



**ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ**

**ΣΧΟΛΗ ΜΗΧΑΝΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ**

**ΤΟΜΕΑΣ ΤΕΧΝΟΛΟΓΙΑΣ ΚΑΤΕΡΓΑΣΙΩΝ**

**ΝΤΕΖΕΣ ΔΗΜΗΤΡΙΟΣ**

**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**

**ΜΟΝΤΕΛΟΠΟΙΗΣΗ ΤΗΣ ΚΑΤΕΡΓΑΣΙΑΣ ΔΙΑΤΡΗΣΗΣ  
ΣΥΝΘΕΤΩΝ ΥΛΙΚΩΝ ΜΕ ΜΟΝΤΕΛΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ**

**ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ: ΜΑΡΚΟΠΟΥΛΟΣ ΑΓΓΕΛΟΣ**

**ΑΘΗΝΑ 2019**

## ΠΡΟΛΟΓΟΣ-ΕΥΧΑΡΙΣΤΙΕΣ

Οι κατεργασίες αφαίρεσης υλικού τόσο ως διαδικασία όσο και ως προς το παραγόμενο αποτέλεσμα, αποτελούσαν για τον υπογράφοντα φοιτητή, ανέκαθεν ένα από τα πιο ενδιαφέροντα αντικείμενα στον τομέα των μηχανολογικών κατασκευών. Πάνω σε αυτό το ενδιαφέρον δόθηκε το έναυσμα για την ανάθεση, σχεδίαση και υλοποίηση της παρούσας διπλωματικής εργασίας, έπειτα από μια πλήρως εποικοδομητική συνεννόηση και συνεργασία όλων των εμπλεκομένων πλευρών και καθόλη την πορεία του εγχειρήματος.

Ως συνέπεια των παραπάνω, στην παρούσα παράγραφο, εκφράζονται οι πλέον θερμές ευχαριστίες στον επιβλέποντα καθηγητή κ. Μαρκόπουλο Άγγελο αλλά και στον υποψήφιο διδάκτορα κ. Κάρκαλο Νικόλαο, τόσο για την ανάθεση της εν λόγω διπλωματικής εργασίας όσο και για τις όποιες βοήθειες παρείχαν, ως προς την επιτυχή ολοκλήρωση της.

## ΠΕΡΙΛΗΨΗ

Ο τομέας των κατεργασιών αφαίρεσης υλικού, αποτελεί έναν από τους πιο σημαντικούς παράγοντες στην μηχανολογία. Επικεντρώνεται στην διαδικασία παραγωγής αντικειμένων μέσω της αφαίρεσης/κοπής υλικού και στόχος είναι το παραγόμενο εξάρτημα, να αποκτήσει την απαιτούμενη διαστασιολογική ακρίβεια, αλλά και η κατεργασία κοπής να πραγματοποιηθεί με το ελάχιστο δυνατό κόστος. Είναι αναμενόμενο ότι τόσο οι παράμετροι κοπής όσο και ποιοτικά χαρακτηριστικά της εκάστοτε κατεργασίας, έχουν πρωτεύοντα ρόλο στην όλη διαδικασία.

Η παρούσα διπλωματική εργασία αποσκοπεί να διερευνήσει την επήρεια παραμέτρων κοπής όπως η διάμετρος και το υλικό του κοπτικού εργαλείου, η ταχύτητα κοπής και η πρόωση, στον προσδιορισμό χαρακτηριστικών της κατεργασίας όπως η Δύναμη Ώθησης -Fz- και ο Παράγοντας Αποκόλλησης - DF(Delamination Factor). Η κατεργασία στην οποία συντελείται η όλη διαδικασία είναι αυτή της διάτρησης και πραγματοποιείται σε 2 δοκίμια από το ίδιο υλικό, των C6-W-03 και C6-W-01. Σε πρώτο στάδιο ελήφθησαν πειραματικά δεδομένα από ανάλογο πείραμα διάτρησης. Σε ύστερη φάση θα χρησιμοποιηθούν κατάλληλα μαθηματικά μοντέλα, όπου μέσω περιβάλλοντος προγραμματισμού MATLAB και με τα πειραματικά δεδομένα των προαναφερθέντων παραμέτρων κοπής, θα αξιολογηθούν ως προς την αποτελεσματικότητα πρόβλεψης των ζητούμενων χαρακτηριστικών συγκρινόμενα με τα ανάλογα πειραματικά αποτελέσματα.

Η εργασία αποτελείται από τέσσερα σκέλη. Στο πρώτο έγινε μια συνοπτική παρουσία των βασικών χαρακτηριστικών των κατεργασιών και συγκεκριμένα της κατεργασίας της διάτρησης. Στο δεύτερο σκέλος παρουσιάστηκαν τα τεχνητά νευρωνικά δίκτυα ως προς τα χαρακτηριστικά τους και την χρησιμοποίησή τους, η μεμονωμένη περίπτωση του δικτύου RBF, ενώ υπήρξε επιπλέον αναφορά σε πρότερες χρονικά μελέτες, απόλυτα σχετικές με το αντικείμενο που πραγματεύεται η παρούσα διπλωματική εργασία. Στο τρίτο σκέλος, καταδείχθηκαν τα ασαφή και κυρίως τα νεύρο-ασαφή συστήματα επικεντρώνοντας στην περίπτωση του δικτύου ANFIS ως προς την δομή του, την εκπαίδευση του, αλλά και σε χρονικά παρελθοντικές βιβλιογραφικές περιπτώσεις εφαρμογής του σε κατεργασίες αφαίρεσης υλικού, ανάλογα των νευρωνικών δικτύων. Στο τελικό σκέλος η εργασία εστίασε στην πειραματική διαδικασία, στην χρησιμοποίηση του τεχνητού νευρωνικού δικτύου MLP (Multilayer Perceptron), του νευρωνικού δικτύου RBF και του νεύρο-ασαφούς συστήματος ANFIS και εν γένει στην ανάδειξη του καταλληλότερου μοντέλου πρόβλεψης από τα τρία για τον σκοπό που προαναφέρθηκε, καθώς και στην βέλτιστη εκδοχή του. Επίσης επιδείχθηκαν τα αποτελέσματα τόσο αριθμητικά, όσο και γραφικά στην περίπτωση του τεχνητού νευρωνικού δικτύου, όπως και επιχειρήθηκε μια συνολική αποτίμηση της διαδικασίας.

## **ABSTRACT**

The machining sector is considered as one of the most significant areas in the field of mechanical engineering. This type of processes are focused in the production of mechanical components through the procedure of material removal, having as purpose the necessary dimensional accuracy of the final product and also the minimization of the production cost. It is expected that the parameters of cutting process and the quality features in every kind of machining, have an important role in the manufacturing procedure.

The current thesis attempted to explore the effect of cutting conditions, such as the cutting speed, the material and the diameter of cutting tool and the feed rate on the thrust force  $F_z$  and delamination factor  $DF$ . The machining process in this particular case was drilling and was performed with two different kinds of material of the cutting tool. In the first stage experimental data were taken from a proper drilling operation. After that, appropriate mathematical models, through MATLAB programming environment were used in order to predict the thrust force and delamination factor, and they will be evaluated regarding their accuracy by conducting a comparison with the experimental results of the drilling operation.

The thesis is divided in four parts. In the first part, there was a general presentation about the basic characteristics of the machining processes and also for this particular case, the drilling process. In the second part a presentation of the artificial neural networks (ANN) from every aspect took place as well as the specific case of the radial basis function (RBF) network. In the third part, the fuzzy and neuro-fuzzy networks were demonstrated with an emphasis in the case of adaptive-network-based fuzzy inference system (ANFIS) in a similar way as the ANN systems. At the final part the thesis focused on the experimental process, the creation, evaluation and comparison of the three mathematical models (ANN, ANFIS, RBF), the choice of the most appropriate from these three models, and the optimization of the chosen network.

## ΕΠΕΞΗΓΗΣΗ ΕΛΛΗΝΙΚΩΝ/ΑΓΓΛΙΚΩΝ ΤΕΧΝΙΚΩΝ ΕΝΝΟΙΩΝ

- M.L.P /(Multilayer Perceptron) : Τεχνητά νευρωνικά δίκτυα (ΤΝΔ).
- ANFIS ( adaptive Neuro-Fuzzy Inference System): Προσαρμοστικό νευρο-ασαφές σύστημα εξαγωγής συμπερασμάτων.
- RBF(Radial Basis Function): Συνάρτηση ακτινικής βάσης.
- DF (Delamination Factor): Παράγων αποκόλλησης.
- Fz: Δύναμη Ώθησης.
- Feedforward: Πρόσθια τροφοδότηση.
- Back Propagation: Οπισθόδρομη διάδοση.
- MSE (Mean Square Error): Μέσο τετραγωνικό σφάλμα.
- MAPE (Mean absolute Percentage Error): Μέσο απόλυτο ποσοστιαίο σφάλμα.
- R (Regression): Συντελεστής συσχέτισης.
- Vallidation: Γενίκευση
- Test: Δοκιμή
- Nclusters: Ομάδες/Συστάδες.
- Epochs: Επαναλήψεις
- Trainlm: Αλγόριθμος εκπαίδευσης ΤΝΔ, Levenberg -Marquadt
- Traingd: Αλγόριθμος εκπαίδευσης ΤΝΔ, Gradient-Descent
- Trainbfg: Αλγόριθμος εκπαίδευσης ΤΝΔ, Quasi-Newton
- Trainscg: Αλγόριθμος εκπαίδευσης ΤΝΔ, Scaled Conjugate Gradient

## Περιεχόμενα

### Κεφάλαιο 1: ΕΙΣΑΓΩΓΗ ΣΤΙΣ ΚΑΤΕΡΓΑΣΙΕΣ

1.1 Γενικά στοιχεία στις κατεργασίες.....	8
1.2 Κατεργασίες αφαίρεσης υλικού.....	10
1.3 Κοπτικά εργαλεία.....	16
1.4 Κατεργασία Διάτρησης.....	20

### Κεφάλαιο 2: ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

2.1 Εισαγωγή.....	28
2.2 Ιστορική αναδρομή και εφαρμογές.....	28
2.3 Αρχή λειτουργίας νευρωνικού δικτύου.....	29
2.4 Πλεονεκτήματα νευρωνικών δικτύων.....	33
2.5 Κατηγορίες νευρωνικών δικτύων.....	34
2.6 Εκπαίδευση νευρωνικών δικτύων.....	36
2.7 Γενίκευση νευρωνικών δικτύων.....	41
2.8 Το νευρωνικό δίκτυο RBF.....	42
2.9 Ανασκόπηση πρότερων εργασιών σχετικά με τα νευρωνικά δίκτυα.....	43

### Κεφάλαιο 3: ΑΣΑΦΗ ΣΥΣΤΗΜΑΤΑ-ΣΥΣΤΗΜΑ ANFIS

3.1 Εισαγωγή στα ασαφή σύνολα.....	51
3.2 Ιστορική αναδρομή.....	51
3.3 Χαρακτηριστικά ασαφών συνόλων.....	52
3.4 Μορφές ασαφών συστημάτων.....	56
3.5 Προσαρμοστικά νευρωνικά-ασαφή συστήματα συμπερασμού.....	57
3.6 Ιστορική αναδρομή των προσαρμοστικών νευρο-ασαφών συστημάτων.....	58

3.7 Αρχή λειτουργίας και αρχιτεκτονική του ANFIS.....	59
3.8 Εκπαίδευση του μοντέλου ANFIS.....	62
3.9 Προϋποθέσεις εφαρμογής του μοντέλου ANFIS.....	63
3.10 Επισκόπηση πρότερων εργασιών σχετικά με το μοντέλο ANFIS...	64
<b>Κεφάλαιο 4: ΕΦΑΡΜΟΓΗ ΤΩΝ ANN/ ANFIS/ RBF ΣΤΗΝ ΚΑΤΕΡΓΑΣΙΑ ΔΙΑΤΡΗΣΗΣ</b>	
4.1 Περιγραφή πειραματικής διαδικασίας.....	68
4.2 Καθορισμός παραμέτρων αρχιτεκτονικής και εκπαίδευσης των υπό σύγκριση υπολογιστικών μοντέλων πρόβλεψης.....	74
4.3 Παρουσίαση αποτελεσμάτων των υπολογιστικών μοντέλων.....	76
4.4 Επιλογή καταλληλότερου αλγορίθμου/μεθόδου.....	92
4.5 Συμπεράσματα.....	93
<b>ΒΙΒΛΙΟΓΡΑΦΙΑ.....</b>	<b>95</b>

# Κεφάλαιο 1

## ΕΙΣΑΓΩΓΗ ΣΤΙΣ ΚΑΤΕΡΓΑΣΙΕΣ

### 1.1 Γενικά στοιχεία στις κατεργασίες

#### ΟΡΙΣΜΟΣ

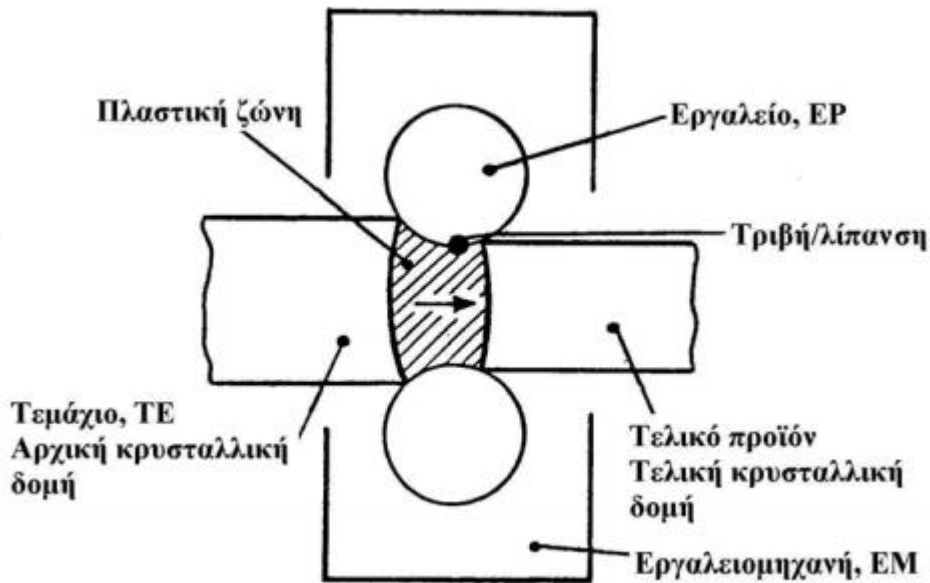
**Κατεργασία** (process) είναι η διαδικασία μορφοποίησης των υλικών που

1) Εκμεταλλεύεται την ιδιότητά τους να παραμορφώνονται πλαστικά (μόνιμες μεγάλες παραμορφώσεις) και 2) συνδυάζει κατάλληλα τις συνθήκες φόρτισης, θερμοκρασίας και ταχύτητας για βέλτιστο αποτέλεσμα.

Στο ακόλουθο σχήμα, παρουσιάζονται οι βασικές παράμετροι που λαμβάνουν μέρος σε μια κατεργασία και αλληλοεπηρεάζονται[1]:

- Το προς κατεργασία τεμάχιο, ΤΕ (workpiece), υπό τη μορφή μπιγέτας (billet) ή ελάσματος (blank).
- Το εργαλείο, ΕΡ (tooling), που διαμορφώνει το ΤΕ.
- Οι συνθήκες στη διεπιφάνεια ΤΕ/ΕΡ (conditions at tool/material interface), δηλ. λίπανση και τριβολογικά χαρακτηριστικά.
- Η ζώνη παραμόρφωσης ή πλαστική ζώνη (deformation zone), όπου επιτελείται η πλαστική παραμόρφωση του ΤΕ.
- Ο χρησιμοποιούμενος εξοπλισμός (equipment used), δηλαδή η εργαλειομηχανή, ΕΜ (machinetool) και ο υπόλοιπος χρησιμοποιούμενος εξοπλισμός.
- Το τελικό προϊόν (product) με κρυσταλλική δομή διαφορετική από αυτή του αρχικού ΤΕ.
- Το περιβάλλον (environment).





Εικόνα 1.1: Σχηματική παράσταση κατεργασίας [1]

Οι παραπάνω παράμετροι επιβάλλουν την ανάλυση τους σε επιμέρους στοιχεία, ώστε η όλη διαδικασία της κατεργασίας, να έχει επιτυχή κατάληξη ως προς το προσδοκώμενο προϊόν σε παράμετρος όπως π.χ η τραχύτητα της επιφάνειας του, η ακρίβεια των επιθυμητών διαστάσεων κ.α.. Για το κατεργαζόμενο τεμάχιο (TE) σημαντικές ιδιότητες είναι: η αρχική γεωμετρία και οι συνθήκες επιφάνειας του, η κατεργασιμότητα του, οι θερμικές και φυσικές ιδιότητες του υλικού του, οι αρχικές συνθήκες σύστασης, θερμοκρασίας και μικροδομής κ.λ.π.

Επίσης σημαντικό ρόλο παίζουν οι ιδιότητες του κοπτικού εργαλείου (KE) που θα επιλεγεί και με το οποίο, θα πραγματοποιηθεί η κατεργασία του εκάστοτε τεμαχίου. Τέτοιες είναι: η γεωμετρία του, το υλικό του ως προς την σκληρότητα, η στιβαρότητα κι η ακρίβεια του κ.α. Κατά αυτό τον τρόπο θα εξασφαλίζεται η κατεργασία του τεμαχίου από το κοπτικό εργαλείο υπό τις κάλλιστες δυνατές συνθήκες και όχι τυχόν ανεπιθύμητη κατάσταση όπως να υφίσταται κατεργασία το κοπτικό εργαλείο από το τεμάχιο λόγω π.χ ανεπαρκούς σκληρότητας του πρώτου.

Επιπλέον είναι απαραίτητα η διερεύνηση των συνθηκών στην διεπιφάνεια του κοπτικού εργαλείου με το τεμάχιο. Ο έλεγχος στην περιοχή αυτή, θα δώσει την δυνατότητα της επιλογής κατάλληλου υλικού λίπανσης της κατεργασίας με βάση τα τριβολογικά χαρακτηριστικά και τις θερμοκρασιακές συνθήκες της διεπιφάνειας, προκειμένου το λιπαντικό μέσο να προσφέρει επαρκή ψύξη στην όλη διαδικασία, με την αποβολή μέρους της θερμότητας που προβλέπεται να αναπτυχθεί.

Εξίσου σημαντικό ρόλο παίζει η μελέτη της ζώνης παραμόρφωσης, όπου συντελείται η μόνιμη-πλαστική-παραμόρφωση του κατεργαζόμενου δοκιμίου. Σε συνδυασμό με την ύπαρξη ενός θεωρητικού μοντέλου ανάλυσης, θα εξασφαλιστεί ο τρόπος ώστε το, προς κατεργασία, τεμάχιο να λάβει την επιθυμητή τελική του μορφή.

Η ανάλυση των παραπάνω παραμέτρων, με την σειρά της, θα οδηγήσει στην επιλογή του κατάλληλου εξοπλισμού, για την περαίωση της κατεργασίας. Η χρησιμοποιούμενη εργαλειομηχανή (EM) θα πρέπει να είναι κατάλληλη για το είδος της κατεργασίας που ζητείται, να έχει τα πρόπαντα χαρακτηριστικά σε ζητήματα φορτίου και ισχύος, αλλά και την απαιτούμενη παραγωγικότητα, για την κάλυψη των ανάλογων απαιτήσεων σε ποσότητα κατεργαζόμενων τεμαχίων.[1]

## ΤΑΞΙΝΟΜΗΣΗ ΚΑΤΕΡΓΑΣΙΩΝ

Οι κατεργασίες ταξινομούνται με βάση, διάφορα κριτήρια όπως: το καθεαυτού είδος της κατεργασίας, την χρησιμοποιούμενη ενέργεια και εξοπλισμό και την εφαρμοζόμενη θερμοκρασία κατεργασίας, όπως επισυνάπτεται στον ακόλουθο πίνακα.

**Εικόνα 1.2:Κατηγοριοποίηση κατεργασιών [1]**

Κριτήριο	Κατεργασίες
Είδος κατεργασίας	<b>Αρχέγονες κατεργασίες:</b> Χύτευση, Κονιομεταλλουργία
	<b>Διαμορφώσεις:</b> Σφυρηλάτηση, Έλαση, Διέλαση, Ολκή, Κάμψη, Βαθεία κοίλανση, Απότμηση
	<b>Κοπές ή κατεργασίες αφαίρεσης υλικού:</b> Τόρνευση, Φρεζάρισμα, Λείανση, Διάτρηση κ.λ.π
	<b>Επιφανειακές κατεργασίες:</b> Θερμικές, Θερμοχημικές, Επικαλύψεις
	<b>Κατεργασίες σύνδεσης:</b> Συγκολλήσεις, Ηλώσεις, Κοχλιώσεις
Χρησιμοποιούμενη ενέργεια/ εξοπλισμός	<b>Συμβατικές:</b> Μηχανουργικές κατεργασίες
	<b>Μη συμβατικές:</b> Κοπή με laser, Υδροκοπή, Μαγνητική Διαμόρφωση, Εκρηκτική Συμπίεση κ.λ.π
Εφαρμοζόμενη θερμοκρασία κατεργασίας	<b>Ψυχρές Κατεργασίες:</b> Επιτελούνται κοντά στην θερμοκρασία περιβάλλοντος $T_e$
	<b>Θερμές Κατεργασίες:</b> Πραγματοποιούνται σε θερμοκρασία $T \in [T_r, T_M]$
	<b>Ημίθερμες Κατεργασίες:</b> Πραγματοποιούνται σε θερμοκρασία $T \in [T_e, T_r]$

(Όπου:  $T_M$  η θερμοκρασία τήξης και  $T_r$  η θερμοκρασία ανακρυστάλωσης-  $0,4 \mu\epsilon 0,5 * T_M$ )


Στην παρούσα διπλωματική εργασία, η έμφαση θα δοθεί αποκλειστικά στις κατεργασίες αφαίρεσης υλικού – κοπές και συγκεκριμένα στην περίπτωση της διάτρησης.

### 1.2 Κατεργασίες αφαίρεσης υλικού-κοπές

#### ΒΑΣΙΚΕΣ ΠΑΡΑΜΕΤΡΟΙ ΚΟΠΗΣ

Οι πιο σημαντικές παράμετροι κατά την διαδικασία της κοπής είναι: 1) Το κατεργαζόμενο τεμάχιο (TE), 2) το κοπτικό εργαλείο (KE) το οποίο κινείται σε

συγκεκριμένη κατεύθυνση σε σχέση με το τεμάχιο με ταχύτητα  $u$  και 3) το υλικό που αφαιρείται κατά την κοπή-το απόβλητο-και το οποίο δημιουργείται από ισχυρή πλαστική παραμόρφωση του, κινούμενο επί του κοπτικού εργαλείου[2].



Εικόνα 1.3:Βασικά χαρακτηριστικά της κοπής [2]

#### ΒΑΣΙΚΑ ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΚΟΠΤΙΚΟΥ ΕΡΓΑΛΕΙΟΥ ΚΑΙ ΑΠΟΒΛΗΤΟΥ

Το κοπτικό εργαλείο λειτουργεί ως ένα είδος σφήνας όπου κινείται ευθύγραμμα , αφαιρώντας υλικό ορισμένου πάχους από το κατεργαζόμενο τεμάχιο. Ως προς την γεωμετρία του ΚΕ, συναντάμε τις παρακάτω παραμέτρους:

- Επιφάνεια αποβλήτου: Είναι η επιφάνεια της σφήνας, πάνω στην οποία ολισθαίνει το απόβλητο κατά την κίνησή του.
- Ελεύθερη επιφάνεια: Είναι η επιφάνεια της σφήνας που αντικρίζει την κατεργασμένη επιφάνεια.
- Κόψη: Είναι η ακμή της σφήνας που προκύπτει ως τομή των δύο παραπάνω επιφανειών.
- Γωνία αποβλήτου,  $\gamma$ : Σχηματίζεται από την επιφάνεια αποβλήτου και το κάθετο επίπεδο στην κατεργασμένη επιφάνεια που διέρχεται από την κόψη του ΚΕ. Μπορεί να είναι θετική, αρνητική ή μηδενική.
- Γωνία ελευθερίας,  $\alpha$ : Σχηματίζεται από την ελεύθερη επιφάνεια του ΚΕ και την κατεργασμένη επιφάνεια.
- Γωνία σφήνας,  $\beta$ : Σχηματίζεται από την ελεύθερη επιφάνεια και από την επιφάνεια αποβλήτου.

Ισχύει :

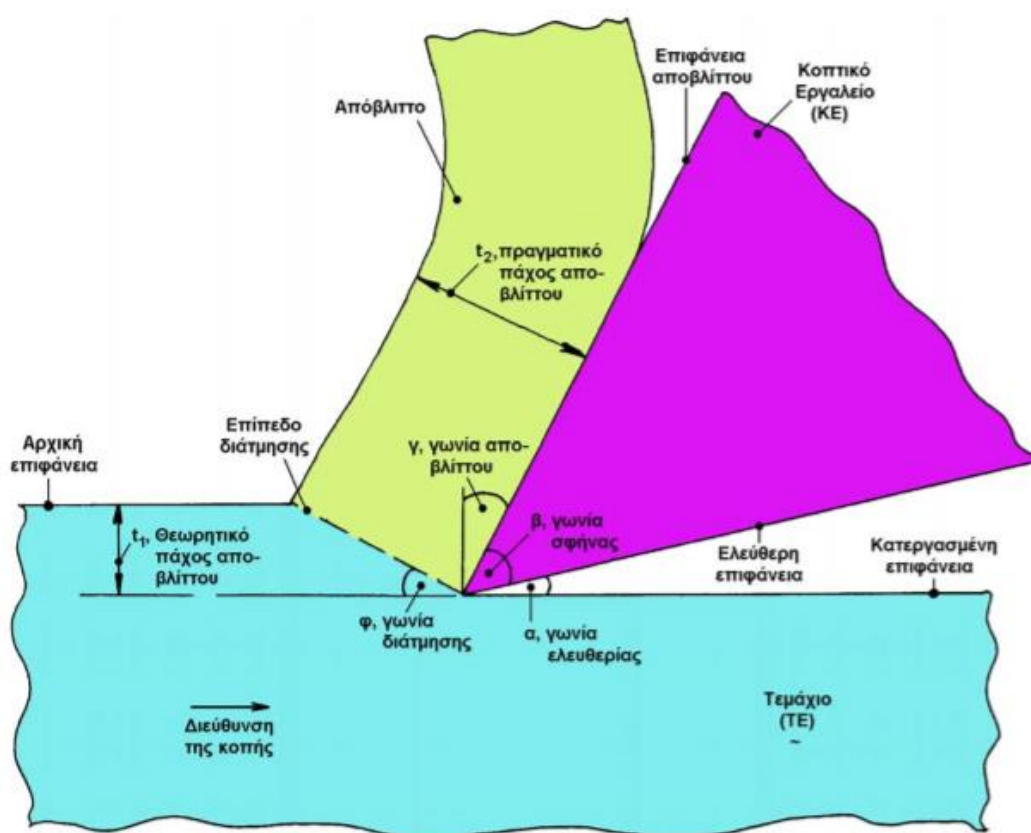
$$\alpha + \beta + \gamma = 90^\circ$$

Ανάλογα με το είδος της κατεργασίας, τα κοπτικά εργαλεία διακρίνονται σε: 1) Καθορισμένης γεωμετρίας και απλής σημειακής επαφής, όπου στην αποβολή υλικού μετέχει μία μόνο κόψη ΚΕ (π.χ. τórνευση, πλάνισμα), 2) Καθορισμένης γεωμετρίας και πολλαπλής σημειακής επαφής, όπου μετέχουν στην κοπή συγχρόνως περισσότερες από μία κόψεις του ΚΕ (π.χ. διάτρηση, φρεζάρισμα) και 3) Μη καθορισμένης γεωμετρίας, π.χ. λειαντικός τροχός.[2]

Στην περίπτωση του υλικού που αφαιρείται κατά την κοπή-απόβλητου-τα πιο σημαντικά χαρακτηριστικά, σχετίζονται με τα γεωμετρικά χαρακτηριστικά του και το πάχος του:

- Θεωρητικό πάχος αποβλίττου,  $t_1$ : Είναι το αφαιρούμενο πάχος υλικού.
- Πραγματικό πάχος αποβλίττου,  $t_2$ : Είναι η μέση τιμή του πάχους που έχει το απόβλητο μετά την κοπή.
- Πλάτος αποβλίττου,  $b$ .
- Θεωρητική διατομή αποβλίττου,  $A_1 = b \cdot t_1$
- Πραγματική διατομή αποβλίττου,  $A_2 = b \cdot t_2$

Οι προαναφερθείσες παράμετροι του κοπτικού εργαλείου και του αποβλήτου, απεικονίζονται στο παρακάτω σχήμα.



Εικόνα 1.4:Βασικές έννοιες της κοπής [2]

#### ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΤΗΣ ΚΟΠΗΣ

Οι παράμετροι κοπής είναι οι πιο σημαντικές για την διεργασία της κοπής, Συνίστανται στο ακόλουθο τρίπτυχο[2]:







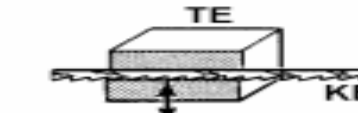


- 1) Ταχύτητα κοπής  $u$  : όπου ο λόγος γίνεται για την στιγμιαία ταχύτητα με την οποία κινείται η κόψη του κοπτικού εργαλείου κατά την πρωτεύουσα κίνηση ( m/min).
- 2) Βάθος κοπής  $a$  : Είναι το βάθος εισχώρησης του κοπτικού εργαλείου στο κατεργαζόμενο τεμάχιο κατά την διαδικασία της κοπής (mm).

- 3) Πρόωση  $s$ : Εκφράζει την σχετική μετατόπιση του κοπτικού εργαλείου ως προς το τεμάχιο ανά περιστροφή ή ενεργό διαδρομή (mm/rev).
- 4) Ταχύτητα πρόωσης  $u_v$ : Αποτελεί την στιγμιαία ταχύτητα της κόψης του κοπτικού εργαλείου ως προς το τεμάχιο και χρησιμοποιείται εναλλακτικά αντί της πρόωσης (m/min)


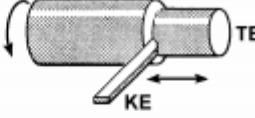
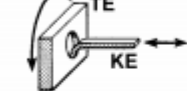
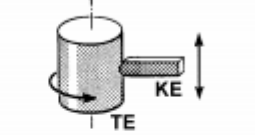

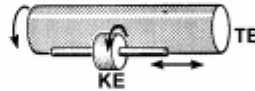

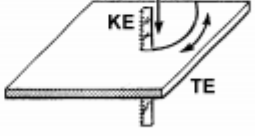
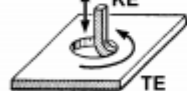
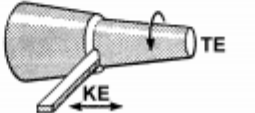

(Μεταξύ της πρόωσης και της ταχύτητας της, ισχύει η σχέση:  $u_v = s \cdot n$ . Όπου  $n$  η ταχύτητα περιστροφής της ατράκτου της εργαλειομηχανής.)

Πέραν των αναφερθέντων χαρακτηριστικών του κοπτικού εργαλείου, του αποβλήτου και της διαδικασίας της κοπής, κρίνεται απαραίτητη η επίδειξη, όλων των ειδών των συμβατικών κατεργασιών αφαίρεσης υλικού, όπως αυτές επισυνάπτονται στους ακόλουθους πίνακες, για επίπεδες και εν συνεχεία για κυλινδρικές επιφάνειες.

Εικόνα 1.5: Κατεργασίες επίπεδων επιφανειών [2]

ΚΙΝΗΣΕΙΣ	ΚΑΤΕΡΓΑΣΙΕΣ
	Τόρνευση
	Πλάνισμα
	Φρεζάρισμα
	Φρεζάρισμα
	Φρεζάρισμα
	Λείανση
	Broaching
	Πριόνισμα
	Φρεζάρισμα

Εικόνα 1.6: Κατεργασίες κυλινδρικών επιφανειών [2]

ΚΙΝΗΣΕΙΣ	ΚΑΤΕΡΓΑΣΙΑ	ΚΙΝΗΣΕΙΣ	ΚΑΤΕΡΓΑΣΙΑ
	Διάτρηση		Τόρνευση
	Boring		Τόρνευση
	Γλύφανση		Λείανση
	Λείανση		Πριόνισμα
	Boring		Τόρνευση
	Broaching		

#### ΔΥΝΑΜΕΙΣ ΚΑΤΑ ΤΗΝ ΚΟΠΗ

Κατά την διαδικασία της κοπής, αναπτύσσονται δυνάμεις τόσο μετά του αποβλήτου και του κατεργαζόμενου τεμαχίου, όσο και μεταξύ αποβλήτου και κοπτικού εργαλείου. Οι δυνάμεις εξαιτίας αυτής της αλληλεπίδρασης αποβλήτου, κοπτικού εργαλείου και τεμαχίου, είναι οι ακόλουθες[2]:


- Δυνάμεις που εμφανίζονται στο επίπεδο διάτμησης όπως η  $F_s$ , ως η αντίσταση του υλικού του ΤΕ σε διάτμηση, και η  $F_{SN}$  ως η κάθετη δύναμη στο επίπεδο διάτμησης (δηλ. κάθετη στην  $F_s$ ). Οι παραπάνω δυνάμεις συνθέτουν την συνισταμένη τους δύναμη  $F$ .
- Δυνάμεις στις επιφάνειες μεταξύ αποβλήτου και κοπτικού εργαλείου όπως η  $F_F$  ως η δύναμη τριβής στη διεπιφάνεια ΚΕ/αποβλήττου, που αντιτίθεται στην κίνηση του αποβλήτου, και η  $F_N$  ως η κάθετη δύναμη στην επιφάνεια επαφής ΚΕ/αποβλήττου (δηλ. κάθετη στην  $F_F$ ). Αναλόγως η συνισταμένη των δύο δυνάμεων είναι η  $F'$ .

Για την ισορροπία του αποβλήτου πρέπει να ισχύει:  $F = F'$ .

Οι συνισταμένες δυνάμεις αναλύονται στις:

- Δύναμη κοπής  $F_1$ .
- Δύναμη άπωσης  $F_2$ .

Οι προαναφερθείσες δυνάμεις αναπαρίστανται, στο ακόλουθο σχήμα.



Εικόνα 1.7:Κύκλος του Merchant [2]

Ο υπολογισμός των δυνάμεων και δίνεται από τις παρακάτω σχέσεις[2]:

$$F_1 = \frac{A_1 * \tau_s * \cos(\rho - \gamma)}{\sin\varphi * \cos(\varphi + \rho - \gamma)}$$

$$F_2 = \frac{A_2 * \tau_s * \sin(\rho - \gamma)}{\sin\varphi * \cos(\varphi + \rho - \gamma)}$$

όπου:

$\mu$  : ο μέσος φαινόμενος συντελεστής τριβής

$\rho = \text{atan}(\mu)$  : η μέση φαινόμενη γωνία τριβής στην επιφάνεια επαφής αποβλίττου/ΚΕ

$\tau$  : μέση διατμητική τάση

$\sigma$  : μέση ορθή τάση  $b$  το πλάτος αποβλίττου

$L$  : το μήκος επαφής αποβλίττου/ΚΕ.

$A_1 = b * t_1$ : η θεωρητική επιφάνεια αποβλίττου

$\varphi = \frac{A_1}{\sin\varphi} = \frac{b * t_1}{\sin\varphi}$  : η επιφάνεια διάτμησης

$A_F = b * L$  η επιφάνεια επαφής αποβλίττου/ΚΕ

#### ΙΣΧΥΣ ΚΑΙ ΕΝΕΡΓΕΙΑ ΚΑΤΑ ΤΗΝ ΚΟΠΗ

Η ισχύς της κοπής  $N_c$  είναι αυτή που καταναλίσκεται κατά την κοπή των μετάλλων και υπολογίζεται ως ακολούθως:

$$N_c = F_1 * v$$

Όπου:  $F_1$  η δύναμη κοπής και  $v$  η ταχύτητα κοπής.

Ως ενέργεια κοπής θεωρείται η ανηγγμμένη ενέργεια. Υπολογίζεται ως το πηλίκο της ισχύος κοπής προς τον αφαιρούμενο όγκο υλικού:

$$u = \frac{F_1 * v}{b_1 * t_1 * v} = \frac{F_1}{A_1}$$


### **1.3 Κοπτικά εργαλεία**

#### **ΦΘΟΡΑ ΚΑΙ ΑΣΤΟΧΙΑ ΚΟΠΤΙΚΟΥ ΕΡΓΑΛΕΙΟΥ**

Η συνεχής χρήση κοπτικών εργαλείων στην διαδικασία των κατεργασιών αφαίρεσης υλικού-κοπών-έχει, ως αναμένεται, με την πάροδο του χρόνου σαν αποτέλεσμα την κόπωση και κατά συν την εμφάνιση φθοράς τους. Η τελευταία οφείλεται σε παράγοντες όπως οι καταπονήσεις, οι τριβές, οι θερμοκρασίες και οι χημικές αντιδράσεις λόγω της επαφής των υλικού του κοπτικού εργαλείου με τα υλικά του τεμαχίου και του αποβλήτου. Πιο συγκεκριμένα, υψηλές τάσεις στην ζώνη επαφής κοπτικού εργαλείου και τεμαχίου, δημιουργούν πλαστική παραμόρφωση του υλικού του ΚΕ και να οδηγήσουν μέχρι και σε σχίσσιμο (αποκόλληση-θραύση) μέρους αυτού, δημιουργώντας μια νέα επιφάνεια μη συμβατή με τα αρχικά ποιοτικά χαρακτηριστικά του κοπτικού εργαλείου. Επίσης η εμφάνιση θερμοκρασιών της τάξης των 1200<sup>ο</sup>C δημιουργούν αλλοιώσεις στην γεωμετρία της κόψης του κοπτικού εργαλείου, ενώ η μεταλλική και άμεση επαφή της επιφάνειας του ΚΕ με αυτές του ΤΕ και αποβλήτου ενισχύουν τα χαρακτηριστικά φθοράς στο κοπτικό εργαλείο[2].

Με την φθορά να εμφανίζεται, τόσο στις ελεύθερες επιφάνειες, όσο και στην επιφάνεια αποβλήτου, το φαινόμενο οδηγείται προοδευτικά σε κατάσταση πλήρους αστοχίας. Σε τέτοια περίπτωση είτε θα υπάρχει αχρήστευση των κόψεων του ΚΕ, αν πρόκειται για πλακίδιο, είτε σε ολοκληρωτική αχρήστευση του ΚΕ. Οι αιτίες για την αστοχία του κοπτικού εργαλείου, ποικίλουν και εντοπίζονται κυρίως στα φαινόμενα ανάπτυξης 1) πεδίου φθοράς στην ελεύθερη επιφάνεια του ΚΕ, 2) πεδίου κρατήρα στην επιφάνεια αποβλήτου, αλλά δευτερευόντως και σε φαινόμενα όπως θραύσεις διαφόρων ειδών, απολέπιση, παραμορφώσεις και ρηγματώσεις λόγω της υψηλής θερμοκρασίας.






Εικόνα 1.8:Περιοχές εντοπισμού φθοράς στο ΚΕ: Α) φθορά κρατήρα Β) πεδίο φθοράς Γ) Εξωτερική αυλακοειδής φθορά Δ) Εσωτερική αυλακοειδής φθορά [2]

#### ΚΥΡΙΑ ΜΕΓΕΘΗ ΚΑΙ ΜΗΧΑΝΙΣΜΟΙ ΦΘΟΡΑΣ ΚΟΠΤΙΚΟΥ ΕΡΓΑΛΕΙΟΥ

Οι ακόλουθοι τύποι φθοράς κοπτικού εργαλείου, είναι αναπόφευκτοι σε κάθε κατεργασία αφαίρεσης υλικού. Ιδιαίτερα το πεδίο φθοράς είναι η πιο σημαντική αιτία από τις υπόλοιπες[2][3].


- Το πεδίο φθοράς (Πλευρική φθορά-Flank Wear) (VB) το οποίο μετατοπίζοντας την κόψη του κοπτικού εργαλείου, υποβαθμίζει τα γεωμετρικά/διαστατικά χαρακτηριστικά του τεμαχίου όσο και τα ποιοτικά του (ταχύτητα επιφάνειας).
- Η φθορά κρατήρα (Crater Wear) (KM, KT) η οποία αδυνατίζοντας την κόψη οδηγεί ταχύτερα στην θραύση μέρους υλικού από την επιφάνεια αποβλήτου του ΚΕ.




Πεδίο φθοράς

Κρατήρας


Εικόνα 1.9:Τύποι φθοράς [2]



Εικόνα 1.10:Ανάπτυξη πλευρικής φθοράς στα κοπτικά εργαλεία [3]



Εικόνα 1.11:Απεικόνιση πλευρικής φθοράς [3]



Εικόνα 1.12:Ανάπτυξη φθοράς κρατήρα στα κοπτικά εργαλεία [3]




Εικόνα 1.13:Απεικόνιση φθοράς κρατήρα [3]

Οι μηχανισμοί χάρη στους οποίους εμφανίζεται το φαινόμενο της φθοράς στο ΚΕ, οφείλονται σε αιτίες όπως:

- Σε συγκολλητούς δεσμούς και μηχανικές τριβές που οδηγούν σε απόσπαση υλικού. Αυτό συμβαίνει λόγω της δημιουργίας ψευδοκόψης. Η τελευταία στο ενδεχόμενο υπερφόρτισης, υπόκειται σε θραύση, δημιουργώντας αποκοπή υλικού από το ΚΕ αλλά και συντελώντας σε επιπλέον φθορά της κόψης.
- Σε οξείδωση, όπου το φαινόμενο εμφανίζεται λόγω των υψηλών θερμοκρασιών κατά την κοπή. Εκδηλώνεται σε όλες τις επιφάνειες του κοπτικού εργαλείου ως στρώμα συνθέτων οξειδίων, δημιουργώντας πρώτα εκσκαφές στο ΚΕ και εν συνεχεία με την αύξηση του χρόνου κοπής να οδηγήσει μέχρι και σε θραύση της κόψης.
- Σε πλαστική παραμόρφωση της ακής το κοπτικού εργαλείου, λόγω του συνδυασμού υψηλής φόρτισης και υψηλών θερμοκρασιών.
- Σε αντιδράσεις διάχυσης, όπου το φαινόμενο ευνοείται από την θερμοκρασία και την διαλυτότητα των υλικών κοπτικού εργαλείου και τεμαχίου. Εμφανίζεται με την αλληλομετακίνηση ατόμων μεταξύ ΚΕ και ΤΕ, με συνέπεια την αλλαγή της κρυσταλλικής δομής του υλικού ΚΕ και εν τέλει την προϊούσα φθορά του.[2]

Η συμβολή των βασικών μηχανισμών στη συνολική φθορά ΚΕ παρουσιάζεται στο ακόλουθο σχήμα.



Εικόνα 1.14: Συμβολή των βασικών μηχανισμών φθοράς ΚΕ [2]

#### ΔΙΑΡΚΕΙΑ ΖΩΗΣ ΚΟΠΤΙΚΟΥ ΕΡΓΑΛΕΙΟΥ

Ορίζεται ως ο χρόνος του κοπτικού εργαλείου μεταξύ δύο διαδοχικών τροχίσεων της κόψης αυτού, ή ο χρόνος για την αλλαγή κόψης (περίπτωση πλακιδίου). Μετρείται σε min και τυποποιείται σε καθορισμένες τιμές από 60 έως 480 min.

Η εκτίμηση της διάρκειας ζωής ενός κοπτικού εργαλείου, γίνεται βάση διαφόρων κριτηρίων, άμεσων όπως ο καθορισμός τιμών των πεδίων φθοράς και κρατήρα αλλά και του όγκου του αφαιρούμενου υλικού του ΚΕ, αλλά και έμμεσων όπως η στόμωση της κόψης του ΚΕ, η αύξηση της ισχύος κοπής, οι ανοχές των βασικών διαστάσεων του τεμαχίου κ.λ.π.[2]

## ΜΕΘΟΔΟΙ ΕΚΤΙΜΗΣΗΣ ΤΗΣ ΔΙΑΡΚΕΙΑΣ ΖΩΗΣ ΤΟΥ ΚΟΠΤΙΚΟΥ ΕΡΓΑΛΕΙΟΥ

Η εκτίμηση της διάρκειας ζωής του κοπτικού εργαλείου γίνεται τόσο με έμμεσες όσο και με άμεσες μεθόδους. Από τις δεύτερες οι κυριότερες είναι οι δύο σχέσεις του Taylor. Στην 1<sup>η</sup> περίπτωση έχουμε την απλή σχέση:

$$v * T^n = C$$

Όπου:  $v$  η ταχύτητα κοπής,  $T$  η διάρκεια ζωής του ΚΕ,  $n$  η κλίση της ευθείας  $\log T - \log v$  και  $C$  η σταθερά Taylor.

Η αναφερθείσα σχέση δεν λαμβάνει υπόψη τις υπόλοιπες συνθήκες κοπής και την γεωμετρία του κοπτικού εργαλείου, αλλά χρησιμοποιεί ως κριτήριο μια ελάχιστη τιμή του πλάτους του πεδίου φθοράς VB.

Ακολουθώντας στην 2<sup>η</sup> περίπτωση, έχουμε την γενικευμένη σχέση[4]:

$$T = \frac{C}{v^{1/\alpha} * s^{1/\beta} * a^{1/\gamma}}$$

Στην συγκεκριμένη σχέση, παρατηρείται ότι λαμβάνονται υπόψη και οι τρεις κύριες συνθήκες κοπής, ταχύτητα, πρόωση και βάθος, ενώ τα μεγέθη  $C, \alpha, \beta, \gamma$  είναι σταθερές.

Οι σχέσεις του ενδείκνυνται για περιπτώσεις, όπου το υλικό του κοπτικού εργαλείου είναι ταχυχάλυβας, σκληρομέταλλο ή κεραμικό υλικό.

Ωστόσο για την περίπτωση κοπτικού εργαλείου με υλικό CBN (Κυβικός Βοριονιτρίτης) έχει αναπτυχθεί η σχέση Kundrak όπως και παρατίθεται ακολούθως[4]:

$$T = \frac{C_{T_1}}{v_c^3 + C_{T_2} * v_c^2 + C_{T_3} * v_c}$$


Όπου:  $T$  η διάρκεια ζωής του ΚΕ,  $v_c$  η ταχύτητα κοπής και  $C_{T_1}, C_{T_2}, C_{T_3}$  σταθερές εξαρτώμενες από τις συνθήκες κοπής.

### 1.4 Η Διάτρηση (Drilling)

#### ΟΡΙΣΜΟΣ

Είναι κατεργασία αφαίρεσης υλικού η οποία πραγματοποιείται με την διάνοιξη οπής ή με την διεύρυνση ήδη υπάρχουσας. Γι' αυτό το σκοπό, το ΚΕ που χρησιμοποιείται είναι το *ελικοειδές τρυπάνι*, με κατάλληλα ενσωματωμένο σε ΕΜ η οποία καλείται *δράπανο*. Τα ΚΕ πραγματοποιεί δύο καίριες κινήσεις κατά την λειτουργία της ΕΜ και οι οποίες παρατίθεται στο ακόλουθο σχήμα: 1) την πρωτεύουσα κίνηση (-C) που αντιστοιχεί στην περιστροφική κίνηση του ΚΕ περί τον κατακόρυφο άξονά του και 2) δευτερεύουσα κίνηση (-Z) που

αντιστοιχεί στη συνεχή αξονική κίνηση πρόωσης του ΚΕ μέσα στο κατεργαζόμενο τεμάχιο (ΤΕ) [2].



Εικόνα 1.15:Χαρακτηριστικά της διάτρησης [2]

#### ΕΙΔΗ ΔΡΑΠΑΝΩΝ

Α. Ανάλογα με το βάρος τους:

- Ελαφριά
- Μεσαία
- Βαρέως τύπου

Β. Ανάλογα με το μέγεθός τους:

- Μικρά
- Μεσαία
- Μεγάλα

Γ. Ανάλογα με την διάταξη της κύριας ατράκτου:

- Κατακόρυφα
- Οριζόντια

Δ. Ανάλογα με τον αριθμό των ατράκτων που λειτουργούν ταυτόχρονα:

- Μονοάτρακτα
- Πολυάτρακτα
- Ακτινωτά


Ε. Ανάλογα με τον τρόπο κίνησης της ατράκτου:

- Χειροκίνητα
- Μηχανοκίνητα
- Αεριοκίνητα

#### ΔΡΑΠΑΝΟ ΣΤΗΛΗΣ

Το δράπανο στήλης αποτελεί, το πλέον συνήθη είδος ΕΜ διάτρησης. Τα κύρια δομικά του στοιχεία είναι:

- *Η βάση* η οποία πρέπει να είναι απόλυτα ευθυγραμμισμένη σε κατάλληλη θεμελίωση.
- *Ο ορθοστάτης*, ορθογωνικής ή κυλινδρικής μορφής, ο οποίος φέρει ολισθητήρες για τη μετακίνηση της κινητής κεφαλής και της τράπεζας.
- *Η Τράπεζα*, η οποία φέρει αύλακες μορφής T για τη συγκράτηση του ΤΕ και αναλόγως τον τύπο του ορθοστάτη μπορεί πέρα από την κατακόρυφη κίνηση να εκτελεί και περιστροφική περί τον άξονα του ορθοστάτη.
- *Η Σταθερή Κεφαλή*, στην οποία βρίσκεται το κιβώτιο ταχυτήτων ή διάταξη βαθμιδωτής μαντοκίνησης, για την αύξηση του πλήθους ταχυτήτων περιστροφής.
- *Η Κύρια Άτρακτος*, με τον οποία εξασφαλίζεται η κύρια κίνηση για τη διάτρηση.
- *Η Κινητή Κεφαλή*, που περιέχει το κιβώτιο πρόωσης που παρέχει την κίνηση πρόωσης με τη μορφή αξονικής μετατόπισης της ατράκτου. Ο μηχανισμός πρόωσης μπορεί να λειτουργεί χειροκίνητα ή μηχανοκίνητα[2].



Εικόνα 1.16: Δράπανο στήλης [2]

#### ΚΟΠΤΙΚΟ ΕΡΓΑΛΕΙΟ ΤΗΣ ΔΙΑΤΡΗΣΗΣ (ΕΛΙΚΟΕΙΔΕΣ ΤΡΥΠΑΝΙ)


Το τρυπάνι αποτελείται από το στέλεχος (κωνικό ή κυλινδρικό) που συμβάλλει στη συγκράτησή του στην άτρακτο και το κοπτικό μέρος με τα εξής χαρακτηριστικά:

- Φέρει δύο τουλάχιστον κύριες κόψεις. Κάθε κύρια κόψη λειτουργεί ως πλήρες και κανονικό ΚΕ.
- Η κόψη κορυφής ή εγκάρσια κόψη απλώς παραμορφώνει πλαστικά το υλικό ΤΕ ωθώντας το προς τις κόψεις.
- Οι δευτερεύουσες κόψεις συμμετέχουν μερικώς στην αποπεράτωση της κοπής.
- Οι ελικοειδείς αύλακες χρησιμεύουν στην απόδοση ενδεδειγμένης γεωμετρίας στις κόψεις, στη διαμόρφωση των οδηγητικών λωρίδων, στη βοστρυχοποίηση (κατσάρωμα) και απομάκρυνση του αποβλίττου και στη διευκόλυνση πρόσβασης του υγρού κοπής μέχρι τις κύριες κόψεις.
- Οι οδηγητικές λωρίδες (πτερύγια) εξασφαλίζουν την ασφαλή στήριξη και οδήγηση του τρυπανιού και την ελάττωση της τριβής στην επιφάνεια επαφής ΚΕ/ΤΕ.[2]

Επιπλέον το ΚΕ της διάτρησης, χαρακτηρίζεται και από τα παρακάτω γεωμετρικά χαρακτηριστικά:

- Γωνία κορυφής  $\omega$  (point angle), η οποία επιτρέπει την προοδευτική διείδυση του ΚΕ.

- Γωνία έλικας αυλακών  $\sigma$  (helix angle), η οποία βαίνει ελαττούμενη από την περιφέρεια προς το κέντρο του τρυπανιού.
- Γωνία αποβλίττου  $\gamma$ , η οποία βαίνει ελαττούμενη από την περιφέρεια προς το κέντρο του τρυπανιού.
- Γωνία ελευθερίας  $\alpha$ , η οποία βαίνει αυξανόμενη από την περιφέρεια προς το κέντρο του ΚΕ.
- Γωνία σφήνας  $\beta$ , η οποία λαμβάνει μικρές τιμές για διάτρηση μαλακών υλικών και μεγάλες τιμές για διάτρηση σκληρών υλικών.
- Γωνία κόψης κορυφής  $\psi$  (chisel angle). Είναι η γωνία που σχηματίζει η εγκάρσια κόψη με τις κύριες κόψεις.



Εικόνα 1.17:Ελικοειδές τρυπάνι[2]

#### ΥΛΙΚΑ ΤΟΥ ΚΕ ΤΗΣ ΔΙΑΤΡΗΣΗΣ

- Ανθρακούχος χάλυβας, βολφραμιούχος ή χρωμιούχος χάλυβας (τρυπάνια κατώτερης ποιότητας).
- Ταχυχάλυβας (ανώτερης ποιότητας τρυπάνια).
- Κόψεις από πλακίδια σκληρομετάλλου που επικολλούνται ή στερεώνονται μηχανικά (όταν απαιτείται μεγάλος ρυθμός παραγωγής και μακρά ΔΖ του ΚΕ).

#### ΣΥΝΘΗΚΕΣ ΚΟΠΗΣ

- Ταχύτητα κοπής  $v$  (m/min): 
$$v = \frac{\pi \cdot D \cdot n}{1000}$$
- Πρόωση  $s$  (mm/rev)



- Πρόωση ανά κόψη  $s_z$  (mm/κόψη):  $S_z = \frac{S}{z}$  όπου  $z$  ο αριθμός κόψεων του τρυπανιού

- Ταχύτητα πρόωσης  $u_v$  (mm/ min):  $u_v = S * n$

- Βάθος κοπής,  $a$  (mm):

I) Πλήρης διάτρηση:  $a = \frac{D}{2}$


II) Διεύρυνση οπής διαμέτρου  $d$ :  $a = \frac{D-d}{2}$

- Θεωρητικό πάχος αποβλίττου ανά κόψη,  $h_z$  (mm):

- Θεωρητική διατομή αποβλίττου,  $A$  (mm<sup>2</sup>):

I) Πλήρης διάτρηση:  $a = \frac{D * S_z}{2}$

II) Διεύρυνση οπής διαμέτρου  $d$ :  $a = \frac{(D-d) * S_z}{2}$



Εικόνα 1.18: Σχηματισμός αποβλήτου [2]

#### ΑΝΑΠΤΥΣΣΟΜΕΝΕΣ ΔΥΝΑΜΕΙΣ, ΡΟΠΕΣ ΚΑΙ ΙΣΧΥΣ ΚΟΠΗΣ

Η συνολική δύναμη κοπής  $F$  αναλύεται στις ακόλουθες συνιστώσες [2]:

- $F_K$  ή  $F_{Hz}$ : Δύναμη κοπής η οποία ασκείται στις κύριες κόψεις
- $F_{EK}$ : Δύναμη η οποία ασκείται στην εγκάρσια κόψη
- $F_{\Lambda}$ : Δύναμη τριβής, η οποία ασκείται στα πτερύγια

### I) Πλήρης Διάτρηση

$$A) \text{ Δύναμη κοπής (daN): } F_{Hz} = \frac{K_K * K_{\varphi} * k_1 * D * (s_z * \sin(\frac{\omega}{2}))^{(1-z)}}{2 * \sin(\frac{\omega}{2})}$$

Όπου :

$k_1$  και  $\zeta$  οι σταθερές Kienzle.

$K_K=1.0$  για πλήρη διάτρηση ή  $K_K=0.95$  για διεύρυνση οπής.

$K_{\varphi}=1.25 \div 1.40$  (η μικρότερη τιμή ισχύει για κοπή χυτοσιδήρου και η μεγαλύτερη για κοπή χάλυβα).

$$B) \text{ Ροπή Στρέψης (daN.cm): } M_d = \frac{1}{10} * F_{Hz} * \frac{D}{2}$$


$$Γ) \text{ Ισχύς κοπής (kW): } P_c = \frac{M_d * n}{97410}$$

### II) Διεύρυνση οπής

$$A) \text{ Δύναμη κοπής (daN): } F_{Hz} = \frac{K_K * K_{\varphi} * k_1 * (D-d) * (s_z * \sin(\frac{\omega}{2}))^{(1-z)}}{2 * \sin(\frac{\omega}{2})}$$

$$B) \text{ Ροπή Στρέψης (daN.cm): } M_d = \frac{1}{10} * F_{Hz} * \frac{D+d}{2}$$

Ισχύς κοπής (kW): Όπως και στην Α περίπτωση



Εικόνα 1.19: Δυνάμεις κοπής κατά την διάτρηση [2]

#### ΧΡΟΝΟΣ ΚΑΤΕΡΓΑΣΙΑΣ ΔΙΑΤΡΗΣΗΣ

Υπολογίζεται από τη σχέση:  $t_c = i * \frac{L}{s * n}$  (min) με:  $L = l + l_a + l_u$  (mm)

Όπου:

$i$ : ο αριθμός ενεργών διαδρομών (πάσων)

$l$ : (mm) το βάθος της οπής

$l_a = 1 + \frac{D}{2 * \tan(\frac{\omega}{2})}$  (mm) για πλήρη διάτρηση

$l_a = 1 + \frac{D-d}{2 * \tan(\frac{\omega}{2})}$  (mm) για διεύρυνση οπής

$l_u = 2$  mm για διαμπερείς οπές ή

$l_u = 0$  mm για τυφλές οπές.

## Κεφάλαιο 2

### ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

#### 2.1 Εισαγωγή

Στην βιομηχανική παραγωγική διαδικασία, οι κατεργασίες αφαίρεσης υλικού επιτελούν ιδιαίτερα σημαντικό ρόλο, όπου ο αντικειμενικός σκοπός είναι η παραγωγή εξαρτημάτων και γενικότερα προϊόντων με τον βέλτιστο συνδυασμό ποιοτικών χαρακτηριστικών και κόστους παραγωγής. Προκειμένου να επιτευχθεί τόσο η βέλτιστη ποιότητα ενός προϊόντος όσο και η όποια εφικτή ελαχιστοποίηση του κόστους παραγωγής αυτού, είναι απαραίτητος ο προσδιορισμός των ιδανικών παραμέτρων κοπής ώστε ανάλογα τους είδους της κατεργασίας-Τόρνευση, Φρεζάρισμα, Διάτρηση, Λείανση, κλπ-να επιτυγχάνεται το επιθυμητό αποτέλεσμα, ως προς το κατεργαζόμενο αντικείμενο, τόσο από θέμα προδιαγραφών όσο και από πλευράς κόστους παραγωγής αλλά και αύξησης της παραγωγικότητας. Για τον προσδιορισμό των βέλτιστων συνθηκών κοπής-ταχύτητα κοπής, στροφές ατράκτου εργαλειομηχανής, πρόωσης, κ.λ.π-σε κάθε περίπτωση κατεργασίας και ανάλογα με το κατεργαζόμενο αντικείμενο, τις προηγούμενες δεκαετίες χρησιμοποιήθηκαν τόσο μαθηματικές όσο και στατιστικές τεχνικές μοντελοποίησης. Σε ύστερη χρονικά κατάσταση, αναπτύχθηκαν νεότερα μαθηματικά μοντέλα, με ένα από αυτά να αναγνωρίζεται ως το Τεχνητό Νευρωνικό Δίκτυο (Artificial Neural Network) που αποτελεί και το αντικείμενο της παρούσας εργασίας.

#### 2.2 Ιστορική αναδρομή και εφαρμογές

Οι πρώτες απόπειρες χρησιμοποίησης των νευρωνικών δικτύων χρονολογούνται μέχρι και στα τέλη του πρώτου μισού του 20<sup>ου</sup> αιώνα, αλλά η συστηματική τους εφαρμογή εντοπίζεται στις τρεις τελευταίες δεκαετίες όταν καθίσταται δυνατή η ανάπτυξη των ηλεκτρονικών υπολογιστών και των κατάλληλης υπολογιστικής ισχύς προγραμμάτων.

Οι πρώτες προσπάθειες εφαρμογής των τεχνητού νευρωνικού δικτύου προσδιορίζεται περί το 1943 αλλά και το 1947 από τους από τους McCulloch και Pitts με αντικείμενο την παρουσίαση των χαρακτηριστικών (νευρώνες, διασυνδέσεις) και του τρόπου λειτουργίας, ενός τέτοιου υπολογιστικού μοντέλου. Συγκεκριμένα γινόταν επίδειξη του τρόπου του νευρώνα και των απολήξεων του, ως ένας πιθανός μηχανισμός μνήμης μέσω της δημιουργίας μηχανισμού ανάδρασης (feedback). Η συνέχεια δόθηκε τόσο στο τέλος της δεκαετίας του 40' όσο και στην επόμενη, όπου οι Neumann, Hebb, Widrow και Hoff, με βάση τα νευρωνικά δίκτυα προχώρησαν στην ανάπτυξη υπολογιστικών μοντέλων όπως το Perceptron, το Adaline και το Madaline. Ιδιαίτερως τα δύο τελευταία χρησιμοποιήθηκαν με επιτυχία, ως φίλτρα στην εξάλειψη της ηχούς σε τηλεφωνικές γραμμές. Όμως η συστηματική ανάπτυξη των νευρωνικών δικτύων κατέστη δυνατή από την δεκαετία του 80 και έπειτα, με τον Hopfield το 1982 και τους McClelland και Rumelhart το 1986, να αναδεικνύουν μέσω των εργασιών τους τον ρόλο των νευρωνικών δικτύων στην αποθήκευση,

ανάκτηση και επεξεργασία δεδομένων. Από τα μέσα της δεκαετίας του 80 και έπειτα, η μελέτη των νευρωνικών δικτύων γίνεται αντικείμενο επιστημονικών συνεδριάσεων από οργανισμούς όπως π.χ American Physical Society.[7]

Η δυνατότητα μεγάλης υπολογιστικής ταχύτητας ιδιαίτερα αν το νευρωνικό δίκτυο υλοποιηθεί σε hardware, επίλυσης μη γραμμικών προβλημάτων, αλλά και η ικανότητα ανάκτησης πληροφοριών και εξαγωγής αξιόπιστων αποτελεσμάτων ανά εφαρμογή, κατέστησε δημοφιλή την χρήση των νευρωνικών δικτύων, σε μια σειρά εφαρμογών μερικοί από του οποίους παρατίθενται ακολούθως[7]:

- Βιομηχανία για θέματα manufacturing, ρομποτικής, έλεγχος ποιότητας, εφαρμογές σε οχήματα και Μ.Ε.Κ κ.λ.π
- Ιατρική για ζητήματα έγκαιρης διάγνωσης ασθενειών αλλά και ζητήματα εφαρμογής θεραπευτικών αγωγών
- Τηλεπικοινωνίες και επεξεργασία σημάτων όπως η χρήση τους ως φίλτρα για την ελαχιστοποίηση του θορύβου στις τηλεφωνικές γραμμές αλλά και η μοντελοποίηση ενός σήματος
- Οικονομικά θέματα όπως η αξιολόγηση, η πρόβλεψη και ο έλεγχος οικονομικών μεγεθών και διαδικασιών όπως π.χ δάνεια, μετοχές, επενδύσεις, ηλεκτρονικές συναλλαγές, δείκτες του Χρηματιστηρίου κ.α
- Μετεωρολογία όπως η πρόγνωση και η ανάλυση καιρικών συνθηκών
- Αεροδιαστημική όπως ο έλεγχος και η πρόγνωση/ανίχνευση βλαβών σε αεροσκάφος

## 2.3 Αρχή λειτουργίας νευρωνικού δικτύου

### ΒΙΟΛΟΓΙΚΟ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ

Τα τεχνητά νευρωνικά δεν αποτελούν παρά μια προσομοίωση των αντίστοιχων βιολογικών, οπότε η περιγραφή των τελευταίων αποτελεί αναγκαία συνθήκη για την κατανόηση του πως λειτουργούν εν γένει τα νευρωνικά δίκτυα. Το κύριο δομικό στοιχείο τους αποτελεί ο νευρώνας, ένας εξειδικευμένος τύπος κυττάρου και ο οποίος λειτουργεί ο μια μονάδα συστήματος επεξεργασίας πληροφοριών. Ενδεικτικά ο εγκέφαλος ενός νεογέννητου ανθρώπου αποτελείται από 100 δισεκατομμύρια νευρώνες, όπου ο καθένας συνδέεται με άλλους 1000 νευρώνες ταυτόχρονα.

Πιο αναλυτικά ο νευρώνας αποτελείται από:

- I. Το σώμα (body) που είναι ο πυρήνας του.
- II. Τους δεντρίτες οι οποίοι λειτουργούν ως οι πύλες εισόδου του νευρώνα, καθώς δέχονται σήματα από άλλους νευρώνες.
- III. Τον άξονα που λειτουργεί ως η πύλη εξόδου του νευρώνα στέλνοντας σήματα σε άλλους νευρώνες.
- IV. Την συνάψεις οι οποίες αποτελούν τα σημεία επαφής του άξονα του νευρώνα με τους δεντρίτες άλλων νευρώνων. Οι συνάψεις κατατάσσονται σε δύο είδη, τις ενισχυτικές και τις ανασταλτικές. Οπότε ανάλογα με το είδος της σύναψης, ο νευρώνας είτε θα παράγει το

ανάλογο σήμα είτε θα αποκλείει οποιαδήποτε πιθανότητα μετάδοσης πληροφορίας/σήματος.

Ανάλογα με το ποσοστό του σήματος που μεταδίδεται από την σύναψη σε ένα δεντρίτη, καθορίζεται και το συναπτικό βάρος. Η ένταση της συμμετοχής μιας σύναψης σε ένα συνολικό φορτίο καθορίζει και το ποσοστό του επιμέρους συναπτικού φορτίου κάθε σύναψης. Εάν αυτό το συνολικό συναπτικό φορτίο ξεπεράσει μια συγκεκριμένη κατάσταση ενέργειας (κατώφλι), αναγκάζει τον νευρώνα να παράξει παλμούς σε υψηλή συχνότητα μεταδίδοντας το ανάλογο σήμα σε άλλον νευρώνα. Σε μια τέτοια περίπτωση χαρακτηριστικά λέγεται ότι ο νευρώνας πυροβολεί. Σε αντίθετη περίπτωση εάν το ενεργειακό κατώφλι δεν καταβληθεί, τότε ο νευρώνας παράγει πολύ αραιά παλμούς οπότε λέγεται ότι ο νευρώνας μένει αδρανής.

Ο τρόπος απεικόνισης ενός νευρώνα και των επιμέρους στοιχείων του, παρατίθεται στο ακόλουθο σχήμα:



**Εικόνα 2.1:Βιολογικός νευρώνας [7]**

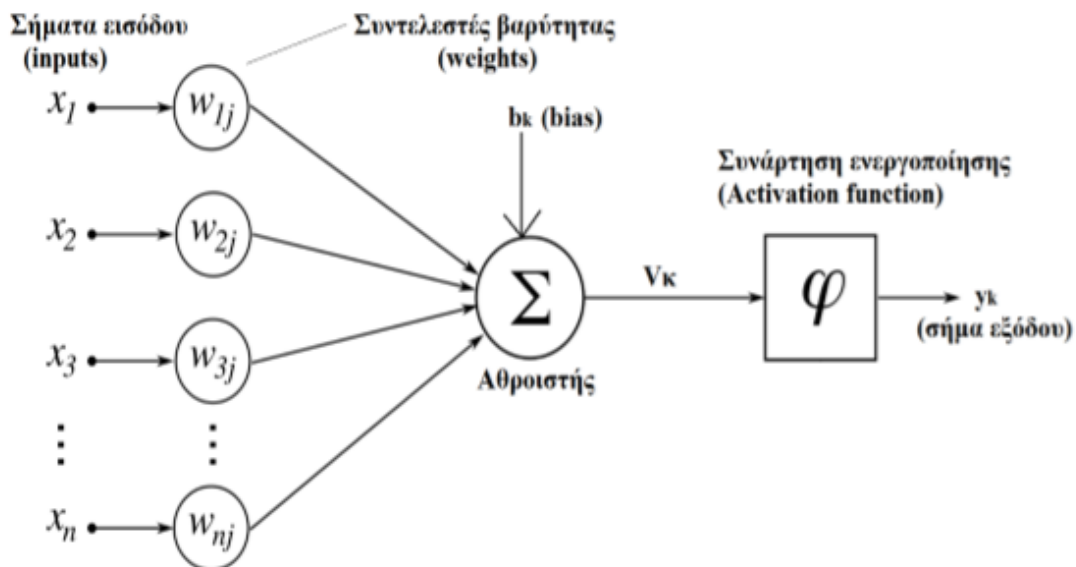
## ΤΕΧΝΗΤΟ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ

Κατά αναλογία με το βιολογικό δίκτυο, το τεχνητό νευρωνικό δίκτυο ακολουθεί πλειοψηφικά τις ίδιες αρχές λειτουργίας. Αποτελείται εξίσου από[6]:

- I. Τον τεχνητό νευρώνα που αποτελεί το κύριο στοιχείο του δικτύου.
- II. Το πλήθος των συνάψεων (συνδετικών στοιχείων με άλλους νευρώνες), οι οποίες χαρακτηρίζονται κάθε μια, από ένα συγκεκριμένο συντελεστή βαρύτητας. Η πληροφορία που μεταφέρεται από κάθε σύναψη στον νευρώνα, πολλαπλασιάζεται με έναν συντελεστή βαρύτητας, ο οποίος μπορεί να παίρνει θετικές ή αρνητικές τιμές.

- III. Τον αθροιστή όπου το σύνολο των πληροφοριών από της συνάψεις, αφού έχει πολλαπλασιαστεί με τους επιμέρους συντελεστές βαρύτητας, προστίθεται δίνοντας την τελική ολοκληρωμένη πληροφορία. Στην άθροιση περιλαμβάνεται και μια παράμετρος η οποία ονομάζεται bias. Η συγκεκριμένη παράμετρος, ως ένας εξωτερικά εφαρμοζόμενος παράγοντας, αποτελεί το κατώφλι και λειτουργεί ως μια επιπλέον σύναψη με συναπτικό βάρος ίσο προς την τιμή του και πάγια τιμή εισόδου ίση προς τη μονάδα.
- IV. Την συνάρτηση ενεργοποίησης η οποία συμβάλει στο τελικό σήμα εξόδου από τον νευρώνα, λειτουργώντας ως μη γραμμικός μετασχηματιστής, περιορίζοντας το εύρος (πλάτος) της πληροφορίας (σήματος) που έρχεται από τον αθροιστή. Είθισται το κανονικοποιημένο εύρος τιμών, να είναι το μοναδιαίο κλειστό διάστημα  $[0,1]$  ή  $[-1,1]$ .

Η γραφική απεικόνιση του νευρώνα, ενός τεχνικού νευρωνικού δικτύου, παρουσιάζεται ακολούθως:



Εικόνα 2.2:Τεχνητός νευρώνας [6]

## ΜΑΘΗΜΑΤΙΚΗ ΜΟΝΤΕΛΟΠΟΙΗΣΗ ΤΕΧΝΗΤΟΥ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ

Από την αναφερθείσα αρχή λειτουργίας του τεχνητού νευρωνικού δικτύου είναι απαραίτητη, η παρουσίαση των μαθηματικών σχέσεων που διέπουν το εν λόγω μοντέλο.

### Συμβολισμοί

Νευρώνας:  $k$

Συνάψεις του νευρώνα  $k$ :  $j$

Σήμα (μεταφερόμενο από σύναψη):  $x_j$

Συντελεστής βαρύτητας:  $w_{kj}$

Συνάρτηση ενεργοποίησης νευρώνα  $k$ :  $\varphi(v_k)$

Σήμα εξόδου του νευρώνα:  $y_k$

Μαθηματικές σχέσεις[6]

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


$$v_k = u_k + b_k$$

$$y_k = \varphi(v_k)$$


#### ΣΥΝΑΡΤΗΣΕΙΣ ΕΝΕΡΓΟΠΟΙΗΣΗΣ ΝΕΥΡΩΝΑ

Η συνάρτηση ενεργοποίησης,  $\varphi(v_k)$ , ορίζει την έξοδο του νευρώνα, βάση ενός τοπικού πεδίου  $v$ . Τα κυριότερα είδη είναι τα ακόλουθα:


- 1) Βηματική συνάρτηση (0,1) (step function)



- 2) Βηματική συνάρτηση (-1,1) (spg function)




- 3) Γραμμική συνάρτηση (-1,1)



- 4) Σιγμοειδής συνάρτηση (0,1) (sigmoid)



Αποτελεί την επικρατέστερη μορφή συνάρτησης ενεργοποίησης που χρησιμοποιείται για τα νευρωνικά δίκτυα. Είναι αύξουσα συνάρτηση με εύρος τιμών 0 έως 1 και είναι διαφορήσιμη.



Εικόνα 2.3:Είδη συναρτήσεων ενεργοποίησης MLP[7]

## 2.4 Πλεονεκτήματα νευρωνικών δικτύων

Όπως αναφέρθηκε σε προηγούμενη ενότητα, ένα από τα κύριο χαρακτηριστικά των MLP είναι η μεγάλη τους υπολογιστική ικανότητα/ισχύ, συνέπεια της παράλληλης δομής τους. Επιπρόσθετα μια επιπλέον ιδιότητα τους, αποτελεί η δυνατότητα να εκπαιδεύονται και να γενικεύουν. Στην περίπτωση της γενίκευσης, ο λόγος γίνεται για την δυνατότητα να παράγονται ρεαλιστικά αποτελέσματα από δεδομένα που δεν χρησιμοποιήθηκαν κατά την εκπαίδευση ενός MLP. Με βάση τις αναφερθείσες ιδιότητες, παρουσιάζονται ορισμένα από τα κυριότερα πλεονεκτήματα των νευρωνικών δικτύων[7]:

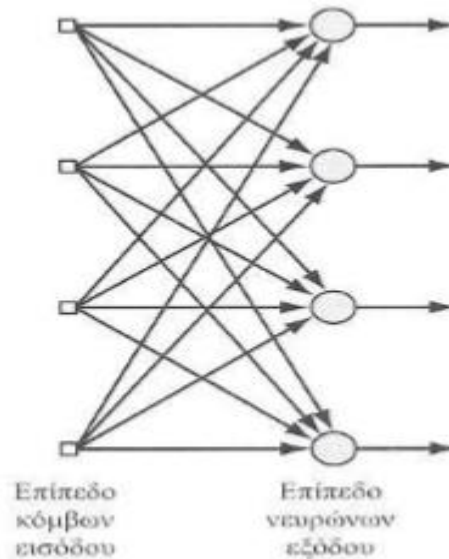
- **Μη γραμμικότητα.**  
Ένα νευρωνικό δίκτυο μπορεί να αποτελείται από νευρώνες οι οποίοι μπορεί να είναι γραμμικοί ή μη γραμμικοί. Το εν λόγω χαρακτηριστικό είναι αρκετά σημαντικό αν το πρόβλημα στο οποίο ζητείται η εφαρμογή ενός MLP είναι μη γραμμικό π.χ η ανθρώπινη ομιλία.
- **Αναλογικότητα εισόδου-εξόδου.**  
Όπως αναφέρθηκε στην ενότητα της αρχής λειτουργίας των MLP, αλλά και αργότερα στην ενότητα της εκπαίδευσης, η τελευταία στα νευρωνικά δίκτυα κατά ένα ενδεχόμενο πραγματοποιείται μέσω ενός αριθμού παραδειγμάτων εισόδου-εξόδου. Η χρησιμότητα ενός MLP έγκειται στο ότι μπορεί να τροποποιεί τα συναπτικά βάρη των νευρώνων, μέχρι που το παραγόμενο αποτέλεσμα να προσεγγίζει όσο το δυνατό καλύτερα το επιθυμητό. Ουσιαστικά αποτελεί ένα εξαιρετικό μαθηματικό μοντέλο αντιπροσώπευσης των πραγματικών διανυσμάτων εξόδου ενός προβλήματος, σε σχέση με τα δεδομένα εισόδου που λαμβάνει.
- **Παράλληλος τρόπος λειτουργίας**  
Ένα MLP αποτελείται από πολλούς επιμέρους νευρώνες, στους οποίους μια ενδεχόμενη εργασία κατανέμεται ομοιόμορφα. Οπότε όταν τίθεται η επίλυση ενός προβλήματος, οι νευρώνες λειτουργούν ταυτόχρονα (παράλληλα). Αυτό προσδίδει στο δίκτυο μεγάλη υπολογιστική ικανότητα/ισχύ όπως και ελαχιστοποίηση του ανάλογου χρόνου.

- **Προσαρμοστικότητα**  
Οι μεταβολές που μπορούν να υπάρξουν σε ένα υπολογιστικό περιβάλλον στο οποίο εφαρμόζεται ένα νευρωνικό δίκτυο, αποτελούν και λόγο τροποποίησης των συναπτικών βαρών του τελευταίου. Αυτό αποδεικνύει την μεγάλη ευελιξία των MLP, στο να επανεκπαιδεύονται σε τυχόν αλλαγές του προβλήματος στο οποίο εργάζονται.
- **Ανοχή σε βλάβες (Fault – tolerant)**  
Τα νευρωνικά δίκτυα έχουν την δυνατότητα σε περίπτωση βλαβών αριθμού νευρώνων να μην εμφανίζουν καθολική αστοχία στο διάνυσμα εξόδου. Επειδή η πληροφορία από τα δεδομένα εισόδου είναι καταναμημένη σε όλο το σύνολο των νευρώνων, σε περίπτωση βλάβης κάποιων νευρώνων δε προκαλείται ολική απόκλιση του διανύσματος εξόδου από το επιθυμητό, αλλά αυτό μειώνεται ως προς την αξιοπιστία του βαθμιαία αναλόγως της έκτασης της βλάβης.
- **Δυνατότητα θεώρησης τους ως καταναμημένη μνήμη (distributed memory) και ως μνήμη συσχέτισης (associative memory)**  
Τα νευρωνικά δίκτυα όταν λαμβάνουν τα εκάστοτε δεδομένα εισόδου, επεξεργάζονται την ανάλογη πληροφορία και δημιουργούν τον ανάλογο κώδικά ως ένα σύνολο. Οπότε η κωδικοποίηση κατανέμεται σε όλο το σύνολο των νευρώνων. Επιπλέον ενδεχόμενη ανάκληση της πληροφορίας εισόδου γίνεται με βάση το περιεχόμενο της και όχι την προέλευση της. Το τελευταίο χαρακτηριστικό είναι αυτό που δίνει την δυνατότητα στα νευρωνικά δίκτυα να είναι ανθεκτικά σε τυχόν μικρές αλλαγές των δεδομένων εισόδου, παράγοντας αποτελέσματα πολύ κοντά στα επιθυμητά. Η αναφερόμενη δυνατότητα αποτελεί και κατ'έπекτασιν την ιδιότητα της γενίκευσης των MLP, που θα αναλυθεί σε ύστερη παράγραφο.

## 2.5 Κατηγορίες νευρωνικών δικτύων

Η μορφή ενός νευρωνικού δικτύου καθορίζεται από τον τρόπο διάταξης των νευρώνων τον αριθμό και τον τύπο τους. Ένα νευρωνικό δίκτυο αποτελείται από επίπεδα, όπου το καθένα περιέχει ένα συγκεκριμένο αριθμό νευρώνων, ο οποίος εξαρτάται από την εκπαίδευση του νευρωνικού δικτύου, προκειμένου το τελευταίο να εμφανίζει τα καλύτερα δυνατά αποτελέσματα στην εκάστοτε εφαρμογή. Τα κυριότερα είδη είναι:


- Δίκτυα πρόσθιας τροφοδότησης ενός επιπέδου (feedforward):  
Αποτελούν τον απλούστερο είδος νευρωνικού δικτύου, με ένα επίπεδο εισόδου και ένα επίπεδο εξόδου (εξού και ο χαρακτηρισμός «ενός επιπέδου»). Στην συγκεκριμένη περίπτωση οι νευρώνες εισόδου, δεν έχουν κάποιο υπολογιστικό ρόλο, αλλά μεταφέρουν μόνο την πληροφορία στον νευρώνα ή νευρώνες εξόδου και όχι το αντίστροφο. Απεικόνιση τέτοιου δικτύου αποτελεί η ακόλουθη.



Εικόνα 2.4: Δίκτυο πρόσθιας τροφοδότησης ενός επιπέδου [7]

- Δίκτυα πρόσθιας τροφοδότησης πολλών επιπέδων:


Σε αυτού του είδους τα δίκτυα, υφίστανται ένα ή και περισσότερα ενδιάμεσα επίπεδα. Αυτά τα επίπεδα χαρακτηρίζονται «κρυφά» όπως και οι νευρώνες τους οποίους περιέχουν τα εν λόγω επίπεδα. Η διαφοροποίηση σε σχέση με του «ενός επιπέδου», έγκειται στο ότι οι νευρώνες τόσο των κρυφών όσο και του επιπέδου εξόδου, επιτελούν υπολογιστικό ρόλο. Ένα δίκτυο που χαρακτηρίζεται π.χ ως 3-6-1 σημαίνει ότι αποτελεί MLP με επίπεδο εισόδου τριών δεδομένων, ένα κρυφό επίπεδο 6 νευρώνων και το επίπεδο εξόδου 1 ζητούμενης παραμέτρου, ενώ αν ανάλογα έχουμε δίκτυο π.χ 4-8-5-2 τότε μιλάμε για MLP με επίπεδο εισόδου τεσσάρων δεδομένων, δύο κρυφά επίπεδα 8 και 5 νευρώνων αντιστοίχως και επίπεδο εξόδου δύο ζητούμενων παραμέτρων. Ακολουθεί ενδεικτικό σχήμα τέτοιου νευρωνικού δικτύου με ένα κρυφό επίπεδο.



Εικόνα 2.5: Δίκτυο πρόσθιας τροφοδότησης με ένα κρυφό επίπεδο [7]

- Αναδρομικά νευρωνικά δίκτυα:

Το κύριο χαρακτηριστικό αυτών των νευρωνικών δικτύων είναι ότι μπορούν να έχουν νευρώνες ανάδρασης, δηλαδή την ικανότητα ο νευρώνας να τροφοδοτεί το σήμα εξόδου του πίσω στις εισόδους όλων των άλλων νευρώνων. Παραλλαγή αυτού του χαρακτηριστικού αποτελεί, η δυνατότητα αυτοανάδρασης, δηλαδή η ικανότητα του νευρώνα στην έξοδο του να ανατροφοδοτεί την είσοδο του. Η παρουσία των νευρώνων ανάδρασης, έχει ένα βαθύ αντίκτυπο στην ικανότητα εκπαίδευσης του δικτύου και στην απόδοσή του. Επιπλέον, οι νευρώνες ανάδρασης περιπλέκουν τη χρησιμοποίηση συγκεκριμένων κλάδων που αποτελούνται από στοιχεία μονάδας καθυστέρησης (δηλώνονται με  $z^{-1}$ ), που έχουν ως αποτέλεσμα μια μη γραμμική δυναμική συμπεριφορά. Χαρακτηριστικός γράφος αναδρομικών δικτύων είναι ο ακόλουθος.



Εικόνα 2.6:Αναδρομικό δίκτυο με κρυφούς νευρώνες [4]

## 2.6 Εκπαίδευση νευρωνικών δικτύων

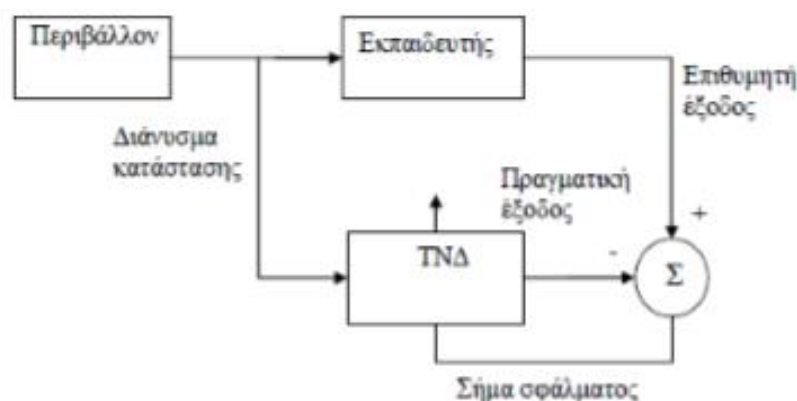
### ΕΙΔΗ ΕΚΠΑΙΔΕΥΣΗΣ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Η εκπαίδευση των νευρωνικών δικτύων είναι από τα πιο σημαντικά χαρακτηριστικά, των εν λόγω μαθηματικών μοντέλων. Μέσω αυτής τα νευρωνικά είναι ικανά να ανταποκρίνονται σε διάφορα προβλήματα, χρησιμοποιώντας δεδομένα και εξάγοντας αποτελέσματα πολύ κοντά σε αυτά των πραγματικών συνθηκών. Η διαδικασία της εκπαίδευσης περιλαμβάνει δύο στάδια, 1<sup>ον</sup> αυτό της ανάκλησης και 2<sup>ον</sup> αυτό της μάθησης. Στην ανάκληση το δίκτυο λαμβάνοντας κάποιο συγκεκριμένο δεδομένο (διάνυσμα εισόδου) και σε συνδυασμό με τους συντελεστές βαρύτητας (βάρη), εξάγει ένα ανάλογο αποτέλεσμα (διάνυσμα εξόδου) που αποτελεί και τον αντικειμενικό σκοπό λειτουργίας ενός τέτοιου δικτύου. Στην μάθηση το δίκτυο τροποποιεί τους συντελεστές βαρύτητας προκειμένου προκειμένου για συγκεκριμένο διάνυσμα εισόδου να υπολογίζει διάνυσμα εξόδου αρκετά κοντά στο επιθυμητό.

Στο στάδιο της μάθησης/εκπαίδευσης γίνεται χρήση ενός αριθμού δεδομένων και ενός αλγόριθμου εκπαίδευσης προκειμένου το νευρωνικό δίκτυο να έχει, σε σχέση με την αρχική κατάσταση, την βέλτιστη απόδοση. Ο αλγόριθμος δεν είναι παρά μια επαναληπτική διαδικασία, με σκοπό την συνεχόμενη τροποποίηση των (βαρών) με απώτερο στόχο την ελαχιστοποίηση της διαφοράς/σφάλματος, μεταξύ πραγματικού και επιθυμητού αποτελέσματος του δικτύου. Ο τρόπος με τον οποίο γίνεται η τροποποίηση των βαρών των συνάψεων, επιτρέπει την διάκριση τριών περιπτώσεων εκπαίδευσης ενός νευρωνικού δικτύου:

1) **Μάθηση με επίβλεψη** (supervised learning).

Στο δίκτυο δίνεται ένας αριθμός ζευγαριών διανυσμάτων εισόδου και επιθυμητής εξόδου και αυτό με δεδομένη την αρχική του κατάσταση, παράγει αποτελέσματα τα οποία διαφέρουν από τα αναμενόμενα. Αυτή η διαφοροποίηση χαρακτηρίζεται ως σφάλμα και μέσω αυτού ο αλγόριθμος εκπαίδευσης αναπροσαρμόζει τα βάρη αλλά και τις μεταβλητές bias, ώστε να επιτευχθεί η μείωση του σφάλματος. Σε ύστερη φάση γίνεται ο έλεγχος/πιστοποίηση της μάθησης όπου χρησιμοποιούνται διανύσματα εισόδου και με τα οποία δεν εκπαιδεύτηκε το δίκτυο ώστε να αξιολογηθούν τα όποια διανύσματα εξόδου σε σχέση με τα επιθυμητά. Η μάθηση με επίβλεψη είναι η συνηθέστερη για την εκπαίδευση των νευρωνικών δικτύων, με τον αντίστοιχο γράφο να ακολουθεί. Οι αλγόριθμοί για αυτού του είδους την εκπαίδευση ποικίλουν και ενδεικτικά στον αλγόριθμό που βασίζεται στον κανόνα Delta rule learning, η ελαχιστοποίηση του σφάλματος γίνεται με την μέθοδο των ελαχίστων τετραγώνων.




Εικόνα 2.7: Σχηματικό διάγραμμα επιβλεπόμενης μάθησης [7]

2) **Βαθμολογημένη μάθηση** (graded learning) ή **ενισχυτική μάθηση**.

Στην συγκεκριμένη περίπτωση το δίκτυο τροφοδοτείται με ποσότητα διανυσμάτων εισόδου, χωρίς όμως τις αντίστοιχες επιθυμητές αποκρίσεις τους. Η αξιολόγηση της απόκρισης του δικτύου και εν συνεχεία η αναπροσαρμογή των βαρών και των μεταβλητών bias γίνεται με βάση μια αριθμητική κλίμακα και εν συνεχεία ενός ενισχυτικού σήματος (reinforcement signal), το οποίο οδηγεί στην επιθυμητή συμπεριφορά.

### 3) Μάθηση χωρίς επίβλεψη (unsupervised learning).

Το δίκτυο χρησιμοποιεί μεν δεδομένα εισόδου χωρίς τις αντίστοιχες αποκρίσεις, αλλά δεν αξιολογείται με βάση κάποια επιθυμητή κατάσταση. Αντιθέτως αυτό-οργανώνεται με βάση τα διανύσματα εισόδου και αναπροσαρμόζει τα βάρη του και των μεταβλητών bias, ώστε τα επιθυμητά αποτελέσματα να έχουν τα ίδια χαρακτηριστικά με τα δεδομένα εισόδου. Η αναπροσαρμογή γίνεται μέσω ενός εσωτερικού ελέγχου, με το δίκτυο να αναζητά κανονικότητα στα σήματα εισόδου, διορθώνοντας τα σφάλματα με έναν μηχανισμό ανάδρασης (feedback), όπως φαίνεται στο ανάλογο σχήμα.



Εικόνα 2.8:Σχηματικό διάγραμμα μη επιβλεπόμενης μάθησης [7]

Στην επιλογή του αλγόριθμου εκπαίδευσης, προσμετρούνται τόσο η πολυπλοκότητα του δικτύου όσο και το είδος του προς επίλυση προβλήματος. Ο ιδανικός αλγόριθμος για κάθε εφαρμογή του νευρωνικού δικτύου θα προκύψει, από την σύγκριση αρκετών περιπτώσεων διαφορετικών αλγορίθμων. Η αξιοπιστία της σύγκρισης θα εξαρτηθεί από την ποσότητα των επαναλήψεων του αλγόριθμου στο δίκτυο ώστε να καθορισθεί το ύψος του σφάλματος σε κάθε περίπτωση.

## ΑΛΓΟΡΙΘΜΟΙ ΕΚΠΑΙΔΕΥΣΗΣ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Η εκπαίδευση των νευρωνικών δικτύων ανεξαρτήτως του είδους, για να πραγματοποιηθεί χρειάζεται την συμβολή ενός αλγόριθμου ο οποίος έχοντας μια σειρά μετρήσεων λειτουργεί το MLP, ώστε το τελευταίο μέσα από δοκιμές να αποκτήσει την βέλτιστη ικανότητα πρόβλεψης των ποσοτικών μεγεθών της εκάστοτε παραμέτρου, για την οποία το MLP χρησιμοποιείται. Ενδεικτικά παρουσιάζονται οι ακόλουθοι αλγόριθμοι.

### 1) Αλγόριθμος Levenberg-Marquardt

Ο αλγόριθμος Levenberg-Marquardt είναι μια μέθοδος που βρίσκει εφαρμογή στην επίλυση μη γραμμικών προβλημάτων ελαχίστων τετραγώνων (προβλήματα ελαχιστοποίησης), τα οποία προκύπτουν στην προσέγγιση καμπυλών με τη μέθοδο ελαχίστων τετραγώνων, ώστε με τον τρόπο αυτό να υπολογίζεται το ελάχιστο μιας συνάρτησης. Σε σχέση με άλλες μεθόδους, π.χ Gauss-Newton, είναι πιο στιβαρή μέθοδος και μπορεί να προσεγγίσει το ελάχιστο ακόμα και αν η αρχική τιμή απέχει πολύ από την τελική. Ωστόσο σε πιο εύκολα προβλήματα είναι ελαφρώς πιο αργή από τη μέθοδο Gauss-Newton. Στην περίπτωση των νευρωνικών δικτύων, ο αλγόριθμος Levenberg Marquardt χρησιμοποιείται συχνά με επιτυχία ως αλγόριθμος εκπαίδευσης νευρωνικών δικτύων. Ο αλγόριθμος Levenberg-Marquardt χρησιμοποιείται διότι προσεγγίζει την ταχύτητα των προσεγγίσεων

δεύτερης τάξης στην εκπαίδευση του δικτύου αποφεύγοντας τον ιδιαίτερα χρονοβόρο υπολογισμό του Εσσιανού Μητρώου. Όταν η συνάρτηση απόδοσης (performance function) έχει τη μορφή αθροίσματος τετραγώνων, πράγμα συνηθισμένο στην εκπαίδευση νευρωνικών δικτύων πρόσθιας τροφοδοσίας, το Εσσιανό μητρώο μπορεί να προσεγγιστεί ως:

$$H = J^T * J$$

και η παράγωγος να υπολογισθεί τότε ως:

$$g = J^T * e$$

όπου J είναι το Ιακωβιανό μητρώο που περιλαμβάνει τις πρώτες παραγώγους των σφαλμάτων του δικτύου ως προς τα βάρη και τα biases και e είναι το διάνυσμα των σφαλμάτων του δικτύου. Αυτή η προσέγγιση του Εσσιανού μητρώου χρησιμοποιείται από το αλγόριθμο Levenberg-Marquardt για την ανανέωση των τιμών των βαρών μέσω μιας σχέσης της μορφής:

$$X_{k+1} = X_k - [J^T * J + \mu * I]^{-1} * J^T * e$$

Όταν η βαθμωτή ποσότητα  $\mu$  ισούται με μηδέν, η μέθοδος LM εκφυλίζεται στη μέθοδο Newton. Όταν η ποσότητα  $\mu$  λάβει μεγάλες τιμές, ισοδυναμεί με την μέθοδο απότομης καθόδου με μικρό μέγεθος βήματος. Καθώς η μέθοδος Newton είναι ταχύτερη και ακριβέστερη στην περιοχή ενός ελαχίστου του σφάλματος, ο στόχος είναι να προσεγγιστεί η μέθοδος του Newton όσο γρηγορότερα γίνεται. Έτσι έπειτα από κάθε πετυχημένο βήμα μείωσης της συνάρτησης απόδοσης, το  $\mu$  μειώνεται και αυξάνεται μόνο όταν κάποιο δοκιμαστικό βήμα αυξάνει την τιμή της συνάρτησης απόδοσης. Έτσι, η συνάρτηση απόδοσης μειώνεται συνεχώς σε κάθε επανάληψη του αλγορίθμου. Ο αλγόριθμος αυτός φαίνεται ότι είναι η ταχύτερη μέθοδος για την εκπαίδευση νευρωνικών δικτύων μετρίου μεγέθους (έως κάποια εκατοντάδες βάρη). [5]

## 2) Η μέθοδος της απότομης καθόδου

Η μέθοδος της απότομης καθόδου (gradient descent) είναι η πιο παλιά και κλασσική μέθοδος εκπαίδευσης στα νευρωνικά δίκτυα. Η μέθοδος της απότομης καθόδου δεν είναι ένας αλγόριθμος εξειδικευμένος για εκπαίδευση νευρωνικών δικτύων. Γενικά έχει ένα μεγάλο εύρος εφαρμογών σε διάφορα πεδία της επιστήμης, της μηχανικής και των μαθηματικών. Ο αλγόριθμος αυτός στην περίπτωση των νευρωνικών δικτύων (όπως και οι άλλοι που αναφέρονται) χρησιμοποιείται για να ελαχιστοποιήσει μια συνάρτηση σφάλματος  $g(y)$  μέσω της αλλαγής των τιμών του διανύσματος των βαρών. Η μέθοδος της απότομης καθόδου είναι πολύ πιο απλό να υλοποιηθεί σε σχέση με άλλες, διότι απαιτεί την εύρεση μόνο της πρώτης παραγώγου (σε αντίθεση με μεθόδους όπως η Newton που απαιτούν τον υπολογισμό του Εσσιανού μητρώου). Η συνάρτηση κόστους πρέπει να είναι γραμμικός συνδυασμός του διανύσματος των βαρών και ενός διανύσματος εισόδου  $x$ . Επίσης, για να

μπορεί να γίνει ο υπολογισμός της πρώτης παραγώγου της συνάρτησης σφάλματος πρέπει η συνάρτηση ενεργοποίησης να είναι παραγωγίσιμη. Ο αλγόριθμος είναι ο εξής:

$$W_{ij}[n + 1] = W_{ij}[n] + \eta * g(W_{ij}[n])$$

Όπου το  $\eta$  ονομάζεται παράμετρος του μεγέθους του βήματος και επηρεάζει το ρυθμό σύγκλισης του αλγορίθμου. Εάν το μέγεθος του βήματος είναι πολύ μικρό, ο αλγόριθμος θα χρειαστεί αρκετά μεγάλο χρόνο για να συγκλίνει ενώ στην αντίθετη περίπτωση αν το βήμα είναι αρκετά μεγάλο ο αλγόριθμος μπορεί να εμφανίσει ταλαντώσεις στη σύγκλιση ή τελικά να αποκλίνει. Ο αλγόριθμος της απότομης καθόδου λαμβάνει την παράγωγο του χώρου των βαρών για να βρει το μονοπάτι της απότομης καθόδου. Ακολουθώντας αυτό το μονοπάτι σε κάθε επανάληψη θα υπολογίσουμε τελικά το ελάχιστο ή ο αλγόριθμος θα αποκλίνει. Επίσης, ο αλγόριθμος αυτός δεν εγγυάται ότι θα επιτευχθεί η εύρεση ενός ολικού ακρότατου στο τέλος της διαδικασίας.[5]

### 3) Η μέθοδος BFGS Quasi-Newton

Η μέθοδος BFGS Quasi-Newton ανήκει στην κατηγορία των μεθόδων Newton, οι οποίες απαιτούν τον υπολογισμό παραγώγων δεύτερης τάξης (στην γενική περίπτωση Εσσιανών μητρώων). Η μέθοδος Newton θεωρείται εφάμιλλη των μεθόδων συζυγούς κλίσης (Conjugate Gradient) όσον αφορά την ταχύτητα. Το βασικό βήμα στη μέθοδο Newton είναι:

$$X_{k+1} = X_k - A_k^{-1} * g_k$$

Όπου  $A_k^{-1}$  είναι το Εσσιανό μητρώο της συνάρτησης σφάλματος σε σχέση με τις τρέχουσες τιμές των βαρών και biases. Παρ' ότι η μέθοδος αυτή αποδεικνύεται ταχύτερη σε διάφορες περιπτώσεις, ο υπολογισμός της δεύτερης παραγώγου θεωρείται ιδιαίτερα πολύπλοκος και επίπονος υπολογιστικά. Γι' αυτό χρησιμοποιείται εναλλακτικά μια κατηγορία μεθόδων που ονομάζονται Quasi-Newton (ψευδο-Newton) μέθοδοι και σε αυτές ο υπολογισμός της δεύτερης παραγώγου γίνεται μόνο προσεγγιστικά σε κάθε βήμα του αλγορίθμου, κάτι που μειώνει σημαντικά το υπολογιστικό κόστος. Η πιο δημοφιλής μέθοδος αυτής της κατηγορίας είναι αυτή που προτάθηκε από τους Broyden, Fletcher, Goldfarb και Shanno (BFGS). Σε σύγκριση με τις μεθόδους συζυγούς κλίσης απαιτεί περισσότερους υπολογισμούς και μνήμη σε κάθε επανάληψη αλλά συγκλίνει σε λιγότερες επαναλήψεις. Έτσι, δεν είναι κατάλληλη για δίκτυα με μεγάλο αριθμό νευρώνων. Λόγω αυτών των μειονεκτημάτων έχουν προταθεί εναλλακτικές μέθοδοι BFGS όπως η LBFGS, η οποία αντί να αποθηκεύει ολόκληρο το Εσσιανό μητρώο, το αναπαριστά έμμεσα, έχοντας αποθηκεύσει συγκεκριμένα διανύσματα από το μητρώο, η O-LBFGS η οποία υπολογίζει την παράγωγο και το σφάλμα σε συγκεκριμένο υποσύνολο των διαθέσιμων δεδομένων σε κάθε επανάληψη.[5]



#### 4) Η μέθοδος Scaled Conjugate Gradient

Η μέθοδος συζυγούς κλίσης (Scaled Conjugate Gradient), βασιζόμενη στην κλασσική μέθοδο απότομης καθόδου, σχεδιάστηκε για να αντιμετωπίσει τις παθογένειες της gradient descent σχετικά με τον χαμηλό ρυθμό σύγκλισης και την υπολογιστική πολυπλοκότητα με την αύξηση των επαναλήψεων κατά την διαδικασία εκπαίδευσης. Για την επίτευξη των παραπάνω, χρησιμοποιεί την προσέγγιση Levenberg-Marquardt, προκειμένου να τεθεί υπό κλίμακα, το μέγεθος κάθε διαδικασίας/βήματος. Ουσιαστικά παράγεται μια ακολουθία  $w_k$ , η οποία τείνει να προσεγγίσει έναν τοπικό ελαχιστοποιητή  $w_e$  της αντικειμενικής συνάρτησης  $E(w)$ . Η βασική ιδέα των μεθόδων αυτών είναι να μην ξαναχρησιμοποιηθεί κατεύθυνση που έχει ξανασαρωθεί. Οι παρακάτω εξισώσεις περιγράφουν την επαναληπτική μέθοδο:

$$w^{k+1} = w^k + a_k d_k \text{ όπου } k = 0, 1, 2 \dots, \text{ όπου:}$$

$$d_k = -g_k \equiv -\nabla E(w^k) \text{ για } k=0$$

$$d_k = -g_k + \beta_k^X d_{k-1} \text{ για } k \geq 1$$

- 1) Το διάνυσμα  $d_k$  εκφράζει την κατεύθυνση ελαχιστοποίησης της αντικειμενικής συνάρτησης  $E(w)$ .
- 2) Το διάνυσμα  $g_k \equiv -\nabla E(w_k)$  εκφράζει την κλίση της  $E(w)$ .
- 3) Το  $a_k$  είναι το μέγεθος βήματος το οποίο επιλέγεται σε κάθε επανάληψη.
- 4) Το μέγεθος  $\beta_k^X$  είναι βαθμωτός.
- 5) Ο δείκτης  $X$  καθορίζει την επιλεγμένη μέθοδο συζυγών κλίσεων.

Οι επαναλήψεις ξεκινούν με μια αρχική προσέγγιση του ελαχιστοποιητή  $w^0$  και με μια αρχική κατεύθυνση αναζήτησης :

$$d_0 = -g_0 \equiv -\nabla E(w^0)$$

Κατόπιν διεξάγεται μια αναζήτηση κατά μήκος της κατεύθυνσης συζυγούς κλίσης, για να προσδιοριστεί το μέγεθος βήματος, το οποίο ελαχιστοποιεί την συνάρτηση σφάλματος, κατά μήκος αυτής της κατεύθυνσης.[8][9]

### 2.7 Γενίκευση νευρωνικών δικτύων

Η συγκεκριμένη ιδιότητα των νευρωνικών δικτύων είναι ιδιαίτερα σημαντική. Αφορά την δυνατότητα του δικτύου να λαμβάνει δεδομένα τα οποία δεν προέρχονται από το σύνολο αυτών που χρησιμοποιήθηκαν κατά την εκπαίδευση, και να παράγει διανύσματα εξόδου πολύ κοντά σε αυτά των πραγματικών συνθηκών της εκάστοτε διαδικασίας. Κατά αυτό τον τρόπο, το δίκτυο έχει την δυνατότητα να αντικατοπτρίζει με μεγάλη αξιοπιστία, μια οποιαδήποτε εργασία ως προς τα αποτελέσματα της, χρησιμοποιώντας μόνο ένα ποσοστό των δεδομένων, για την εξοικείωση του με τις συνθήκες του προβλήματος. Η ικανότητα γενίκευσης εξαρτάται κυρίως από:

- Τον αριθμό των διανυσμάτων εισόδου-εξόδου με τα οποία εκπαιδεύεται το δίκτυο και κατά πόσο αυτά αποτελούν αξιόπιστο δείγμα του ευρύτερου περιβάλλοντος από τον οποίο προέρχονται. Όσο μεγαλύτερος είναι ο αριθμός των διανυσμάτων εκπαίδευσης τόσο πιο πιθανότερη είναι η εξεύρεση του βέλτιστου μοντέλου γενίκευσης του MLP.
- Την πολυπλοκότητα του προβλήματος για το οποίο θα εφαρμοστεί το MLP.
- Το μέγεθος του νευρωνικού δικτύου. Η απαίτηση συνίσταται ώστε το MLP να αναπαριστά όσο πιο πιστά το περιβάλλον του προβλήματος με όσο πιο δυνατό απλούστερη μορφή. Αιτία αποτελεί η αποφυγή αυξημένων χρόνων υπολογισμών και γενικά προσαρμογής του, στο εκάστοτε περιβάλλον στο οποίο θα γίνει η εφαρμογή του.

Ειδικότερα ως προς την τελευταία παράμετρο, σημαντικό ρόλο στην γενίκευση ενός νευρωνικού δικτύου, αποτελεί η αποφυγή του αρνητικού φαινομένου της υπερπροσαρμογής. Σε αυτή την περίπτωση, παρατηρείται το φαινόμενο ενώ το δίκτυο με το πέρας της εκπαίδευσης να ικανοποιεί τις απαιτήσεις του προβλήματος από θέμα ελαχιστοποίησης του σφάλματος, να μην τα καταφέρνει ανάλογα κατά την διαδικασία της γενίκευσης. Αυτό έχει την εξήγησή του, στο ότι κατά το στάδιο της εκπαίδευσης το δίκτυο απομνημόνευσε τα δεδομένα που χρησιμοποιήθηκαν, με τρόπο πιο λεπτομερή από ότι θα έπρεπε. Αυτό έχει ως συνέπεια το MLP σε νέα δεδομένα να μην έχει την αποτελεσματικότητα που απαιτείται και να εμφανίζει αποτελέσματα με αυξημένη απόκλιση/σφάλμα από τα επιθυμητά. Οπότε είναι σημαντικό, το νευρωνικό δίκτυο να αναπαριστά πιστό το όποιο πρόβλημα με την λιγότερη πολυπλοκότητα.

## **2.8 Το νευρωνικό δίκτυο RBF**

Μια χαρακτηριστική μορφή MLP πρόσθιας τροφοδότησης, είναι το νευρωνικό δίκτυο RBF. Πρόκειται για εκδοχή MLP όπου η συνάρτηση ενεργοποίησης είναι ακτινικής βάσης (radial basis function), η αρχιτεκτονική θεωρείται παγιωμένη με ένα μόνο κρυφό επίπεδο, λόγω της αδυναμίας των υπάρχοντων αλγορίθμων εκπαίδευσης να αναπτύξουν ένα τέτοιου τύπου νευρωνικό δίκτυο με παραπάνω από ένα κρυφά επίπεδα. Η ακτινικού τύπου συνάρτηση υφίσταται, εάν υπάρχει κάποιο διάνυσμα  $c$  το οποίο ονομάζεται κέντρο (center) και η τιμή της συνάρτησης εξαρτάται μόνο από την απόσταση του  $x$  από το  $c$ . Χαρακτηριστικές συναρτήσεις ακτινικού τύπου είναι οι περιπτώσεις τύπου Gauss, η πολύ-τετραγωνική και η Cauchy, με την πρώτη να είναι και αυτή που χρησιμοποιείται ευρύτατα στα δίκτυα RBF. Η εκπαίδευση ενός τέτοιου δικτύου είναι χωρίς επίβλεψη (αυτό-οργανωμένα επίπεδα), ενώ τα εν λόγω νευρωνικά δίκτυα παρόλο που μπορούν να εκτελέσουν πολύ καλά μια συγκεκριμένη λειτουργία-ταξινομητές, δεν μπορούν ωστόσο να παρουσιάσουν το φαινόμενο της γενίκευσης, περιοριζόμενα μόνο στα δεδομένα στα οποία σχεδιάστηκαν.

## 2.9 Επισκόπηση πρότερων εργασιών σχετικά με τα τεχνητά νευρωνικά δίκτυα

Στην περίπτωση των κατεργασιών αφαίρεσης υλικού, οι προσπάθειες χρησιμοποίησης των νευρωνικών δικτύων έχουν ως χρονική αφετηρία το 2<sup>ο</sup> μισό της δεκαετίας του 90. Από την δεκαετία του 2000 οι εφαρμογές των MLP σε θέματα κατεργασιών αφαίρεσης υλικού εντατικοποιήθηκαν, φτάνοντας στην τρέχουσα χρονική στιγμή όπου η χρησιμοποίηση των νευρωνικών δικτύων στον προσδιορισμό παραμέτρων κοπής σε θέματα κατεργασιών, θεωρείται από τις επικρατέστερες μεθόδους.

- Το 1995 οι Cook και Chiu επιχείρησαν την βελτίωση της απόδοσης του νευρωνικού δικτύου για τον προσδιορισμό των ποσοτικών μεγεθών, των παραμέτρων κοπής. Χρησιμοποιώντας για την ενεργοποίηση των νευρώνων χρησιμοποιήθηκε ένα ακτινικής βάσης (radial basis) MLP, όπως και ένα μοντέλο χρόνου για την πρόβλεψη του δικτύου, κατάφεραν να βελτιώσουν την ακρίβεια πρόβλεψης του νευρωνικού δικτύου, αξιολογώντας μια σειρά δεδομένων από μια διαδικασία κατεργασίας.[10]
- Επίσης το 1995, οι Elanayar και Shin εφάρμοσαν το νευρωνικό δίκτυο, για την παρακολούθηση του φαινομένου της διάβρωσης του κοπτικού εργαλείου. Χρησιμοποιώντας επίσης ένα ακτινικής βάσης (radial basis), MLP, εμφανίζοντας τις διάφορες παραμέτρους με γραμμικό τρόπο και με αλγόριθμο εκπαίδευσης την μέθοδο την ελαχίστων τετραγώνων, συμπέραναν την καλή απόδοση του εν λόγω μαθηματικού μοντέλου.[11]
- Το 1997 οι Kao και Tarng μέσω του νευρωνικού δικτύου αποπειράθηκαν με επιτυχία να μελετήσουν την διαδικασία της κατεργασίας ήλεκτροδιάβρωσης, με σκοπό την ανάπτυξη λειτουργιών ελέγχου και ασφάλειας της διαδικασίας, προς όφελος της παραγωγικότητας. Για τον σκοπό αυτό χρησιμοποίησαν ένα νευρωνικό δίκτυο πρόσθιας τροφοδότησης (feedforward) και οπισθόδρομης διάδοσης (back propagation), με συνάρτηση ενεργοποίησης την υπερβολική (hyperbolic tangent). Ως δεδομένα για το επίπεδο εισόδου του MLP θα λογίζονται η τάση και η ένταση του ηλεκτρικού ρεύματος, όπου μέσω των ηλεκτρικών παλμών θα τροφοδοτούν το δίκτυο, το οποίο επιλέχθηκε να έχει αρχιτεκτονική πέρα του επιπέδου εισόδου, με δυό κρυμμένα επίπεδα με 6 και 8 νευρώνες αντίστοιχα και επίπεδο εξόδου 5 μεγεθών. Τα ζητούμενα μεγέθη στην έξοδο του MLP για την εν λόγω περίπτωση, ήταν διάφορα είδη παλμών και τα οποία άμεσα προσδιορίζουν παραμέτρους όπως ο ρυθμός αφαίρεσης υλικού, η ποιότητα της επιφάνειας του δοκιμίου και η διαστασιολογική ακρίβεια.[12]
- Επιπλέον οι Liu και Altintas το 1999 χρησιμοποίησαν τα νευρωνικά δίκτυα για την παρακολούθηση του φαινομένου φθοράς (flank wear) στην τórνευση σε δοκίμια mold χάλυβα. Συγκεκριμένα, εφαρμόστηκε ένα τριών επιπέδων νευρωνικό δίκτυο, πρόσθιας τροφοδότησης με δεδομένα εισόδου την ταχύτητα κοπής, την πρόωση, ενώ για την ενεργοποίηση του δικτύου επιλέχθηκε η σιγμοειδής συνάρτηση. Ο προσδιορισμός της

απόκλισης έγινε με την μέθοδο των ελαχίστων τετραγώνων και το συμπέρασμα ήταν ότι το MLP απέδωσε πολύ καλά, χρησιμοποιώντας δεδομένα εισόδου, διαφορετικά από αυτά με τα οποία εκπαιδεύτηκε.[13]

- Το ίδιο έτος οι Cheng και Lin με την ίδια τεχνική, επιχείρησαν να προσδιορίσουν την γωνία κάμψης (bending angle), σε κατεργασία διαμόρφωσης μεταλλικού ελάσματος με χρήση laser. Χρησιμοποιήθηκαν συγκριτικά, τρία εναλλακτικά νευρωνικά δίκτυα με δεδομένα εισόδου την διάμετρο οπής, την ταχύτητα σάρωσης, την ισχύ της κατεργασίας, καθώς και το πάχος και το μήκος του δοκιμίου. Από τα νευρωνικά δίκτυα, τα δύο ήταν οπισθόδρομης διάδοσης (back propagation) με συναρτήσεις ενεργοποίησης, την υπερβολική και την λογαριθμική αντίστοιχα, ενώ τα τρίτο ήταν ακτινικής βάσης (radial basis) δίκτυο. Και στις τρεις περιπτώσεις τα δίκτυα ήταν τριών επιπέδων ενώ για την επίδραση των παραμέτρων εισόδου, επιλέχθηκε η “στρατηγική ανάλυσης της διακύμανσης” (ANOVA). Τα αποτελέσματα έδειξαν την ανωτερότητα του δικτύου στην αξιοπιστία πρόβλεψης της γωνίας κάμψης έναντι των άλλων δύο περιπτώσεων.[14]

Με τις αρχές του 21<sup>ου</sup> αιώνα, η εφαρμογή των νευρωνικών δικτύων για τον προσδιορισμό παραμέτρων κοπής σε κατεργασίες αφαίρεσης υλικού γνώρισε καθολική αποδοχή από πλήθος ερευνητών, διαφόρων πανεπιστημιακών ιδρυμάτων. Ενδεικτικά, τόσο σε διεθνές όσο και σε εγχώριο επίπεδο, ακολουθεί αριθμός μελετών σχετικών με το αντικείμενο:

- Οι Γ.Χ.Βοσνιάκος και Π.Μπερνάρδος, το 2002, ασχολήθηκαν με την χρήση νευρωνικού δικτύου για τον προσδιορισμό της τραχύτητας δοκιμίου σε κατεργασία φρεζαρίσματος-CNC. Για τον σκοπό αυτό, χρησιμοποιήθηκαν η μέθοδος σχεδιασμού πειραμάτων κατά Taguchi, αλλά και νευρωνικό δίκτυο πρόσθιας τροφοδότησης (feedforward), με τον αλγόριθμο εκπαίδευσης του δικτύου να είναι των Levenberg-Marquardt. Το υλικό του δοκιμίου ήταν από κράμα αλουμινίου σειράς 2, με κύρια χρήση στην αεροναυπηγική, ενώ στην διαδικασία χρησιμοποιήθηκε μετωπικός κοπτήρας τεσσάρων ακμών κοπής και διαμέτρου 40mm. Επιπλέον επιλέχθηκαν ως παράμετροι δεδομένων εισόδου, το βάθος κοπής, η πρόωση ανά δόντι, η ταχύτητα κοπής, η φθορά του κοπτικού εργαλείου, το υγρό κοπής και οι τρεις συνιστώσες της δύναμης κοπής. Από την πειραματική διαδικασία, συλλέχθηκαν 27 γκρουπ μετρήσεων, εκ των οποίων 18 χρησιμοποιήθηκαν για την εκπαίδευση, 5 για την γενίκευση και 4 για την πιστοποίηση, ενώ η επεξεργασία έλαβε χώρα σε γλώσσα προγραμματισμού MATLAB. Από τις δοκιμές καταδείχτηκε, ότι νευρωνικό δίκτυο δομής 5-3-1, (δηλαδή MLP με επίπεδο εισόδου 5 δεδομένων, ενός κρυμμένου επιπέδου με 3 κόμβους και επίπεδο εξόδου μιας μεταβλητής), ήταν κατάλληλο να προβλέψει την επιθυμητή τραχύτητα, με το μέσο τετραγωνικό σφάλμα να κυμαίνεται στο 1,86%, επί του συνόλου των μετρήσεων. Επιπρόσθετα από την εν λόγω μελέτη, διαπιστώθηκε ότι από τα δεδομένα εισόδου, αυτά που επηρεάζουν πρωτίστως την επιφανειακή τραχύτητα είναι, η πρόωση ανά οδόντα, η συνιστώσα κατά τον άξονα x της δύναμης κοπής, το βάθος

κοπής, η επαφή του κοπτικού εργαλείου με το τεμάχιο, και το υγρό κοπής.[15]

- Το 2006 οι U. Zuperl, F. Cus, B. Mursec και T. Ploj μέσω των MLP επιχείρησαν να προσδιορίσουν τις δυνάμεις κοπής κατά την κατεργασία φρεζαρίσματος. Για τον σκοπό αυτό δοκίμιο από χάλυβα CK45 αποτέλεσε το αντικείμενο λήψης μετρήσεων σε εργαλειομηχανή φρέζας CNC ισχύος 6HP. Το κοπτικό εργαλείο ήταν κοπτήρας δυό κόψεων διαμέτρου 16mm, γωνίας έλικας 10 μοιρών και υλικό KE P30-50 ή P10-20 με επικάλυψη TiC/TiN. Τα δεδομένα εισόδου αποτέλεσαν η ταχύτητα ατράκτου, η πρόωση και το αξονικό και ακτινικό βάθος κοπής, ενώ άλλες παράμετροι όπως η διάμετρος KE, η γωνία κλίσης, το υλικό και η σκληρότητα υλικού του κατεργαζόμενου δοκιμίου, η ταχύτητα κοπής, η φθορά και η παρουσία υγρού κοπής παρέμειναν σταθεροί για τον σκοπό της μελέτης. Ελήφθησαν 15000 μετρήσεις εκ των οποίων 3500 χρησιμοποιήθηκαν για την εκπαίδευση και 1450 για την πιστοποίηση, με την διαδικασία να εκτελείται σε γλώσσα προγραμματισμού MATLAB. Σε νευρωνικό δίκτυο με 10 inputs, 1 κρυφό επίπεδο 7 νευρώνων και 3 outputs (δυνάμεις κοπής), αποδείχθηκε % σφάλμα μεταξύ πειραματικών τιμών και τιμών από την εφαρμογή του MLP, για την  $F_x$  4%, για την  $F_y$  2,7-3,5% και για την  $F_z$  1,4-3,9%, αποτέλεσμα που απέδειξε την χρησιμότητα του νευρωνικού δικτύου ως προς την ικανότητα πρόβλεψης.[16]
- Το 2012 οι F. J. Pontes, A. P. de Paiva, P. P. Balestrassi, J. R. Ferreira και M. B. da Silva μελέτησαν τον προσδιορισμό της μέσης επιφανειακής τραχύτητας  $R_a$  σε κατεργασία τόννευσης μέσω των MLP. Επιλέχτηκε ένα νευρωνικό δίκτυο ακτινικής βάσης (Radial basis), όπως και η μεθοδολογία σχεδιασμού πειραμάτων κατά Taguchi. Τα δοκίμια για την διεξαγωγή του πειράματός ήταν 60 κυλινδρικές μπάρες διαμέτρου χμήκος 49x50mm αντίστοιχα, με υλικό από χάλυβα AISI 52100. Επιπλέον το κοπτικό εργαλείο αποτελείται από κεραμικό υλικό ( $Al_2O_3 + TiC$ ) με επικάλυψη από στρώμα TiN), σε εργαλειομηχανή CNC ισχύος 5,5KW στην άτρακτο. Ως δεδομένα εισόδου για το MLP αποτέλεσαν η ταχύτητα κοπής, η πρόωση και το βάθος κοπής. Πραγματοποιήθηκαν 10 μετρήσεις σε κάθε δοκίμιο, σύνολο 600, από τις οποίες 500 χρησιμοποιήθηκαν για την εκπαίδευση και 100 για πιστοποίηση του MLP. Τα αποτελέσματα έδειξαν μια μέγιστη απόκλιση των αποτελεσμάτων από τα πειραματικά, μέσω του προσδιορισμού του κλάσματος της τιμής από το MLP προς την πειραματικής κατά 0,016409 γεγονός που αποδεικνύει την υψηλή αποτελεσματικότητα και αξιοπιστία των MLP.[17]
- Πέρα από τις συνήθεις κατεργασίες, η χρήση των νευρωνικών δικτύων επεκτάθηκε και στις λιγότερο συμβατικές. Συγκεκριμένα το 2016 οι D.K.Kasdekar, V.Parashar, C.Aryaa εφάρμοσαν το MLP, για τον προσδιορισμό του ρυθμού αποβολής υλικού σε ηλεκτροχημική κατεργασία. Σε ειδική διάταξη (θάλαμος) όπου εγχέεται υλικό από κάθοδο/ηλεκτρολύτη με υλικό από χαλκό ή ορείχαλκο, γίνεται έλεγχος δοκιμίου με διαστάσεις 27x27x27mm, από υλικό κράμα αλουμινίου AA6061-T6 κατάλληλο για εφαρμογές στην αεροδιαστημική και στην

αυτοκινητοβιομηχανία. Ως παράμετροι εισόδου έχουν επιλεγθεί η τάση, η πρόωση, το είδος του ηλεκτρόδιου και την συγκέντρωση του ηλεκτρολύτη σε MLP οπισθόδρομης διάδοσης (back propagation), με την μέθοδο εκπαίδευσης του δικτύου να αποτελεί ο αλγόριθμος Levenberg–Marquardt. Αναλύθηκαν αποτελέσματα από 24 συνδυασμούς δεδομένων εισόδου με το 70% αυτών να χρησιμοποιούνται για την εκπαίδευση του MLP. Για την συλλογή και επεξεργασία των πειραματικών μετρήσεων χρησιμοποιήθηκε η μέθοδος σχεδιασμού πειραμάτων DOE και η μέθοδος ανάλυσης ποικιλότητας ANOVA, ενώ η διαδικασία έγινε σε γλώσσα προγραμματισμού MATLAB. Από την διεξαγωγή της εφαρμογής, βρέθηκε ότι νευρωνικό δίκτυο 4 εισόδων, 1 κρυμμένου επιπέδου με 4 κρυφούς νευρώνες και την μια έξοδο (MRR) έδειξε μέσο τετραγωνικό σφάλμα MSE της τάξης του 0,0067, απόδειξη της επιτυχίας της εφαρμογής του MLP ως εργαλείο πρόβλεψης της παραμέτρου MRR.[18]

- Ένα χρόνο μετά, το 2017, οι Α.Μαρκόπουλος και Ν.Κάρκαλος χρησιμοποίησαν το νευρωνικό δίκτυο, για την πρόβλεψη του χρόνου ζωής κοπτικού εργαλείου, σε κατεργασία τόννευσης. Για αυτή την περίπτωση χρησιμοποιήθηκαν δύο διαδικασίες σχεδιασμού πειραμάτων, η κλασσική μέθοδος σχεδιασμού πειραμάτων κατά Taguchi και επίσης η πλήρως παραγοντική σχεδίαση πειραμάτων ( $4^3$  full factorial design), με την διαδικασία να εκτελείται σε περιβάλλον MATLAB. Επιλέχτηκε κοπτικό εργαλείο από CBN υλικό, με τα δεδομένα εισόδου να αποτελούνται από την ταχύτητα κοπής, το βάθος κοπής και την πρόωση. Τα μεγέθη απόκλισης που προσδιορίστηκαν για την εκτίμηση της ακρίβειας του μοντέλου ήταν, το μέσο απόλυτο σφάλμα, το μέσο ποσοστιαίο % σφάλμα και το μέσο τετραγωνικό σφάλμα. Παρόλο που χρησιμοποιήθηκε μικρός αριθμός δειγμάτων (16) και τα σφάλματα MAE και MPE παρουσίαζαν απόκλιση άνω του 20% σε σχέση με το αποδεκτό όριο του 10% ενώ, το μέσο τετραγωνικό σφάλμα MSE κυμάνθηκε γύρω στο 15% γεγονός που αποδεικνύει, ότι τα αποτελέσματα του MLP δεν ήταν πολύ μακριά από τα ανάλογα πειραματικά.[19]

Σε ότι αφορά την προς εξέταση κατεργασία της παρούσας διπλωματικής εργασίας, η χρήση των νευρωνικών δικτύων γνώρισε πλήρη εφαρμογή και μάλιστα οι πρώτες έρευνες μπορεί να διαπιστωθεί ότι συμπίπτουν, με το ξεκίνημα της χρήσης των νευρωνικών δικτύων σε ζητήματα των κατεργασιών αφαίρεσης υλικού. Συνήθεις προθέσεις των εργασιών αυτών ήταν η πρόβλεψη παραμέτρων όπως η επιφανειακή τραχύτητα, οι δυνάμεις κοπής, η ακρίβεια της διαμέτρου οπής η φθορά του ΚΕ. Ενδεικτικά παρουσιάζονται οι ακόλουθες μελέτες σχετικά με την χρήση των MLP στην κατεργασία διάτρησης.

- Στα μέσα της δεκαετίας του 90, συγκεκριμένα το 1995, οι S. C. LIN και C. J. TING προχώρησαν στην χρήση του MLP για την πρόβλεψη της φθοράς του ΚΕ κατά την διάτρηση. Χρησιμοποιήθηκε ένα οπισθόδρομης διάδοσης νευρωνικό δίκτυο. Δεδομένα εισόδου αποτέλεσαν για την περίπτωση αυτή η δύναμη ώθησης, η ροπή, η διάμετρος ΚΕ, η ταχύτητα ατράκτου και η πρόωση με το δίκτυο να εκπαιδεύεται στην εκτίμηση της μέσης τιμής φθοράς. Το προς κατεργασία δοκίμιο είναι κράμα χαλκού με

διάμετρο 25 mm και πάχος επίσης 25 mm, το ΚΕ αποτελείται από χάλυβα υψηλής αντοχής, ενώ η διαδικασία έγινε σε εργαλειομηχανή CNC Ta-Li MCV-610V. Πραγματοποιήθηκαν 27 ποσοτικοί συνδυασμοί δεδομένων και έγινε συγκριτική δοκιμή διαφόρων MLP προκειμένου να προσδιοριστεί η αρχιτεκτονική, που θα έδινε την ελάχιστη απόκλιση μετά πειραματικών τιμών και θεωρητικών από την χρήση του MLP. Από τις δοκιμές διαπιστώθηκε ότι MLP με δύο κρυφά επίπεδο παρείχαν καλύτερη ακρίβεια σε σχέση με αυτά με ένα κρυφό επίπεδο. Έχοντας ως παράμετρο αξιολόγησης το μέσο απόλυτο (AAE-Average Absolute Error) και το μέγιστο απόλυτο σφάλμα (MAE-Maximum Absolute Error), μεταξύ των νευρωνικών δικτύων δύο κρυφών επιπέδων παρατηρήθηκε αντίστοιχα για τα δύο παραπάνω σφάλματα διακύμανση, από 0,0238 έως 0,0416 και από 0,0894 έως 0,2037. Τα εν λόγω αποτελέσματα με βάση τους στόχους των ερευνητών, απέδειξαν την υψηλή ακρίβεια των νευρωνικών δικτύων ως μοντέλα πρόβλεψης παραμέτρων στην κατεργασία διάτρησης.[20]

- 12 χρόνια μετά, το 2007, οι S.R.Karnik, V.N.Gaitonde, J.C.Rubio, A.E.Correia, A.M.Abrão, J.P.Davim, ασχολήθηκαν με την χρήση του νευρωνικού δικτύου σε θέματα διάτρησης και ιδιαίτερα στην περίπτωση συνθετικών υλικών, ενισχυμένων από ανθρακονήματα. Η μελέτη τους αποσκοπούσε στην έρευνα σχετικά με το φαινόμενο κατά την διάτρηση τέτοιων υλικών. Νευρωνικό δίκτυο πολλών επιπέδων με έναν αλγόριθμο οπισθόδρομης διάδοσης (EBPTA) για την εκπαίδευση του δικτύου και σιγμοειδής συνάρτηση ενεργοποίησης δικτύου, επιστρατεύτηκε για την περίπτωση αυτή, με δεδομένα εισόδου την ταχύτητα ατράκτου, την πρόωση και την γωνία σημείου. Το δίκτυο διέθετε αρχιτεκτονική με επίπεδο εισόδου 3 δεδομένων που προαναφέρθηκαν, το επίπεδο εξόδου με την ζητούμενη δύναμη  $F_d$  και ένα κρυμμένο επίπεδο 12 νευρώνων, ενώ πραγματοποιήθηκαν συνολικά 36 επαναλήψεις-μετρήσεις σε πειραματικό επίπεδο. Από τις παραπάνω μετρήσεις, 30 χρησιμοποιήθηκαν για την εκπαίδευση του δικτύου και οι υπόλοιπες για την πιστοποίηση του, με την διαδικασία να γίνεται σε περιβάλλον προγραμματισμού MATLAB, ενώ για την αξιολόγηση των τιμών από την εκτέλεση του μοντέλου του MLP σε σχέση με τα πειραματικά δεδομένα, επιλέχθηκε ο προσδιορισμός του απόλυτου επί % σφάλματος. Από τα αποτελέσματα προσδιορίστηκε ότι η καλύτερη επιλογή μεγεθών για τα δεδομένα εισόδου αποτελεί ο συνδυασμός υψηλών τιμών της ταχύτητας ατράκτου και χαμηλών της πρόωσης και της γωνίας. Στην περίπτωση των αποκλίσεων μετρήθηκε στην βέλτιστη περίπτωση, απόλυτο σφάλμα 1,46% κατά την εκπαίδευση και 12% κατά την πιστοποίηση, αποκλίσεις αποδεκτές μεν, αλλά οι οποίες θα μπορούσαν να ελαχιστοποιηθούν με πιθανή αύξηση του εύρους τιμών των δεδομένων εισόδου των μετρήσεων και των κρυφών επιπέδων του MLP.[21]
- Το 2012 οι M.Vrabel, I.Mankova, J.Beno και J.Tuharský ασχολήθηκαν με τον προσδιορισμό της επιφανειακής τραχύτητας και της διάβρωσης ΚΕ, σε τεμάχιο από κράμα νικελίου UDIMET 720, υλικό με εφαρμογή στην αεροδιαστημική. Το ΚΕ είχε διάμετρο 15,5mm ενώ η οπή βάθος 37mm.

Χρησιμοποιήθηκε το MLP ως μοντέλο πρόβλεψης της τραχύτητας αλλά και της φθοράς του ΚΕ σε τρεις εκδοχές, με το κρυφό επίπεδο να μεταβάλλεται ως προς τον αριθμό των νευρώνων του, ώστε μέσω δοκιμών να επιλεγούν τα δίκτυα με το ελάχιστο σφάλμα (RMS-Root Mean Square). Ως δεδομένα εισόδου για την περίπτωση της φθοράς του ΚΕ επελέγησαν η πρόωση, η ταχύτητα κοπής και η συνιστώσα της δύναμης κοπής Fz, ενώ στην περίπτωση της επιφανειακής τραχύτητας ως παράμετροι εισόδου επίσης η πρόωση, η ταχύτητα κοπής και η Fz αλλά επιπλέον και η μετρούμενη φθορά ΚΕ, VB. Για την περίπτωση της διάβρωσης υλικού την καλύτερη απόδοση είχε δίκτυο με 3 inputs, 1 κρυφό επίπεδο 5 νευρώνων και το μοναδικό output με σφάλμα RMS 12,7%. Στην περίπτωση της επιφανειακής τραχύτητας το επιλεγέν δίκτυο διέθετε 4 inputs και 1 outputs αλλά 2 κρυφά επίπεδα με 6 και 4 νευρώνες αντίστοιχα και συνολικό σφάλμα RMS 2,64%. Αμφότερα τα αποτελέσματα κρίθηκαν απολύτως συμβατά για τους στόχους των ερευνητών.[22]

- Το 2013 οι J.Xu, K.Yamada, K.Seikiya, R.Tanaka, Y.Yamane μελέτησαν το φαινόμενο φθοράς ΚΕ διάτρησης χρησιμοποιώντας νευρωνικό δίκτυο οπισθόδρομης διάδοσης. Τα πειράματα διεξήχθησαν σε εργαλειομηχανή διάτρησης CNC, ενώ η εφαρμογή του MLP έγινε σε γλώσσα προγραμματισμού MATLAB. Ως δεδομένα εισόδου χαρακτηρίστηκαν η ροπή, η δύναμη ώσης, η ταχύτητα ατράκτου, η πρόωση, το υλικό του κατεργαζόμενου δοκιμίου και η διάμετρο του τρυπανιού, ενώ ως μοναδική έξοδος η γωνιακή φθορά του ΚΕ. Εξετάστηκαν 4 δοκίμια από χυτοσίδηρο, S45C, SUS304 και από κράμα αλουμινίου και συλλέγησαν 256 γκρουπ χαρακτηριστικών τιμών από τα πειραματικά δεδομένα. Το 70% των παραπάνω γκρουπ εκπαίδευσαν το δίκτυο με τον αλγόριθμο αλγόριθμος Levenberg–Marquardt, 15% χρησιμοποιήθηκε για την γενίκευση και 15% για την πιστοποίηση του δικτύου. Εφαρμοζόμενο νευρωνικό δίκτυο με 11 δεδομένα εισόδου, 1 κρυφό επίπεδο 10 νευρώνων και την γωνιακή φθορά ως μοναδική έξοδο, στο δοκίμιο από κράμα αλουμινίου κατέγραψε μέσο τετραγωνικό σφάλμα (MSE), ως απόκλιση πειραματικών τιμών και τιμών από το MLP, αποτέλεσμα της τάξης 0,000626 ενδεικτικό της επιτυχής χρήσης του μοντέλου του MLP.[23]
- Το ίδιο έτος οι F.C. Neto, T.M. Gerônimo, C.E.D. Cruz, P.R. Aguiar και E.E.C. Bianchi μέσω της χρήσης του ίδιου μαθηματικού μοντέλου για την πρόβλεψη της διαμέτρου οπής, λαμβάνοντας ως ενός εκ των δεδομένων εισόδου τις εκπομπές ακουστικών σημάτων. Επιπρόσθετα, πέραν των τελευταίων, η ηλεκτρική ισχύς, η δύναμη κοπής και οι δονήσεις αποτέλεσαν τα πρωταρχικά inputs με τα οποία θα γινόταν η χρήση του MLP. Μάλιστα έλαβε μέρος, συγκριτική αξιολόγηση δυό ειδών υπολογιστικών μοντέλων προκειμένου να διαπιστωθεί ποιο θα μπορούσε να δώσει τα βέλτιστα αποτελέσματα. Συγκεκριμένα το πρώτο ήταν ένα τεχνητό νευρωνικό δίκτυο (MLP) και το δεύτερο ένα adaptive neuro-fuzzy inference system (ANFIS). Και τα δυό υπολογιστικά μοντέλα χρησιμοποιήθηκαν σε δυό περιπτώσεις συνθετικών υλικών, μιας από



κράμα τιτανίου Ti6Al4V και εναλλακτικά από κράμα αλουμινίου 2024-T3 με εφαρμογή και στις δύο περιπτώσεις, στην αεροδιαστημική βιομηχανία. Υπήρξε κατεργασία 9 δοκιμίων όπου και μέσω διάτρησης δημιουργήθηκαν συνολικά 1351 οπές, από τις οποίες 1143 για την εκπαίδευση του MLP και οι υπόλοιπες 208 για έλεγχο και πιστοποίηση. Η επιλογή της βέλτιστης μορφής νευρωνικού δικτύου έγινε από 7000 διαφορετικές εκδοχές, όπου και για τις δύο περιπτώσεις κραμάτων η κάλλιστη εκδοχή να είναι κοινή και να αποτελείται από επίπεδο 10 παραμέτρων εισόδου, 1 κρυφό επίπεδο 5 νευρώνων και επίπεδο 10 παραμέτρων εξόδου. Από την σύγκριση πειραματικών και αποτελεσμάτων από τους υπολογισμούς των δύο, αποδείχτηκε ότι το νευρωνικό δίκτυο MLP επέδειξε καλύτερη αποτελεσματικότητα σε σχέση με το ANFIS. Αναλυτικά για την περίπτωση του MLP διαπιστώθηκε μέσο σφάλμα και μέγιστο σφάλμα, 7,4 $\mu$ m και 36 $\mu$ m για το κράμα τιτανίου και 11,4 $\mu$ m και 45,4 $\mu$ m για το κράμα αλουμινίου και επίσης για την περίπτωση του ANFIS, 8,1 $\mu$ m και 40,4 $\mu$ m για το κράμα τιτανίου και 12,4 $\mu$ m και 61,7 $\mu$ m για το κράμα αλουμινίου.[24]

- Ένα χρόνο αργότερα (2014) οι K.Patra, A.K.Jha, T.Szalay, J.Ranjan και L.Monostori αποπειράθηκαν μέσω του MLP να προσδιορίσουν την ακρίβεια διαμέτρου διαμπερούς οπής σε κατεργασία μικρό-διάτρησης με ιδιαιτερότητα χρήσης των thrust force signals ως ενός από τα δεδομένα εισόδου. Γι'αυτό τον σκοπό η δύναμη ώθησης, η ταχύτητα κοπής, η ταχύτητα ατράκτου και η πρόωση όπως και οι εκδοχές της δύναμης ώσης ελήφθησαν ως πιθανά δεδομένα εισόδου με την πειραματική διαδικασία να εκτελείται σε υψηλής αντοχής μικρό-τόρνο με αριθμό στροφών 120000 RPM και ισχύ kW. Το υλικό του τεμαχίου ήταν χάλυβας AISI P20, ενώ με 9 συνδυασμούς μεγεθών των δεδομένων εισόδου ελήφθησαν αποτελέσματα από 90 συνολικά επαναλήψεις και σύνολο 810 μετρήσεων. Το προς εφαρμογή οπισθόδρομη διάδοσης MLP, εκπαιδεύτηκε με τον αλγόριθμο Levenberg-Marquardt και η λειτουργία του διεξήχθη σε περιβάλλον προγραμματισμού MATLAB. Από τις 810 μετρήσεις, η εκπαίδευση του MLP έγινε με το 70%, η γενίκευση με το 15% και ο έλεγχος/πιστοποίηση με το εναπομένον 15%. Από την εκτέλεση του εν λόγω μαθηματικού μοντέλου, αποδείχθηκε ότι MLP με 9 παραμέτρους εισόδου, 1 κρυφό επίπεδο 10 νευρώνων και την έξοδο με μοναδικό output την ακρίβεια της διαμέτρου οπής παρουσίασε την μέγιστη απόδοση έχοντας μέσο τετραγωνικό σφάλμα (MSE) της τάξης 0,00037803, γεγονός άκρως ενδεικτικό της αποτελεσματικότητας του MLP ως εργαλείο πρόβλεψης.[25]
- Το ίδιο έτος οι T.D.B. Kannan, G.R.Kannan, B.S.Kumar Dr N.Baskar επιχείρησαν μέσω του νευρωνικού δικτύου να προσδιορίσουν τις βέλτιστες συνθήκες στην διάτρηση. Χρησιμοποιώντας ως δεδομένα την πρόωση, την ταχύτητα ατράκτου και την διάμετρο του ΚΕ, σε τεμάχιο πάχους 10mm από χαλκό και πραγματοποιώντας 18 διαφορετικούς συνδυασμούς των παραπάνω παραμέτρων. Οι συνθήκες κοπής που αξιολογήθηκαν ήταν η επιφανειακή τραχύτητα, ο χρόνος κατεργασίας, η δύναμη ώθησης και το μέγεθος παραμόρφωσης. Τα αποτελέσματα που

υπολογίστηκαν από το MLP σε σχέση με τα πειραματικά έδειξαν αποκλίσεις για τις 4 προαναφερθείσες συνθήκες  $2,24 \cdot 10^{-5}$ , 0,001348 0,003614 και  $3,74 \cdot 10^{-6}$  αντίστοιχα, μεγέθη τα οποία θεωρήθηκαν πλήρως αποδεκτά.[26]

- Δυό χρόνια αργότερα, το 2016, οι R.Corne, C.Nath, M.E.Mansori, και T. Kurfess μελέτησαν επίσης την φθορά ΚΕ βασιζόμενοι στην ισχύ ατράκτου και κατά την διάρκεια inconel διάτρησης. Πέραν της ισχύς ατράκτου, ως δεδομένα εισόδου χρησιμοποιήθηκαν τιμές τόσο της ταχύτητας κοπής όσο και της πρόωσης. Η διαδικασία έλαβε μέρος σε τριαξονικό κάθετο κέντρο κατεργασίας, ενώ το προς επεξεργασία δοκίμιο να αποτελείται ως υλικό από υπέρκράμα Ni inconel 625 έχοντας διαστάσεις 200mm x 100mm x 12.7mm. Υπήρξε δοκιμή δυό ΚΕ εκ των οποίων το πρώτο υπέστη καταστροφή φθορά στην διάνοιξη της 34 οπής ενώ στο δεύτερο ΚΕ το ίδιο φαινόμενο έλαβε χρόνο στην διάνοιξης της 55 οπής. Παρατηρήθηκε η απότομη αύξηση της φθοράς ΚΕ αναλογικά, με την απότομη αύξηση της ισχύς ατράκτου από 230W σε 795W και της δύναμης ώσης από 964N σε 2650N. Για την μελέτη του φαινομένου χρησιμοποιήθηκε ένα MLP με τον προγραμματισμό να γίνεται σε περιβάλλον MATLAB. Συλλέχθηκαν 36 συνολικά μετρήσεις σχετικά με την φθορά ΚΕ, εκ των οποίων 70% ήταν για την εκπαίδευση του δικτύου, 15% για την γενίκευση και 5% για τον έλεγχο, ενώ για την διεκπεραίωση των υπολογισμών σε κάθε στάδιο χρησιμοποιήθηκαν συγκριτικά τρεις αλγόριθμοί, ο Levenberg Marquandt (LM) , η μέθοδος απότομης καθόδου (Conjugate Gradient Descent-CGD) και ο Bayesian Inference (BI). Σε κάθε περίπτωση και έχοντας ως παράμετρους αξιολόγησης το μέσο τετραγωνικό σφάλμα (mean square error-MSE)και την συσχέτισης R (%), η πρώτη περίπτωση αλγορίθμου πέτυχε την καλύτερη απόδοση τόσο στο MSE R έχοντας αποτελέσματα αντιστοίχως, 2.23 και 85.5 στην εκπαίδευση, 2,33 και 92,2 στην γενίκευση και 11.8 και 94.0 στον έλεγχο. Τα παραπάνω αποτελέσματα επιτεύχθηκαν μέσα από νευρωνικό δίκτυο με 1 κρυφό επίπεδο και 5 νευρώνες, ενώ η συνολική απόδοση του MLP κρίθηκε από τους ερευνητές ως ικανοποιητική.[27]

## Κεφάλαιο 3

### ΑΣΑΦΗ ΚΑΙ ΝΕΥΡΟ-ΑΣΑΦΗ ΣΥΣΤΗΜΑΤΑ

#### 3.1 Εισαγωγή στα Ασαφή Σύνολα

Με βάση τους κανόνες που διέπουν ένα κλασσικό σύνολο αριθμών, ένα σημείο ανήκει ή δεν θα ανήκει στο διάστημα ορισμού του συνόλου. Στην περίπτωση των ασαφών συνόλων το εν λόγω χαρακτηριστικό δεν ακολουθείται πιστά διότι, υπάρχει περίπτωση κάποια σημεία να ανήκουν μερικώς σε ένα σύνολο ή να ανήκουν σε παραπάνω από ένα σύνολο [29]. Ένα ασαφές σύνολο (fuzzy set) ορίζεται ως ένα σύνολο διατεταγμένων ζευγών  $(x, \mu(x))$  όπου  $x \in X$  και  $\mu(x) \in [0,1]$ . Το σύνολο  $X$  αποτελεί ένα ευρύτερο σύνολο αναφοράς (universe of discourse), που περιλαμβάνει όλα τα αντικείμενα στα οποία μπορεί να γίνει αναφορά. Η τιμή  $\mu_A(x)$  λέγεται συνάρτηση συμμετοχής (membership function) ή βαθμός αλήθειας (degree of truth), συμβολίζει το βαθμό συμμετοχής του  $x$  στο  $A$  και παίρνει τιμές στο διάστημα  $[0,1]$ . Η διαφορά των ασαφών συνόλων συγκριτικά με την κλασσική θεωρία συνόλων είναι, ότι στη δεύτερη ισχύει  $\mu_A(x) \in \{0,1\}$ , δηλαδή το  $x$  είτε ανήκει στο  $A$  [ $\mu_A(x) = 1$ ] ή δεν ανήκει [ $\mu_A(x) = 0$ ]. Το ασαφές σύνολο ορίζεται ως:  $A = \sum \mu_A(x)/X$  στην διακριτή και  $A = \int \mu_A(x)/X$  στην περίπτωση, που το  $X$  είναι ένα συνεχές διάστημα.[30]

#### 3.2 Ιστορική Αναδρομή

Η Λογική της Ασάφειας, ως επιστήμη και ως μέθοδος προσεγγίζει με αληθοφάνεια τις συνθήκες του πραγματικού κόσμου. Μπορεί να ερμηνεύσει και συνεχείς, μη γραμμικές ή κατηγοριοποιημένες ιδιότητες δεδομένων, καθώς και δεδομένα με διαφορετικές κλίμακες μέτρησης όπως ποιοτική και ποσοτική.

Στις αρχές του 20ου αιώνα ο B. Russel, έθεσε τα θεμέλια της αόριστης - ασαφούς σήμερα λογικής. Στη συνέχεια ο Heisenberg ανακάλυψε στην κβαντική φυσική την αρχή της αβεβαιότητας, σύμφωνα με την οποία μπορούμε να μετρήσουμε κάποια πράγματα με πολύ μεγάλη ακρίβεια, αλλά δεν μπορούμε να μετρήσουμε ταυτόχρονα κάποια άλλα πράγματα με την ίδια ακρίβεια. Η αρχή αυτή δηλώνει ότι στην πραγματικότητα ασχολούμαστε με την τρίτημη λογική: Οι προτάσεις είναι αληθείς, ψευδείς ή ακαθόριστες, Ο Πολωνός Lukasiewicz τεμάχισε το ακαθόριστο σε πολλαπλά κομμάτια, εισάγοντας την πολύτιμη ή πλειοτιμη λογική και στη συνέχεια όρισε στην ακαθοριστία ένα συνεχές σύνολο.

Το 1937, ο φιλόσοφος της Κβαντικής θεωρίας Max Black δημοσίευσε ένα άρθρο για τα αόριστα σύνολα, αυτά που σήμερα ονομάζουμε ασαφή σύνολα, το οποίο αγνοήθηκε από τον κόσμο της επιστήμης και της φιλοσοφίας.

Η ασαφής λογική επινοήθηκε από τον L. Zadeh, στα μέσα της δεκαετίας του 1960. Σύμφωνα με τον Zadeh, η ασαφής λογική παρέχει μια μέθοδο εξήγησης και ταυτόχρονα μείωσης της πολυπλοκότητας των ασαφών συστημάτων. Κατά τον Zadeh, μεγάλο μέρος της πολυπλοκότητας των ασαφών συστημάτων προέρχονταν από τον τρόπο που αναπαρίστανται και χρησιμοποιούνται οι μεταβλητές, καθώς μπορούσαν να αναπαραστήσουν την κατάσταση ενός φαινομένου, είτε ως υπάρχουσα, είτε ως μη υπάρχουσα, με αποτέλεσμα οι

μαθηματικοί υπολογισμοί για την εκτίμηση πράξεων σε οριακές καταστάσεις να γίνονται ιδιαίτερα πολύπλοκοι. Την παραπάνω διαπίστωση τη δήλωσε με την αρχή της ασυμβατότητας: «...καθώς η πολυπλοκότητα ενός συστήματος αυξάνεται, η ικανότητα για ακριβείς και ταυτόχρονα σημαντικές δηλώσεις σχετικά με τη συμπεριφορά του μειώνεται, μέχρι ένα σημείο πέρα από το οποίο η ακρίβεια και η σημαντικότητα αποτελούν σχεδόν αμοιβαία αποκλειόμενα χαρακτηριστικά...»

Κάτω από αυτό το πρίσμα μοντελοποίησης συστημάτων, οι βασικοί μηχανισμοί αναπαρίστανται με γλωσσικές και όχι μαθηματικές μεταβλητές. Σύμφωνα με τον Zadeh, οι άνθρωποι επικοινωνούν χρησιμοποιώντας ασαφείς όρους και όχι σύμβολα ή αριθμούς. Οι ασαφείς αυτοί όροι αναπαριστούν γενικές κατηγορίες και όχι καθορισμένα εκ των προτέρων σύνολα. Η μετάβαση από μια κατηγορία – έννοια, ιδέα ή κατάσταση προβλήματος – στην επόμενη είναι σταδιακή, με κάποιες καταστάσεις να έχουν μεγαλύτερη ή μικρότερη συμμετοχή σε ένα σύνολο από ότι σε κάποιο άλλο. Χρησιμοποιώντας αυτή την έννοια των ελάχιστων συνόλων και επηρεαζόμενος από τα έργα των Black και Lukaiseiwicz, πρότεινε την ιδέα των ασαφών συνόλων, εισάγοντας έτσι και την ασαφή λογική.

Στην σημερινή εποχή, τα ασαφή συστήματα μπορούν να χρησιμοποιηθούν σε εκτιμήσεις, στη λήψη αποφάσεων, σε οικονομικά θέματα καθώς και σε μηχανικά συστήματα, όπως τα συστήματα κλιματισμού, ηλεκτρικοί υπολογιστές, ηλεκτρικές σκούπες, μηχανικά συστήματα αεροπλάνων και πολλές άλλες συσκευές.[29]

### **3.3 Χαρακτηριστικά Ασαφών Συνόλων**

Τα βασικά στοιχεία ενός ασαφούς συστήματος και τα οποία χρησιμοποιούνται στην λύση των όποιων προβλημάτων, είναι τα ακόλουθα:

- Μετατροπή(ασαφοποίηση) των δεδομένων εισόδου σε ασαφή στοιχεία
- Ανάπτυξη των κανόνων
- Επεξεργασία των κανόνων
- Μετατροπή των αποτελεσμάτων από ασαφή σε αριθμητικά στοιχεία (απασαφοποίηση)

#### **A) Ασαφοποίηση**

Η μετατροπή των αρχικών αριθμητικών δεδομένων των παραμέτρων εισόδου, σε ασαφή ορισμένα σε ένα διάστημα, χαρακτηρίζεται ως ασαφοποίηση. Οι αριθμοί που αντιστοιχούν στις μεταβλητές, αντικαθίστανται από λεκτικούς όρους (terms) ή προτάσεις και δημιουργούνται συναρτήσεις συμμετοχής αντίστοιχα για κάθε κριτήριο.

Οι συναρτήσεις συμμετοχής των ασαφών αριθμών παίρνουν σίγουρα την τιμή 1 σε ένα σημείο ή το πολύ σε ένα διάστημα. Αριστερά του διαστήματος αυτού είναι αύξουσες και δεξιά φθίνουσες. Με τη βοήθεια των λεκτικών μεταβλητών


διαμερίζουμε τα διαστήματα των τομών με ασαφή τρόπο και προσεγγίζουμε τη συνάρτηση του συστήματος. Οι συνηθέστερες μορφές συναρτήσεων συμμετοχής είναι οι ακόλουθες:

### 1. Τριγωνική συνάρτηση συμμετοχής

Η μαθηματική της μορφή δίνεται από την σχέση:

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

Όπου α,β,с κορυφές του τριγώνου, όπως θα φανεί στο ακόλουθο σχήμα.



Εικόνα 3.1:Υπόδειγμα τριγωνικής συνάρτησης συμμετοχής [29]


Στην τριγωνική συνάρτηση συμμετοχής επισημαίνεται η εύκολη και απλή απεικόνιση εκτιμήσεων τριών σημείων (μικρή, μεσαία, μεγάλη πιθανότητα). Μεταξύ των ακραίων τιμών και της αναμενόμενης, οι υπόλοιπες τιμές αποτελούν ενδιάμεσες καταστάσεις που υποδεικνύουν την απόκλιση από τις εκτιμήσεις, πάντα όμως, μέσα στο εύρος τιμών που ορίζονται από τα τρία σημεία.

### 2. Τραπεζοειδής συνάρτηση συμμετοχής.

Η μαθηματική έκφραση της συνάρτησης αποδίδεται από την ακόλουθη σχέση:

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

Στην περίπτωση αυτή, α,β,с και d αποτελούν τις κορυφές του τραπεζιού, όπως φαίνεται στο παρακάτω σχήμα:



Εικόνα 3.2:Υπόδειγμα τραπεζοειδούς συνάρτησης συμμετοχής [29]

Στην τραπεζοειδή συνάρτηση συμμετοχής, η πιθανότητα εμφάνισης απεικονίζεται στη βάση της εκτίμησης δυο διαστημάτων, εκείνου που ορίζει το εύρος του συνόλου των ενδεχομένων (μεγάλη πλευρά τραπεζίου) και εκείνου που ορίζει το εύρος των πλέον αναμενόμενων ενδεχομένων (μικρή πλευρά τραπεζίου). Οι υπόλοιπες πλευρές, όπως και στην τριγωνική συνάρτηση, αποτελούν ενδιάμεσες καταστάσεις που υποδεικνύουν την απόκλιση από τις εκτιμήσεις.

### 3. Συνάρτηση συμμετοχής Gauss και Bell

Στην εν λόγω περίπτωση μπορεί να υφίσταται για την συνάρτηση συμμετοχής η σχέση του Gauss:


$$\mu_{gauss} = (x; c, \sigma) = e^{-\left(\frac{x-c}{\sigma}\right)^2}$$

όπως και από την γενικευμένη μορφή της καμπύλης Bell που μαθηματικά περιγράφεται ως:

$$\mu_{gbell} = (x; a, b, c) = \frac{1}{1 + \left|\frac{x-c}{a}\right|^{2b}}, b > 0$$

όπου οι παράμετροι  $c, \sigma$  για τη συνάρτηση συμμετοχής Gauss και  $a, b, c$  για τη Bell καθορίζουν τις λεπτομέρειες της μορφής των συναρτήσεων συμμετοχής για το εκάστοτε σύστημα.

Στο ακόλουθο σχήμα φαίνονται ενδεικτικά, οι καμπύλες για τις συναρτήσεις συμμετοχής Gauss και Bell.



**Εικόνα 3.3:Υπόδειγμα συνάρτησης συμμετοχής Gauss και Bell [29]**

Γενικά, η απόδοση της συνάρτησης συμμετοχής αποτελεί μια υποκειμενική διαδικασία η οποία αντικατοπτρίζει τη γνώση ενός ή περισσότερων ειδικών, μπορεί δε να υποβοηθηθεί από διάφορες μεθόδους όπως: η μέθοδος του μέσου όρου, η μέθοδος της απόστασης, η μέθοδος της διαίσθησης, η μέθοδος της ψήφου, η μέθοδος της σχετικής προτίμησης και η δελφική μέθοδος

#### B) Κατασκευή κανόνων

Την ασαφοποίηση των δεδομένων εισόδου, ακολουθεί η κατασκευή των κανόνων. Ουσιαστικά πρόκειται για την σύνδεση εισόδου και εξόδου (αποτελεσμάτων) όπου αξιοποιούνται τα ασαφή πλέον στοιχεία κάθε μεταβλητής-κριτηρίου προκειμένου να αποδοθεί η βεβαιότητα καθορισμού του κανόνα. Επιπλέον αποδίδεται και το ποσοστό βεβαιότητας που δείχνει πόσο σημαντικός είναι ο κάθε κανόνας ως προς την εκπλήρωση του, μαζί με την σχετική σημαντικότητα των επιμέρους στοιχείων (λογικές προτάσεις) από τις οποίες αποτελείται.

#### Γ) Επεξεργασία κανόνων

Από την κατασκευή των κανόνων, η διαδικασία προχωρά στον επόμενο επίπεδο που είναι η επεξεργασία τους. Ουσιαστικά πρόκειται για μια διεργασία αξιολογής των κανόνων που επιτελείται σε τρία στάδια: τη συσσώρευση (aggregation), την σημαντικότητα (implication) και την συγκέντρωση (accumulation). Στην συσσώρευση αξιολογείται η εκπλήρωση του κάθε κανόνα μέσω της εκπλήρωσης των επιμέρους μεταβλητών του. Αυτό συντελείται με την επιλογή κατάλληλων τελεστών για το εκάστοτε πρόβλημα.

Στο στάδιο της σημαντικότητας υπολογίζεται η βεβαιότητα του συνόλου των κανόνων μέσω των βεβαιοτήτων του κάθε επιμέρους κανόνα. Στην περίπτωση όπου υπάρχει η μέγιστη βεβαιότητα δίνεται η μονάδα (1) και αντιστοιχεί σε σίγουρο αποτέλεσμα, γεγονός σχετικά σπάνιο. Το στάδιο αυτό συνδέει τα

ποσοστά βεβαιότητας του κάθε κανόνα με τον τελικό βαθμό εκπλήρωσής του και υλοποιείται εξίσου με την εφαρμογή κατάλληλων τελεστών.

Στο τελικό στάδιο της συγκέντρωσης, λόγω της ύπαρξης πολλών κανόνων που μπορούν να προσδώσουν ίδιο αποτέλεσμα με διαφορετικό βαθμό εκπλήρωσης, γίνεται η επιλογή ενός τελικού βαθμού εκπλήρωσης, πάλι μέσα από την επιλογή κατάλληλων τελεστών.

#### Δ) Απασαφοποίηση

Το αποτέλεσμα της επεξεργασίας των κανόνων είναι η παραγωγή μιας λεκτικής μεταβλητής. Από την εν λόγω μεταβλητή θα προκύψει το τελικό αποτέλεσμα το οποία μέσω της απασαφοποίησης θα παρασταθεί ως μια αριθμητικό αποτέλεσμα. Κυριότερη μέθοδος αυτής της μετατροπής είναι αυτή της μέγιστης τιμής η οποία περιλαμβάνει τις περιπτώσεις απασαφοποίησης: του μικρότερου των μεγίστων (Smallest of maxima – SOM), μεγαλύτερου των μεγίστων (Largest of maxima – LOM) ή του μέσου των μεγίστων (Middle of maxima – MOM).

### 3.4 Μορφές Ασαφών Συστημάτων

Ανάλογα με την μορφή των κανόνων υπάρχουν και κατάλληλα ασαφή συστήματα. Τα πιο γνωστά είναι τα αναφερόμενα:

- Τύπου Mamdani

Προσδιορίζεται ως ένας κανόνας της μορφής:

If **x** is **A** then **y** is **B**.

Οι έξοδοι των κανόνων αυτής της μορφής είναι ασαφή σύνολα.

- Τύπου Sugeno-Tagaki

Αποτελεί ένα κανόνα της μορφής:

If **x** is **A** then **y** is **c**.

Όπου το  $c$  είναι αριθμός ή ένα ασαφές σύνολο.

- Τύπου Sugeno-Tagaki-Kang

Είναι ένας από τους κυριότερους τύπους ασαφούς κανόνα και προσδιορίζεται από την μορφή:

If **x** is **A** then **y** is  $c_0+c_1x$ .

Όπου  $c_0, c_1 \in \mathbb{R}$ . Οι έξοδοι των κανόνων αυτής της μορφής είναι συναρτήσεις των εισόδων.[30]



### 3.5 Προσαρμοστικά νευρωνικά-ασαφή συστήματα συμπερασμού

Τόσο τα ασαφή συστήματα όσο και νευρωνικά δίκτυα, λογίζονται ως ισοδύναμα μοντέλα πρόβλεψης. Όμως κάθε μια από τις δυό αυτές μεθόδους διακρίνεται τόσο από πλεονεκτήματα όσο και από αδυναμίες κατά την εφαρμογή τους. Οι δύο προσεγγίσεις, αμφότερες, κατασκευάζουν μη-γραμμικά συστήματα βασισμένα πάνω σε συνεχείς μεταβλητές, με τη διαφορά ότι η μεταχείριση των νευρωνικών συστημάτων γίνεται με τρόπο αριθμητικό- ποσοτικό, ενώ η μεταχείριση των ασαφών συστημάτων γίνεται με τρόπο συμβολικό-ποιοτικό. Τα MLP ενώ διαθέτουν ικανότητα αυτομάθησης, υπολογιστική ικανότητα για περιπτώσεις πολλών μετρήσιμων δεδομένων δεν αναδεικνύουν τον τρόπο λήψης αποφάσεων, την γενικότερη δομή του δικτύου, λειτουργώντας ως «μαύρα κουτιά», ενώ η επιβολή εξωτερικής γνώσης στο σώμα ενός νευρωνικού δικτύου αναφορικά με ένα συγκεκριμένο πρόβλημα είναι αρκετά δύσκολη. Στην περίπτωση των ασαφών συστημάτων ενώ δεν απαιτείται ακρίβεια της πληροφορίας και εξηγείται η συμπεριφορά και ο τρόπος λήψης αποφάσεων του δικτύου/συστήματος, η όποια δυνατότητα υπολογισμών περιορίζεται σημαντικά αν δεν υπάρξει διαθέσιμη εξωτερική γνώση, ενώ ζητήματα όπως ο ακριβής διαμερισμός του χώρου εισόδων και εξόδων ενός προβλήματος σε ασαφή σύνολα, οι τιμές των παραμέτρων των συναρτήσεων συμμετοχής και ο ακριβής αριθμός των ασαφών κανόνων, έχουν ως αποτέλεσμα τον περιορισμό της σημαντικής ισχύος που χαρακτηρίζει την ασαφή λογική.

Με βάση τα παραπάνω δεδομένα ως προς τις ικανότητες και τις παθογένειες των δυό υπολογιστικών μοντέλων, κρίθηκε αναγκαία η δημιουργία υβριδικών μοντέλων τα οποία θα συνδυάζουν τα πλεονεκτήματα τόσο των MLP όσο και των ασαφών συστημάτων, περιορίζοντας ταυτόχρονα τις αδυναμίες τους. Συνεπακόλουθα αναπτύχθηκαν τριών ειδών υβριδικά μοντέλα:

- 1) Neural Fuzzy System : Σε αυτού του είδους τα συστήματα τα νευρωνικά δίκτυα χρησιμοποιούνται ως εργαλεία μέσα σε ένα ασαφές μοντέλο.
- 2) Fuzzy Neural Networks: Τα δίκτυα αυτά ουσιαστικά συνιστούν την ασαφοποίηση του συμβατικού μοντέλου νευρωνικού δικτύου.
- 3) Fuzzy-neural Hybrid System: Τα συστήματα αυτά συνίστανται στην ενσωμάτωση τεχνολογίας ασαφούς λογικής και νευρωνικών δικτύων σε υβριδικά συστήματα.

Στις δυό πρώτες κατηγορίες, ο συνδυασμός των MLP με τα ασαφή συστήματα επιτυγχάνεται παρέχοντας σε ένα νευρωνικό δίκτυο την ικανότητα χειρισμού ασαφούς πληροφορίας (fuzzy-neural network) και ενισχύοντας ένα ασαφές σύστημα με νευρωνικά δίκτυα, προκειμένου να βελτιωθούν χαρακτηριστικά, όπως η ευελιξία, η ταχύτητα και η προσαρμοστικότητα (neural-fuzzy systems). Οι διαφορές εντοπίζονται στο ότι στα FNN οι είσοδοι και τα βάρη των συνδέσεων και οι έξοδοι του δικτύου αποτελούν ασαφή υποσύνολα ή ένα σύνολο από τιμές συμμετοχής σε ασαφή σύνολα, ενώ στην περίπτωση των NFS ο σκοπός είναι η πραγματοποίηση της διαδικασίας ασαφούς συλλογιστικής (fuzzy reasoning), όπου τα βάρη των συνδέσεων του δικτύου αντιστοιχούν στις

παραμέτρους της ασαφούς συλλογιστικής, οπότε χρησιμοποιώντας αλγόριθμους μάθησης της μορφής backpropagation, το NFS μπορεί να αναγνωρίσει ασαφείς κανόνες και να "μάθει" τις συναρτήσεις συμμετοχής της ασαφούς συλλογιστικής.

Στην τρίτη περίπτωση, σε ένα πλήρως υβριδικό σύστημα οι ιδιότητες τόσο των MLP όσο και των ασαφών συστημάτων, χρησιμοποιούνται για την δραστηριοποίηση διαφορετικών λειτουργιών του συστήματος. Σε αυτήν την κατηγορία ανήκει το **ANFIS (Adaptive Network based Fuzzy Inference System Adaptive ή αλλιώς Adaptive Neuro Fuzzy Inference System)**. Εμπερικλείοντας το σύστημα ασαφούς συμπερασμού σε ένα πλαίσιο προσαρμοστικών δικτύων (adaptive networks), προκύπτει η δομή του ANFIS.

Τα κύρια χαρακτηριστικά υβριδικών συστημάτων όπως το ANFIS είναι:

- 1) Κατασκευή ευέλικτου, μη-τυπικού μοντέλου για τα δεδομένα εκπαίδευσης με τη μορφή ασαφών κανόνων (fuzzy rules).
- 2) Χρησιμοποίηση a priori γνώσης για το πρόβλημα.
- 3) Η αρχική γνώση μπορεί εύκολα να προσαρμοστεί βάσει των δεδομένων εκπαίδευσης με νευρωνικούς αλγόριθμους μάθησης.
- 4) Η γνώση είναι άμεσα προσπελάσιμη με τη μορφή κανόνων (rules). Οι κανόνες είναι της μορφής : Εάν (if) <συνθήκες (conditions) > τότε (then) <αποτελέσματα (consequents)>.
- 5) Ο τρόπος διατύπωσης των κανόνων είναι πολύ κοντά στην κοινή ανθρώπινη λογική και συνεπώς η δυνατότητα των ασαφών συστημάτων για παροχή επεξηγήσεων του τρόπου εξαγωγής ενός συμπεράσματος είναι εξαιρετικά αποτελεσματική.

### 3.6 Ιστορική αναδρομή των προσαρμοστικών νεύρο-ασαφών συστημάτων

Τα ολοκληρωμένα νεύρο-ασαφή συστήματα που παρουσιάζονται στην διεθνή βιβλιογραφία, ξεκινούν την δεκαετία του 70'. Ενδεικτικά παρουσιάζονται τα ακόλουθα:

Πρώτοι, το 1975, οι E.H. Mamdani and S. Assilian δημιουργούν το Mamdani Integrated Neuro-Fuzzy System το οποίο χρησιμοποιεί τον αλγόριθμο μάθησης backpropagation, προκειμένου να προσαρμόσει τις παραμέτρους των συναρτήσεων συμμετοχής.

Μετά από περίοδο 10 ετών, ο Sugeno (1985) χρησιμοποιεί το Takagi-Sugeno Integrated Neuro-fuzzy system όπου επίσης μέσω του αλγόριθμου μάθησης backpropagation πετυχαίνεται η προσαρμογή των συναρτήσεων συμμετοχής και την μέθοδο των ελαχίστων τετραγώνων για τον υπολογισμό του γραμμικού μέρους των κανόνων.

Στην δεκαετία του 90, πρώτος ο Lin, 1991, δημιουργεί το Fuzzy Adaptive Learning Control Network (FALCON). Μέσω του μηχανισμού συμπερασμού

Mamdani με αρχιτεκτονική πέντε επιπέδων, διαθέτει υβριδικό αλγόριθμο μάθησης είναι και εξελίσσεται σε δύο φάσεις. Στην αρχική φάση καθορίζονται τα κέντρα και τα βάρη των συναρτήσεων συμμετοχής με τεχνικές μάθησης self-organized, ενώ στη δεύτερη φάση εφαρμόζεται ο αλγόριθμος backpropagation για την προσαρμογή των παραμέτρων των συναρτήσεων συμμετοχής.

Το 1993 ο J.-S.R. Jang δημιούργησε το **Adaptive Network based Fuzzy Inference System (ANFIS)**. Το ANFIS ανήκει στα προσαρμοστικά δίκτυα (adaptive networks), τα οποία ομοιάζουν με τα νευρωνικά δίκτυα. Διαθέτοντας προσαρμοστικούς και μη κόμβους συνδεδεμένοι μέσω κατευθυντήριων συνδέσμων. Ουσιαστικά πρόκειται για πολύ-επίπεδο δίκτυο πρόσθιας τροφοδότησης (multi-layer feed-forward network), όπου κάθε κόμβος εκτελεί μια μία συγκεκριμένη λειτουργία πάνω στα εισερχόμενα σήματα και πάνω στο σύνολο των παραμέτρων που τον καθορίζουν, ενώ στους κόμβους που θεωρούνται προσαρμοστικοί, ο κανόνας μάθησης προσδιορίζει πώς αυτοί οι παράμετροι θα πρέπει να μεταβληθούν για την ελαχιστοποίηση ενός προκαθορισμένου μέτρου σφάλματος.

Ένα χρόνο μετά οι D. Nauck, and R. Kruse δημιουργούν το Neuro-Fuzzy Controller (NEFCON). Έχει την δυνατότητα να μαθαίνει ασαφή σύνολα και ασαφής κανόνες χρησιμοποιώντας τον μηχανισμό συμπερασμού Mamdani. Η διαδικασία μάθησης χωρίζεται σε δύο φάσεις. Στην πρώτη φάση το σύστημα μαθαίνει τους κανόνες και στη δεύτερη φάση βελτιστοποιεί τους κανόνες μεταβάλλοντας τα ασαφή σύνολα των κανόνων.

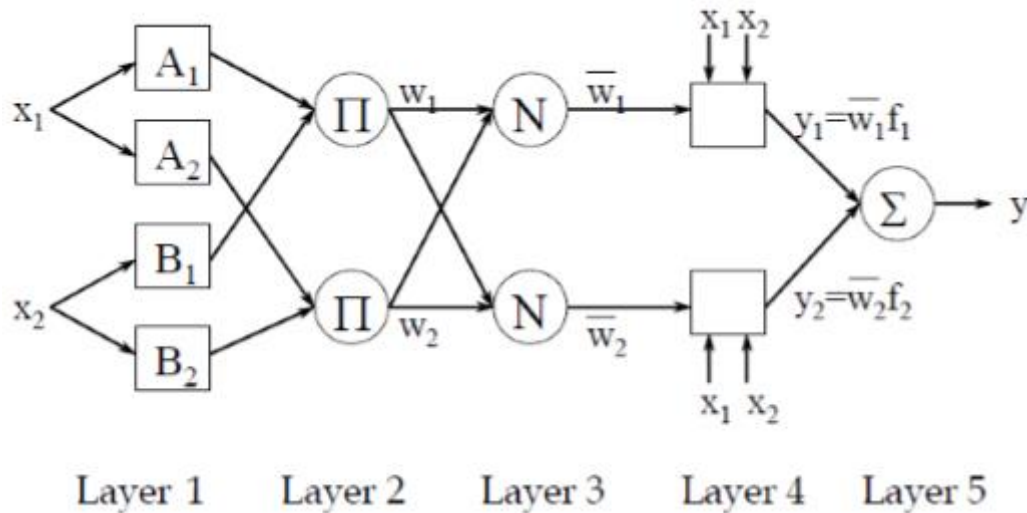
Ακριβώς στα μισά της δεκαετίας του 90 ο Nauck, 1995, αναπτύσσει το Neuro-Fuzzy Classification (NEFCLASS). Το σύστημα εξάγει ασαφείς κανόνες από τα δεδομένα τα οποία μπορούν να διαιρεθούν σε σαφείς περιοχές (ταξινόμηση). Η βάση δεδομένων του συστήματος προσεγγίζει μια άγνωστη συνάρτηση  $f$  η οποία αναπαριστά το πρόβλημα της ταξινόμησης και αντιστοιχίζει κάθε τιμή της εισόδου  $x$  στην τάξη της  $C_i$ . Επίσης το 1999 ο ίδιος αναπτύσσει το Neuro-Fuzzy Function Approximation (NEFPROX), (Nauck, 1999). Αποτελεί μια τροποποιημένη έκδοση του NEFCON χωρίς την reinforcement μάθηση και χρησιμοποιείται για να προσεγγίσει μια συνάρτηση. Σε σχέση με το ANFIS μπορεί να χρησιμοποιήσει εκτός από Sugeno και Mamdani μηχανισμό συμπερασμού.[28]

### **3.7 Αρχή λειτουργίας και αρχιτεκτονική του ANFIS**

Όπως αναφέρθηκε και στην ενότητα της ιστορικής αναδρομής, το ANFIS αποτελεί ένα προσαρμοστικό δίκτυο που εμφανίζει ομοιότητα με τα τυπικά MLP. Αποτελείται από προσαρμοστικούς και μη προσαρμοστικούς κόμβους. Το σύνολο των κόμβων εκτελεί μια λειτουργία τόσο απέναντι στις εισερχόμενες πληροφορίες, όσο και στις παραμέτρους που τους καθορίζουν, ενώ η σύνδεση των κόμβων μεταξύ τους επιτυγχάνεται μέσω κατευθυντήριων συνδέσμων. Όπως αναφέρθηκε αριθμός κόμβων του συστήματος χαρακτηρίζονται ως προσαρμόσιμοι, που σημαίνει ότι οι παράμετροι καθορισμού των κόμβων αυτών μπορούν να μεταβληθούν, μέσω ενός κανόνα μάθησης, επιδιώκοντας την ελαχιστοποίηση ενός προκαθορισμένου μέτρου σφάλματος.

Η απεικόνιση ενός τέτοιου δικτύου, απαιτεί κατάδειξη με διαφορετικό τρόπο των διαφορετικών ικανοτήτων προσαρμοστικότητας. Όπως θα γίνει εμφανές στο ακόλουθο σχήμα, ενδεικτικά ένας προσαρμοστικός κόμβος (adaptive node)

απεικονίζεται με τετράγωνο, σε αντίθεση με έναν μη προσαρμοστικό (fixed node) που απεικονίζεται με κύκλο. Οι παράμετροι των προσαρμοστικών κόμβων ενημερώνονται κατάλληλα, σύμφωνα με τα δοσμένα δεδομένα εκπαίδευσης και μία gradient based διαδικασία μάθησης, μοντέλο Sugeno στην περίπτωση του ANFIS, προκειμένου να επιτευχθεί μία επιθυμητή αντιστοίχιση μεταξύ των δεδομένων εισόδου-εξόδου.



Εικόνα 3.4: Η αρχιτεκτονική δομή του ANFIS [28]

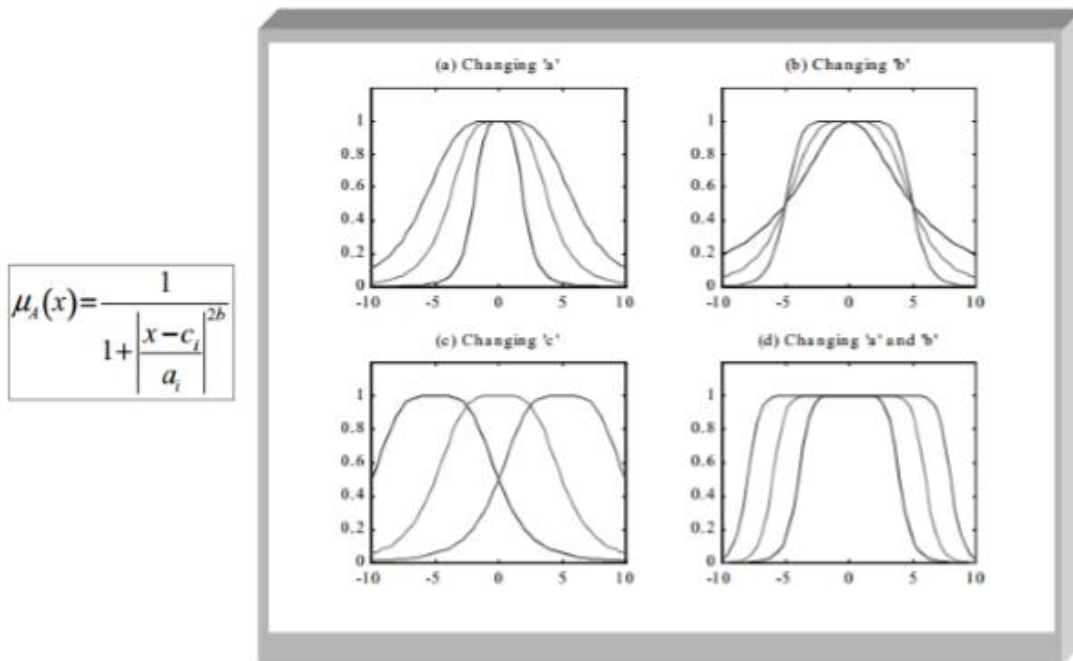
Με βάση την παραπάνω διάταξη του ANFIS, θα αναλυθούν κάθε ένα από τα 5 επίπεδα που το αποτελούν.

**Layer 1:** Οι κόμβοι αυτού του επιπέδου θεωρούνται προσαρμοστικοί-μη γραμμικοί έχοντας συνάρτηση κόμβου:

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

$$O_{1,i} = \mu B_{i-2}(y) \text{ για } i = 3,4$$

Το μέγεθος εκφράζει τον βαθμό συμμετοχής του A, με 1) x,y την είσοδο στον κόμβο και 2) Ai(ή Bi-2) την γλωσσική μεταβλητή (small, large, κλπ.) που σχετίζεται με αυτή τη συνάρτηση του κόμβου. Εδώ η συνάρτηση συμμετοχής για το A μπορεί να είναι οποιαδήποτε κατάλληλη παραμετρική συνάρτηση συμμετοχής. Καθώς οι τιμές των παραμέτρων των κόμβων αλλάζουν, οι συναρτήσεις ποικίλλουν ανάλογα, παρουσιάζοντας έτσι διάφορες μορφές της συνάρτησης συμμετοχής για το ασαφές σύνολο A. Οι παράμετροι σε αυτό το επίπεδο αναφέρονται ως αρχικές παράμετροι (premise parameters).



Εικόνα 3.5: Γραφική αναπαράσταση της επίδρασης που έχει η αλλαγή των παραμέτρων a, b και c [28]

**Layer 2:** Οι κόμβοι αυτού του επιπέδου θεωρούνται σταθεροί έχοντας ως συνάρτηση κόμβου την ακόλουθη:

$$O_{2,i} = w_i = \mu_{A_i}(x_1) \mu_{B_i}(x_2) \quad (\text{για } i=1,2)$$

Κάθε κόμβος-έξοδος αντιπροσωπεύει το βαθμό ενεργοποίησης ενός κανόνα (firing strength), ενώ η έξοδος είναι το γινόμενο όλων των εισερχόμενων σημάτων.

**Layer 3:** Στο 3<sup>ο</sup> επίπεδο κάθε κόμβος είναι ένας σταθερός κόμβος N. Επίσης σε αυτό το επίπεδο πραγματοποιείται η κανονικοποίηση των βαθμών ενεργοποίησης. Ο i-ιστός κόμβος υπολογίζει το λόγο της βαθμού ενεργοποίησης (firing strength) του i-οστού κανόνα στο άθροισμα των βαθμών ενεργοποίησης όλων των κανόνων. Η συνάρτηση κόμβου είναι η ακόλουθη:

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

**Layer 4:** Οι κόμβοι αυτού του επιπέδου θεωρούνται προσαρμόσιμοι-γραμμικοί έχοντας ως συνάρτηση κόμβου την ακόλουθη:

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i)$$

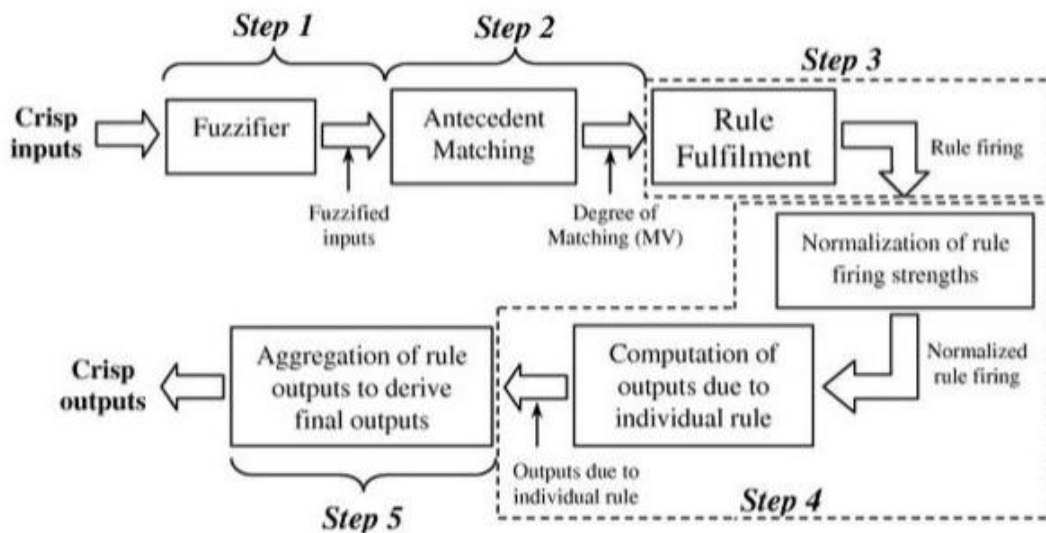
Όπου  $w_i$  είναι ο κανονικοποιημένος βαθμός ενεργοποίησης από το επίπεδο 3, και  $p_i, q_i, r_i$  οι παράμετροι της συνάρτησης.

**Layer 5:** Σε αυτό το επίπεδο υφίσταται ένας κόμβος, που είναι σταθερός, υπολογίζοντας τη συνολική έξοδο σαν το ολικό άθροισμα όλων των

εισερχόμενων σημάτων. Ο συγκεκριμένος «τελικός» κόμβος έχει ως συνάρτηση την ακόλουθη:

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

Συμπερασματικά, η αρχιτεκτονική του μοντέλου ANFIS έχει δύο προσαρμοστικά στρώματα: Τα στρώματα 1 και 4. Το στρώμα 1 έχει τροποποιήσιμες παραμέτρους  $(a_i, b_i, c_i)$  και  $(a_j, b_j, c_j)$  που σχετίζονται με τις συναρτήσεις συμμετοχή εισαγωγής. Το στρώμα 4 έχει τροποποιήσιμες παραμέτρους  $(p_{ij}, q_{ij}, r_{ij})$  που ανήκουν στο πολυώνυμο πρώτου βαθμού.



Εικόνα 3.6:Υπολογιστική πολυπλοκότητα του συστήματος ANFIS [28]

### 3.8 Εκπαίδευση του μοντέλου ANFIS

Από την προηγούμενη ενότητα συμπεραίνεται, ότι οι παράμετροι των κόμβων που μπορούν να μεταβληθούν κατά την εκπαίδευση ανήκουν στους προσαρμοστικούς κόμβους. Συγκεκριμένα στους μη γραμμικούς του 1<sup>ου</sup> layer και στους γραμμικούς του 4<sup>ου</sup> layer.

Αν το σύνολο των παραμέτρων είναι  $S$  τότε θα ισχύει:

$$S = S_1 \cup S_2$$

Όπου  $S_1$  το σύνολο των μη γραμμικών παραμέτρων και  $S_2$  το αντίστοιχο των γραμμικών.

Η εκπαίδευση του δικτύου πραγματοποιείται μέσω ενός αλγόριθμου εκπαίδευσης που αποτελείται από δύο στάδια:

- 1) Διάδοση προς τα εμπρός: Οι μη γραμμικοί παράμετροι παραμένουν σταθεροί και το δίκτυο παράγει εξόδους μέχρι το 4<sup>ο</sup> layer, όπου οι γραμμικοί παράμετροι προσδιορίζονται με την μέθοδο των ελαχίστων τετραγώνων.

- 2) **Διάδοση προς τα πίσω:** Τα σήματα σφάλματος (η διαφορά πραγματικής από την επιθυμητή έξοδο), Η διάδοση γίνεται προς τα πίσω με τις γραμμικές παραμέτρους να παραμένουν σταθερές. Οι μη γραμμικές μεταβάλλονται με βάση τον «αλγόριθμο μέγιστης κλίσης».

### Αλγόριθμος μέγιστης κλίσης

Το κεντρικό μέρος αυτού του κανόνα εκμάθησης αφορά στο πως να επιλεγεί επαναληπτικά ένα διάνυσμα κλίσης στο οποίο κάθε στοιχείο ορίζεται ως η παράγωγος ενός μέτρου σφάλματος ως προς μια παράμετρο. Η διαδικασία εύρεσης ενός διανύσματος κλίσης σε ένα δίκτυο αναφέρεται γενικά σαν οπισθοδρόμηση (backpropagation) επειδή το διάνυσμα κλίσης υπολογίζεται σε κατεύθυνση αντίθετη από τη ροή της εξόδου κάθε κόμβου. Μόλις επιλεγεί η κλίση, διάφορες τεχνικές βελτιστοποίησης και παλινδρόμησης βασισμένες στις παραγώγους είναι διαθέσιμες για την ενημέρωση των παραμέτρων

Για την οποιαδήποτε μη γραμμική παράμετρο  $\alpha_i$ , η μεταβολή της δίνεται από την ακόλουθη σχέση:

$$\Delta\alpha_i = -\eta \frac{\partial + E}{\partial\alpha_i}$$

Όπου ο ρυθμός εκπαίδευσης  $\eta$ , υπολογίζεται από το μέγεθος βήματος  $\kappa$  μέσω του τύπου:

$$\eta = \frac{\kappa}{\sum_i \left(\frac{\partial E}{\partial\alpha_i}\right)^2}$$

### 3.9 Προϋποθέσεις εφαρμογής του μοντέλου ANFIS

- Βασίζονται σε ένα FIS τύπου Sugeno.
- Έχουν μια έξοδο, που λαμβάνεται με τη μέθοδο αποσαφήνισης σταθμισμένου μέσου.
- Όλες οι συναρτήσεις συμμετοχής εξόδου πρέπει να είναι ίδιου τύπου, είτε γραμμικές είτε σταθερές.
- Δεν μπορεί να γίνεται κοινή χρήση κανόνων. Διαφορετικοί κανόνες δεν μπορούν να έχουν την ίδια συνάρτηση συμμετοχής εξόδου.
- Πρέπει να υπάρχουν βάρη σε κάθε κανόνα.
- Δεν μπορεί να χρησιμοποιηθεί οποιαδήποτε συνάρτηση συμμετοχής, παρά μόνο προκαθορισμένοι τύποι συναρτήσεων που επιβάλλουν οι ορισμοί ενός μοντέλου ANFIS.

### 3.10 Επισκόπηση πρότερων εργασιών σχετικά με το μοντέλο ANFIS

Αν και η ανάπτυξη των ασαφών και νεύρο-ασαφών δικτύων γίνεται έντονη την δεκαετία του 90', η χρησιμοποίηση του ANFIS στην μηχανολογία και ιδιαίτερα σε θέματα κατεργασιών αφαίρεσης υλικού, συντελείται στις επόμενες δεκαετίες και κυρίως στην τρέχουσα. Παρόλο που η χρήση του ANFIS δεν έχει γνωρίσει αντίστοιχη έκταση όπως αυτή των MLP, εντοπίζονται τα τελευταία χρόνια χαρακτηριστικές περιπτώσεις χρήσης, σε προσδιορισμό παραμέτρων κοπής στις κατεργασίες αφαίρεσης υλικού. Επίσης πρέπει να τονισθεί ότι η διαδικασία υπολογιστικά εκτελέστηκε σε περιβάλλον προγραμματισμού MATLAB.

- Το 2012 οι A.M.Abdulshahed, A.P.Longstaff και S.Fletcher επιχείρησαν τον προσδιορισμό του μηχανισμού προστασίας CNC εργαλείου κοπής, από αστοχίες λόγω θερμότητας. Χρησιμοποιήθηκε ως υπολογιστικό μοντέλο πρόβλεψης το ANFIS, σε δύο εκδοχές i) ως GRID-ANFIS ταξινομώντας τα δεδομένα εκπαίδευσης σε ορθογωνικά υπό-διαστήματα, και ii) ως ANFIS-FCM με την χρήση της μεθόδου fuzzy c-means. Η διαδικασία συντελέστηκε σε CNC εργαλειομηχανή φρεζαρίσματος με μεταβλητή ταχύτητα περιστροφής από 60 έως και 8000RPM, ενώ τοποθετήθηκαν 76 αισθητήρες θερμοκρασίας σε διάφορα σημεία της εργαλειομηχανής, όπου πέντε εξ'αυτών προσδιορίστηκαν ως οι πιο σημαντικοί στην καταγραφή της φαινομένου. Έγιναν συνολικά 7 δοκιμές συνδυασμού θέρμανσης και ψύξης σε διάφορες ταχύτητες περιστροφής, χρησιμοποιήθηκαν όλοι οι πιθανοί αριθμοί (1-5) των σημαντικότερων αισθητήρων σε διάφορες επαναλήψεις (epochs), ενώ με βάση τους 3 άξονες κοπής του κοπτικού εργαλείου (X,Y,Z) προσδιορίστηκαν τα σφάλματα στους άξονες Z και Y με έμφαση στο, σε ρίζα μέσο τετραγωνικό σφάλμα (RMSE), στην συσχέτιση  $R^2$  και στην απόκλιση (residual value). Από τα αποτελέσματα διαπιστώθηκε ότι, η εκδοχή ANFIS-FCM παρουσίασε ανώτερη απόδοση από την ANFIS-GRID σε κάθε περίπτωση έχοντας τα βέλτιστα αποτελέσματα στην 2<sup>ο</sup> δοκιμή (3 ώρες θέρμανση με 2 ώρες ψύξη και ταχύτητα περιστροφής 4000RPM) με  $RMSE=0,57$ ,  $R^2=0,99$  και απόκλιση +/- 2 $\mu$ m.[31]
- Ένα χρόνο αργότερα (2013) οι K.A.Ghamdi και O.Taylan μέσω του ANFIS, μελέτησαν το φαινόμενο του ρυθμού αποβολής υλικού σε κατεργασία EDM. Το ANFIS εφαρμόστηκε συγκριτικά με υπολογιστική μέθοδο πολυωνύμου, σε δοκίμιο από κράμα Ti-6Al-4V. Η πολυωνύμου συνδυάστηκε με την μέθοδο ANOVA χρησιμοποιώντας ως μεταβλητές εισόδου το υλικό του ηλεκτρόδιου και τα on σήματα, ενώ αναπτύχθηκαν 5 εκδοχές του ANFIS με 6, 9, 19, 21 και 51 κανόνες αντίστοιχα και μεταβλητές εισόδου το ονομαστικό ρεύμα, τα on/off σήματα και το υλικό του ηλεκτροδίου. Το πείραμα πραγματοποιήθηκε σε ONA D-2030-S EDM μηχανή και τα δοκίμια αποτελούνταν από μπάρες κυλινδρικές μήκους 15mm και διαμέτρου 20mm, ενώ τα ηλεκτρόδια αποτελούνταν από υλικά όπως αλουμίνιο, γραφίτη και χαλκό. Τα αποτελέσματα έδειξαν ανωτερότητα του ANFIS έναντι του πολυωνυμικού υπολογιστικού μοντέλου, με τα βέλτιστα αποτελέσματα να επιτυγχάνεται για το ANFIS των 21 κανόνων με σφάλμα εκπαίδευσης % περίπου στο 1,55 και



συσχέτιση R στο 0,99, όταν τα αντίστοιχα αποτελέσματα για το πολυωνυμικό μοντέλο ήταν 10,45 και 0,93.[32]

- Το 2015 οι I.Maher, L.H.Ling, A.A.D.Sarhan και M.Hamdi χρησιμοποίησαν το ANFIS επίσης σε κατεργασία EDM. Η διαφοροποίηση έγκειται, ότι στην εν λόγω περίπτωση το ANFIS εφαρμόστηκε, για τον προσδιορισμό παραμέτρων κοπής, όπως της ταχύτητας κοπής, της επιφανειακής τραχύτητας και της θερμικής ζώνης παραμόρφωσης του δοκιμίου. Ως μεταβλητές εισόδου λογίστηκαν το μέγιστο ρεύμα, τα on σήματα και η ένταση του ρεύματος, με το δοκίμιο να αποτελείται από υλικό AISI 1050 carbon steel. Έγιναν συνολικά 18 συνδυασμοί τιμών των προαναφερθέντων μεταβλητών εισόδου με ισάριθμα πειραματικά αποτελέσματα για τα 3 ζητούμενα μεγέθη. Το ANFIS αναπτύχθηκε με βάση 2 συναρτήσεις συμμετοχής του μέγιστου ρεύματος, και 6 συναρτήσεις (3+3) των on σημάτων και της έντασης του ρεύματος, ενώ ως συνάρτηση συμμετοχής επιλέχθηκε αυτή των Gauss/Bell με 18 ασαφείς κανόνες. Τα αποτελέσματα κατέδειξαν σφάλμα % για την ταχύτητα κοπής, επιφανειακή τραχύτητα και ζώνη θερμικής παραμόρφωσης σε 3,41 3,89 και 4,10 αντίστοιχα.[33]
- Ένα χρόνο αργότερα, 2016, οι B.Sen, U.K.Mandal και S.P.Mondal μέσω του ANFIS αποπειράθηκαν επίσης να προβλέψουν τις παραμέτρους κοπής, αλλά σε κατεργασία CNC φρεζαρίσματος και επιπλέον να υπάρξει μια συγκριτική μελέτη μέσω της ταυτόχρονης εφαρμογής MLP στην ίδια διαδικασία. Συγκεκριμένα τα ζητούμενη μεγέθη αποτέλεσαν η επιφανειακή τραχύτητα, οι δυνάμεις κοπής και η θερμοκρασία κοπής με τα δοκίμια να αποτελείται από υλικό Inconel 690 και το κοπτικό εργαλείο αντίστοιχα, από κυβικό Βόριο-νιτρίδιο. Η πειραματική διεργασία έγινε σε CNC φρεζομηχανή τριών αξόνων, όπου σε αριθμό 29 δοκιμών διαστάσεων μήκοςxπλάτοςxύψος, να είναι 50x32x32mm, ενώ χρησιμοποιήθηκε οι μέθοδοι σχεδιασμού πειραμάτων DOE και ANOVA. Ως δεδομένα εισόδου επιλέχθηκαν η ταχύτητα κοπής, η πρόωση, το βάθος και το πλάτος κοπής, ενώ χρησιμοποιήθηκαν για την ανάλυση 29 ζεύγη δεδομένων εκ των οποίων τα 15 για εκπαίδευση του δικτύου και τα υπόλοιπα για την γενίκευση και έλεγχο, με κριτήριο τα σφάλματα RMSE και MAPE και την συσχέτιση R. Τα αποτελέσματα κατέδειξαν οριακή ανωτερότητα του ANFIS έναντι του MLP και στα τρία ζητούμενα μεγέθη. Συγκεκριμένα: για την επιφανειακή τραχύτητα το ANFIS είχε RMSE 0,455%, MAPE 3,880% και R 0,977, ενώ αντίστοιχα το MLP είχε RMSE 0,564%, MAPE 4,587% και R 0,966 , για τις δυνάμεις κοπής το ANFIS είχε RMSE 0,045%, MAPE 4,684% και R 0,989, ενώ το MLP είχε RMSE 0,050%, MAPE 4,875% και R 0,956, ενώ τέλος για την θερμοκρασία κοπής το ANFIS είχε RMSE 0,746%, MAPE 7,456% και R 0,946, ενώ το MLP είχε RMSE 0,759%, MAPE 6,998% και R 0,945.[34]
- Το 2017 οι H.W.Chiu και C.H.Lee, επίσης σε κατεργασία CNC φρεζαρίσματος, δοκίμασαν μέσω του ANFIS να προσδιορίσουν παραμέτρους όπως η ακρίβεια της κατεργασίας και η ποιότητα επιφάνειας του κατεργαζόμενου τεμαχίου. Ως δεδομένα εισόδου

ελήφθησαν οι μέγιστες τιμές χαρακτηριστικών του CNC ελεγκτή όπως η επιτάχυνση και η υπέρ-επιτάχυνση, ο ρυθμός πρόωσης και η περιφερειακή επιτάχυνση με την πειραματική διαδικασία να λαμβάνει μέρος σε φρεζομηχανή CNC 5 αξόνων. Συλλέχθηκαν 113 μετρήσεις εκ των οποίων το 90% εκπαίδευσε το ANFIS και το υπόλοιπο χρησιμοποιήθηκε για τον έλεγχο του δικτύου, ενώ το κριτήριο απόδοσης αποτέλεσε το σφάλμα RSME. Ο έλεγχος του δικτύου κατέδειξε για την ακρίβεια της κατεργασίας και την ποιότητα επιφάνειας RSME 0,000911 και 0,002062 αντίστοιχα, ενώ τα ποσοστιαία σφάλματα ήταν κάτω από 9% και 5%, γεγονός που αποδεικνύει την ικανότητα του ANFIS ως μαθηματικό μοντέλο πρόβλεψης.[35]

Στην περίπτωση της κατεργασίας διάτρησης υπήρξαν επίσης προσπάθειες εφαρμογής του ANFIS (με την υπολογιστική διαδικασία πάντα να εκτελείται σε περιβάλλον προγραμματισμού MATLAB), όπου τα προς διερεύνηση μεγέθη αποτέλεσαν παράμετροι όπως και στις προαναφερθέντες περιπτώσεις των άλλων μορφών κατεργασιών.

- Το 2010 οι S.S.Gill και J.Singh σε κατεργασία ultrasonic διάτρησης κεραμικών υλικών εφάρμοσαν το ANFIS, για την πρόβλεψη του ρυθμού αφαίρεσης υλικού κατά την διαδικασία. Το βάθος, ο χρόνος και ο ρυθμός διείσδυσης χρησιμοποιήθηκαν ως μεταβλητές εισόδου, ενώ ως ζητούμενο μέγεθος ο προαναφερθείς ρυθμός αφαίρεσης υλικού (MRR). Οι παράμετροι εισόδου με τα ακόλουθα εύρη τιμών- 0,1 έως 2,9mm, 0,33-19,9min και 0,15-0,28mm/min, για το βάθος, χρόνο και ρυθμό διείσδυσης αντίστοιχα- σε 4 συνδυασμούς μεταξύ τους, ενώ ως συνάρτηση συμμετοχής επιλέχθηκε να είναι αυτή του Gauss. Χρησιμοποιήθηκε δοκίμιο πάχους 2,9mm με το κοπτικό εργαλείο από χάλυβα υψηλής αντοχής να διανοίγει οπές εξωτερικής και εσωτερικής διαμέτρου 6,01 και 5,01mm αντίστοιχα. Δημιουργήθηκαν 29 πειραματικά δεδομένα, ενώ ως κριτήριο απόδοσης εφαρμόστηκε το τέστ χ<sup>2</sup>. Η κατάληξη της συνολικής διαδικασίας κατέδειξε ένα μέσο συνολικό σφάλμα του 2,155% με ακρίβεια πάνω από 97%, αποτελέσματα αντιπροσωπευτικά της επιτυχίας χρήσης του ANFIS ως μοντέλου πρόβλεψης.[36]
- Το 2014 οι S.Prakash, J.L.Mercy, P.V.S.Teja και P.Vijayalakshmi εφάρμοσαν το ANFIS στην μελέτη του φαινομένου αποκόλλησης, σε ξύλινο υλικό μέτριας πυκνότητας σε ανθρακονήματα. Ως δεδομένα εισόδου επιλέχθηκαν η πρόωση, η ταχύτητα κοπής και η διάμετρος του τρυπανιού σε τρεις συνδυασμούς τιμών μεταξύ τους, ενώ το κριτήριο απόδοσης αποτέλεσε επίσης σε αυτή την περίπτωση το σφάλμα RSME. Τα πειράματα διεξήχθησαν σε κέντρο διάτρησης CNC με το υλικό του τρυπανιού να αποτελείται από καρβίδια. Το ANFIS αναπτύχθηκε με 27 συναρτήσεις συμμετοχής, ενώ δοκιμάστηκαν όλες οι δυνατές περιπτώσεις όπως η τριγωνική, η τραπεζοειδής, και οι συναρτήσεις Gauss και Bell. Εκτελέστηκαν 50 επαναλήψεις ως μέγιστος αριθμός ενώ η τριγωνική συνάρτηση συμμετοχής αποδείχθηκε η καταλληλότερη για το ANFIS επιδεικνύοντας σφάλμα RSME ίσο με  $1,292 \cdot 10^{-6}$ , αποτέλεσμα λίαν

ενδεικτικό της επιτυχίας εφαρμογής του ANFIS ως μαθηματικό μοντέλο πρόβλεψης.[37]

- Το ίδιο έτος οι K.Abhishek, B.N.Panda, S.Datta και S.S.Mahapatra προσπάθησαν να προσδιορίσουν την επιφανειακή τραχύτητα και την δύναμη ώθησης, σε συνθετικά πολυμερή υλικά από υαλοβάμβακα. Για αυτό τον σκοπό η ταχύτητα ατράκτου, ο ρυθμός πρόωσης, το πάχος του δοκιμίου και η διάμετρος του τρυπανιού θεωρήθηκαν ως μεταβλητές εισόδου σε 16 διαφορετικούς συνδυασμούς τιμών μεταξύ τους, την λήψη ισάριθμων πειραματικών αποτελεσμάτων των δύο ζητούμενων παραμέτρων και την όλη διαδικασία να συντελείται σε μηχανή διάτρησης CNC.. Το ANFIS μαζί με τον γενετικό αλγόριθμο GP εφαρμόστηκαν συγκριτικά, ως μοντέλα πρόβλεψης όπως επίσης χρησιμοποιήθηκε η μέθοδος σχεδιασμού πειραμάτων κατά Taguchi. Έχοντας ως κριτήριο απόδοσης το ποσοστιαίο σφάλμα συσχέτισης, και στις δύο περιπτώσεις η μέθοδος του ANFIS είχε υπέρτερα αποτελέσματα από αυτήν του γενετικού αλγόριθμου GP.[38]
- Το 2016 οι L.H.Saw, L.W.Ho, M.C.Yew, F.Yusof, N.A.Pambudi, T.C.Ng και M.K.Yew, εξίσου σε εφαρμογή του ANFIS, ερεύνησαν το φαινόμενο της φθοράς του κοπτικού εργαλείου. Λαμβάνοντας ως δεδομένα εισόδου την ταχύτητα ατράκτου, το ρυθμό πρόωσης, την μέση «ποσοτικά» φθορά και την διάμετρο του τρυπανιού, επιχείρησαν να προσδιορίσουν ως ζητούμενα μεγέθη, την ροπή και την δύναμη ώθησης. Μέσα από 12 διαφορετικούς συνδυασμούς των 4 παραμέτρων εισόδου, 27 σετ μετρήσεων επιλέχθηκαν για την εκπαίδευση των δικτύων και άλλα 15 για τον έλεγχο, με τα κριτήρια απόδοσης να αποτελούν το σφάλμα RMSE. Τα αποτελέσματα έδειξαν ότι το ANFIS με τριγωνική συνάρτηση συμμετοχής, παρουσίασε ελάχιστο σφάλμα 0,0855 τιμή άκρως αποδεκτή για τους στόχους της διαδικασίας.[39]

## Κεφάλαιο 4

### ΕΦΑΡΜΟΓΗ ΤΩΝ ANN/ANFIS/RBF ΣΤΗΝ ΚΑΤΕΡΓΑΣΙΑ ΔΙΑΤΡΗΣΗΣ

#### 4.1 Περιγραφή πειραματικής διαδικασίας

Στην εν λόγω διπλωματική εργασία ο στόχος είναι η πρόβλεψη του παράγοντα αποκόλλησης και της δύναμης ώσης κατά την διάτρηση, μέσω της συγκριτικής δοκιμής συνήθους νευρωνικού δικτύου MLP, νεύρο-ασαφούς συστήματος ANFIS αλλά και νευρωνικού δικτύου RBF. Για την ικανοποίηση αυτού του στόχου, χρησιμοποιήθηκαν δεδομένα από πειράματα, σε δοκίμια από πολυστρωματικά σύνθετα υλικά πολυμερικής μήτρας με ενίσχυση ανθρακονήματος που αποτελείται από 12 στρώσεις για δύο περιπτώσεις όπου αλλάζουν οι παράμετροι κατεργασίας. Τα δύο δοκίμια χαρακτηρίζονται ως 1) C6-W-03 και 2) C6-W-01.



Εικόνα 4.1: Δοκίμιο C6-W-03 [40]



**Εικόνα 4.2:Δοκίμιο C6-W-01 [40]**

Για την διάτρηση των δύο δοκιμίων χρησιμοποιήθηκαν τρυπάνια διαμέτρων: 2mm, 3mm, 4mm και 5mm. Τα υλικά των τρυπανιών αποτελούνται από α) μίγμα ταχυάλυβα-κοβαλτίου (HSS-Co) και β) μίγμα ταχυάλυβα-καρβιδίου (HSS-CC). Το δοκίμιο C6-W-03 θα υποστεί κατεργασία από το τρυπάνι HSS-Co, ενώ το δοκίμιο C6-W-01 από το τρυπάνι HSS-CC. [40]



Εικόνα 4.3: Τρυπάνια HSS-Co, από αριστερά προς δεξιά  $\Phi 2$ ,  $\Phi 3$ ,  $\Phi 4$ ,  $\Phi 5$  αντίστοιχα [40]



Εικόνα 4.4: Τρυπάνια HSS-CC, από αριστερά προς δεξιά  $\Phi 2$ ,  $\Phi 3$ ,  $\Phi 4$ ,  $\Phi 5$  αντίστοιχα [40]

Η διαδικασία της διάτρησης έγινε σε φρεζομηχανή CNC. Το κάθε δοκίμιο συγκρατήθηκε με μία μέγγενη, η οποία ήταν πάνω στη μετρητική πλάκα, που συγκρατούνταν στην τράπεζα της εργαλειομηχανής. Για τη συγκράτηση των τρυπανιών κατά τη διάρκεια της διάτρησης χρησιμοποιήθηκε ένας εργαλειοδέτης (ξεχωριστός ειδικά για τα μικρά τρυπάνια Φ2). [40]



Εικόνα 4.5: Φρεζομηχανή CNC [40]



Εικόνα 4.6: Διάταξη συγκράτησης δοκιμίου-μέγγενη-και μετρητική πλάκα συγκρατημένη στην τράπεζα της εργαλειομηχανής [40]



Εικόνα 4.7: Διάταξη συγκράτησης δοκιμίου-μέγγενη [40]





Εικόνα 4.8: Διάταξη διάτρησης-Τρυπάνι, δοκίμιο συγκρατημένο από μέγγενη και μετρητική πλάκα [40]

Από τα πειράματα αυτά συλλέχθηκαν οι τιμές, τόσο των παραμέτρων που θα αποτελέσουν τα δεδομένα εισόδου για το νευρωνικό δίκτυο όσο και των ζητούμενων μεγεθών που είναι και οι έξοδοι του ΤΝΔ. Για κάθε ζητούμενο μέγεθος και είδος υλικού παρατίθενται τα παρακάτω πειραματικά αποτελέσματα:

1) Δοκίμιο C6-W-03

A/A	Δύναμη Ωσης				Παράγων Αποκόλλησης			
	$d_o$ (mm)	$V_c$ (m/min)	$f$ (mm/min)	$F_z$ (N)	$d_o$ (mm)	$V_c$ (m/min)	$f$ (mm/min)	DF
1	2	5	50	34	2	5	50	1.111
2	2	10	125	41	2	10	125	1.123
3	2	15	200	44	2	15	200	1.131
4	2	20	275	49	2	20	275	1.142
5	3	10	50	40	3	10	50	1.165
6	3	5	125	130	3	5	125	1.172
7	3	20	200	75	3	20	200	1.181
8	3	15	275	110	3	15	275	1.191
9	4	15	50	45	4	15	50	1.215
10	4	20	125	72	4	20	125	1.223
11	4	5	200	225	4	5	200	1.235
12	4	10	275	180	4	10	275	1.248
13	5	20	50	75	5	20	50	1.287
14	5	15	125	135	5	15	125	1.294
15	5	10	200	230	5	10	200	1.305

16	5	5	275	<b>510</b>	5	5	275	<b>1.318</b>
----	---	---	-----	------------	---	---	-----	--------------

Πίνακας 4.1:Πειραματικά αποτελέσματα C6-W-03[40]

2) Δοκίμιο C6-W-01

A/A	Δύναμη Ώσης				Παράγων Αποκόλλησης			
	d <sub>o</sub> (mm)	V <sub>c</sub> (m/min)	f (mm/min)	F <sub>z</sub> (N)	d <sub>o</sub> (mm)	V <sub>c</sub> (m/min)	f (mm/min)	DF
1	2	5	50	<b>60</b>	2	5	50	<b>1.154</b>
2	2	10	125	<b>76</b>	2	10	125	<b>1.166</b>
3	2	15	200	<b>85</b>	2	15	200	<b>1.181</b>
4	2	20	275	<b>92</b>	2	20	275	<b>1.188</b>
5	3	10	50	<b>50</b>	3	10	50	<b>1.213</b>
6	3	5	125	<b>150</b>	3	5	125	<b>1.221</b>
7	3	20	200	<b>70</b>	3	20	200	<b>1.232</b>
8	3	15	275	<b>85</b>	3	15	275	<b>1.245</b>
9	4	15	50	<b>70</b>	4	15	50	<b>1.271</b>
10	4	20	125	<b>92</b>	4	20	125	<b>1.279</b>
11	4	5	200	<b>295</b>	4	5	200	<b>1.286</b>
12	4	10	275	<b>250</b>	4	10	275	<b>1.296</b>
13	5	20	50	<b>72</b>	5	20	50	<b>1.325</b>
14	5	15	125	<b>130</b>	5	15	125	<b>1.334</b>
15	5	10	200	<b>210</b>	5	10	200	<b>1.346</b>
16	5	5	275	<b>540</b>	5	5	275	<b>1.357</b>

Πίνακας 4.2:Πειραματικά αποτελέσματα C6-W-01[40]

**4.2 Καθορισμός παραμέτρων αρχιτεκτονικής και εκπαίδευσης των υπό σύγκριση υπολογιστικών μοντέλων πρόβλεψης**

Προκειμένου τα τρία υπό σύγκριση δίκτυα-MLP, ANFIS, RBF-να έχουν την βέλτιστη αποδοτικότητα ως προς τους σκοπού της παρούσας εργασίας, είναι αναγκαίος ο προσδιορισμός των παραμέτρων, οι οποίες καθορίζουν την αρχιτεκτονική τους. Ο λόγος γίνεται για τον αριθμό των επιπέδων και τον αριθμό των νευρώνων σε κάθε επίπεδο. Η επιλογή πρέπει να γίνει κατά τέτοιο τρόπο ώστε να εμφανίζεται μεν στο δίκτυο η μέγιστη αποδοτικότητα, αφετέρου δε να αποφευχθεί το φαινόμενο της πολυπλοκότητας αλλά και του κινδύνου της υπέρ-προσαρμογής κατά το στάδιο της εκπαίδευσης. Σε κάθε μια από τις παρακάτω τρεις περιπτώσεις, η εκπαίδευση των δικτύων και η εξαγωγή των αποτελεσμάτων αλλά και ενδεικτικών διαγραμμάτων, θα λάβει μέρος σε περιβάλλον προγραμματισμού MATLAB.

A) Στην περίπτωση του συνήθους νευρωνικού δικτύου, τόσο ο αριθμός των παραμέτρων εισόδου και εξόδου είναι καθορισμένος με βάση τα πειραματικά δεδομένα. Οπότε εξετάζοντας δυό περιπτώσεις, θα έχουμε το επίπεδο εισόδου με τέσσερις παραμέτρους (διάμετρος και υλικό τρυπανιού, ταχύτητα κοπής, πρόωση,) και το επίπεδο εξόδου μιας ζητούμενης παραμέτρου (δύναμη ώσης στην 1<sup>η</sup> περίπτωση και παράγων αποκόλλησης στην 2<sup>η</sup>). Για απλούστευση των υπολογισμών ώστε να αποφευχθεί τυχόν πολυπλοκότητα του δικτύου, η εκπαίδευση θα πραγματοποιηθεί με ένα μόνο κρυφό επίπεδο. Αυτό που

απομένει είναι ο αριθμός των νευρώνων σε κάθε ένα από αυτά. Αυτό θα συμβεί από την πραγματοποίηση δοκιμών όπου θα τεθούν υπό αξιολόγηση από 2 έως 10 νευρώνες για κάθε περίπτωση.

Έχοντας ως στόχο την μεγιστοποίηση της αποτελεσματικότητας του MLP, αλλά και λαμβάνοντας υπόψη παρόμοιες μελέτες, επιλέγεται η ενοποίηση των δυο σετ δεδομένων, έτσι ώστε να φτάσουμε στον αριθμό των 32 μετρήσεων για κάθε παράμετρο (Fz και DF). Από τις 32 πειραματικές τιμές, στην περίπτωση του MLP το 70% να χρησιμοποιηθεί για την εκπαίδευση, το 15% για την γενίκευση και επίσης το 15% για τον έλεγχο του νευρωνικού δικτύου. Αντιθέτως στις περιπτώσεις των ANFIS και RBF, για την εκπαίδευση θα χρησιμοποιηθεί το 85% και για τον έλεγχο το 15%, ενώ το στάδιο της γενίκευσης δεν υφίσταται. Οπότε η διαδικασία θα λάβει μέρος μέσα από το ακόλουθα βήματα:

- 1) Εκπαίδευση (Training) του νευρωνικού δικτύου με περιπτώσεις δεδομένων μετρήσεων, για την εκτίμηση του σφάλματος αλλά και εν συνεχεία την ελαχιστοποίηση του.
- 2) Γενίκευση (Validation) του δικτύου με επιπλέον περιπτώσεις μετρήσεων για την αξιολόγηση της εκπαίδευσης του δικτύου, ως προς το να εξάγει αποτελέσματα κοντά στα επιθυμητά πειραματικά (μόνο για την περίπτωση του TND).
- 3) Έλεγχος (Testing) του δικτύου με επιπλέον περιπτώσεις μετρήσεων όπου αξιολογείται η συνολική επίδοση του TND.
- 4) Συνολικό σφάλμα (Total error). Αποτελεί το σύνολο/συνδυασμό των τριών παραπάνω καταστάσεων, κυρίως για το σφάλμα MSE.

Οι αλγόριθμοι εκπαίδευσης θα είναι για την περίπτωση 1) ο αλγόριθμος των Levenberg–Marquardt, 2) η μέθοδος της απότομης καθόδου gradient descent, 3) η μέθοδος BFGS και 4) η μέθοδος Scaled Conjugate Gradient.

Σε πρώτη φάση θα επιχειρηθεί η εύρεση του καταλληλότερου αλγόριθμου εκπαίδευσης και σε δεύτερη η βέλτιστη εκδοχή του MLP, με βάση των επιλεχθέν αλγόριθμο.

Β) Σε ότι αφορά το νεύρο-ασαφές σύστημα ANFIS θα χρησιμοποιηθεί η μέθοδος Fuzzy c-means clustering. Λόγω της δεδομένης αρχιτεκτονικής αλλά και των περιορισμών που έχουν αναφερθεί στην ενότητα των ασαφών και νεύρο-ασαφών συστημάτων, ο σκοπός είναι η εύρεση του κατάλληλου αριθμού «ομαδοποιήσεων των δεδομένων» (nclusters), τόσο όσο και των επαναλήψεων (epochs). Για την παρούσα μελέτη θα επιχειρηθεί συνδυασμός δοκιμών με 2 έως 5 nclusters και 20 έως 100 epochs.

Γ) Επίσης στην περίπτωση του νευρωνικού δικτύου RBF, επειδή η αρχιτεκτονική θεωρείται εξίσου δεδομένη, απομένει ο προσδιορισμός του βέλτιστου αριθμού νευρώνων για την κάλλιστη απόδοση του δικτύου. Όπως

στην περίπτωση του κοινού MLP, έτσι και εδώ θα γίνουν δοκιμές του RBF δικτύου με 2 έως 10 νευρώνες.

Κριτήρια για την εύρεση του καταλληλότερου υπολογιστικού μοντέλου πρόβλεψης θα αποτελέσουν, το μέσο τετραγωνικό σφάλμα, το μέσο απόλυτο ποσοστιαίο σφάλμα και το μέγιστο δυνατό regression (R)-συσχέτιση, δίνοντας βάση στα συνολικά σφάλματα- MSE total error.

Το μέσο τετραγωνικό σφάλμα (Mean Square Error, MSE), υπολογίζεται ως ακολούθως:

$$M.S.E = \frac{1}{n} * \sum_{i=1}^n (Y_i - Y_i^{\mu\acute{\epsilon}\sigma\sigma})^2$$

ενώ για την εν λόγω περίπτωση πρέπει να μην ξεπερνά το 0,1-0,01.

Το μέσο απόλυτο ποσοστιαίο σφάλμα (Mean Absolute Percentage Error, MAPE), υπολογίζεται ανάλογα ως:

$$M.A.P.E = \frac{100\%}{n} * \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right|$$

όπου για την εν λόγω περίπτωση πρέπει να μην ξεπερνά το 10%.

Τέλος, ο Συντελεστής συσχέτισης (Regression, R), πρέπει να είναι η μέγιστη δυνατή προσεγγίζοντας το 1.

Λόγω του ότι αναμένεται τόσο το σφάλμα MSE όσο και η συσχέτιση R να είναι ι αποδεκτά με βάση τα όρια που τίθενται, η μεγαλύτερη βαρύτητα θα δοθεί στο σφάλμα MAPE.

#### 4.3 Παρουσίαση αποτελεσμάτων των υπολογιστικών μοντέλων

Με βάση τα προαναφερθέντα κριτήρια, παρατίθενται τα ακόλουθα αποτελέσματα ανά υπολογιστικό μοντέλο και ανά ζητούμενο μέγεθος:

##### Α) Τεχνητά νευρωνικά δίκτυα MLP

Traingd	Δύναμη Ωθησης Fz			Παράγων Αποκόλλησης DF		
	(MSE)(total)	R	MAPE(%)	(MSE)(total)	R	MAPE(%)
2	1,31*10 <sup>-2</sup>	0,898	47,18	1,9*10 <sup>-3</sup>	0,892	5,996
3	1,08*10 <sup>-2</sup>	0,811	48,38	2,3*10 <sup>-3</sup>	0,695	5,739
4	8,3*10 <sup>-3</sup>	0,885	48,29	5,3*10 <sup>-3</sup>	0,744	7,365
5	2,9*10 <sup>-3</sup>	0,887	40,89	5,7*10 <sup>-3</sup>	0,846	6,383
6	2,02*10 <sup>-2</sup>	0,942	37,82	5,0*10 <sup>-3</sup>	0,604	5,993
7	2,04*10 <sup>-2</sup>	0,833	38,33	3,5*10 <sup>-3</sup>	0,701	5,056
8	3,2*10 <sup>-3</sup>	0,84	31,75	1,4*10 <sup>-3</sup>	0,754	5,538

9	$6,3 \cdot 10^{-3}$	0,775	43,54	$6,1 \cdot 10^{-3}$	0,869	6,305
10	$8,2 \cdot 10^{-3}$	0,845	37,4	$6,28 \cdot 10^{-4}$	0,852	3,95

**Πίνακας 4.3:Αποτελέσματα αλγόριθμου εκπαίδευσης Gradient Descent**

Trainlm	Δύναμη Ωθησης Fz			Παράγων Αποκόλλησης DF		
	(MSE)(Total)	R	MAPE(%)	(MSE)(Total)	R	MAPE(%)
2	$3,8 \cdot 10^{-3}$	0,991	11,54	$3,92 \cdot 10^{-5}$	0,997	0,359
3	$3,8 \cdot 10^{-3}$	0,994	9,58	$1,56 \cdot 10^{-5}$	0,999	0,218
4	$4,2 \cdot 10^{-3}$	0,982	7,16	$4,83 \cdot 10^{-5}$	0,991	0,295
5	$3,6 \cdot 10^{-3}$	0,994	7,86	$1,37 \cdot 10^{-5}$	0,998	0,264
6	$2,6 \cdot 10^{-3}$	0,985	7,02	$4,16 \cdot 10^{-5}$	0,999	0,125
7	$3,5 \cdot 10^{-3}$	0,996	4,52	$6,33 \cdot 10^{-6}$	0,996	0,097
8	$6,94 \cdot 10^{-2}$	0,982	7,62	$7,37 \cdot 10^{-6}$	0,997	0,186
9	$4,2 \cdot 10^{-3}$	0,989	9,28	$1,79 \cdot 10^{-4}$	0,989	0,677
10	$1,14 \cdot 10^{-2}$	0,976	9,94	$2,13 \cdot 10^{-4}$	0,993	0,403

**Πίνακας 4.4:Αποτελέσματα αλγόριθμου εκπαίδευσης Levenberg-Marquadt**

Trainbfg	Δύναμη Ωθησης Fz			Παράγων Αποκόλλησης DF		
	(MSE)(Total)	R	MAPE(%)	(MSE)(Total)	R	MAPE(%)
2	$8,07 \cdot 10^{-4}$	0,988	16,25	$8,96 \cdot 10^{-4}$	0,895	1,958
3	$1,88 \cdot 10^{-2}$	0,966	18,43	$4,55 \cdot 10^{-4}$	0,943	1,675
4	$3,6 \cdot 10^{-3}$	0,985	15,63	$1,55 \cdot 10^{-4}$	0,973	1,145
5	$5,2 \cdot 10^{-3}$	0,988	14,24	$4,61 \cdot 10^{-4}$	0,969	1,102
6	$4,26 \cdot 10^{-2}$	0,928	14,05	$9,78 \cdot 10^{-5}$	0,977	0,97
7	$1,01 \cdot 10^{-2}$	0,969	15,09	$1,70 \cdot 10^{-5}$	0,974	0,955
8	$6,3 \cdot 10^{-3}$	0,977	18,75	$2,30 \cdot 10^{-4}$	0,981	0,866
9	$1,02 \cdot 10^{-2}$	0,842	19,85	$3,34 \cdot 10^{-4}$	0,972	1,075
10	$2,36 \cdot 10^{-2}$	0,947	20,11	$3,30 \cdot 10^{-4}$	0,979	0,79

**Πίνακας 4.5:Αποτελέσματα αλγόριθμου εκπαίδευσης Quasi-Newton**

Trainscg	Δύναμη Ωθησης Fz			Παράγων Αποκόλλησης DF		
	(MSE)(Total)	R	MAPE(%)	(MSE)(Total)	R	MAPE(%)
2	$3,25 \cdot 10^{-2}$	0,967	16,12	$1,21 \cdot 10^{-5}$	0,998	0,271
3	$2,16 \cdot 10^{-2}$	0,969	15,42	$1,68 \cdot 10^{-5}$	0,998	0,241
4	$1,3 \cdot 10^{-3}$	0,99	14,61	$8,25 \cdot 10^{-6}$	0,999	0,211
5	$1,1 \cdot 10^{-3}$	0,957	14,4	$1,23 \cdot 10^{-4}$	0,995	0,358
6	$2,83 \cdot 10^{-2}$	0,955	12,79	$1,07 \cdot 10^{-5}$	0,999	0,228
7	$2,0 \cdot 10^{-3}$	0,987	14,37	$1,54 \cdot 10^{-4}$	0,995	0,31
8	$1,4 \cdot 10^{-3}$	0,995	10,91	$2,51 \cdot 10^{-4}$	0,989	0,428
9	$7,4 \cdot 10^{-3}$	0,98	10,68	$1,76 \cdot 10^{-4}$	0,994	0,42

10	$4,2*10^{-3}$	0,989	13,4	$2,77*10^{-4}$	0,986	0,506
----	---------------	-------	------	----------------	-------	-------

Πίνακας 4.6: Αποτελέσματα αλγόριθμου εκπαίδευσης Scaled Conjugate Gradient

#### Συμπεράσματα επί του μοντέλου MLP

Όπως παρατηρείται και οι τέσσερις αλγόριθμοι εκπαίδευσης, δίνουν πολύ καλά αποτελέσματα για την ζητούμενη παράμετρο του παράγοντα αποκόλλησης DF ικανοποιώντας όχι μόνο τα κριτήρια για το MSE και το R, αλλά και για το σφάλμα MAPE. Τα καλύτερα αποτελέσματα ανήκουν στον αλγόριθμο Levenberg-Marquadt, τα δυσμενέστερα σε αυτού της απότομης καθόδου (Gradient Descent). Σε ότι αφορά όμως την ζητούμενη παράμετρο της δύναμης ώθησης Fz, παρατηρείται ότι ενώ και οι τέσσερις αλγόριθμοι ικανοποιούν τα κριτήρια για το MSE και το R, στην περίπτωση του MAPE μόνο ο αλγόριθμος Levenberg-Marquadt ικανοποιεί το όριο του 10%, ενώ οι υπόλοιποι BFGS, SCG δίνουν σφάλματα που κυμαίνονται μεταξύ 10 και 20%, στον δε αλγόριθμο της απότομης καθόδου το σφάλμα MAPE φτάνει μεταξύ 30 και 48%. *Αυτό έχει ως αποτέλεσμα να προκρίνεται ο αλγόριθμος Levenberg-Marquadt ως ο καταλληλότερος από την εκπαίδευση μέσω του κλασικού MLP.*

Έχοντας ως τελική επιλογή για τον προσδιορισμό της δύναμης ώθησης Fz και τον παράγοντα αποκόλλησης DF, το τεχνητό νευρωνικό δίκτυο (MLP) ενός κρυφού επιπέδου με αλγόριθμο εκπαίδευσης δικτύου τον Levenberg-Marquadt, θεωρείται απαραίτητη εκ νέου η παράθεση των αποτελεσμάτων, με βάση τα σφάλματα MSEval, MSEtotal, MAPE, τις επαναλήψεις epochs και τον χρόνο υπολογισμού σε sec για αριθμό νευρώνων από 2 έως 10.

Δύναμη Ώθησης Fz						
Trainlm	Validation (MSE)	Total (MSE)	R	Best Epoch	MAPE(%)	Time(sec)
2	$2,94*10^{-4}$	$3,8*10^{-3}$	0,991	8//14	11,54	0,269
3	$4,25*10^{-3}$	$3,8*10^{-3}$	0,994	7//13	9,58	0,288
4	$02,80*10^{-3}$	$4,2*10^{-3}$	0,982	10//16	7,16	0,328
5	$4,48*10^{-4}$	$3,6*10^{-3}$	0,994	8//12	7,86	0,25
6	$4,7*10^{-3}$	$2,6*10^{-3}$	0,985	11//16	7,02	0,281
7	$3,45*10^{-4}$	$3,5*10^{-3}$	0,996	7//11	4,52	0,25
8	$1,1*10^{-2}$	$6,94*10^{-2}$	0,982	6//7	7,62	0,187
9	$3,32*10^{-3}$	$4,2*10^{-3}$	0,989	8//10	9,28	0,282
10	$4,48*10^{-3}$	$1,14*10^{-2}$	0,976	7//7	9,94	0,171


Παράγων Αποκόλλησης DF						
Trainlm	Validation (MSE)	Total (MSE)	R	Best Epoch	MAPE(%)	Time(sec)
2	$2,78*10^{-5}$	$3,92*10^{-5}$	0,997	4//10	0,359	0,25
3	$1,31*10^{-5}$	$1,56*10^{-5}$	0,999	6//12	0,218	0,265
4	$6,13*10^{-5}$	$4,83*10^{-5}$	0,997	5//11	0,295	0,234

5	$1,76 \cdot 10^{-5}$	$1,37 \cdot 10^{-5}$	0,998	7//13	0,264	0,281
6	$4,9 \cdot 10^{-5}$	$4,16 \cdot 10^{-5}$	0,999	8//10	0,125	0,219
7	$3,02 \cdot 10^{-6}$	$6,33 \cdot 10^{-6}$	0,999	8//10	0,097	0,218
8	$9,94 \cdot 10^{-5}$	$7,37 \cdot 10^{-6}$	0,997	7//9	0,186	0,219
9	$1,97 \cdot 10^{-4}$	$1,79 \cdot 10^{-4}$	0,988	3//7	0,677	0,172
10	$1,63 \cdot 10^{-4}$	$2,13 \cdot 10^{-4}$	0,993	5//7	0,403	0,172

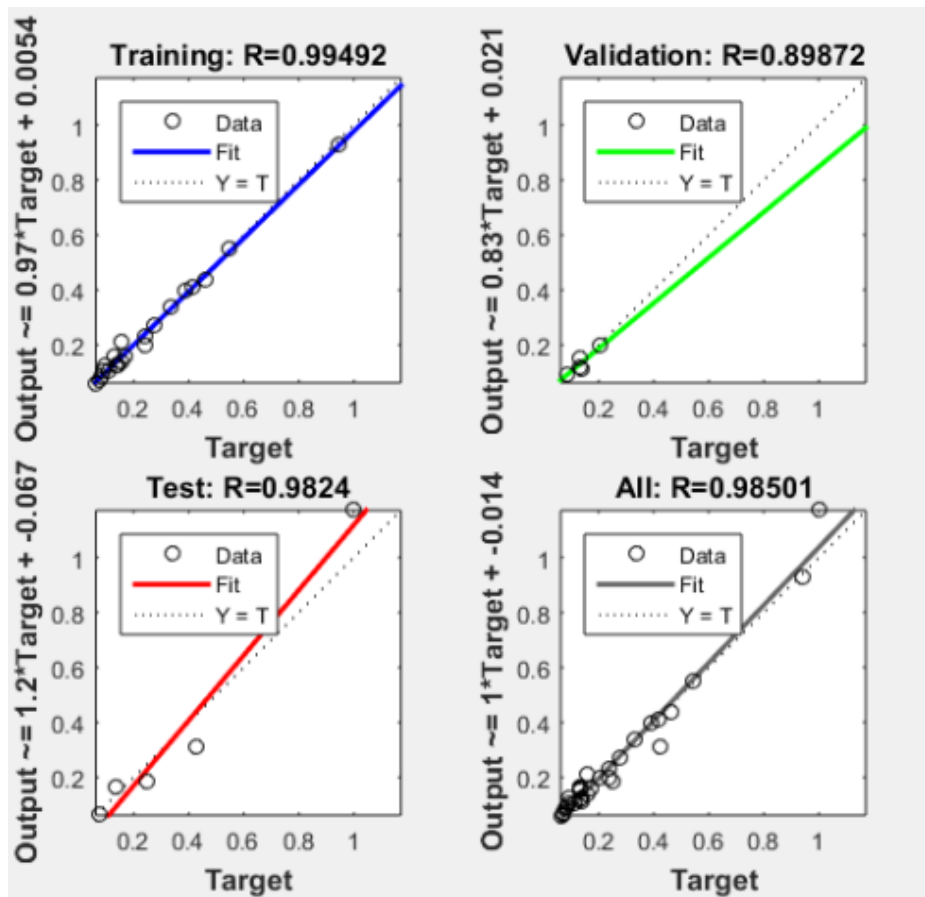
**Πίνακας 4.7: Επιμέρους αποτελέσματα αλγόριθμου εκπαίδευσης Levenberg-Marquadt**

Επιπλέον παρατίθενται αντιπροσωπευτικά διαγράμματα τόσο του σφάλματος MSEval, όσο και της συσχέτισης R, με βάση. Επειδή δεν είναι δυνατόν να δίνει παράθεση των διαγραμμάτων όλων των παραπάνω περιπτώσεων, επιλέχθηκε η παράθεση των διαγραμμάτων 5 περιπτώσεων MLP, ενός κρυφού επιπέδου 2, 4, 6, 7 και 9 νευρώνων.


(Σημείωση: Η ονομασία των διαγραμμάτων γίνεται με βάση τα αρχικά του ζητούμενου μεγέθους, τον αριθμό των νευρώνων και την ονομασία του κριτηρίου αξιολόγησης)



**Εικόνα 4.9: Διάγραμμα Fz-2-Validation error/MSE**

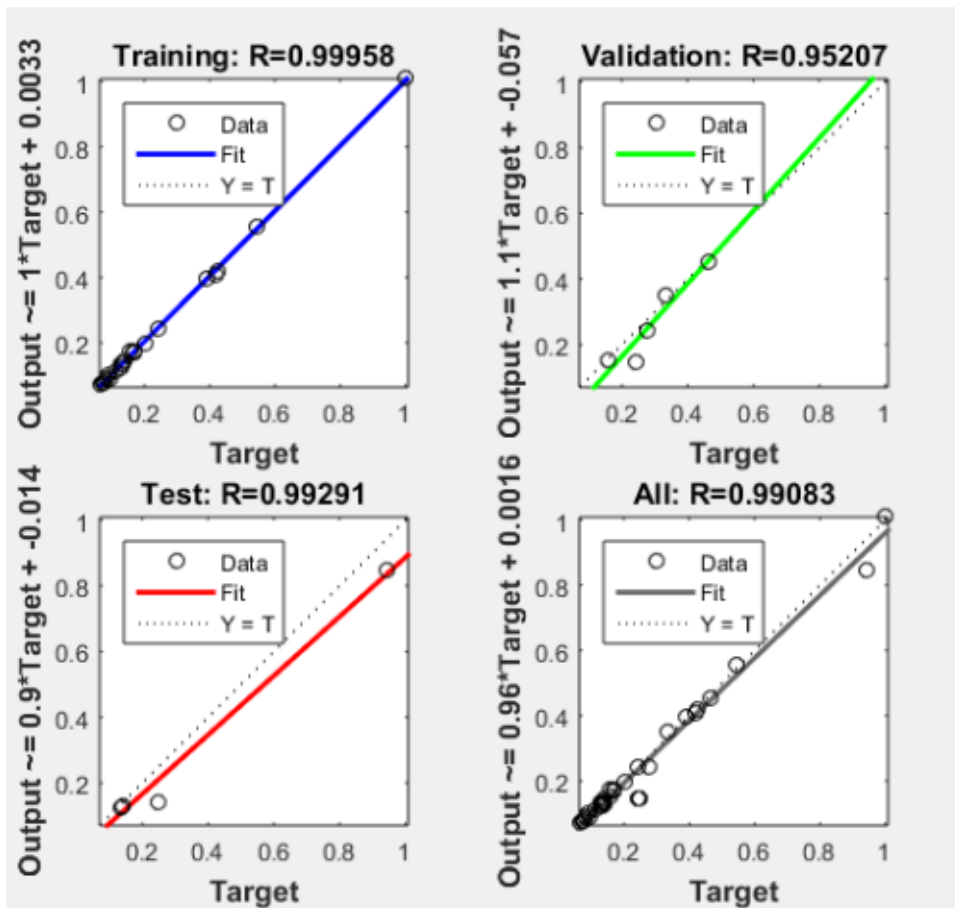


Εικόνα 4.10: Διάγραμμα Fz-2-Regression/R




Εικόνα 4.11: Διάγραμμα Fz-4-Validation error/MSE

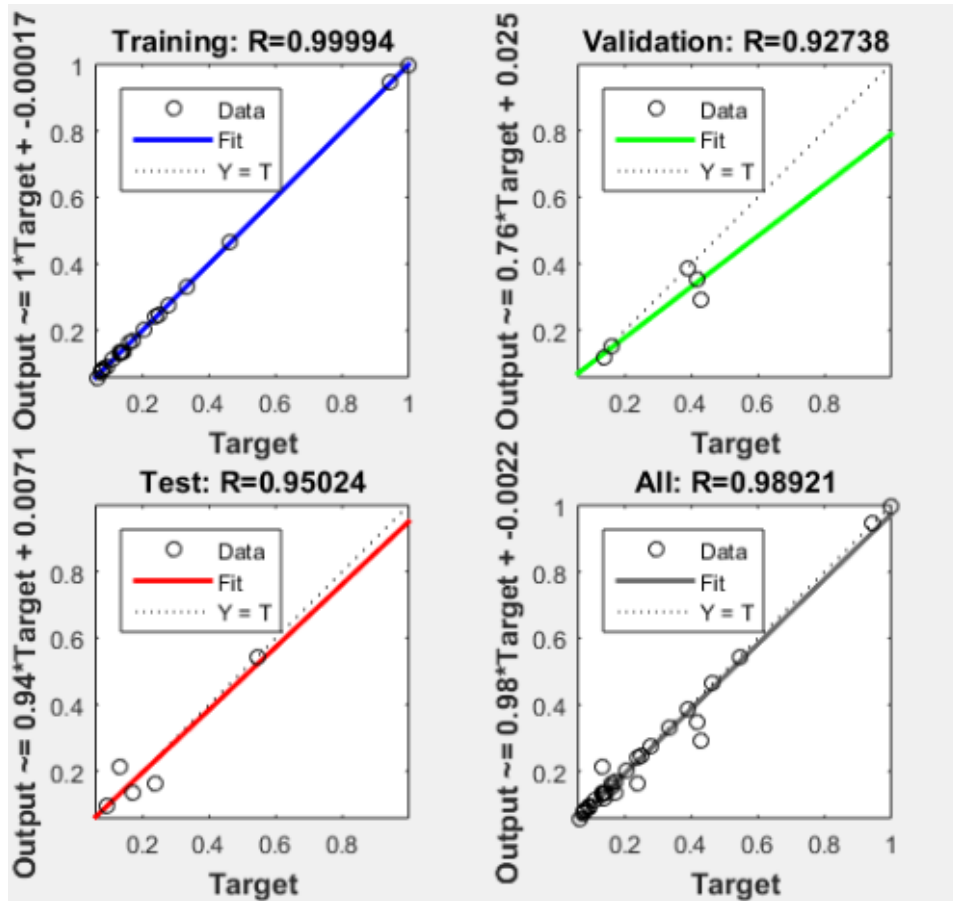





Εικόνα 4.12: Διάγραμμα Fz-4-Regression/R



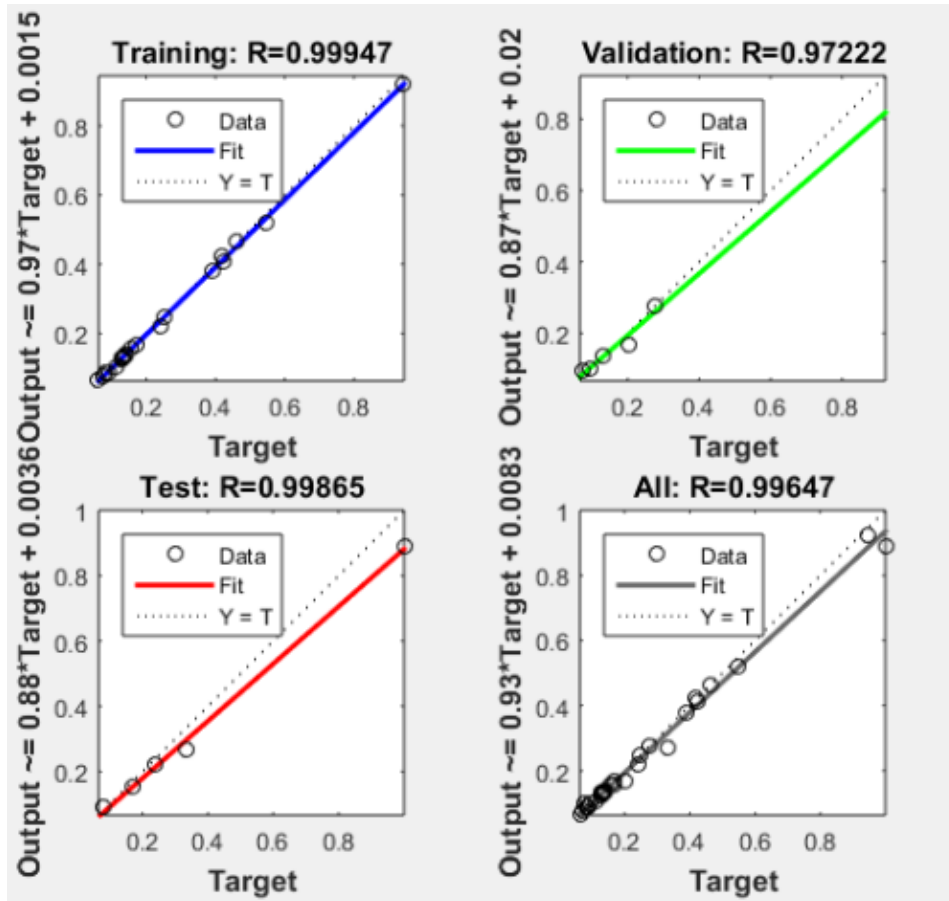
Εικόνα 4.13: Διάγραμμα Fz-6-Validation error/MSE




Εικόνα 4.14: Διάγραμμα Fz-6-Regression/R




Εικόνα 4.15: Διάγραμμα Fz-7-Validation error/MSE




Εικόνα 4.16: Διάγραμμα Fz-7-Regression/R



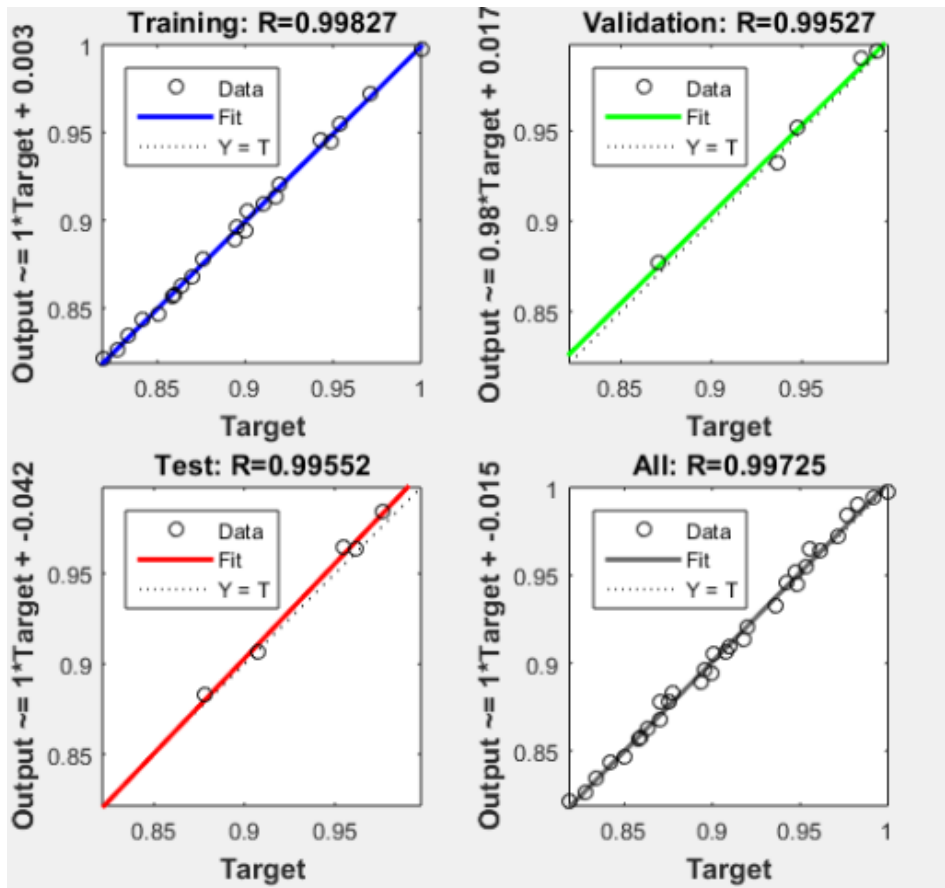
Εικόνα 4.17: Διάγραμμα Fz-9-Validation error/MSE




Εικόνα 4.18: Διάγραμμα Fz-9-Regression/R



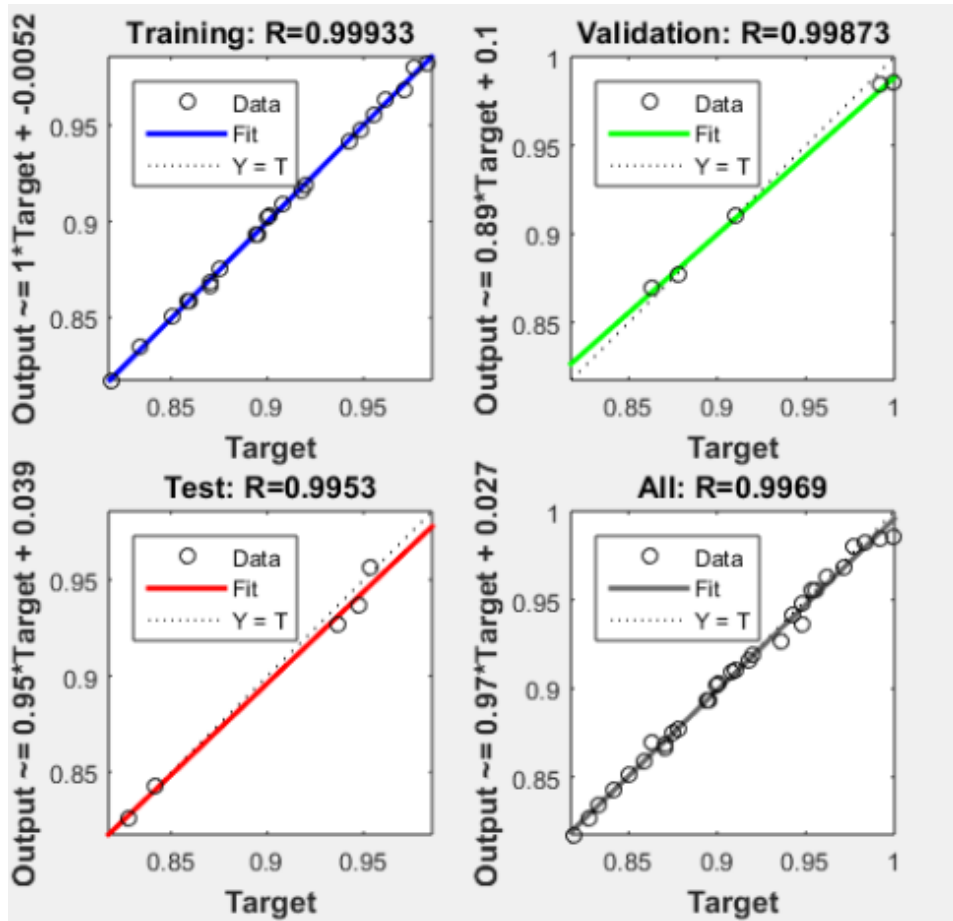
Εικόνα 4.19: Διάγραμμα DF-2-Validation error/MSE




Εικόνα 4.20: Διάγραμμα DF-2-Regression/R



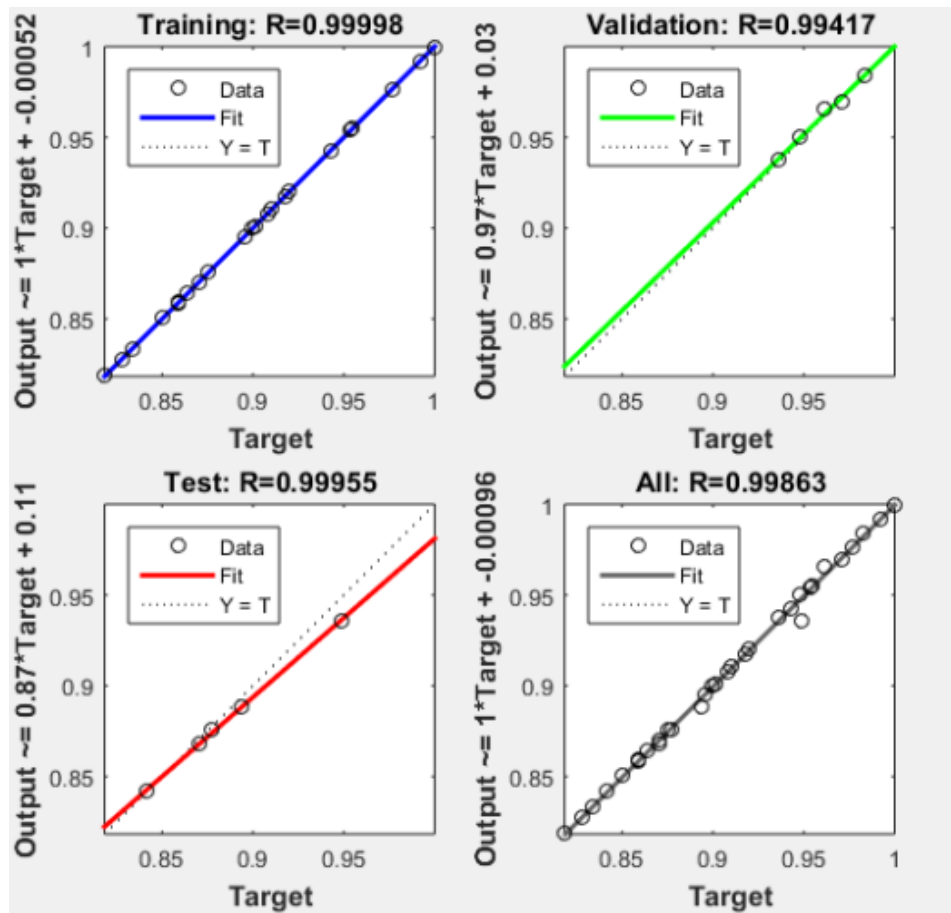
Εικόνα 4.21: Διάγραμμα DF-4-Validation error/MSE




Εικόνα 4.22: Διάγραμμα DF-4-Regression/R



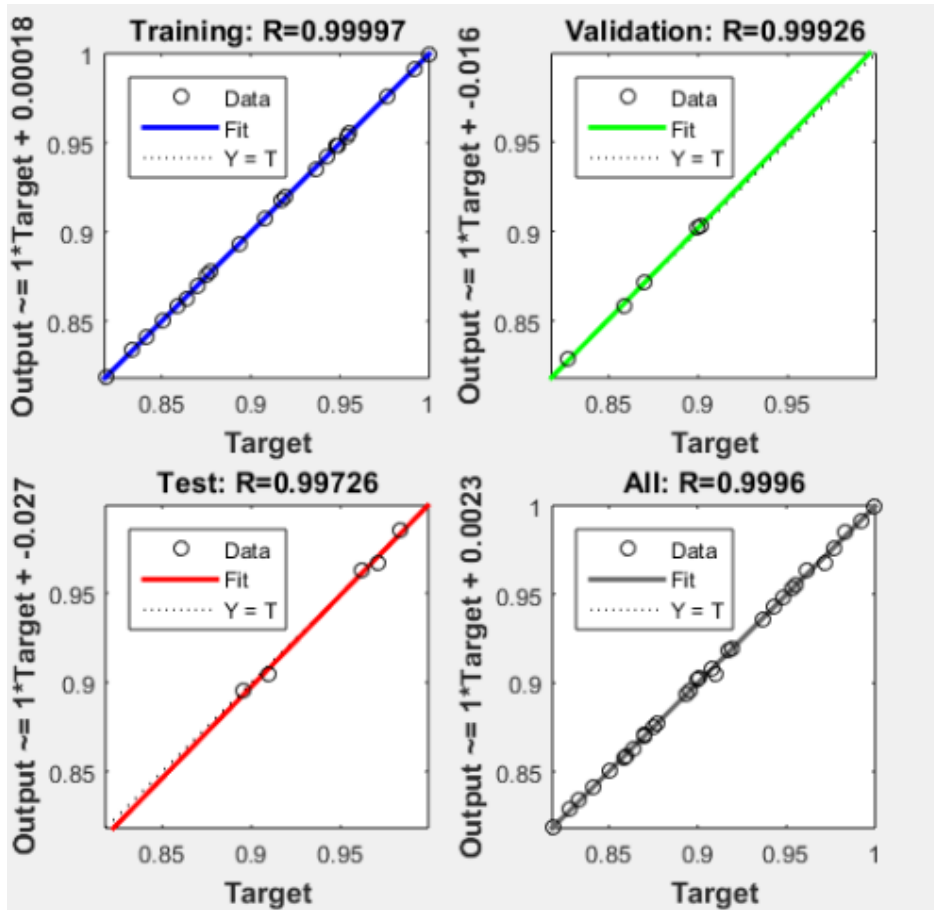
Εικόνα 4.23: Διάγραμμα DF-6-Validation error/MSE




Εικόνα 4.24: Διάγραμμα DF-6-Regression/R



Εικόνα 4.25: Διάγραμμα DF-7-Validation error/MSE

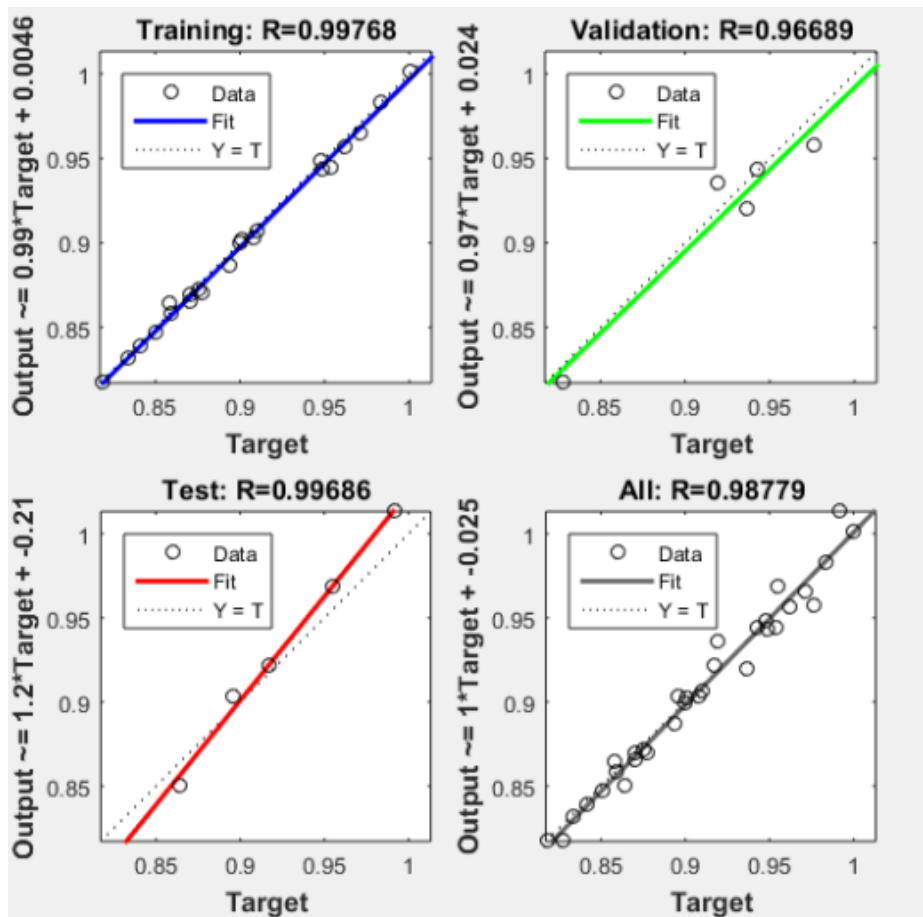


Εικόνα 4.26: Διάγραμμα DF-7-Regression/R



Εικόνα 4.27: Διάγραμμα DF-9-Validation error/MSE



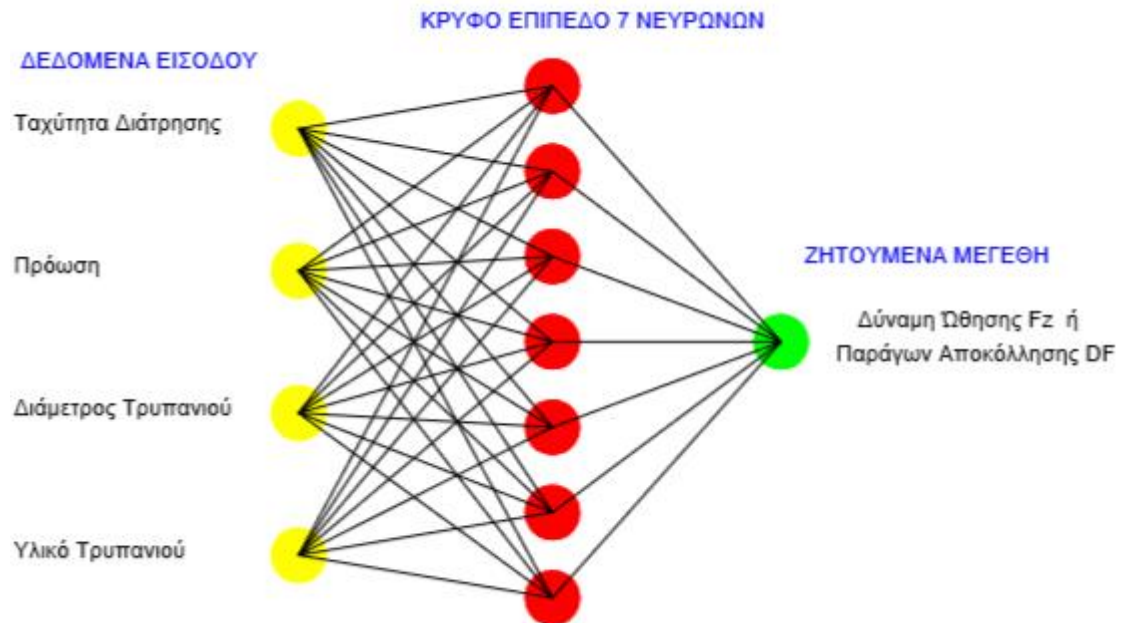


Εικόνα 4.28: Διάγραμμα DF-7-Regression/R

Από την παράθεση των μετρήσεων, φαίνεται ότι για όλες τις περιπτώσεις αριθμού νευρώνων ικανοποιούνται οι προϋποθέσεις τόσο για τα σφάλματα MSE και MAPE όσο και για την συσχέτιση R, ανεξαρτήτως ζητούμενου μεγέθους, με μόνη εξαίρεση την περίπτωση κρυφού επιπέδου με 2 νευρώνες όπου το σφάλμα MAPE υπερβαίνει σχετικά οριακό το όριο του 10% και μόνο για το μέγεθος της δύναμης ώθησης Fz. Από τα αποτελέσματα, τις καλύτερες επιδόσεις και στα δύο ζητούμενα μεγέθη και ιδιαίτερος στο σφάλμα MAPE, που αποτελεί και το κυριότερο κριτήριο αξιολόγησης, σημειώνει η περίπτωση του κρυφού επιπέδου 7 νευρώνων όπου φτάνει στην περίπτωση του παράγοντα αποκόλλησης DF, να δίνει μια τάξη μεγέθους καλύτερη μέτρηση, ενώ σε κάθε περίπτωση σημειώνεται συσχέτιση R της τάξης του 0,99 τόσο στο στάδια της γενίκευσης (Validation) όσο και στο συνολικό (Total). Επιπλέον οι επιδόσεις σημειώνονται σε χρόνους αρκετά ικανοποιητικούς, άνω του μέσου όρου όπως φαίνεται και από τα αποτελέσματα ενώ επιτυγχάνονται σε λιγότερες από 10 epochs.

Εν τέλει η εκδοχή του κρυφού επιπέδου 7 νευρώνων, θα αποτελέσει και την τελική επιλογή ως προς την βέλτιστη αρχιτεκτονική του MLP. Μπορεί δε να θεωρηθεί πραγματιστική επιλογή, διότι βάσης προαναφερθείσας θεωρίας αλλά και του εύρους νευρώνων που δοκιμάστηκαν κατά την εκπαίδευση του MLP, παρουσιάζει την κάλλιστη αποδοτικότητα ως προς τον προσδιορισμό των ζητούμενων μεγεθών κάτι που δεν θα ήταν τόσο εύκολο επιτεύξιμο με περιπτώσεις κρυφού επιπέδου με λιγότερους νευρώνες. Επιπλέον ολοκληρώνει

την υπολογιστική διαδικασία σε αρκετά ικανοποιητικούς χρόνους, συγκριτικά με άλλες περιπτώσεις και δεν μπορεί να θεωρηθεί ως προς το μέγεθος του ότι εγκυμονεί τον κίνδυνο της πολυπλοκότητας και κυρίως και υπερπροσαρμογής, καταστάσεις πιθανές σε περιπτώσεις MLP όπου το ενδιάμεσο επίπεδο θα έχει μεγαλύτερο αριθμό νευρώνων. Ενδεικτική αναπαράσταση του MLP με 1 κρυφό επίπεδο 7 νευρώνων παρατίθεται ακολούθως:



Εικόνα 4.29: Σχηματική αναπαράσταση ΤΝΔ με 1 ενδιάμεσο επίπεδο 7 νευρώνων

### Β) Νεύρο-Ασαφές δίκτυο ANFIS

MSE(Total)	Δύναμη Ώθησης Fz				Παράγων αποκόλλησης DF			
ncluster →	2	3	4	5	2	3	4	5
Epochs ↓								
20	4,9*10 <sup>-3</sup>	6,052*10 <sup>-4</sup>	3,884*10 <sup>-5</sup>	2,81*10 <sup>-2</sup>	4,062*10 <sup>-6</sup>	1,541*10 <sup>-4</sup>	6,252*10 <sup>-6</sup>	7,711*10 <sup>-5</sup>
30	6,1*10 <sup>-3</sup>	1,3*10 <sup>-3</sup>	8,049*10 <sup>-4</sup>	3,8*10 <sup>-3</sup>	9,085*10 <sup>-7</sup>	2,946*10 <sup>-4</sup>	8,741*10 <sup>-6</sup>	1,777*10 <sup>-4</sup>
40	6,6*10 <sup>-3</sup>	1,6*10 <sup>-3</sup>	1,821*10 <sup>-5</sup>	2,8*10 <sup>-3</sup>	5,168*10 <sup>-7</sup>	3,263*10 <sup>-4</sup>	5,552*10 <sup>-6</sup>	8,962*10 <sup>-5</sup>
50	6,1*10 <sup>-3</sup>	1,7*10 <sup>-3</sup>	2,3*10 <sup>-3</sup>	2,6*10 <sup>-3</sup>	4,248*10 <sup>-7</sup>	3,870*10 <sup>-4</sup>	6,473*10 <sup>-6</sup>	6,855*10 <sup>-5</sup>
60	6,1*10 <sup>-3</sup>	1,9*10 <sup>-3</sup>	1,1*10 <sup>-3</sup>	2,6*10 <sup>-3</sup>	4,491*10 <sup>-7</sup>	9,194*10 <sup>-4</sup>	6,970*10 <sup>-6</sup>	6,865*10 <sup>-5</sup>
70	6,1*10 <sup>-3</sup>	2,0*10 <sup>-3</sup>	1,4*10 <sup>-3</sup>	2,7*10 <sup>-3</sup>	4,875*10 <sup>-7</sup>	6,881*10 <sup>-4</sup>	8,764*10 <sup>-6</sup>	2,006*10 <sup>-4</sup>
80	7,9*10 <sup>-3</sup>	2,0*10 <sup>-3</sup>	2,5*10 <sup>-3</sup>	2,7*10 <sup>-3</sup>	5,295*10 <sup>-7</sup>	6,287*10 <sup>-4</sup>	1,060*10 <sup>-5</sup>	7,873*10 <sup>-5</sup>
90	7,9*10 <sup>-3</sup>	2,0*10 <sup>-3</sup>	6,354*10 <sup>-4</sup>	2,6*10 <sup>-3</sup>	5,648*10 <sup>-7</sup>	6,059*10 <sup>-4</sup>	1,888*10 <sup>-5</sup>	8,388*10 <sup>-5</sup>
100	7,9*10 <sup>-3</sup>	2,0*10 <sup>-3</sup>	3,2*10 <sup>-3</sup>	2,7*10 <sup>-3</sup>	5,988*10 <sup>-7</sup>	6,472*10 <sup>-4</sup>	5,287*10 <sup>-5</sup>	9,362*10 <sup>-5</sup>

Πίνακας 4.8: Αποτελέσματα δικτύου ANFIS-MSE

MAPE %	Δύναμη Ώθησης Fz				Παράγων αποκόλλησης DF			
ncluster →	2	3	4	5	2	3	4	5
Epochs ↓								
20	14,45	7,782	5,566	9,881	0,124	0,274	0,097	0,141
30	15	8,633	4,993	7,335	0,106	0,332	0,081	0,189
40	14,94	8,729	5,477	5,017	0,098	0,339	0,075	0,133
50	14,69	8,395	5,868	4,792	0,094	0,363	0,078	0,127
60	14,68	8,139	5,988	4,528	0,092	0,318	0,078	0,127
70	14,68	7,759	5,452	4,522	0,092	0,291	0,08	0,169
80	15,51	7,603	7,336	4,592	0,092	0,285	0,08	0,132
90	15,48	7,541	5,348	4,566	0,092	0,283	0,09	0,133
100	15,49	7,564	4,546	4,53	0,092	0,292	0,112	0,137

**Πίνακας 4.9: Αποτελέσματα δικτύου ANFIS-MAPE**

Regr-R	Δύναμη Ώθησης Fz				Παράγων αποκόλλησης DF			
ncluster →	2	3	4	5	2	3	4	5
Epochs ↓								
20	0,9689	0,998	0,999	0,95	0,999	0,987	0,999	0,993
30	0,971	0,996	0,998	0,902	0,999	0,977	0,999	0,98
40	0,967	0,986	0,999	0,915	0,999	0,976	0,999	0,99
50	0,971	0,986	0,996	0,919	0,999	0,974	0,999	0,994
60	0,971	0,983	0,994	0,917	0,999	0,866	0,999	0,994
70	0,971	0,981	0,993	0,916	0,999	0,893	0,999	0,992
80	0,957	0,98	0,973	0,917	0,999	0,899	0,999	0,996
90	0,957	0,979	0,991	0,917	0,999	0,902	0,998	0,996
100	0,958	0,979	0,998	0,916	0,999	0,908	0,994	0,996

**Πίνακας 4.10: Αποτελέσματα δικτύου ANFIS-R**

#### Συμπεράσματα επί του μοντέλου ANFIS

Στην περίπτωση του μοντέλου ANFIS, σε ότι αφορά και τις δυό ζητούμενες παραμέτρους, το σύνολο των συνδυασμών nclusters και epochs δίνει πλήρως ικανοποιητικά αποτελέσματα, πληρώντας τα όρια και για τα τρία κριτήρια (MSE, MAPE, R). Εξαίρεση αποτελεί η περίπτωση των 2 nclusters, όπου για την Δύναμη Ώθησης Fz δεν ικανοποιεί το όριο του 10% στο σφάλμα MAPE. Επίσης παρατηρείται ανάλογη εικόνα όπως και στα MLP, δηλαδή ενώ ικανοποιούνται τόσο το MSE όσο και το R. Στην περίπτωση της δύναμης ώθησης στο σφάλμα MAPE τα καλύτερα αποτελέσματα παρουσιάζονται στην εκδοχή των 5 nclusters. Αντιθέτως για τον παράγοντα αποκόλλησης, η κάλλιστη απόδοση εμφανίζεται στην περίπτωση των 4 nclusters. Αξίζει να σημειωθεί ότι όπως και στο επιλεγέν ANN-Levenberg-Marquadt, έτσι και εδώ υφίσταται παρόμοια συμπεριφορά, δηλαδή τα βέλτιστα αποτελέσματα δίνονται σε μέσο αριθμό epochs.

Εν τέλει και βάση των αποτελεσμάτων, για το σύστημα ANFIS, η περίπτωση των 5 nclusters θεωρείται η καταλληλότερη για την προσδιορισμό της Fz, ενώ αυτή των 4 nclusters, θεωρείται η καλύτερη για τον προσδιορισμό του μεγέθους DF.

#### Γ) Δίκτυο ακτινικής συνάρτησης βάσης RBF

RBF	MSE(Total)		MAPE %		Regression - R	
	Δύναμη Ώθησης Fz	Παράγων Αποκόλλησης DF	Δύναμη Ώθησης Fz	Παράγων Αποκόλλησης DF	Δύναμη Ώθησης Fz	Παράγων Αποκόλλησης DF
2	8,3*10 <sup>-3</sup>	1,0*10 <sup>-3</sup>	41,51	2,667	0,8278	0,8061
3	9,6*10 <sup>-3</sup>	7,927*10 <sup>-4</sup>	41,34	2,614	0,8657	0,8434
4	4,0*10 <sup>-3</sup>	4,340*10 <sup>-4</sup>	33,29	2,26	0,9131	0,9637
5	7,1*10 <sup>-3</sup>	7,596*10 <sup>-4</sup>	35,06	2,03	0,9074	0,917
6	2,6*10 <sup>-3</sup>	7,118*10 <sup>-4</sup>	18,18	1,598	0,9509	0,8949
7	3,8*10 <sup>-3</sup>	2,870*10 <sup>-4</sup>	19,03	1,402	0,9802	0,9547
8	3,7*10 <sup>-3</sup>	2,653*10 <sup>-4</sup>	16,74	1,326	0,9937	0,9527
9	9,2*10 <sup>-3</sup>	4,954*10 <sup>-4</sup>	20,06	1,223	0,9191	0,9509
10	1,05*10 <sup>-2</sup>	2,101*10 <sup>-4</sup>	21,83	1,018	0,9089	0,9701
11	1,71*10 <sup>-2</sup>	3,827*10 <sup>-5</sup>	25,48	0,34	0,834	0,9947
12	1,82*10 <sup>-2</sup>	4,268*10 <sup>-5</sup>	24,49	0,345	0,7967	0,9945

Πίνακας 4.11: Αποτελέσματα δικτύου RBF

#### Συμπεράσματα επί του μοντέλου RBF

Και στην περίπτωση του δικτύου RBF, συμπεραίνεται πανομοιότυπη κατάσταση με αυτήν στα δίκτυα MLP και ANFIS. Δηλαδή ικανοποίηση όλων των κριτηρίων σχετικά με τα MSE, MAPE R στην παράμετρο του παράγοντα αποκόλλησης, αλλά αδυναμία της πλήρωσης του κριτηρίου του MAPE στην παράμετρο της δύναμης ώθησης, στο σύνολο των περιπτώσεων αριθμών νευρώνων που επιλέχθηκαν κατά την εκπαίδευση.

Με βάση τα αποτελέσματα και παρόλο την μη ικανοποίηση του ορίου του 10% σχετικά με το MAPE, στην περίπτωση της δύναμης ώθησης Fz, αποφασίζεται ότι η περίπτωση των 8 νευρώνων είναι η επιλεγείσα λόγω της μικρότερης απόκλισης από το όριο σχετικά με το σφάλμα MAPE, αλλά επίσης συγκαταλέγεται στις καλύτερες περιπτώσεις τόσο στην περίπτωση του σφάλματος MSE, όσο και στην περίπτωση της συσχέτισης R και στα δύο ζητούμενα μεγέθη.

#### 4.4 Επιλογή καταλληλότερου αλγορίθμου/μεθόδου

Με βάση τόσο τα αποτελέσματα όσο και τις επιμέρους διαπιστώσεις σε κάθε περίπτωση, παρατηρείται ότι οι τρεις αλγόριθμοι ικανοποιούν σε κάθε ζητούμενη παράμετρο (δύναμη ώθησης Fz, παράγων αποκόλλησης DF), και τα τρία κριτήρια αξιολόγησης, σφάλματα MSE και MAPE καθώς και την συσχέτιση

R. Μόνη εξαίρεση αποτελεί η αδυναμία του δικτύου RBF, να ικανοποιήσει το όριο του 10% για το σφάλμα MAPE και μόνο στην περίπτωση της δύναμης ώθησης Fz.

Επειδή τα αποτελέσματα για τα κριτήρια του MSE και του Regression-R, θεωρούνται αρκετά ικανοποιητικά και για τα τρία υπολογιστικά μοντέλα, όπως αναφέρθηκε σε κάθε περίπτωση, το βασικό κριτήριο αξιολόγησης θα αποτελέσει το σφάλμα MAPE.

Παρατηρείται λοιπόν ότι το δίκτυο RBF αποτελεί, την δυσμενέστερη περίπτωση, μια εκτός της περίπτωσης της δύναμης ώθησης Fz όπου δεν ικανοποιεί το όριο του 10%, στον παράγων αποκόλλησης DF δίνει έως και δύο τάξεις μεγέθους υποδεέστερο αποτέλεσμα.

Στις περιπτώσεις των δικτύων MLP και ANFIS η εικόνα είναι γενικά η ίδια και για τις δύο ζητούμενες παραμέτρους. Συγκεκριμένα στην περίπτωση της δύναμης ώθησης Fz, το MLP με τον αλγόριθμο εκπαίδευσης Levenberg-Marquadt και το ANFIS των 5 nclusters έχουν παρόμοια αποτελέσματα ως προς την τάξη μεγέθους, εμφανίζουν βέλτιστη απόδοση σε μέσους αριθμούς νευρώνων και epochs, ενώ θεωρούνται ουσιαστικά ισάξια ως προς την καλύτερη τιμή του σφάλματος MAPE. Στο μέγεθος του παράγοντα αποκόλλησης DF, επίσης εμφανίζονται σχετικά παρόμοια αποτελέσματα ως προς την τάξη μεγέθους, επίσης βέλτιστη απόδοση σε μέσους αριθμούς νευρώνων και epochs, αλλά με το ANFIS των 4 nclusters να έχει ελαφρά καλύτερη τιμή.

*Εν τέλει παρόλο που τα δίκτυα MLP και ANFIS, ποιοτικά μπορούν να θεωρηθούν ισοδύναμα, ως καταλληλότερο υπολογιστικό μοντέλο επιλέγεται το δίκτυο ANFIS λόγω οριακά καλύτερων αποτελεσμάτων, στον παράγοντα αποκόλλησης DF.*

#### **4.5 Συμπεράσματα**

Στην παρούσα διπλωματική εργασία, επιχειρήθηκε ο προσδιορισμός της δύναμης ώθησης Fz και του παράγοντα αποκόλλησης DF κατά την κατεργασία διάτρησης σε δοκίμια από πολυστρωματικά σύνθετα υλικά και η σύγκριση των αποτελεσμάτων τους με αυτά της αντίστοιχης πειραματικής διαδικασίας. Η υλοποίηση όλης της διεργασίας έγινε μέσω της εφαρμογής μαθηματικών μοντέλων προσομοίωσης σε περιβάλλον προγραμματισμού MATLAB και συγκεκριμένα του Τεχνητού Νευρωνικού Δικτύου MLP, του νεύρο-ασαφούς συστήματος ANFIS και επίσης του συστήματος RBF, χρησιμοποιώντας ως δεδομένα την ταχύτητα κοπής, την διάμετρο του τρυπανιού, την πρόωση και το είδος υλικού του τρυπανιού. Η ανάπτυξη και χρήση τέτοιων υπολογιστικών μοντέλων μπορεί να αποβεί άκρως αποτελεσματική στην βελτιστοποίηση παραμέτρων ποιότητας για την παραγωγή βιομηχανικών εξαρτημάτων με ταυτόχρονη εξοικονόμηση χρόνου και πρώτης ύλης και συνεπαγόμενα κόστους.

Η εργασία επικεντρώθηκε αρχικά στην ανάδειξη γενικών στοιχείων για τις κατεργασίες αποβολής υλικού αλλά και πιο ειδικά για την κατεργασία της διάτρησης που αφορούσε και το αντικείμενο της. Μεταγενέστερα έγινε περιγραφή των τριών μεθόδων που επρόκειτο να χρησιμοποιηθούν στην

διαδικασία, σε θέματα ιστορικής αναδρομής κατά την εμφάνιση και ανάπτυξη των εν λόγω μεθόδων, δομής/αρχιτεκτονικής τους, επιμέρους χαρακτηριστικών τους, εκπαίδευσης, σχετικών μειονεκτημάτων και περιορισμών ως προς την εφαρμογή τους. Επιπλέον στις περιπτώσεις του MLP και του ANFIS έγινε παράθεση εργασιών προγενέστερου χρονικού πλαισίου τόσο σε γενικό επίπεδο, σε περιπτώσεις κατεργασιών αφαίρεσης υλικού αλλά και πιο ειδικά σε περιπτώσεις κατεργασιών διάτρησης.

Σε τελικό στάδιο έγινε η ενασχόληση με το καθεαυτού αντικείμενο της εργασίας. Υπήρξε παρουσίαση της πειραματικής διαδικασίας, επιλογή των παραμέτρων που χρησιμοποιήθηκαν ως φορείς ποσοτικών (32 αριθμητικά) και ποιοτικών δεδομένων (ταχύτητα κοπής, πρόωση, διάμετρος τρυπανιού και υλικό τρυπανιού) αλλά και η επίδειξη των πειραματικών αποτελεσμάτων των ζητούμενων προς προσδιορισμό μεγεθών. Επιπλέον έγινε περιγραφή της διαδικασίας εφαρμογής των τριών υπολογιστικών μεθόδων σε επιλεγμένο εύρος συνδυασμών παραμέτρων τους (4 πιθανοί αλγόριθμοι εκπαίδευσης για το ANN, 2-10 νευρώνες για το κρυφό επίπεδο των MLP και RBF, 2-5 nclusters και 20-100 epochs για το ANFIS), καθώς και παρουσίαση των τριών κριτηρίων αξιολόγησης, των σφαλμάτων MSE και MAPE αλλά και της συσχέτισης R, με την μεγαλύτερη βαρύτητα να δίνεται στο σφάλμα MAPE.

Η εφαρμογή των τριών υπολογιστικών μεθόδων κατέδειξε από πλευράς ποιότητας, ως καταλληλότερες αυτές του MLP και του ANFIS, με το δίκτυο RBF να χαρακτηρίζεται ως υποδεέστερη μέθοδος προσδιορισμού των ζητούμενων μεταβλητών. Ως τελική επιλογή μπορεί να θεωρηθεί το μοντέλο ANFIS λόγω οριακά καλύτερων αποτελεσμάτων, κυρίως στο μέγεθος του παράγοντα αποκόλλησης DF. Όμως αξίζει να τονισθεί το γεγονός, ότι ανεξαρτήτως κατάληξης της διαδικασίας και τα τρία υπολογιστικά μοντέλα και κυρίως το Τεχνητό Νευρωνικό Δίκτυο MLP αλλά και το Νεύρο-Ασαφές Δίκτυο ANFIS, απέδειξαν την χρησιμότητα τους ως μαθηματικά εργαλεία επίλυσης βιομηχανικών προβλημάτων. Ιδιαίτερα όταν χρειάζεται να προσδιοριστούν παράμετροι ποιότητας παραγόμενων αντικειμένων, δίχως την ανάγκη διεξαγωγής πειραματικών διαδικασιών που ενέχουν αυξημένο κόστος και χρόνος πραγματοποίησής τους ως εναλλακτική επιλογή.

## **ΒΙΒΛΙΟΓΡΑΦΙΑ**

- [1]: Δημήτριος Μανωλάκος Καθηγητής Ε.Μ.Π., «Κατεργασίες Ι, Πρόχειρες Σημειώσεις», 2011.
- [2]: Δημήτριος Μανωλάκος Καθηγητής Ε.Μ.Π., «Κατεργασίες ΙΙ, Πρόχειρες Σημειώσεις», 2011.
- [3]: Βογιατζή Μαρία «Αξιολόγηση παραμέτρων εκτίμησης φθοράς κοπτικών με χρήση της μεθόδου σχεδιασμού πειράματος», Διπλωματική εργασία, Δημοκρίτειο Πανεπιστήμιο Θράκης – Τμήμα Μηχανικών Παραγωγής και Διοίκησης, 2010.
- [4]: Ιωάννης Ε. Λιβιέρης «Αποτίμηση μεθόδων εκπαίδευσης τεχνητών νευρωνικών δικτύων και εφαρμογές» Πανεπιστήμιο Πατρών Σχολή Θετικών Επιστημών Τμήμα Μαθηματικών, 2008.
- [5]: Χρύση Γιακουμίδη «Πρόβλεψη της επιφανειακής τραχύτητας κατά το Διπλωματική εργασία, Σχολή Μηχανολόγων Μηχανικών Ε.Μ.Π. 2016.
- [6]: Ειρηναίος Μπαλλάς «Πρόβλεψη της διάρκειας ζωής κοπτικού εργαλείου με χρήση νευρωνικών δικτύων και μεθόδων σχεδιασμού πειραμάτων», Διπλωματική εργασία, Σχολή Μηχανολόγων Μηχανικών Ε.Μ.Π. 2016.
- [7]: Λάουρα Θεοδόση Κοκκίνου «Τεχνητά Νευρωνικά Δίκτυα και εφαρμογές στα συστήματα αυτομάτων ελέγχου», Τμήμα Ηλεκτρολόγων Μηχανικών Τεχνολογίας Υπολογιστών, Πολυτεχνική Σχολή Πατρών, 2013.
- [8]: Γεώργιος Σ. Τεμπονέρας «Τεχνητά Νευρωνικά Δίκτυα και Εφαρμογές σε Σύγχρονα Προγραμματιστικά Περιβάλλοντα», Μεταπτυχιακή Διπλωματική Εργασία, Πανεπιστήμιο Πατρών, Διατμηματικό Πρόγραμμα Μεταπτυχιακών Σπουδών "Μαθηματικά των Υπολογιστών και των Αποφάσεων", 2018.
- [9]: Martin Fodslette Meiller «A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning», University of Aarhus, 1991.
- [10]: D. Cook, C. Chiu, «Combining a radial basis neural network with time series analysis techniques to predict manufacturing process parameters», Appl. Artif. Intell. 9, 1995.
- [11]: S. Elanayar, Y.C. Shin, «Design and implementation of tool wear monitoring with radial basis function neural networks», in: Proceedings of the American Control Conference. Part 3 (6), 1995.
- [12]: J.YKao, Y.S.Tarng, «A neural network approach for the on-line monitoring of the electrical discharge machining process», Journal of Materials Processing Technology, Vol. 69, No. 1, Pp. 112-119, 1997.
- [13]: Q. Liu, Y. Altintas, «On-line monitoring of flank wear in turning with multi-

- layered feed-forward neural network», *Int. J. Machine Tools Manuf.* 39 1999.
- [14]: P.J. Cheng, S.C. Lin, «Using neural networks to predict bending angle of sheet metal formed by laser», *Int. J. Machine Tools Manuf.* 40, 1999.
- [15]: Benardos, P.G. and Vosniakos, G.C.(2002) «Prediction of surface roughness in CNC face milling using neural networks and Taguchi's design of experiments», *Robotics and Computer-Integrated Manufacturing*, 18
- [16]: U. Zuperl, F. Cus, B. Mursec, T. Ploj «A generalized neural network model of ball-end milling force system», University of Maribor, 2006.
- [17]: F. J. Pontes, A. P. de Paiva, P. P. Balestrassi, J. R. Ferreira, M. B. da Silva «Optimization of Radial Basis Function neural network employed for prediction of surface roughness in hatd turning process using Tangushi's orthogonal arrays», 2012.
- [18]: D.K.Kasdekar, V.Parashar, C.Aryaa «Artificial neural network models for the prediction of MRR in Electro-chemical machining», Department of Mechanical Engineering, Maulana Azad National Institute of Technology, India, 2016.
- [19]: A.Markopoulos and N.Karkalos (2017) «Applicability of ANN models and Taguchi method for the determination of tool life in turning», N.T.U.A.
- [20]: S.C.Lin, C.J.Ting, «Drill Wear Monitoring Using Neural Networks», 1995.
- [21]: S.R.Karnik, V.N.Gaitonde, J.C.Rubio, A.E.Correia, A.M.Abrão, J.P.Davim, «Delamination analysis in high speed drilling of carbon fiber reinforced plastics (CFRP) using artificial neural network model», Department of Electrical and Electronics Engineering, B.V.B. College of Engineering and Technology, Hubli, Karnataka, India/ Department of Mechanical Engineering, Federal University of Minas Gerais, Av. Antônio Carlos, Pampulha, Belo Horizonte MG, Brazil/ Department of Mechanical Engineering and Industrial Management, School of Technology, Polytechnic Institute of Viseu, Campus de Repeses, Viseu, Portugal, 2007.
- [22]: M.Vrabel, I.Mankova, J.Beno, J.Tuharský, «Surface roughness prediction using artificial neural networks when drilling Udimet 720», Technical University of Košice, Masiarska 74, 04001 Košice, Slovakia, 2012.
- [23]: J.Xu, K.Yamada, K.Seikiya, R.Tanaka, Y.Yamane «Effect of different features to drill-wear prediction with back propagation neural network», Graduate School of Engineering Hiroshima University, Japan, 2013.
- [24]: F.C. Neto, T.M. Gerônimo, C.E.D. Cruz, P.R. Aguiar, E.E.C. Bianchi «Neural models for predicting hole diameters in drilling processes», Universidade Estadual Paulista - Faculdade de Engenharia, Av. Eng. Luiz Edmundo C. Coube 14-01, Bauru 17033-360, Brazil , 2013.



- [25]: K.Patra, A.K.Jha, T.Szalay, J.Ranjan, L.Monostori, «Artificial neural network based tool condition monitoring in micro mechanical peck drilling using thrust force signals», Department of mechanical engineering, Indian Institute of technology Patna, India- Department of manufacturing science and engineering, Budapest, Hungary, 2014.
- [26]: T.D.B. Kannan, G.R.Kannan, B.S.Kumar Dr N.Baskar «Application of Artificial neural network modeling for machining parameters optimization in drilling operation», Department of mechanical engineering, Trichy, India, 2014.
- [27]: R.Corne, C.Nath, M.E.Mansori, T. Kurfess, «Enhancing Spindle Power Data Application with Neural Network for Real-Time Tool Wear/Breakage Prediction during Inconel Drilling», School of Mechanical Engineering, Georgia Institute of Technology, Atlanta, Georgia, USA b-Arts et Métiers ParisTech, Aix-en-Provence, 13617, France, 2016.
- [28]: Παπαδάκης Στυλιανός «Το νεύρο-ασαφες μοντέλο ANFIS. Πρόβλεψη τιμών συναλλάγματος με νεύρο-ασαφή συστήματα», Διπλωματική εργασία, Τμήμα Μηχανικών Παραγωγής και Διοίκησης, Πολυτεχνείο Κρήτης, 2014.
- [29]: Χαλούλος .Σ.Κων/νος «Έλεγχος ισχύος ασαφούς λογικής σε τηλεπικοινωνιακά δίκτυα LMDS», Διπλωματική εργασία, Σχολή Ηλεκτρολόγων Μηχανικών και Ηλεκτρονικών Υπολογιστών, ΕΜΠ, 2010.
- [30]: Γιαννάκης Περικλής «Ιεραρχική νεύρο-ασαφής δομή δέντρου για την μοντελοποίηση πολυεπίπεδων δυναμικών συστημάτων» Διαπανεπιστημιακό διατμηματικό πρόγραμμα μεταπτυχιακών σπουδών στα προηγμένα συστήματα υπολογιστών και επικοινωνιών, Α.Π.Θ, 2010.
- [31]: Ali M.Abdulshahed, Andrew P.Longstaff, Simon Fletcher, «The application of ANFIS prediction models for thermal error compensation on CNC machine tools», Centre for Precision Technologies, University of Huddersfield, HD1 3DH, UK, 2012.
- [32]: Khalid Al-Ghamdi, Osman Taylan, «A comparative study on modelling material removal rate by ANFIS and polynomial methods in electrical discharge machining process», King Abdulaziz University, Faculty of Engineering, Department of Industrial Engineering, P.O. Box 80204, Jeddah 21589, Saudi Arabia, 2013.
- [33]: Ibrahem Maher, Liew Hui Ling, Ahmed A. D. Sarhan, M. Hamdi, « Improve wire EDM performance at different machining parameters – ANFIS modeling», Department of Mechanical Engineering, University of Malaya, Faculty of Engineering, University of Kafrelsheikh Department of Mechanical Engineering, Faculty of Engineering, University, Assiut, 2015.
- [34]: Binayak Sen, Uttam Kumar Mandal, Sankar Prasad Mondal « Advancement of an intelligent system based on ANFIS for predicting machining performance parameters of Inconel 690 – A perspective of metaheuristic

- approach», National Institute of Technology, Agartala, India, 2016.
- [35]: Hung-Wei Chiu, Ching-Hung Lee « Prediction of machining accuracy and surface quality for CNC machine tools using data driven approach», Department of Mechanical Engineering, National Chung Hsing University, Taiwan, ROC, 2017.
- [36]: Simranpreet Singh Gill, Jagdev Singh « An Adaptive Neuro-Fuzzy Inference System modeling for material removal rate in stationary ultrasonic drilling of sillimanite ceramic», Department of Mechanical Engineering, Beant College of Engineering and Technology, Gurdaspur, Punjab, India, 2010.
- [37]: S.Prakash, J.Lilly Mercy, Putti Venkata Siva Teja, P.Vijayalakshmi « ANFIS modeling of delamination during drilling of Medium Density Fiber (MDF) board», Professor, Department of Mechanical and Production Engineering, Sathyabama University, Chennai, 600119, India, 2014.
- [38]: Kumar Abhishek, Biranchi Narayan Panda, Saurav Datta, Siba Sankar Mahapatra «Comparing Predictability of Genetic Programming and ANFIS on Drilling Performance Modeling for GFRP Composites», Department of Mechanical Engineering, Department of Industrial Design, National Institute of Technology, Odisha, India, 2014.
- [39]: Lip Huat Saw, Li Wen Ho, Ming Chian Yew, Farazila Yusof, Nugroho Agung Pambudi, Tan Ching Ng, Ming Kun Yew «Sensitivity analysis of drill wear and optimization using Adaptive Neuro fuzzy-genetic algorithm technique toward sustainable machining», Faculty of Engineering and Science, UTAR, Selangor, Malaysia, Department of Mechanical Engineering, University of Malaya, Kuala Lumpur, Malaysia, Mechanical Engineering Education, Universitas, Surakarta, Indonesia, 2016.
- [40]: Παναγιώτης Ζιώβας-Δηλεπάλτας «Πειραματική μελέτη διάτρησης δοκιμίων συνθέτου υλικού πολυμερικής μήτρας με ενίσχυση ανθρακονήματος», Διπλωματική εργασία, Σχολή Μηχανολόγων Μηχανικών Ε.Μ.Π. 2018.