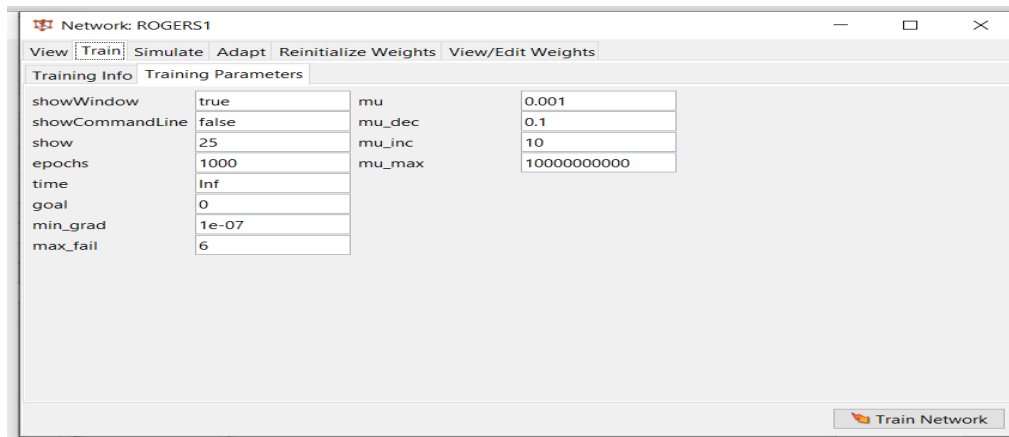
Επιλέγεται το **Train**. Στην καρτέλα **training info** δηλώνονται τα δεδομένα εκπαίδευσης, τα δεδομένα εισόδου στο “inputs” και οι επιθυμητές έξοδοι στο “targets” ενώ αντίστοιχα δηλώνονται και τα ονόματα με τα οποία θα αποθηκευτούν τα αποτελέσματα. (Σχήμα 3.9)



Σχήμα 3.9. Καθορισμός παραμέτρων εκπαίδευσης “training info”

### Καθορισμός παραμέτρων εκπαίδευσης από την καρτέλα “training parameters”





Σχήμα 3.10. Καθορισμός παραμέτρων εκπαίδευσης “training parameters”

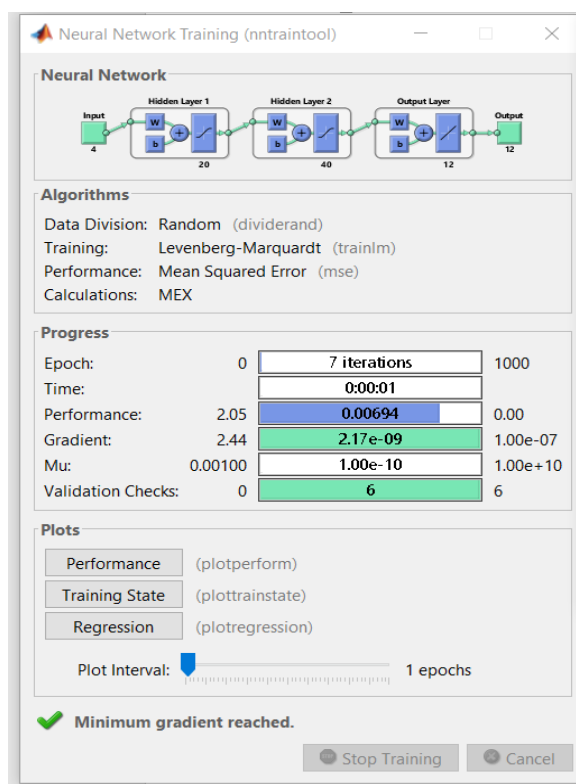
Εδώ φαίνονται οι σημαντικότερες παράμετροι της εκπαίδευσης. Οι παράμετροι αυτοί συνήθως δεν αλλάζονται και είναι προτεινόμενοι από το MATLAB. Ξεχωρίζουν:

- Το πεδίο “show” στο οποίο καθορίζεται ανά πόσες εποχές να φαίνονται τα αποτελέσματα της εκπαίδευσης.
- Το πεδίο “epoch” με το οποίο δηλώνεται σε πόσες εποχές θα τερματίσει η εκπαίδευση εάν δεν έχει επιτευχθεί ο στόχος ο οποίος ορίζεται στο πεδίο “goal”.
- Η παράμετρος “time” καθορίζει τον χρόνο στον οποίον θα τελειώσει η εκπαίδευση εάν δεν συγκλίνει το δίκτυο.
- Η παράμετρος “min\_grad” δηλώνει την ελάχιστη τιμή της παραγώγου, την οποία αν το δίκτυο επιτύχει, αποτυγχάνει και σταματά την εκπαίδευση.

## ΒΗΜΑ 4

### Εκπαίδευση Δικτύου - Train Network

Επιλέγοντας το “train Network” το MATLAB πραγματοποιεί την εκπαίδευση του δικτύου. Μόλις οι στόχοι των παραμέτρων που ορίστηκαν στο προηγούμενο βήμα επιτευχθούν, η διαδικασία της εκπαίδευσης ολοκληρώνεται και απεικονίζεται στην παρακάτω καρτέλα (Σχήμα. 3.11)



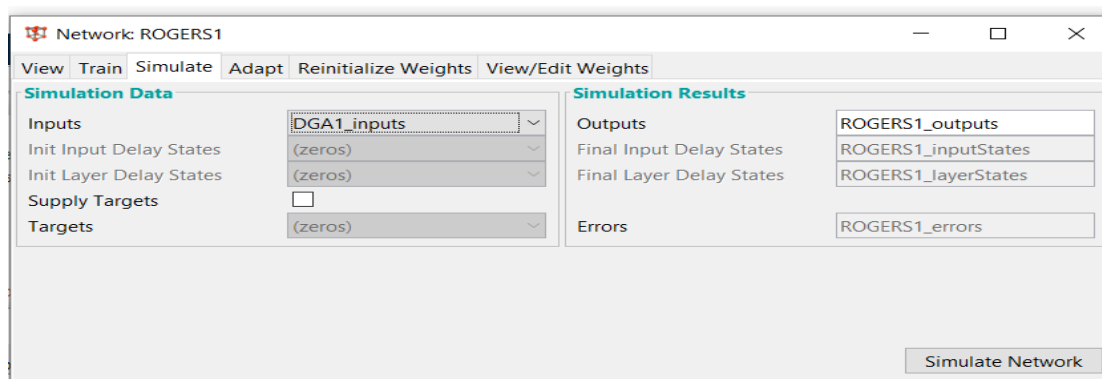
Σχήμα 3.11. Παράθυρο GUI “ntraintool” μετά την εκπαίδευση του ANN

## ΒΗΜΑ 5

### Προσομοίωση Δικτύου-Simulate

Αφού ολοκληρώθηκε η εκπαίδευση του δικτύου μπορεί να γίνει η προσομοίωση από την καρτέλα “simulate” του παραθύρου “Network ROGERS1”.

Επιλέγεται στο input το όνομα της μεταβλητής που δόθηκε στα δεδομένα προσομοίωσης DGA1\_inputs και στο πλαίσιο Simulation Results φαίνεται το όνομα της μεταβλητής ROGERS1\_outputs στην οποία θα αποθηκευτούν τα αποτελέσματα της προσομοίωσης. Επιλέγοντας την μεταβλητή εξόδου βλέπουμε την έξοδο του δικτύου για τα δεδομένα που δόθηκαν προς προσομοίωση.

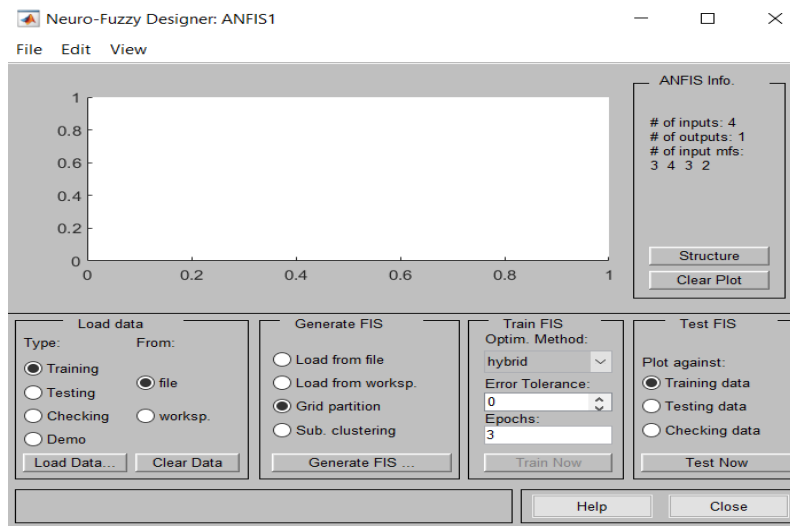


Σχήμα 3.12. Simulation Data

Η έξοδος του δικτύου ROGERS1\_outputs, για 20 δείγματα (Πίνακας 3) που εισήχθησαν στο ANN ROGERS1 για ταξινόμηση απεικονίζεται στον Πίνακα 4.

### 3.3 Μεθοδολογία διάγνωσης σφαλμάτων με την μέθοδο Προσαρμοστικού Συστήματος Νευρο-ασαφούς Συμπερασμού- ANFIS

Η εφαρμογή Neuro-Fuzzy Designer επιτρέπει τον σχεδιασμό, την εκπαίδευση και την δοκιμή (ANFIS) χρησιμοποιώντας δεδομένα εκπαίδευσης εισόδου / εξόδου. Από τα Apps του MATLAB επιλέγεται το Neuro Fuzzy Designer και εμφανίζεται το παράθυρο Anfis Editor από το οποίο γίνονται όλες οι ενέργειες για τη δημιουργία του μοντέλου ANFIS.



Σχήμα 3.13. Neuro Fuzzy Designer

### 3.3.1 Προσομοίωση του Νευρο-Ασαφούς Συστήματος μέσω της εφαρμογής Neuro-Fuzzy Designer του MATLAB

#### ΒΗΜΑ 1

##### – Εισαγωγή δεδομένων εκπαίδευσης

A. Κατά τη μέθοδο **Rogers** χρησιμοποιούνται τέσσερις λόγοι συγκέντρωσης αερίων (λόγοι του Rogers):

$$MH = CH_4/H_2$$

$$EE = C_2H_4/C_2H_6$$

$$AE = C_2H_2/C_2H_4$$

$$EM = C_2H_6/CH_4$$

Από τον Πίνακα 4.2 δημιουργώ τις συναρτήσεις συμμετοχής για τις 4 εισόδους MH , EM, EE, AE

Χρησιμοποιούμε τραπεζοειδή συνάρτηση συμμετοχής. Οι συναρτήσεις δεν παρουσιάζουν επικαλύψεις στο 50% σύμφωνα με τη μέθοδο συντονισμού.

- Το σύστημα αποτελείται από 4 INPUTS

INPUT 1 MH

INPUT 2 EM

INPUT 3 EE

INPUT 4 AE

- Και μια έξοδο OUTPUT 1

Όπως παρατίθενται στον Πίνακα 3.1 οι τέσσερις κωδικοί 0,1,2,5 ορίζονται ως 4 λεκτικοί όροι των συναρτήσεων συμμετοχής και ταξινομούνται ως:

Χαμηλής σημασίας (LOW)

Μεσαίας (MED)

Υψηλής (Hi)

Πολύ Υψηλής (VH)

Ο Πίνακας 3.1 δείχνει τα διαστήματα συμμετοχής για κάθε λόγο.

- ✓ την είσοδο INPUT 1 EM την επιμερίζουμε σε 2 διαστήματα L, που αντιστοιχεί στον κωδικό 0 και H που αντιστοιχεί στον κωδικό 1 σύμφωνα με τον Πίνακα 6 μέσω τραπεζοειδών συναρτήσεων συμμετοχής.
- ✓ την είσοδο INPUT 2 AE την επιμερίζουμε σε διαστήματα L, M, H
- ✓ την είσοδο INPUT 3 MH την επιμερίζουμε σε 4 διαστήματα L, M, H, VH

- ✓ την είσοδο INPUT 4 ΕΕ την επιμερίζουμε σε 3 διαστήματα L, M, H
- ✓ την έξοδο OUTPUT 1 την επιμερίζουμε σε κατηγορίες με χρήση γλωσσικών όρων για το είδος του κάθε σφάλματος και έχουμε:  
τα **διανύσματα εξόδου** είναι οι 12 βλάβες που εμφανίζονται σε έναν Μ/Σ ισχύος  $\Upsilon_1, \Upsilon_2, \Upsilon_3, \Upsilon_4, \dots, \Upsilon_{10}, \Upsilon_{11}, \Upsilon_{12}$  και αναγράφονται στο Πίνακα 1.7

– Εισαγωγή μεταβλητών στο MATLAB Neuro Fuzzy Designer

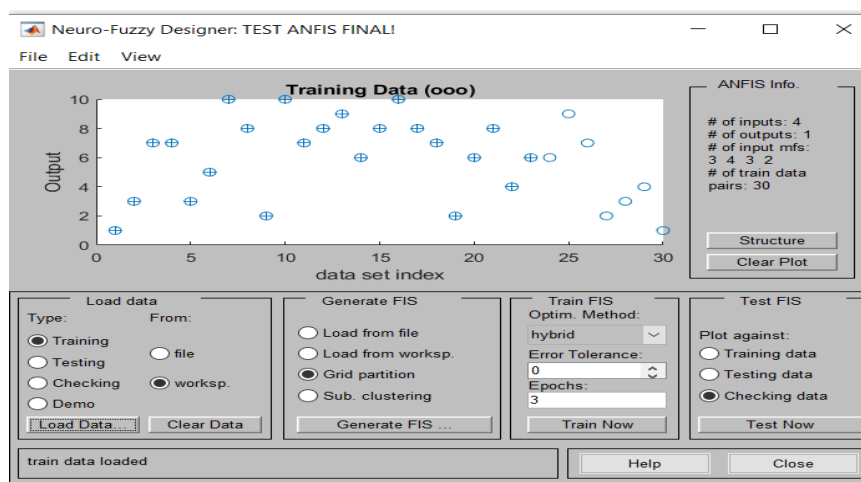
Στο workspace από το εικονίδιο New Variable και το Variable Editor δημιουργούμε 2 νέες μεταβλητές: QHtraining, QHchecking, οι οποίες περιέχουν πίνακες με δεδομένα σε στήλες, με την τελευταία στήλη να απεικονίζει τα δεδομένα εξόδου.

- Στον Variable Editor της **QHtraining** εισάγονται τα 2/3 των δεδομένων για να χρησιμοποιηθούν για την εκπαίδευση του ANFIS
- Στον Variable Editor της **QHchecking** εισάγονται το υπόλοιπο 1/3 των δεδομένων για τον έλεγχο προσαρμογής του μοντέλου.

Στον πίνακα 3.2 φαίνονται 30 data samples.

Από το πλαίσιο Load data εισάγονται τα δεδομένα γράφοντας το όνομα της μεταβλητής (π.χ. QHtraining και QHchecking κατόπιν εμφανίζονται τα δεδομένα στην περιοχή σχεδίασης.

Τα checking data συμβολίζονται με (+) ενώ τα training data με (O).



Σχήμα 3.14. Training Data

## ΒΗΜΑ 2

### Δημιουργία FIS.

Σε αυτό το βήμα δημιουργείται το σύστημα Sugeno βάσει των χαρακτηριστικών που εισάγονται.

**Επιλέγοντας το Πλαίσιο Generate FIS** και Grid partition εμφανίζεται παράθυρο όπου επιλέγονται:

- ο αριθμός των λεκτικών μεταβλητών ( για το πείραμα 3 4 3 2)
- το είδος των ασαφών συνόλων MF type (τραπεζοειδής )
- και τον τύπο της Εξόδου (γραμμικός)

Ο αριθμός των λεκτικών μεταβλητών είναι σημαντικός, καθορίζει τον αριθμό των κανόνων και απορρέει από την εμπειρία του χρήστη .

Από το **Edit** του **Anfis Editor** επιλέγοντας:

- **Membership Function.** Εμφανίζονται πληροφορίες σχετικά με τις Συναρτήσεις συμμετοχής, Λεκτικές μεταβλητές: τύπο, όνομα, εύρος και τιμές των ορίων τους.

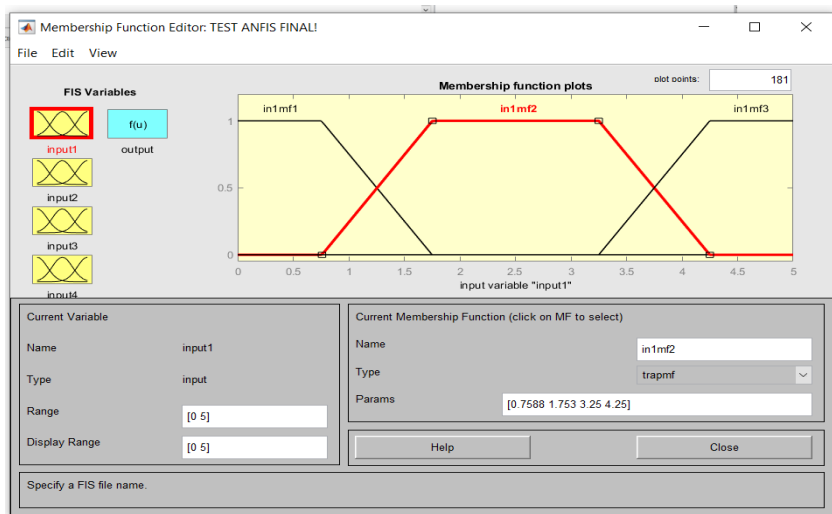
Ένα παράδειγμα Membership Function Editor απεικονίζεται παρακάτω (Σχήμα 3.15).

- **FIS Properties** Εμφανίζονται πληροφορίες σχετικά τις ιδιότητες του Ασαφούς Συστήματος τύπου Sugeno που δημιουργήθηκε.
- **Rules** Εμφανίζονται οι κανόνες που έχουν δημιουργηθεί.
- **Anfis** Εμφανίζεται το **Anfis model Structure**.

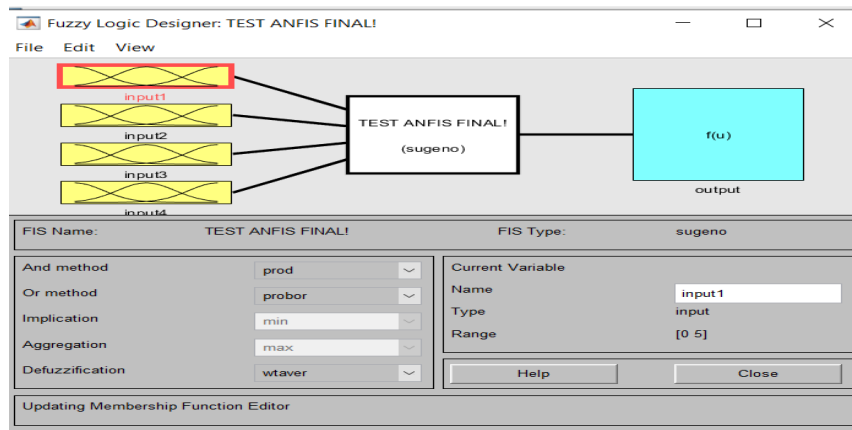
Όπως φαίνεται στο Σχήμα 3.19 το μοντέλο περιλαμβάνει 5 επίπεδα:

- **Επίπεδο 1 : input**, Μεταβλητή Εισόδου (Στάθμη). Στο πείραμα μας τις 4 μεταβλητές:  
INPUT 1 EM  
INPUT 2 AE  
INPUT 3 MH  
INPUT 4 EE
- **Επίπεδο 2 : inputmf**, Ασαφή Σύνολα (βαθμίδες γλωσσικών μεταβλητών)  
L, H  
L, M , H  
L, M , H, VH  
L, M , H
- **Επίπεδο 3: rule**, Κανόνες του συστήματος
- **Επίπεδο 4: outputmf**, Σχηματισμός ασαφών συνόλων Εξόδου

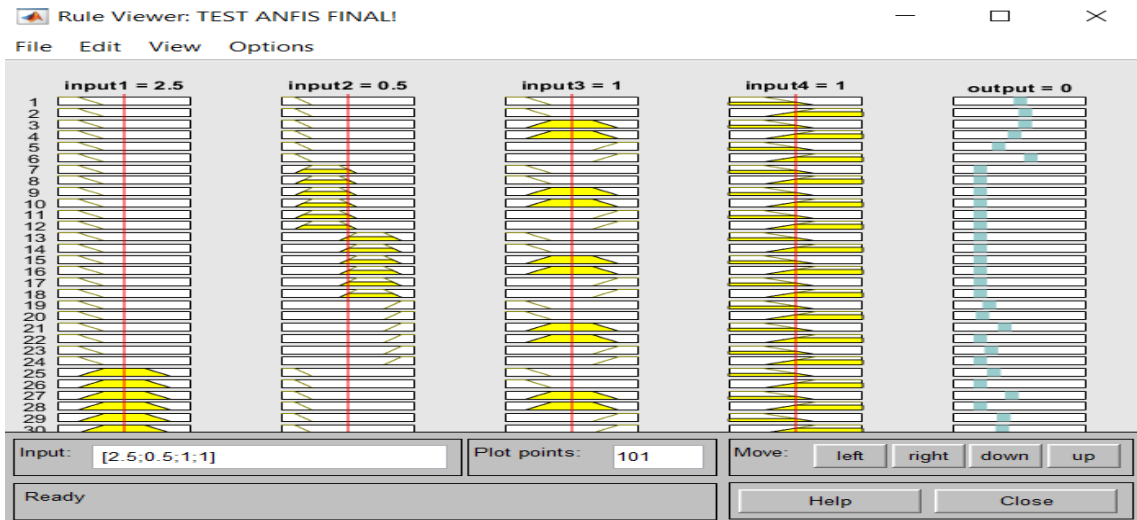
– Επίπεδο 5: output, Έξοδος (crisp)- Παροχή



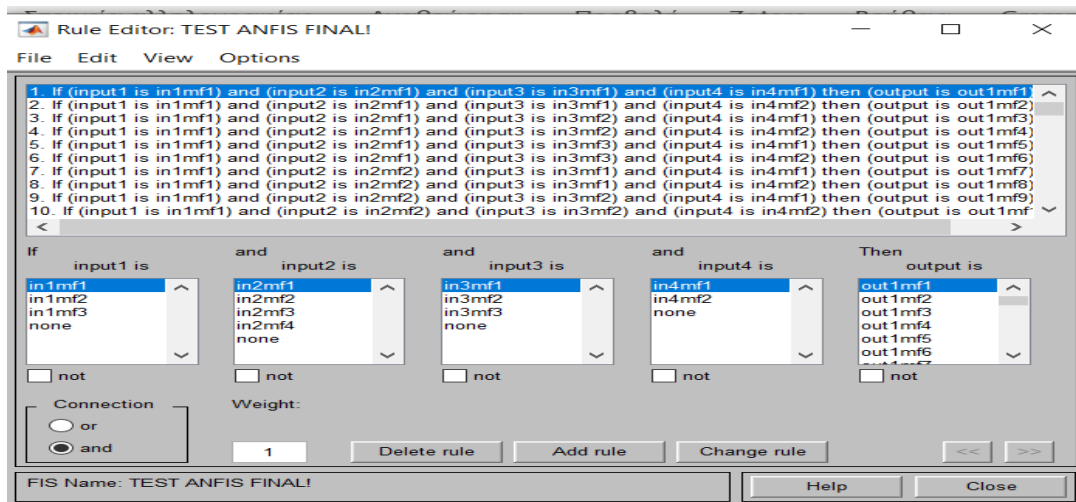
Σχήμα 3.15. Membership Function Editor



Σχήμα 3.16. FIS Properties

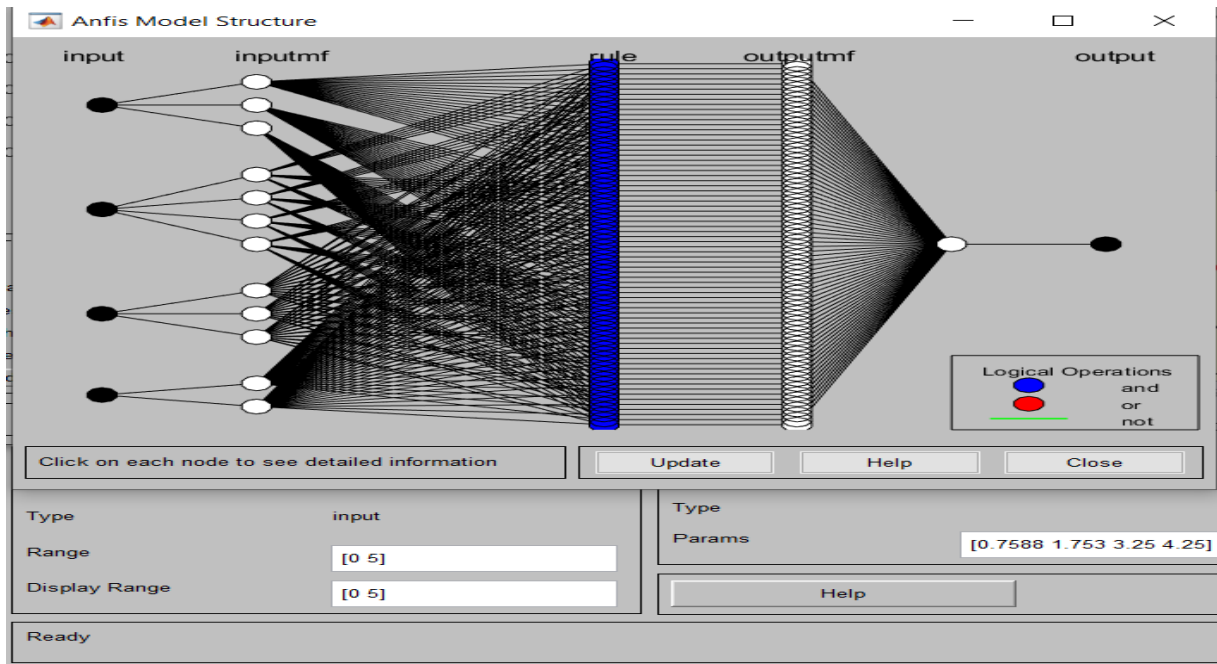


Σχήμα 3.17. Rule viewer



Σχήμα 3.18. Rule Editor





Σχήμα 3.19. Anfis model Structure

### ΒΗΜΑ 3

#### *Εκπαίδευση μοντέλου*

Πλαίσιο **Train FIS** επιλέγονται:

- Optimum method: hybrid ή την απλή μέθοδο BP. Τις περισσότερες φορές διαλέγεται η hybrid καθώς δίνει τα βέλτιστα αποτελέσματα.
- Error Tolerance (ανοχής σφάλματος)
- Epochs (αριθμός επαναλήψεων)

Επιλέγοντας Train Now λαμβάνει χώρα η εκπαίδευση του μοντέλου.

### ΒΗΜΑ 4

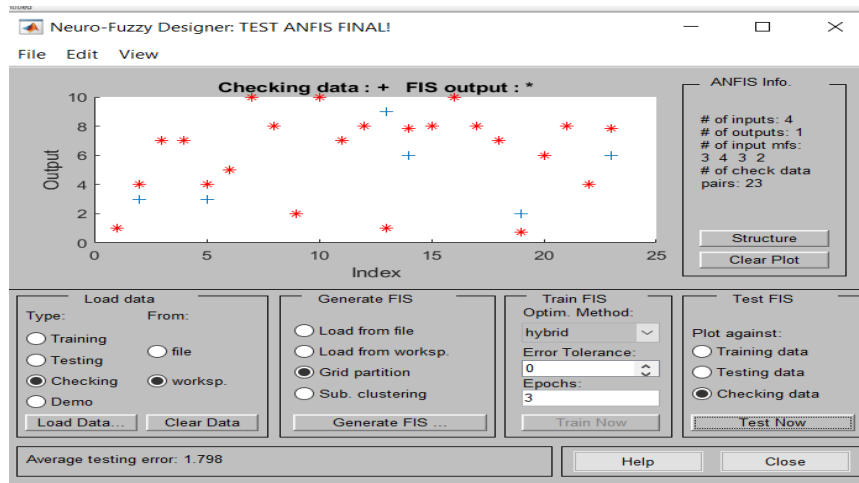
#### *Έλεγχος προσαρμογής*

Από το Πλαίσιο **Test FIS** επιλέγονται:

- Checking Data (δεδομένα ελέγχου)

Επιλέγοντας Test Now Ελέγχεται αν προσαρμόζεται ικανοποιητικά το δίκτυο στα δεδομένα όπως προσδίδει το μικρό σφάλμα.

Γενικά η προσαρμογή του μοντέλου είναι ικανοποιητική όταν τα δεδομένα ελέγχου με τα δεδομένα εξόδου έχουν μερική ταύτιση.



Σχήμα 3.20. Checking Data

Παρακάτω φαίνονται 30 data samples.

Πίνακας 3.2. Data sample

CH4/H2	C2H6/CH4	C2H4/C2H6	C2H2/C2H4	συναρτηση code X1	CODE X2	CODE X3	CODE X4	REAL FAULT
0.25	0.91	0.35	0.00	0	0	0	0	1
4.00	1.50	0.67	0.25	2	1	0	0	3
6.81	0.59	2.31	0.00	2	0	1	0	7
2.17	0.73	2.67	0.00	1	0	1	0	7
2.40	15.50	0.06	0.00	1	1	0	0	3
0.41	1.86	0.23	0.00	0	1	0	0	5
0.20	0.38	5.13	2.70	0	0	2	1	10
1.30	0.23	6.83	0.02	1	0	2	0	8
0.05	0.80	0.75	0.33	5	0	0	0	2
0.84	0.10	14.00	1.45	0	0	2	1	10
4.86	0.28	1.86	0.00	2	0	1	0	7
2.40	0.47	6.70	0.02	1	0	2	0	8
0.75	0.67	0.50	0.00	0	0	0	0	9
0.82	0.77	2.32	0.15	0	0	1	0	6
2.39	0.38	7.17	0.02	1	0	2	0	8
0.30	0.15	10.82	2.26	0	0	2	1	10
2.08	0.28	4.85	0.01	1	0	2	0	8
1.35	0.25	1.11	0.00	1	0	1	0	7
0.06	0.30	0.33	1.00	5	0	0	1	2
3.87	0.28	6.95	0.05	2	0	2	0	6

1.67	0.11	11.72	0.00	1	0	2	0	8
2.70	1.81	0.08	0.25	1	1	0	0	4
0.65	0.22	1.53	0.19	0	0	1	0	6
0.72	0.35	2.00	0.08	0	0	1	0	6
0.40	0.21	0.40	0.63	0	0	0	1	9
4.17	0.32	1.21	0.00	2	0	1	0	7
0.07	0.79	0.21	0.00	5	0	0	0	2
5.36	0.80	0.13	0.27	2	0	0	0	3
2.99	1.20	0.43	0.01	1	1	0	0	4
0.50	87.50	0.07	0.08	0	1	0	0	1

Οι ανωτέρω τιμές αποθηκεύονται στην μεταβλητή QHtraining ως ένας πίνακας [30 × 5], η τελευταία στήλη είναι ο αριθμός της κάθε βλάβης 1,2,3, ..., 12. Με τον ίδιο τρόπο αποθηκεύονται και οι τιμές στην QHchecking.

	1	2	3	4	5	6	7	8
1	0	0	0	0	1			
2	2	1	0	0	0			
3	2	0	1	0	7			
4	1	0	1	0	7			
5	1	1	0	0	3			
6	0	1	0	0	5			
7	0	0	2	1	10			
8	1	0	2	0	8			
9	5	0	0	0	2			
10	0	0	2	1	10			
11	2	0	1	0	7			
12	1	0	2	0	8			
13	0	0	0	0	9			
14	0	0	1	0	6			
15	1	0	2	0	8			
16	0	0	2	1	10			
17	1	0	2	0	8			
18	1	0	1	0	7			
19	5	0	0	1	2			
20	2	0	2	0	6			
21	1	0	2	0	8			
22	1	1	0	0	4			
23	0	0	1	0	6			
24	0	0	1	0	6			
25	0	0	0	1	9			
26	2	0	1	0	7			
27	5	0	0	0	2			
28	2	0	0	0	3			
29	1	1	0	0	4			
30	0	1	0	0	1			

Σχήμα 3.21. Μεταβλητή QHtraining

## ΚΕΦΑΛΑΙΟ 4: Εφαρμογή και Αποτελέσματα

---

Όπως αναφέρθηκε και στα προηγούμενα κεφάλαια η υλοποίηση των μεθόδων για τη διάγνωση σφαλμάτων Μ/Σ ισχύος μέσω της μεθόδου Roger's Ratio πραγματοποιείται με τρία μοντέλα Τεχνητής Νοημοσύνης:

- Σύστημα Ασαφούς Λογικής -Fuzzy Logic System
- Νευρωνικά Δίκτυα-Multilayer Feed Forward Back Propagation Neural Network.
- Προσαρμοστικό Σύστημα Νευρο-ασαφούς Συμπερασμού-Adaptive Network based Fuzzy Inference System

Η προτεινόμενη μέθοδος που ακολουθείται και αναπτύχθηκε διεξοδικά στο κεφάλαιο 3, είναι η προσομοίωση των προαναφερθέντων μοντέλων στο πρόγραμμα MATLAB. Θα εξαχθεί η ακρίβεια της κάθε μεθόδου και τέλος θα γίνει μια συγκριτική παρουσίαση των FIS, ANN, ANFIS και της συμβατικής μεθόδου Rogers Ratio . Τελικός στόχος της μελέτης αυτής είναι να εξαχθεί το μοντέλο με την βέλτιστη απόδοση για την πρόβλεψη βλαβών Μετασηματιστών Ισχύος.

*Παρακάτω περιγράφεται η κάθε μέθοδος ξεχωριστά δίνονται αναλυτικά τα βήματα της σχεδίασης, ανάπτυξης καθώς και η εξαγωγή-ανάλυση των αποτελεσμάτων.*

### 4.1 Εφαρμογή Ασαφούς Λογικής -Fuzzy Logic στην ερμηνεία των αποτελεσμάτων της DGA με τη μέθοδο Rogers.

Κατά τη μέθοδο **Rogers** χρησιμοποιούνται τέσσερις λόγοι συγκέντρωσης διαλυμένων αερίων (λόγοι του Rogers):

$$MH = CH_4/H_2$$

$$EE = C_2H_4/C_2H_6$$

$$AE = C_2H_2/C_2H_4$$

$$EM = C_2H_6/CH_4$$

➤ Από τον Πίνακα 1.6 βρίσκω τους λόγους Roger's

## *Δημιουργία στο MATLAB του Ασαφούς συστήματος (FIS)*

Από τον Πίνακα 4.2 δημιουργώ τις συναρτήσεις συμμετοχής για τις 4 εισόδους ΜΗ, ΕΜ, ΕΕ, ΑΕ.

Χρησιμοποιούμε τραπεζοειδή συνάρτηση συμμετοχής. Οι συναρτήσεις δεν παρουσιάζουν επικαλύψεις στο 50% σύμφωνα με τη μέθοδο συντονισμού.

Το σύστημα αποτελείται από:

4 INPUTS:

INPUT 1 ΜΗ

INPUT 2 ΕΜ

INPUT 3 ΕΕ

INPUT 4 ΑΕ

Και μια OUTPUT:

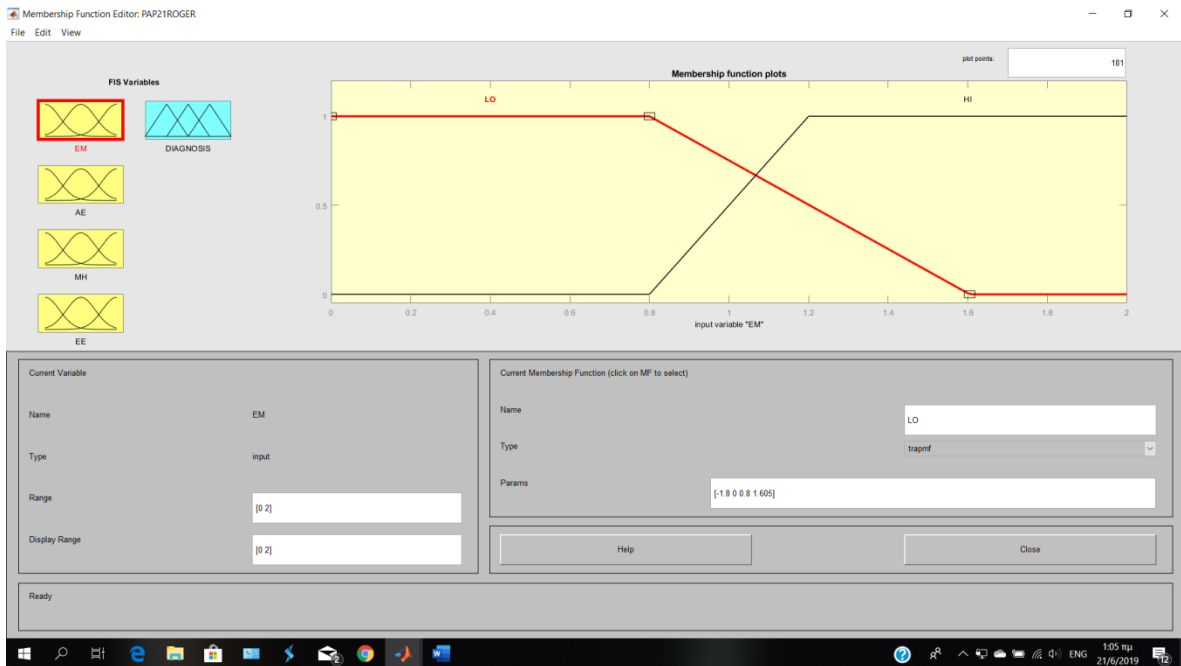
DIAGNOSIS 1

Όπως παρατίθενται στον Πίνακα 3.1 , οι τέσσερις κωδικοί 0,1,2,5 ορίζονται ως 4 λεκτικοί όροι των συναρτήσεων συμμετοχής και ταξινομούνται ως:

- ✓ Χαμηλής σημασίας (LOW)
- ✓ Μεσαίας (MED)
- ✓ Υψηλής (Hi)
- ✓ Πολύ Υψηλής (VH)

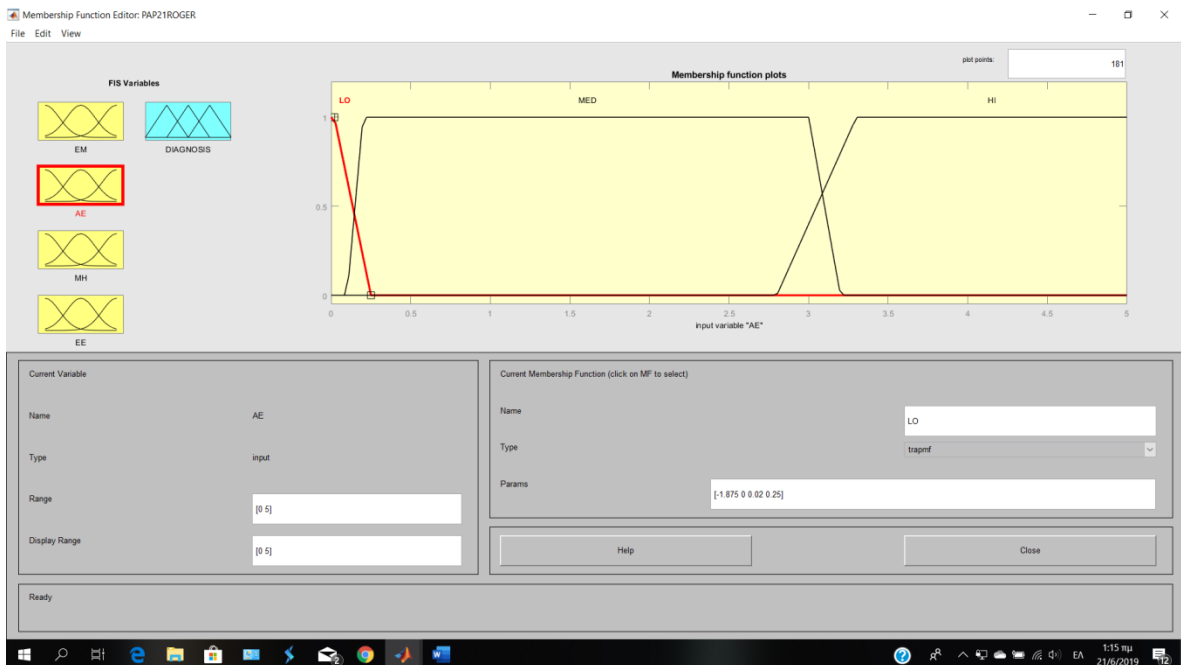
Ο Πίνακας 3.1 δείχνει τα διαστήματα συμμετοχής για κάθε λόγο.

- ✓ Την είσοδο **INPUT 1 ΕΜ** την επιμερίζουμε σε 2 διαστήματα L, που αντιστοιχεί στον κωδικό 0 και H, που αντιστοιχεί στον κωδικό 1 σύμφωνα με τον Πίνακα 3.1 μέσω τραπεζοειδών συναρτήσεων συμμετοχής.



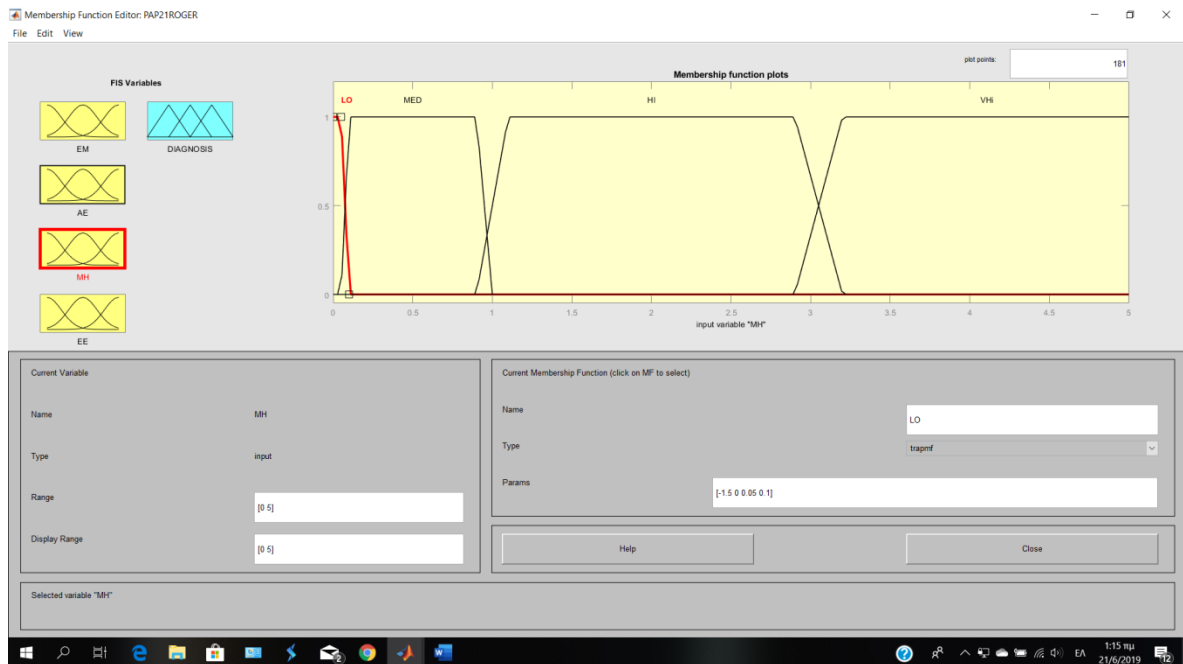
Σχήμα 4.1. INPUT 1 EM

- ✓ Την είσοδο **INPUT 2 AE** την επιμερίζουμε σε διαστήματα L, M, H σύμφωνα με τον Πίνακα 3.1 μέσω τραπεζοειδών συναρτήσεων συμμετοχής.



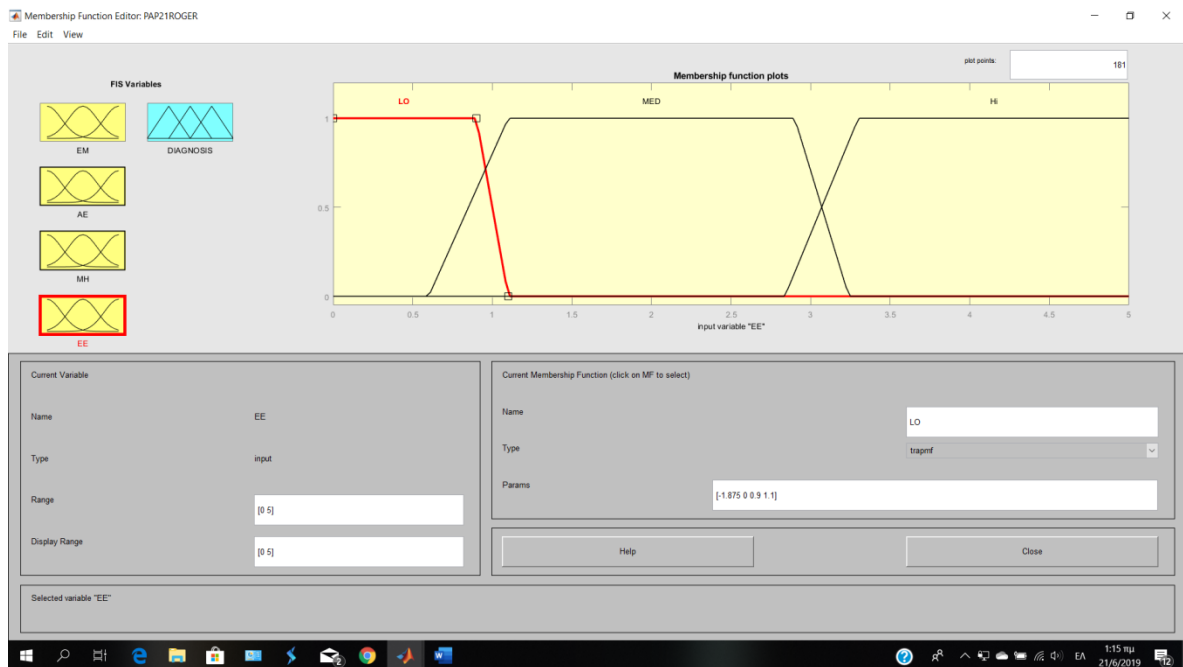
Σχήμα 4.2. INPUT 2 AE

- ✓ Την είσοδο INPUT 3 MH την επιμερίζουμε σε 4 διαστήματα L, M, H, VH σύμφωνα με τον Πίνακα 3.1 μέσω τραπεζοειδών συναρτήσεων συμμετοχής



Σχήμα 4.3. INPUT 3 MH

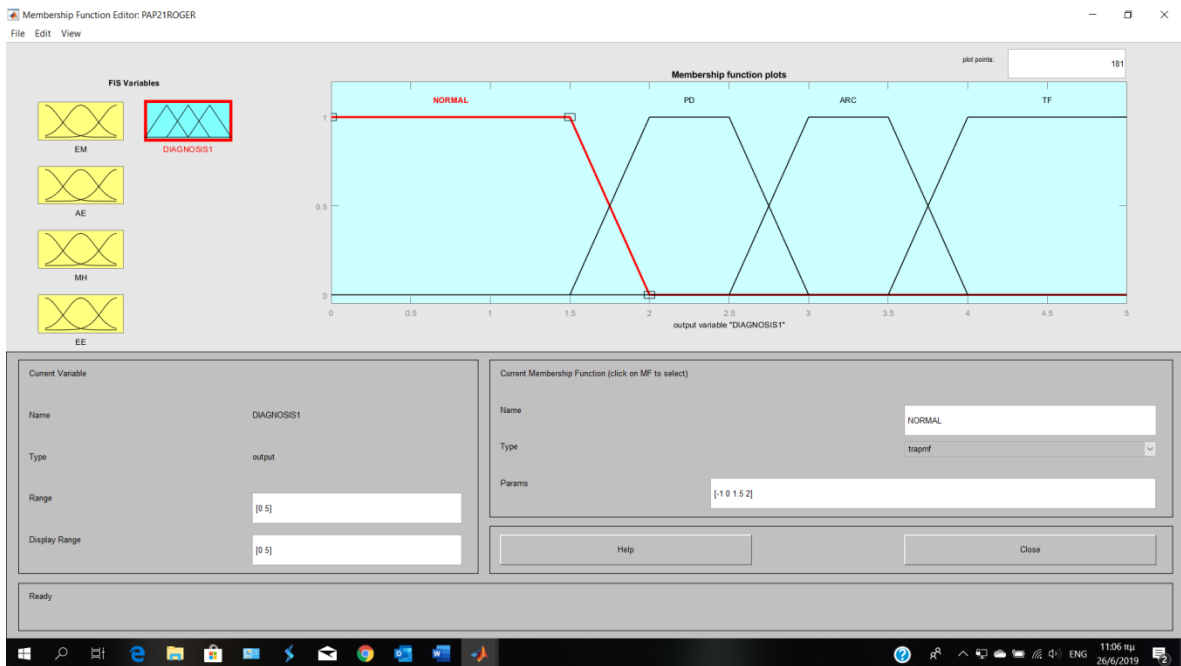
- ✓ την είσοδο INPUT 4 EE την επιμερίζουμε σε 3 διαστήματα L, M, H σύμφωνα με τον Πίνακα 3.1 μέσω τραπεζοειδών συναρτήσεων συμμετοχής.



#### Σχήμα 4.4. INPUT 4 EE

✓ Την έξοδο **OUTPUT 1: DIAGNOSIS 1** την επιμερίζουμε σε κατηγορίες με χρήση γλωσσικών όρων για το είδος του κάθε σφάλματος, σύμφωνα με τον Πίνακα 5 έχουμε:

- NORMAL
- PD
- ARC
- TF




Σχήμα 4.5. DIAGNOSIS 1



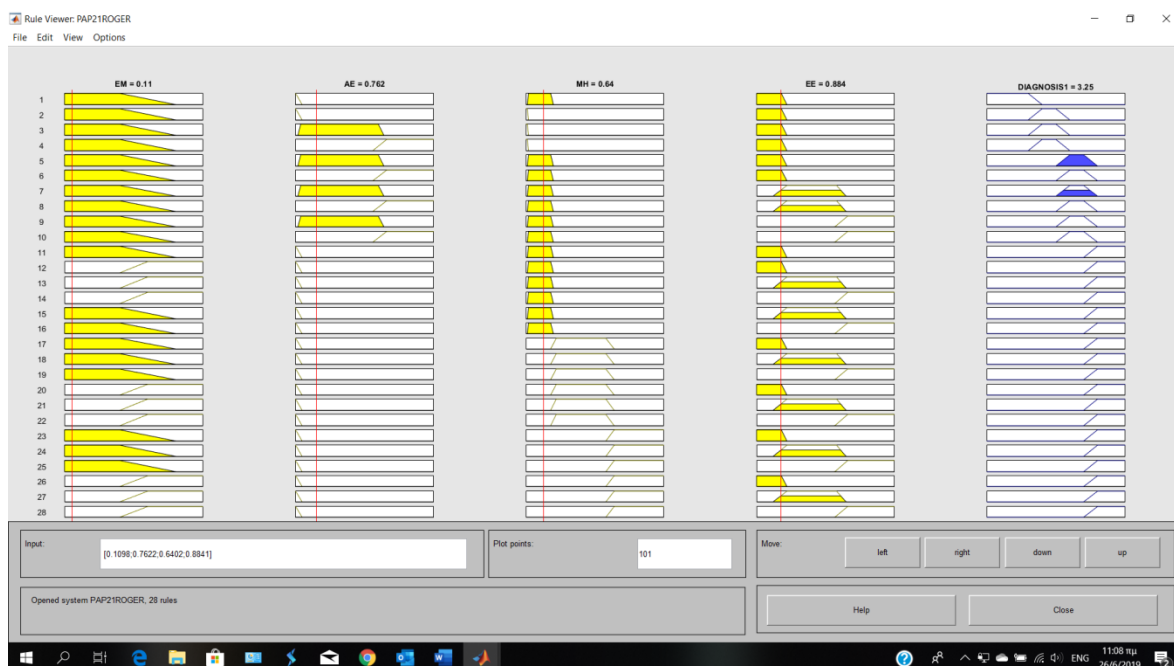
## Δημιουργία Ασαφών κανόνων

Βάση του παραπάνω μοντέλου μπορούν να εξαχθούν 29 ασαφείς κανόνες από τις τέσσερις αναλογίες αερίων:



Σχήμα 4.6. Rule Editor

## Επεξεργασία κανόνων



Σχήμα 4.7. Rule Viewer

Εν κατακλείδι μπορούμε να πούμε ότι:

- Για σύνθετα και πολύπλοκα συστήματα για τα οποία διαθέτουμε λίγα αριθμητικά δεδομένα και αμφίβολη μη ακριβή πληροφορία, ο ασαφής συλλογισμός μας δίνει τη δυνατότητα να κατανοήσουμε τη συμπεριφορά του συστήματος.
- Τα συστήματα ασαφούς λογικής μπορούν να συνδυάσουν δυο διαφορετικά είδη πληροφορίας για το σύστημα. Το ένα είδος πληροφορίας είναι αριθμητικό και προέρχεται από τις μετρήσεις των αισθητήρων και το άλλο είδος της πληροφορίας προέρχεται από τη γνώση των εμπειρογνομώνων του συστήματος και εκφράζεται με φυσική γλώσσα.

#### 4.1.2 Μεθοδολογία διάγνωσης σφαλμάτων με τη μέθοδο TDCG

Η συμβατική μέθοδος διάγνωσης σφαλμάτων μετασχηματιστών, TDCG με IEC κριτήρια, χρησιμοποιείται ευρέως στην επίλυση του προβλήματος διάγνωσης σφαλμάτων, αλλά σε ορισμένες περιπτώσεις είναι πολύ δύσκολο να προσδιοριστεί η σωστή ομάδα της τιμής TDCG, ειδικά όταν η τιμή TDCG πέφτει πλησίον της οριακής γραμμής, όπως φαίνεται στους κανόνες TDCG που ορίζονται στον Πίνακα 4.1. Η μέθοδος αυτή έχει το χαρακτηριστικό να μην καθορίζει γενικώς κάποιες τιμές – όρια, επειδή τα αποτελέσματα των μετρήσεων εξαρτώνται σε μεγάλο βαθμό από τη θερμοκρασία του λαδιού, τον τύπο του λαδιού, τον τύπο του χαρτιού, την αναλογία χαρτί/λάδι κ.ά.. Για αυτό συνεκτιμάται η ταχύτητα παραγωγής αερίων για την τελική απόφαση. Ορίζονται τέσσερις καταστάσεις για την ταξινόμηση κινδύνων προκειμένου για Μ/Σ που δεν έχουν εμφανίσει πρόβλημα στο παρελθόν.

Πίνακας 4.1. Μέθοδος TDCG

Status/ TDCG	TDCG_Rates (ppm/day)	Sampling Intervals and Operating Procedures for Gas Generation Rates	
		Sampling Interval (SI)	Operating Procedure (OP)
Condition 1 <720	<10 (LO)	6 Monthly (SIA)	Continue normal operation (OPA)
	10-30 (MED)	Quarterly (SIQ)	
	>30 (HI)	Monthly (SIM)	Exercise caution. Analyse individual gases to find cause. Determine load dependant (OPB)
Condition 2 721-1920	<10 (LO)	Quarterly (SIQ)	Exercise caution. Analyse individual gases to find cause. Determine load dependant (OPB)
	10-30 (MED)	Monthly (SIM)	
	>30 (HI)		
Condition 3 1921-4630	<10 (LO)	Monthly (SIM)	Exercise caution. Analyse individual gases to find cause. Plan outage. (OPC)
	10-30 (MED)	Weekly (SIW)	
	>30 (HI)		
Condition 4 >4630	<10 (LO)	Weekly (SIW)	Exercise caution. Analyse individual gases to find cause. Plan outage. (OPC)
	10-30 (MED)	Daily (SID)	
	>30 (HI)		Consider removal from service

## Επεξήγηση Πίνακα 4.1

**Condition 1 :** Αν ο TDCG είναι κάτω από τα όρια αυτής, τότε ο μετασχηματιστής λειτουργεί ικανοποιητικά. Επιπρόσθετη διερεύνηση πρέπει να γίνει για οποιοδήποτε μεμονωμένο αέριο, του οποίου οι τιμές ξεπερνούν τα οριζόμενα επίπεδα.

**Condition 2 :** Το επίπεδο των αερίων είναι υψηλότερο από το κανονικό. Ενδεχομένως να υπάρχει ήδη κάποιο σφάλμα. Πρέπει να διενεργούνται DGA αρκετά συχνά για να υπολογιστούν τα ποσά παραγωγής κάθε αερίου ανά ημέρα.

**Condition 3 :** Το επίπεδο των αερίων είναι υψηλό και υποδηλώνει αποσύνθεση της κυτταρίνης ή/και του λαδιού. Πιθανότατα υπάρχουν ήδη σφάλματα. Πρέπει να διενεργούνται DGA αρκετά συχνά για να υπολογιστούν τα ποσά παραγωγής κάθε αερίου ανά ημέρα.

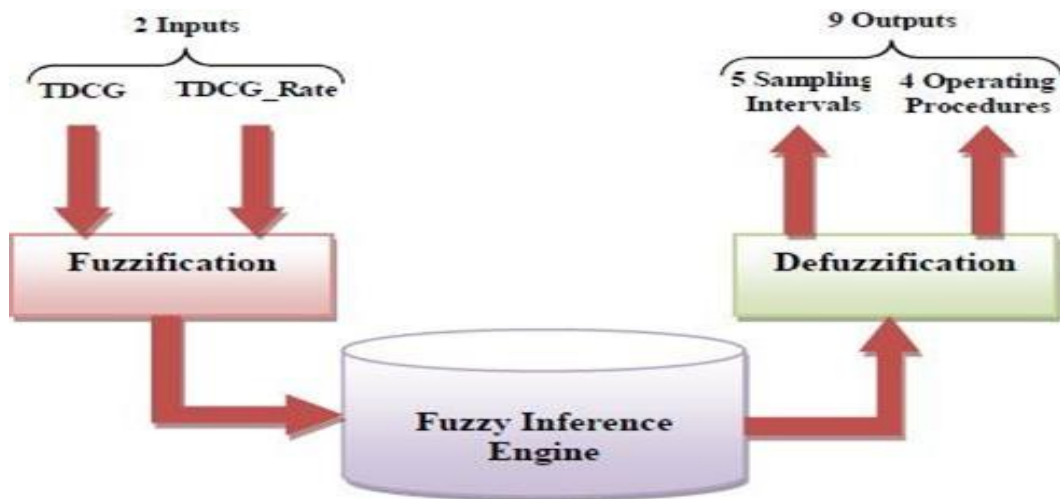
**Condition 4 :** Το επίπεδο των αερίων δείχνει υπερβολική αποσύνθεση της μόνωσης. Η λειτουργία πέρα από αυτό το σημείο οδηγεί στην καταστροφή του μετασχηματιστή.

**Condition 4,** Μέχρι αυτή την κατάσταση ο μετασχηματιστής μπορεί να παραμείνει σε λειτουργία αν η συγκέντρωση των αερίων δεν αυξάνεται ή αυξάνεται με μικρό ρυθμό. Κάποια αιφνίδια αύξηση ενός αερίου και ο ρυθμός παραγωγής αερίων είναι πιο σημαντικές ενδείξεις από το συνολικό ποσό όλων των αερίων. Η παραγωγή  $C_2H_2$  επίσης πρέπει να ληφθεί σοβαρά υπόψη, γιατί υποδηλώνει επερχόμενο τόξο. Αν στις επαναλαμβανόμενες DGA δεν διαπιστωθεί αύξηση της παραγωγής της, τότε μπορεί ο μετασχηματιστής να παραμείνει σε λειτουργία, διαφορετικά πρέπει να αποσυρθεί καθώς υπάρχει κίνδυνος έκρηξης του δοχείου.

Η συνολική συγκέντρωση διαλυμένων αερίων (TDCG) στην ανίχνευση βλαβών του μετασχηματιστή είναι χρήσιμη για την εξεύρεση του κατάλληλου διαστήματος δειγματοληψίας λαδιού με βάση την κατάσταση λειτουργίας του μετασχηματιστή, ώστε να αποφευχθεί το υψηλό κόστος λόγω υπερβολικά συχνής περιόδου δειγματοληψίας και ο κίνδυνος ενδεχομένης βλάβης λόγω μακράς περιόδου δειγματοληψίας.

Για τη διαγνωστική μέθοδο TDCG, λαμβάνουμε το άθροισμα των έξι διαλυμένων αερίων και της ταχύτητας παραγωγής αυτών. Με βάση αυτά τα αποτελέσματα, αναπτύσσεται ένα ασαφές μοντέλο χρησιμοποιώντας ως **μεταβλητές εισόδου : TDCG και TDCG\_Rate**. Η μεθοδολογία περιγράφεται διεξοδικά παρακάτω.

1. Το σχηματικό διάγραμμα του μοντέλου του έμπειρου συστήματος που χρησιμοποιήθηκε στην παρούσα εφαρμογή απεικονίζεται στο παρακάτω σχηματικό διάγραμμα:



Σχήμα 4.8. Μοντέλο Έμπειρου Συστήματος

Η διαδικασία διάγνωσης Μ/Σ μέσω Ασαφούς Λογικής-Fuzzy Logic Transformer Diagnosis γίνεται μέσω της χρήσης της θεωρίας της ασαφούς λογικής. Περιλαμβάνει τις ακόλουθες τρεις φάσεις:

#### φάση I

- Δοκιμαστική επιλογή της συγκέντρωσης των σχηματιζόμενων αερίων του Μ/Σ , *Total Dissolved Combustible Gas (TDCG)*,
- και του ρυθμού παραγωγής των σχηματιζόμενων αερίων του Μ/Σ (*TDCG\_rate*)

#### φάση II

- Διαδικασία μηχανικής προσαρμογής. mechanical-fit process

#### φάση III

- Εκτίμηση και βελτιστοποίηση του διαστήματος δειγματοληψίας (SI), και διαδικασία λειτουργίας (OP).

### Ανάλυση κάθε φάσης

#### Κατά τη φάση I

- λαμβάνουμε δεδομένα από τον Πίνακα 4.2, ο οποίος μας δίνει τις συγκεντώσεις των αερίων του προς εξέταση μετασχηματιστή μετά από 10 μετρήσεις.
- Υπολογίζουμε το άθροισμα των έξι αερίων από τον τύπο:  

$$TDCG = C_2H_2 + C_2H_4 + H_2 + CH_4 + C_2H_6 + CO \quad (1)$$
- Και τον ρυθμό παραγωγής αερίων

$$\text{TDCG\_Rate} = (\text{St}-\text{So}) / \text{T} \quad (2)$$

όπου  $\text{St} = \text{Current TDCG}$

$\text{So} = \text{Προηγούμενο TDCG}$

$\text{T} = \text{Χρόνος σε ημέρες.}$

Για παράδειγμα, τα δεδομένα που ελήφθησαν για το δείγμα αρ. 5 από τον Πίνακα 4.2 έχουμε :

$\text{H}_2 = 16, \text{CO} = 935, \text{C}_2\text{H}_4 = 28, \text{C}_2\text{H}_6 = 6, \text{CH}_4 = 12, \text{C}_2\text{H}_2 = 29,$

$\text{TDCG} = \text{C}_2\text{H}_2 + \text{C}_2\text{H}_4 + \text{H}_2 + \text{CH}_4 + \text{C}_2\text{H}_6 + \text{CO}$

τότε  $\text{TDCG} = 1026$

Ας υποθέσουμε ότι το προηγούμενο TDCG είναι 630 για το δείγμα νούμερο 5 και η διάρκεια από την τελευταία ημερομηνία δειγματοληψίας είναι 30 ημέρες.

Ο ρυθμός TDCG μπορεί να υπολογιστεί χρησιμοποιώντας τον τύπο 2 ως:  $\text{TDCG\_Rate} = (1026-630) / 30 = 13.2$

με παρόμοιο τρόπο το TDCG\_rate υπολογίζεται για όλα τα δείγματα του Πίνακα 4.2.

**Πίνακας 4.2.** Συγκεντρώσεις αερίων

S. N.	H <sub>2</sub>	CO <sub>2</sub>	CO	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	TDCG
1	6	2552	295	27	137	79	<0.5	544
2	<5	2261	51	63	160	4	2	280
3	10	8185	358	21	84	18	16	506
4	7	9320	726	327	106	171	<0.5	1337
5	16	5004	935	28	6	12	29	1026
6	1866	229	10	111	2	64	1265	3318
7	1879	198	6	36	5	29	521	2477
8	505	2626	340	817	82	256	881	2881
9	3619	2395	41	80	4	61	900	4705
10	3524	103	10	115	4	69	1163	4885

Γενικά, η μέθοδος TDCG χρησιμοποιεί το άθροισμα των 6 βασικών τιμών αερίου (όπως ο τύπος 1) και του ρυθμού παραγωγής αερίων TDCG για τον καθορισμό της διαδικασίας λειτουργίας και την πρόβλεψη του κατάλληλου διαστήματος δειγματοληψίας λαδιού όπως φαίνεται στον Πίνακα 4.1.

### ***Κατά τη φάση II έχουμε:***

Ένα γενικό σχήμα του FLTD που αντιπροσωπεύει τη δεύτερη φάση φαίνεται στο Σχήμα 4.8 Περιλαμβάνει τα ακόλουθα βήματα:

#### **BHMA ΠΡΩΤΟ**

##### **Fuzzification (Ασαφοποίηση)**

**Καθορισμός εισόδων και εξόδων.** Δηλ. καθορισμός των συγκεντρώσεων των σχηματιζόμενων αερίων και του ρυθμού παραγωγής των σχηματιζόμενων αερίων ως Ασαφών Μεταβλητών (Fuzzy Variables Determination).

**Καθορισμός Συναρτήσεων Συμμετοχής.** Το επόμενο βήμα στην ανάπτυξη του ασαφούς συστήματος είναι ο ορισμός του αριθμού των ασαφών συνόλων για κάθε μεταβλητή εισόδου και εξόδου - η μορφή της συναρτήσεως συμμετοχής που επιλέγεται είναι η τραπεζοειδής.

➤ Έχουμε δύο εισόδους

*INPUT 1 TDCG*

*INPUT 2 TDCG\_Rate*

➤ Και 2 εξόδους

*OUTPUT 1 (SI)*

Sampling Intervals, διαστήματος δειγματοληψίας  
(SIA, SIQ, SIM, SIW, SID)

*OUTPUT 2 (OP)*

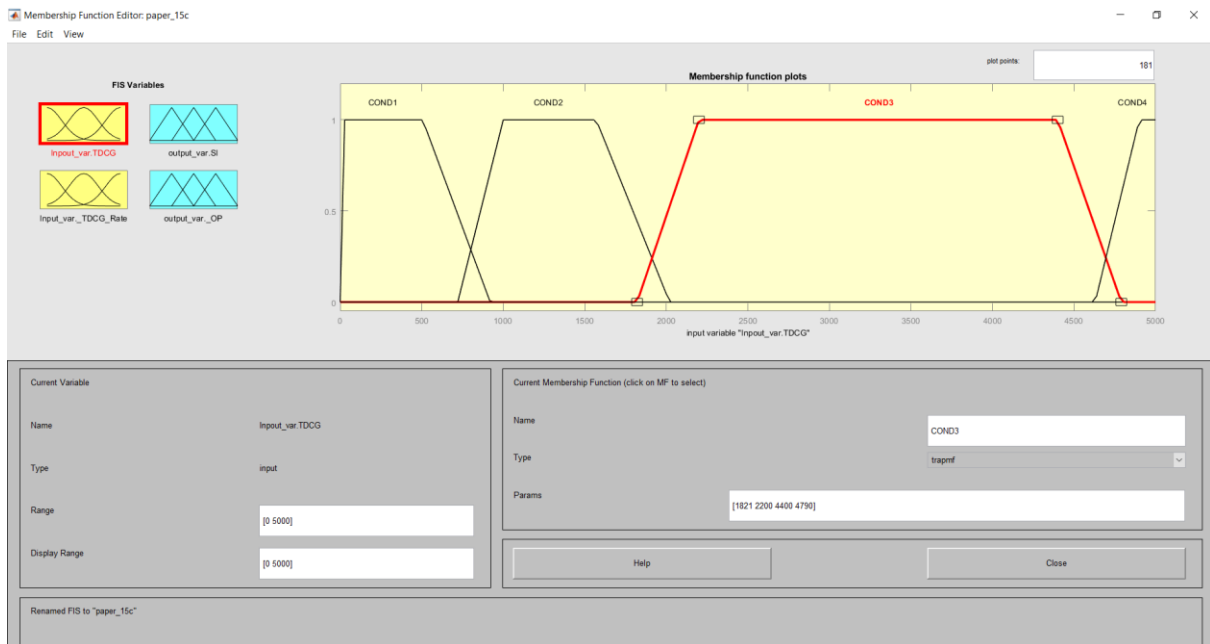
Operating Procedures διαδικασίες λειτουργίας  
(OPA, OPB, OPC OPD)

✓ την είσοδο TDCG την επιμερίζουμε σε 4 διαστήματα σύμφωνα με τον Πίνακα 4.1 μέσω τραπεζοειδών συναρτήσεων συμμετοχής.

- Στο διάστημα <720 όπου το ονομάζουμε Condition 1
- 721-1920 Condition 2
- 1921-4630 Condition 3
- > 4630 Condition 4

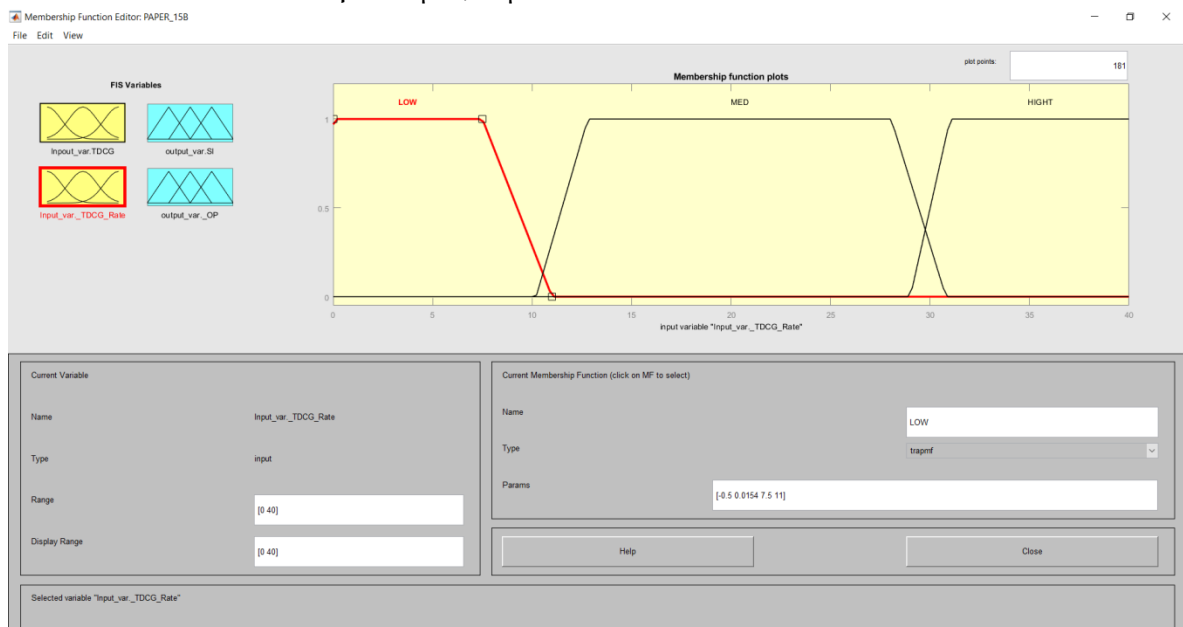
δηλ. σε 4 λεκτικούς όρους χωρίς τον στενό περιορισμό της αριθμητικής έκφρασης.

Παράδειγμα : για TDCG=1000 ppm έχουμε από την τραπεζοειδή συνάρτηση συμμετοχής της, ότι εκφράζεται με βαθμό βεβαιότητας ή συμμετοχής 0,45 ότι είναι στην Condition 2



Σχήμα 4.9. INPUT 1 TDCG

- ✓ Για την INPUT 2 TDCG\_Rate ομοίως καθορίζουμε τραπεζοειδή συνάρτηση συμμετοχής και την επιμερίζουμε σε 3 κατηγορίες με χρήση γλωσσικών όρων ανάλογα με το διάστημα τιμών TDCG\_Rate που ανήκουν, έτσι έχουμε:
- ✓ TDCG\_Rate <10 την ονομάζουμε LO
- ✓ TDCG\_Rate 10-30 την ονομάζουμε MEDIUM
- ✓ TDCG\_Rate >30 την ονομάζουμε HIGH

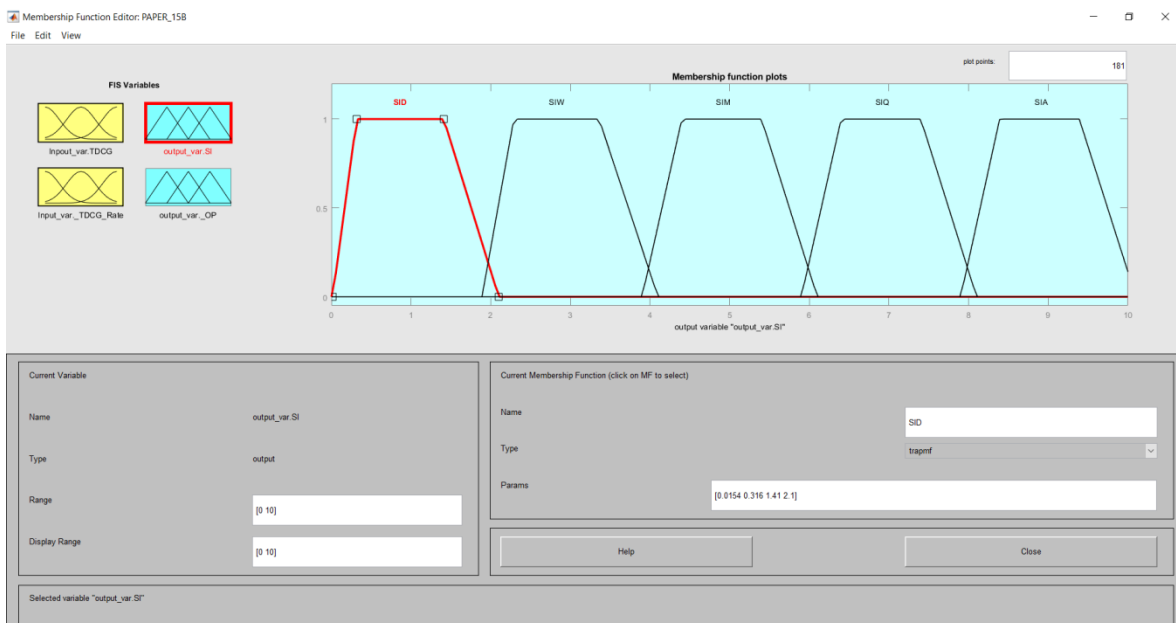


Σχήμα 4.10. INPUT 2 TDCG\_Rate



Με παρόμοιο τρόπο ορίζουμε τις TRAPEZOIDAL Membership Functions (MF) για τις εξόδους:

- ✓ OUTPUT 1 (SI) Sampling Intervals, διαστήματος δειγματοληψίας την επιμερίζουμε σε 5 κατηγορίες με χρήση γλωσσικών όρων ανάλογα με το χρονικό διάστημα λήψης δείγματος:
  - ✓ SIA, ανά 6 μήνες
  - ✓ SIQ, ανά τετράμηνο
  - ✓ SIM, ανά μήνα
  - ✓ SIW, ανά εβδομάδα
  - ✓ SID, ανά ημέρα



Σχήμα 4.11. OUTPUT 1 (SI)

- ✓ και OUTPUT 2 (OP), Operating Procedures διαδικασίες λειτουργίας, την επιμερίζουμε σε 5 κατηγορίες με χρήση γλωσσικών όρων ανάλογα με το είδος διαδικασίας λειτουργίας
  - ✓ OPA
  - ✓ OPB
  - ✓ OPC
  - ✓ OPD



Σχήμα 4.12. OUTPUT 2 (OP)

## ΒΗΜΑ ΔΕΥΤΕΡΟ

### Knowledge Representation

#### *Δημιουργία Ασαφών κανόνων.*

Οι κανόνες που είναι ένα σύνολο προτάσεων - συνδέουν το σύνολο των εισαγόμενων δεδομένων με τα αποτελέσματα. Καθορίζονται έτσι ώστε το σύστημα να μπορεί να μετατρέπει οποιαδήποτε εισερχόμενη τιμή σε κάποιο αποτέλεσμα, καλύπτοντας όλους τους δυνατούς συνδυασμούς δεδομένων - αποτελεσμάτων. Οι γλωσσικοί αυτοί κανόνες προσομοιώνουν την διαδικασία συλλογισμού ενός έμπειρου μηχανικού. Στην παρούσα εργασία οι κανόνες λαμβάνονται μέσω του Πίνακα 4.1 και παρουσιάζονται στον Πίνακα 4.3.

Στη συνέχεια εκτελούμε στο Matlab την εντολή Edit-Rules, και με βάση τις μεταβλητές εισόδου και τις μεταβλητές εξόδου διαμορφώνονται οι κανόνες. Οι κανόνες αυτοί έπειτα εισάγονται στο παράθυρο Rule Editor που προσφέρει το γραφικό περιβάλλον του FIS Editor.

Η διαμόρφωση ενός κανόνα γίνεται με την επιλογή μίας ή περισσότερων λεκτικών μεταβλητών εισόδου και μίας μεταβλητής εξόδου, ώστε να έχουν την παρακάτω μορφή:


**ΕΑΝ** η είσοδος 1 είναι MF1 (η πρώτη συνάρτηση της μεταβλητής εισόδου 1)

**ΚΑΙ** η είσοδος 2 είναι MF1

**TOTE** η έξοδος 1 θα είναι MF1 (η πρώτη συνάρτηση συμμετοχής της εξόδου 1) και η έξοδος 2 θα είναι MF1 (η πρώτη συνάρτηση συμμετοχής της εξόδου 2)

**Πίνακας 4.3. Κανόνες**

Rule 1	If (TDCG is COND.1) and (TDCG_Rate is <10) then (SI is SIA)(OP is OPA)
Rule 2	If (TDCG is COND.1) and (TDCG_Rate is 10-30) then (SI is SIQ)(OP is OPA)
Rule 3	If (TDCG is COND.1) and (TDCG_Rate is >30) then (SI is SIM)(OP is OPB)
Rule 4	If (TDCG is COND.2) and (TDCG_Rate is <10) then (SI is SIQ)(OP is OPB)
Rule 5	If (TDCG is COND.2) and (TDCG_Rate is 10-30) then (SI is SIM)(OP is OPB)
Rule 6	If (TDCG is COND.2) and (TDCG_Rate is >30) then (SI is SIM)(OP is OPB)
Rule 7	If (TDCG is COND.3) and (TDCG_Rate is <10) then (SI is SIM)(op is OPC)
Rule 8	If (TDCG is COND.3) and (TDCG_Rate is 10-30) then (SI is SIW)(OP is OPC)
Rule 9	If (TDCG is COND.3) and (TDCG_Rate is >30) then (SI is SIW)(OP is OPC)
Rule10	If (TDCG is COND.4) and (TDCG_Rate is <10) then (SI is SIW)(OP is OPC)
Rule 11	If (TDCG is COND.4) and (TDCG_Rate is 10-30) then (SI is SID)(OP is OPC)
Rule 12	If (TDCG is COND.4) and (TDCG_Rate is >30) then (SI is SID)(OP is OPD)



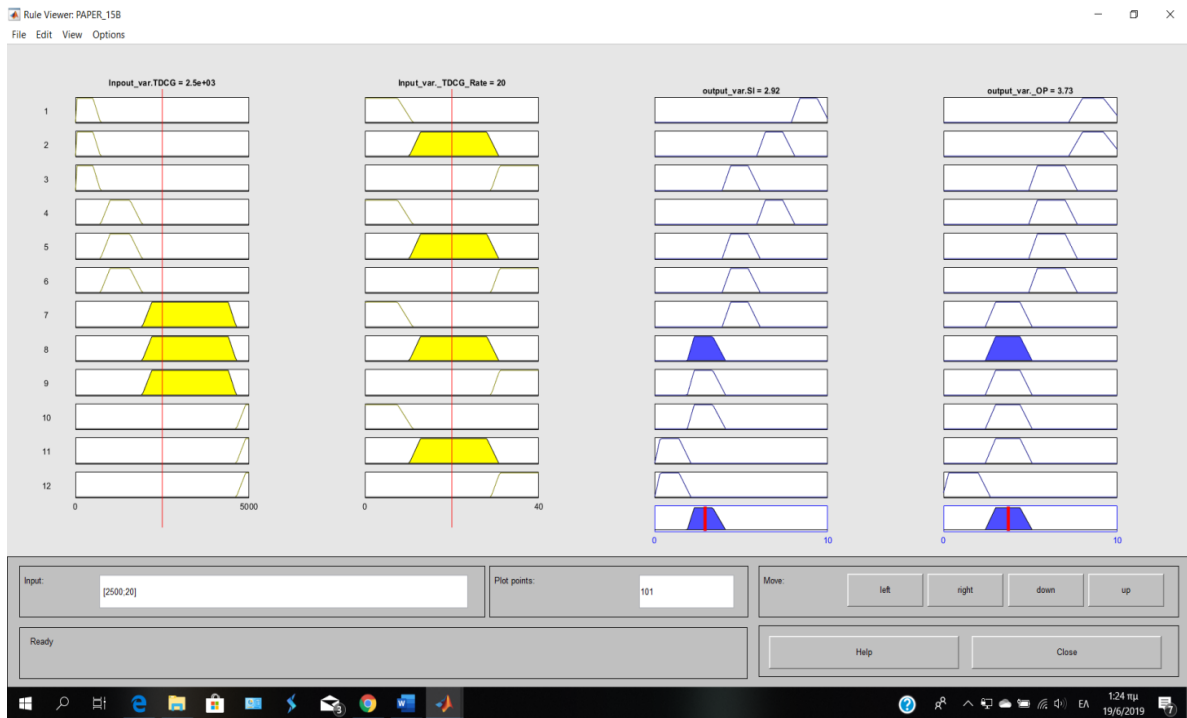
Σχήμα 4.13. Rule Editor

### *BHMA TPITO*

### *Inference scheme, Σύστημα συμπερασμάτων*

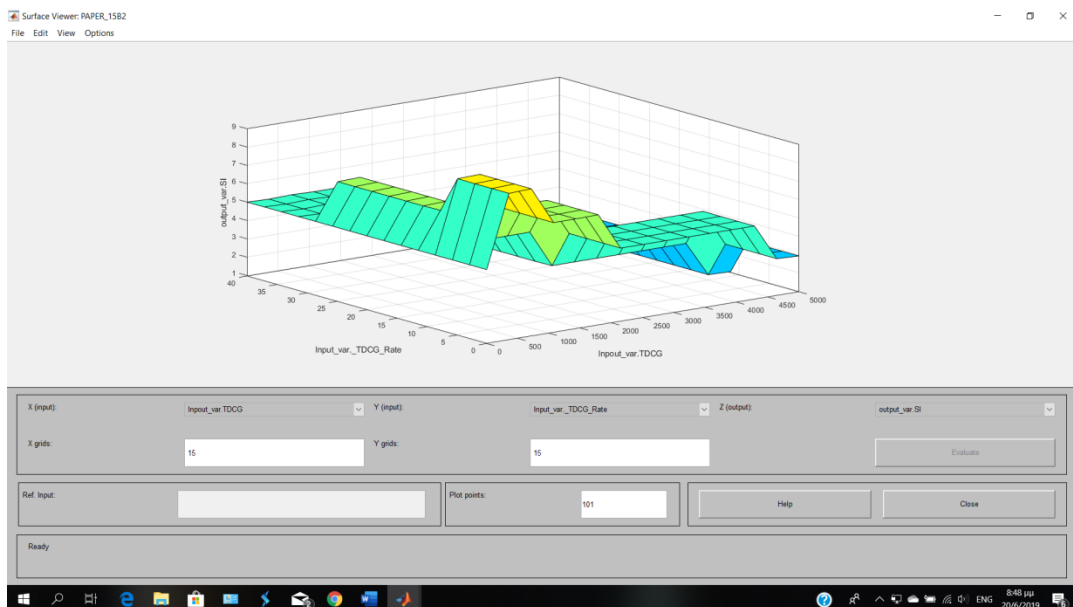
#### *Επεξεργασία κανόνων.*

Σε αυτό το βήμα πραγματοποιείται ο μηχανισμός της απόφασης, κατά τον οποίο αξιολογούνται όλοι οι κανόνες και μετά τη διαδικασία συνεπαγωγής, ανάλογα με το βαθμό εκπλήρωσης ή συμμετοχής του καθενός, το σύστημα βγάζει ένα συμπέρασμα. Ο μηχανισμός συμπερασμού βασίζεται στη **συνεπαγωγή Mamdani**.



Σχήμα 4.14. Επισκόπηση Κανόνων (Rule Viewer)

Η Επισκόπηση Επιφανειών (Surface Viewer) λαμβάνεται από το MATLAB και είναι:



Σχήμα 4.15. Επισκόπηση Επιφανειών -Surface Viewer

## ΒΗΜΑ ΤΕΤΑΡΤΟ

### Defuzzification (Αποασαφοποίηση)

Το τελευταίο μέρος ενός συστήματος ασαφούς λογικής είναι η αποασαφοποίηση της ασαφούς εξόδου σε σαφή τιμή. Υπάρχουν διάφορες τεχνικές αποασαφοποίησης, δεν υπάρχει θεωρητική βάση για καμία από αυτές, το βασικό κριτήριο επιλογής μιας κατάλληλης τεχνικής είναι η υπολογιστική απλότητα. Συνήθως επιλέγεται η **Αποασαφοποίηση Κέντρου Βάρους**.

Συνεχίζοντας και εκτελώντας την εντολή View-Rules, εμφανίζονται τα αποτελέσματα του ασαφούς συστήματος συμπερασμού, στα οποία επεμβαίνουμε εμείς, και μεταβάλλοντας κάθε φορά τις τιμές των εισόδων, βλέπουμε τις αντίστοιχες εξόδους.

Οι τιμές αποασαφοποίησης που λαμβάνονται μετά την προσομοίωση στο MATLAB του παραπάνω FIS παρουσιάζονται στον Πίνακα 4.4 για

(SI) Sampling Intervals, και

(OP) Operating Procedures

## ΑΠΟΤΕΛΕΣΜΑΤΑ

Από την παραπάνω προσομοίωση κατασκευάζεται ο Πίνακας 4.4 από τον οποίο μπορούμε να λάβουμε τα παρακάτω συμπεράσματα:

- ✓ Για την προσέγγιση μέσω FL λήφθηκαν οι σωστές MF, τα απαραίτητα διαστήματα επιμερισμού των εισόδων και εξόδων, καθώς και οι κατάλληλοι κανόνες ώστε το σύστημα λειτούργησε με μεγάλη ακρίβεια.
- ✓ Για αυτή τη μέθοδο, καθορίζονται 4 λειτουργικές διαδικασίες (OP) και 5 διαστήματα δειγματοληψίας (SI), επιλέγοντας τον υψηλότερο βαθμό συμμετοχής που λαμβάνεται από τους κανόνες ασαφούς συμπερασμού. Η διαδικασία λειτουργίας και το διάστημα δειγματοληψίας μπορούν να ταξινομηθούν σε γλωσσικές μεταβλητές βάσει της συνάρτησης συμμετοχής όπως φαίνεται στον Πίνακα 4.5 και Πίνακα 4.6

Πίνακας 4.4. Αποτελέσματα Ασαφούς Λογικής σε σύγκριση με IEEE Std

TRF NO.	TDCG	TDCG Rate	Action for Gas Generation Rate as per IEEE Std. C57.104		Action for Gas Generation Rate as per Fuzzy Logic		
			Sampling Interval (SI)	Operating Procedure (OP)	Sampling Interval (SI)	Operating Procedure (OP)	
1	544	<10	SIA	OPA	8.98-8.99	8.75	
		10-30	SIQ		6-7.84	7.9-8.75	
		>30	SIM	OPB	4.98	6.25	
2	280	<10	SIA	OPA	8.98-8.99	8.75	
		10-30	SIQ		6-7.84	7.49-8.75	
		>30	SIM	OPB	4.97-4.98	6.25	
3	506	<10	SIA	OPA	8.98-8.99	8.75	
		10-30	SIQ		6-7.84	7.79-8.75	
		>30	SIM	OPB	4.97-4.98	6.25	
4	1337	<10	SIQ		6.97-6.99	6.25	
		10-30	SIM		4.97-5.85	6.25	
		>30	SIM		4.97-4.98	6.25	
5	1026	<10			SIQ	6.97-6.99	6.25
		10-30			SIM	4.97-5.85	6.25
		>30	4.97-4.98			6.25	
6	3318	<10	SIW			4.97-4.99	3.75
		10-30			2.96-3.84	3.75	
		>30			2.96-2.98	3.75	
7	2477	<10		SIM	4.97-4.99	3.75	
		10-30		SIW	2.96-3.84	3.75	
		>30			2.96-2.98	3.75	
8	2881	<10			SIM	4.97-4.99	3.75
		10-30		SIW	2.96-3.84	3.75	
		>30			2.96-2.98	3.75	
9	4705	<10			SID	2.99	3.75
		10-30	1.03-1.9	2.51-3.75			
		>30	OPD	1.03		1.26	
10	4885	<10	SIW	OPC		2.96-298	3.75
		10-30	SID	OPD		1.01-1.9	2.51-3.75
		>30				1.01-1.02	1.25

Πίνακας 4.5. Συγκεντρώσεις αερίων

Membership Degree (out of 10) of Fuzzy output Result for SI		Membership Degree (out of 10) of Fuzzy output Result for OP	
SIA	>8		
SIQ	6.0-7.84	OPA	>7.45
SIM	4.97-5.85	OPB	6.25
SIW	2.96-3.84	OPC	3.75
SID	<1.9	OPD	<1.29

- ✓ Όπως παρατηρούμε όταν η τιμή της εξόδου SI είναι μεγαλύτερη από 8 της αποδίδεται η γλωσσική μεταβλητή SIA που σημαίνει ότι η δειγματοληψία των αερίων του Μ/Σ πρέπει να γίνεται ανά εξάμηνο,
- ✓ Για τιμή SI 6-7,84 αποδίδεται η γλωσσική μεταβλητή SIQ (δειγματοληψία ανά τετράμηνο)
- ✓ Για τιμή SI 4,97-5,84 αποδίδεται η γλωσσική μεταβλητή SIM (δειγματοληψία ανά μήνα)
- ✓ Για τιμή SI 2,96-3,84 αποδίδεται η γλωσσική μεταβλητή SIW (δειγματοληψία ανά εβδομάδα)
- ✓ Για τιμή SI μικρότερη του 1,9 αποδίδεται η γλωσσική μεταβλητή SID (δειγματοληψία ανά ημέρα).

Ομοίως:

- ✓ Όταν η τιμή της λειτουργικής διαδικασίας εξόδου OP είναι μεγαλύτερη από 7.45 της αποδίδεται η γλωσσική μεταβλητή OPA που σημαίνει ότι η παρέμβαση που πρέπει να γίνει στον ΜΣ είναι η διαδικασία Α.
- ✓ Όταν η τιμή της λειτουργικής διαδικασίας εξόδου OP είναι 6,25 της αποδίδεται η γλωσσική μεταβλητή OPB που σημαίνει ότι η παρέμβαση που πρέπει να γίνει στον Μ/Σ είναι η διαδικασία Β.
- ✓ Όταν η τιμή της λειτουργικής διαδικασίας εξόδου OP είναι 3,75 της αποδίδεται η γλωσσική μεταβλητή OPC που σημαίνει ότι η παρέμβαση που πρέπει να γίνει στον Μ/Σ είναι η διαδικασία C.



- ✓ Όταν η τιμή της λειτουργικής διαδικασίας εξόδου OP είναι μικρότερη από 1.29 της αποδίδεται η γλωσσική μεταβλητή OPD που σημαίνει ότι η παρέμβαση που πρέπει να γίνει στον Μ/Σ είναι η διαδικασία D.

Πίνακας 4.6

Degree of Membership	Condition
1	Most Encourageable
0.75 ñ 0.99	Encourageable
0.5 ñ 0.74	Preferable

Από τον Πίνακα 4.6:

- ✓ Η *πιο ενθαρρυντική* συνθήκη είναι όταν ο βαθμός συμμετοχής είναι 1
- ✓ Η *ενθαρρυντική* συνθήκη είναι όταν ο βαθμός συμμετοχής είναι 0,75-0,99
- ✓ Η *προτιμότερη* συνθήκη είναι όταν ο βαθμός συμμετοχής είναι 0,5-0,74

Από την προηγούμενη μελέτη συνάγουμε τα συμπεράσματα για την μέθοδο TDCG:

Στο παρόν κεφάλαιο παρουσιάζεται ένα πλαίσιο για τη διεξαγωγή διαγνωστικού ελέγχου ενός Μ/Σ για το εάν αυτός βρίσκεται σε ομαλή λειτουργία ανάλογα με το είδος των αερίων που παράγονται καθώς και τον ρυθμό με τον οποίο αυτά σχηματίζονται, χρησιμοποιώντας ένα Fuzzy-Logic System.

Σαν παράδειγμα μπορούμε να πάρουμε την κατάσταση όπου η τιμή δειγματοληψίας των αερίων είναι:

- 1330 ppm δηλ. βρίσκεται στην condition 2 και
- Ρυθμός παραγωγής αερίου είναι 40 ppm/day δηλ. παράγονται 40 parts per million την ημέρα

Τότε βγάζουμε το συμπέρασμα από τη *συμβατική μέθοδο* ANSI / IEEE C57.104 ότι πρέπει να γίνεται δειγματοληψία κάθε μήνα (SIM), η διεργασία αντιμετώπισης που πρέπει να ακολουθηθεί είναι επιπέδου B (OPB). Το είδος της βλάβης όμως δεν μπορεί να καθοριστεί με αυτή τη μέθοδο.

Από τη μέθοδο *Fuzzy Logic* βγάζουμε το συμπέρασμα ότι πρέπει να γίνεται δειγματοληψία κάθε μήνα (SIM), η διεργασία αντιμετώπισης που πρέπει να ακολουθηθεί είναι επιπέδου B (OPB).

Τα αποτελέσματα δηλαδή συμφωνούν.

Οι τεχνικές FL παρέχουν αποτελεσματική λύση για να αποφασιστεί το διάστημα δειγματοληψίας (SI) του λαδιού μετασχηματιστή και η διαδικασία λειτουργίας (OP) για τη συντήρηση του μετασχηματιστή.

*Μπορεί να φανεί από τον Πίνακα 4.4 ότι η νέα μέθοδος είναι γενικά σύμφωνη με τη μέθοδο ANSI / IEEE για διάγνωση Μετασχηματιστών Ισχύος.*

Σε σύγκριση με τη μέθοδο ANSI / IEEE C57.104, η μέθοδος ασαφούς λογικής έχει επίσης ορισμένα πλεονεκτήματα. Για παράδειγμα, λόγω μη συνάφειας κάποιοι μετασχηματιστές δεν μπορούν να διαγνωσθούν με τη μέθοδο ANSI / IEEE, αλλά η διάγνωση μπορεί να επιτευχθεί την παρούσα μέθοδο Ασαφούς Λογικής.

Ωστόσο, αυτή η μέθοδος δεν μπορεί να καθορίσει τον τύπο σφάλματος που συμβαίνει στον μετασχηματιστή. Αυτή η μέθοδος είναι σε θέση μόνο να ανιχνεύσει εάν ο μετασχηματιστής είναι σε καλή ή κακή κατάσταση.

Στην επόμενη ενότητα θα περιγράψουν άλλες μέθοδοι Τεχνητής Νοημοσύνης όπου θα είναι σε θέση να ανιχνεύσουν και τα είδη των βλαβών.

#### **4.1.3 Αλλαγή συναρτήσεων συμμετοχής**

Στην παρούσα παράγραφο θα γίνει προσπάθεια να αποδειχθεί τι συμβαίνει με τα αποτελέσματα της μεθόδου όταν αλλάξουμε την επιλεγμένη συνάρτηση συμμετοχής του πειράματος και από *τραπεζοειδή trapmf*, την μετατρέψουμε μέσω του προγράμματος Matlab σε:

- ✓ *τριγωνική, trimf*
- ✓ *καμπανοειδή, gbellmf.*
- ✓ *γκουοσιανή, Συμμετρική συνάρτηση του Gauss. Gaussmf.*

➤ Οι μετατροπές έγιναν βάση των παρακάτω σχέσεων:

1. *Τραπεζοειδής trapmf.* Η μαθηματική έκφραση της συνάρτησης αποδίδεται από την ακόλουθη σχέση.

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

Στη σχέση αυτή  $a, b, c$  και  $d$  είναι οι κορυφές του τραπεζίου.

2. **Τριγωνική, trimf.** Η μαθηματική έκφραση της συνάρτησης αποδίδεται από την σχέση:

$$\text{triangle}(x; a, b, c) = \begin{cases} 0, & x \leq a \text{ ή } x \geq c \\ x-a/b-a, & a \leq x \leq b \\ c-x/c-b, & b \leq x \leq c \end{cases}$$

Όπου  $a, b$ , και  $c$  είναι οι κορυφές το τριγώνου.

3. **Καμπανοειδής, gbellmf.** Έχει σαν παραμέτρους τρεις πραγματικούς αριθμούς  $a, b, c$ .

$$\text{bell}(x; a, b, c) = 1/1+(x-c)^2b/a$$

Η παράμετρος  $c$  δείχνει το κέντρο της καμπύλης,

η  $b$  το σημείο που έχει σαν τιμή 0.5

και η  $a$  το σημείο που από 0 γίνεται αυστηρά θετική.

4. **Γκαουσιανή, Συμμετρική συνάρτηση του Gauss. Gaussmf.** Έχει σαν παραμέτρους δύο πραγματικούς αριθμούς  $a, c$ .

$$\text{Gaussian}(x; \sigma, c) = e^{-\frac{(x-c)^2}{\sigma^2}}$$

Η  $c$  δείχνει το κέντρο της καμπύλης.

Όμως καθένα από αυτά τα ασαφή σύνολα, πάρα τις σημαντικές (υποκειμενικές) διαφορές τους, όπως φαίνονται στα γραφήματα των συναρτήσεων συμμετοχής τους, έχουν και αρκετά βασικά κοινά (αντικειμενικά) χαρακτηριστικά.

Ας πάρουμε για παράδειγμα τη δημιουργία της INPUT1, όπου η είσοδος αυτή διαμερίζεται σε λεκτικούς όρους, τις 4 CONDITIONS. Στην COND1 η συνάρτηση συμμετοχής  $A(x)$  εκφράζει με μια ιδιαίτερη μορφή, την ίδια γενική (ασαφή) έννοια « *x* περίπου 253», με  $x \in \mathbb{R}$ , έχοντας όμως ταυτόχρονα τα εξής κοινά χαρακτηριστικά:

- α)  $A(253) = 1$  και  $A(x) < 1$ , για κάθε  $x \neq 253$
- β)  $A(x)$  είναι συμμετρική ως προς την ευθεία  $x = 253$
- γ)  $A(x)$  φθίνει από 1 μέχρι 0, με αύξουσα διαφορά  $|253 - x|$

Επίσης οι τέσσερις αυτές συναρτήσεις συμμετοχής, είναι όμοιες στο ότι για  $x$  εκτός του διαστήματος  $[0, 720]$ , έχουν «βαθμό συμμετοχής» αμελητέο ή 0. Η ομοιότητα όμως αυτή δεν είναι πάντα απαραίτητη για την έκφραση της ασαφούς έννοιας, αλλά συνήθως συνάγεται από τα συμφραζόμενα.

Ομοίως οι είσοδοι :

- COND2 έχει την ασαφή έννοια « *x* περίπου 1285»,
- COND3 έχει την ασαφή έννοια « *x* περίπου 3300»,
- COND4 έχει την ασαφή έννοια « *x* περίπου 4950».

Οι ιδιότητες αυτές είναι αναγκαίες για να εκφραστεί κατάλληλα η δοθείσα ασαφής έννοια π.χ. « *x* περίπου 253», με  $x \in \mathbb{R}$ , αλλά και οποιοδήποτε άλλο ασαφές σύστημα θέλει να εκφράσει την ίδια έννοια, πρέπει (γενικά) να έχει αυτές τις ιδιότητες.

➤ Με βάση τα παραπάνω σχηματίστηκε ο Πίνακας 4.7 μετά από την λεπτομερή εξέταση του διαγράμματος των 10 ασαφών κανόνων με τις δύο εισόδους και τις 2 εξόδους SI και OP. Δοκιμάζοντας όλες τις τιμές που υπάρχουν στον Πίνακα 4.4 ελήφθησαν οι αντίστοιχες αποασαφοποιημένες τιμές μέσω της μεθόδου «κέντρου βάρους» για τις εξόδους SI, OP και για τις 4 συναρτήσεις συμμετοχής (*trapmf*, *trimf*, *gbellmf*, *gaussmf*).

*Παρατηρούνται τα εξής:*

✓ Για την *τριγωνική συνάρτηση* παρατηρούμε ότι συμφωνεί σε όλες τις τιμές του SI με την τραπεζοειδή. Και για την έξοδο OP παρατηρούμε ότι συμφωνεί με πολύ μικρές αποκλίσεις της τάξης του 0,05 και για ληφθήσες τιμές αερίων TDCG πάνω από 3300 rpm έχουν μεγαλύτερη σύγκλιση.

✓ Για την *καμπανοειδή συνάρτηση* έχουμε:

Η SI, συμφωνεί με την τραπεζοειδή σε 2 περίπου τιμές μόνο και σε άλλες δυο έχει απόκλιση πάνω από 0,1 και σε μία τιμή περίπου 2.

Η OP συμφωνεί με όλες εκτός από δύο τιμές που έχει απόκλιση 0,3 περίπου και 2.

✓ Για την **γκαουσιανή** έχουμε:

Η SI απέχει από την τραπεζοειδή σχεδόν σε όλες τις τιμές από 0, 1 έως 1 περίπου.

Η OP συμφωνεί με αποκλίσεις 0.2, 0.5, 1, 1.5. Παρατηρούμε ότι η γκαουσιανή MF έχει τις περισσότερες αποκλίσεις από τις υπόλοιπες χωρίς όμως σε γενικές γραμμές να δίνει λάθος αποτελέσματα.

✚ **Σαν γενικό συμπέρασμα** συγκρίνοντας τις τέσσερις διαφορετικές MF μπορεί κανείς να πει ότι δεν παρουσιάζονται διαφορές στα αποτελέσματα της μεθόδου μέσω Fuzzy Logic σε σχέση με της συμβατικής μεθόδου ANSI / IEEE C57.104.

Άρα, η ίδια ασαφής έννοια μπορεί να εκφράζεται από πολλά και διαφορετικά Ασαφή Σύνολα (Α.Σ) και η επιλογή του κατάλληλου Α.Σ. είναι υποκειμενική, αφού τα όρια του είναι ασαφή και επομένως εξαρτώνται τελικά από την κρίση του παρατηρητή. Στον παρακάτω Πίνακα 4.7 με κόκκινο χρώμα έχουν επισημανθεί οι τιμές που έχουν απόκλιση από τις υπόλοιπες πάνω από 1.00.

**Πίνακας 4.7.** Σύγκριση μεθόδων F.L

1	2	3	4	5	6	7	8	9	10	
S N	INPU TI TDCG	INPUT2 TDCG rate	ΤΙΜΕΣ Πίνακας 4 Με τραπεζοειδή MF	ΤΙΜΕΣ Με τριγωνι κή MF SI	ΤΙΜΕΣ Με καμπανοει δή MF	ΤΙΜΕΣ Με Γκαουσι ανή MF SI	ΤΙΜΕΣ Πίνακας 4 Με τραπεζοει δή MF	ΤΙΜΕΣ Με τριγωνική MF OP	ΤΙΜΕΣ Με καμπαν οειδή MF OP	ΤΙΜΕΣ Με Γκαουσιαν ή MF
1	544	<10	8.98-8.99	8.98	6.92	7.58	8.75	8.7	6.24	7.71
		10-30	6-7.84	6.98	4.94	6.28	7.9-8.75	8,70	6.24	7.71
		>30	4.98	4.98	4.91	5.27	6.25	6.28	6.21	6.43
2	280	<10	8,98-8,99	8,99	8.9	8.19	8.75	8,67	8.61	8.25
		10-30	6-7.84	6.97	6.91	6.56	7.49- 8.75	8.68	8.61	8.08
		>30	4.97-4.98	4.97	4.91	5.27	6.25	6.27	6.21	6.44
3	506	<10	8,98-8,99	8,98	8.9	7.7	8.75	8,70	8.61	7.84
		10-30	6-7.84	6.98	6.91	6.38	7.79-	8.7	8.61	7.84
		>30	4.97-4.98	4.98	4.91	5.26	6.25	6.28	6.21	6.43
4	1337	<10	6.97-6.99	6.97	6.91	5.97	6.25	6.27	6.21	5.74
		10-30	4.97-8.85	4.98	4.91	4.46	6.25	6,29	6.21	5.74
		>30	4.97-4.98	4.97	4.91	4.46	6.25	6.27	6.21	5.74
5	1026	<10	6.97-6.99	6.99	6.91	6.15	6.25	6,3	6.21	5.96
		10-30	4.97-5.85	4.98	4.91	4.73	6.25	6.28	6.21	5.96
		>30	4.97-4.98	4.98	4.91	4.73	6.25	6.28	6.21	5.96
6	3318	<10	4.97-4.99	4.97	4.91	4.32	3.75	3.73	3.7	3.7
		10-30	2.96-3.84	2.94	2.84	2.72	3.75	3.73	3.7	3.53
		>30	2.96-2.98	2.95	2.84	2.71	3.75	3,74	3.7	3.5
7	2477	<10	4.97-4.99	4.99	4.91	4.46	3.75	3,75	3.7	3.76
		10-30	2.96-3.84	2.96	2.84	2.89	3.75	3.74	3.7	3.75
		>30	2.96-2.98	2.96	2.84	2.87	3.75	3.74	3.7	3.75
8	2881	<10	4.97-4.99	4.97	4.91	4.48	3.75	3.74	3.7	3.71
		10-30	2.96-3.84	2.97	2.84	2.82	3.75	3,74	3.7	3.66
		>30	2.96-2.98	2.94	2.84	2.82	3.75	3.74	3.7	3.66
9	4705	<10	2.99	2.97	2.91	3.42	3.75	3.74	3.7	3.7
		10-30	1.03-1.9	1.03	0.94	1.78	2.51-	1.3	3.7	3.53
		>30	1,03	1,03	0.9	1.77	1.26	1,30	1.26	2.23
1 0	4885	<10	2.96-2.98	2.94	2.84	3.24	3.75	3,74	3.7	3.7
		10-30	1.01-1.9	0.99	0.88	1.68	2.51-	3.73	3.7	3.53
		>30	1.01-1.02	0.99	0.88	1.67	1.25	1.26	1.17	2.1

#### 4.2 Εφαρμογή Τεχνητών Νευρωνικών Δικτύων στην ερμηνεία των αποτελεσμάτων της DGA με τη μέθοδο Rogers.

Η υλοποίηση του μοντέλου για την διάγνωση σφαλμάτων Μ/Σ ισχύος μέσω της μεθόδου Roger's Ratio πραγματοποιείται με ένα Multilayer Feed Forward Back

Propagation Neural Network. Η προτεινόμενη μέθοδος αναπτύχθηκε διεξοδικά στο κεφάλαιο 3. Ο Πίνακας 1 και Πίνακας 2 απεικονίζουν το σύνολο δεδομένων εκπαίδευσης του δικτύου.

Ο Πίνακας 1 περιέχει τις συγκεντρώσεις των εκλυόμενων αερίων από τους υπό έλεγχο μετασχηματιστές σε ppm. (100 δείγματα)

H<sub>2</sub>, CH<sub>4</sub>, C<sub>2</sub>H<sub>6</sub>, C<sub>2</sub>H<sub>4</sub>, C<sub>2</sub>H<sub>2</sub>

ο Πίνακας 2 περιέχει τους τέσσερις λόγους συγκέντρωσης αερίων (λόγοι του Rogers):

$$X_1 = \text{CH}_4/\text{H}_2$$

$$X_2 = \text{C}_2\text{H}_4/\text{C}_2\text{H}_6$$

$$X_3 = \text{C}_2\text{H}_2/\text{C}_2\text{H}_4$$

$$X_4 = \text{C}_2\text{H}_6/\text{CH}_4$$

Και τους αντίστοιχους κωδικούς Rogers: CODE X<sub>1</sub>, CODE X<sub>2</sub>, CODE X<sub>3</sub>, CODE X<sub>4</sub>.

Το εύρος κάθε λόγου αερίου αντιστοιχεί σε έναν συγκεκριμένο κωδικό ( Πίνακας 1.6).

Ο συνδυασμός αυτών των κωδικών αντιστοιχεί σε ένα συγκεκριμένο σφάλμα (Πίνακας 1.7).

**Είσοδοι δικτύου :** Οι τέσσερις λόγοι αερίων

**Εξοδος -στόχοι :** τα 12 είδη σφαλμάτων των μετασχηματιστών (από τον Πίνακα 1.7).

Τα δεδομένα ταξινομήθηκαν από το MATLAB σε training, validation, and testing sets. Τα training set είναι το 70% των συνολικών data, και το υπόλοιπα 30% είναι τα validation και test data.

Τα στάδια που ακολουθούνται είναι τα εξής:

**Training stage** - Στάδιο Εκπαίδευσης. Επιτελεί το ουσιαστικό μέρος της εκπαίδευσης του ANN. Το σετ εκπαίδευσης εφαρμόζεται για τον υπολογισμό της gradient και ενημερώνει τα biases και τα βάρη.

**Validation stage**- Στάδιο Επικύρωσης. Εφαρμόζεται για να εποπτευθεί η κατάσταση του σταδίου εκπαίδευσης. Το σφάλμα επικύρωσης υπολογίζεται σε κάθε εποχή των δεδομένων εκπαίδευσης και όταν δεν έχει μειωθεί μετά από κάποιες επαναλήψεις, τότε η διαδικασία εκπαίδευσης σταματά.

**Testing stage**- Στάδιο Δοκιμής. Σε αυτό το στάδιο, εφαρμόζεται ένα νέο σύνολο δεδομένων για την εκτίμηση της απόδοσης του δικτύου.

## ANN 1

Η πρώτη δομή του ANN έχει τα χαρακτηριστικά που παρουσιάζονται στο Σχήμα 4.16 και παρέχονται στο δίκτυο 100 σύνολα δεδομένων.

- ο αριθμός των δεδομένων 100 δείγματα
- ο αριθμός των Κρυφών Επιπέδων-Hidden Layers είναι 2 με

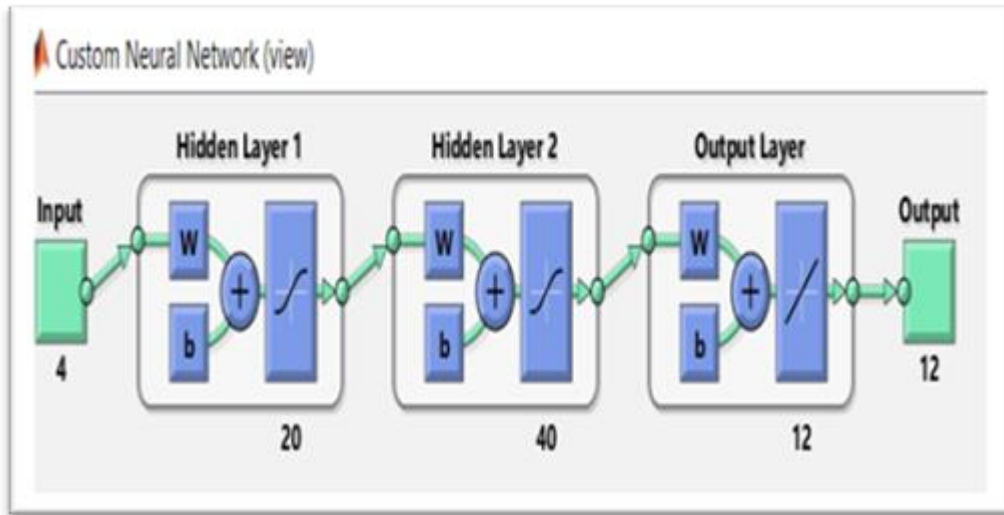
- Hidden Layer 1: 20 νευρώνες-neurons
- Hidden Layer 2: 40 νευρώνες-neurons

**Διάγραμμα Απόδοσης Δικτύου-Performance Plot:** Το Σχήμα 4.18 (γραφική παράσταση απόδοσης δικτύου), απεικονίζει την γραφική παράσταση μεταξύ της τιμής σφάλματος και του αριθμού των επαναλήψεων στις οποίες η απόδοση επικύρωσης πέτυχε ένα ελάχιστο. Το ελάχιστο σφάλμα είναι 0.7 και επιτυγχάνεται στην τέταρτη εποχή. Οι καμπύλες επικύρωσης και δοκιμής είναι παράλληλες και το σφάλμα δεν είναι ικανοποιητικά μικρό.


<b>ANN parameters</b>	<b>Type/Value</b>
Training Function	TRAINLM
Learning Function	LEARNGDM
Number of Neurons in HL1	20
Number of Neurons in HL2	40
Transfer function	tansig-tansig (output purelin)
LR	0.05 (default)
MC	0.95 (default)
% of correct fault prediction	65%

**Σχήμα 4.16.** ANN 1 parameters





Σχήμα 4.17. ANN 1 structure



Σχήμα 4.18. Performance Plot


- *Επειδή το δίκτυο δεν είναι αρκετά ακριβές, γίνεται βελτίωση των αποτελεσμάτων του ως εξής :*

## ANN 2

Στο δεύτερο αυτό μοντέλο ο αριθμός των κρυφών νευρώνων αυξάνεται: (Σχήμα 4.19)

- ο αριθμός των δεδομένων 100 δείγματα
- ο αριθμός των Κρυφών Επιπέδων-Hidden Layers είναι 2 με
- Hidden Layer 1: 50 νευρώνες-neurons
- Hidden Layer 2 : 80 νευρώνες-neurons

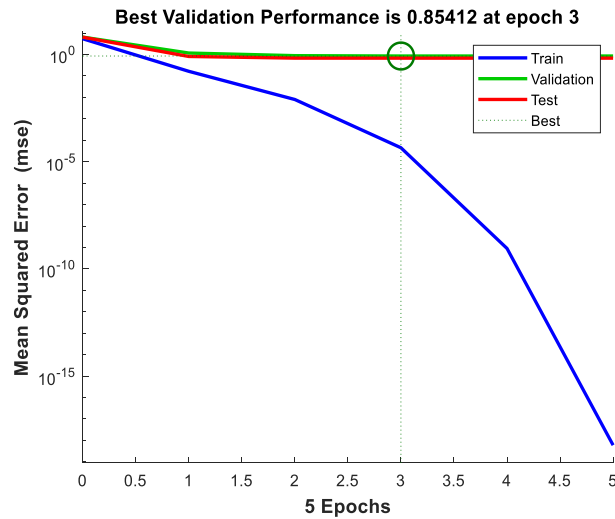
Στο παρόν μοντέλο τα αποτελέσματα είναι καλύτερα όπως φαίνεται από το αντίστοιχο διάγραμμα, Σχήμα 4.21 αλλά απαιτείται βελτίωση.



Σχήμα 4.19. ANN 2

ANN parameters	Type/Value
Training Function	TRAINLM
Learning Function	LEARNGDM
Number of Neurons in HL1	50
Number of Neurons in HL2	80
Transfer function	tansig-tansig (output purelin)
LR	0.05 (default)
MC	0.95 (default)
% of correct fault prediction	78%

Σχήμα 4.20. ANN 2 Parameter



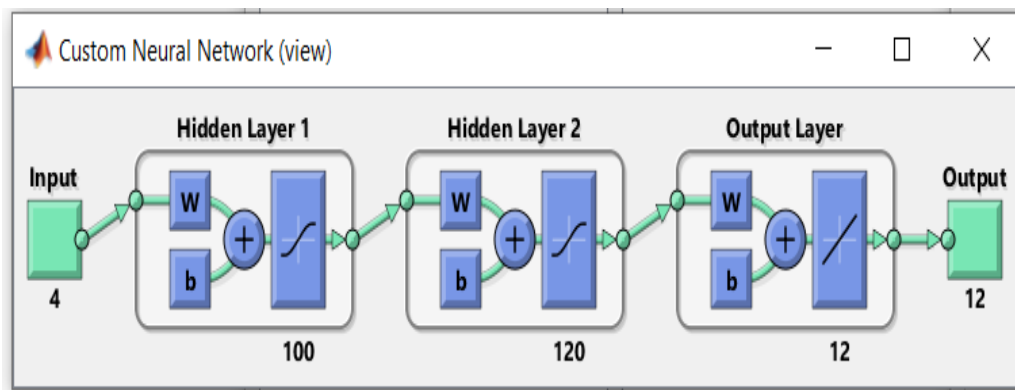
Σχήμα 4.21. Performance Plots

### ANN 3


Στη συνέχεια στο ANN 3 αυξάνεται ο αριθμός των κρυφών νευρώνων (Σχήμα 4.22).

- ο αριθμός των δεδομένων 100 δείγματα
- ο αριθμός των Κρυφών Επιπέδων-Hidden Layers είναι 2 με
- Hidden Layer 1: 100 νευρώνες-neurons
- Hidden Layer 2: 120 νευρώνες-neurons

Εδώ παρατηρούμε το πρόβλημα της *υπερεκπαίδευσης*. Κατά το οποίο το δίκτυο κατά τη διαδικασία εκπαίδευσης έχει μάθει τέλεια τα δεδομένα αλλά δεν μπορεί να κάνει σωστή πρόβλεψη κατά τη διαδικασία της δοκιμής. Από την καμπύλη απόδοσης, παρατηρούμε ότι το σφάλμα είναι 1.1274 και δεν είναι ικανοποιητικά μικρό.



Σχήμα 4.22. ANN 3



Σχήμα 4.23. Performance plot

## ANN 4

Μετά από πολλές δοκιμές κατά τις οποίες αλλάζεται ο αριθμός νευρώνων και των Κρυφών Επιπέδων-hidden layers, εξάγεται το συμπέρασμα ότι το ANN παρουσιάζει την καλύτερη απόδοση όταν: **τροφοδοτείται με περισσότερα test data (200) και ο αριθμός των Κρυφών Επιπέδων-hidden layers είναι 2, με 10 και 20 νευρώνες αντίστοιχα.**

- Αριθμός των δεδομένων 200 δείγματα
- Αριθμός των Κρυφών Επιπέδων-Hidden Layers είναι 2 με
- Hidden Layer 1: 10 νευρώνες-neurons
- Hidden Layer 2: 20 νευρώνες-neurons

Για την Αξιολόγηση της επίδοσης του δικτύου μπορεί να εξαχθεί ο Πίνακας σύγχυσης-Confusion Matrix του ANN 4 από το MATLAB.

**Πίνακας σύγχυσης (Confusion Matrix):** Ένας Πίνακας C με στοιχεία  $c_{ij}$ , όπου  $c_{ij}$  είναι το πλήθος των που ανήκουν στην κλάση  $i$  και έχουν αποδοθεί στην κλάση  $j$ .

Σωστή ταξινόμηση: Στοιχεία της κύριας διαγωνίου (πράσινα).

Λανθασμένη ταξινόμηση: Στοιχεία της εκτός κύριας διαγωνίου (κόκκινα)

Όπως μπορούμε να παρατηρήσουμε από τον Confusion Matrix στο Σχήμα 4.25 η κύρια διαγώνιος δείχνει τα σωστά αποτελέσματα και το κελί στην κάτω δεξιά γωνία της γραφικής παράστασης δείχνει την πλήρη ακρίβεια του ANN και φτάνει το **92%**.

**Network performance plot:** γραφική απεικόνιση της απόδοσης του δικτύου.

απεικονίζει την σχέση μεταξύ τιμής σφάλματος και του αριθμού των επαναλήψεων στις οποίες η απόδοση επικύρωσης πέτυχε ένα ελάχιστο. Το ελάχιστο σφάλμα είναι 0.008 και επιτυγχάνεται στην εποχή 0. Οι καμπύλες επικύρωσης και δοκιμής είναι παράλληλες και το σφάλμα είναι ικανοποιητικό. (Σχήμα 4.26)

ANN parameters	Type/Value
Training Function	TRAINLM
Learning Function	LEARNGDM
Number of Neurons in HL1	10
Number of Neurons in HL2	20
Transfer Function	tansig-tansig (output purelin)
LR	0.05 (default)
MC	0.95 (default)
% of correct fault prediction	92%

Σχήμα 4.24. ANN 4 parameters

**Confusion Matrix**

1	6 6.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 1.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	35.7%
2	0 0.0%	6 6.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
3	0 0.0%	0 0.0%	7 8.0%	0 0.0%	0 0.0%	1 1.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	37.5%
4	0 0.0%	0 0.0%	0 0.0%	6 6.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3 3.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
6	1 1.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	14 15.9%	0 0.0%	0 0.0%	0 0.0%	1 1.1%	0 0.0%	0 0.0%	37.5%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 9.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	12 13.6%	0 0.0%	1 1.1%	0 0.0%	0 0.0%	32.3%
9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 2.3%	0 0.0%	0 0.0%	0 0.0%	100%
10	1 1.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	14 15.9%	0 0.0%	0 0.0%	33.3%
11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 1.1%	1 1.1%	0 0.0%	50.0%
12	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 2.3%	100%
	75.0%	100%	100%	100%	100%	93.3%	38.9%	100%	100%	32.4%	100%	100%	92.0%
	25.0%	0.0%	0.0%	0.0%	0.0%	6.7%	11.1%	0.0%	0.0%	17.6%	0.0%	0.0%	8.0%
	1	2	3	4	5	6	7	8	9	10	11	12	
	Target Class												

Σχήμα 4.25. Confusion Matrix




Σχήμα 4.26. Performance plot

## ANN 5

Αφού βρέθηκε το δίκτυο με την καλύτερη απόδοση από άποψη αριθμού κρυμμένων επιπέδων και νευρώνων, εκτελείται μια ακόμα δοκιμή προκειμένου να αξιολογηθεί η απόδοση του δικτύου αλλάζοντας μια διαφορετική παράμετρο αυτή τη φορά. Στο παρόν δίκτυο αλλάζουμε τη Training Function από το `trainlm` Levenberg-Marquardt σε `trainbfg` BFGS Quasi-Newton και τα αποτελέσματα, όπως μπορούμε να δούμε από το Σχήμα 4.28, δεν είναι ικανοποιητικά. Από την βιβλιογραφική αναζήτηση εξάγεται ότι η γρηγορότερη Training Function είναι κυρίως `trainlm` και είναι η προεπιλεγμένη για το feedforward ANN. Ο αλγόριθμος quasi-Newton είναι επίσης αρκετά γρήγορος. Και οι δύο αλγόριθμοι απαιτούν περισσότερη μνήμη και περισσότερο χρόνο υπολογισμού (computation time) επομένως δεν είναι αποδοτικοί για μεγάλα δίκτυα με χιλιάδες βάρη.

ANN parameters	Type/Value
Training Function	trainbfg5
Learning Function	LEARNGDM
Number of Neurons in HL1	10
Number of Neurons in HL2	20
Transfer function	tansig-tansig (output purelin)
LR	0.05 (default)
MC	0.95 (default)
% of correct fault prediction	31%

Σχήμα 4.27. ANN 5 parameters



Σχήμα 4.28. Performance plot

Κατόπιν πολλών δοκιμών συμπερασματικά μπορεί να ειπωθεί ότι η καλύτερη απόδοση του ANN είναι όταν:

- Αριθμός των δεδομένων αυξάνεται σε 200 δείγματα
- Αριθμός των Κρυφών Επιπέδων-Hidden Layers είναι 2 με
- Hidden Layer 1: 10 νευρώνες-neurons
- Hidden Layer 2 : 20 νευρώνες-neurons
- Training Function : trainlm, Levenberg-Marquardt

### 4.3 Εφαρμογή Προσαρμοστικών Συστημάτων Νευρο-ασαφούς Συμπερασμού (ANFIS) στην ερμηνεία των αποτελεσμάτων της DGA με τη μέθοδο Rogers.

Το μοντέλο ANFIS συσχετίζει τα **Sugeno Fuzzy Inference Models** με τα **Multilayer Feedforward Neural Networks**. Πρόκειται για έναν υβριδικό αλγόριθμο εκμάθησης, ο οποίος τροποποιεί τις παραμέτρους της membership function του Fuzzy Inference System σύμφωνα με τον συνδυασμό των least square method και backpropagation gradient descent method. Αυτή η λειτουργία επιτρέπει στο FIS να μάθει από τα δεδομένα του. Έτσι το ANFIS έχει τα πλεονεκτήματα τόσο των ANN όσο και των FIS.

Για την ανάπτυξη του ANFIS χρησιμοποιείται το λογισμικό MATLAB . Η διαδικασία δημιουργίας ενός Νευρο-ασαφούς μοντέλου περιλαμβάνει τα ακόλουθα στάδια τα οποία έχουν αναπτυχθεί στο κεφάλαιο 3. Μέσω του ANFIS Editor και επιλέγοντας κάθε φορά το κατάλληλο παράθυρο δημιουργείται το μοντέλο.

#### A. Εισαγωγή των δεδομένων εκπαίδευσης κατάλληλα τροποποιημένων στο ANFIS:

- Ως INPUTS ορίζονται οι τέσσερις αναλογίες αερίων  
INPUT 1 MH  
INPUT 2 EM  
INPUT 3 EE  
INPUT 4 AE
- Ως OUTPUTS, οι 12 βλάβες που εμφανίζονται σε έναν M/Σ ισχύος  $\Upsilon_1, \Upsilon_2, \Upsilon_3, \Upsilon_4, \dots, \Upsilon_{10}, \Upsilon_{11}, \Upsilon_{12}$  και αντιστοιχίζονται στους αριθμούς 1 έως 12.

Το σύνολο δεδομένων που χρησιμοποιούνται ως είσοδος είναι σε μορφή πίνακα όπου η τελευταία στήλη του πίνακα είναι η έξοδος και η μήτρα περιέχει όσες στήλες χρειάζεται για να αντιπροσωπεύει τις εισόδους στο σύστημα. Οι γραμμές περιλαμβάνουν όλες τις υπάρχουσες καταστάσεις δεδομένων.

Μέσω του παραθύρου **Load Data** φορτώνουμε τα αρχεία με δεδομένα για εκπαίδευση, δοκιμή και έλεγχο. Ο τρόπος εισαγωγής τους περιεγράφηκε στο κεφάλαιο 3. Το σύνολο εκπαίδευσης είναι το 70% των συνολικών δεδομένων και το άλλο 30% για τον έλεγχο δεδομένων.

#### B. Δημιουργία Δομής ANFIS:

Στο παράθυρο **Generate FIS** επιλέγεται το Grid partition και καθορίζεται:

- Ο αριθμός των ασαφών συνόλων για κάθε είσοδο

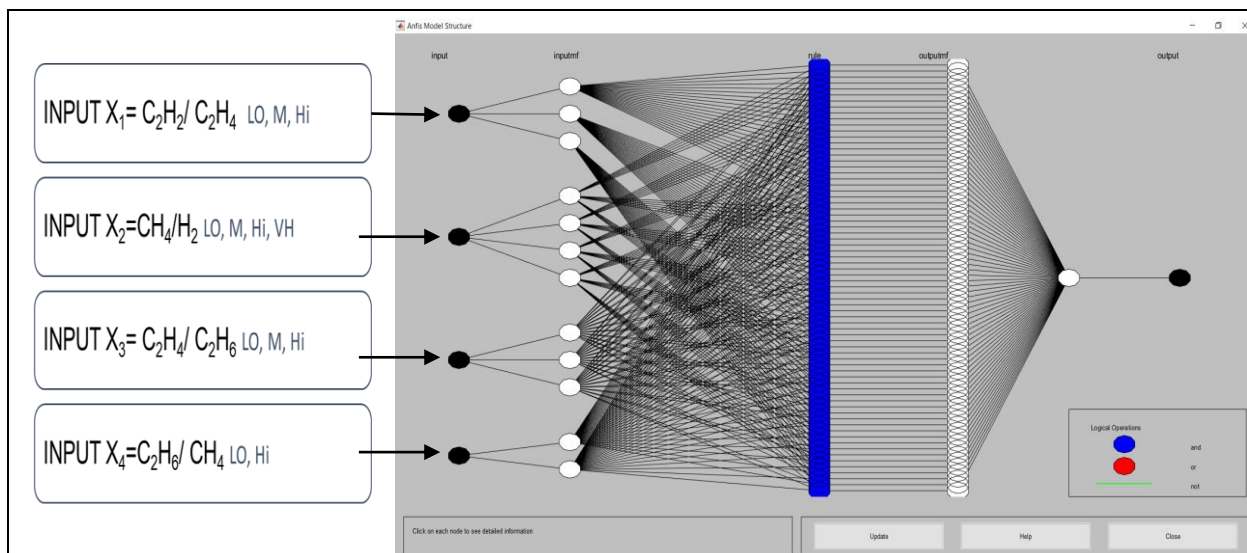


INPUT  $X_1 = C_2H_2/C_2H_4$  διαμερίζεται σε 3 ασαφή σύνολα LO, M, Hi  
 INPUT  $X_2 = CH_4/H_2$  διαμερίζεται σε 4 ασαφή σύνολα LO, M, Hi, VH  
 INPUT  $X_3 = C_2H_4/C_2H_6$  διαμερίζεται σε 3 ασαφή σύνολα LO, M, Hi  
 INPUT  $X_4 = C_2H_6/CH_4$  διαμερίζεται σε 2 ασαφή σύνολα LO, Hi

- Η μορφή της Membership Function (MF): Επιλέγεται η τραπεζοειδής
- Ο τύπος MF εξόδου: γραμμικός.

Δημιουργείται λοιπόν το μοντέλο FIS Sugeno type για την εκπαίδευση ANFIS. Η προσαρμογή των παραμέτρων της MF υπολογίζεται από το gradient vector, το οποίο δείχνει πόσο καλά αναπτύσσεται το ANFIS από ένα διαφορετικό σύνολο δεδομένων εκπαίδευσης.

Από το **ANFIS info**, μπορούμε να δούμε τη δομή, structure του ANFIS



Σχήμα 4.29. ANFIS structure

### Γ. Εκπαίδευση μοντέλου

Περνώντας στο παράθυρο Train FIS ορίζονται:

- **Optimization methods** - Μέθοδοι Βελτιστοποίησης Παραμέτρων ANFIS: το υβριδικό μοντέλο, hybrid (integrated least squares και backpropagation).
- Error Tolerance - Ανοχή Σφάλματος : 0.05
- Number of training Epochs - Αριθμός Εποχών Εκπαίδευσης: 50

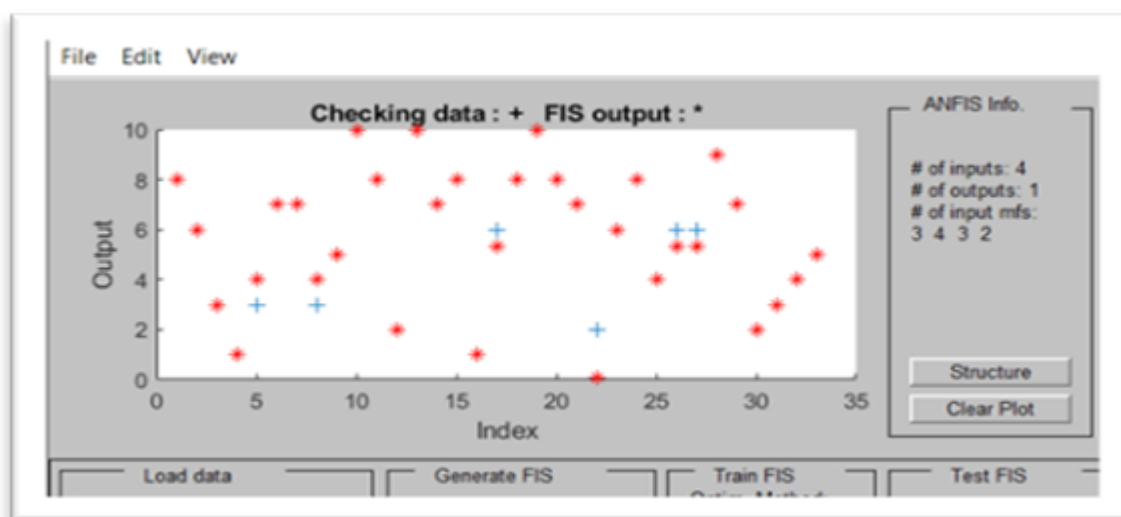
Η ανοχή σφάλματος εφαρμόζεται για τη δημιουργία ενός επιπέδου διακοπής εκπαίδευσης, το οποίο σχετίζεται με το μέγεθος σφάλματος. Η εκπαίδευση θα λήξει όταν το σφάλμα δεδομένων εκπαίδευσης παραμένει εντός αυτής της ανοχής.

#### Δ. Έλεγχος προσαρμογής Μοντέλου σε σχέση με τα checking data:


Μέσω του παραθύρου Test FIS, επιλέγονται :

- Checking data and Test Now-Έλεγχος δεδομένων και Δοκιμή τώρα. Εμφανίζονται τα διαγράμματα checking data σε σχέση με τα δεδομένα εξόδου του δικτύου και Testing data σε σχέση με τα δεδομένα εξόδου του δικτύου.

Από το διάγραμμα του Σχήματος 4.30 εξάγεται ότι : η έξοδος δεδομένων ελέγχου και η έξοδος FIS παρουσιάζουν μερική ταύτιση, επομένως η προσαρμογή του μοντέλου είναι ικανοποιητική. Επιπλέον τα test data έχουν προβλεφθεί με υψηλή ακρίβεια, μόνο ένας τύπος σφάλματος ήταν λάθος.



Σχήμα 4.30. Checking data plot



Σχήμα 4.31. Testing data plot

## ΚΕΦΑΛΑΙΟ 5: Ανάλυση Αποτελεσμάτων – Συζήτηση

---

Η προσομοίωση και η απόδοση των τριών προτεινόμενων τεχνικών διάγνωσης FIS, ANN και ANFIS, που παρουσιάστηκαν στην παρούσα διπλωματική εργασία επιτεύχθηκαν μέσω του λογισμικού MATLAB R2019a. Τα αποτελέσματα παρουσιάζονται στον Πίνακα 5.1.

Η ακρίβεια κάθε μεθόδου υπολογίζεται χρησιμοποιώντας τον τύπο:

$$(A) = (\text{Σύνολο δειγμάτων σωστά ταξινομημένο}) / (\text{Σύνολο δειγμάτων}).$$

Βάση του προαναφερόμενου Πίνακα 5.1 δύναται να αναλυθούν και συγκριθούν τα αποτελέσματα τα οποία εξήχθησαν από κάθε μοντέλο.

Ο αριθμός των δειγμάτων που χρησιμοποιήθηκαν για τον έλεγχο της ακρίβειας κάθε μοντέλου είναι 40.

Στη στήλη (S), αναφέρεται ο αύξοντας αριθμός κάθε δείγματος δεδομένων.

Στη στήλη (1) έως (5), παρουσιάζονται οι συγκεντρώσεις των εκλυόμενων αερίων σε ppm.

Στη στήλη (6), δίνονται τα πραγματικά σφάλματα των εξεταζόμενων μετασχηματιστών.

Στις στήλες της 'συμφωνίας μεθόδων' (8), (10), (12), συγκρίνουμε τα αποτελέσματα κάθε μεθόδου με τα πραγματικά σφάλματα.

Στη στήλη (7), τα σφάλματα εξάγονται από τη συμβατική μέθοδο Rogers, σύμφωνα με τον τρόπο που αναφέρθηκε προηγουμένως. Παρατηρούμε ότι η συμβατική αυτή μέθοδος δεν καταφέρνει να εντοπίσει εννέα σφάλματα (το κύριο μειονέκτημα της μεθόδου Rogers) και υπάρχουν επίσης επτά λανθασμένες προβλέψεις στη στήλη (8).

Αυτό οφείλεται στο ότι κάποιες φορές δημιουργούνται λόγοι που δεν ανήκουν στο εύρος των σφαλμάτων του πίνακα της μεθόδου και γενικά η μέθοδος αυτή χρειάζεται συνεργασία με άλλες μεθόδους προκειμένου να εξαχθεί ένα έγκυρο και ξεκάθαρο αποτέλεσμα. Συνεπώς η ακρίβεια της μεθόδου είναι 60%, πολύ χαμηλή, όπως αναμενόταν σύμφωνα με άλλες μελέτες και θεωρητικά δεδομένα.

Στη στήλη (9) παρουσιάζονται οι προβλέψεις που εξήχθησαν από το μοντέλο FIS. Από τη στήλη συμφωνίας (10), παρατηρείται ότι η ακρίβεια είναι 95%, η οποία είναι πολύ

υψηλή. Αλλά για το μοντέλο FIS, οι δώδεκα διαφορετικοί τύποι βλαβών ταξινομούνται στους ακόλουθους τέσσερις : Κανονική λειτουργία, Μερικές εκκενώσεις, τόξα, και θερμικά σφάλματα. Τα θερμικά σφάλματα ( Thermal faults) περιλαμβάνουν έξι τύπους βλαβών (Πίνακας 5). Έτσι, πρέπει να προβλέψει μικρότερο αριθμό τύπων βλαβών από τα άλλα τρία μοντέλα.

Εν γένει, η ασαφής λογική μπορεί να εξηγήσει τη συμπεριφορά ενός συστήματος χρησιμοποιώντας κανόνες, οι οποίοι αντιπροσωπεύουν τις γνώσεις των ειδικών και έχει ένα σημαντικό πλεονέκτημα ότι δεν απαιτεί ακρίβεια πληροφοριών. Ωστόσο, σε περιπτώσεις όπου δεν υπάρχει πληροφορία από εμπειρογνώμονα, η δυνατότητα εφαρμογής ασαφών συστημάτων είναι περιορισμένη. Επίσης, είναι δύσκολο να γίνει η ακριβής διαίρεση του χώρου των εισόδων και εξόδων ενός προβλήματος σε ασαφή σύνολα ή να βρεθούν οι τιμές των παραμέτρων των συναρτήσεων συμμετοχής και ο ακριβής αριθμός των ασαφών κανόνων. Όλα αυτά τα αποτελέσματα καθιστούν την ασαφή λογική λιγότερο κατάλληλη για πρόβλεψη βλαβών Μ/Σ ισχύος.

Η στήλη (11) απεικονίζει την έξοδο του συστήματος ANN. Εδώ μπορούμε να παρατηρήσουμε ότι το μοντέλο μπορεί να προβλέψει 37 σωστά σφάλματα - στήλη (12). **Η ακρίβειά του φτάνει το 92,5%**, είναι εξαιρετικά υψηλή όπως παρατηρείται από τον Confusion Matrix (Σχήμα 4.28)

Πράγμα αναμενόμενο καθώς το ANN είναι ένα στιβαρό και εξαιρετικό σχήμα με δεξιότητες αυτο-οργάνωσης και αυτοεκμάθησης. Γενικά, το ANN απαιτεί σημαντικό αριθμό δειγμάτων για εκπαίδευση και αυτό επηρεάζει τη διαγνωστική του απόδοση, κατά συνέπεια χρησιμοποιείται σε προβλήματα όπου υπάρχουν αρκετά μετρήσιμα δεδομένα. Εκτός αυτού, υπάρχουν σημαντικές δυσκολίες στον καθορισμό αριθμών κόμβων και παραμέτρων κρυφών επιπέδων καθώς αυτά λειτουργούν ως μαύρο κουτί.

Η στήλη (13) απεικονίζει τις προβλέψεις του μοντέλου ANFIS. Από τη στήλη (14) διακρίνεται ότι η λανθασμένη πρόβλεψη είναι μόνο μία, πράγμα που σημαίνει ότι **η ακρίβεια του μοντέλου ANFIS είναι 97,5%**. Αυτή η μεγάλη ακρίβεια ήταν αναμενόμενη, καθώς τα ANFIS είναι ο συνδυασμός ANN και FIS και λειτουργούν με τέτοιο τρόπο ώστε ο αλγόριθμος εκμάθησης νευρωνικών δικτύων να χρησιμοποιείται για τον προσδιορισμό των παραμέτρων FIS. Έτσι, ενοποιούνται τα πλεονεκτήματα της ANN και της Fuzzy Logic αποφεύγοντας τα μειονεκτήματά τους.

*Συμπερασματικά είναι αποτελεσματικότερο και ασφαλέστερο να εφαρμόζεται η μέθοδος ANFIS για τη Διάγνωση Σφαλμάτων Μετασχηματιστών Ισχύος.*

#### Πίνακας 5.1. Αποτελέσματα

S.N	H <sub>4</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	Real F.	Rog.	A	FL	A	ANN	A	ANFIS	A
	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	12	(13)	(14)
1	13	138	83	16	0	Y3	Y3	√	TF	√	Y3	√	Y3	√
2	762	93	38	54	126	Y10	Y10	√	ARC	√	Y10	√	Y10	√
3	43	116	65	139	0	Y7	Y7	√	TF	√	Y7	√	Y7	√
4	179	306	73	579	0	Y8	Y8	√	TF	√	Y8	√	Y8	√
5	57	141	38	51	0	Y7	Y7	√	TF	√	Y7	√	Y7	√
6	40	8	34	15	0	Y5	Y5	√	TF	√	Y5	√	Y5	√
7	35	283	121	222	0	Y7,Y8	U.F	—	TF	√	Y1.Y7	√	Y1.Y7	√
8	15	159	29	87	0	Y7,Y8	U.F	—	TF	√	Y6	—	Y6	—
9	55	159	114	493	0	Y8	Y8	√	TF	√	Y8	√	Y8	√
10	37	123	67	52	0	Y3	Y3	√	TF	√	Y3	√	Y3	√
11	723	191	110	293	288	Y10	Y10	√	ARC	√	Y10	√	Y10	√
12	7	15	78	58	0	Y4	Y4	√	TF	√	Y4	√	Y4	√
13	30	51	12	54	0	Y8	Y8	√	TF	√	Y8	√	Y8	√
14	31	56	33	77	0	Y7	Y7	√	TF	√	Y7	√	Y7	√
15	109	226	68	192	0	Y7	Y7	√	TF	√	Y7	√	Y7	√
16	137	279	66	505	0	Y8	Y8	√	TF	√	Y8	√	Y8	√
17	59	119	36	70	0	Y7	Y7	√	PD	√	Y7	√	Y7	√
18	151	242	68	232	0	Y8	Y8	√	TF	√	Y8	√	Y8	√
19	870	77	73	54	14	Y2	Y2	√	PD	√	Y2	√	Y2	√
20	376	575	146	1092	0	Y8	Y8	√	TF	√	Y8	√	Y8	√
21	269	1081	347	1725	25	Y6	U.F	—	TF	√	Y6	√	Y6	√
22	10	10	8	1	0.01	Y3	Y3	√	TF	√	Y3	√	Y3	√
23	30	22	14	4.10	0.1	Y1	Y1	√	NF	√	Y1	√	Y1	√
24	2.90	2	2	0.3	0.1	Y1	Y1	√	NF	√	Y1	√	Y1	√
25	4	99	82	4	0.1	Y3	Y3	√	TF	√	Y3	√	Y3	√
26	21	34	5	47	62	Y10	U.F	—	ARC	√	Y10	√	Y10	√
27	50	100	51	305	9	Y8	Y8	√	TF	√	Y8	√	Y8	√
28	120	17	32	4	23	Y1	U.F	—	NF	√	Y1	√	Y1	√
29	980	73	58	12	0.01	Y2	Y2	√	PD	√	Y2	√	Y2	√
30	1607	615	80	916	1294	Y10	U.F	—	ARC	√	Y10	√	Y10	√
31	14.7	3.7	10.5	2.7	0.2	Y5	U.F	—	TF	√	Y6	—	Y5	√
32	181	262	41	28	0.01	Y3	U.F	—	TF	√	Y3	√	Y3	√
33	173	334	172	812.5	33.7	Y8	Y5	—	TF	√	Y8	√	Y8	√
34	127	107	11	154	224	Y10	Y3	—	ARC	√	Y10	√	Y10	√
35	60	40	6.9	110	70	Y10	Y8	—	ARC	√	Y10	√	Y10	√
36	980	73	58	12	0.01	Y2	Y10	—	TF	—	Y2	√	Y2	√
37	86	187	136	363	0.01	Y7	Y10	—	TF	√	Y6	—	Y7	√
38	10	24	372	24	0.01	Y4	U.F	—	TF	√	Y4	√	Y4	√
39	260	3	18	2	0.01	Y2	Y2	√	PD	√	Y2	√	Y2	√
40	586	19	77	6	0.01	Y2	Y7	—	TF	—	Y2	√	Y2	√

Key: UF = Ακαθόριστο Σφάλμα (Unidentified Fault)  
✓= ο τύπος σφάλματος έχει διαγνωστεί σωστά  
— = ο τύπος σφάλματος δεν έχει διαγνωστεί σωστά  
A = συμφωνία με πραγματικό σφάλμα

**Πίνακας 5.2.** Ποσοστά ακρίβειας Μεθόδων

<b>Method</b>	<b>Accuracy</b>
Roger's Conventional	60%
FIS (predicts only six F.T)	95%
ANN	92,5
ANFIS	97.5%

## ΚΕΦΑΛΑΙΟ 6: Συμπεράσματα – Προτάσεις

---

### ΣΥΜΠΕΡΑΣΜΑΤΑ

Η χημική μέθοδος DGA παρουσιάζει περιορισμούς κατά την εφαρμογή της καθώς δεν παρέχει ακριβή ανάλυση όλων των σφαλμάτων και απόλυτη αξιοπιστία. Αυτό συμβαίνει συνήθως όταν λαμβάνουν χώρα στον Μ/Σ περισσότερα του ενός σφάλματα ή όταν οι συγκεντρώσεις των εκλυόμενων αερίων είναι κοντά στα όρια κατωφλίου τους.

Προκειμένου να αντιμετωπιστούν τα προβλήματα αυτά και να βελτιωθεί η αξιοπιστία της μεθόδου έχουν αναπτυχθεί διάφορες προηγμένες τεχνικές ελέγχου με τη χρήση μεθόδων Τεχνητής Νοημοσύνης, όπως τα τεχνητά νευρωνικά δίκτυα (ANN), τα Fuzzy Inference Systems (FIS) και τα Neuro-Fuzzy Systems (ANFIS).

Η εκτίμηση διάγνωσης σφάλματος μετασχηματιστή είναι ένα πολύπλοκο μη γραμμικό πρόβλημα καθότι οι εισοδοί και οι έξοδοι είναι πολλαπλές μεταβλητές και δεν υπάρχει γραμμική σχέση μεταξύ τους. Στην παρούσα εργασία, ελέγχονται και συγκρίνονται τρεις τεχνικές AI (Fuzzy Logic, ANN και ANFIS) Προκειμένου να ξεπεραστούν οι περιορισμοί του προτύπου IEC-599, Rogers Ratio Method και να βελτιωθεί η αξιοπιστία της μεθόδου.

Αποδεικνύεται μετά από αρκετό πειραματισμό με τα διάφορα αυτά μοντέλα ότι: το Ασαφές Σύστημα παρέχει ένα ισχυρό υπόβαθρο για την εκπροσώπηση των γνώσεων των ειδικών και τα συστήματα ANN είναι χρήσιμα σε περιπτώσεις όπου υπάρχουν αρκετά μετρήσιμα δεδομένα για την υπό εξέταση διαδικασία. Και οι δύο προσεγγίσεις δημιουργούν μη γραμμικά συστήματα που βασίζονται σε συνεχείς μεταβλητές. Στα Νευρωνικά Δίκτυα, λόγω του ότι απαιτούν ένα μεγάλο αριθμό δεδομένων εκπαίδευσης, η διαδικασία εκπαίδευσης έχει χαρακτήρα **αριθμητικό ποσοτικό**. Αντίθετα, η διαδικασία των ασαφών συστημάτων είναι **συμβολική-ποιοτική**, καθώς εμπεριέχει δεδομένα που εξαγονται από εμπειρογνώμονες. Το τρίτο σχήμα που έχει προταθεί, το ANFIS είναι μια σύνθεση των άλλων δύο. Παρέχει ακρίβεια 97,5%, για όλες τις 40 περιπτώσεις σφαλμάτων υπό έρευνα, χρησιμοποιώντας το πρότυπο IEC, ενώ η ικανότητα χρησιμοποιώντας τη συμβατική μέθοδο Rogers Ratio είναι 60%, η ακρίβεια FIS είναι 95% (υπό ορισμένες συνθήκες που έχουν αναφερθεί παραπάνω). Η ακρίβεια ANN είναι 92,5%.



*Εν κατακλείδι, το ANFIS είναι μια διαγνωστική μέθοδος που υπερέχει στη διάγνωση σφαλμάτων Μετασχηματιστών Ισχύος καθώς παρέχει περισσότερο αξιόπιστα και ακριβή αποτελέσματα.*

### **Μελλοντικές κατευθύνσεις έρευνας**

Η συγχώνευση των **γενετικών αλγορίθμων** με τα νευρωνικά δίκτυα, είχε σαν αποτέλεσμα την ενίσχυση των ικανοτήτων των ANN να επιλύουν προβλήματα. Πριν την εισαγωγή τους, ο καθορισμός παραμέτρων, όπως τα βάρη, η αρχιτεκτονική του δικτύου, ο ρυθμός εκμάθησης, βασιζόταν σε εμπειρικούς κανόνες των οποίων η αξιοπιστία είναι μειωμένη. Οι γενετικοί αλγόριθμοι είναι μέθοδοι καθολικής έρευνας (global search) που βασίζονται σε αρχές όπως η επιλογή (selection), η διασταύρωση (crossover) και η μετάλλαξη.

Σύμφωνα με τα παραπάνω προτείνονται ως μελλοντικές κατευθύνσεις έρευνας:

- Η ανάπτυξη μοντέλων πρόβλεψης βλαβών μέσω γενετικών αλγορίθμων.
- Χρησιμοποίηση μεγαλύτερου αριθμού δειγμάτων για δεδομένα εισόδου στα μοντέλα που ήδη μελετήθηκαν στην παρούσα διατριβή προκειμένου να επιτύχουμε πιο ακριβή αποτελέσματα.
- Η υλοποίηση των προαναφερθέντων μοντέλων με χρήση άλλων λογισμικών όπως το NNC, ή το λογισμικό μηχανικής μάθησης WEKA καθώς και μέσω μικροελεγκτών.

## ΒΙΒΛΙΟΓΡΑΦΙΑ - ΠΗΓΕΣ

---

### Βιβλιογραφία – Πηγές στην ελληνική γλώσσα

1. Τεχνητή Νοημοσύνη, Μια Σύγχρονη Προσέγγιση - Υλικό [WWW Document], n.d. URL <http://ai.uom.gr/aima/Material.htm> (accessed 2.24.19).
2. Τεχνητή Νοημοσύνη Michael Negnevitsky, Τζιόλας, 2018
3. Εισαγωγή στην Ασαφή Λογική ( Fuzzy Logic), Γιάννης Α. Θεοδώρου, Τζιόλας, 2014
4. MATLAB για Επιστήμονες και Μηχανικούς ,4<sup>η</sup> έκδοση, Τζιόλας, 2017
5. Υπολογιστική Νοημοσύνη Κ Ευφυσείς Πράκτορες, Λ. Ηλιάδης- Α. Παπαλεωνίδης Τζιόλας, 2017.
6. <https://opencourses.gr/>

### Βιβλιογραφία – Πηγές σε ξένες γλώσσες

1. K.K. Gautam and A.K.S. Tomar, IJESI **7**, 43-45 (2018).
2. S. Alsuhaibani, Y. Khan, A. Beroual, and N.H. Malik, Energies **9** (11), 1-17 (2016).
3. D. Bhalla, R.K. Bansal, and H.O. Gupta, International Journal of Electrical Power and Energy Systems **43**, 1196–1203 (2012).
4. P. Kumari, J. Singh, and K. Kaur, International Journal of industrial Electronics and Electrical Engineering, **4** (7),170–174 (2016).
5. D.M. Vishnu and A.P.P.D. Kulkarni, IJCRT **33000**, 238–243 (2017).
6. S. Koroglu, Journal of Electrical Systems **12**, 442-459 (2016).
7. S. Russell and P. Norvig, *Artificial Intelligence A Modern Approach ,Third Edition* (Pearson, New Jersey, 2010).
8. Z. Husain, International Journal on Electrical Engineering and Informatics **10**, 300-317 (2018).
9. C.A. Ciulavu, *Journal of Sustainable Energy III*, 85-90 (2012).
10. T. Committee, I. Power, and E. Society, *IEEE Guide for the Interpretation of Gases Generated in Oil - Immersed Transformers* (2009).
11. J. Golarz, Proceedings of the IEEE Power Engineering Society Transmission and Distribution Conference 2016-July, (2016).
12. J.J. Sarma and R. Sarma, IJAREEIE **6** (4), 2411- 2419 (2017).
13. P.S. Khade, G.K. Mahajan, and A.P. Chaudhari, International Journal of Scientific & Engineering Research **7**, 373-377 (2016).
14. R.S. Zade and P.S. Kudkelwar, International Journal of Trend in Scientific Research and Development **2**, 1179-1184 (2018).
15. H. Malik, T. Mahto, B.K. Anil, K. Mantosh, and R.K. Jarial, Journal of Electrical Engineering **12**, 105-109 (2012).
16. M. Negnevitsky, *Artificial Intelligence: A Guide to Intelligent Systems*, 2nd Edition ( Pearson, New Jersey, 2005), pp. 1-364.
17. N.K. Sharma, P.K. Tiwari, and Y.R. Sood, International Journal of Computer and Electrical Engineering **3**, 577-582 (2011).
18. N.K. Dhote and J.B. Helonde, WSEAS Transactions on Power Systems **7**, 114-125 (2013).

19. K.C. Jane, P.D. Ugale, and S.D. Hire, *International Journal of Electrical and Electronics Engineering* **4**, 1-4 (2017).
20. R.N. Afiqah, I. Musirin, D. Johari, M.M. Othman, T.K.A. Rahman, and Z. Othman, *International Conference on Electric Power Systems, High Voltages, Electric Machines, International Conference on Remote Sensing - Proceedings* **83** (2010).
21. A.Muthi, S. Sumarto, and W.S. Saputra, *IOP Conference Series: Materials Science and Engineering* **384**, (2018).
22. M.E. Senoussaoui, I.S. Bousmaha, and M.M. Brahami, "Improved Gas Ratios Models for DGA Interpretation Using Artificial Neural Networks." *World Congress on Multimedia and Computer Science and Association of Computer Electronics and Electrical Engineers* (2019).
23. O. Rahman, S. A. Wani, S. Parveen, and S. A. Khan, "Detection of Incipient Fault in Transformer using DGA Based Integrated Intelligent Method." *2019 International Conference on Power Electronics, Control and Automation (ICPECA)*. IEEE, (2019), pp. 1-6.
24. D.D. Dhonge, P.S. Swami, and A.G. Thosar, *International Journal of Scientific & Engineering Research*, **6**, 1127-1132 (2015).
25. A.R. Hussein, M.M. Yaacob, and M.F. Othman, *Journal of Theoretical and Applied Information Technology* **78**, 278-285 (2015).
26. S.S.M. Ghoneim and I.B. Taha, "Artificial neural networks for power transformers fault diagnosis based on IEC code using dissolved gas analysis." *Int. J. Control. Autom. Syst* **4.2** (2015), pp. 18-21.
27. H. Malik, A. Khatri, and R. Dohare, *Procedia Computer Science* **58**, 665-667 (2015).
28. R.R.B. De Aquino, M.M.S. Lira, T. Filgueiras, H. Ferreira, O.N. Neto, A.M.S. Silva, and V.K. Asfora, *2010 IEEE World Congress on Computational Intelligence, WCCI 2010* (2010).
29. O.E. Gouda, S.M. Saleh, and S.H. El-Hoshy, *Indonesian Journal of Electrical Engineering and Computer Science* **1**, 10-16 (2016).
30. H.A. Illias, X.R. Chai, A.H.A. Bakar, and H. Mokhlis, *PLoS ONE* **10**, 1-16 (2015).
31. N.S. Mahajan and P.S.S. Hadpe, *IRJET* **3**, 1111-1114 (2016).
32. T. Nagpal and Y.S. Brar, *Neural Computing and Applications* **25**, 1863-1870 (2014).
33. T. Kari, W. Gao, D. Zhao, Z. Zhang, W. Mo, Y. Wang, and L. Luan, *IEEE Transactions on Dielectrics and Electrical Insulation* **25**, 360-371 (2018).
34. A.S. Kulkarni, P.S. Swami, and A.G. Thosar, *International Journal of Scientific & Engineering Research* **7**, 1487-1491 (2016).
35. Al-Hmouz, J. Shen, R. Al-Hmouz, and J. Yan, *IEEE Transactions on Learning Technologies* **5**, 226-237 (2012).
36. A.F. Pashchenko and I.S. Durgaryan, On neuro-fuzzy prediction in MATLAB. in *Proceedings of the 2015 10th IEEE Conference on Industrial Electronics and Applications, ICIEA* 1539-1542 (2015).
37. S. Shinde, *International Journal for Research in Applied Science and Engineering Technology* **6**, 2030-2035 (2018).
38. R.A. Hooshmand, M. Parastegari, and Z. Forghani, *IEEE Electrical Insulation Magazine* **28**, 32-42 (2012).
39. M.M. Bin Yaacob, A.R. Hussein, and M.F. Bin Othman, *Modern Applied Science* **10**, 13-22 (2015).
40. V. Alamuru and S.R.C.M. Pessapaty, *Journal of Engineering and Technology Research* **7**, 32-43 (2015).
41. S. Marsland *Machine Learning: An Algorithmic Perspective Second Edition*. CRC Press, ISBN 978-1-4987-5978-6, 2015.
42. <http://www.mathworks.com/>
43. <https://www.ieee.org/>

## Πίνακες Δεδομένων

Πίνακας 1. Data Samples

S.N	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	S.N	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>
1	269	1081	347	1725	25	23	180.8	0.5	0.234	0.18	0.0001
2	10	10	8	1	0.01	24	12	8	40	5	0.01
3	30	22	14	4.1	0.1	25	16	25	19	39	0.01
4	2.9	2	1.5	0.3	0.1	26	1	22	88	143	1
5	4	99	82	4.2	0.1	27	17	15	20	78	35
6	21	34	5	47	62	28	1046	2809	675	321	1
7	50	100	51	305	9	29	62	26	18	9	1
8	120	17	32	4	23	30	3	600	437	1588	61
9	980	73	58	12	0.01	31	239	41	21	59	227
10	1607	615	80	916	1294	32	0.5	115	147	16	0.5
11	14.7	3.7	10.5	2.7	0.2	33	2	113	235	6	0.5
12	181	262	41	28	0.01	34	127	76	32	23	49
13	173	334	172	812.5	33.7	35	367	903	921	5760	54
14	127	107	11	154	224	36	4	144	234	15	0.5
15	60	40	6.9	110	70	37	1	8	15	21	3
16	980	73	58	12	0.01	38	53	611	725	1644	0.5
17	86	187	136	363	0.01	39	645	45	0.5	51	326
18	10	24	372	24	0.01	40	6	9	4	10	0.5
19	260	3	18	2	0.01	41	111	26	9	31	65
20	586	19	77	6	0.01	42	11	101	110	0.5	0.5
21	33	26	6	53	0.2	43	1443	3899	1115	600	113
22	34.45	21.3	3.19	45	19.62	44	107	27	18	25	65

S.N	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	S.N	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>
45	72	278	289	629	0.5	73	36	245	144	332	0.0001
46	41	65	22	58	0	74	86	187	136	363	0.0001
47	17	66	9	17	0	75	10	24	372	24	0.0001
48	20	48	36	186	0	76	17	7	13	3	0
49	179	306	73	579	0	77	206	42	16	82	221
50	73	177	37	52	0	78	769	999	234	1599	31
51	210	43	12	102	187	79	1000	50	40	30	10
52	39	7	12	65	0	80	127	107	11	154	224
53	37	96	19	57	0	81	2004	9739	2750	5114	0
54	46	147	27	150	0	82	60	144	67	449	9

55	18	63	20	51	0	83	4	3	2	1	0
56	200	30	9	60	98	84	65	53	41	95	14
57	28	62	16	76	0	85	33	79	30	215	5
58	68	78	103	136	0	86	1249	370	56	606	1371
59	54	143	23	101	0	87	507	1053	297	1440	17
60	19	47	27	62	0	88	57	77	19	21	0
61	678	70	31	89	237	89	160	10	3	1	1
62	86	277	63	338	0	90	199	770	217	1508	72
63	20	19	45	77	0	91	416	695	74	867	0
64	25	49	42	58	0	92	10	27	49	4	1
65	53	150	64	379	0	93	1450	940	211	322	61
66	114	241	80	574	0	94	2.35	1.7	0.6	1.2	0.1
67	99	288	73	386	0	95	240	96	20	8	5
68	1374	2648	628	5376	298	96	960	4000	1290	1560	6
69	34	83	100	136	0	97	980	73	58	12	0
70	20	132	61	17	0	98	280	1500	1200	150	40
71	191	47	43	15	0.0001	99	2844	8517	10196	4422	39
72	50	200	300	200	50	100	8	4	350	24	2

Πίνακας 2. Συγκεντρώσεις αερίων και κωδικό ROGERS

CH <sub>4</sub> /H <sub>2</sub>	C <sub>2</sub> H <sub>6</sub> /CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub>	CODE X1	CODE X2	CODE X3	CODE X4
4.0	0.3	5.0	0.0	2	0	2	0
1.0	0.8	0.1	0.0	1	0	0	0
0.7	0.6	0.3	0.0	0	0	0	0
0.7	0.8	0.2	0.3	0	0	0	0
24.8	0.8	0.1	0.0	2	0	0	0
1.6	0.1	9.4	1.3	1	0	2	1
2.0	0.5	6.0	0.0	1	0	2	0
0.1	1.9	0.1	5.8	0	1	0	2
0.1	0.8	0.2	0.0	5	0	0	0
0.4	0.1	11.5	1.4	0	0	2	1
0.3	2.8	0.3	0.1	0	1	0	0
1.4	0.2	0.7	0.0	1	0	0	0
1.9	0.5	4.7	0.0	1	0	2	0
0.8	0.1	14.0	1.5	0	0	2	1
0.7	0.2	15.9	0.6	0	0	2	1
0.1	0.8	0.2	0.0	5	0	0	0
2.2	0.7	2.7	0.0	1	0	1	0
2.4	15.5	0.1	0.0	1	1	0	0
0.0	6.0	0.1	0.0	5	1	0	0
0.0	4.1	0.1	0.0	5	1	0	0
0.8	0.2	8.8	0.0	0	0	2	0

0.6	0.1	14.1	0.4	0	0	2	0
0.0	0.5	0.8	0.0	5	0	0	0
0.7	5.0	0.1	0.0	0	1	0	0
1.6	0.8	2.1	0.0	1	0	1	0
22	4.0	1.6	0.0	2	1	1	0
0.9	1.3	3.9	0.4	0	1	2	0
2.7	0.2	0.5	0.0	1	0	0	0
0.4	0.7	0.5	0.1	0	0	0	0
200	0.7	3.6	0.0	2	0	2	0
0.2	0.5	2.8	3.8	0	0	1	2
230	1.3	0.1	0.0	2	1	0	0
56.5	2.1	0.0	0.1	2	1	0	0
0.6	0.4	0.7	2.1	0	0	0	1
2.5	1.0	6.3	0.0	1	1	2	0
36	1.6	0.1	0.0	2	1	0	0
8.0	1.9	1.4	0.1	2	1	1	0
11.5	1.2	2.3	0.0	2	1	1	0
0.1	0.0	102	6.4	5	0	2	2
1.5	0.4	2.5	0.1	1	0	1	0
0.2	0.3	3.4	2.1	0	0	2	1
9.2	1.1	0.0	1.0	2	1	0	1
2.7	0.3	0.5	0.2	1	0	0	0
0.3	0.7	1.4	2.6	0	0	1	1
3.9	1.0	2.2	0.0	2	1	1	0
1.6	0.3	2.6	0.0	1	0	1	0
3.9	0.1	1.9	0.0	2	0	1	0
2.4	0.8	5.2	0.0	1	0	2	0
1.7	0.2	7.9	0.0	1	0	2	0
2.4	0.2	1.4	0.0	1	0	1	0
0.2	0.3	8.5	1.8	0	0	2	1
0.2	1.7	5.4	0.0	0	1	2	0
2.6	0.2	3.0	0.0	1	0	2	0
3.2	0.2	5.6	0.0	2	0	2	0
3.5	0.3	2.6	0.0	2	0	1	0
0.2	0.3	6.7	1.6	0	0	2	1
2.2	0.3	4.8	0.0	1	0	2	0
1.1	1.3	1.3	0.0	1	1	1	0
2.6	0.2	4.4	0.0	1	0	2	0
2.5	0.6	2.3	0.0	1	0	1	0
0.1	0.4	2.9	2.7	0	0	1	1
3.2	0.2	5.4	0.0	2	0	2	0
1.0	2.4	1.7	0.0	0	1	1	0
2.0	0.9	1.4	0.0	1	0	1	0
2.8	0.4	5.9	0.0	1	0	2	0
2.1	0.3	7.2	0.0	1	0	2	0

2.9	0.3	5.3	0.0	1	0	2	0
1.9	0.2	8.6	0.1	1	0	2	0
2.4	1.2	1.4	0.0	1	1	1	0
6.6	0.5	0.3	0.0	2	0	0	0
0.2	0.9	0.3	0.0	0	0	0	0
4.0	1.5	0.7	0.3	2	1	0	0
6.8	0.6	2.3	0.0	2	0	1	0
2.2	0.7	2.7	0.0	1	0	1	0
2.4	15.5	0.1	0.0	1	1	0	0
0.4	1.9	0.2	0.0	0	1	0	0
0.2	0.4	5.1	2.7	0	0	2	1
1.3	0.2	6.8	0.0	1	0	2	0
0.1	0.8	0.8	0.3	5	0	0	0
0.8	0.1	14	1.5	0	0	2	1
4.9	0.3	1.9	0.0	2	0	1	0
2.4	0.5	6.7	0.0	1	0	2	0
0.8	0.7	0.5	0.0	0	0	0	0
0.8	0.8	2.3	0.1	0	0	1	0
2.4	0.4	7.2	0.0	1	0	2	0
0.3	0.2	10.8	2.3	0	0	2	1
2.1	0.3	4.8	0.0	1	0	2	0
1.4	0.2	1.1	0.0	1	0	1	0
0.1	0.3	0.3	1.0	5	0	0	1
3.9	0.3	6.9	0.0	2	0	2	0
1.7	0.1	11.7	0.0	1	0	2	0
2.7	1.8	0.1	0.3	1	1	0	0
0.6	0.2	1.5	0.2	0	0	1	0
0.7	0.4	2	0.1	0	0	1	0
0.4	0.2	0.4	0.6	0	0	0	1
4.2	0.3	1.2	0.0	2	0	1	0
0.1	0.8	0.2	0.0	5	0	0	0
5.4	0.8	0.1	0.3	2	0	0	0
3.0	1.2	0.4	0.0	1	1	0	0
0.5	87.5	0.1	0.1	0	1	0	0

Πίνακας 3. 20 Samples Data

S. N	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	CH <sub>4</sub> /H <sub>2</sub>	C <sub>2</sub> H <sub>6</sub> /CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub>	CODE X1	CODE X2	CODE X3	CODE X4
1	269	1081	347	1725	25	4.02	0.32	4.97	0.01	2	0	2	0
2	10	10	8	1	0.01	1.00	0.80	0.13	0.01	1	0	0	0
3	30	22	14	4.10	0.1	0.73	0.64	0.29	0.02	0	0	0	0
4	2.90	2	2	0.3	0.1	0.69	0.75	0.20	0.33	0	0	0	0
5	4	99	82	4	0.1	24.75	0.83	0.05	0.02	2	0	0	0
6	21	34	5	47	62	1.62	0.15	9.40	1.32	1	0	2	1
7	50	100	51	305	9	2.00	0.51	5.98	0.03	1	0	2	0
8	120	17	32	4	23	0.14	1.88	0.13	5.75	0	1	0	2
9	980	73	58	12	0.01	0.07	0.79	0.21	0.00	5	0	0	0
10	1607	615	80	916	1294	0.38	0.13	11.45	1.41	0	0	2	1
11	14.7	3.7	10.5	2.7	0.2	0.25	2.84	0.26	0.07	0	1	0	0
12	181	262	41	28	0.01	1.45	0.16	0.68	0.00	1	0	0	0
13	173	334	172	812.5	33.7	1.93	0.51	4.72	0.04	1	0	2	0
14	127	107	11	154	224	0.84	0.10	14.00	1.45	0	0	2	1
15	60	40	6.9	110	70	0.67	0.17	15.94	0.64	0	0	2	1
16	980	73	58	12	0.01	0.07	0.79	0.21	0.00	5	0	0	0
17	86	187	136	363	0.01	2.17	0.73	2.67	0.00	1	0	1	0
18	10	24	372	24	0.01	2.40	15.50	0.06	0.00	1	1	0	0
19	260	3	18	2	0.01	0.01	6.00	0.11	0.01	5	1	0	0
20	586	19	77	6	0.01	0.03	4.05	0.08	0.00	5	1	0	0



Πίνακας 4. ROGERS\_output

S.N	Y1	Y2	Y3	Y4	Y5	Y6	Y7	Y8	Y9	Y10	Y11	Y12	ANN
1	0.00	0.01	1.00	0.00	0.00	0.01	0.01	0.01	0.01	0.01	0.00	0.00	Y3
2	0.00	0.00	0.01	0.01	0.01	0.02	0.02	0.01	0.01	0.99	0.00	0.01	Y10
3	0.01	0.00	0.00	0.01	0.01	0.01	0.98	0.01	0.01	0.01	0.01	0.01	Y7
4	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00	0.01	0.00	Y8
5	0.01	0.00	0.00	0.01	0.01	0.01	0.98	0.01	0.01	0.01	0.01	0.01	Y7
6	0.00	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	Y5
7	0.50	0.00	0.00	0.00	0.00	0.01	0.49	0.01	0.00	0.01	0.00	0.00	Y1.Y7
8	0.01	0.00	0.00	0.00	0.00	1.00	0.01	0.01	0.00	0.00	0.00	0.00	Y6
9	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00	0.01	0.00	Y8
10	0.00	0.01	1.00	0.00	0.00	0.01	0.01	0.01	0.01	0.01	0.00	0.00	Y3
11	0.00	0.00	0.01	0.01	0.01	0.02	0.02	0.01	0.01	0.99	0.00	0.01	Y10
12	0.11	0.17	0.04	0.59	0.28	0.20	0.17	0.09	0.08	0.11	0.22	0.30	Y4
13	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00	0.01	0.00	Y8
14	0.01	0.00	0.00	0.01	0.01	0.01	0.98	0.01	0.01	0.01	0.01	0.01	Y7
15	0.01	0.00	0.00	0.01	0.01	0.01	0.98	0.01	0.01	0.01	0.01	0.01	Y7
16	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00	0.01	0.00	Y8
17	0.01	0.00	0.00	0.01	0.01	0.01	0.98	0.01	0.01	0.01	0.01	0.01	Y7
18	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00	0.01	0.00	Y8
19	0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	Y2
20	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00	0.01	0.00	Y8

Πίνακας 5: Ταξινόμηση βλαβών σε σχέση με Roger's ratio codes για FL

MH	EM	EE	AE	Βλάβες	Σύντμηση
0- 1- 2	0- 1	0- 1- 2	0	Θερμικά σφάλματα	TF
0	0	0-1- 2	1- 2	Τόξα	ARC
5	0	0	0- 1- 2	Μερικές εκκενώσεις	PD
0	0	0	0	Κανονική λειτουργία	Normal