

READ ME.txt

Η πτυχιακή είναι αποθηκευμένη σε δύο μορφές αρχείων (.pdf και .xps)

Ο λόγος:

-το αρχείο .pdf αποθηκεύει σωστά τις εικόνες, ενώ δεν αποθηκεύει σωστά τα σχήματα που έγιναν με το matlab

-το αρχείο .xps αποθηκεύει σωστά τα σχήματα που έγιναν με το matlab, ενώ δεν αποθηκεύει σωστά τις εικόνες

Σημείωση:η εκτύπωση της εργασίας για να έχει το σωστό αποτέλεσμα έγινε και από τα δύο αρχεία.

© 2013 Κων/νος Παύλου

Η έγκριση της μεταπτυχιακής εργασίας από το Τμήμα Μηχανολόγων Μηχανικών της Πολυτεχνικής Σχολής του Πανεπιστημίου Θεσσαλίας δεν υποδηλώνει αποδοχή των απόψεων του συγγραφέα (Ν. 5343/32 αρ. 202 παρ. 2).

Εγκρίθηκε από τα Μέλη της Τριμελούς Εξεταστικής Επιτροπής:

Πρώτος Εξεταστής (Επιβλέπων) Δρ. Αναστάσιος Σταμάτης
Αναπληρωτής Καθηγητής, Τμήμα Μηχανολόγων Μηχανικών
Βιομηχανίας, Πανεπιστήμιο Θεσσαλίας

Δεύτερος Εξεταστής Δρ. Νικόλαος Πελεκάσης
Καθηγητής, Τμήμα Μηχανολόγων Μηχανικών Βιομηχανίας,
Πανεπιστήμιο Θεσσαλίας

Τρίτος Εξεταστής Δρ. Νικόλαος Ανδρίτσος
Αναπληρωτής Καθηγητής, Τμήμα Μηχανολόγων Μηχανικών
Βιομηχανίας, Πανεπιστήμιο Θεσσαλίας

Ευχαριστίες

Πρώτα απ' όλα, θέλω να ευχαριστήσω τον επιβλέποντα της μεταπτυχιακής εργασίας μου, Αναπληρωτή Καθηγητή κ. Αναστάσιο Σταμάτη, για την πολύτιμη βοήθεια και καθοδήγησή του κατά τη διάρκεια της δουλειάς μου. Επίσης, είμαι ευγνώμων στα υπόλοιπα μέλη της εξεταστικής επιτροπής της μεταπτυχιακής εργασίας μου, Καθηγητή κ. Νικόλαο Πελεκάση και Αναπληρωτή Καθηγητή κ. Νικόλαο Ανδρίτσο, για την προσεκτική ανάγνωση της εργασίας μου και για τις πολύτιμες υποδείξεις τους. Ευχαριστώ τους υποψήφιους διδάκτορες, διπλωματούχους Μηχανολόγους Μηχανικούς του Πανεπιστημίου Θεσσαλίας, κ. Διαμαντή Μπακάλη και Απόστολο Γκούντα, για την βοήθειά τους στην κατανόηση της πειραματικής διάταξης των εργαστηρίων Θερμοδυναμικής και Θερμικών Μηχανών των Μηχανολόγων Μηχανικών του Πανεπιστημίου Θεσσαλίας, καθώς και στην προσκόμιση αποτελεσμάτων από παλαιότερα πειράματα. Ευχαριστώ τους φίλους μου για την κατανόησή τους, ιδιαίτερα κατά τη διάρκεια των τελευταίων μηνών της προσπάθειάς μου. Πάνω απ' όλα, είμαι ευγνώμων στους γονείς μου για την ολόψυχη αγάπη και υποστήριξή τους όλα αυτά τα χρόνια. Αφιερώνω αυτήν την μεταπτυχιακή εργασία στην μητέρα μου και στον πατέρα μου.

Κων/νος Παύλου

ΕΦΑΡΜΟΓΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΣΤΟΝ ΜΙΚΡΟΣΤΡΟΒΙΛΟ OLYMPUS HP

ΚΩΝ/ΝΟΣ ΠΑΥΛΟΥ

Πανεπιστήμιο Θεσσαλίας, Τμήμα Μηχανολόγων Μηχανικών, 2013

Επιβλέπων Καθηγητής: Δρ. Αναστάσιος Σταμάτης, Αναπληρωτής Καθηγητής, Τμήμα
Μηχανολόγων Μηχανικών Βιομηχανίας, Πανεπιστήμιο Θεσσαλίας

Περίληψη

Τα τεχνητά νευρωνικά δίκτυα αποτελούν έναν εναλλακτικό τρόπο ανάπτυξης ενός αλγοριθμικού μοντέλου, σύμφωνα με το οποίο οι υπολογισμοί γίνονται παράλληλα και μαζικά, και η εκπαίδευση αντικαθιστά την ανάπτυξη προγράμματος. Ουσιαστικά εντάσσονται στον τομέα εφαρμογής της τεχνητής νοημοσύνης.

Αρχικά, γίνεται αναφορά στην συσχέτιση των βιολογικών με των τεχνητών νευρωνικών δικτύων, καθώς και εκτενής αναφορά στην λειτουργία, στην εκπαίδευση, στα βασικά χαρακτηριστικά και στις εφαρμογές των δεύτερων.

Στην συνέχεια παρουσιάζονται οι μικροστροβίλοι και ειδικότερα ο μικροστροβίλος Olympus HP ES, καθώς και η λειτουργία της πειραματικής διάταξης του συγκεκριμένου κινητήρα των εργαστηρίων Θερμοδυναμικής και Θερμικών Μηχανών των Μηχανολόγων Μηχανικών του Πανεπιστημίου Θεσσαλίας.

Ακολουθεί η προσομοίωση των αισθητήρων του κινητήρα. Εξετάζεται η χρήση των μεθόδων εκπαίδευσης Levenberg-Marquardt και BFGS quasi-Newton του εμπορικού υπολογιστικού πακέτου Matlab R2012b, εναλλάσσοντας σε κάθε μέθοδο την συνάρτηση μεταφοράς του στρώματος εξόδου μεταξύ της γραμμικής και της υπερβολικής εφαιπόμενης σιγμοειδής. Επιπρόσθετα, για τους αισθητήρες που περιγράφουν το ίδιο μέγεθος σε διαφορετικά σημεία περιμετρικά του κινητήρα, εξετάζεται η μοντελοποίηση τους με χρήση νευρωνικών δικτύων μονής (για κάθε αισθητήρα) και πολλαπλής εξόδου (για όλους τους κοινούς αισθητήρες μαζί).

Τέλος, παρουσιάζονται τα αποτελέσματα των μοντελοποιήσεων και κατόπιν συγκριτικής μελέτης αυτών, επιλέγεται η βέλτιστη μοντελοποίηση για τα μετρούμενα μεγέθη. Επίσης, τα διεξαγόμενα συμπεράσματα σχολιάζονται και αιτιολογούνται.

Πίνακας Περιεχομένων

1. ΕΙΣΑΓΩΓΗ ΣΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ	1
1.1. ΕΙΣΑΓΩΓΗ.....	1
1.2. ΒΙΟΛΟΓΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ	2
1.3. ΣΥΣΧΕΤΙΣΗ ΒΙΟΛΟΓΙΚΩΝ - ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ.....	6
1.4. ΛΕΙΤΟΥΡΓΙΑ ΤΩΝ ΤΝΔ	8
1.5. ΕΚΠΑΙΔΕΥΣΗ ΤΩΝ ΤΝΔ.....	10
1.5.1. Μάθηση με επίβλεψη.....	10
1.5.2. Μάθηση χωρίς επίβλεψη	11
1.5.3. Αλγόριθμοι εκπαίδευσης νευρωνικών δικτύων.....	12
1.5.4. Αλγόριθμος Back Propagation	13
1.6. ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΤΩΝ ΤΝΔ.....	19
1.7. ΕΦΑΡΜΟΓΕΣ ΤΩΝ ΤΝΔ	20
2. ΜΙΚΡΟΣΤΡΟΒΙΟΙ	23
2.1. ΕΙΔΗ ΑΕΡΟΠΟΡΙΚΩΝ ΚΙΝΗΤΗΡΩΝ	23
2.2. ΜΙΚΡΟΣΤΡΟΒΙΟΙ	24
2.2.1. Γενική περιγραφή λειτουργίας μικροστροβίλων και των παρελκομένων τους.....	25
2.2.2. Εφαρμογές μικροστροβίλων.....	27
3. ΚΙΝΗΤΗΡΑΣ ΕΡΓΑΣΤΗΡΙΟΥ.....	31
3.1. ΠΕΡΙΓΡΑΦΗ ΚΙΝΗΤΗΡΑ OLYMPUS HP ES.....	32
3.2. ΠΕΡΙΓΡΑΦΗ ΕΚΚΙΝΗΣΗΣ ΚΑΙ ΛΕΙΤΟΥΡΓΙΑΣ ΚΙΝΗΤΗΡΑ OLYMPUS HP ES	36
3.3. ΠΕΙΡΑΜΑΤΙΚΗ ΕΓΚΑΤΑΣΤΑΣΗ ΚΙΝΗΤΗΡΑ OLYMPUS HP ES	37
3.3.1. Σημεία λήψεως μετρήσεων του κινητήρα Olympus HP ES.....	38
3.3.2. Μετρητικά όργανα κινητήρα του κινητήρα Olympus HP ES	39
3.4. ΠΡΟΣΚΤΗΣΗ ΔΕΔΟΜΕΝΩΝ ΛΕΙΤΟΥΡΓΙΑΣ ΚΙΝΗΤΗΡΑ OLYMPUS HP ES	42
3.4.1. Ενισχυτής θερμοστοιχείων.....	43
3.4.2. Κάρτα πρόσκτησης δεδομένων.....	44
3.4.3. Ανάκτηση δεδομένων από την ECU.	47
3.4.4. Πρόγραμμα πρόσκτησης δεδομένων.....	47
4. ΠΡΟΣΟΜΟΙΩΣΗ ΛΕΙΤΟΥΡΓΙΑΣ ΚΙΝΗΤΗΡΑ OLYMPUS HP ES.....	51
4.1. ΣΥΝΑΦΕΙΣ ΜΕΛΕΤΕΣ ΧΡΗΣΗΣ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΣΕ ΑΕΡΟΚΙΝΗΤΗΡΕΣ.....	51
4.2. ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ	60
4.2.1. Πακέτα δεδομένων τροφοδότησης των νευρωνικών δικτύων.....	61
4.2.2. Αδιαστατοποίηση δεδομένων εισόδου	67
4.2.3. Χρησιμοποιούμενος κώδικας	68
4.3. ΠΕΡΙΓΡΑΦΗ ΔΙΕΡΓΑΣΙΑΣ ΑΞΙΟΛΟΓΗΣΗΣ	72
5. ΠΑΡΟΥΣΙΑΣΗ ΑΠΟΤΕΛΕΣΜΑΤΩΝ - ΣΥΜΠΕΡΑΣΜΑΤΑ.....	79
5.1. ΔΙΑΔΙΚΑΣΙΑ ΕΠΙΛΟΓΗΣ ΒΕΛΤΙΣΤΟΥ ΣΥΝΔΥΑΣΜΟΥ ΕΚΠΑΙΔΕΥΣΗΣ	79
5.2. ΑΠΟΤΕΛΕΣΜΑΤΑ ΓΙΑ ΕΚΠΑΙΔΕΥΣΗ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ ΜΙΑΣ ΕΞΟΔΟΥ	80
5.2.1. Συγκριτική μελέτη των συνδυασμών εκπαίδευσης.....	84
5.2.2. Τελική επιλογή νευρωνικών δικτύων μίας εξόδου	87
5.2.3. Διαγράμματα αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου.....	90

5.3.	ΑΠΟΤΕΛΕΣΜΑΤΑ ΓΙΑ ΕΚΠΑΙΔΕΥΣΗ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ ΜΕ ΠΟΛΛΑΠΛΕΣ ΕΞΟΔΟΥΣ.....	108
5.3.1.	<i>Συγκριτική μελέτη των συνδυασμών εκπαίδευσης.....</i>	110
5.3.2.	<i>Τελική επιλογή νευρωνικών δικτύων πολλαπλών εξόδων.....</i>	112
5.3.3.	<i>Διαγράμματα αποτελεσμάτων νευρωνικών δικτύων πολλαπλών εξόδων.....</i>	114
5.4.	ΣΥΓΚΡΙΣΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΟΝΗΣ ΚΑΙ ΠΟΛΛΑΠΛΗΣ ΕΞΟΔΟΥ	120
5.5.	ΤΕΛΙΚΗ ΕΠΙΛΟΓΗ ΜΟΝΤΕΛΟΠΟΙΗΣΗΣ ΜΕ ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ.....	124
6.	ΑΝΑΚΕΦΑΛΑΙΩΣΗ – ΣΥΜΠΕΡΑΣΜΑΤΑ –ΠΡΟΤΑΣΕΙΣ.....	127
6.1.	ΑΝΑΚΕΦΑΛΑΙΩΣΗ	127
6.2.	ΣΥΜΠΕΡΑΣΜΑΤΑ	128
6.3.	ΠΡΟΤΑΣΕΙΣ	130
	ΒΙΒΛΙΟΓΡΑΦΙΑ.....	131
	ΠΑΡΑΡΤΗΜΑΤΑ	135
Π.1	ΣΧΗΜΑΤΙΚΗ ΕΠΕΞΗΓΗΣΗ ΛΕΙΤΟΥΡΓΙΑΣ BACKPROPAGATION	135
Π.2	ΠΕΡΙΓΡΑΦΗ ΚΩΔΙΚΑ	143
Π.2.1.	<i>Πρόγραμμα nn_trainlm_purelin.m.....</i>	143
Π.2.2.	<i>Πρόγραμμα nn_trainlm_tansig.m.....</i>	143
Π.2.3.	<i>Πρόγραμμα nn_trainbfg_purelin.m.....</i>	143
Π.2.4.	<i>Πρόγραμμα nn_trainbfg_tansig.m.....</i>	144
Π.2.5.	<i>Υπορουτίνα xlsread.m.....</i>	144
Π.2.6.	<i>Υπορουτίνα adiastr1.m.....</i>	145
Π.2.7.	<i>Υπορουτίνα adiastr0.m.....</i>	145
Π.2.8.	<i>Υπορουτίνα fitnet.m.....</i>	146
Π.2.9.	<i>Υπορουτίνα dividerand.m.....</i>	146
Π.2.10.	<i>Υπορουτίνα trainlm.m.....</i>	147
Π.2.11.	<i>Υπορουτίνα trainbfg.m.....</i>	147
Π.2.12.	<i>Υπορουτίνα purelin.m.....</i>	147
Π.2.13.	<i>Υπορουτίνα tansig.m.....</i>	148
Π.2.14.	<i>Υπορουτίνα mse.m.....</i>	148
Π.2.15.	<i>Υπορουτίνα train.m.....</i>	148
Π.2.16.	<i>Υπορουτίνα gsubtract.m.....</i>	149
Π.2.17.	<i>Υπορουτίνα perform.m.....</i>	149
Π.2.18.	<i>Υπορουτίνα regression.m.....</i>	150
Π.2.19.	<i>Υπορουτίνα plotouttar.m.....</i>	150
Π.3	ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΗΛΕΚΤΡΟΝΙΚΟΥ ΥΠΟΛΟΓΙΣΤΗ	151
Π.4	ΦΩΤΟΓΡΑΦΙΕΣ ΔΟΚΙΜΑΣΤΗΡΙΟΥ.....	152

Κατάλογος Πινάκων

Πίνακας 1-1: Αλγόριθμοι εκπαίδευσης των τεχνητών νευρωνικών δικτύων.....	12
Πίνακας 1-2: Συναρτήσεις ενεργοποίησης.	14
Πίνακας 2-1: Είδη αεροπορικών κινητήρων.	23
Πίνακας 3-1: Χαρακτηριστικά κινητήρα Olympus HP με E-Start και Air-Start σύστημα.	31
Πίνακας 3-2: Μετρητικά μεγέθη σε κάθε θέση.....	39
Πίνακας 3-3: Θέσεις μετρητικών οργάνων.	39
Πίνακας 3-4: Θέσεις σύνδεσης θερμοστοιχείων στον ενισχυτή.....	44
Πίνακας 3-5: Συνδεσμολογία ακροδεκτών αισθητήρων πίεσης και θερμοκρασίας.	47
Πίνακας 4-1: Δεδομένα εισόδου νευρωνικών δικτύων.....	61
Πίνακας 4-2: Επιθυμητές εξόδους νευρωνικών δικτύων.	62
Πίνακας 4-3: Αποτελέσματα εκπαίδευσης νευρωνικού δικτύου για τον αισθητήρα T3 right χωρίς το κριτήριο σταματημού “number of validation checks”.	76
Πίνακας 4-4: Αποτελέσματα εκπαίδευσης νευρωνικού δικτύου για τον αισθητήρα T3 right με το κριτήριο σταματημού “number of validation checks”.	77
Πίνακας 4-5: Μεταβολή αποτελεσμάτων με και χωρίς χρήση του κριτηρίου “number of validation checks”.	77
Πίνακας 4-6: Ποσοστά χρήσης μεταβλητών εισόδου για εκπαίδευση, επιβεβαίωση και δοκιμή.	78
Πίνακας 5-1: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με μία έξοδο με μέθοδο εκπαίδευσης Trainlm και συνάρτηση μεταφοράς στρώματος εξόδου Purelin.	80
Πίνακας 5-2: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με μία έξοδο με μέθοδο εκπαίδευσης Trainlm και συνάρτηση μεταφοράς στρώματος εξόδου Tansig.	81
Πίνακας 5-3: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με μία έξοδο με μέθοδο εκπαίδευσης Trainbfg και συνάρτηση μεταφοράς στρώματος εξόδου Purelin.....	82
Πίνακας 5-4: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με μία έξοδο με μέθοδο εκπαίδευσης trainbfg και συνάρτηση μεταφοράς στρώματος εξόδου tansig.	83
Πίνακας 5-5: Σύγκριση των τεσσάρων μεθόδων εκπαίδευσης ως προς το σφάλμα εξόδου.	83
Πίνακας 5-6: Μεταβολή μεγεθών συνδυασμού Trainbfg–Tansig συναρτήσει του συνδυασμού Trainlm–Purelin.....	84
Πίνακας 5-7: Μεταβολή μεγεθών συνδυασμού Trainbfg–Purelin συναρτήσει του συνδυασμού Trainbfg–Purelin.	85
Πίνακας 5-8: Μεταβολή μεγεθών συνδυασμού Trainlm–Tansig συναρτήσει του συνδυασμού Trainlm–Purelin.....	86
Πίνακας 5-9: Τελική επιλογή νευρωνικών δικτύων μίας εξόδου.	87
Πίνακας 5-10: Τελική επιλογή νευρωνικών δικτύων μίας εξόδου.	88
Πίνακας 5-11: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με εξόδους το πλήθος των όμοιων αισθητήρων με μέθοδο εκπαίδευσης trainlm και συνάρτηση μεταφοράς στρώματος εξόδου purelin.	108
Πίνακας 5-12: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με εξόδους το πλήθος των όμοιων αισθητήρων με μέθοδο εκπαίδευσης trainlm και συνάρτηση μεταφοράς στρώματος εξόδου tansig.	108
Πίνακας 5-13: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με εξόδους το πλήθος των όμοιων αισθητήρων με μέθοδο εκπαίδευσης trainbfg και συνάρτηση μεταφοράς στρώματος εξόδου purelin.	109

Πίνακας 5-14: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με εξόδους το πλήθος των όμοιων αισθητήρων με μέθοδο εκπαίδευσης trainbfg και συνάρτηση μεταφοράς στρώματος εξόδου tansig.	109
Πίνακας 5-15: Σύγκριση των τεσσάρων μεθόδων εκπαίδευσης ως προς το σφάλμα εξόδου.	109
Πίνακας 5-16: Μεταβολή μεγεθών συνδυασμού Trainbfg–Tansig συναρτήσει του συνδυασμού Trainlm–Purelin.....	110
Πίνακας 5-17: Μεταβολή μεγεθών συνδυασμού Trainbfg–Purelin συναρτήσει του συνδυασμού Trainlm–Purelin.....	110
Πίνακας 5-18: Μεταβολή μεγεθών συνδυασμού Trainlm–Tansig συναρτήσει του συνδυασμού Trainlm–Purelin.....	111
Πίνακας 5-19: Τελική επιλογή νευρωνικών δικτύων πολλαπλής εξόδου.	112
Πίνακας 5-20: Τελική επιλογή νευρωνικών δικτύων πολλαπλής εξόδου.	112
Πίνακας 5-21: Μεταβολή αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου συναρτήσει πολλαπλών για το μέγεθος P3.	120
Πίνακας 5-22: Μεταβολή αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου συναρτήσει πολλαπλών για το μέγεθος P5.	121
Πίνακας 5-23: Μεταβολή αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου συναρτήσει πολλαπλών για το μέγεθος Pt3.	121
Πίνακας 5-24: Μεταβολή αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου συναρτήσει πολλαπλών για το μέγεθος Pt5.	122
Πίνακας 5-25: Μεταβολή αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου συναρτήσει πολλαπλών για το μέγεθος T3.	122
Πίνακας 5-26: Μεταβολή αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου συναρτήσει πολλαπλών για το μέγεθος T5.	123
Πίνακας 5-27: Τελική επιλογή είδους νευρωνικού δικτύου, μεθόδου εκπαίδευσης και χρήσης συναρτήσεων μεταφοράς για τους αισθητήρες του κινητήρα Olympus HP ES.....	125

Κατάλογος Σχημάτων

Σχήμα 1-1: (Αριστερά) Βασική λειτουργία ενός νευρώνα, (δεξιά) Μία δομή ΤΝΔ με μία κρυφή στρώση.....	8
Σχήμα 1-2: Τυπικός υπολογιστικός κόμβος ενός ΤΝΔ.....	9
Σχήμα 1-3: Κατηγορίες μεθόδων μάθησης των ΤΝΔ.....	10
Σχήμα 1-4: Τυπικός υπολογιστικός κόμβος ενός ΤΝΔ.....	11
Σχήμα 1-5: Μοντέλο Back Propagation.....	13
Σχήμα 1-6: Υπολογιστικός κόμβος.....	14
Σχήμα 3-1: (αριστερά) Τομή κινητήρα Olympus HP E-Start και (δεξιά) οι διαστάσεις του.....	32
Σχήμα 3-2: Αρίθμηση θέσεων σε τομή του κινητήρα Olympus HP ES και οι θέσεις των αισθητήριων οργάνων.....	38
Σχήμα 3-3: Κύκλωμα σύνδεσης μεταλλάκτη πίεσης.....	41
Σχήμα 3-4: Η μετρική αλυσίδα της διάταξης.....	43
Σχήμα 3-5: (αριστερά) μπροστινή και (δεξιά) πίσω όψη ενισχυτή θερμοστοιχείων.....	44
Σχήμα 4-1: Δομή νευρωνικού δικτύου τύπου backpropagation.....	52
Σχήμα 4-2: Δεδομένα εκπαίδευσης των νευρωνικών δικτύων.....	52
Σχήμα 4-3: Αποτελέσματα μοντελοποίησης νευρωνικών δικτύων.....	53
Σχήμα 4-4: Adaptive observer-engine with radial basis function network.....	54
Σχήμα 4-5: Δομή νευρωνικού δικτύου.....	55
Σχήμα 4-6: Δομή νευρωνικών δικτύων με την μεγαλύτερη ακρίβεια.....	55
Σχήμα 4-7: Σύγκριση αποτελεσμάτων προσομοίωσης και πραγματικών τιμών.....	56
Σχήμα 4-8: Σύγκριση αποτελεσμάτων προσομοίωσης και πραγματικών τιμών ισχύος.....	57
Σχήμα 4-9: Σύγκριση αποτελεσμάτων προσομοίωσης και πραγματικών τιμών συγκέντρωσης NO_x	58
Σχήμα 4-10: Απόδοση των μεθόδων ANN και ANFIS που χρησιμοποιήθηκαν στην συγκεκριμένη μελέτη.....	58
Σχήμα 4-11: Μεταβολή του σφάλματος rmse με την μεταβολή του ρυθμού εκπαίδευσης.....	59
Σχήμα 4-12: (α) Σχηματική απεικόνιση του κινητήρα με τα σημεία μέτρησης, (β) μοντέλο εκπαίδευσης νευρωνικού δικτύου.....	60
Σχήμα 4-13: Δομή νευρωνικού δικτύου.....	60
Σχήμα 4-14: Πλήθος των μετρήσεων για όλες τις επιθυμητές εξόδους εκτός της ώσης συναρτήσει των στροφών του κινητήρα.....	63
Σχήμα 4-15: (πάνω) Πλήθος των μετρήσεων για την ώση συναρτήσει των στροφών του κινητήρα, (κάτω) Μετρήσεις ώσης συναρτήσει των στροφών του κινητήρα.....	63
Σχήμα 4-16: (πάνω) Πλήθος των μετρήσεων για τις πιέσεις και τις θερμοκρασίες συναρτήσει των στροφών του κινητήρα, (κάτω) Πλήθος των μετρήσεων για την ώση συναρτήσει των στροφών του κινητήρα.....	64
Σχήμα 4-17: Μετρήσεις θερμοκρασιών συναρτήσει των στροφών του κινητήρα.....	65
Σχήμα 4-18: Μετρήσεις των πιέσεων συναρτήσει των στροφών του κινητήρα.....	66
Σχήμα 4-19: Μετρήσεις ώσης συναρτήσει των στροφών του κινητήρα.....	66
Σχήμα 4-20: Αδιαστατοποιημένα δεδομένα εισαγωγής του δικτύου της ώσης συναρτήσει των στροφών του κινητήρα.....	68
Σχήμα 4-21: Δομή νευρωνικού δικτύου.....	68
Σχήμα 4-22: Εμφανιζόμενο παράθυρο μετά το πέρας της διεργασία και εκπαίδευσης του δικτύου.....	70
Σχήμα 4-23: Απεικόνιση απόδοσης δικτύου.....	70

Σχήμα 4-24: Εμφανιζόμενο παράθυρο μετά το πέρας της διεργασία και εκπαίδευσης του δικτύου.	71
Σχήμα 4-25: Εμφανιζόμενο παράθυρο μετά το πέρας της διεργασία και εκπαίδευσης του δικτύου.	71
Σχήμα 4-26: Κανονική κατανομή τιμών σφάλματος rmse της δοκιμής για τον αισθητήρα T3right για 600 επαναλήψεις αποτελεσμάτων.	72
Σχήμα 4-27: Δομή νευρωνικού δικτύου για κάθε αισθητήρα.	73
Σχήμα 4-28: Συναρτήσεις μεταφοράς.	73
Σχήμα 4-29: Δομή νευρωνικού δικτύου για θερμοκρασία T5.....	74
Σχήμα 4-30: Αποτελέσματα εκπαίδευσης-δοκιμής του νευρωνικού δικτύου για τον αισθητήρα T3 right χωρίς το κριτήριο σταματημού “number of validation checks”.....	76
Σχήμα 4-31: Αποτελέσματα εκπαίδευσης-δοκιμής του νευρωνικού δικτύου για τον αισθητήρα T3 right με το κριτήριο σταματημού “number of validation checks”.....	77
Σχήμα 5-1: Διαδικασία επιλογής βέλτιστου συνδυασμού εκπαίδευσης.	79
Σχήμα 5-2: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα P3 left.	90
Σχήμα 5-3: Διάγραμμα targets – outputs για τον αισθητήρα P3 left.	90
Σχήμα 5-4: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα P3 right.	91
Σχήμα 5-5: Διάγραμμα targets – outputs για τον αισθητήρα P3 right.	91
Σχήμα 5-6: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα P5 down.....	92
Σχήμα 5-7: Διάγραμμα targets – outputs για τον αισθητήρα P5 down.	92
Σχήμα 5-8: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα P5 up.	93
Σχήμα 5-9: Διάγραμμα targets – outputs για τον αισθητήρα P5 up.....	93
Σχήμα 5-10: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα Pt3 left.	94
Σχήμα 5-11: Διάγραμμα targets – outputs για τον αισθητήρα Pt3 left.	94
Σχήμα 5-12: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα Pt3 right.	95
Σχήμα 5-13: Διάγραμμα targets – outputs για τον αισθητήρα Pt3 right.	95
Σχήμα 5-14: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα Pt4.	96
Σχήμα 5-15: Διάγραμμα targets – outputs για τον αισθητήρα Pt4.....	96
Σχήμα 5-16: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα Pt5 down.....	97
Σχήμα 5-17: Διάγραμμα targets – outputs για τον αισθητήρα Pt5 down.	97
Σχήμα 5-18: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα Pt5 up.	98
Σχήμα 5-19: Διάγραμμα targets – outputs για τον αισθητήρα Pt5 up.....	98
Σχήμα 5-20: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T3 left.	99
Σχήμα 5-21: Διάγραμμα targets – outputs για τον αισθητήρα T3 left.	99
Σχήμα 5-22: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T3 right.....	100
Σχήμα 5-23: Διάγραμμα targets – outputs για τον αισθητήρα T3 right.	100
Σχήμα 5-24: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T4.	101
Σχήμα 5-25: Διάγραμμα targets – outputs για τον αισθητήρα T4.	101
Σχήμα 5-26: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T5 down.....	102
Σχήμα 5-27: Διάγραμμα targets – outputs για τον αισθητήρα T5 down.	102
Σχήμα 5-28: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T5 left.	103
Σχήμα 5-29: Διάγραμμα targets – outputs για τον αισθητήρα T5 left.	103
Σχήμα 5-30: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T5 right.....	104
Σχήμα 5-31: Διάγραμμα targets – outputs για τον αισθητήρα T5 right.	104
Σχήμα 5-32: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T5 up.	105
Σχήμα 5-33: Διάγραμμα targets – outputs για τον αισθητήρα T5 up.....	105
Σχήμα 5-34: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα EGT.....	106
Σχήμα 5-35: Διάγραμμα targets – outputs για τον αισθητήρα EGT.	106

Σχήμα 5-36: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα THRUST.	107
Σχήμα 5-37: Διάγραμμα targets – outputs για τον αισθητήρα THRUST.....	107
Σχήμα 5-38: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες P3.	114
Σχήμα 5-39: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες P3.	114
Σχήμα 5-40: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες P5.	115
Σχήμα 5-41: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες P5.	115
Σχήμα 5-42: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες Pt3.	116
Σχήμα 5-43: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες Pt3.	116
Σχήμα 5-44: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες Pt5.	117
Σχήμα 5-45: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες Pt5.	117
Σχήμα 5-46: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες T3.	118
Σχήμα 5-47: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες T3.	118
Σχήμα 5-48: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T5.....	119
Σχήμα 5-49: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες T5.....	119
Σχήμα 5-50: Χαρακτηριστικά των νευρωνικών δικτύων των αισθητήρων του κινητήρα Olympus HP ES.....	125

Κατάλογος Εικόνων

Εικόνα 1-1: Νευρικό σύστημα ανθρώπου.....	3
Εικόνα 1-2: Σχηματική απεικόνιση βιολογικού νευρωνικού κυττάρου.	3
Εικόνα 1-3: Μέθοδος επικοινωνίας νευρικών κυττάρων.....	5
Εικόνα 1-4: Αντιστοιχία βιολογικού - τεχνητού νευρώνα.	6
Εικόνα 2-1: Μικροστροβίλος WREN MW54.....	24
Εικόνα 2-2: Τυπική μορφή φυγοκεντρικού συμπιεστή και μονής βαθμίδας τουρμπίνας μικροστροβίλου, συζευγμένα με μηχανικό τρόπο (άξονα).	25
Εικόνα 2-3: Σύστημα εκκίνησης Kerosene (P/N: KS-1).	26
Εικόνα 2-4: (Αριστερά) Κινητήρας JetCat P-120-SX και (δεξιά) τα παρελκόμενα του κινητήρα.....	26
Εικόνα 2-5: Μικροστροβίλος jet σε μοντέλο οχήματος.	27
Εικόνα 2-6: Μικροστροβίλος jet σε μοντέλο αεροσκάφους JMP HUSTLER.	27
Εικόνα 2-7: Μικροστροβίλος turboprop σε μοντέλο αεροσκάφους Tucano.....	27
Εικόνα 2-8: (a) Εφαρμογή μικροστροβίλου σε ελικόπτερο, (b) λάδι λιπάνσεως Mobil – jet oil 254 για ανάμειξη με το καύσιμο του κινητήρα, (c) φιάλη μείγματος προπανίου – βουτανίου για την προθέρμανση του κινητήρα και (d) γέμισμα δεξαμενής καυσίμου ελικοπτέρου με καύσιμο JET-A.....	28
Εικόνα 2-9: Πρωτότυπο UAV MQ-X της εταιρίας Lockheed Martin me turbo-diesel και jet κινητήρες.....	29
Εικόνα 2-10: Ανεμόπτερο με μικροστροβίλο Olympus HP E-start για την επιστροφή στον τόπο προσγείωσης (bringing home device).....	29
Εικόνα 2-11: Ο Σουηδός πιλότος Yves Rossy κατά την πτήση του με την ιπτάμενη πτέρυγα προωθούμενη από τέσσερις jet μικροστροβίλους.....	30
Εικόνα 3-1: Ο κινητήρας Olympus HP E-Start.....	31
Εικόνα 3-2: Αντλία καυσίμου του κινητήρα.....	33
Εικόνα 3-3: Βαλβίδες (αριστερά) αερίου εκκίνησης και (δεξιά) καυσίμου του κινητήρα.	34
Εικόνα 3-4: Βαλβίδες (αριστερά) αερίου εκκίνησης και (δεξιά) καυσίμου του κινητήρα.	34
Εικόνα 3-5: Μπαταρία κλειστού τύπου συνολικής τάσης 12Volt/1700 mA.	35
Εικόνα 3-6: Τερματικό πρόγραμμα παρακολούθησης της λειτουργίας τους κινητήρα.....	35
Εικόνα 3-7: Τερματικό παρακολούθησης της λειτουργίας του κινητήρα.....	36
Εικόνα 3-8: Χειριστήριο κινητήρα.....	36
Εικόνα 3-9: Κινητήρας Olympus HP ES με σημεία ελέγχου.....	37
Εικόνα 3-10: Αρίθμηση θέσεων σε τομή του κινητήρα Olympus HP ES και οι θέσεις των αισθητήρων οργάνων.....	40
Εικόνα 3-11: Τύποι μέτρησης πίεσης.....	40
Εικόνα 3-12: Μεταλλάκτης πίεσης A-10 της WIKA.	41
Εικόνα 3-13: Κυψελίδα φόρτισης και βάση κινητήρα.....	42
Εικόνα 3-14: Ο ενισχυτής των θερμοστοιχείων.....	43
Εικόνα 3-15: Η κάρτα πρόσκτησης δεδομένων USB-6229.....	45
Εικόνα 3-16: Λειτουργίες ακροδεκτών κάρτας.....	46
Εικόνα 3-17: Το πρόγραμμα πρόσκτησης δεδομένων.....	49

1. Εισαγωγή στα νευρωνικά δίκτυα

Στο πλαίσιο της μίμησης της φύσης, στον τομέα της επιστήμης των υπολογιστών, ο άνθρωπος ανέπτυξε τα τεχνητά νευρωνικά δίκτυα (ΤΝΔ). Στην προσπάθειά τους της εφαρμογής της τεχνητής νοημοσύνης, αντιγράφοντας την λειτουργία των βιολογικών νευρωνικών δικτύων, τα ΤΝΔ αποτελούν έναν εναλλακτικό τρόπο ανάπτυξης ενός αλγοριθμικού μοντέλου, σύμφωνα με το οποίο οι υπολογισμοί γίνονται παράλληλα και μαζικά, και η εκπαίδευση αντικαθιστά την ανάπτυξη προγράμματος. Σκοπός τους δεν είναι η αντικατάσταση του μέχρι τώρα παραδοσιακού προγραμματισμού, αλλά η συμπλήρωση αυτού. Είτε μόνα τους τα ΤΝΔ, είτε σε συνδυασμό με τις παραδοσιακές τεχνικές προγραμματισμού, προσφέρουν λύσεις σε προβλήματα με μεγαλύτερη αξιοπιστία. Στο συγκεκριμένο κεφάλαιο γίνεται αναφορά στην συσχέτιση των βιολογικών με των τεχνητών νευρωνικών δικτύων, καθώς και εκτενής αναφορά στην λειτουργία, στην εκπαίδευση, στα βασικά χαρακτηριστικά και στις εφαρμογές των δεύτερων.

1.1. Εισαγωγή

Η υπάρχουσα τεχνολογία που αναπτύσσει συνεχώς ο άνθρωπος, με σκοπό την διευκόλυνση του στην καθημερινότητά του, προέρχεται από την παρατήρηση και μίμηση της φύσης. Στον τομέα της επιστήμης των υπολογιστών, ο άνθρωπος καταβάλει συνεχώς προσπάθειες για ανάπτυξη υπολογιστικών συστημάτων που μιμούνται την ανθρώπινη συμπεριφορά. Ειδικότερα, υπολογιστικά συστήματα που διαθέτουν στοιχειώδη ευφυΐα: μάθηση, προσαρμοστικότητα, εξαγωγή συμπερασμάτων, κατανόηση από συμφραζόμενα, επίλυση πολύπλοκων προβλημάτων, κ.τ.λ. Έτσι εισήχθηκε στον κλάδο της επιστήμης των υπολογιστών ο όρος **Τεχνητή Νοημοσύνη**, ή σύμφωνα με τον Τζον Μακάρθι¹ : «η επιστήμη και η μεθοδολογία της δημιουργίας νοούντων μηχανών» .

Στα πλαίσια της τεχνητής νοημοσύνης έχουν αναπτυχθεί τα **Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ)**, τα οποία είναι εμπνευσμένα από το Κεντρικό Νευρικό Σύστημα των ζωντανών οργανισμών.

Όλοι οι ζωντανοί οργανισμοί, από τον πιο απλό (π.χ. βδέλλα), ως τον πιο σύνθετο (π.χ. άνθρωπο), διαθέτουν ένα νευρωνικό δίκτυο με βάση το οποίο εκτελούν ένα πλήθος διεργασιών, με πρωταρχικό σκοπό την επιβίωσή τους. Πλήθος ερεθισμάτων από τον εξωτερικό τους χώρο οδηγούνται διαμέσου του νευρικού συστήματος, στον εγκέφαλο του κάθε οργανισμού, όπου κατόπιν επεξεργασίας ακολουθούν ανάλογες διεργασίες. Ο εγκέφαλος αποτελείται και αυτός από ένα

1 Ο Τζον Μακάρθι (γεννήθηκε στις 4 Σεπτεμβρίου 1927 στη Βοστώνη της Μασαχουσέτης και πέθανε στις 23 Οκτωβρίου 2011) ήταν εξέχουσα φυσιογνωμία του πεδίου της Επιστήμης των υπολογιστών. Το 1971 έλαβε το βραβείο Turing για τις σημαντικές του συνεισφορές στον τομέα της Τεχνητής Νοημοσύνης. Ήταν υπεύθυνος για τη δημιουργία του όρου «Τεχνητή Νοημοσύνη» στη διάσκεψη του Ντάρτμουθ το 1956 και ο εφευρέτης της γλώσσας προγραμματισμού Lisp.

τεράστιο πλήθος νευρωνικών δικτύων. Κάθε νευρωνικό δίκτυο αποτελείται με την σειρά του από ένα μεγάλο αριθμό μονάδων που λέγονται νευρώνες. Ο νευρώνας είναι η πιο μικρή μονάδα του δικτύου.

Όπως και ένα βιολογικό νευρωνικό δίκτυο, το τεχνητό νευρωνικό δίκτυο είναι δίκτυο από απλούς υπολογιστικούς κόμβους (νευρώνες) διασυνδεδεμένους μεταξύ τους. Οι νευρώνες είναι τα δομικά στοιχεία του δικτύου. Κάθε τέτοιος κόμβος δέχεται ένα πλήθος αριθμητικών εισόδων από διαφορετικές πηγές (είτε από άλλους νευρώνες, είτε από το περιβάλλον), επιτελεί έναν υπολογισμό με βάση αυτές τις εισόδους και παράγει μία έξοδο. Η εν λόγω έξοδος είτε κατευθύνεται στο περιβάλλον, είτε τροφοδοτείται ως είσοδος σε άλλους νευρώνες του δικτύου.

Για την καλύτερη κατανόηση των τεχνητών νευρωνικών δικτύων ακολουθεί μία αναφορά στα βιολογικά νευρωνικά δίκτυα.

1.2. Βιολογικά νευρωνικά δίκτυα

Όλες οι λειτουργίες του ανθρώπινου οργανισμού ρυθμίζονται από το **Νευρικό Σύστημα**. Ο εγκέφαλος είναι το κύριο όργανο του νευρικού συστήματος και έχει τη δυνατότητα να λαμβάνει, να διακρίνει και να επεξεργάζεται τις πληροφορίες που φτάνουν από το εσωτερικό του σώματος και το περιβάλλον και να αντιδρά με τον κατάλληλο τρόπο. Το νευρικό σύστημα είναι αρκετά πολύπλοκο έτσι ώστε να συντονίζει τις δραστηριότητες του νευροφυτικού συστήματος, τις ψυχικές και τις αυτόματες αντανακλαστικά.


Το ανθρώπινο νευρικό σύστημα περιλαμβάνει το **Κεντρικό Νευρικό Σύστημα**, το **Περιφερειακό** και το **Αυτόνομο**.

Το Κ.Ν.Σ. αποτελείται από τον εγκέφαλο και τον προμήκη μυελό. Στο εσωτερικό του διακρίνουμε τα κινητικά και αισθητικά κέντρα του οργανισμού μας.

Το Π.Ν.Σ. περιλαμβάνει όλα τα όργανα του νευρικού συστήματος, δηλαδή τα (κρανιακά νεύρα) και τα νωτιαία νεύρα που συνδέουν το Κ.Ν.Σ. με την περιφέρεια. Στο Π.Ν.Σ. μπορούμε να διακρίνουμε στα **αισθητικά νεύρα**, που φέρουν τις πληροφορίες από την περιφέρεια στο σώμα, στον νωτιαίο μυελό και στον **εγκέφαλο** και τα κινητικά νεύρα που μεταφέρουν τις εντολές του εγκεφάλου στους μύες.

Το Αυτόνομο Νευρικό Σύστημα είναι αυτό που νευρώνει τα όργανα που ρυθμίζουν τις φυτικές λειτουργίες του οργανισμού, όπως την αναπνοή και την κυκλοφορία του αίματος. Το Α.Ν.Σ. ελέγχει την κίνηση των οργάνων αλλά και επεξεργάζεται τις πληροφορίες που του μεταφέρουν. Το Α.Ν.Σ. διαιρείται σε **συμπαθητικό** και σε **παρασυμπαθητικό**, τα οποία νευρώνουν όλα τα όργανα αλλά με αντίθετες επιδράσεις: για παράδειγμα, το παρασυμπαθητικό επιβραδύνει την καρδιακή συχνότητα, ενώ το συμπαθητικό την επιταχύνει. Σ' αυτές τις αντίθετες επιδράσεις αντιστοιχεί και η έκκριση των ορμονών από τους αδένες. Όλα αυτά γίνονται κάτω από τον έλεγχο του υποθαλάμου του εγκεφάλου.

Ο πυρήνας όλου του νευρικού συστήματος είναι το νευρικό κύτταρο ή νευρώνας. Ένα εξωτερικό ερέθισμα συλλαμβάνεται, συσχετίζεται συγχρόνως με άλλα, απομνημονεύεται και υφίσταται επεξεργασία. Αυτή η διαδικασία επαναλαμβάνεται συνεχώς, ακόμη και κατά τη διάρκεια του ύπνου, χάρη στα νευρικά κύτταρα που μεταφέρουν τα ερεθίσματα και τις πληροφορίες στον εγκέφαλο.




Εικόνα 1-1: Νευρικό σύστημα ανθρώπου.

Προέλευση:[4]

Με τον όρο νευρώνας ορίζουμε το κύτταρο που αποτελεί δομικό μέρος και λειτουργική μονάδα του νευρικού συστήματος. Κάθε νευρώνας αποτελείται από:

- Το **κυτταρικό σώμα**, με τον πυρήνα και το κυτταρόπλασμα.
- Τους **δενδρίτες** διαμέσου των οποίων εισέρχονται οι πληροφορίες στο κύτταρο.
- Τον **νευράξονα** από τον οποίο εξέρχονται οι πληροφορίες από το κύτταρο.



Εικόνα 1-2: Σχηματική απεικόνιση βιολογικού νευρωνικού κυττάρου.

Προέλευση:[2]

Οι **δενδρίτες** ομοιάζουν με τα κλαδιά ενός δένδρου και σε κάθε νευρικό κύτταρο μπορεί να υπάρχουν από εκατοντάδες έως εκατοντάδες χιλιάδες. Από αυτή την περιοχή γίνεται η πρόσληψη ερεθισμάτων στο νευρωνικό από άλλους νευρώνες.

Ο **νευράξονας** σε κάθε κύτταρο είναι ένας και μπορεί να τον παρομοιάσουμε σχηματικά σαν μια λεωφόρο σημάτων που στην μία άκρη της εισέρχονται τα σήματα που παράγονται στον πυρήνα και το κυτταρόπλασμα του νευρικού κυττάρου και στην άλλη άκρη υπάρχουν πολλές και διαφορετικές διακλαδώσεις που καταλήγουν σε πολλά άλλα παραπλήσια νευρικά κύτταρα. Η ταχύτητα των μηνυμάτων εξαρτάται από το εάν ένας νευράξονας είναι επικαλυμμένος ή όχι από μυελίνη (μυελώδες έλυτρο: προστατευτικό περίβλημα, που σχηματίζεται από μια μεγάλη αλυσίδα κυττάρων Σβαν (Schwann)). Το σύστημα αυτό διασφαλίζει την διάδοση των ηλεκτρικών παλμών (Spike) κατά μήκος του άξονα, με ταχύτητα περίπου 100 μ./δευτ. Ο αριθμός των spikes ανά δευτερόλεπτο ($F_i = \text{Spike/s}$) ορίζεται ως η "συχνότητα κένωσης" ή συχνότητα νεύρωσης του νευρώνα. Οι ηλεκτρικοί παλμοί (spikes) προκαλούνται από έναν μηχανισμό πόλωσης και εκπόλωσης της μεμβράνης του νευρώνα. Ανάμεσα στα έλυτρα υπάρχει ένα κένο, στο οποίο ο νευράξονας είναι γυμνός. Αυτό το σημείο ονομάζεται κόμβος Ραβιέ και είναι πλούσιο σε διαύλους νατρίου. Σε κάθε κόμβο το σήμα ενδυναμώνεται ξανά. Οι άξονες των κυττάρων του κεντρικού νευρικού συστήματος καλύπτονται από έλυτρα μυελίνης που φτιάχνονται από ειδικά νευρογλοιακά κύτταρα, τους ολιγοδενδρίτες. Η αλλοίωση της μυελίνης, παρούσα στους νευράξονες, εξαιτίας εσφαλμένης λειτουργίας του ανοσοποιητικού συστήματος, προκαλεί πολλαπλή σκλήρυνση, που οδηγεί στη σταδιακή απώλεια του μυϊκού ελέγχου, της εγκεφαλικής λειτουργίας και της ικανότητας μετάδοσης των μηνυμάτων.


Το **κυτταρικό σώμα** του βιολογικού νευρωνικού κυττάρου περιλαμβάνει τον πυρήνα του και έναν μεγάλο αριθμό οργανιδίων. Όπως και τα άλλα κύτταρα του οργανισμού, έτσι και τα νευρωνικά, έχουν διαφορετικό ηλεκτρικό φορτίο στις δύο πλευρές της κυτταρικής τους μεμβράνης. Στο εσωτερικό του κυττάρου το ηλεκτρικό φορτίο είναι αρνητικό ενώ στο εξωτερικό περιβάλλον του κυττάρου κυριαρχούν τα θετικά φορτία.

Σε περιπτώσεις που τα νευρικά κύτταρα δέχονται κάποιο ερέθισμα στις δενδριτικές απολήξεις τους, πχ αύξηση της θερμοκρασίας, τότε οι ειδικοί υποδοχείς που φέρουν, διεγείρονται και ανοίγουν τους διαύλους νατρίου που υπάρχουν στην κυτταρική επιφάνεια του δενδρίτη. Τα θετικό ιόν νάτριο εισέρχεται ταχύτατα μέσα στο αρνητικά φορτισμένο εσωτερικό περιβάλλον του δενδρίτη και του αλλάζει στιγμιαία το ηλεκτρικό του δυναμικό, παράγοντας έτσι μια τοπική εκφόρτιση ή εκπόλωση η οποία εκφράζεται σαν δυναμικό ενέργειας. Το δυναμικό ενέργειας διατηρείται χιλιοστά του δευτερολέπτου και αφενός η κυτταρική μεμβράνη του δενδρίτη επανέρχεται στην προηγούμενη κατάσταση (επαναπόλωση) με την αποβολή θετικά φορτισμένων ιόντων καλίου από το εσωτερικό της προς το εξωτερικό περιβάλλον διαμέσου ειδικών διαύλων, αφετέρου το δυναμικό ενέργειας ή καλύτερα η αίσθηση της θερμότητας, μεταδίδεται κατά μήκος του δενδρίτη προς το κέντρο του

νευρικού κυττάρου. Εκεί υφίσταται ή όχι μεταβολή και μεταδίδεται στη συνέχεια ταχύτατα κατά μήκος του νευράξονα σε πολλά άλλα παραπλήσια κύτταρα. Πολλοί μαζί νευρώνες, δημιουργούν δεμάτια νευρώνων και αποτελούν τα νεύρα.

Η μετάδοση του ερεθίσματος μεταξύ των νευρικών κυττάρων δεν γίνεται με απλή επαφή, αλλά παρεμβαίνουν κάποιοι σχηματισμοί που ονομάζονται **συνάψεις**. Το τμήμα της σύναψης που φθάνει αρχικά το ερέθισμα λέγεται προσυναπτικό τμήμα, το τμήμα που θα μεταδοθεί το ερέθισμα στο επόμενο κύτταρο λέγεται μετασυναπτικό τμήμα και ο μεταξύ τους χώρος λέγεται συναπτική σχισμή.

Στη σύναψη φθάνει το ηλεκτρικό δυναμικό ενέργειας και προκαλεί την διάνοιξη κάποιων διαύλων ιόντων πχ διαύλων ασβεστίου. Το ασβέστιο εισέρχεται από το εξωτερικό περιβάλλον στο κύτταρο και διεγείρει τα μιτοχόνδρια για παραγωγή ενέργειας. Η επιπλέον ενέργεια προκαλεί τη διάνοιξη κυστιδίων που περιέχουν ουσίες που ονομάζονται νευροδιαβιβαστές ². Οι νευροδιαβιβαστές εξέρχονται από το προσυναπτικό τμήμα της σύναψης, κυκλοφορούν στην συναπτική σχισμή και συνδέονται με τους αντίστοιχους υποδοχείς του μετασυναπτικού τμήματος. Η σύνδεση αυτή προκαλεί την διάνοιξη διαύλων θετικών ιόντων όπως νατρίου ή ασβεστίου που θα δημιουργήσουν εισερχόμενα στο κύτταρο μια νέα εκφόρτιση, παρόμοια με αυτή που ήδη περιγράψαμε προηγουμένως. Το νέο δυναμικό ενέργειας από το μετασυναπτικό τμήμα των δενδριτών του επόμενου κυττάρου θα καταλήξει στον νευράξονά του και από εκεί διαμέσου άλλων συνάψεων σε άλλα νευρικά κύτταρα.



Εικόνα 1-3: Μέθοδος επικοινωνίας νευρικών κυττάρων.

Προέλευση:[1]

² Οι νευροδιαβιβαστές είναι ουσίες (αμίνες, αμινοξέα, πεπτίδια κα) που παράγονται και αποθηκεύονται, συνήθως σε ειδικά κυστίδια, στο προσυναπτικό τμήμα της σύναψης. Κατά τη διάρκεια της μετάδοσης του ερεθίσματος το δυναμικό ενέργειας προκαλεί την έκκρισή τους στην συναπτική σχισμή. Από εκεί προσλαμβάνονται από τους ειδικούς υποδοχείς τους στο μετασυναπτικό τμήμα της σύναψης. Ο ρόλος των νευροδιαβιβαστών είναι η μετάδοση του ερεθίσματος, για το οποίο είναι υπεύθυνοι, από τον έναν νευρώνα στον επόμενο ή τους επόμενους.

Η ευκολία με την οποία η ηλεκτρική δραστηριότητα μεταδίδεται από τον άξονα στον δενδρίτη επηρεάζεται από το πλάτος της σύναψης, την απόστασή της από τον δενδρίτη και την πυκνότητα του ηλεκτροχημικού υλικού. Το ποσοστό της ηλεκτρικής δραστηριότητας που μεταδίδεται από τον δενδρίτη λέγεται **συναπτικό βάρος**. Είναι διαφορετικό για κάθε ζεύγος συνδεδεμένων νευρώνων και η γνώση στο βιολογικό νευρικό σύστημα είναι ουσιαστικά αποθηκευμένη με κατανομημένο τρόπο στις τιμές του συναπτικού βάρους. Με την μεταβολή των συναπτικών βαρών επιτυγχάνεται η μάθηση.

Ένα χαρακτηριστικό του ανθρωπίνου εγκεφάλου είναι η πλαστικότητα, δηλαδή η ικανότητα του σώματος να προσαρμόζεται στο περιβάλλον. Στον εγκέφαλο ενός ενήλικου ατόμου, η πλαστικότητα εκφράζεται με δύο τρόπους:

- Με δημιουργία νέων συνάψεων μεταξύ των νευρώνων
- Την καταστροφή ή αλλαγή των υπάρχοντων συνάψεων.

1.3. Συσχέτιση βιολογικών - τεχνητών νευρωνικών δικτύων

Όπως στον ανθρώπινο εγκέφαλο, έτσι και στα τεχνητά νευρωνικά δίκτυα η πλαστικότητα είναι απαραίτητη για την λειτουργία των νευρώνων σαν αυτόνομες μονάδες επεξεργασίας πληροφοριών. Στην γενική μορφή, ένα νευρωνικό δίκτυο είναι μία μηχανή που έχει σχεδιαστεί για να μοντελοποιεί τον τρόπο με τον οποίο ο εγκέφαλος εκτελεί μία συγκεκριμένη διαδικασία. Το δίκτυο υλοποιείται με την χρήση ανάλογου λογισμικού στον ηλεκτρονικό υπολογιστή.

Σε πλήρη αντιστοιχία με το απλοποιημένο μοντέλο του βιολογικού νευρώνα αναπτύχθηκε το μοντέλο του τεχνητού νευρώνα. Η αντιστοιχία διακρίνεται στην ακόλουθη εικόνα.



Εικόνα 1-4: Αντιστοιχία βιολογικού - τεχνητού νευρώνα.

Προέλευση:[5]

Οι κυριότερες ομοιότητες μεταξύ των βιολογικών και των τεχνητών νευρωνικών δικτύων είναι οι ακόλουθες:

a. Τρόπος λειτουργίας

Ένας βιολογικός νευρώνας λαμβάνει σήματα από άλλους νευρώνες μέσω των δενδριτών. Το άθροισμα των διεγέρσεων σε όλους τους δενδρίτες αποτελεί τη συνολική διεγερση του νευρώνα. Στο σώμα του νευρώνα πραγματοποιείται η επεξεργασία αυτών των σημάτων, τα οποία συνδυάζει με κάποιον τρόπο και εκτελεί μια μη γραμμική διεργασία για την απόκριση της εξόδου. Το σήμα εξόδου μεταφέρεται μέσω του άξονα και τελικά μέσω των συνάψεων σε άλλους νευρώνες.

Αντίστοιχα ένας τεχνητός νευρώνας δέχεται ένα διάνυσμα εισόδων $p(n)$. Κάθε είσοδος πολλαπλασιάζεται με έναν πραγματικό αριθμό που ονομάζεται συντελεστής βάρους. Τα συνοπτικά βάρη w χρησιμοποιούνται για την τροποποίηση των εισόδων του νευρώνα και αντιστοιχούν στη δύναμη μίας σύναψης. Οι τροποποιημένες εισοδοί αθροίζονται και στο αποτέλεσμα που συχνά χαρακτηρίζεται ως είσοδος του δικτύου εφαρμόζεται μια συνάρτηση ενεργοποίησης. Το κυτταρικό σώμα του νευρώνα αναπαρίσταται από τον αθροιστή και τη συνάρτηση ενεργοποίησης και η έξοδος του τεχνητού νευρώνα y αναπαριστά το σήμα στον άξονα του νευρώνα.

b. Φαινομενική απλότητα λειτουργίας

Μία διεργασία που εκτελούν και τα δύο δίκτυα μπορεί στην πραγματικότητα να φαίνεται πολύ απλή, όμως στην πραγματικότητα για την εκτέλεσή της κρύβεται ένα στρώμα πολύπλοκης σύνδεση νευρώνων. Όπως για την κίνηση του χεριού πρέπει να φθάσει το σήμα από τον εγκέφαλο του ανθρώπου μέσω ενός πλήθους διασυνδεδεμένων μεταξύ τους νευρών στους μυς του χεριού για την συστολή-διαστολή αυτών, έτσι και στο διαδίκτυο η απλή αποστολή ενός αρχείου βασίζεται σε ένα πλήθος πρωτοκόλλων και υπολογιστικών προγραμμάτων που καθορίζουν τους κανόνες και τις ρυθμίσεις του δικτύου.

c. Προσαρμοστικότητα

Η προσαρμοστικότητα είναι το στοιχείο που επιτρέπει στα βιολογικά νευρωνικά δίκτυα να αναπτύσσονται δημιουργώντας νέες συνάψεις. Ο ανθρώπινος εγκέφαλος έχει την δυνατότητα να ανταπεξέρχεται σωστά στην λειτουργία του για μία ολόκληρη ζωή, παρότι μερικά κύτταρα πεθαίνουν. Επίσης, δημιουργώντας νέες συνάψεις καθίσταται ικανή η μάθηση και απομνημόνευση νέων πραγμάτων. Παρόμοια και τα τεχνητά νευρωνικά δίκτυα, με τις μεθόδους εκπαίδευσής τους, μπορούν να προσαρμόζουν την λειτουργία τους ανάλογα με τις απαιτήσεις του χρήστη, μεταβάλλοντας το πλήθος των νευρώνων και τις μεταξύ τους συνάψεις.

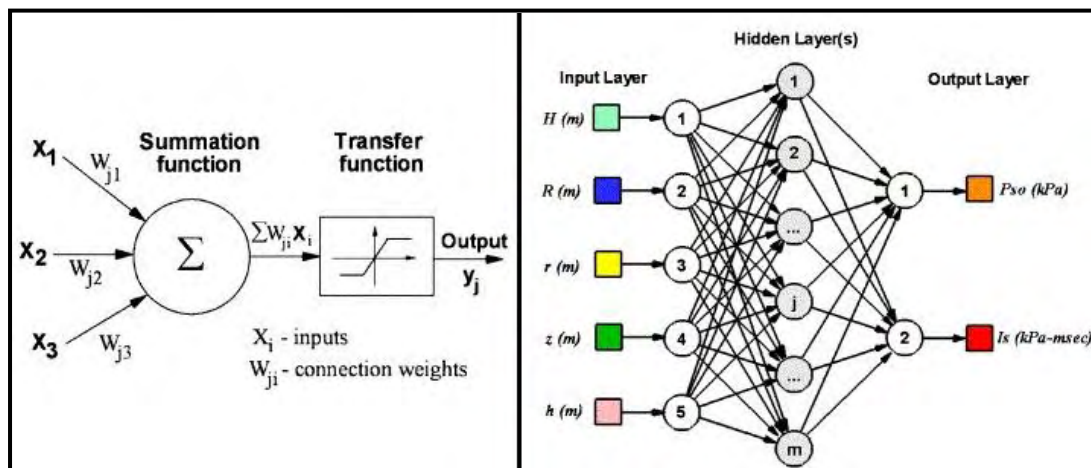
d. Ευαισθησία

Η ευαισθησία και των δύο δικτύων, παρά την ύπαρξη της προσαρμοστικότητας, απορρέει από την πολυπλοκότητα της δομής τους. Σε ένα

βιολογικό νευρωνικό δίκτυο αν για κάποιο λόγο υποστεί βλάβη καίριου κόμβου (π.χ. τραυματισμός σπονδυλικής στήλης, άρα και νωτιαίου μυελού), τότε έχουμε δυσλειτουργία του συστήματος και άρση της δυνατότητάς του για προσαρμογή στην νέα κατάσταση. Στα τεχνητά νευρωνικά δίκτυα αν καταστραφούν καίριοι κόμβοι-νευρώνες, τότε το νευρωνικό δίκτυο παύει να λειτουργεί σωστά και χάνει την δυνατότητά του για περαιτέρω εκπαίδευση και αναπροσαρμογή στα νέα δεδομένα.

1.4. Λειτουργία των ΤΝΔ

Όπως αναφέρθηκε και προηγουμένως, το νευρωνικό δίκτυο αποτελεί ένα δίκτυο από απλούς υπολογιστικούς κόμβους (νευρώνες) διασυνδεδεμένους μεταξύ τους. Κάθε νευρώνας του δικτύου επεξεργάζεται τα εισερχόμενα δεδομένα και τα μετατρέπει σε εξόδους. Οι εξόδοι αυτοί κατευθύνονται σε άλλους νευρώνες. Μερικοί νευρώνες σχηματίζουν το interface του δικτύου: υπάρχει μία στρώση (input layer) για τα σήματα εισόδου, μία ή περισσότερες κρυφές στρώσεις (hidden layers) και μία για τα σήματα εξόδου (output layer). Η πληροφορία μπαίνει στην στρώση εισόδου. Στη συνέχεια, όλες οι υπόλοιπες στρώσεις νευρώνων επεξεργάζονται το σήμα αυτό διαμέσου του δικτύου, μέχρι να φτάσει στη στρώση εξόδου.



Σχήμα 1-1: (Αριστερά) Βασική λειτουργία ενός νευρώνα, (δεξιά) Μία δομή ΤΝΔ με μία κρυφή στρώση.

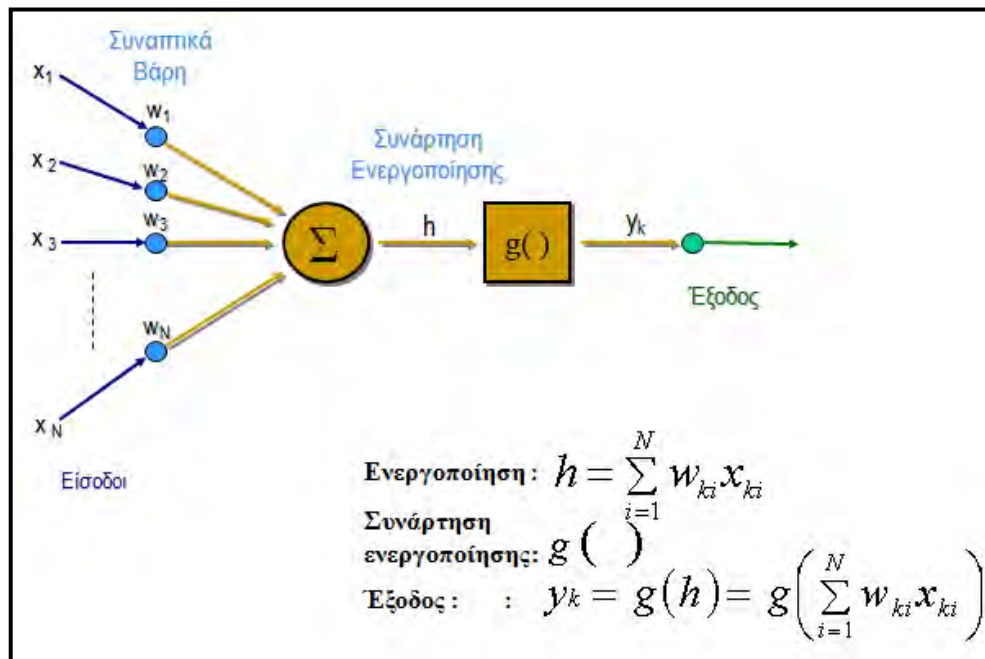
Προέλευση:[7]

Ο κάθε νευρώνας δέχεται ένα σύνολο αριθμητικών εισόδων από διαφορετικές πηγές (είτε από άλλους κόμβους ή από κάποια εξωτερική πηγή). Κάθε είσοδο σταθμίζεται με κατάλληλα βάρη σύνδεσης και αθροίζεται αλγεβρικά με τις υπόλοιπες εισόδους του κόμβου, σχηματίζοντας το όρισμα της συνάρτησης ενεργοποίησης του κόμβου. Η συνάρτηση ενεργοποίησης είναι εν γένει μη γραμμική. Συνηθέστερα χρησιμοποιούνται κάποιες συναρτήσεις ορίου, όπως η σιγμοειδής, η υπερβολική εφαιπτομένη, η γκαουσιανή, κ.τ.λ. . Το αποτέλεσμα αυτής της διαδικασίας αποτελεί την έξοδο του δικτύου που διανέμεται σε άλλους κόμβους.

Εάν x_{ki} είναι η i -οστή είσοδος του k νευρώνα, w_{ki} : το i -οστό συναπτικό βάρος του k νευρώνα και $g()$ η συνάρτηση ενεργοποίησης του νευρωνικού δικτύου, τότε η έξοδος y_k του k νευρώνα δίνεται από την εξίσωση:

$$y_k = g\left(\sum_{i=1}^N x_{ki} w_{ki}\right)$$

Στην παρακάτω εικόνα απεικονίζεται ένας τυπικός υπολογιστικός κόμβος ενός ΤΝΔ.



Σχήμα 1-2: Τυπικός υπολογιστικός κόμβος ενός ΤΝΔ.

Στον k -οστό νευρώνα υπάρχει ένα συναπτικό βάρος w_{k1} με ιδιαίτερη σημασία, το οποίο καλείται πόλωση ή κατώφλι (bias, threshold). Η τιμή της εισόδου του είναι πάντα η μονάδα, $w_{k1} = 1$. Εάν το συνολικό άθροισμα από τις υπόλοιπες εισόδους του νευρώνα είναι μεγαλύτερο από την τιμή αυτή, τότε ο νευρώνας ενεργοποιείται. Εάν είναι μικρότερο, τότε ο νευρώνας παραμένει ανενεργός. Η ιδέα προέκυψε από τα βιολογικά νευρικά κύτταρα.

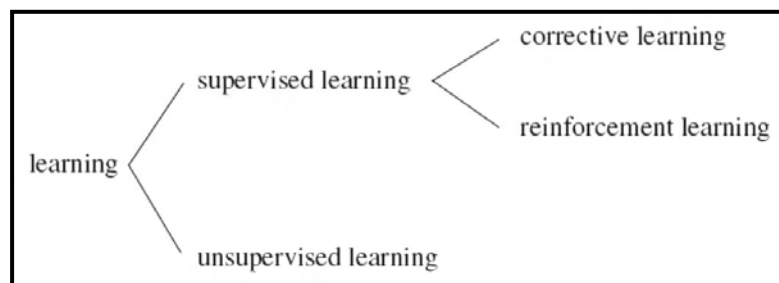
Το κύριο χαρακτηριστικό των ΤΝΔ είναι η εγγενής ικανότητα μάθησης. Ως μάθηση μπορεί να οριστεί η σταδιακή βελτίωση της ικανότητας του δικτύου να επιλύει κάποιο πρόβλημα (π.χ. η σταδιακή προσέγγιση μίας συνάρτησης). Η μάθηση επιτυγχάνεται μέσω της εκπαίδευσης, μίας επαναληπτικής διαδικασίας σταδιακής προσαρμογής των παραμέτρων του δικτύου (συνήθως των βαρών και της πόλωσής του) σε τιμές κατάλληλες ώστε να επιλύεται με επαρκή επιτυχία το προς εξέταση πρόβλημα. Αφού ένα δίκτυο εκπαιδευτεί, οι παράμετροί του συνήθως «παγώνουν» στις κατάλληλες τιμές και από εκεί κι έπειτα είναι σε λειτουργική κατάσταση. Το ζητούμενο είναι το λειτουργικό δίκτυο να χαρακτηρίζεται από μία

ικανότητα γενίκευσης: αυτό σημαίνει πως δίνει ορθές εξόδους για εισόδους καινοφανείς και διαφορετικές από αυτές με τις οποίες εκπαιδεύτηκε.

1.5. Εκπαίδευση των ΤΝΔ

Υπάρχουν πολλοί αλγόριθμοι που η εφαρμογή τους έχει στόχο την προσαρμογή των τιμών των βαρών ενός Τεχνητού Νευρωνικού Δικτύου. Όλες οι μέθοδοι μάθησης μπορούν να καταταχτούν στις ακόλουθες κατηγορίες :

- a. **μάθηση με επίβλεψη** (supervised learning)
 - i. **εκπαίδευση με διόρθωση σφάλματος** (corrective learning)
 - ii. **εκπαίδευση με ενίσχυση** (reinforcement learning)
- b. **μάθηση χωρίς επίβλεψη** (unsupervised learning)



Σχήμα 1-3: Κατηγορίες μεθόδων μάθησης των ΤΝΔ.

1.5.1. Μάθηση με επίβλεψη

Η μάθηση με επίβλεψη είναι μία διαδικασία που συνδυάζει έναν εξωτερικό εκπαιδευτή και τη συνολική γενικευμένη πληροφορία.

Κατά την εκπαίδευση με διόρθωση σφάλματος, στο δίκτυο παρουσιάζεται τόσο το διάνυσμα εισόδου όσο και το αντίστοιχο διάνυσμα εξόδου. Το διάνυσμα εξόδου είναι το σωστό για την συγκεκριμένη έξοδο. Έτσι μέσω της τεχνικής διόρθωσης σφάλματος, στα πλαίσια της εκπαίδευσης του ΤΝΔ, η έξοδος του δικτύου συγκρίνεται με την είσοδο του δικτύου και ανάλογα τροποποιούνται τα διάφορα βάρη. Με το τέλος της επιτυχής εκπαίδευσης, το ΤΝΔ είναι σε θέση για κάθε διάνυσμα εισόδου να δίνει το σωστό – αναμενόμενο διάνυσμα εξόδου. Παραδείγματα τα οποία αντιπροσωπεύουν την μάθηση με επίβλεψη συμπεριλαμβάνουν αποφάσεις για το πότε θα πρέπει να σταματήσει η διαδικασία εκπαίδευσης (κριτήρια σταματημού), αποφάσεις αναφορικά με τη συχνότητα παρουσίας στο δίκτυο τα πρότυπα εκπαίδευσης και η παρουσίαση προόδου του δικτύου.


Η εκπαίδευση με ενίσχυση αποτελεί μία τεχνική εκπαίδευσης στην οποία ο ορισμός του στόχου δεν είναι συγκεκριμένος, αλλά αόριστος. Αντί να ορίζεται η ακριβής επιθυμητή τιμή εξόδου, δίνεται μία βαθμολογία της απόδοσης του ΤΝΔ. Για να γίνει πιο κατανοητός, έστω ότι θέλουμε να εκπαιδευτεί ένα ΤΝΔ να παίζει σκάκι. Στην προκειμένη περίπτωση δεν αξιολογείται – βαθμολογείται η κάθε κίνηση

ξεχωριστά, αλλά η βαθμολογία εξαρτάται μόνο από το τελικό αποτέλεσμα (νίκη, ήττα ή ισοπαλία). Εάν το ΤΝΔ κερδίσει τότε ενισχύεται η τάση του δικτύου την επόμενη φορά να κάνει τις ίδιες κινήσεις (η μία ακολουθία κινήσεων), αντιθέτως αυτή η τάση εξασθενεί. Από σκοπιά υπολογιστικής ισχύς και χρόνου εκπαίδευσης έχει μεγάλες απαιτήσεις, αλλά όμως παρέχει την δυνατότητα εκπαίδευσης δικτύων με παρόμοιο τρόπο με την απόκτηση εμπειρίας από τους ανθρώπους, καθώς δίνεται βάση κυρίως στο αποτέλεσμα και όχι στο κάθε βήμα της διαδικασίας.

1.5.2. Μάθηση χωρίς επίβλεψη

Στην περίπτωση της εκπαίδευσης χωρίς επίβλεψη, δεν απαιτείται η ύπαρξη κάποιου εκπαιδευτή. Το δίκτυο από μόνο του διαμορφώνει τα βάρη των συνδέσεών του, χωρίς την ύπαρξη διανυσμάτων εξόδου. Το ΤΝΔ αναγνωρίζει από μόνο του κάποιες ομοιότητες μεταξύ των προτύπων εκπαίδευσης και τα ομαδοποιούν ανάλογα σε γενικότερες κατηγορίες. Μεγάλο πλεονέκτημα αυτής της μορφής εκπαίδευσης είναι ότι απαιτεί συγκριτικά πολύ μικρότερο υπολογιστικό χρόνο από ότι η εκπαίδευση με επίβλεψη, ενώ παράλληλα αν προστεθούν νέα πρότυπα, συνήθως δεν απαιτείται επανεκπαίδευση. Για να γίνει πιο κατανοητή αυτή η μέθοδος ακολουθεί παράδειγμα.

Έστω ότι σε ένα δυσδιάστατο σύστημα αξόνων υπάρχουν κάποια σημεία τα οποία ο χρήστης επιθυμεί να τα κατηγοριοποιήσει σε τρεις ομάδες. Γι' αυτήν την διεργασία μπορεί να χρησιμοποιηθεί ένας αλγόριθμος ταξινόμησης (classifier network) με τρεις γραμμές (lines), η κάθε μία για κάθε κατηγορία. Κάθε μία από τις υπολογιστικές μονάδες (computing units) στην έξοδο πρέπει να ειδικευτούν, ώστε να εκτελούνται ανάλογα με την κατηγορία στην οποία ανήκουν τα δεδομένα εισόδου. Αν η μία υπολογιστική μονάδα εκτελείται, τότε οι άλλες πρέπει να παραμένουν ανενεργές. Στην συγκεκριμένη περίπτωση εκπαίδευσης δεν γνωρίζουμε εξ αρχής ποια μονάδα θα ειδικευτεί – αντιστοιχηθεί σε κάποια κατηγορία. Γενικά δεν είναι γνωστό ακόμη και πόσες καλά ορισμένες κατηγορίες υπάρχουν. Αφού δεν υπάρχει εξωτερικός εκπαιδευτής, το δίκτυο από μόνο του πρέπει να οργανωθεί κατάλληλα ώστε να συσχετιστούν οι υπολογιστικές μονάδες με τις υπάρχουσες κατηγορίες.



Σχήμα 1-4: Τυπικός υπολογιστικός κόμβος ενός ΤΝΔ.

Προέλευση:[47]

Κατά κύριο λόγο οι περισσότερες διαδικασίες εκπαίδευσης είναι **off line**. Όταν χρησιμοποιείται όλο το δείγμα προτύπων για την τροποποίηση των τιμών των βαρών, πριν της τελικής χρήσης του δικτύου ως εφαρμογή, τότε ονομάζεται off line εκπαίδευση. Οι αλγόριθμοι εκπαίδευσης off line έχουν την απαίτηση να βρίσκονται στην εκπαίδευση του δικτύου παρόντα όλα τα πρότυπα. Το γεγονός αυτό αποκλείει την πιθανότητα εισαγωγής νέων πληροφοριών μέσω νέων προτύπων. Βέβαια, υπάρχουν και Τεχνητά Νευρωνικά Δίκτυα τα οποία δεν αποκλείουν την εισαγωγή νέας πληροφορίας, μετά την τελική τους μοντελοποίηση. Αν παρουσιαστεί ανάγκη εισαγωγής νέου προτύπου στο δίκτυο, μπορεί να γίνει απευθείας χωρίς τον κίνδυνο να χαθεί κανένα μέρος της αρχικής πληροφορίας. Το πλεονέκτημα των δικτύων που χρησιμοποιούν off line διαδικασίες εκπαίδευσης επικεντρώνεται κυρίως στη δυνατότητα να δίνουν καλύτερες λύσεις σε δύσκολα προβλήματα.

Η όλη φιλοσοφία των τεχνητών νευρωνικών δικτύων αλλάζει την προσέγγιση του προγραμματισμού απέναντι στους υπολογιστές. Η παραδοσιακή μέθοδος αφορά την ανάπτυξη προγραμμάτων, τα οποία καθορίζουν εκ των προτέρων, βήμα προς βήμα, τη λειτουργία και τις ενέργειες του υπολογιστή, μια διαδικασία που είναι ιδιαίτερα απαιτητική τόσο σε χρόνο όσο και σε ανθρώπινους πόρους. Αντίθετα, η προσέγγιση των ΤΝΔ, χρησιμοποιεί παραδείγματα εισόδου-εξόδου, με τα οποία το δίκτυο μαθαίνει να δίνει τις σωστές απαντήσεις για κάθε πρότυπο εισόδου.

Τελειώνοντας, πρέπει να τονιστεί ότι ανάλογα με το πρόβλημα πρέπει πάντοτε να επιλέγεται και η ανάλογη μέθοδος εκπαίδευσης για την επίτευξη του βέλτιστου αποτελέσματος.

1.5.3. Αλγόριθμοι εκπαίδευσης νευρωνικών δικτύων

Έχουν αναπτυχθεί πολλοί αλγόριθμοι εκπαίδευσης των νευρωνικών δικτύων, που βασίζονται σε διαφορετικές φιλοσοφίες εκπαίδευσης. Οι βασικότεροι αλγόριθμοι εκπαίδευσης των νευρωνικών δικτύων αναφέρονται στον ακόλουθο πίνακα.

Αλγόριθμοι εκπαίδευσης ΤΝΔ
Perceptron
Adaline – Madaline
Hopfield
Back Propagation
Kohoren
ART
General Regression
Probabilistic
DDA – Dynamical Decay Adjustment

Πίνακας 1-1: Αλγόριθμοι εκπαίδευσης των τεχνητών νευρωνικών δικτύων.

Ακολουθεί η ανάπτυξη του αλγορίθμου Back Propagation, ο οποίος χρησιμοποιήθηκε στο πλαίσιο της παρούσας εργασίας.

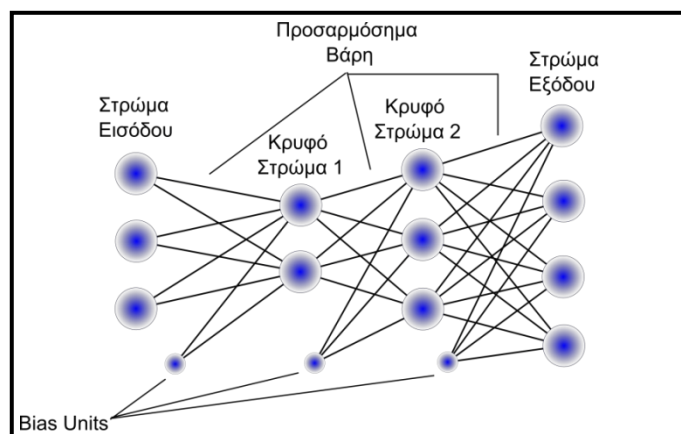
1.5.4. Αλγόριθμος Back Propagation

Ο Back Propagation (BP) είναι ο πλέον συνηθισμένος αλγόριθμος, από όσους χρησιμοποιούνται για την εκπαίδευση ΤΝΔ, με εφαρμογή σε ένα πολύ μεγάλο εύρος περιπτώσεων. Η θεωρητική βάση του BP, παρουσιάστηκε το 1974 από τον Paul Werbos και στη συνέχεια επαναεπινοήθηκε ανεξάρτητα το 1982 από τον David Parker. Το 1986 έγινε η πρώτη του παρουσίαση στο ευρύ κοινό από τους Rumelhart και McClelland.

Η λειτουργία του αλγορίθμου BP βασίζεται σε μια σχετικά απλή αρχή. Αν το δίκτυο δίνει λανθασμένη απάντηση, τότε τα βάρη των διαφόρων συνδέσεων τροποποιούνται κατά τρόπο ώστε να ελαττώνεται το σφάλμα και έτσι να αυξάνει η πιθανότητα να είναι σωστές οι μελλοντικές απαντήσεις του δικτύου. Ο μηχανισμός αυτής της τροποποίησης των βαρών ξεκινά από τις συνδέσεις του στρώματος εξόδου με το αμέσως προηγούμενό του και στη συνέχεια επεκτείνεται προς τα πίσω (δηλαδή προς τα πρώτα στρώματα), μέχρι να φτάσουμε στο στρώμα εισόδου. Σε αυτήν τη διαδικασία οφείλεται και το όνομα Back Propagation (οπίσθια διάδοση).


Η μορφή των δικτύων που εκπαιδεύει ο BP, είναι ίδια με το Perceptron μοντέλο, με μία όμως βασική διαφορά. Στην προκειμένη περίπτωση μπορούμε να έχουμε δίκτυα με περισσότερα του ενός στρώματα προσαρμόσιμων βαρών. Σε αυτή τη διαφορά οφείλει την μεγάλη του χρηστικότητα ο BP αλγόριθμος. Πράγματι η ύπαρξη περισσότερων τέτοιων στρωμάτων άρει τον βασικό περιορισμό του Perceptron μοντέλου, τη δυνατότητα δηλαδή να αντιμετωπίζει μόνο περιπτώσεις όπου τα πρότυπα είναι γραμμικά διαχωρίσιμα. Μια επιπλέον διαφορά μεταξύ των δύο αλγορίθμων είναι το ότι ο BP παράγει συνεχείς τιμές στην έξοδο των κόμβων αντί για τη δυαδική μορφή 1/0 ή 1/-1.

Τέτοια δίκτυα ονομάζονται δίκτυα εμπρόσθιας ροής (feed-forward nets) και εκτός των υπολογιστικών κόμβων περιέχουν και τα λεγόμενα bias units. Αυτά είναι κόμβοι σταθερής τιμής (συνήθως ίσης με 1), οι οποίοι λειτουργούν ως σταθερές ποσότητες στο άθροισμα κάθε κόμβου.



Σχήμα 1-5: Μοντέλο Back Propagation.

Κάθε κόμβος του δίκτυο Back Propagation (εκτός των κόμβων εισόδου) έχει την ακόλουθη μορφή:



Σχήμα 1-6: Υπολογιστικός κόμβος.

Ο κάθε κόμβος αποτελείται από δύο τμήματα:

- Το πρώτο τμήμα προσθέτει το γινόμενο των εισόδων του κόμβου με τα αντίστοιχα βάρη τους, δηλαδή πραγματοποιεί το σταθμισμένο άθροισμα του στρώματος εισόδου σύμφωνα με την σχέση:

$$S_j = \sum_{i=1}^n x_i \cdot w_{ji}$$

x_i : η τιμή του κόμβου εισόδου i

w_{ji} : το βάρος σύνδεσης μεταξύ του κόμβου εισόδου i , και του κόμβου εξόδου j .

- Το δεύτερο τμήμα αποτελείται από την ενεργοποίηση μίας συνεχής και παραγωγίσιμης συνάρτησης, η οποία έχει ως είσοδο το σταθμισμένο άθροισμα S_j . Οι πιο συχνά χρησιμοποιούμενες τέτοιες μη γραμμικές συναρτήσεις είναι η υπερβολική εφαιτομένη και η σιγμοειδής.

Υπερβολική εφαιτομένη	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	
Σιγμοειδής	$f(x) = \frac{1}{1 + e^{-a \cdot x + b}}$	

Πίνακας 1-2: Συναρτήσεις ενεργοποίησης.

Η διαδικασία της εκπαίδευσης γίνεται υπό επίβλεψη και πραγματοποιείται με βάση στα ακόλουθα βήματα:

- i. Τα βάρη λαμβάνουν κάποιες αρχικές (τυχαίες συνήθως) τιμές.
- ii. Με αυτές τις τιμές υπολογίζεται η έξοδος του δικτύου.
- iii. Αν ο κόμβος υπολογισμού βρίσκεται στο στρώμα εξόδου, τότε υπολογίζεται το σφάλμα της τιμής κάθε κόμβου εξόδου από την αντίστοιχη επιθυμητή.

$$\delta_j = (t_j - a_j) \cdot f'(S_j)$$

,όπου: δ_j : σφάλμα τιμής του κάθε κόμβου, t_j : επιθυμητή τιμή, a_j : τιμή κόμβου, $f'(S_j)$: η παράγωγος της συνάρτησης ενεργοποίησης για το άθροισμα S_j .

- iv. Αν ο κόμβος υπολογισμού βρίσκεται σε κάποιο κρυμμένο στρώμα το σφάλμα δ_j υπολογίζεται από τη σχέση:

$$\delta_j = \left[\sum_k \delta_k w_{kj} \right]$$

Δηλαδή το σφάλμα υπολογίζεται σαν συνάρτηση των σφαλμάτων των κόμβων που έχουν σαν είσοδο τον υπό εξέταση κόμβο.

- v. Τα διάφορα βάρη σύνδεσης τροποποιούνται σύμφωνα με την σχέση:

$$w'_{ji} = w_{ji} + \Delta w_{ji}$$

$$, \text{όπου } \Delta w_{ji} = n \cdot \delta_j \cdot a_i$$

Η μεταβολή των βαρών σύνδεσης κάθε κόμβου εξαρτάται από την τιμή του κόμβου και του σφάλματος που αντιστοιχεί σε αυτόν. Ο κανόνας αυτός ονομάζεται γενικευμένος κανόνας δέλτα (delta generalized rule). Η παράμετρος n είναι μια σταθερά που ονομάζεται ρυθμός εκμάθησης (learning rate). Συνηθισμένες τιμές κυμαίνονται στο εύρος 0,25-0,75 και συνήθως αντικατοπτρίζουν την ταχύτητα εκπαίδευσης του δικτύου. Έτσι μεγάλες τιμές επιταχύνουν την διαδικασία, αλλά μπορεί να οδηγήσουν σε αστάθειες και σε μη ικανοποιητική εκπαίδευση. Από την άλλη, πολύ μικρές τιμές οδηγούν συνήθως σε υπερβολικά αργή εκμάθηση

Η παραπάνω διαδικασία επαναλαμβάνεται για κάθε πρότυπο του συνόλου εκπαίδευσης. Με την παρουσίαση όλων των προτύπων θεωρούμε ότι έχει ολοκληρωθεί μία επανάληψη. Στη συνέχεια η όλη διαδικασία επαναλαμβάνεται μέχρις ότου η εκπαίδευση να έχει φτάσει σε ένα ικανοποιητικό σημείο. Για να μπορούμε να έχουμε μια εκτίμηση της “ποιότητας” της εκπαίδευσης χρειαζόμαστε κάποιο ποσοτικό μέγεθος. Ένα τέτοιο μέγεθος είναι το μέσο τετραγωνικό σφάλμα

(RMS). Γενικά, σφάλμα RMS μικρότερο του 0,1 δείχνει ότι το δίκτυο έχει μάθει το σετ εκπαίδευσης.

Στο τέλος της παρούσας εργασίας (στο Παράρτημα1) γίνεται αναλυτική επεξήγηση της λειτουργίας του αλγορίθμου Back Propagation για την εκπαίδευση ενός νευρωνικού δικτύου πολλαπλών στρωμάτων. Για της ανάγκες της ανάλυσης γίνεται χρήση ενός νευρωνικού δικτύου τεσσάρων στρωμάτων. Πιο συγκεκριμένα:

- δύο κόμβους εισόδου (inputs)
- ένας κόμβος εξόδου (output)
- δύο κρυφά στρώματα (hidden layers)
 - το πρώτο κρυφό στρώμα με τρεις κόμβους (nodes)
 - το δεύτερο κρυφό στρώμα με δύο κόμβους (nodes)

Μπορεί εκ πρώτης εικόνας ο αλγόριθμος BP να φαίνεται πως επιλύει όλα τα προβλήματα των προκατόχων του. Όμως και αυτός παρουσιάζει δύο σημαντικά προβλήματα που δεν μπορούν να αμεληθούν.

Πρώτον, οι χρόνοι εκπαίδευσης που απαιτούνται είναι αρκετά μεγάλοι. Ακόμα και απλά προβλήματα απαιτούν συνήθως κάποιες εκατοντάδες ή και χιλιάδες επαναλήψεις. Ρεαλιστικές εφαρμογές μπορούν να περιλαμβάνουν χιλιάδες πρότυπα στο σετ εκπαίδευσης και να απαιτούν μέχρι και εβδομάδες υπολογιστικού χρόνου ακόμα και σε μεγάλα συστήματα. Εντούτοις, συνήθως η εκπαίδευση απαιτείται να πραγματοποιηθεί μόνο μια φορά καθώς οι περισσότερες εφαρμογές δεν απαιτούν συνεχή εμπλουτισμό των σημείων εκπαίδευσης.

Δεύτερον, η πιθανότητα να μην έχουμε ικανοποιητική εκπαίδευση είναι σημαντική. Σε αντίθεση με δίκτυα ενός στρώματος, δεν αποδεικνύεται μαθηματικά ότι θα επέλθει σύγκλιση όταν εργαζόμαστε με μεγαλύτερα δίκτυα. Εξάλλου, πάντα υπάρχει και η περίπτωση ο αλγόριθμος να “κολλήσει” σε κάποιο τοπικό ελάχιστο. Επίσης, αξίζει να σημειωθεί πως για κάθε πρόβλημα, πάντα υπάρχει έναν βέλτιστος συνδυασμός αριθμού κρυφών στρωμάτων με το πλήθος κόμβων που εμπεριέχουν τα δίκτυα αυτά. Συνεπώς δεν σημαίνει ότι όσο μεγαλύτερη υπολογιστική ισχύς έχουμε, τόσο περισσότερους κόμβους και κρυφά στρώμα πρέπει να βάλουμε ώστε να έχουμε καλύτερα αποτελέσματα.

Για την αντιμετώπιση των προβλημάτων αυτών έχουν αναπτυχθεί διάφορες μέθοδοι. Η προσθήκη ενός όρου ορμής στην σχέση τροποποίησης των βαρών σύνδεσης μερικές φορές επιταχύνει τη διαδικασία. Βελτιώσεις στην εκπαίδευση έχουν επίσης γίνει με μεταβολή του ρυθμού εκμάθησης η κατά τη διάρκεια της τελευταίας (η εκπαίδευση ξεκινά με σχετικά μεγάλη τιμή για το η η οποία μειώνεται σταδιακά ή ο δεύτερος τρόπος (πιο πολύπλοκος), το δίκτυο εκπαιδεύεται με μικρές τιμές του η , οι οποίες αυξάνονται καθώς εκπαιδεύεται το δίκτυο και μειώνονται ξανά στο τελευταίο στάδιο της εκπαίδευσης). Τέλος για την αποφυγή των τοπικών ελάχιστων έχουν χρησιμοποιηθεί διάφορες τεχνικές όπως είναι η προσθήκη θορύβου στα βάρη, η τροποποίηση του σετ εκπαίδευσης, κλπ..

Παρά τα παραπάνω προβλήματα, ο BP μέχρι στιγμής έχει δείξει πολύ καλά αποτελέσματα καθώς μπορεί να προσεγγίσει οποιοδήποτε πρόβλημα για το οποίο υπάρχει ικανοποιητικός αριθμός παραδειγμάτων. Ένα σημαντικό πλεονέκτημα αποτελεί και το γεγονός ότι η έξοδος των δικτύων είναι ένα διάνυσμα συνεχών αντί για δυαδικών τιμών. Έτσι είναι δυνατή η χρήση του για την προσέγγιση μιας άγνωστης συνάρτησης για την οποία δεν υπάρχει κάποια γνώση ως προς τη μορφή της, με τη χρήση μόνο παραδειγμάτων τιμών της.

Τελειώνοντας, αξίζει να σημειωθεί ότι αν και σε αρκετά σημεία ομοιάζει με τα βιολογικά νευρικά κύτταρα (άθροιση εισόδων, ύπαρξη βαρών σύνδεσης), η φιλοσοφία του αλγορίθμου BP δεν μιμείται την λειτουργία των βιολογικών συστημάτων. Στη φύση, η διαδικασία υπολογισμού του σφάλματος και της διόρθωσης βάσει αυτού των βαρών σύνδεσης δεν έχει μέχρι τώρα παρατηρηθεί.

Παραλλαγές Του Back Propagation Αλγόριθμου [25]

Υπάρχουν πολλές παραλλαγές του τυπικού Back Propagation (BP) αλγόριθμου. Η πλήρης αναφορά όλων αυτών των παραλλαγών είναι αδύνατη για αυτό και παρουσιάζονται επιλεκτικά ορισμένες.

1. Αν θεωρήσει κανείς την διαφορά της εξόδου του δικτύου από την επιθυμητή σαν μια συνάρτηση, η λειτουργία του BP ουσιαστικά μετατρέπεται στην ελαχιστοποίηση αυτής της συνάρτησης, δηλαδή:

$$\text{BP} \Leftrightarrow \text{Ελαχιστοποίηση της } f(x),$$

όπου $x=(x_1, x_2, \dots, x_n)$ ένα n -διάστατο διάνυσμα.

Η κλασσική προσέγγιση του προβλήματος αφορά την επιλογή μιας αρχικής τιμής $x(0)$ και εν συνεχεία τροποποίηση αυτής της πρώτης εκτίμησης με κάποια σχέση της μορφής:

$$x^{(k+1)} = x^{(k)} + a^{(k)} \cdot d^{(k)}$$

Στην παραπάνω σχέση η παράμετρος a καθορίζει το μέγεθος της μεταβολής του x σε κάθε χρονική στιγμή ενώ η d καθορίζει την κατεύθυνση προς την οποία πρέπει να γίνει η μετατροπή ώστε να βελτιωθεί η τιμή της f . Για την επιλογή της κατεύθυνσης υπάρχουν δύο δημοφιλείς μέθοδοι.

- Η μέθοδος της πιο απότομης καθόδου (steepest descent method).

$$d^{(k)} = -\nabla f(x^{(k)})$$

- Η μέθοδος του Newton

$$d^{(k)} = -[\nabla^2 f(x^{(k)})]^{-1} \cdot \nabla f(x^{(k)})$$

Καθεμία από τις δύο αυτές μεθόδους έχει κάποια μειονεκτήματα. Αν και η πρώτη μέθοδος είναι εύκολα εφαρμόσιμη είναι αργή, ιδιαίτερα όταν η επιφάνειες που αναπαριστούν την περίπτωση $f(x)=\text{const}$ μοιάζουν με μεγάλες “κοιλιάδες” ή τοπικές ανυψώσεις (κορυφογραμμές). Από την άλλη μεριά, η μέθοδος του Newton συγκλίνει πολύ γρήγορα όταν η λύση βρίσκεται κοντά στη βέλτιστη. Εντούτοις, είναι υπολογιστικά περισσότερο απαιτητική καθώς υπολογίζει το μέγεθος $\nabla^2 f(x^{(k)})$.

Η πιο δημοφιλής από τις μεθόδους της πιο απότομης καθόδου είναι η μέθοδος συζευγμένης κλίσης (conjugate gradient method). Στη μέθοδο αυτή η παράμετρος $d(k)$ υπολογίζεται ως ο γραμμικός συνδιασμός του τρέχοντος και του προηγούμενου διανύσματος κλίσης. Δηλαδή, ξεκινώντας με $d^{(0)} = -\nabla^2 f(x^{(0)})$ οι επόμενες κατευθύνσεις υπολογίζονται με χρήση της σχέσης:

$$d^{(k+1)} = -\nabla f(x^{(k+1)}) + b^{(k)} \cdot d^{(k)}$$

Ο όρος $b^{(k)}$ είναι ένας αριθμός που εγγυάται την αμοιβαία συνεισφορά των δύο όρων.

Η πιο δημοφιλής από τις μεθόδους Newton είναι η ψευδό-Newton μέθοδος (quasi-Newton method). Η μέθοδος αυτή αποφεύγει τον υπολογισμό της τιμής $\nabla^2 f(x^{(k)})$, καθώς την προσεγγίζει με μια σταθερή μήτρα $H(k)$. Έτσι, η σχέση υπολογισμού της διεύθυνσης γίνεται:

$$d^{(k)} = -H^{(k)} \cdot \nabla f(x^{(k)})$$

2. Μία άλλη παραλλαγή της μεθόδου αφορά την μείωση του μέσου τετραγωνικού σφάλματος ως παράμετρο καθορισμού της εκπαιδευτικής διαδικασίας. Μειονέκτημα της παραλλαγής αυτής, απαιτεί η ανάγκη υπολογισμού της δεύτερης παραγώγου του σφάλματος.

3. Η μέθοδος διαδοχικής συσχέτισης (cascade correlation method) ακολουθεί κάποια από τις παραπάνω παραλλαγές. Η διαφορά έγκειται στο ότι το δίκτυο ξεκινάει χωρίς να υπάρχουν κόμβοι στο κρυμμένο στρώμα. Τέτοιοι κόμβοι προστίθενται διαδοχικά, ενώ κάθε φορά που έχουμε μια τέτοια προσθήκη, τα βάρη σύνδεσης των κόμβων εισόδου “παγώνουν” χωρίς να επιτρέπεται να μεταβληθούν στη συνέχεια.

4. Αρκετές προτάσεις έχουν γίνει για την εισαγωγή μεθόδων που δεν εξαρτώνται από την κλίση της επιφάνειας σφάλματος. Μία τέτοια μέθοδος

προτείνεται από τους Bremmerman και Anderson. Στη μέθοδο αυτή η τροποποίηση των συνδέσεων $w+\Delta w$ γίνεται με τυχαίο τρόπο, καθώς το Δw ανήκει σε μία πολυμεταβλητή κανονική κατανομή μηδενικής μέσης τιμής και τυπικής απόκλισης σ . Σε κάθε επανάληψη, κάποια συνάρτηση σφάλματος (π.χ. το άθροισμα των σφαλμάτων) εξετάζεται ώστε να αποτιμάται η διαδικασία.

1.6. Χαρακτηριστικά των ΤΝΔ

Τα τελευταία χρόνια έχει υπάρξει μία έκρηξη ενδιαφέροντος για τα νευρωνικά δίκτυα καθώς εφαρμόζονται με μεγάλη επιτυχία σε ένα ασυνήθιστα μεγάλο φάσμα τομέων της επιστήμης και της τεχνολογίας, όπως τα χρηματοοικονομικά, η ιατρική, η επιστήμη μηχανικού, η γεωλογία, η φυσική, η ρομποτική, η επεξεργασία σήματος κτλ. Στην πραγματικότητα, τα νευρωνικά δίκτυα εισάγονται οπουδήποτε τίθεται θέμα πρόβλεψης, ταξινόμησης ή ελέγχου. Η σαρωτική αυτή επιτυχία, μπορεί να αποδοθεί στα ακόλουθα χαρακτηριστικά των ΤΝΔ.

i. **Μνημονική Ισχύς:** Με τον όρο Μνημονική Ισχύ, ορίζουμε τη δυνατότητα ενός ΤΝΔ να μαθαίνει ένα σύνολο δεδομένων, δηλαδή να αποθηκεύει στα βάρη σύνδεσης τα στοιχεία εκείνα που θα του επιτρέπουν να αναπαράγει τις σωστές απαντήσεις για τα δεδομένα πρότυπα. Αυτή η διαδικασία πραγματοποιείται μέσω της τροποποίησης των βαρών σύνδεσης μεταξύ των υπολογιστικών κόμβων του δικτύου. Είναι επόμενο, λοιπόν, ενδεχόμενη αύξηση του αριθμού των υπολογιστικών κόμβων, να επηρεάζει θετικά τη μνημονική ισχύ του δικτύου, καθώς αυξάνεται ο αριθμός των διασυνδέσεων και κατά συνέπεια των βαρών που αντιστοιχούν σε αυτές.

ii. **Ευχρηστία:** Τα νευρωνικά δίκτυα εκπαιδεύονται με παραδείγματα. Ο χρήστης συγκεντρώνει αντιπροσωπευτικά δεδομένα και στη συνέχεια, καθώς τα τροφοδοτεί συστηματικά στο δίκτυο μέσω των κατάλληλων αλγορίθμων εκπαίδευσης, το δίκτυο «αντιλαμβάνεται» αυτομάτως τη δομή των δεδομένων και η «γνώση» αυτή εκφράζεται ως κατάλληλες επιλογές συναπτικών βαρών. Επομένως το τελικό αποτέλεσμα της εκπαίδευσης με ένα συγκεκριμένο σύνολο παραδειγμάτων είναι ο προσδιορισμός των κατάλληλων βαρών του δικτύου. Ο χρήστης χρειάζεται να έχει κάποιες ουσιώδεις γνώσεις σχετικά με τον τρόπο επιλογής και προετοιμασίας των δεδομένων, τον τρόπο εκλογής του κατάλληλου νευρωνικού δικτύου και στο πώς θα ερμηνευτούν τα αποτελέσματα. Παρά ταύτα, το επίπεδο των γνώσεων του χρήστη που απαιτούνται για μια επιτυχημένη εφαρμογή των νευρωνικών δικτύων, είναι πολύ χαμηλότερο συγκριτικά με κάποια περίπτωση που θα χρησιμοποιούνταν ορισμένες πιο παραδοσιακές, μη γραμμικές στατιστικές μέθοδοι.

iii. **Ιδιότητα Γενίκευσης:** Ως Γενίκευση, ορίζεται η δυνατότητα των νευρωνικών δικτύων να δίνουν καλά αποτελέσματα για δεδομένα εισόδου τα οποία διαφέρουν από αυτά με τα οποία έχουν εκπαιδευτεί. Αντίθετα με τη λειτουργία των ψηφιακών

Η/Υ, οι οποίοι μπορούν να δώσουν αποτελέσματα μόνο για τις περιπτώσεις για τις οποίες έχουν προγραμματιστεί, τα νευρωνικά δίκτυα εμφανίζουν αυτή τη δυνατότητα της γενίκευσης. Ωστόσο, συχνά η γενίκευση έρχεται σε αντίφαση με την ικανότητα ενός δικτύου να μαθαίνει καλά το σύνολο εκπαίδευσης. Είναι δηλαδή πιθανό, να έχουμε πολύ καλά αποτελέσματα στο σύνολο εκπαίδευσης αλλά η συμπεριφορά σε άγνωστα σημεία να μην είναι εξίσου καλή. Γενικά αν και δεν υπάρχουν συγκεκριμένοι κανόνες, έχει παρατηρηθεί ότι η δυνατότητα γενίκευσης ενός δικτύου είναι αντιστρόφως ανάλογη του μεγέθους του.

iv. **Ιδιότητα Σύνθεσης:** Η ιδιότητα της σύνθεσης αναφέρεται στην ικανότητα ενός δικτύου το οποίο έχει εκπαιδευτεί στο να αναγνωρίζει κάποια χαρακτηριστικά και να διατηρεί την ικανότητα να αναγνωρίζει σωστά τα χαρακτηριστικά αυτά ακόμα και όταν συνυπάρχουν. Η διαδικασία αυτή είναι εξαιρετικά περίπλοκη, (στη φύση παρατηρείται μόνο στον ανθρώπινο εγκέφαλο), με αποτέλεσμα εν γένει να είναι ιδιαίτερα δύσκολη η δημιουργία ενός δικτύου το οποίο εμφανίζει την ιδιότητα αυτή.

v. **Λειτουργία υπό μερική καταστροφή:** Λόγω του τρόπου οργάνωσής τους, τα ΤΝΔ διαμοιράζουν τις πληροφορίες που λαμβάνουν παρά τις συγκεντρώνουν σε κάποια λίγα σημεία. Σε ένα τυπικό δίκτυο, η αποθηκευμένη πληροφορία είναι κοινή για διάφορους υπολογιστικούς κόμβους. Αυτή η μεθοδολογία καταχώρησης των δεδομένων παρουσιάζει το βασικό πλεονέκτημα ότι πολύ συχνά η πληροφορία είναι πλεονάζουσα, δηλαδή έχει καταχωρηθεί (ολόκληρη ή εν μέρει) περισσότερες από μία φορές. Εκ πρώτης όψεως, το γεγονός αυτό φαίνεται να αποτελεί σπατάλη μνημονικής ισχύος, ωστόσο αυτή η πρώτη εντύπωση ανατρέπεται αν αναλογιστούμε ότι το δίκτυο μπορεί να συνεχίσει να λειτουργεί σωστά, ακόμα και αν υποστεί μερική καταστροφή. Αν και αυτή η πλεονάζουσα καταχώρηση των πληροφοριών μπορεί να εφαρμοστεί και σε άλλα συστήματα, τα ΤΝΔ έχουν τέτοια εσωτερική δομή, ώστε να μπορούν με φυσικό τρόπο να οργανώνουν αλλά και να χρησιμοποιούν αυτόν τον πλεονασμό. Είναι, δηλαδή, κατ' ουσίαν συστήματα που εκ κατασκευής ανέχονται την αστοχία.

1.7. Εφαρμογές των ΤΝΔ

Τα νευρωνικά δίκτυα είναι εφαρμόσιμα σχεδόν σε κάθε κατάσταση στην οποία ισχύει μια σχέση μεταξύ μεταβλητών πρόβλεψης (ανεξάρτητες, εισροές) και προβλεπόμενες μεταβλητές (εξαρτημένες, εκροές), ακόμα και όταν αυτή η σχέση είναι πολύ περίπλοκη για να αποδοθεί με τους συνηθισμένους όρους της «συσχέτισης» ή των «διαφόρων ομάδων».

Ο Σ.Α. Καλογήρου στα πλαίσια της εργασίας του [45] προβαίνει σε μία εκτενή αναφορά στις ποικίλες εφαρμογές των νευρωνικών δικτύων σε ενεργειακά προβλήματα. Από την εφαρμογή του ιδίου των πολύστρωτων νευρωνικών δικτύων

στα ηλιακά ενεργειακά συστήματα αποδείχτηκε ότι το σφάλμα με την χρήση αυτών των μοντέλων είναι σε αποδεκτά – ανεκτά όρια, κάτι το οποίο αποδεικνύει την ευχρηστία τους και την συνετή χρήση τους σε πεδία εφαρμογών ενεργειακών εφαρμογών καθώς και σε μία πληθώρα εφαρμογών, συμπεριλαμβανομένων των εφαρμογών ελέγχου, ρομποτικής, πρόβλεψης καιρού, ιατρικής, συστημάτων συμπαραγωγής, κατασκευής, βελτιστοποίησης, επεξεργασία σήματος, καθώς και οικονομικών, κοινωνικών και ψυχολογικών επιστημών.

Ενδεικτικά αντιπροσωπευτικά παραδείγματα προβλημάτων στα οποία η ανάλυση των νευρωνικών δικτύων έχει εφαρμοστεί με επιτυχία είναι τα εξής:

- i. **Ιατρική διάγνωση:** Ένα ευρύ φάσμα ιατρικά συσχετιζόμενων ενδείξεων, όπως ο συνδυασμός της καρδιακής συχνότητας, τα επίπεδα των διαφόρων ουσιών στο αίμα, ο ρυθμός της αναπνοής μπορούν να παρακολουθηθούν. Η εκδήλωση μιας συγκεκριμένης ιατρικής κατάστασης, γίνεται να συσχετιστεί με ένα πολύπλοκο συνδυασμό μεταβολών σε ένα υποσύνολο μεταβλητών που παρακολουθούνται. Τα νευρωνικά δίκτυα έχουν χρησιμοποιηθεί για την αναγνώριση αυτού του προτύπου πρόβλεψης, ώστε να χορηγηθεί η κατάλληλη θεραπεία.
- ii. **Ενεργειακά συστήματα:** Τα νευρωνικά δίκτυα προσφέρουν την ικανότητα μοντελοποίησης και σχεδιασμού ηλιακών μονάδων παραγωγής ατμού, την βελτιστοποίηση της απόδοσης φωτοβολταϊκών πάρκων, καθώς και την πρόβλεψη της απόδοσης συστημάτων ηλιακής θέρμανσης νερού. Επίσης ευρεία είναι η χρήση τους και στην ενεργειακή μελέτη των εγκαταστάσεων, με την πρόβλεψη των θερμικών φορτίων ενός κτιρίου, της ροής του αέρα στον φυσικό αερισμό αυτών και της πρόβλεψης της ενεργειακής κατανάλωσης των παθητικών ηλιακών κτιρίων.
- iii. **Χρηματιστηριακές προβλέψεις:** Οι διακυμάνσεις των τιμών των μετοχών και των χρηματιστηριακών δεικτών είναι ακόμα ένα παράδειγμα ενός πολύπλοκου, πολυδιάστατου, αλλά και σε ορισμένες περιπτώσεις εν μέρει ντετερμινιστικού φαινομένου. Τα νευρωνικά δίκτυα χρησιμοποιούνται από πολλούς τεχνικούς αναλυτές, ώστε να κάνουν προβλέψεις σχετικά με τις τιμές των μετοχών, βασιζόμενοι σε ένα μεγάλο αριθμό παραγόντων, όπως δηλαδή, τις προηγούμενες επιδόσεις άλλων αποθεμάτων και διαφόρων οικονομικών δεικτών.
- iv. **Επεξεργασία Σήματος:** Τα ΤΝΔ μπορούν να χρησιμοποιηθούν σε ένα μεγάλο εύρος εφαρμογών που αφορούν επεξεργασία σήματος. Συστήματα παρακολούθησης πολλαπλών στόχων σε ραντάρ, αναγνώρισης αντικειμένων από σήματα σόναρ, συστήματα σύνθεσης ομιλίας, αναγνώρισης ήχων αλλά και μετάφρασης σεισμικών σημάτων, είναι ορισμένα μόνο παραδείγματα τέτοιων εφαρμογών. Η μεγαλύτερη ωστόσο συνεισφορά των ΤΝΔ στον τομέα επεξεργασίας σήματος, αφορά την λειτουργία σε περιβάλλοντα όπου ο λόγος σήμα-θόρυβος είναι ιδιαίτερα μικρός. Αυτό οφείλεται στο ότι η πλειοψηφία των εναλλακτικών μεθόδων επεξεργασίας σήματος παρέχει σωστά αποτελέσματα, μόνο όταν το σήμα έχει σημαντικά μεγαλύτερη ένταση από το επίπεδο θορύβου. Αντίθετα, τα ΤΝΔ παρουσιάζουν την ικανότητα να καταχωρούν στη μνήμη τους τα διάφορα πρότυπα

με γενικό τρόπο, ξεπερνώντας έτσι προβλήματα θορύβου ή ελλιπών στοιχείων, αλλά παράλληλα αρκετά σθεναρά, ώστε να μην επηρεάζονται από τη μεταβλητότητα που παρουσιάζεται τόσο στις ίδιες τις υπογραφές των υπό αναγνώριση αντικειμένων όσο και στο περιβάλλον μέσα στο οποίο βρίσκονται τα τελευταία.

v. **Πιστωτική ανάθεση:** Μια ποικιλία από κομμάτια πληροφοριών, τα οποία είναι συνήθως γνωστά για ένα απαιτούμενο δάνειο. Για παράδειγμα, η ηλικία του αιτούντος, η εκπαίδευση, το επάγγελμα και πολλά άλλα στοιχεία που μπορεί να είναι διαθέσιμα. Μετά την εκπαίδευση ενός νευρωνικού δικτύου σε ιστορικά δεδομένα η ανάλυση μπορεί να εκτοπίσει τα πιο κατάλληλα και σχετικά χαρακτηριστικά και να τα χρησιμοποιήσει για την ταξινόμηση των αιτούντων ως χαμηλού ή υψηλού κινδύνου.

vi. **Παρακολούθηση της κατάστασης των μηχανημάτων:** Τα νευρωνικά δίκτυα μπορούν να συμβάλλουν στη μείωση του κόστους με την εξασφάλιση της πρόσθετης εμπειρογνωμοσύνης για τον προγραμματισμό προληπτικής συντήρησης των μηχανημάτων. Ένα νευρωνικό δίκτυο, λοιπόν, μπορεί να εκπαιδευτεί με τέτοιο τρόπο, ώστε να διακρίνει από τους ήχους τους οποίους παράγει μια μηχανή είτε αν εκτελεί κανονικά τις λειτουργίες της, είτε βρίσκεται στα πρόθυρα εμφάνισης οποιασδήποτε δυσλειτουργίας. Μετά από αυτήν την περίοδο εκπαιδευτικής κατάρτισης, η εμπειρία του ίδιου δικτύου είναι δυνατό να χρησιμοποιηθεί με σκοπό την προειδοποίηση ενός τεχνικού για κάποια επικείμενη βλάβη προτού συμβεί και ενδεχομένως προκαλέσει πολυδάπανες και απρόβλεπτες χρονικές καθυστερήσεις.

vii. **Συστήματα διαχείρισης κινητήρα:** Τα νευρωνικά δίκτυα έχουν χρησιμοποιηθεί για την ανάλυση των εισροών που δέχονται οι αισθητήρες ενός κινητήρα. Το νευρωνικό δίκτυο ελέγχει μια ποικιλία παραμέτρων με τις οποίες λειτουργεί ο κινητήρας, προκειμένου να επιτευχθεί ένας συγκεκριμένος στόχος. Για παράδειγμα, το δίκτυο αυτό επιχειρεί την ελαχιστοποίηση της κατανάλωσης των καυσίμων.

viii. **Αμυντικά συστήματα παρακολούθησης:** Ποικίλες είναι οι εφαρμογές που καλύπτουν τα ΤΝΔ και στον τομέα των συστημάτων αμύνης. Χαρακτηριστικές εφαρμογές αυτών συναντώνται στην πλοήγηση μη επανδρωμένων αεροσκαφών, αναγνώριση σημάτων από ραντάρ, αναγνώριση και στόχευση στόχων από έξυπνα όπλα, κρυπτογραφία και στην βέλτιστη αξιοποίηση των αποθεμάτων.

2. Μικροστροβίλοι

Στο κεφάλαιο αυτό, αφότου γίνει αναφορά στα είδη των αεροπορικών κινητήρων καθώς και στις εφαρμογές τους, περιγράφονται τα βασικά χαρακτηριστικά των μικροστροβίλων, καθώς η μελέτη της εργασίας θα επικεντρωθεί στον μικροστροβίλο Olympus HP ES. Επίσης, πραγματοποιείται εκτενής αναφορά στις εφαρμογές αυτού του είδους των κινητήρων.

2.1. Είδη αεροπορικών κινητήρων

Τα είδη των κινητήρων που χρησιμοποιούνται για ενδοατμοσφαιρικές πτήσεις των αεροσκαφών μπορούν να χωριστούν σε δύο βασικές κατηγορίες:

1. Εμβολοφόρους κινητήρες
2. Jet κινητήρες

Αεροπορικοί κινητήρες		
Εμβολοφόροι Κινητήρες	Αεριοστροβίλοι	Αυλωθητές
1. Εν σειρά	1. Turbojet	1. Ramjet
2. Εγκάρσιας διάταξης	2. Turboprop	2. Scramjet
3. Αστεροειδείς	3. Turboshift	3. Pulsejet
4. Περιστροφικοί	4. Turbofan	
5. Τύπου V		

Πίνακας 2-1: Είδη αεροπορικών κινητήρων.

Εκτός από την χρήση των αεριοστροβίλων για την πτήση των αεροσκαφών, έχουν γίνει πολλαπλές μελέτες και μετατροπές για την αξιοποίησή τους σε μία πληθώρα εφαρμογών. Αυτές είναι:

- Συστήματα συμπαραγωγής
- Παραγωγή ηλεκτρικής ενέργειας
- Κίνηση βαρέων οχημάτων
- Υποβοήθηση κίνησης πλοίων
- Μεταφορά πετρελαίου σε μεγάλες αποστάσεις
- Καθαρισμός οδοστρώματος
- Αποπαγοποίηση (de-ice) επιφάνειας αεροσκαφών
- Κατάσβεση πυρκαγιάς

Στο πλαίσιο της παρούσας εργασίας εξετάζεται ένας μικροστροβίλος, πιο συγκεκριμένα ο Olympus HP ES, ο οποίος εντάσσεται στην οικογένεια των turbojet κινητήρων. Στην συνέχεια ακολουθεί περιγραφή των βασικών χαρακτηριστικών και εφαρμογών των μικροστροβίλων.

2.2. Μικροστροβίλοι


Οι μικροστροβίλοι είναι μικρογραφίες (σε μικρότερη κλίμακα) των στροβιλοκινητήρων που χρησιμοποιούνται από τα κανονικά αεροσκάφη.

Τα δομικά τους μέρη είναι:

- | | |
|---|---------------|
| <ul style="list-style-type: none">• Διάταξη εισαγωγής (intake)• Συμπιεστής (compressor) | } Ψυχρό τμήμα |
| <ul style="list-style-type: none">• Θάλαμος καύσης (combustion chamber)• Στρόβιλος (turbine)• Ακροφύσιο (exhaust duct ή nozzle) | |

Η αρχή λειτουργίας τους είναι η ακόλουθη: Μία μάζα αέρα οδηγείται από το τμήμα εισαγωγής στο συμπιεστή. Εκεί συμπιέζεται και οδηγείται στο θάλαμο καύσης. Αναμιγνύεται με εγχυόμενο καύσιμο και επιτυγχάνεται καύση. Τα παραγόμενα θερμά καυσαέρια εκτονώνονται και οδηγούνται προς την εξαγωγή. Στη διαδρομή αυτήν προκαλούν την περιστροφή του στροβίλου ο οποίος συνδέεται με το συμπιεστή με κοινό άξονα. Στη συνέχεια, τα καυσαέρια συνεχίζουν την εκτόνωσή τους και περνώντας από το ακροφύσιο εξόδου, εξέρχονται από τον κινητήρα έχοντας πολύ μεγαλύτερη ταχύτητα από αυτήν της εισερχόμενης μάζας αέρα.

Η κατασκευή τους είναι πανομοιότυπη, όπως και οι αρχές λειτουργίας που τους διέπουν, με την διαφορά ότι η ισχύς τους είναι σημαντικά μικρότερη. Σαφέστατα, μικρογραφίες κινητήρων με περίπλοκα κατασκευαστικά χαρακτηριστικά (π.χ. turbofan κινητήρας) αποφεύγονται λόγω της δυσκολίας της κατασκευής και συντήρησης, έχοντας αρνητικό αντίκτυπο στο κόστος. Η πιο συνηθισμένη σχεδίαση αυτών των κινητήρων είναι αυτή των turbojet, κυρίως λόγω της απλότητας της κατασκευής τους.



Εικόνα 2-1: Μικροστροβίλος WREN MW54.

Προέλευση:[28]

Η μόνη σημαντική διαφορά παρατηρείται συνήθως στον συμπιεστή του κινητήρα. Στους μικροστροβίλους προτιμούνται οι φυγοκεντρικοί συμπιεστές, διότι

επιτυγχάνουν πολύ μεγαλύτερη συμπίεση σε σχέση με μία βαθμίδα αξονικού συμπιεστή, σε αυτές τις διαστάσεις. Σε συνδυασμό και με τα ελάχιστα κινούμενα μέρη του φυγοκεντρικού συμπιεστή, η χρήση τους αποτελεί μονόδρομος για αυτούς τους κινητήρες μικρού μεγέθους. Επίσης η τουρμπίνα τους αποτελείται κατά βάση από μόνο ένα ζεύγος σταθερών –κινητών πτερυγίων.



Εικόνα 2-2: Τυπική μορφή φυγοκεντρικού συμπιεστή και μονής βαθμίδας τουρμπίνας μικροστροβίλου, συζευγμένα με μηχανικό τρόπο (άξονα).


Το καύσιμο που χρησιμοποιούν οι συγκεκριμένοι κινητήρες είναι κηροζίνη (κυρίως JP-4/PETROLEUM/Jet A1), ακριβώς το ίδιο με των κανονικών κινητήρων. Λόγω της έλλειψης συστήματος λιπάνσεως του κινητήρα, ενδείκνυται η χρήση μικρού ποσοστού λιπαντικού αναμιγμένο με το καύσιμο.

2.2.1. Γενική περιγραφή λειτουργίας μικροστροβίλων και των παρελκομένων τους.

Για την εκκίνηση των κινητήρων αυτών υπάρχει ένας μικρός ηλεκτροκινητήρας, ο οποίος τίθεται σε λειτουργία από εξωτερική πηγή ενέργειας (μπαταρία) με σκοπό να “ανεβάσει” τις στροφές του κινητήρα (για να αυξήσει την πίεση και να αποκτήσει ο κινητήρας την κατάλληλη θερμοκρασία). Στον θάλαμο καύσης αντί για το κύριο καύσιμο που χρησιμοποιείται απαιτείται η χρήση κατάλληλου αερίου εκκίνησης για να προθερμάνει τον κινητήρα ομαλά. Το προπάνιο ή μείγμα αυτού με βουτάνιο συνήθως χρησιμοποιούνται ως αέρια εκκίνησης.

Μόλις ο κινητήρας πιάσει τις κατάλληλες στροφές (έχουν οριστεί από τον κατασκευαστή) κόβεται η παροχή του αερίου εκκίνησης και αρχίζει η έκχυση του κύριου καυσίμου, οπότε ο κινητήρας πλέον αυτοσυντηρείται.

Ο παραπάνω τρόπος είναι ο πιο συνηθισμένος, όμως οι εταιρίες προχώρησαν στην κατασκευή συστήματος εκκίνησης με την καύση του ίδιου καυσίμου με του κυρίου, απλοποιώντας έτσι τα παρελκόμενα του κινητήρα (μία δεξαμενή καυσίμου αντί δύο διαφορετικών και λιγότερες σωληνώσεις). Χαρακτηριστικό παράδειγμα αποτελεί το σύστημα εκκίνησης Kerosene της εταιρίας Altecure, το οποίο παρέχει την δυνατότητα προθέρμανσης, εκκίνησης και λειτουργίας του κινητήρα με το ίδιο καύσιμο.




Εικόνα 2-3: Σύστημα εκκίνησης Kerosene (P/N: KS-1).

Προέλευση:[29]

Η συνολική διεργασία εκκίνησης συντονίζεται και ρυθμίζεται από την ECU (Engine Control Unit – Μονάδα Ελέγχου Κινητήρα). Η ECU είναι ο υπολογιστής που ρυθμίζει την βαλβίδα καυσίμου και το σύστημα ανάφλεξης (ignition system).

Οι περισσότεροι κινητήρες διαθέτουν μία GSU (Ground Support System – Σύστημα Επίγειας Υποστήριξης) . Η GSU είναι μία εφαρμογή τερματικού για τον προγραμματισμό των παραμέτρων του κινητήρα, καθώς και για την απεικόνιση των παραμέτρων του κινητήρα κατά την λειτουργία του. Η GSU μπορεί να συνδεθεί και να αποσυνδεθεί από τον κινητήρα ανά πάσα στιγμή χωρίς να επηρεάσει την λειτουργία του κινητήρα.

Μεταξύ της σύνδεσης της GSU με την ECU, παρεμβάλλεται συνήθως ένας πίνακας LED, με σκοπό την απεικόνιση της λειτουργίας που εκτελεί η ECU κατά την εκκίνηση και λειτουργία του κινητήρα.




Εικόνα 2-4: (Αριστερά) Κινητήρας JetCat P-120-SX και (δεξιά) τα παρελκόμενα του κινητήρα.

Προέλευση:[30]


Αναλυτικότερες πληροφορίες σχετικά με τους μικροστροβίλους δίνονται στο επόμενο κεφάλαιο, όπου γίνεται εκτενής παρουσίαση του κινητήρα Olympus HP ES των εργαστηρίων Θερμοδυναμικής και Θερμικών Μηχανών των Μηχανολόγων Μηχανικών του Πανεπιστημίου Θεσσαλίας.

2.2.2. Εφαρμογές μικροστροβίλων.

Η κυριότερη και πολυσυνηθισμένη εφαρμογή των μικροστροβίλων είναι η χρήση τους στον μοντελισμό (οχήματα, αεροσκάφη με jet κινητήρα, αεροσκάφη με turboprop κινητήρα, ελικόπτερα με turboshaft κινητήρα).



Εικόνα 2-5: Μικροστρόβιλος jet σε μοντέλο οχήματος.




Εικόνα 2-6: Μικροστρόβιλος jet σε μοντέλο αεροσκάφους JMP HUSTLER.

Προέλευση:[33]



Εικόνα 2-7: Μικροστρόβιλος turboprop σε μοντέλο αεροσκάφους Tucano.

Προέλευση:[32]



Εικόνα 2-8: (a) Εφαρμογή μικροστροβίλου σε ελικόπτερο, (b) λάδι λιπάνσεως Mobil – jet oil 254 για ανάμειξη με το καύσιμο του κινητήρα, (c) φιάλη μείγματος προπανίου – βουτανίου για την προθέρμανση του κινητήρα και (d) γέμισμα δεξαμενής καυσίμου ελικοπτέρου με καύσιμο JET-A.

Προέλευση:[31]

Μεγάλη μελλοντική απήχηση των μικροστροβίλων (με πιο ποιοτική κατασκευή από αυτών για χρήση σε εφαρμογές μοντελισμού) πρόκειται να παρατηρηθεί στις στρατιωτικές εφαρμογές στα UAVs (Unmanned Air Vehicles –Μη Επανδρωμένα Αεροσκάφη). Τα μη επανδρωμένα αεροσκάφη, είναι αεροσκάφη χωρίς ιπτάμενο προσωπικό με μία πληθώρα πλεονεκτημάτων, με πληθώρα εφαρμογών σε στρατιωτικές επιχειρήσεις. Ενδεικτικά αναφέρονται οι παρακάτω:

- Μηδενική θνησιμότητα προσωπικού κατά την διεξαγωγή αποστολών, καθώς δεν υπάρχει ιπτάμενο προσωπικό
- Μικρότερο μέγεθος αεροσκάφους
- Πλήρεις συστήματα συνηθισμένου επανδρωμένου αεροσκάφους, με την διαφορά ότι απουσιάζει ένα πολύ σημαντικό ποσοστό υλικών και παρελκομένων για την εξυπηρέτηση και τον χειρισμό του αεροσκάφους από το ιπτάμενο προσωπικό
- Ολοκληρωμένες εφαρμογές κατάδειξης στόχου, παρακολούθησης και βομβαρδισμού
- Πολύ μεγάλη αυτονομία, που μπορεί να φτάσει μέχρι και τις 24 ώρες πτήσεις
- Συγκριτικά με την απώλεια ενός επανδρωμένου αεροσκάφους είναι πολύ μικρότερο το κόστος, καθώς δεν υπάρχει χειριστής και το κόστος κατασκευής ενός μη επανδρωμένου οχήματος είναι πολύ μικρότερο.
- Λιγότερα έξοδα συντήρησης

Χαρακτηριστικό παράδειγμα ενός τέτοιου UAV αποτελεί το MQ-X της εταιρίας Lockheed Martin, οποίο διαθέτει τόσο ένα turbo-diesel κινητήρα για την ώθηση με προπέλα για μεγαλύτερες και χαμηλής ταχύτητας πτήσεις καθώς και δύο μικρούς jet κινητήρες για μεγαλύτερες επιταχύνσεις και ταχύτητες πτήσης.



Εικόνα 2-9: Πρωτότυπο UAV MQ-X της εταιρίας Lockheed Martin με turbo-diesel και jet κινητήρες.

Προέλευση:[34]

Μία άλλη σημαντική εφαρμογή των μικροστροβίλων εμφανίζεται στα ανεμόπτερα (gliders). Ο μικροστρόβιλος σε αυτήν την εφαρμογή χρησιμοποιείται κυρίως για την επιστροφή του οχήματος στον τόπο προσγείωση, αλλά όμως με τον σωστό σχεδιασμό μπορεί να αξιοποιηθεί και για την απογείωση του ανεμόπτερου και την προώθησή του μέχρι το κατάλληλο ύψος.



Εικόνα 2-10: Ανεμόπτερο με μικροστρόβιλο Olympus HP E-start για την επιστροφή στον τόπο προσγείωσης (bringing home device).

Προέλευση:[35]

Τέλος, η χρήση μικροστροβίλων πραγματοποιήθηκε σε μία πολλά υποσχόμενη (μελλοντικά) ιπτάμενη πτέρυγα που θα αλλάξει τα δεδομένα στον χώρο των εναέριων πτήσεων. Ειδικότερα πρόκειται για την υλοποίηση της ιδέα – ονείρου του ιπτάμενου Σουηδού Yves Rossy. Η επιθυμία του ήταν να μπορέσει να πετάξει όσο το δυνατόν με πιο φυσικό τρόπο, απομακρυνόμενος από την συνήθη πτήση μέσα στο πιλοτήριο ενός αεροσκάφους. Προσαρμόζοντας (έπειτα από την κατασκευή πολλών πρωτοτύπων) τέσσερις μικρούς αεροστροβίλους πάνω σε μία πτέρυγα δέλτα μικρού μεγέθους, που μπορεί εύκολα να τοποθετηθεί στην πλάτη ενός ανθρώπου, κατάφερε να πραγματοποιήσει πτήση διάρκειας δέκα λεπτών. Ο χειρισμός της πτέρυγας πραγματοποιείται με την κίνηση του σώματος, ενώ η ώση των κινητήρων ρυθμίζεται από μία μικρή μανέτα στο χέρι του.




Εικόνα 2-11: Ο Σουηδός πιλότος Yves Rossy κατά την πτήση του με την ιπτάμενη πτέρυγα προωθούμενη από τέσσερεις jet μικροστροβίλους.

Προέλευση:[36]

3. Κινητήρας εργαστηρίου

Στην παρούσα εργασία πραγματοποιείται η εφαρμογή των τεχνητών νευρωνικών δικτύων στον κινητήρα Olympus HP ES (E- Start)³ των εργαστηρίων Θερμοδυναμικής και Θερμικών Μηχανών των Μηχανολόγων Μηχανικών του Πανεπιστημίου Θεσσαλίας. Τα απαραίτητα στοιχεία για τον συγκεκριμένο κινητήρα δίνονται στις ακόλουθες ενότητες.



Εικόνα 3-1: Ο κινητήρας Olympus HP E-Start.

Olympus HP gas-turbine	E-start system		Air-start system	
Diameter	131	mm	131	mm
Length	384	mm	273	mm
Turbine weight	2850	gram	2475	gram
System weight *	3795	gram	3150	gram
Thrust @ max. rpm	230	N	230	N
Thrust @ min. rpm	13	N	13	N
Maximum RPM	108,500		108,500	
Idle RPM	36,000		36,000	
Pressure ratio @ max. rpm	3,8 :1		3,8 :1	
Mass flow @ max. rpm	450	gr/sec.	450	gr/sec.
Normal EGT	700	C	700	C
Maximum EGT	750	C	750	C
Fuel consumption @ max. rpm	640	gr/min.	640	gr/min.
Fuel	JP-4/petroleum/Jet A1			
Oil	4,5% aeroshell 500 mixed with fuel.			
* System airborne weight. (complete system)				
Engine, ECU, pump, battery, thermo sensor, mounting straps.				
All data at STP	S.T.P.	: Standard Temp. & Pressure		
	Temperature	: 15 Degrees Celsius / 59 Degrees Fahrenheit		
	Pressure	: 1013 Mbar / 29.91 in		

Πίνακας 3-1: Χαρακτηριστικά κινητήρα Olympus HP με E-Start και Air-Start σύστημα.


³ Υπάρχουν δύο τύποι αυτού του κινητήρα, ανάλογα μες τον τρόπο εκκίνησής τους. (1) Ο Olympus HP E-start: η εκκίνησή του γίνεται από ηλεκτρική μίζα και (2) ο Olympus HP Air-start: Η εκκίνησή του γίνεται με εισροή αέρα μεγάλης ταχύτητας.

3.1. Περιγραφή κινητήρα Olympus HP ES

Ο κινητήρας Olympus είναι Ολλανδικής κατασκευής της εταιρίας AMT (Advanced Micro Turbines). Πρόκειται για μία μικρογραφία turbojet κινητήρα οι εφαρμογές του οποίου αναφέρθηκαν στην προηγούμενη ενότητα.

- Δομή κινητήρα

Ο κινητήρας Olympus HP από έναν μονοβάθμιο ακτινικό (φυγοκεντρικό) συμπιεστή, έναν αξονικό στρόβιλο, ένα θάλαμο καύσης και ένα συγκλινόν ακροφύσιο. Ο θάλαμος καύσης είναι δακτυλιοειδούς μορφής και τροφοδοτείται από ένα σύστημα καυσίμου χαμηλής πίεσης, το οποίο χρησιμοποιεί τα έδρανα κύλισης του άξονα περιστροφής για την εισαγωγή του καυσίμου. Το μήκος του κινητήρα, μαζί με τον ηλεκτροκινητήρα της εκκίνησης είναι 38,43 cm και η μέγιστη διάμετρός του 13,09 cm.



Σχήμα 3-1: (αριστερά) Τομή κινητήρα Olympus HP E-Start και (δεξιά) οι διαστάσεις του.

Προέλευση:[35]


- Αέριο εκκίνησης

Για την εκκίνηση του κινητήρα απαιτείται η χρήση ενός αερίου εκκίνησης. Σκοπός αυτού του αερίου είναι η προθέρμανση του κινητήρα και η αύξηση της πίεσης του κινητήρα. Μόλις οι στροφές φτάσουν τις 9000 RPM και η θερμοκρασία των καυσαερίων EGT τους 88°C, η ECU (Engine Control Unit – Μονάδα Ελέγχου Κινητήρα) (γίνεται αναφορά στην συνέχεια) σταματά την τροφοδοσία του αερίου εκκίνησης και τροφοδοτεί το σύστημα με το κύριο καύσιμο. Το πιο συνηθισμένο αέριο εκκίνησης είναι το προπάνιο, το οποίο χρησιμοποιείται και στον συγκεκριμένο κινητήρα του εργαστηρίου. Η χρήση μίγματος βουτανίου/προπανίου δεν προτιμάται λόγω αναξιοπιστίας (ειδικά στα ψυχρά κλίματα).

- Αντλία καυσίμου

Το καύσιμο διακινείται μέσω αντλίας γραναζωτού τύπου. Αποτελείται από δύο οδοντωτούς τροχούς, οι οποίοι περιστρέφονται μέσα στο κέλυφός τους. Λόγω του

μικρού μεγέθους της και την ακρίβεια κατασκευής το τροφοδοτούμενο καύσιμο πρέπει να είναι απολύτως καθαρό, χωρίς ξένα σωματίδια ή άλλες διαλυμένες ουσίες που μπορεί να οδηγήσουν στην αστοχία της αντλίας.



Εικόνα 3-2: Αντλία καυσίμου του κινητήρα.

Προέλευση:[37]

- Καύσιμο λειτουργίας – Λίπανση

Ο κινητήρας δύναται να λειτουργήσει με διάφορους τύπους καυσίμου, οι οποίοι είναι:

1. JP-4/Kerosene (χρησιμοποιείται στα στρατιωτικά αεροσκάφη)
2. Paraffin (χρησιμοποιείται στις θερμάστρες πετρελαίου)
3. Jet A-1 (χρησιμοποιείται στα πολιτικά αεροσκάφη)
4. White spirit (χρησιμοποιείται ως διαλυτικό χρωμάτων)


Στο δοκιμαστήριο του κινητήρα που εγκαταστάθηκε στο εργαστήριο, εξ' αρχής χρησιμοποιήθηκε ως καύσιμο paraffin, γνωστό και ως φωτιστικό πετρέλαιο, του οποίου η σύσταση είναι παραφινική και έχει ιδιότητες παρόμοιες με τα αεροπορικά καύσιμα.

Εξαιτίας της χρήσης του καυσίμου από τον κινητήρα ως μέσο λίπανσης των εδράνων κύλισης (ρουλεμάν)⁴ του περιστρεφόμενου άξονα, πριν την έναρξη της λειτουργίας το καύσιμο αναμιγνύεται με λιπαντικό Aeroshell 500 σε ποσότητα 5% κ.ο.. Το λιπαντικό φροντίζει για την λίπανση του κινητήρα κατά τις διαδικασίες εκκίνησης και τερματισμού της λειτουργίας. Όταν ξεκινήσει η διαδικασία τερματισμού, η ροή του καυσίμου διακόπτεται και το καύσιμο που υπάρχει μέσα στη μηχανή εξατμίζεται από την υψηλή θερμοκρασία που επικρατεί και επικάθεται σε όλες τις επιφάνειες. Αυτή η διαδικασία πραγματοποιεί την λίπανση που απαιτείται για να είναι έτοιμος ο κινητήρας κατά την επομένη διαδικασία εκκίνησης.

- Βαλβίδες καυσίμου και αερίου

Ο έλεγχος και η επιλογή του καυσίμου που εισέρχεται στον κινητήρα ανάλογα με την κατάσταση (εκκίνηση: αέριο εκκίνησης, μόνιμη λειτουργία: κύριο καύσιμο) ρυθμίζεται από την ECU και υλοποιείται μέσω των αντίστοιχων βαλβίδων.

⁴ Το ένα έδρανο βρίσκεται μετά τον συμπιεστή και το άλλο πριν από τον στρόβιλο.




Εικόνα 3-3: Βαλβίδες (αριστερά) αερίου εκκίνησης και (δεξιά) καυσίμου του κινητήρα.

Προέλευση:[37]

- ECU (Engine Control Unit)

Η ECU ελέγχει πλήρως την λειτουργία του κινητήρα. Καθορίζει τα όρια λειτουργίας του κινητήρα και τον προστατεύει από εσφαλμένη χρήση. Στην ουσία η ECU είναι ένας μικροεπεξεργαστής ρυθμισμένος κατάλληλα από τον εργοστασιακό φορέα και δεν επιδέχεται αλλαγές, παρά μόνο με την αναβάθμιση του λογισμικού του. Πάνω σε αυτήν συνδέονται όλα τα εξαρτήματα που συνοδεύουν την μηχανή και συμβάλουν στην λειτουργία της. Η τροφοδοσία της ECU πραγματοποιείται από μία μπαταρία κλειστού τύπου (αυτοκινήτου) συνολικής τάσης 12Volt/1700 mA.

Η ECU ελέγχει την κατάσταση του κινητήρα μετρώντας τις στροφές και την θερμοκρασία καυσαερίων. Επίσης πραγματοποιεί και την διαδικασία εκκίνησης του κινητήρα. Ως εισόδους από τον χρήστη δέχεται το επίπεδο ισχύος (throttle level) και την κατάσταση της μηχανής (Running position, Auto-Stop, Stop). Οι παράμετροι αυτοί καθορίζονται από το χειριστήριο (control box). [37]



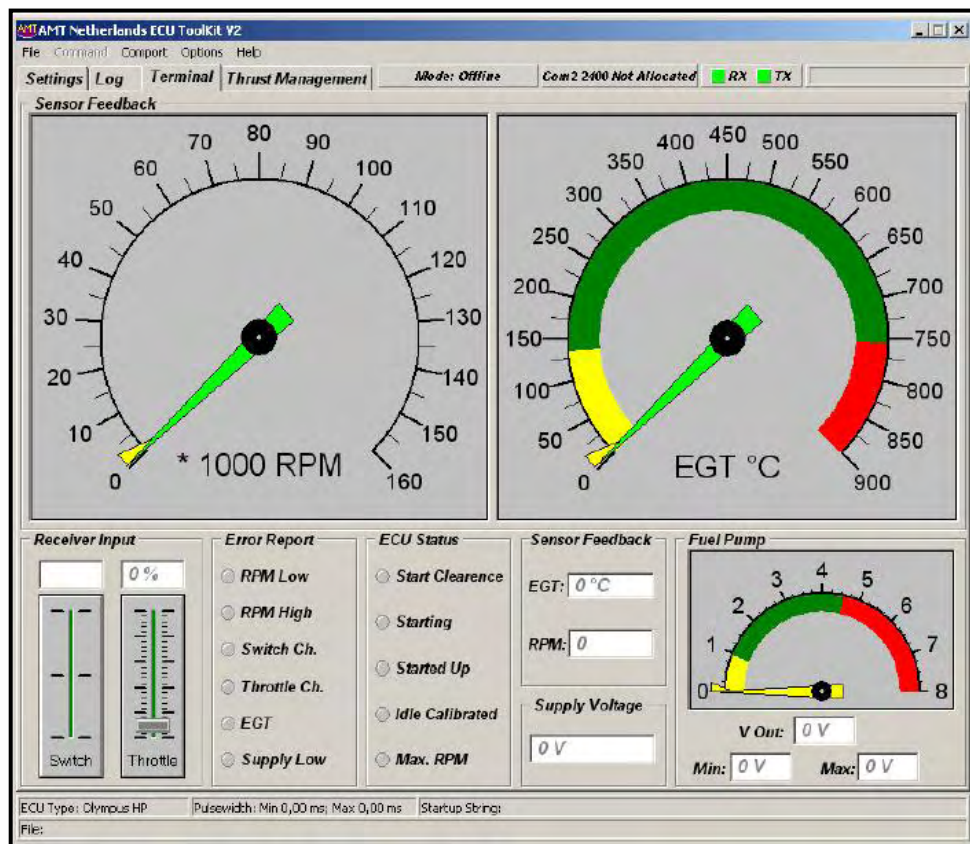
Εικόνα 3-4: Βαλβίδες (αριστερά) αερίου εκκίνησης και (δεξιά) καυσίμου του κινητήρα.




Εικόνα 3-5: Μπαταρία κλειστού τύπου συνολικής τάσης 12Volt/1700 mA.

- EDT (Engine Data Terminal)

Η εταιρία δεν παρέχει την δυνατότητα στον χρήστη της επεξεργασίας και ελέγχου των λειτουργιών που εκτελεί η ECU, παρόλο που ο τρόπος με τον οποίο λειτουργεί είναι γνωστός. Η μόνη δυνατότητα που δίνει στο χρήστη είναι, είτε μέσω του EDT (Engine Data Terminal) είτε μέσω ηλεκτρονικού υπολογιστή, την παρακολούθηση της ταχύτητας περιστροφής του κινητήρα και της θερμοκρασίας καυσαερίων καθώς και ορισμένων μηνυμάτων που αφορούν την λειτουργία του κινητήρα και των εξαρτημάτων του.



Εικόνα 3-6: Τερματικό πρόγραμμα παρακολούθησης της λειτουργίας τους κινητήρα.



Εικόνα 3-7: Τερματικό παρακολούθησης της λειτουργίας του κινητήρα.

- Χειριστήριο κινητήρα

Το χειριστήριο (control box) του κινητήρα συνδέεται πάνω στην ECU (ενσύρματη σύνδεση)⁵. Διαθέτει έναν διακόπτη και ένα ροοστάτη. Με τον διακόπτη επιλέγουμε την κατάσταση λειτουργίας του κινητήρα (Running position, Auto-Stop, Stop), ενώ με τον ροοστάτη ελέγχουμε το επίπεδο ισχύος αυτού (throttle level).



Εικόνα 3-8: Χειριστήριο κινητήρα.

3.2. Περιγραφή εκκίνησης και λειτουργίας κινητήρα Olympus HP ES

Η διαδικασία εκκίνησης του κινητήρα είναι η ακόλουθη:

Αρχικά ενεργοποιείται η ηλεκτρική μίζα, η οποία περιστρέφει τον κινητήρα. Μόλις η ταχύτητα φτάσει τις κατάλληλες στροφές, σβήνει η μίζα και ανοίγει η βαλβίδα του προπανίου. Με την διοχέτευση του προπανίου στον κινητήρα ενεργοποιείται και ο αναφλεκτήρας. Ακολουθεί η εκ νέου επιτάχυνση του κινητήρα από την μίζα, η οποία ενεργοποιείται με σκοπό την αύξηση των στροφών του κινητήρα. Παράλληλα με αυτήν την επιτάχυνση κλείνει η βαλβίδα του προπανίου, απενεργοποιείται ο αναφλεκτήρας και ανοίγει η βαλβίδα καυσίμου καθώς και η αντλία αυτού. Μετά από λίγο χρονικό διάστημα, αφού ανεβούν αρκετά οι στροφές, ο

⁵ Σε περίπτωση που ο κινητήρας τοποθετηθεί σε κάποιο μοντέλο, δηλαδή επιθυμείται απομακρυσμένος χειρισμός αυτού, υπάρχει η κατάλληλη σύνδεση στην κάρτα για την ρύθμιση του ασύρματου χειριστηρίου.

κινητήρας μπορεί από μόνος του (χωρίς την βοήθεια της μίζας) να συντηρήσει τις στροφές του, οπότε και η μίζα σταματάει. Η μηχανή μόλις αρχίσει να λειτουργεί από μόνη της είναι ρυθμισμένη να επιταχύνει στις 50000 RPM (σημείο αναφοράς) και παραμένει για πέντε δευτερόλεπτα, ώστε να βαθμονομηθεί η ECU. Αφότου συντελεστή η βαθμονόμηση οι στροφές μειώνονται στις 36000 RPM (ρελαντί) και η μηχανή είναι έτοιμη για χρήση. Να σημειωθεί πως όλη η παραπάνω αλληλουχία ενεργειών συντονίζεται και υλοποιείται, όπως αναφέρθηκε και προηγουμένως, από την ECU του κινητήρα.

3.3. Πειραματική εγκατάσταση κινητήρα Olympus HP ES

Για τις ανάγκες ερευνητικής μελέτης και εκπαίδευσης, η κατασκευάστρια εταιρία διαθέτει στο εμπόριο τον κινητήρα Olympus HP ES με εγκατεστημένα σημεία ελέγχου παραμέτρων του κινητήρα (θα αναπτυχθούν στην συνέχεια).




Εικόνα 3-9: Κινητήρας Olympus HP ES με σημεία ελέγχου.

Προέλευση:[37]

Στα σημεία ελέγχου της λειτουργίας του κινητήρα είναι τοποθετημένα τα ανάλογα αισθητήρια όργανα μέτρησης στατικής, ολικής πίεσης και θερμοκρασίας, στις διάφορες θέσεις του κινητήρα. Τα αισθητήρια όργανα στέλνουν σε μορφή σήματος την μέτρησή τους σε μία κάρτα, η οποία στη συνέχεια τα προωθεί σε έναν ηλεκτρονικό υπολογιστή. Με το κατάλληλο λογισμικό παρέχεται η δυνατότητα στον χρήστη της:

- On-line παρακολούθησης και επεξεργασίας των μετρούμενων μεγεθών
- Αποθήκευσης των μετρήσεων για περαιτέρω επεξεργασία.

Σύμφωνα με το πρότυπο SAE AS755 (39) χρησιμοποιούνται κάποιοι πρότυποι δείκτες για την υποδήλωση της θέσης μιας διατομής κατά μήκος της μηχανής.



Σχήμα 3-2: Αρίθμηση θέσεων σε τομή του κινητήρα Olympus HP ES και οι θέσεις των αισθητήριων οργάνων.

Προέλευση:[40]

3.3.1. Σημεία λήψεις μετρήσεων του κινητήρα Olympus HP ES

Όπως αναφέρθηκε και προηγουμένως ο κινητήρας του εργαστηρίου είναι κατάλληλα διαμορφωμένος για την τοποθέτηση αισθητήριων οργάνων μέτρησης πίεσης (ολικής και στατικής) και θερμοκρασίας. Οι θέσεις των οργάνων φαίνονται στην παραπάνω εικόνα. Ακολουθεί ανάλυση της κάθε θέσης.

Θέση 3

Η θέση 3 είναι τοποθετημένη στην έξοδο του συμπιεστή. Σε αυτή την θέση μετράμε την θερμοκρασία, την ολική πίεση και την στατική πίεση. Για την θερμοκρασία έχουν τοποθετηθεί δύο θερμοστοιχεία σε αντιδιαμετρικές θέσεις και συμβολίζονται με $T_{3, \text{left}}$ και $T_{3, \text{right}}$. Σε αντιδιαμετρικές θέσεις βρίσκονται και οι αισθητήρες της πίεσης, οι οποίοι είναι οι $P_{t3, \text{left}}$, $P_{t3, \text{right}}$, $P_{3, \text{left}}$, $P_{3, \text{right}}$.

Θέση 4


Η θέση 4 βρίσκεται στην έξοδο του θαλάμου καύσης. είναι τοποθετημένη στην έξοδο του συμπιεστή. Σε αυτή την θέση μετράμε τα ολικά μεγέθη της πίεσης και της θερμοκρασίας με την χρήση δύο μετρητικών οργάνων. Οι αισθητήρες συμβολίζονται με T_4 και P_{t4} .

Θέση 5

Η θέση 5 αντιστοιχεί στην έξοδο του στροβίλου. Είναι τοποθετημένα τέσσερα θερμοστοιχεία (με γωνία μεταξύ τους 90°), τα οποία συμβολίζονται με $T_{5,up}$, $T_{5,down}$, $T_{5,left}$ και $T_{5,right}$. Υπάρχουν ακόμη τέσσερεις αισθητήρες για την μέτρηση της ολικής και στατικής πίεσης, οι οποίοι συμβολίζονται με $P_{t5,up}$, $P_{5,up}$, $P_{t5,down}$ και $P_{5,down}$.

Θέση	Στατική Πίεση	Ολική Πίεση	Θερμοκρασία
3	$P_{3,left} / P_{3,right}$	$P_{t3,left} / P_{t3,right}$	$T_{3,left} / T_{3,right}$
4	-	P_{t4}	T_4
5	$P_{5,up} / P_{5,down}$	$P_{t5,up} / P_{t5,down}$	$T_{5,up} / T_{5,down} / T_{5,left} / T_{5,right}$

Πίνακας 3-2: Μετρητικά μεγέθη σε κάθε θέση.



Πίνακας 3-3: Θέσεις μετρητικών οργάνων.


3.3.2. Μετρητικά όργανα κινητήρα του κινητήρα Olympus HP ES

Ακολουθεί η παρουσία των συσκευών μέτρησης θερμοκρασία και πίεσης.

Μέτρηση θερμοκρασίας

Για την μέτρηση της θερμοκρασίας χρησιμοποιήθηκαν θερμοζεύγη (thermocouples). Τα θερμοστοιχεία (ή θερμοζεύγη) που χρησιμοποιήθηκαν για την μηχανή Olympus είναι τύπου K. Το υλικό κατασκευής τους είναι 90%Ni-10%Cr για το θετικό άκρο και 95%Ni-2%Si-2%Mn-1%Al για το αρνητικό άκρο. Το εύρος θερμοκρασιών που μπορεί να μετρήσει είναι από -200°C έως 1100°C το οποίο μπορεί να επεκταθεί μέχρι τους 1300°C για μικρής διάρκειας μετρήσεις. Σε αυτό το εύρος θερμοκρασιών η ΗΕΔ που αναπτύσσεται μεταξύ των επαφών του θερμοστοιχείου είναι γραμμική συνάρτηση της θερμοκρασίας. Αυτού του τύπου τα

θερμοστοιχεία αντέχουν σε οξειδωτικά περιβάλλοντα όπως είναι αυτά των καυσαερίων των στροβιλοαντιδραστήρων. Επομένως τα θερμοστοιχεία που επιλέχθηκαν ικανοποιούν τις απαιτήσεις του δοκιμαστηρίου.[38]




Εικόνα 3-10: Αρίθμηση θέσεων σε τομή του κινητήρα Olympus HP ES και οι θέσεις των αισθητήριων οργάνων.

Μέτρηση πίεσης

Για την μέτρηση της πίεσης στις θέσεις 3, 4 και 5 του κινητήρα έγινε χρήση μεταλλακτών πίεσης. Πάνω στον κινητήρα είναι τοποθετημένα τα αισθητήρια όργανα μέτρησης, τα οποία είναι μεταλλικοί σωλήνες, εσωτερικής διαμέτρου 1mm, κατασκευασμένοι από ανοξείδωτο χάλυβα για την θέση 3 και κράμα Inconel για τις θέσεις 4 και 5.

Για την μέτρηση της **στατικής πίεσης** οι σωλήνες τοποθετούνται στο περίβλημα της μηχανής έτσι ώστε το άκρο τους να βρίσκεται πάνω στο όριο της διατομής για την οποία γίνεται η μέτρηση της πίεσης και να μην παρεμβάλλονται στο πεδίο ροής.

Για την μέτρηση της **ολικής πίεσης** οι σωλήνες σχηματίζουν στο άκρο του ένα σωλήνα Pitot, ο οποίος παρεμβάλλεται στο πεδίο ροής. Οι αισθητήρες συνδέονται με τους μεταλλάκτες με την βοήθεια πλαστικών σωλήνων.



Εικόνα 3-11: Τύποι μέτρησης πίεσης.

Οι μεταλλάκτες πίεσης που χρησιμοποιούνται στο εργαστήριο είναι τύπου A10 της εταιρίας WIKA. Η αρχή λειτουργίας τους βασίζεται στο πιεζοηλεκτρικό φαινόμενο. Δηλαδή, υπάρχει ένα λεπτό μεταλλικό διάφραγμα, το οποίο όταν μετατοπίζεται από την εκάστοτε πίεση, πιέζει έναν πιεζοηλεκτρικό κρύσταλλο. Υπάρχει μία αναλογία μεταξύ της αναπτυσσόμενης τάσης στα άκρα του κρυστάλλου με την μηχανική τάση, άρα και με την επιβαλλόμενη πίεση. Τα πλεονεκτήματα αυτών των αισθητήρων είναι:


- ταχεία απόκριση
- σχετικά μεγάλο εύρος λειτουργίας
- πολύ μεγάλη ευαισθησία
- καλή ακρίβεια και επαναληψιμότητα
- χαμηλή υστέρηση.



Εικόνα 3-12: Μεταλλάκτης πίεσης A-10 της WIKA.

Προέλευση:[41]


Το εύρος μέτρησης του μεταλλάκτη A10 είναι 0-10bar. Μπορεί να τροφοδοτηθεί με συνεχές ρεύμα τάσης 8-30VDC. Στην περίπτωση του δοκιμαστηρίου του Olympus επιλέχθηκε τροφοδοσία με τάση 9VDC που παρέχεται με κατάλληλο μετασχηματιστή. Οι μεταλλάκτες, χρησιμοποιούν ένα ολοκληρωμένο κύκλωμα για την ρύθμιση του σήματος εξόδου. Η έξοδος του μεταλλάκτη είναι ρεύμα εντάσεως 4-20mA το οποίο μεταβάλλεται γραμμικά σε όλο το εύρος μέτρησης. Αλλά για να είναι εκμεταλλεύσιμη αυτή η έξοδος από την κάρτα ανάκτησης δεδομένων (θα αναφερθεί στην συνέχεια) πρέπει να μετατραπεί σε τάση. Για να επιτευχθεί αυτό εισάγεται μια αντίσταση στο κύκλωμα τροφοδοσίας και μετράται η τάση στα άκρα της, η οποία είναι ανάλογη της πίεσης αφού η ένταση του ρεύματος του μεταλλάκτη είναι και αυτή ανάλογη της πίεσης. Η διαμόρφωση του κυκλώματος φαίνεται στο επόμενο σχήμα.[38,41]



Σχήμα 3-3: Κύκλωμα σύνδεσης μεταλλάκτη πίεσης.

Μέτρηση ώσης

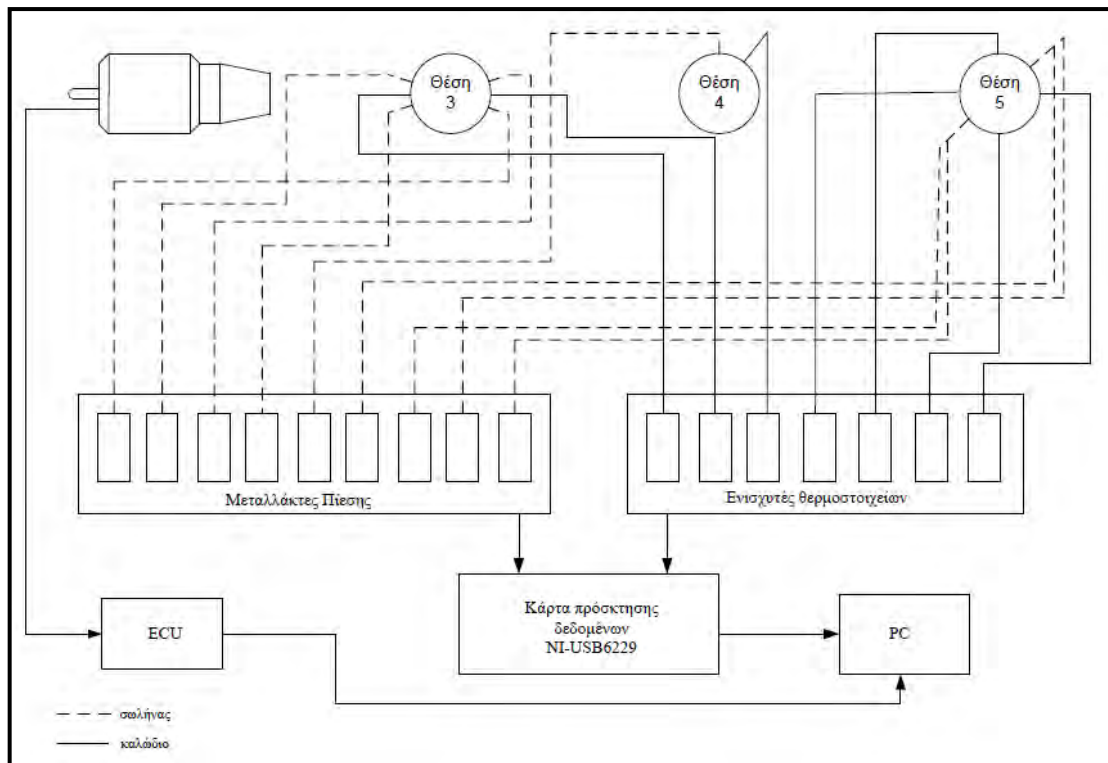
Η μέτρηση της ώσης πραγματοποιήθηκε με την βοήθεια μίας κυψελίδας φόρτισης. Σκοπός της είναι να μετατρέπει την τάση που δέχεται σε ηλεκτρικό σήμα. Η κυψελίδα φόρτισης που χρησιμοποιήθηκε για την καταγραφή της ώσης είναι η MOD 546QD-A5 της εταιρείας DS EUROPE, η οποία μπορεί να καταγράφει ώση από -60 μέχρι 110 kg. Η ακρίβεια στη συλλογή δεδομένων είναι απαραίτητη για την παρατήρηση της συμπεριφοράς του αεριοστροβίλου. Αυτός είναι ο λόγος για τον οποίο ο στρόβιλος τοποθετείται σε μια ευθεία ράγα, που είναι ουσιαστικά χωρίς τριβές, πάνω στην οποία κινείται ελεύθερα η βάση του αεριοστροβίλου ώστε να αυξάνει την ακρίβεια της ώσης που καταγράφεται. Η κυψελίδα φόρτισης τοποθετήθηκε αντικριστά στην είσοδο του συμπιεστή. Τα σφάλματα που προκαλούν οι μεταβολές θερμοκρασίας (καθώς επηρεάζονται οι τιμές των αντιστάσεων) μπορούν να ελαχιστοποιηθούν εάν οι μετρητές μηχανικής τάσης προσαρμοστούν ηλεκτρικά.



Εικόνα 3-13: Κυψελίδα φόρτισης και βάση κινητήρα.

3.4. Πρόσκτηση δεδομένων λειτουργίας κινητήρα Olympus HP ES

Για την πρόσκτηση των δεδομένων ακολουθείται η εξής διαδικασία. Τα ηλεκτρικά σήματα από τους μεταλλάκτες πίεσης και των ενισχυτή των θερμοστοιχείων (όπου καταλήγουν οι ακροδέκτες των θερμοστοιχείων) οδηγούνται σε μία κάρτα πρόσκτησης δεδομένων (NI-USB6229). Η κάρτα συνδέεται με τον ηλεκτρονικό υπολογιστή, ο οποίος χρησιμοποιώντας την τεχνολογία DAQmx (τρόπος προγραμματισμού LabVIEW) προβαίνει στην ανάκτηση των δεδομένων. Παράλληλα όμως με σειριακή σύνδεση της ECU με τον ηλεκτρονικό υπολογιστή και του κατάλληλου πρωτοκόλλου επικοινωνίας, ανακτούνται τα δεδομένα της (στροφές κινητήρα, EGT και επίπεδο ισχύος (throttle level)). Στην παρακάτω εικόνα απεικονίζεται η μετρική αλυσίδα της διάταξης και ακολουθεί αναλυτικότερη επεξήγηση της διαδικασίας πρόσκτησης δεδομένων και των χρησιμοποιούμενων συσκευών.



Σχήμα 3-4: Η μετρική αλυσίδα της διάταξης.

Προέλευση:[38]

3.4.1. Ενισχυτής θερμοστοιχείων.

Σε αντίθεση με την αναπτυσσόμενη τάση των μεταλλακτών πίεσης, η οποία είναι ικανή για άμεση καταγραφή και επεξεργασία, η αναπτυσσόμενη τάση των θερμοστοιχείων πρέπει να ενισχυθεί προτού οδηγηθεί στην κάρτα πρόσκτησης δεδομένων, διότι είναι πολύ μικρή. Γιαυτό τον λόγο χρησιμοποιείται ο ενισχυτής σήματος (ολοκληρωμένο κύκλωμα) AD595AQ.

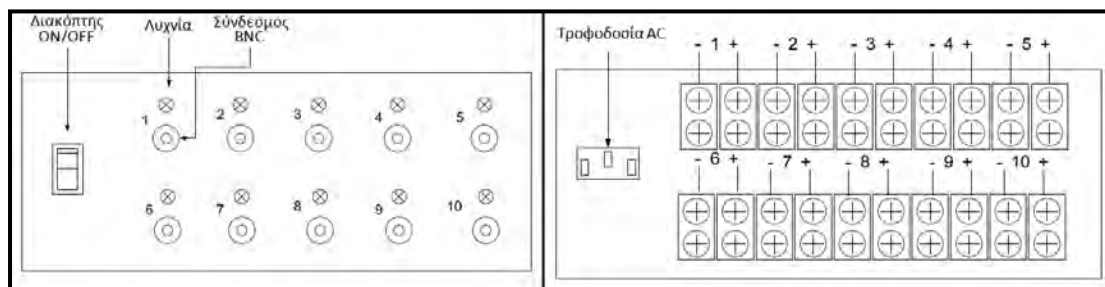


Εικόνα 3-14: Ο ενισχυτής των θερμοστοιχείων.

Σύντομη περιγραφή ενισχυτή:

Στην μπροστινή όψη του ενισχυτή διακρίνονται διακόπτης ενεργοποίησης της λειτουργίας του ενισχυτή, οι λυχνίες λειτουργίας (ανάβουν σε περίπτωση βλάβης του

εκάστοτε θερμοστοιχείου ή όταν είναι απενεργοποιημένη η κάρτα πρόσκτησης δεδομένων) και οι σύνδεσμοι BNC για την σύνδεση με την κάρτα πρόσκτησης δεδομένων (μέσω αυτών αποστέλλεται το ενισχυμένο σήμα). Η σύνδεση των ακροδεκτών των θερμοστοιχείων πραγματοποιείται στην πίσω πλευρά του ενισχυτή, πάνω στις κλέμες. Στην παρακάτω εικόνα φαίνονται οι δύο όψεις του ενισχυτή και στον πίνακα που ακολουθεί παρουσιάζονται οι θέσεις σύνδεσης των ακροδεκτών.



Σχήμα 3-5: (αριστερά) μπροστινή και (δεξιά) πίσω όψη ενισχυτή θερμοστοιχείων.

Θερμοστοιχείο	$T_{3,left}$	$T_{3,right}$	T_4	$T_{5,left}$	$T_{5,right}$	$T_{5,up}$	$T_{5,down}$
Θέση	1	2	3	4	5	6	7

Πίνακας 3-4: Θέσεις σύνδεσης θερμοστοιχείων στον ενισχυτή.

3.4.2. Κάρτα πρόσκτησης δεδομένων.

Όπως αναφέρθηκε προηγουμένως, τα σήματα των μεταλλακτών πίεσης καθώς και τα ενισχυμένα σήματα των θερμοστοιχείων οδηγούνται σε μία κάρτα πρόσκτησης δεδομένων, για την καταγραφή, παρακολούθηση και αποθήκευση αυτών των δεδομένων. Στην συγκεκριμένη εργαστηριακή εγκατάσταση χρησιμοποιείται η κάρτα USB-6229 της National Instruments. Συνδέεται με τον υπολογιστή μέσω USB θύρας. Χρησιμοποιεί την τεχνολογία DAQmx⁶ για την ανάκτηση των δεδομένων. Διαθέτει 32 αναλογικά κανάλια εισόδου, 4 αναλογικά κανάλια εξόδου καθώς και 48 ψηφιακά κανάλια εισόδου/εξόδου. Ο ρυθμός πρόσκτησης δεδομένων είναι 250 kS/s, ο οποίος μοιράζεται στα κανάλια που χρησιμοποιούνται κάθε φορά. Με την χρήση του κατάλληλου τροφοδοτικού παρέχεται η απαιτούμενη τροφοδοσία για την λειτουργία της.

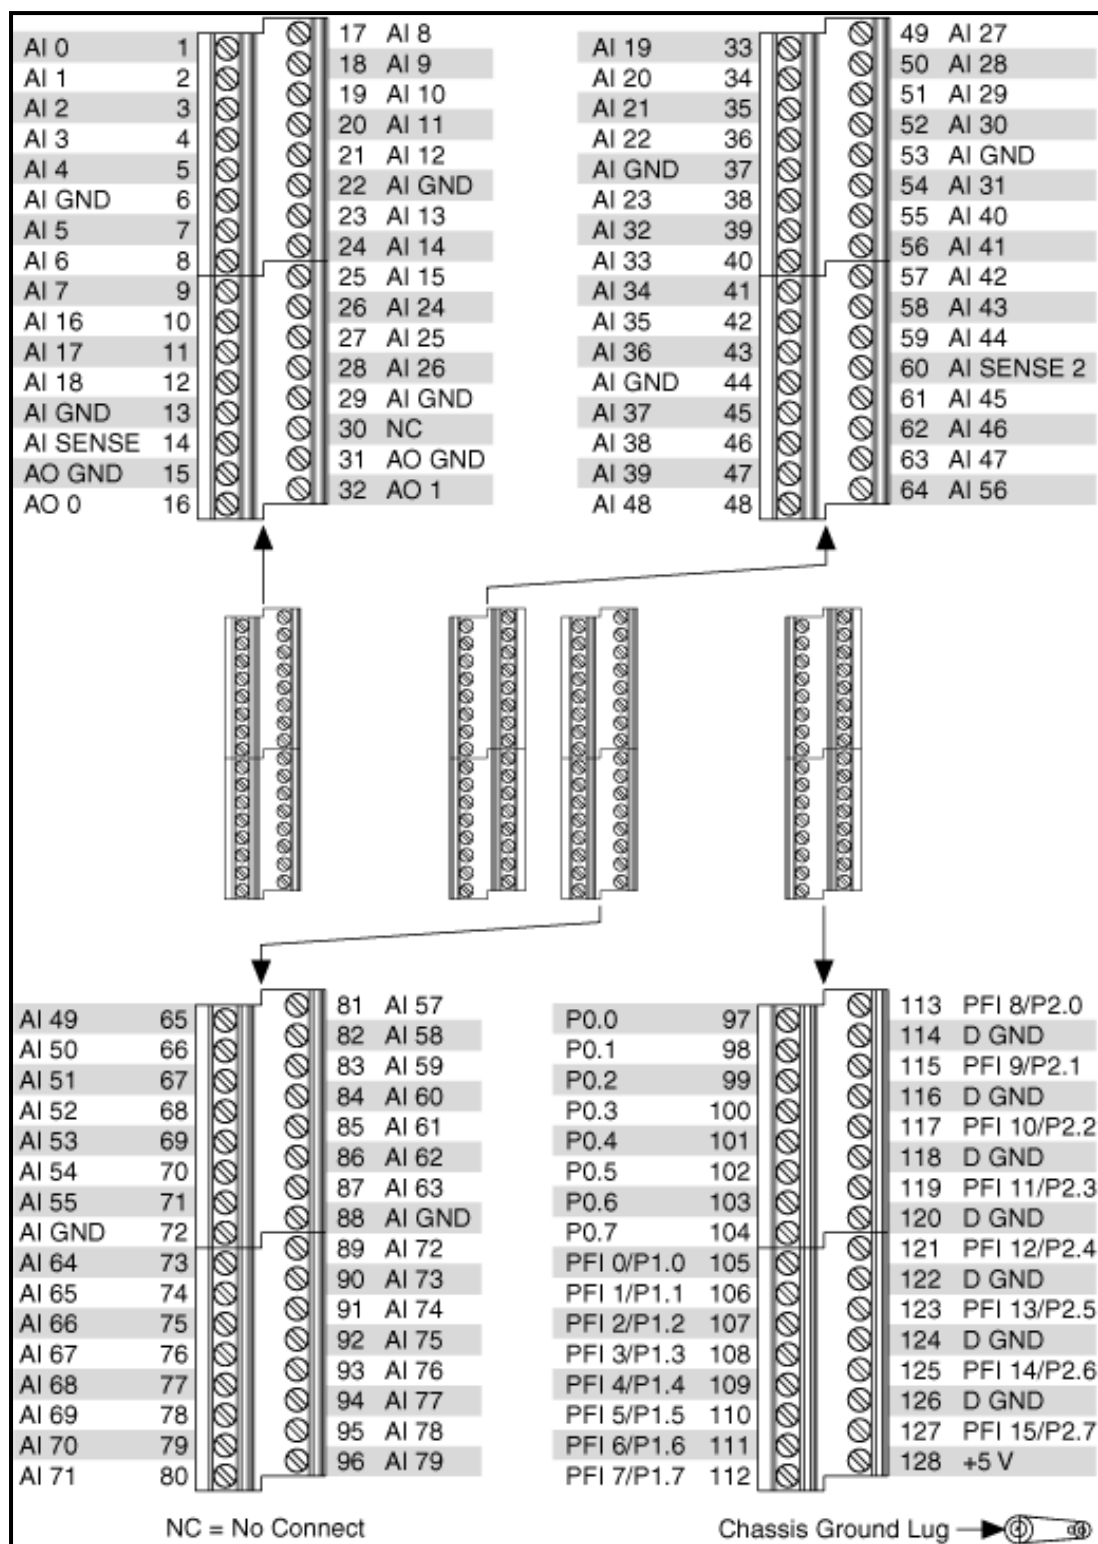
⁶ Τρόπος προγραμματισμού σε LabVIEW. Υπάρχουν δύο μεθοδολογίες, η Traditional NI-DAQ και η DAQmx. Η διαφορά αυτών συναντάται στις συναρτήσεις που χρησιμοποιούν για την ανάκτηση των δεδομένων από τις συσκευές εισόδου. Η πρώτη περιέχει πολύπλοκες συναρτήσεις για την ανάκτηση δεδομένων με περιορισμένες δυνατότητες. Η δεύτερη (πρόσφατη ανάπτυξη) απλοποιεί αρκετά την διαδικασία ανάκτησης δεδομένων, με απλές συναρτήσεις και μεγάλους ρυθμούς δειγματοληψίας. Το κύριο πλεονέκτημα της είναι ότι μπορεί να προσομοιώσει οποιαδήποτε συσκευή υποστηρίζει το λογισμικό DAQmx και έτσι να γίνουν έλεγχοι και τροποποιήσεις στο κώδικα του LabVIEW χωρίς να είναι συνδεδεμένη η συσκευή.[38]



Εικόνα 3-15: Η κάρτα πρόσκτησης δεδομένων USB-6229.

Προέλευση:[43]

Οι αισθητήρες συνδέονται στις κλέμες που διαθέτει η κάρτα (συνολικά περιέχει 128 ακροδέκτες). Η λειτουργία του κάθε ακροδέκτη φαίνεται στην παρακάτω εικόνα. Η συνδεσμολογία των ακροδεκτών των αισθητήρων πίεσης και θερμοκρασίας διευκρινίζεται στον επόμενο πίνακα.



Εικόνα 3-16: Λειτουργίες ακροδεκτών κάρτας.

Προέλευση:[43]

a/a	Αισθητήρας	Κανάλι	Ακροδέκτες	
			(+)	(-)
0	P _{3, right}	ai0	1	3
1	P _{3, left}	ai1	4	6
2	P _{t3, right}	ai2	7	9
3	P _{t3, left}	ai3	10	12
4	P _{t4}	ai4	17	19
5	P _{5, up}	ai5	20	22
6	P _{5, down}	ai6	23	25
7	P _{t5, up}	ai7	26	28
8	P _{t5, down}	ai8	2	3
9	T _{t3, left}	ai9	5	6
10	T _{t3, right}	ai10	8	9
11	T _{t4}	ai11	11	12
12	T _{t5, left}	ai12	18	19
13	T _{t5, right}	ai13	21	22
14	T _{t5, up}	ai14	24	25
15	T _{t5, down}	ai15	27	28

Πίνακας 3-5: Συνδεσμολογία ακροδεκτών αισθητήρων πίεσης και θερμοκρασίας.
Προέλευση:[38]

3.4.3. Ανάκτηση δεδομένων από την ECU.


Η ECU συνδέεται με σειριακή θύρα, μέσω της εξόδου Telemetry που διαθέτει, για παρακολούθηση των παραμέτρων ελέγχου της (στροφές κινητήρα, EGT και επίπεδο ισχύος (throttle level)). Ο κατασκευαστής δεν παρέχει όμως την δυνατότητα στον χρήστη για την καταγραφή και επεξεργασία αυτών των δεδομένων, παρά μόνο την on-line παρατήρησή τους. Όμως, με την βοήθεια του πρωτοκόλλου σειριακής επικοινωνίας που παρέχεται από τον κατασκευαστή [44] αντιμετωπίζεται το πρόβλημα αυτό προσθέτοντας τον κατάλληλο κώδικα στο LabVIEW. Έτσι παράλληλα με την πρόσκτηση των δεδομένων της κάρτας USB-6229, ανακτούνται και τα δεδομένα της ECU.

3.4.4. Πρόγραμμα πρόσκτησης δεδομένων.

Η πρόκτηση των δεδομένων πραγματοποιήθηκε με την χρήση του προγράμματος AMT.vi που γράφτηκε στα πλαίσια της διπλωματικής του Δ.

Μπακάλη, με τίτλο «Μελέτη εγκαταστάσεων μικρών αεροστροβίλων», στο Πανεπιστήμιο Θεσσαλίας το 2008. Τα ζητούμενα μετρούμενα μεγέθη του κινητήρα Olympus διαβάζονται από την κάρτα πρόκτησης δεδομένων και την ECU, στην συνέχεια επεξεργάζονται από τον κώδικα του LabVIEW, απεικονίζονται στα τερματικά του front panel και αποθηκεύονται σε αρχείο.

Η φωτογραφία που ακολουθεί αποτελεί στιγμιότυπο του προγράμματος πρόκτησης. Όπως φαίνεται στην εικόνα, απεικονίζεται ο κινητήρας σε τομή, πάνω στον οποίο έχουν σχεδιαστεί οι θέσεις με την αρίθμησή τους. Επίσης, διακρίνονται και τα τερματικά των οργάνων μέτρησης και τα εικονίδια στα οποία εισάγονται οι συνθήκες περιβάλλοντος.



Εικόνα 3-17: Το πρόγραμμα πρόσκτησης δεδομένων.

Προέλευση:[38]

4. Προσομοίωση λειτουργίας κινητήρα Olympus HP ES

Στο κεφάλαιο αυτό αρχικά παρουσιάζονται οι αναφορές στην διεθνή βιβλιογραφία γύρω από το θέμα της μοντελοποίησης αεροστροβίλων με χρήση νευρωνικών δικτύων. Έπειτα, δίνονται τα βασικά χαρακτηριστικά των νευρωνικών δικτύων που θα χρησιμοποιηθούν στην συνέχεια και τέλος περιγράφεται η διεργασία αξιολόγησης των αποτελεσμάτων που θα δοθούν από την μοντελοποίηση.

Η επεξεργασία όλων των δεδομένων που προβάλλονται στην συνέχεια έχει πραγματοποιηθεί με την χρήση των ακόλουθων προγραμμάτων:

- Matlab R2012b
- OriginPro 8
- Microsoft Office Excel 2007

4.1. Συναφείς μελέτες χρήσης νευρωνικών δικτύων σε αεροκινητήρες

Γενικά, το μαθηματικό μοντέλο ενός στροβιλοκινητήρα είτε δεν είναι διαθέσιμο είτε είναι πολύ πολύπλοκο για την εφαρμογή των κλασικών μεθόδων πρόβλεψης-εκτίμησης. Παρόλου αυτά, υπάρχουν διαθέσιμες υπολογιστικές προσομοιώσεις για την μοντελοποίηση του κινητήρα με μεγάλη ακρίβεια.

Τα νευρωνικά δίκτυα έχουν την ικανότητα να προσεγγίζουν την μη γραμμικότητα όταν εκπαιδεύονται με πειραματικά δεδομένα του κινητήρα. Έχουν γίνει πολλές προσπάθειες για εφαρμογή αυτών των δικτύων στον κλάδο των αεροκινητήρων [58], ωθώντας πολλούς ερευνητές στην ενασχόλησή τους με την προσομοίωση των αεροστροβίλων με νευρωνικά δίκτυα. Κάποιες από αυτές τις έρευνες αναφέρονται στην συνέχεια.


Τα αποτελέσματα της μελέτης των P. Moraal και I. Kolmanovsky [24] υποδηλώνουν ότι η μοντελοποίηση με χρήση νευρωνικών δικτύων είναι ανώτερη έναντι άλλων αντίστοιχων μεθόδων, αν το δίκτυο έχει εκπαιδευτεί σωστά. Βέβαια, ανέφεραν την αδυναμία των νευρωνικών δικτύων στην μοντελοποίηση της ροής μάζας σε συμπιεστή συναρτήσεως του λόγου συμπίεσης και των στροφών του κινητήρα.

Σε μία διαφορετική μελέτη, οι Cheng Bao, Minggao Ouyang και Baolian Yi Bao [11] χρησιμοποίησαν νευρωνικά δίκτυα τύπου backpropagation (BPNN) για την μοντελοποίηση των χαρτών λειτουργίας φυγοκεντρικών και κοχλιωτών συμπιεστών.

Οι Y. Yu, L. Chen, F. Sun, C. Wu [12] εφάρμοσαν ένα νευρωνικό δίκτυο τριών στρωμάτων (δύο κρυφών στρωμάτων) τύπου backpropagation, με μέθοδο εκπαίδευσης τον αλγόριθμο Levenberg–Marquardt, για την πρόβλεψη των χαρτών λειτουργίας. Για την εκπαίδευση των δικτύων χρησιμοποιήθηκαν για την εκπαίδευση προήλθαν από δοκιμές του κατασκευαστή. Απέδειξαν την ικανότητα των νευρωνικών


δικτύων για την μοντελοποίηση ολόκληρης της συμπεριφοράς ενός αεριοστροβίλου. Στα επόμενα σχήματα απεικονίζονται: το χρησιμοποιούμενο νευρωνικό δίκτυο, τα δεδομένα εισόδου και τα αποτελέσματα της μοντελοποίησης. Η συνάρτηση μεταφοράς που χρησιμοποιήθηκε ήταν η υπερβολική εφαιπτόμενη σιγμοειδής (στο Matlab ονομάζεται ως Tansig), με την ακόλουθη μορφή:

$$f = \frac{e^n - e^{-n}}{e^n + e^{-n}}$$




Σχήμα 4-1: Δομή νευρωνικού δικτύου τύπου backpropagation

Προέλευση:[12]



Σχήμα 4-2: Δεδομένα εκπαίδευσης των νευρωνικών δικτύων.

Προέλευση:[12]



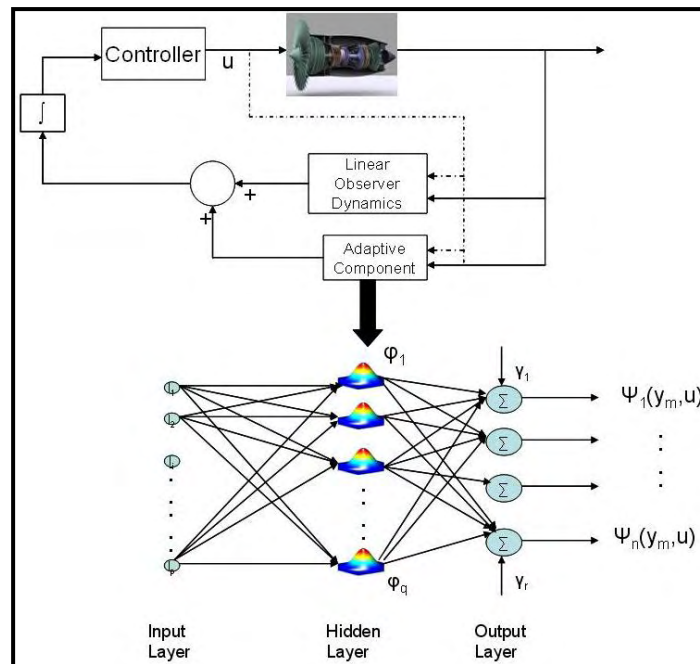
Σχήμα 4-3: Αποτελέσματα μοντελοποίησης νευρωνικών δικτύων.

Προέλευση:[12]

Οι K. Ghorbanian, M. Gholamrezaei [58] εξέτασαν την εφαρμογή των τεχνητών νευρωνικών δικτύων στην πρόβλεψη των χαρτών λειτουργίας του συμπιεστή. Διαφορετικοί τύποι νευρωνικών δικτύων μελετήθηκαν, όπως το δίκτυο general regression και το δίκτυο rotated general regression. radial basis function network, and multilayer Perceptron network are considered. Two different models are utilized in simulating the performance map. Τα αποτελέσματα έδειξαν ότι ενώ το νευρωνικό δίκτυο rotated general regression έχει το ελάχιστο μέσο σφάλμα και την καλύτερη συμφωνία με τα πειραματικά δεδομένα, μολοταύτα στερείται σε εφαρμογές συσχέτισης. Παρά ταύτα, αν επιθυμείται κάποιο εργαλείο για εφαρμογές συσχέτισης, η μέθοδος του πολύστρωτου δικτύου Perceptron είναι η πιο αποτελεσματική. Επίσης εξέτασαν την επίδοση του συμπιεστή με την χρήση των νευρωνικών δικτύων. Τα αποτελέσματα μεταξύ των τιμών που προβλέφθηκαν με τις πειραματικές τιμές συμφωνούν σε άριστο βαθμό.

Οι Praveen Shankar, Rama K. Yedavalli προέβησαν [56] στην εκτίμηση μη μετρήσιμων παραμέτρων, όπως είναι η ώση και η θερμοκρασία εισόδου σε στροβιλοκινητήρες, κάτι το οποίο αποτελεί μία σημαντική πρόκληση για την αντίστοιχη κοινότητα αεροκατασκευών. Μία λύση στο πρόβλημα είναι ο υπολογισμός αυτών των παραμέτρων από τις μετρούμενες εξόδους από έναν adaptive observer. Η τότε τεχνολογία βασίζεται στα φίλτρα Kelman για την πραγματοποίηση αυτής της εκτίμησης. Στην εργασία τους όμως, οι προαναφερόμενοι, παρουσίασαν έναν adaptive observer που συνδυάζει το γραμμικό φίλτρο Kalman με ένα νευρωνικό δίκτυο για την αντιστάθμιση της οποιασδήποτε μη γραμμικότητας που δεν μπορεί να διαχειριστεί από το γραμμικό φίλτρο. Το νευρωνικό δίκτυο που δημιουργήθηκε είναι

ένα Radial Basis Function Network. Ο adaptive observer χρησιμοποιήθηκε για την εκτίμηση της θερμοκρασίας εισόδου στον HPT, της ώσης και των ορίων στολαρίσματος.




Σχήμα 4-4: Adaptive observer-engine with radial basis function network.

Προέλευση:[56]

Οι M. Gholamrezaei και K Ghorbanian στην εργασία τους [61], επιδίωξαν την ανάπτυξη ενός νευρωνικού δικτύου εμπρόσθιας τροφοδότησης για την δημιουργία των χαρτών λειτουργίας ενός αξονικού συμπιεστή χρησιμοποιώντας ένα περιορισμένο πλήθος από πειραματικά δεδομένα. Χρησιμοποίησαν τον αλγόριθμο Levenberg–Marquardt με την μέθοδο Bayesian regularization για την ρύθμιση των βαρών και των biases του δικτύου. Η προτεινόμενη τεχνική χρησιμοποιείται για την εκτίμηση της ροής καυσίμου, τον λόγο συμπίεσης, την ταχύτητα περιστροφής του άξονα, και της αποδοτικότητας στις περιοχές όπου δεν ήταν διαθέσιμα τα πειραματικά δεδομένα. The surge line is predicted and the line of maximum efficiencies is determined. Τα αποτελέσματα συγκρίνονται με τα πειραματικά δεδομένα.

Οι A. Lazzaretti, A. Toffolo [62] εστίασαν την έρευνά τους στην παρουσίαση ενός μοντέλου, εντός και εκτός σημείου λειτουργίας, για έναν αεριοστρόβιλο, στο οποίο οι δυσκολίες εξαιτίας της έλλειψης γνώσεων για τις επιδόσεις εξαλείφονται με την κατασκευή κατάλληλων νευρωνικών δικτύων. Ειδικότερα, η μοντελοποίηση πραγματοποιήθηκε σε εύρος πιέσεων P_0 από 98 kPa έως 104 kPa, με βήμα το 1 kPa, ενώ η θερμοκρασία κυμάνθηκε μεταξύ 0°C και 40°C , με βήμα 5°C . Χρησιμοποιήθηκε ένα απλό νευρωνικό δίκτυο δύο στρωμάτων, λόγω του σύντομου χρόνου εκπαίδευσης και της καλής ακρίβειας του.



Σχήμα 4-5: Δομή νευρωνικού δικτύου.

Για κάθε μία έξοδο ($T_{02}, T_{05}, T_{06}, \dot{m}_1, \dot{m}_f, r_c, L, \eta_{tot}$) δημιουργήθηκε ένα δίκτυο, όμοιο με την παραπάνω εικόνα, χρησιμοποιώντας το Matlab. Αποφεύχθηκε η χρήση νευρωνικού δικτύου με πολλαπλές εξόδους (όλες τις μεταβλητές), διότι μειώνεται η γενίκευση της μοντελοποίησης, αυξάνεται το σφάλμα των εξόδων του δικτύου και απαιτείται η εισαγωγή πάρα πολλών δεδομένων εισόδου [15]. Συνεχίζοντας στην μελέτη των A. Lazzaretti, A. Toffolo, χρησιμοποιήσαν στην εκπαίδευση των δικτύων τις μεθόδους Levenberg – Marquardt και BFGS quasi-Newton, εναλλάσσοντας την συνάρτηση μεταφοράς του στρώματος εξόδου μεταξύ της υπερβολικής εφαπτόμενης σιγμοειδής (Hyperbolic Tangent Sigmoid - Tansig) και της γραμμικής. Ως συνάρτηση μεταφοράς του κρυφού στρώματος χρησιμοποιήθηκε σε όλα τα δίκτυα η υπερβολική εφαπτόμενη σιγμοειδής (Tansig). Το σφάλμα, με βάσει του οποίου αξιολογήθηκαν τα δίκτυα ήταν το:

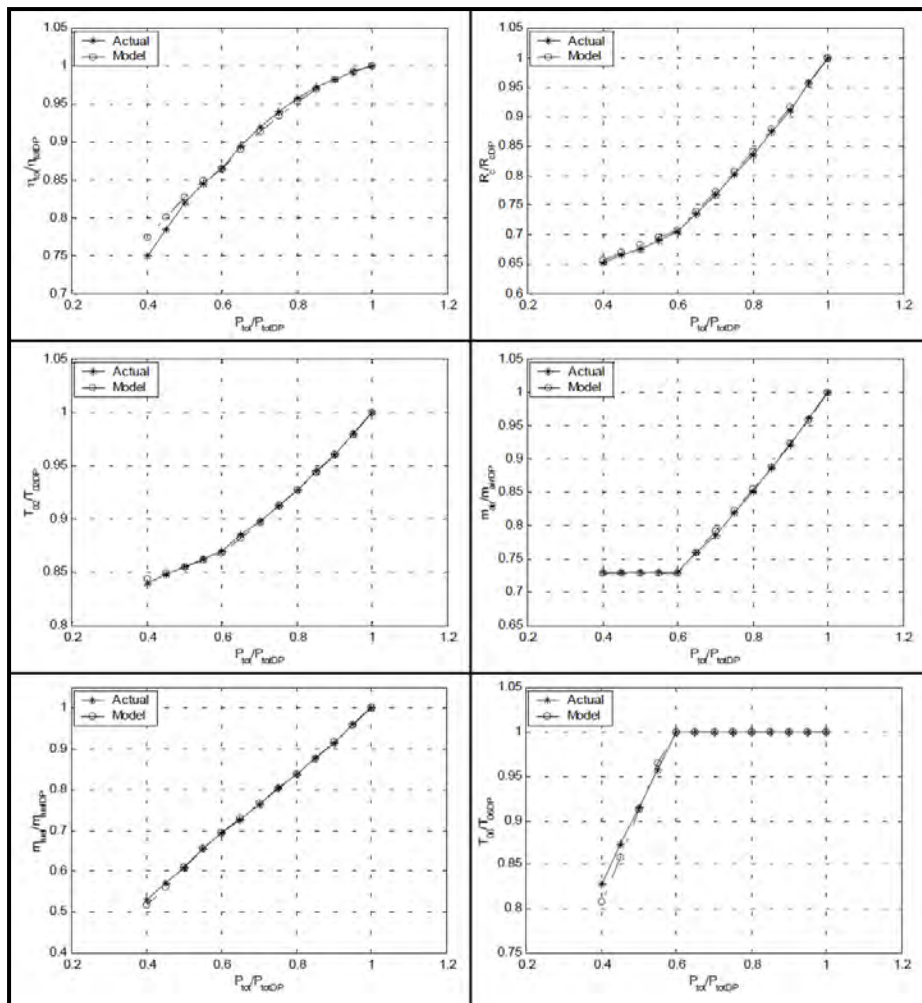
$$err\% = (x_{NN} - x_{actual})/x_{actual}$$

Τα νευρωνικά δίκτυα που επιλέχθηκαν για κάθε έξοδο έχουν την δομή:

Network	No. of neurons in the hidden layer	Hidden layer Transfer function	Output layer Transfer function	Learning algorithm	Maximum Percentage Error
η_{tot}	15	hyperbolic tangent sigmoid	hyperbolic tangent sigmoid	BFGS	1.05
R_c	15	hyperbolic tangent sigmoid	hyperbolic tangent sigmoid	Levenberg-Marquardt	0.79
\dot{m}_I	15	hyperbolic tangent sigmoid	hyperbolic tangent sigmoid	Levenberg-Marquardt	0.47
T_{02}	21	hyperbolic tangent sigmoid	linear	Levenberg-Marquardt	0.3
T_{03}	18	hyperbolic tangent sigmoid	linear	Levenberg-Marquardt	0.13
T_{05}	14	hyperbolic tangent sigmoid	hyperbolic tangent sigmoid	Levenberg-Marquardt	0.49
\dot{m}_f	9	hyperbolic tangent sigmoid	linear	Levenberg-Marquardt	0.92
L	12	hyperbolic tangent sigmoid	hyperbolic tangent sigmoid	BFGS	0.99

Σχήμα 4-6: Δομή νευρωνικών δικτύων με την μεγαλύτερη ακρίβεια.

Προέλευση:[62]



Σχήμα 4-7: Σύγκριση αποτελεσμάτων προσομοίωσης και πραγματικών τιμών.
Προέλευση:[62]

Οι C.M. Bartolini, F. Caresana, G. Comodi, L. Pelagalli, M. Renzi, S. Vagni στην εργασία τους [55] εφάρμοσαν τα νευρωνικά δίκτυα για την περιγραφή των επιδόσεων του μικροστροβίλου (MTG). Ειδικότερα, τα χρησιμοποίησαν για: (i) την συμπλήρωση των μη διαθέσιμων πειραματικών στοιχείων των διαγραμμάτων λειτουργίας και (ii) την ανάλυση και πρόβλεψη των εκπομπών ρύπων της εξόδου του κινητήρα. Τα δεδομένα που χρησιμοποιήθηκαν προέρχονται από δοκιμές του κατασκευαστή. Παρά το μεγάλο πλήθος των δεδομένων, τα στοιχεία δεν κάλυπταν τον πλήρη κύκλο της λειτουργίας του κινητήρα. Γι' αυτό χρησιμοποιήθηκαν νευρωνικά δίκτυα “fuzzy interference system” (ANFIS) για την αναπλήρωση των κενών. Τα αποτελέσματα αυτής της έρευνας χρησιμοποιήθηκαν επίσης για την ανάλυση της ευαισθησίας της συμπεριφοράς του κινητήρα σε διαφορετικές περιβαλλοντικές συνθήκες. Τα νευρωνικά δίκτυα μπόρεσαν να αξιολογήσουν αποτελεσματικά τόσο τις επιδόσεις όσο και τις εκπομπές του κινητήρα κατά την εγκατάστασή του σε πραγματικές συνθήκες σε οποιοδήποτε κλίμα. Το χειρότερο R^2 κατά την αξιολόγηση ήταν 0,9962. Τα σφάλματα που χρησιμοποιήθηκαν για την αξιολόγηση των δικτύων, ήταν:

- Mean absolute error (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y_i^*|$$

- Mean relative error (MRE):

$$MRE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y_i^*}{y_i} \right|$$

- Root mean square error (RMSE)


$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - y_i^*)^2}{n}}$$

Και για την συσχέτιση χρησιμοποιήθηκε το R^2 .


$$R^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y}_i)^2$$

,όπου y_i τα γνωστά δεδομένα, y_i^* οι τιμές που προβλέφθηκαν από το δίκτυο, n το πλήθος των πειραματικών δεδομένων και \bar{y}_i είναι η μέση τιμή των δεδομένων.

Κάποια ενδεικτικά αποτελέσματα της συγκεκριμένης μελέτης απεικονίζονται στα σχήματα που ακολουθούν:



Σχήμα 4-8: Σύγκριση αποτελεσμάτων προσομοίωσης και πραγματικών τιμών ισχύος. Προέλευση:[55]



Σχήμα 4-9: Σύγκριση αποτελεσμάτων προσομοίωσης και πραγματικών τιμών συγκέντρωσης NO_x .

Προέλευση:[55]


Predicted quantity	Range	MAE	RMSE	MRE (%)	R^2	Predicting tool
Power output	75–110 kW	0.8241 kW	1.0745 kW	0.8646	0.9999	Levenberg–Marquardt ANN
Fuel mass flow	3.5–7.5 g/s	0.0437 g/s	0.0660 g/s	0.9402	0.9998	Bayesian Regularization ANN
NO_x concentration	2–6 ppmv	0.1246 ppmv	0.1678 ppmv	3.42	0.9981	Levenberg–Marquardt ANN
CO concentration	0–425 ppmv	8.2785 ppmv	11.946 ppmv	11.98	0.9962	Sugeno ANFIS

Σχήμα 4-10: Απόδοση των μεθόδων ANN και ANFIS που χρησιμοποιήθηκαν στην συγκεκριμένη μελέτη.

Προέλευση:[55]

Το αντικείμενο μελέτης των C. Boccaletti, G. Cerri, B. Seyedan, [57] είναι η αξιολόγηση της αποτελεσματικότητας της εφαρμογής των νευρωνικών δικτύων στις μονάδες παραγωγής ενέργειας. Ένα νευρωνικό δίκτυο αναπτύχθηκε, τύπου back propagation και εφαρμόστηκε σε έναν αεριοστρόβιλο με αναγέννηση και θερμαντήρα νερού. Τα δεδομένα εκπαίδευσης προήλθαν από φυσικές και εμπειρικές προσομοιώσεις των παρελκόμενων του κινητήρα. Τα αποτελέσματα τα οποία προήλθαν από συμβατικές υπολογιστικές τεχνικές συγκρίθηκαν με αυτά τις άμεσης μεθόδου των νευρωνικών δικτύων. Τα αποτελέσματα των δικτύων χαρακτηρίζονται από πολύ μεγάλη ακρίβεια, προβλέποντας διάφορα συνθήκες σταθερής λειτουργίας του κινητήρα, αναφορικά με εισόδους που μπορούν εύκολα να προσκομιστούν από μετρητικά όργανα της εγκατάστασης. Στην εργασία τους σχολιάζονται διάφοροι παράμετροι βελτιστοποίησης των νευρωνικών δικτύων, όπως είναι το πλήθος των κόμβων στα κρυφά στρώματα, το μέγεθος του πακέτου δεδομένων εκπαίδευσης και του ρυθμού εκπαίδευσης. Αξίζει να δοθεί το ακόλουθο διάγραμμα που προήλθε από

την συγκεκριμένη έρευνα, στο οποίο απεικονίζεται η μεταβολή του μέσου τετραγωνικού σφάλματος όταν αλλάζει ο ρυθμός εκπαίδευσης.



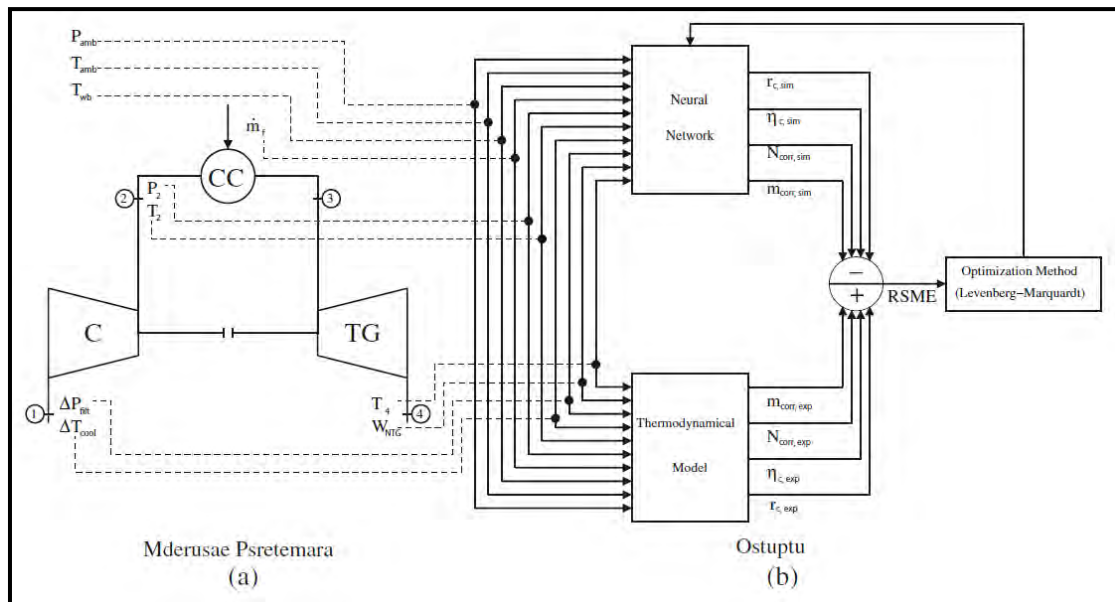
Σχήμα 4-11: Μεταβολή του σφάλματος rmse με την μεταβολή του ρυθμού εκπαίδευσης.

Προέλευση:[57]

Οι O. Cortis, G. Urquiza, J.A. Hernandez [59] εξέτασαν την βελτιστοποίηση των παραμέτρων (π.χ. συνθήκες λειτουργίας), οι οποίες συσχετίζονται με τις επιδόσεις του συμπιεστή, βασισμένη σε νευρωνικά δίκτυα και στην μέθοδο βελτιστοποίησης simplex Nelder–Mead. Σκοπός, η βελτιστοποίηση των παραμέτρων σε συγκεκριμένες συνθήκες με την χρήση νευρωνικών δικτύων (artificial neural network inverse, ANNi). Αρχικά αναπτύχθηκε ένα νευρωνικό δίκτυο, το οποίο προβλέπει : το λόγο συμπίεσης του συμπιεστή, τον ισεντροπικό βαθμό απόδοσης του συμπιεστή, την διορθωμένη ταχύτητα και τον διορθωμένο ρυθμό ροή του αέρα. Ως δεδομένα εισόδου χρησιμοποιήθηκαν: η πίεση περιβάλλοντος, η θερμοκρασία περιβάλλοντος, η πτώση θερμοκρασία του ψύκτη, η πτώση πίεσης του φίλτρου, εξωτερική θερμοκρασία του συμπιεστή η ισχύς του κινητήρα, η θερμοκρασία καυσαερίων και η ρυθμός κατανάλωσης καυσίμου.

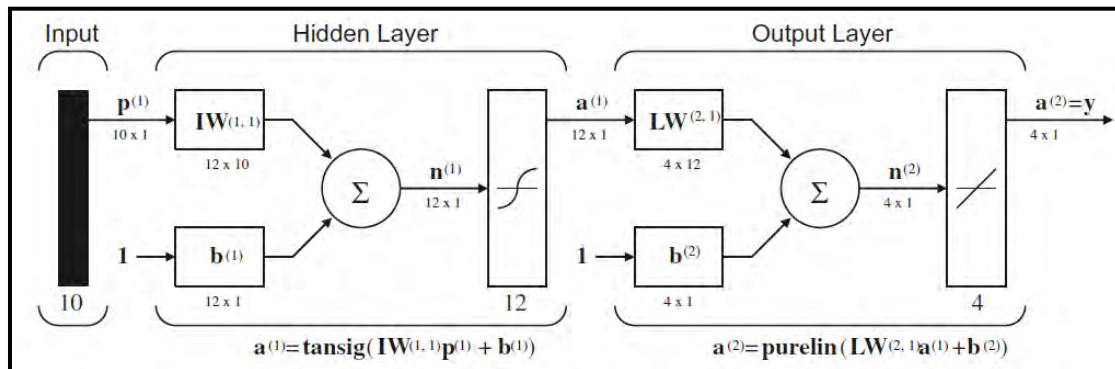
Στο δίκτυο χρησιμοποιήθηκε ένα κρυφό στρώμα. Ως μέθοδος εκπαίδευσης ορίστηκε ο αλγόριθμος Levenberg–Marquardt. Ως συναρτήσεις μεταφοράς χρησιμοποιήθηκαν η υπερβολική εφαπτόμενη σιγμοειδής και τη γραμμική. Τα καλύτερα αποτελέσματα δόθηκαν όταν χρησιμοποιήθηκαν 12 κόμβοι στο κρυφό στρώμα. Η συσχέτισης των εξόδων κυμάνθηκε σε πολύ καλά επίπεδα, καθώς βρέθηκε ότι $R^2 > 0.99$. Οπότε, τα νευρωνικά δίκτυα μπορούν να χρησιμοποιηθούν για την πρόβλεψη των συνθηκών λειτουργίας, όταν οι παράμετροι εισόδου είναι γνωστοί. Επίσης, το σφάλμα των εξόδων, κυμάνθηκε σε πολύ χαμηλά επίπεδα (error < 0.1%). Συνεπώς, η προτεινόμενη μεθοδολογία μπορεί να εφαρμοστεί στην βελτιστοποίηση

της απόδοσης του συμπιεστή, εκτελώντας την βελτιστοποίηση σε πολύ μικρό χρόνο (μικρότερο των 0,5s).



Σχήμα 4-12: (α) Σχηματική απεικόνιση του κινητήρα με τα σημεία μέτρησης, (β) μοντέλο εκπαίδευσης νευρωνικού δικτύου.

Προέλευση:[59]



Σχήμα 4-13: Δομή νευρωνικού δικτύου.

Προέλευση:[59]

4.2. Χαρακτηριστικά των νευρωνικών δικτύων

Στη συνέχεια κρίνεται σκόπιμη μία σύντομη περιγραφή της δημιουργίας και λειτουργίας ενός νευρωνικού δικτύου οπίσθιας διάδοσης (Back Propagation) (βλέπε ενότητα 1.5.4) πριν την επεξήγηση, ανάπτυξη και παρουσίαση των αποτελεσμάτων.

Για την δημιουργία ενός νευρωνικού δικτύου απαιτείται αρχικά η επιλογή κάποιων βασικών παραμέτρων που το απαρτίζουν:

- Το πλήθος των εισόδων
- Το πλήθος των εξόδων
- Το πλήθος των κρυφών στρωμάτων
- Το πλήθος των κόμβων του κάθε στρώματος
- Η συνάρτηση μεταφοράς
- Ο αλγόριθμος εκπαίδευσης

Για να καταστεί το νευρωνικό δίκτυο λειτουργήσιμο, απαιτούνται οι δύο ακόλουθες φάσεις:

Πρώτη Φάση:

Αρχικά πρέπει να γίνει η εκπαίδευση του δικτύου, κατά την οποία το δίκτυο μαθαίνει να αντιστοιχεί ένα σετ γνωστών εισόδων με τις αντίστοιχες εξόδους τους (πακέτο δεδομένων εκπαίδευσης). Έτσι το δίκτυο «μαθαίνει» την σχέση μεταξύ των εισόδων και των εξόδων. Κατά την διάρκεια της εκπαίδευσης μεταβάλλονται τα βάρη σύνδεσης. Ο σκοπός της διαδικασίας αυτής είναι η ελαχιστοποίηση του σφάλματος μεταξύ των πραγματικών τιμών (targets) και των τιμών εξόδου του δικτύου (outputs).

Δεύτερη Φάση:

Σε αυτή την φάση πραγματοποιείται ο έλεγχος του δικτύου (generalization ή testing). Εδώ το νευρωνικό δίκτυο ελέγχεται με την χρήση ενός άλλου γνωστού πακέτου δεδομένων (διαφορετικό πάντα από αυτό της εκπαίδευσης) και αξιολογείται η επίδοση (performance) του δικτύου.

4.2.1. Πακέτα δεδομένων τροφοδότησης των νευρωνικών δικτύων

Τα δεδομένα εισόδου (είσοδοι και επιθυμητές έξοδοι) προέρχονται από μετρήσεις που έχουν γίνει στον συγκεκριμένο κινητήρα του εργαστηρίου στα πλαίσια παλαιότερων διπλωματικών εργασιών και πειραματικών μετρήσεων για τις ανάγκες του αντίστοιχου εργαστηριακού μαθήματος.

Ως δεδομένα εισόδου χρησιμοποιήθηκαν οι μετρήσεις του μεγέθους:

Μέγεθος	Συμβολισμός	Μονάδα Μέτρησης
Στροφές κινητήρα	RPM	rpm


Πίνακας 4-1: Δεδομένα εισόδου νευρωνικών δικτύων.

Ως δεδομένα εξόδου (επιθυμητές εξόδους) χρησιμοποιήθηκαν τα ακόλουθα μεγέθη:


Θέση	Μέγεθος	Συμβολισμός	Μονάδα Μέτρησης
Έξοδος Συμπιεστή	Θερμοκρασία (αριστερός αισθητήρας)	$T_{3, \text{left}}$	K
	Θερμοκρασία (δεξιός αισθητήρας)	$T_{3, \text{right}}$	K
	Στατική πίεση (αριστερός αισθητήρας)	$P_{3, \text{left}}$	bar
	Στατική πίεση (δεξιός αισθητήρας)	$P_{3, \text{right}}$	bar
	Ολική πίεση (αριστερός αισθητήρας)	$P_{t3, \text{left}}$	bar
	Ολική πίεση (δεξιός αισθητήρας)	$P_{t3, \text{right}}$	bar
Έξοδος Θ.Κ.	Θερμοκρασία	T_4	K
	Ολική πίεση	P_{t4}	bar
Έξοδος Στροβίλου	Θερμοκρασία (πάνω αισθητήρας)	$T_{5, \text{up}}$	K
	Θερμοκρασία (κάτω αισθητήρας)	$T_{5, \text{down}}$	K
	Θερμοκρασία (αριστερός αισθητήρας)	$T_{5, \text{left}}$	K
	Θερμοκρασία (δεξιός αισθητήρας)	$T_{5, \text{right}}$	K
	Στατική πίεση (πάνω αισθητήρας)	$P_{5, \text{up}}$	bar
	Στατική πίεση (κάτω αισθητήρας)	$P_{5, \text{down}}$	bar
	Ολική πίεση (πάνω αισθητήρας)	$P_{t5, \text{up}}$	bar
	Ολική πίεση (κάτω αισθητήρας)	$P_{t5, \text{down}}$	bar
	Έξοδος καυσαερίων	EGT	K
	Ώση κινητήρα	THRUST	N

Πίνακας 4-2: Επιθυμητές εξόδους νευρωνικών δικτύων.

Το πλήθος το δεδομένων που αρχικά πάρθηκαν για την εκπαίδευση των δικτύων για όλες τις επιθυμητές εξόδους, εκτός της ώσης του κινητήρα, είναι **10874** μετρήσεις (με εύρος στροφών 35000-104500), ενώ για την ώση του κινητήρα είναι **8171** (με εύρος στροφών 35000-104500). Οι μετρήσεις της ώσης είναι λιγότερες, διότι σε κάποιο πείραμα δεν είχε ρυθμιστεί να λαμβάνεται σήμα από τον αντίστοιχο αισθητήρα. Στα παρακάτω ιστογράμματα φαίνεται το πλήθος των μετρήσεων και η κατανομή τους συναρτήσει των στροφών του κινητήρα.




Σχήμα 4-14: Πλήθος των μετρήσεων για όλες τις επιθυμητές εξόδους εκτός της ώσης συναρτήσει των στροφών του κινητήρα.



Σχήμα 4-15: (πάνω) Πλήθος των μετρήσεων για την ώση συναρτήσει των στροφών του κινητήρα, (κάτω) Μετρήσεις ώσης συναρτήσει των στροφών του κινητήρα.

Σημείωση: Στο παραπάνω σχήμα δίνεται και το αντίστοιχο διάγραμμα ώσης συναρτήσει στροφών κινητήρα, ώστε να δοθεί μία εικόνα αναλογικά με την κατανομή των μετρήσεων που δίνεται στο παραπάνω ιστόγραμμα.

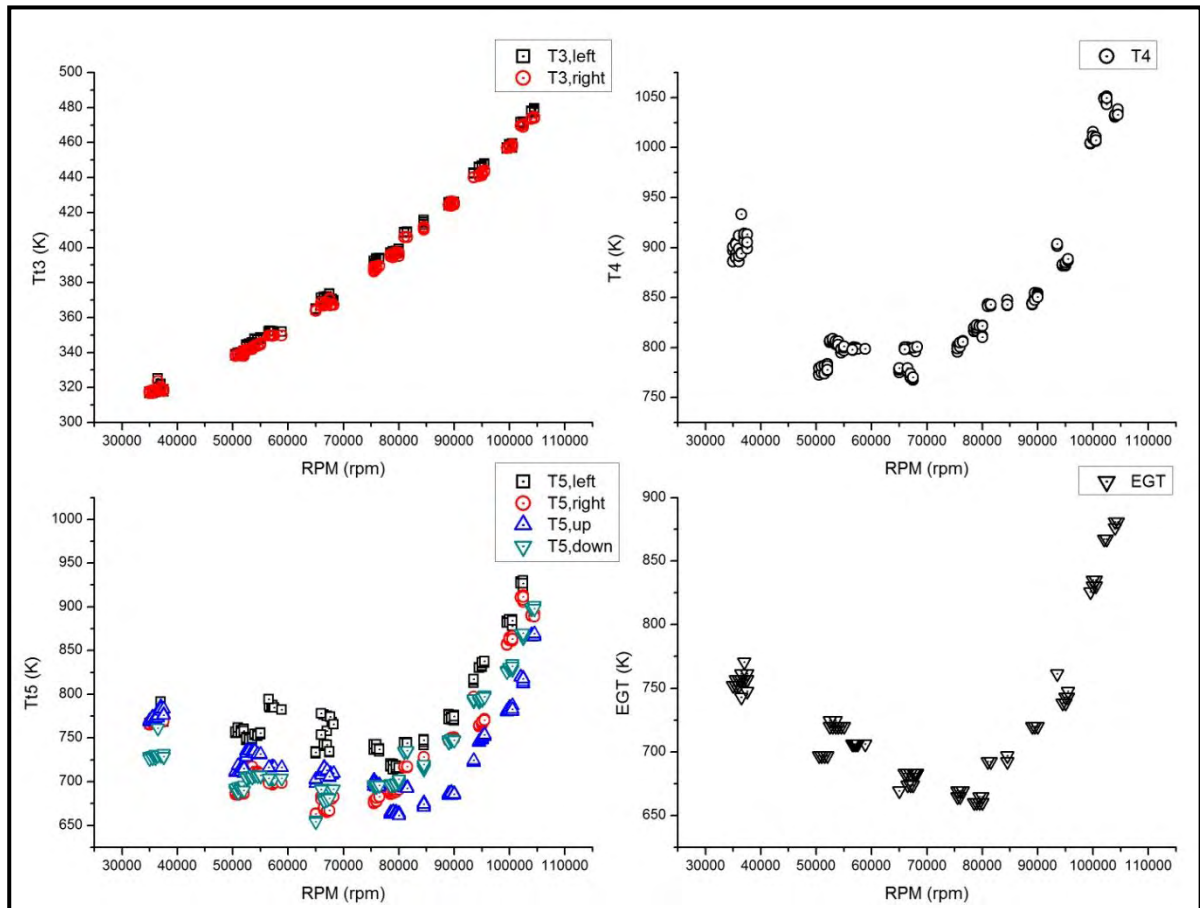
Λόγω του πολύ μεγάλου πλήθους των δεδομένων πραγματοποιείται κάποια σχετικά τυχαία επιλογή των διαθέσιμων δεδομένων. Ο λόγος, να αποφευχθεί η πολύ μεγάλη καθυστέρηση της εκπαίδευσης, η οποία είναι και άσκοπη, καθώς όπως φαίνεται και στα παραπάνω ιστογράμματα για ένα μικρό εύρος στροφών το πλήθος των μετρήσεων είναι σημαντικά πολύ μεγάλο (περίπου έως και 1000 μετρήσεις για εύρος 100 στροφών), άρα και η τροποποίηση των βαρών θα πραγματοποιείται για σχεδόν ίδιες τιμές. Για τον λόγο αυτό για την ώση του κινητήρα επιλέγονται 185 μετρήσεις, ενώ για τις υπόλοιπες παραμέτρους 192 μετρήσεις. Όπως θα αναφερθεί και στην συνέχεια, το πλήθος αυτών των μετρήσεων θα μειωθεί ώστε να εξεταστεί ο επηρεασμός του πλήθους των διαθέσιμων μετρήσεων στην εκπαίδευση και δοκιμή ενός δικτύου.



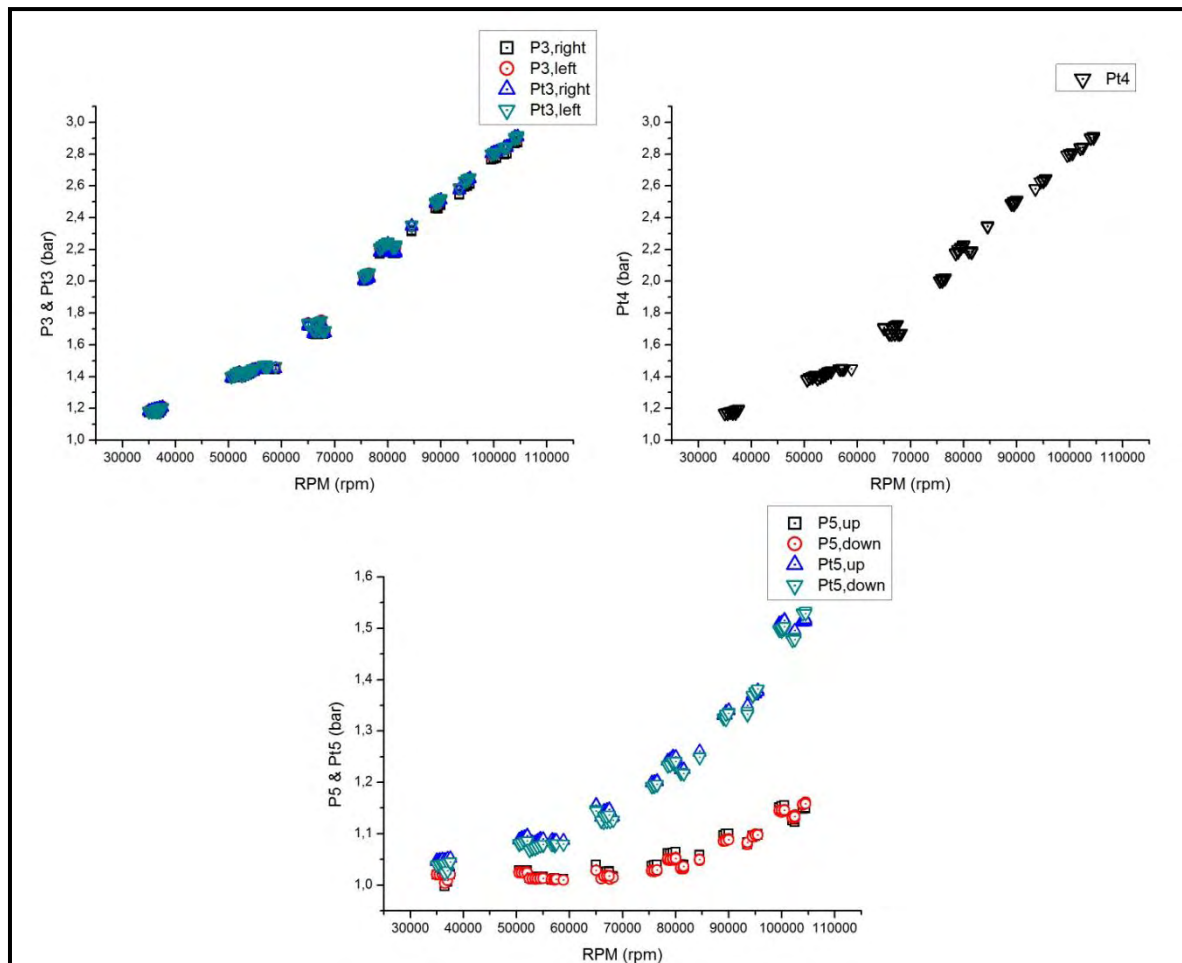
Σχήμα 4-16: (πάνω) Πλήθος των μετρήσεων για τις πιέσεις και τις θερμοκρασίες συναρτήσει των στροφών του κινητήρα, (κάτω) Πλήθος των μετρήσεων για την ώση συναρτήσει των στροφών του κινητήρα.

Όπως φαίνεται και στα παραπάνω ιστογράμματα έχουν επιλεγεί οι τιμές ώστε να υπάρχει μία ομοιόμορφη κατανομή των μετρήσεων συναρτήσει των στροφών του κινητήρα, έτσι ώστε να αποφευχθεί να δοθεί βαρύτητα από το πρόγραμμα κατά την φάση της εκπαίδευσης σε ένα συγκεκριμένο μικρό εύρος στροφών, όπου το πλήθος των διαθέσιμων μετρήσεων μπορεί να ήταν υπερβολικά υψηλό σε σχέση με της υπόλοιπες (βλέπε σχήματα 6-1 και 6-2).


Ακολουθούν τα διαγράμματα των μετρήσεων πίεσης θερμοκρασίας και ώσης συναρτήσει των στροφών που θα χρησιμοποιηθούν ως δεδομένα εισόδου στα νευρωνικά δίκτυα για τις φάσεις της εκπαίδευσης και δοκιμής.



Σχήμα 4-17: Μετρήσεις θερμοκρασιών συναρτήσει των στροφών του κινητήρα.



Σχήμα 4-18: Μετρήσεις των πιέσεων συναρτήσει των στροφών του κινητήρα.



Σχήμα 4-19: Μετρήσεις ώσης συναρτήσει των στροφών του κινητήρα.

4.2.2. Αδιαστατοποίηση δεδομένων εισόδου

Πρέπει να αναφερθεί ότι πάγια μέθοδος κατά την επεξεργασία δεδομένων με νευρωνικά δίκτυα, αυτού του είδους με την παρούσα εργασία, αποτελεί η αδιαστατοποίηση των δεδομένων πριν την τροφοδότησή τους στο δίκτυο.

Ο λόγος της εφαρμογής της αδιαστατοποίησης αποσκοπεί στην σωστή λειτουργία του δικτύου, καθώς επιτυγχάνεται η ίδια τάξη μεγέθους τόσο για τα δεδομένα εισόδου, όσο και για τα δεδομένα εξόδου. Αν δεν εφαρμοζόταν η τεχνική αυτή το νευρωνικό δίκτυο δεν θα μπορούσε να συσχετίσει τα δεδομένα εισόδου και εξόδου με αποτέλεσμα το σφάλμα να μην συγκλίνει ποτέ σε μία ελάχιστη τιμή, άρα και η εκπαίδευση να αποτυγχάνει.

Στο πλαίσιο της συγκεκριμένης μεταπτυχιακής εργασίας αναπτύχθηκαν και χρησιμοποιήθηκαν οι υπορουτίνες `adiast0.m` και `adiast1.m`, οι οποίες έχουν ως είσοδο τα δεδομένα προς αδιαστατοποίηση (εισόδου και επιθυμητές εξόδους) και αφότου εφαρμόσουν μία απλή γραμμική σχέση αδιαστατοποίησης, δίνουν ως έξοδο τις αντίστοιχες τιμές, αδιαστατοποιημένες στο εύρος τιμών που έχει οριστεί.

Οι σχέσεις που χρησιμοποιούνται στην παραπάνω διαδικασία είναι:


$$X^* = \frac{X - A}{B}$$
$$A = X_{\max} - X_{\max}^* \cdot B \quad \text{και} \quad B = \frac{X_{\max} - X_{\min}}{X_{\max}^* - X_{\min}^*}$$

,όπου: X : μέγεθος προς αδιαστατοποίηση, X^* : αδιαστατοποιημένο μέγεθος, X_{\max} & X_{\min} : μέγιστο και ελάχιστο μέγεθος προς αδιαστατοποίηση αντίστοιχα και X_{\max}^* & X_{\min}^* : μέγιστη και ελάχιστη τιμή του εύρους της αδιαστατοποίησης.

Στην παρούσα πτυχιακή, λαμβάνοντας υπόψη και αντίστοιχες δημοσιευμένες έρευνες, επιλέγεται ως εύρος αδιαστατοποίησης για τις τιμές εισόδου το $[-1,1]$, ενώ για τις τιμές εξόδου επιλέγεται το εύρος $[0,1]$.

Εδώ πρέπει να τονιστεί ότι τα δεδομένα εκπαίδευσης και ελέγχου οφείλουν να έχουν πάντοτε το ίδιο εύρος αδιαστατοποίησης, διότι διαφορετικά δεν θα μπορέσει να υπάρξει ταύτιση μεταξύ αυτών, έχοντας ως αποτέλεσμα την ύπαρξη σημαντικών σφαλμάτων.

Στο επόμενο σχήμα απεικονίζονται τα δεδομένα εισαγωγής στο δίκτυο της ώσης συναρτήσει των στροφών του κινητήρα, ως ένδειξη της διαδικασίας αδιαστατοποίησης. Οι τιμές εισόδου αποκαλούνται `inputs`, ενώ οι τιμές εξόδου ως `targets`.




Σχήμα 4-20: Αδιαστατοποιημένα δεδομένα εισαγωγής του δικτύου της ώσης συναρτήσει των στροφών του κινητήρα.

4.2.3. Χρησιμοποιούμενος κώδικας

Για τις ανάγκες της εργασίας γίνεται η χρήση του ευρέως διαδεδομένου εμπορικού πακέτου Matlab R2012b και πιο συγκεκριμένα του Neural Network Fitting Tool. Ο λόγος που χρησιμοποιείται αυτό το υπολογιστικό πακέτο οφείλεται τόσο στην απλότητά του όσο και στην ακρίβεια που προσδίδει. Επίσης, όπως θα αναφερθεί και στο αντίστοιχο κεφάλαιο των προτάσεων για τις δυνατότητες περαιτέρω συνέχειας της συγκεκριμένης εργασίας, τα νευρωνικά δίκτυα που θα αναπτυχθούν μπορούν εύκολα να μετατραπούν σε Simulink και να συνδεθούν με τις υπάρχοντες εργασίες του εργαστηρίου σχετικά με την μοντελοποίηση του κινητήρα Olympus HP ES.

Η γενική δομή του νευρωνικού δικτύου που θα χρησιμοποιηθεί απαρτίζεται από τις μεταβλητές εισόδου (inputs), ένα κρυφό στρώμα και ένα στρώμα εξόδου το οποίο τροφοδοτεί τις μεταβλητές εξόδου (outputs).



Σχήμα 4-21: Δομή νευρωνικού δικτύου.

Για αποφυγή οποιασδήποτε σύγχυσης αποσαφηνίζεται η χρήση των ακόλουθων όρων:

- Inputs: δεδομένα εισόδου
- Targets: επιθυμητά δεδομένα εξόδου
- Outputs: δεδομένα εξόδου δικτύου

Τόσο τα inputs όσο και τα targets δίνονται εξ αρχής στο δίκτυο, ένα ποσοστό (ορίζεται από τον χρήστη) δεδομένων inputs-targets χρησιμοποιείται από το δίκτυο για την διαδικασία της εκπαίδευσης (training) και το υπόλοιπο για την διεργασία της δοκιμής (testing). Ο καθορισμός των τιμών αναφορικά με την κατηγορία στην οποία ανήκουν γίνεται τυχαία από το ίδιο το πρόγραμμα. Κατά την δοκιμή το δίκτυο αξιολογεί την διαδικασία της εκπαίδευσης και αυτό πραγματοποιείται συγκρίνοντας κάθε φορά το σφάλμα μεταξύ της επιθυμητής εξόδου (target) με την έξοδο (output) για κάθε αντίστοιχη είσοδο (input), αντλώντας στοιχεία από το ποσοστό των δεδομένων που ορίστηκε για την αξιολόγηση.

Για την επεξήγηση των δεδομένων που αντλούνται από τον αλγόριθμο εκπαίδευσης και δοκιμής του Matlab χρησιμοποιείται το νευρωνικό δίκτυο ενός κρυφού στρώματος (αποτελούμενο από δέκα νευρώνες) για τον αισθητήρα της ώσης.

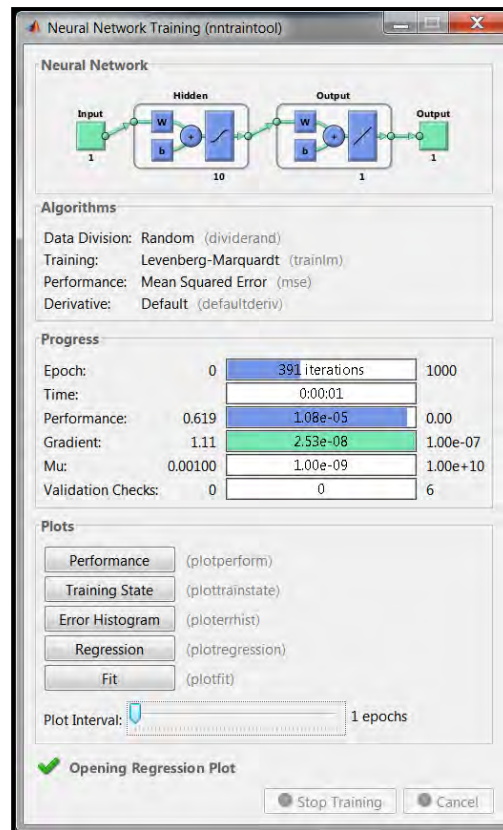
Αρχικά δίνεται στο πρόγραμμα ως είσοδος τα αδιαστατοποιημένα δεδομένα εισόδου:

- Inputs: RPM
- Outputs: Thrust

Ορίζεται ως ποσοστό εκπαίδευσης το 60% των δεδομένων και το υπόλοιπο 40% προορίζεται για την δοκιμή του δικτύου.

Μετά το πέρας της εκπαίδευσης και της δοκιμής εμφανίζεται στην οθόνη ένα παράθυρο στο οποίο διευκρινίζονται:

- Η δομή του δικτύου
- Οι παράμετροι εκπαίδευσης (μέθοδος διαίρεσης δεδομένων, αλγόριθμος εκπαίδευσης και είδος σφάλματος για την αξιολόγηση του δικτύου)
- Τα αποτελέσματα της διεργασίας
- Η επιλογή απεικόνισης διαγραμμάτων αναφορικά με την εκπαίδευση και την δοκιμή




Σχήμα 4-22: Εμφανιζόμενο παράθυρο μετά το πέρας της διεργασία και εκπαίδευσης του δικτύου.

Τα σημαντικότερα διαγράμματα που μπορούν να απεικονιστούν είναι:

- Διάγραμμα απόδοσης του δικτύου


Στο συγκεκριμένο διάγραμμα απεικονίζεται η εξέλιξη του σφάλματος της εκπαίδευσης και της δοκιμής σε κάθε επανάληψη που πραγματοποιείται. Επίσης δίνεται το πλήθος των επαναλήψεων στο οποίο το σφάλμα είναι ελάχιστο.



Σχήμα 4-23: Απεικόνιση απόδοσης δικτύου.

- Διάγραμμα τελικής μοντελοποίησης

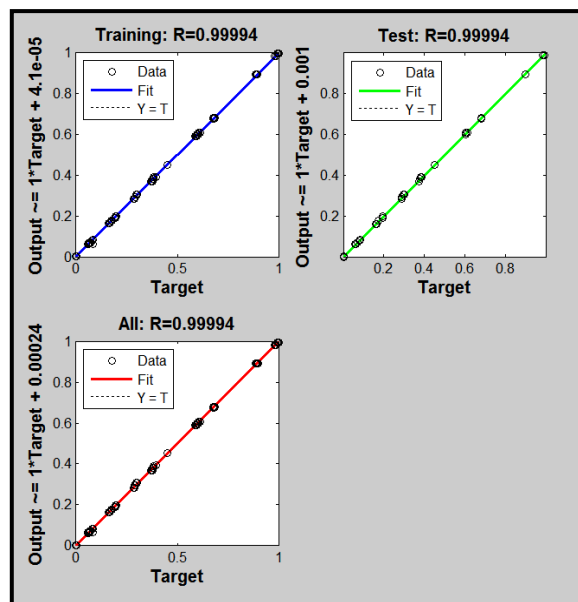
Όπως απεικονίζεται και στο σχήμα που ακολουθεί, αναπαρίσταται η τελική μοντελοποίηση των δεδομένων, καθώς και διευκρινίζονται σε ποια κατηγορία ανήκουν τα σημεία της μοντελοποίησης. Επιπρόσθετα δίνεται και το σφάλμα της κάθε εξόδου.



Σχήμα 4-24: Εμφανιζόμενο παράθυρο μετά το πέρας της διεργασία και εκπαίδευσης του δικτύου.

- Διάγραμμα συσχέτισης

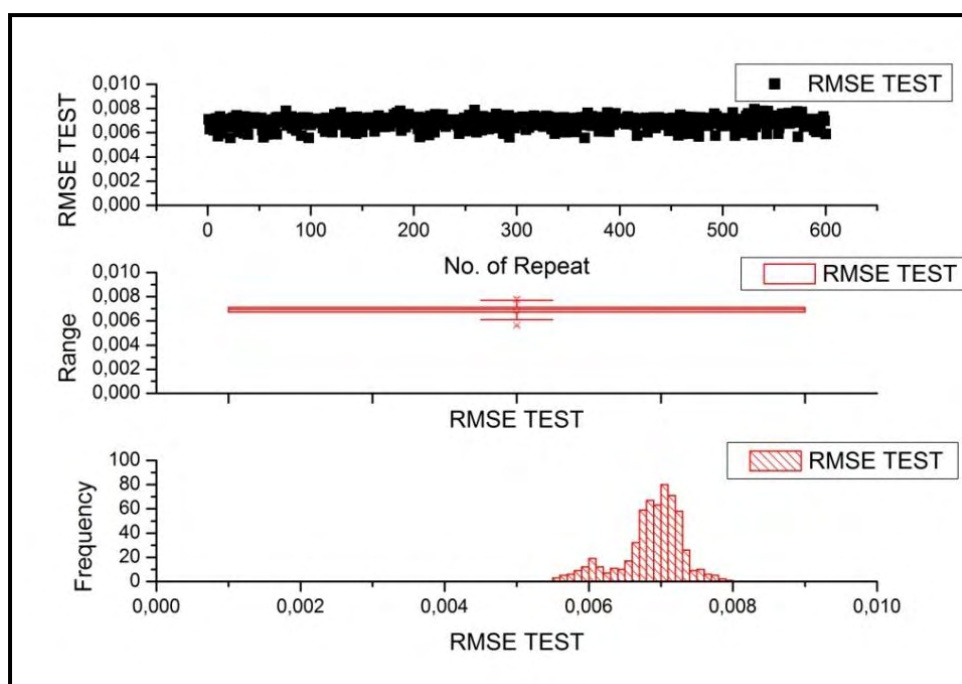
Ένα εξίσου σημαντικό διάγραμμα είναι αυτό της συσχέτισης των τιμών. Ειδικότερα δίνεται η συσχέτιση των εξόδων του δικτύου (outputs) με τις επιθυμητές εξόδους (targets) για τις τιμές εκπαίδευσης, δοκιμής καθώς και του συνόλου αυτών.



Σχήμα 4-25: Εμφανιζόμενο παράθυρο μετά το πέρας της διεργασία και εκπαίδευσης του δικτύου.

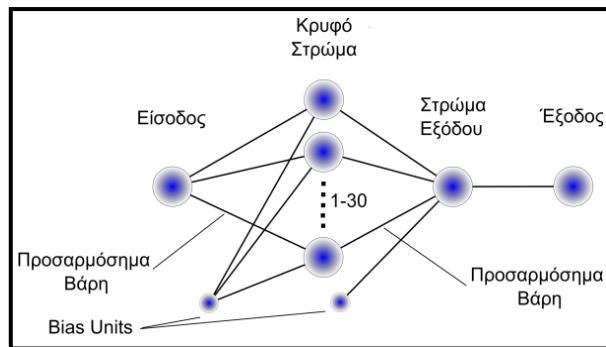
4.3. Περιγραφή διεργασίας αξιολόγησης

Για την μοντελοποίηση των δεδομένων το matlab, για κάθε ίδιου είδους νευρωνικού δικτύου, αρχικοποιεί τις τιμές των βαρών με τυχαίες τιμές. Επίσης, η διαίρεση των δεδομένων εισόδου στις κατηγορίες εκπαίδευσης και δοκιμής γίνεται με τυχαίο τρόπο. Συνεπώς, τα αποτελέσματα του προγράμματος κάθε φορά θα διαφέρουν μεταξύ τους για τα ίδια δεδομένα. Όμως παρατηρήθηκε ότι για 600 τρεξίματα η τιμή του σφάλματος, καθώς και τα υπόλοιπα αποτελέσματα, τείνουν να συγκεντρώνονται γύρω από μία τιμή, δηλαδή παρουσιάζουν μία κανονική κατανομή. Στο παρακάτω σχήμα απεικονίζεται ενδεικτικά τα αποτελέσματα του σφάλματος rmse της δοκιμής του αισθητήρα για δίκτυο ενός κρυφού στρώματος με δέκα κόμβους. Το ίδιο ακριβώς παρατηρήθηκε και στα αποτελέσματα των υπόλοιπων αισθητήρων. Για αυτό τον λόγο για να υπάρξει μία πιο αντικειμενική εικόνα του σφάλματος κάθε αποτέλεσμα που θα παρουσιάζεται στην συνέχεια θα αποτελεί η μέση τιμή που προκύπτει από 600 επαναλήψεις.



Σχήμα 4-26: Κανονική κατανομή τιμών σφάλματος rmse της δοκιμής για τον αισθητήρα T3right για 600 επαναλήψεις αποτελεσμάτων.

Η μελέτη που θα επακολουθήσει θα εστιαστεί στην προσημείωση του κάθε αισθητήρα ξεχωριστά με νευρωνικό δίκτυο ενός κρυφού στρώματος, εναλλάσσοντας το πλήθος των κόμβων στο κρυφό υπόστρωμα, ξεκινώντας από 1 κόμβο έως τους 30 κόμβους.




Σχήμα 4-27: Δομή νευρωνικού δικτύου για κάθε αισθητήρα.

Θα αξιολογηθούν οι δύο διαφορετικοί αλγόριθμοι εκπαίδευσης του matlab, οι οποίοι βασίζονται στις μεθόδους:

- Levenberg-Marquardt (trainlm)
- BFGS quasi-Newton (trainbfg)

Οι συναρτήσεις μεταφοράς που θα χρησιμοποιηθούν είναι:

- στο κρυφό στρώμα: υπερβολική εφαπτόμενη σιγμοειδής (tansig)
- στο στρώμα εξόδου: θα γίνει μελέτη με εναλλαγή των ακόλουθων δύο:
 - γραμμική (purelin)
 - υπερβολική εφαπτόμενη σιγμοειδής (tansig)



Σχήμα 4-28: Συναρτήσεις μεταφοράς.

Το εξαγόμενο σφάλμα υπολογίζεται και δίνεται από το μέσο τετραγωνικό σφάλμα (mean square error – mse) μεταξύ outputs και targets, τόσο για την διαδικασία της εκπαίδευσης όσο και της δοκιμής. Υπολογίζοντας την τετραγωνική ρίζα του σφάλματος, δίνεται το root mean square error (rmse). Όσο περισσότερο πλησιάζει στο μηδέν τόσο μικρότερο σφάλμα έχουμε.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2}$$

,όπου: \hat{Y}_i : outputs και Y_i : targets

Για την συσχέτιση των targets και outputs χρησιμοποιείται η γραμμική συσχέτιση. Όσο τείνει στο 1 έχουμε τέλεια συμφωνία μεταξύ των τιμών, ενώ όταν τείνει στο 0 δεν έχουμε καμία συμφωνία.

Μετά το πέρας του κάθε τρεξίματος δημιουργείται μία εξάδα διαγραμμάτων (όπως απεικονίζεται στην συνέχεια), όπου:

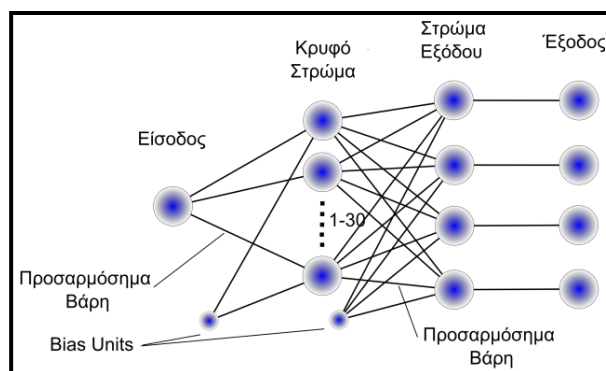
1	2
3	4
5	6

- 1: το σφάλμα RMSE για τις φάσεις εκπαίδευσης και δοκιμής για τους κόμβους 1 έως 30
- 2: εστίαση του διαγράμματος 1 στους 10 κόμβους με το μικρότερο σφάλμα δοκιμής και επιλογή αυτού με το μικρότερο σφάλμα.
- 3: η συσχέτισης μεταξύ outputs και targets για τους κόμβους 1 έως 30
- 4: εστίαση του διαγράμματος 3 στους 10 κόμβους με το μικρότερο σφάλμα δοκιμής και επιλογή αυτού με το μικρότερο σφάλμα.
- 5: χρόνος διεξαγωγής της εκπαίδευσης και δοκιμή για μία φορά “τρεξίματος” του αλγορίθμου
- 6: αριθμός επαναλήψεων ανανέωσης βαρών και bias για μία φορά “τρεξίματος” του αλγορίθμου

Πρέπει να σημειωθεί ότι χρόνος εκτέλεσης του αλγορίθμου διαφέρει ανάλογα με τις δυνατότητες του υπολογιστικού μηχανήματος. Ο λόγος που δίνεται αποσκοπεί στην συγκριτική αξιολόγηση, καθώς όλα τα αποτελέσματα διεξήχθησαν από τον ίδιο υπολογιστή (βλέπε αντίστοιχο παράρτημα).

Η αξιολόγηση και επιλογή του πλήθους των κόμβων για κάθε αλγόριθμο πραγματοποιήθηκε βάσει του ελάχιστου σφάλματος δοκιμής. Ενώ για την τελική επιλογή μεταξύ των διαφορετικών αλγορίθμων λήφθηκαν υπόψη το σφάλμα δοκιμής, η συσχέτιση και ο σχετικός χρόνος εκπαίδευσης-δοκιμής.

Αφότου πραγματοποιήθηκε η παραπάνω διαδικασία ακολούθησε η ίδια διεργασία όμως σαν έξοδος ορίστηκε το πλήθος των αισθητήρων που περιγράφουν το ίδιο μέγεθος. Δηλαδή για την θερμοκρασία T5 το δίκτυο αποτελείται από 1 είσοδο και 4 εξόδους (αφού υπάρχουν 4 αισθητήρες).



Σχήμα 4-29: Δομή νευρωνικού δικτύου για θερμοκρασία T5.

Κατά την διάρκεια εκπαίδευσης, η διαδικασία επαναλαμβάνεται συνεχώς μέχρι κάποιο από τα κριτήρια σταματημού αποκτήσει αληθή τιμή. Ο λόγος ύπαρξης αυτών των κριτηρίων είναι ο τερματισμός της εκπαίδευσης του δικτύου για την αποτροπή της μετάβασης του αλγορίθμου σε ατέρμονα βρόγχο. Τα κριτήρια που θα χρησιμοποιηθούν είναι:

- **Prerformance**

Η μεταβλητή ορίζει τον στόχο της εκπαίδευσης του δικτύου, δηλαδή την επιθυμητή τιμή του σφάλματος που δεν θέλουμε να ξεπερνάει το σφάλμα εκπαίδευσης. Εδώ ορίζεται με την τιμή 0 (όσο το δυνατό καλύτερη συμφωνία).

- **Magnitude of Gradient**

Η τιμή της παραμέτρου gradient μικραίνει καθώς η εκπαίδευσης φτάνει στο βέλτιστο της απόδοσης. Η τιμή που ορίζεται είναι $1e-5$.

- **Epoch**

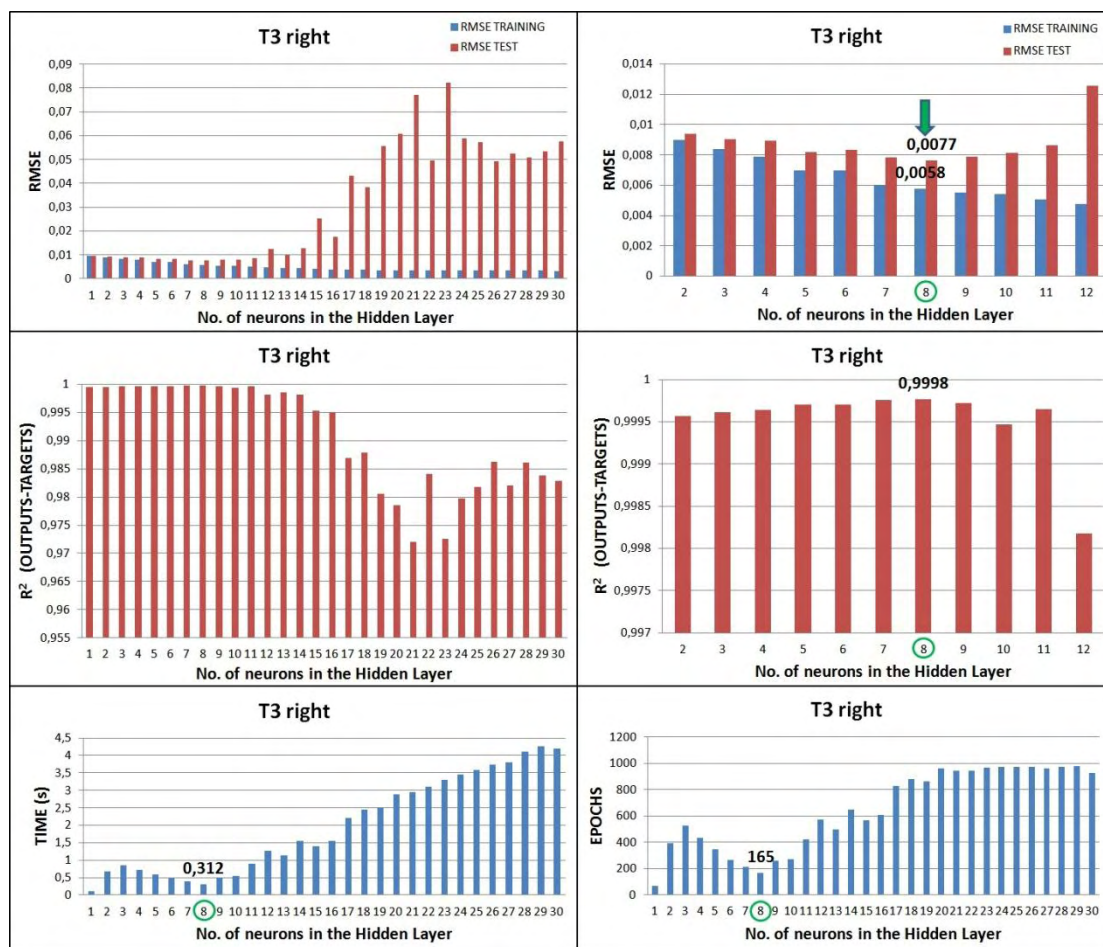
Ως μέγιστο επιτρεπτό αριθμό επαναλήψεων ορίζονται οι 1000 επαναλήψεις.

- **Time**

Αναφορικά με τον χρόνο δεν ορίζεται κάποια τιμή σταματημού, αλλά ως ανώτατο όριο θέτεται το άπειρο.

Υπάρχει και ένα άλλο κριτήριο σταματημού, το “the number of validation checks”. Σκοπός του κριτηρίου αυτού είναι να ελέγχει την μείωση της τιμής του σφάλματος. Πιο συγκεκριμένα όταν το σφάλμα εκπαίδευσης σταματάει να μειώνεται για 6 συνεχόμενες φορές (6 γιατί αυτή η τιμή συνηθίζεται να χρησιμοποιείται) τότε παύει την λειτουργία εκπαίδευσης, καθώς το δίκτυο χάνει την ικανότητά του για καλύτερη εκπαίδευση.

Για λόγους αξιολόγησης της αναγκαιότητας χρήσης του συγκεκριμένου κριτηρίου, ακολουθούν τα αποτελέσματα για την εκπαίδευση νευρωνικού δικτύου του αισθητήρα T3 right. Αρχικά τίθενται σε ισχύ τα κριτήρια σταματημού “performance”, “magnitude of gradient”, “epoch” και “time” και έπειτα προστίθεται και το κριτήριο “number of validation checks”. Τέλος γίνεται συγκριτική μελέτη και τελική επιλογή των κριτηρίων που θα χρησιμοποιηθούν.

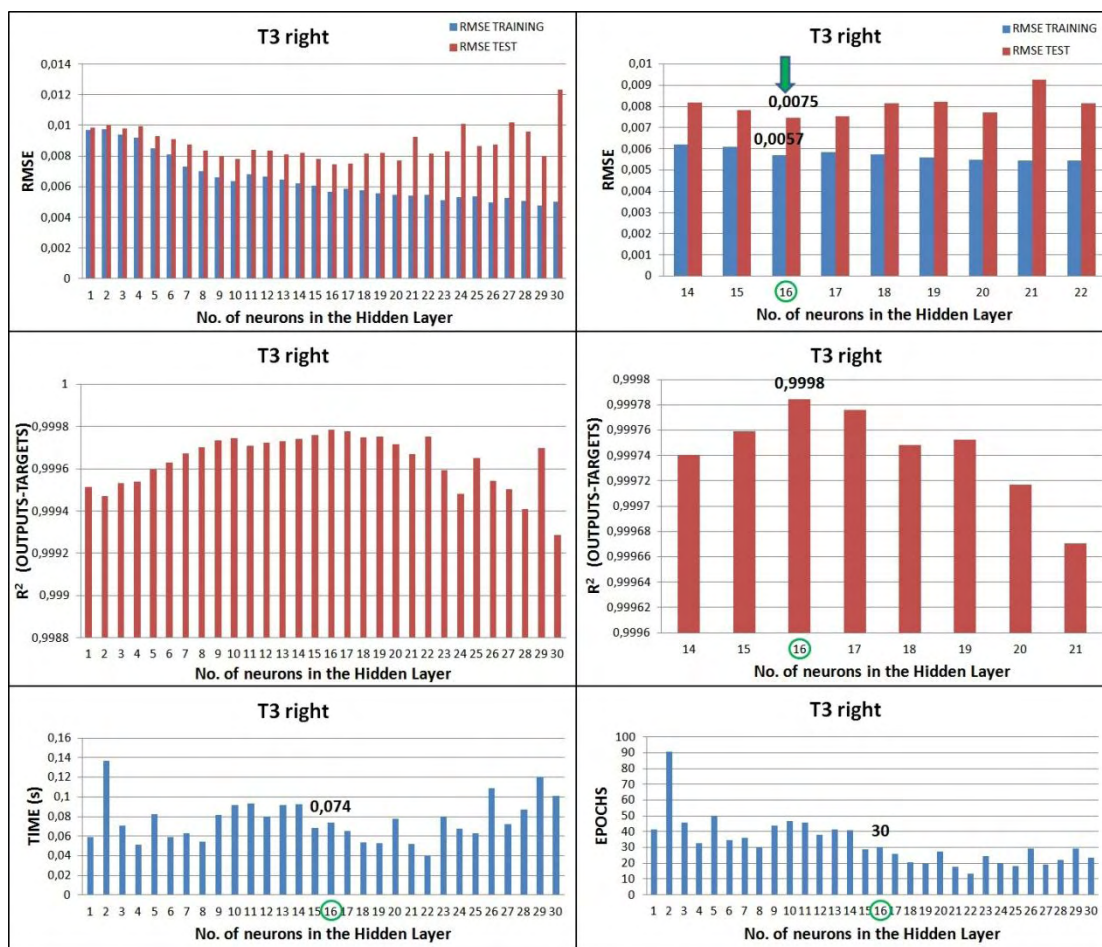


Σχήμα 4-30: Αποτελέσματα εκπαίδευσης-δοκιμής του νευρωνικού δικτύου για τον αισθητήρα T3 right χωρίς το κριτήριο σταματημού “number of validation checks”.

Τα αποτελέσματα από τα παραπάνω διαγράμματα συναρτήσε του μικρότερου σφάλματος δοκιμής είναι:

Αισθητήρας	Κριτήριο Validation	No. of Neuron in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
T3 right	OXI	8	0,0077	0,0058	0,9998	0,312	165

Πίνακας 4-3: Αποτελέσματα εκπαίδευσης νευρωνικού δικτύου για τον αισθητήρα T3 right χωρίς το κριτήριο σταματημού “number of validation checks”.



Σχήμα 4-31: Αποτελέσματα εκπαίδευσης-δοκιμής του νευρωνικού δικτύου για τον αισθητήρα T3 right με το κριτήριο σταματημού “number of validation checks”.

Τα αποτελέσματα από τα παραπάνω διαγράμματα συναρτήσε του μικρότερου σφάλματος δοκιμής είναι:

Αισθητήρας	Κριτήριο Validation	No. of Neuron in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
T3 right	NAI	16	0,0075	0,0057	0,9998	0,074	30

Πίνακας 4-4: Αποτελέσματα εκπαίδευσης νευρωνικού δικτύου για τον αισθητήρα T3 right με το κριτήριο σταματημού “number of validation checks”.

Στον παρακάτω πίνακα γίνεται συγκριτικής μελέτη των αποτελεσμάτων των δύο εκπαιδεύσεων:

Αισθητήρας	Κριτήριο Validation	No. of Neuron in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
T3 right	OXI	8	0,0077	0,0058	0,9998	0,312	165
T3 right	NAI	16	0,0075	0,0057	0,9998	0,074	30
METABOLH (%)	-	100,00%	-2,60%	-1,72%	0,00%	-76,25%	-81,82%

Πίνακας 4-5: Μεταβολή αποτελεσμάτων με και χωρίς χρήση του κριτηρίου “number of validation checks”.

Από τον παραπάνω πίνακα παρατηρείται πως η μεταβολή του σφάλματος τόσο της εκπαίδευσης όσο και της δοκιμής της εκπαίδευσης-δοκιμή με το κριτήριο “number of validation checks” είναι ελάχιστη. Αξιοσημείωτη είναι η αύξηση του πλήθους των κόμβων στο κρυφό στρώμα, καθώς έχουμε τον διπλασιασμό αυτών (από 8 σε 16). Όμως η πολύ μεγαλύτερη μείωση στον χρόνο (από 0,312 sec σε 0,074 sec) και στον αριθμό των επαναλήψεων (από 165 σε 30), οδηγεί στην τελική επιλογή της χρήσης του κριτηρίου “number of validation checks”.

Πρέπει να σημειωθεί εδώ ότι για την χρήση αυτού του κριτηρίου εξαρχής δεσμεύεται ένα ποσοστό των δεδομένων εισόδου. Θα ακολουθηθεί η πάγια τακτική σε παρόμοιες εκπαιδεύσεις. Δηλαδή, τα ποσοστά θα είναι:

Σκοπός χρήσης δεδομένων εισόδου:	Ποσοστό
Learn	60%
Validation	15%
Test	25%

Πίνακας 4-6: Ποσοστά χρήσης μεταβλητών εισόδου για εκπαίδευση, επιβεβαίωση και δοκιμή.

Τα κριτήρια που τελικώς θα χρησιμοποιηθούν στις εκπαίδευσης και δοκιμή όλων των νευρωνικών δικτύων:

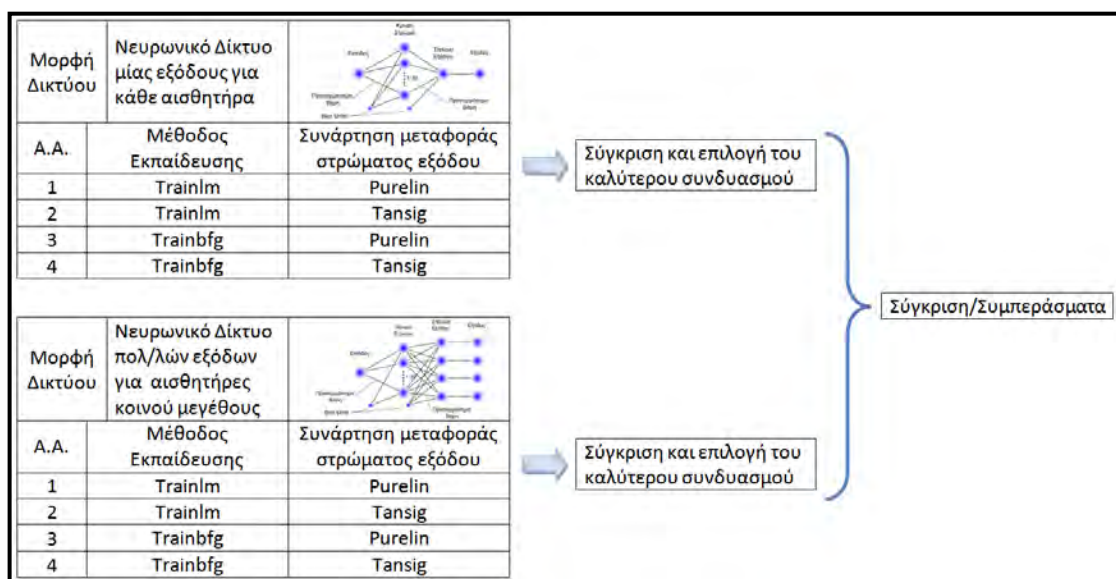
- Prerformance
- Magnitude of Gradient
- Number of validation checks
- Epoch
- Time

5. Παρουσίαση αποτελεσμάτων - Συμπεράσματα

Σκοπός του κεφαλαίου αυτού είναι η παράθεση των αποτελεσμάτων για κάθε συνδυασμό εκπαίδευσης (μέθοδος εκπαίδευσης και συνάρτηση μεταφοράς στρώματος εξόδου), τόσο για τα νευρωνικά δίκτυα μονής εξόδου για κάθε αισθητήρα, όσο και για τα υπόλοιπα με πολλαπλές εξόδους για το πλήθος των αισθητήρων που περιγράφουν το ίδιο μέγεθος. Με την βοήθεια των πινάκων αποτελεσμάτων που ακολουθούν θα γίνει η τελική βέλτιστη επιλογή για κάθε αισθητήρα.

5.1. Διαδικασία επιλογής βέλτιστου συνδυασμού εκπαίδευσης

Αρχικά δίνονται τέσσερις πίνακες, οι οποίοι περιλαμβάνουν τα αποτελέσματα της εκπαίδευσης και δοκιμής των νευρωνικών δικτύων μίας εξόδου (για κάθε αισθητήρα ξεχωριστά), για κάθε συνδυασμό εκπαίδευσης (μέθοδο εκπαίδευσης και συνάρτηση μεταφοράς στρώματος εξόδου). Ακολουθεί η σύγκριση των αποτελεσμάτων των συνδυασμών με βάση το μικρότερο παρατηρούμενο σφάλμα δοκιμής (RMSE TEST). Έπειτα γίνεται σύγκριση της μεταβολή όλων των εξεταζόμενων παραμέτρων (RMSE TEST, RMSE TRAINING, Regression, Time και Epochs) του συνδυασμού με το μικρότερο σφάλμα δοκιμής συναρτήσει των υπόλοιπων τριών μεθόδων. Η μέθοδος με τον βέλτιστο συνδυασμό των εξεταζόμενων χαρακτηριστικών επιλέγεται για την τελική του χρήση για εκπαίδευση του κάθε αισθητήρα. Η ίδια διεργασία έπειτα ακολουθείται και για τα νευρωνικά δίκτυα πολλαπλών εξόδων (για του αισθητήρες που περιγράφουν όμοιο μέγεθος). Τέλος, για τα μεγέθη που περιγράφονται από περισσότερους από έναν αισθητήρες, πραγματοποιείται σύγκριση των αποτελεσμάτων των συνδυασμών που επιλέχτηκαν προηγουμένως και διεξάγονται τα ανάλογα συμπεράσματα.



Σχήμα 5-1: Διαδικασία επιλογής βέλτιστου συνδυασμού εκπαίδευσης.

5.2. Αποτελέσματα για εκπαίδευση νευρωνικού δικτύου μίας εξόδου

Ακολουθούν οι πίνακες αποτελεσμάτων για την εκπαίδευση και δοκιμή των νευρωνικών δικτύων με μία έξοδο, δηλαδή για κάθε αισθητήρα ξεχωριστά, με την ακόλουθη σειρά:

- Trainlm-Purelin
- Trainlm-Tansig
- Trainbfg-Purelin
- Trainbfg-Tansig

Για μέθοδο εκπαίδευσης Trainlm και συνάρτηση μεταφοράς στρώματος εξόδου Purelin, προέκυψαν:

Trainlm - Purelin							
Αισθητήρας		No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ	P3 left	22	0,0077	0,0057	0,9998	0,067	21
	P3 right	22	0,0080	0,0060	0,9998	0,074	24
	P5 down	26	0,0195	0,0132	0,9984	0,144	38
	P5 up	23	0,0258	0,0179	0,9970	0,118	36
	Pt3 left	18	0,0072	0,0056	0,9998	0,059	22
	Pt3 right	22	0,0079	0,0059	0,9998	0,084	27
	Pt4	18	0,0070	0,0053	0,9998	0,066	25
	Pt5 down	23	0,0091	0,0062	0,9996	0,154	47
	Pt5 up	18	0,0107	0,0080	0,9996	0,148	54
ΘΕΡΜΟΚΡΑΣΙΕΣ	T3 left	17	0,0082	0,0066	0,9997	0,051	21
	T3 right	16	0,0075	0,0057	0,9998	0,074	30
	T4	23	0,0270	0,0206	0,9967	0,079	24
	T5 down	25	0,0194	0,0138	0,9975	0,085	24
	T5 left	29	0,0318	0,0222	0,9939	0,101	24
	T5 right	23	0,0197	0,0133	0,9982	0,147	44
	T5 up	29	0,0209	0,0133	0,9971	0,147	35
	EGT	29	0,0217	0,0150	0,9977	0,104	25
ΩΣΗ	THRUST	21	0,0049	0,0038	0,9999	0,140	47

Πίνακας 5-1: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με μία έξοδο με μέθοδο εκπαίδευσης Trainlm και συνάρτηση μεταφοράς στρώματος εξόδου Purelin.

Για μέθοδο εκπαίδευσης Trainlm και συνάρτηση μεταφοράς στρώματος εξόδου Tansig, προέκυψαν:

Trainlm - Tansig							
Αισθητήρας		No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ	P3 left	11	0,0091	0,0076	0,9995	0,114	54
	P3 right	14	0,0094	0,0078	0,9996	0,084	37
	P5 down	18	0,0255	0,0203	0,9967	0,118	43
	P5 up	20	0,0341	0,0270	0,9932	0,109	37
	Pt3 left	14	0,0083	0,0067	0,9996	0,083	36
	Pt3 right	13	0,0096	0,0075	0,9997	0,101	46
	Pt4	11	0,0083	0,0069	0,9997	0,092	45
	Pt5 down	15	0,0142	0,0126	0,9984	0,176	72
	Pt5 up	15	0,0148	0,0128	0,9988	0,122	51
ΘΕΡΜΟΚΡΑΣΙΕΣ	T3 left	8	0,0093	0,0080	0,9996	0,066	37
	T3 right	8	0,0086	0,0073	0,9997	0,063	35
	T4	8	0,0381	0,0340	0,9907	0,073	40
	T5 down	9	0,0301	0,0259	0,9928	0,080	42
	T5 left	10	0,0382	0,0329	0,9877	0,079	39
	T5 right	22	0,0349	0,0297	0,9882	0,098	31
	T5 up	8	0,0305	0,0273	0,9878	0,100	54
	EGT	9	0,0365	0,0323	0,9900	0,097	51
ΩΣΗ	THRUST	11	0,0070	0,0062	0,9996	0,133	65

Πίνακας 5-2: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με μία έξοδο με μέθοδο εκπαίδευσης Trainlm και συνάρτηση μεταφοράς στρώματος εξόδου Tansig.

Για μέθοδο εκπαίδευσης Trainbfg και συνάρτηση μεταφοράς στρώματος εξόδου Purelin, προέκυψαν:

Trainbfg - Purelin							
Αισθητήρας		No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ	P3 left	14	0,0109	0,0092	0,9995	0,121	43
	P3 right	14	0,0120	0,0103	0,9992	0,119	42
	P5 down	21	0,0291	0,0241	0,9958	0,122	39
	P5 up	21	0,0376	0,0312	0,9928	0,113	37
	Pt3 left	21	0,0286	0,0232	0,9954	0,114	37
	Pt3 right	14	0,0127	0,0111	0,9992	0,115	41
	Pt4	14	0,0114	0,0097	0,9992	0,119	41
	Pt5 down	21	0,0188	0,0145	0,9981	0,136	43
	Pt5 up	18	0,0188	0,0158	0,9983	0,127	42
ΘΕΡΜΟΚΡΑΣΙΕΣ	T3 left	13	0,0129	0,0113	0,9990	0,108	40
	T3 right	1	0,0113	0,0111	0,9993	0,101	50
	T4	21	0,0331	0,0282	0,9941	0,109	36
	T5 down	21	0,0270	0,0219	0,9946	0,120	39
	T5 left	21	0,0367	0,0311	0,9901	0,104	34
	T5 right	21	0,0295	0,0239	0,9948	0,113	37
	T5 up	21	0,0301	0,0246	0,9925	0,117	38
	EGT	21	0,0286	0,0232	0,9954	0,114	37
ΩΣΗ	THRUST	11	0,0104	0,0094	0,9993	0,114	43

Πίνακας 5-3: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με μία έξοδο με μέθοδο εκπαίδευσης Trainbfg και συνάρτηση μεταφοράς στρώματος εξόδου Purelin.

Για μέθοδο εκπαίδευσης Trainbfg και συνάρτηση μεταφοράς στρώματος εξόδου Tansig, προέκυψαν:

Trainbfg - Tansig							
Αισθητήρας		No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ	P3 left	27	0,0194	0,0175	0,9968	0,207	51
	P3 right	30	0,0198	0,0175	0,9969	0,230	49
	P5 down	21	0,0408	0,0383	0,9907	0,142	43
	P5 up	21	0,0476	0,0442	0,9878	0,133	41
	Pt3 left	30	0,0181	0,0156	0,9973	0,234	51
	Pt3 right	30	0,0190	0,0165	0,9972	0,222	50
	Pt4	21	0,0200	0,0185	0,9964	0,157	48
	Pt5 down	21	0,0252	0,0234	0,9949	0,160	48
	Pt5 up	30	0,0239	0,0217	0,9963	0,200	45
ΘΕΡΜΟΚΡΑΣΙΕΣ	T3 left	21	0,0185	0,0167	0,9967	0,146	45
	T3 right	21	0,0170	0,0155	0,9971	0,150	46
	T4	22	0,0445	0,0417	0,9806	0,147	39
	T5 down	21	0,0345	0,0316	0,9892	0,150	46
	T5 left	21	0,0493	0,0460	0,9836	0,134	41
	T5 right	21	0,0381	0,0352	0,9877	0,137	42
	T5 up	21	0,0436	0,0399	0,9793	0,145	45
	EGT	27	0,0437	0,0399	0,9855	0,179	43
ΩΣΗ	THRUST	14	0,0191	0,0182	0,9957	0,135	47

Πίνακας 5-4: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με μία έξοδο με μέθοδο εκπαίδευσης trainbfg και συνάρτηση μεταφοράς στρώματος εξόδου tansig.

Από την συγκριτική μελέτη των παραπάνω τεσσάρων διαγραμμάτων ως προς το σφάλμα εκπαίδευσης (RMSE TEST), ξεκινώντας από το καλύτερο, δηλαδή αυτό με το μικρότερο σφάλμα, παρατηρείται η ακόλουθη σειρά:

Αύξηση RMSE TEST		Μέθοδος Εκπαίδευσης	Συνάρτηση μεταφοράς Στρώματος εξόδου
↓	1.	Trainlm	Purelin
	2.	Trainlm	Tansig
	3.	Trainbfg	Purelin
	4.	Trainbfg	Tansig

Πίνακας 5-5: Σύγκριση των τεσσάρων μεθόδων εκπαίδευσης ως προς το σφάλμα εξόδου.

5.2.1. Συγκριτική μελέτη των συνδυασμών εκπαίδευσης

Όπως προκύπτει από τον παραπάνω πίνακα ο συνδυασμός μεθόδου εκπαίδευσης-συνάρτησης μεταφοράς στρώματος εξόδου με το καλύτερο σφάλμα έγινε με την μέθοδο Trainlm και συνάρτηση μεταφοράς στρώματος εξόδου την Purelin. Οπότε η σύγκριση των υπολοίπων συνδυασμών θα γίνει με βάση αυτή για την τελική επιλογή για κάθε μέγεθος. Ακολουθούν τα συγκριτικά διαγράμματα του καλύτερου συνδυασμού μεθόδου-συνάρτησης με τους υπόλοιπους τρεις.

(Trainlm - Purelin) vs. (Trainbfg - Tansig)							
Αισθητήρας		No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ	P3 left	22,73%	151,95%	207,02%	-0,30%	208,04%	142,86%
	P3 right	36,36%	147,50%	191,67%	-0,29%	209,41%	104,17%
	P5 down	-19,23%	109,23%	190,15%	-0,77%	-1,53%	13,16%
	P5 up	-8,70%	84,50%	146,93%	-0,92%	12,84%	13,89%
	Pt3 left	66,67%	151,39%	178,57%	-0,25%	295,43%	131,82%
	Pt3 right	36,36%	140,51%	179,66%	-0,26%	163,50%	85,19%
	Pt4	16,67%	185,71%	249,06%	-0,34%	138,30%	92,00%
	Pt5 down	-8,70%	176,92%	277,42%	-0,47%	4,23%	2,13%
	Pt5 up	66,67%	123,36%	171,25%	-0,33%	35,05%	-16,67%
ΘΕΡΜΟΚΡΑΣΙΕΣ	T3 left	23,53%	125,61%	153,03%	-0,30%	183,85%	114,29%
	T3 right	31,25%	126,67%	171,93%	-0,27%	102,02%	53,33%
	T4	-4,35%	64,81%	102,43%	-1,62%	87,77%	62,50%
	T5 down	-16,00%	77,84%	128,99%	-0,83%	77,40%	91,67%
	T5 left	-27,59%	55,03%	107,21%	-1,04%	32,28%	70,83%
	T5 right	-8,70%	93,40%	164,66%	-1,05%	-6,47%	-4,55%
	T5 up	-27,59%	108,61%	200,00%	-1,79%	-1,22%	28,57%
	EGT	-6,90%	101,60%	166,00%	-1,22%	72,70%	70,41%
ΩΣΗ	THRUST	-33,33%	289,80%	378,95%	-0,42%	-3,22%	0,00%
AVERAGE		7,73%	128,58%	186,94%	-0,69%	89,46%	58,64%
MAX DCREASE		-33,33%	-	-	-0,25%	-6,47%	-16,67%
MIN DCREASE		-4,35%	-	-	-1,79%	-1,22%	-4,55%
MAX INCREASE		66,67%	289,80%	378,95%	-	295,43%	142,86%
MIN INCREASE		16,67%	55,03%	102,43%	-	4,23%	0,00%

Πίνακας 5-6: Μεταβολή μεγεθών συνδυασμού Trainbfg–Tansig συναρτήσεως του συνδυασμού Trainlm–Purelin.

Από τον πίνακα 5-6 απορρίπτεται η εκπαίδευση με την μέθοδο Trainbfg και συνάρτηση μεταφοράς στρώματος εξόδου Tansig, καθώς η αύξηση τόσο στο σφάλμα δοκιμής όσο και στο σφάλμα εκπαίδευσης είναι πολύ μεγάλη, φτάνοντας μέχρι και

290% και 379% για την ώση, αντίστοιχα, σε σχέση με τον πρώτο συνδυασμό εκπαίδευσης.

(Trainlm - Purelin) vs. (Trainbfg - Purelin)							
Αισθητήρας		No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ	P3 left	-36,36%	41,56%	61,40%	-0,03%	80,51%	104,76%
	P3 right	-36,36%	50,00%	71,67%	-0,06%	59,27%	75,00%
	P5 down	-19,23%	49,23%	82,58%	-0,26%	-15,16%	2,63%
	P5 up	-8,70%	45,74%	74,30%	-0,42%	-3,74%	2,78%
	Pt3 left	16,67%	297,22%	314,29%	-0,44%	93,57%	68,18%
	Pt3 right	-36,36%	60,76%	88,14%	-0,06%	36,15%	51,85%
	Pt4	-22,22%	62,86%	83,02%	-0,06%	80,24%	64,00%
	Pt5 down	-8,70%	106,59%	133,87%	-0,15%	-11,65%	-8,51%
	Pt5 up	0,00%	75,70%	97,50%	-0,13%	-14,14%	-22,22%
ΘΕΡΜΟΚΡΑΣΙΕΣ	T3 left	-23,53%	57,32%	71,21%	-0,07%	110,31%	90,48%
	T3 right	-93,75%	50,67%	94,74%	-0,05%	36,03%	66,67%
	T4	-8,70%	22,59%	36,89%	-0,26%	38,22%	50,00%
	T5 down	-16,00%	39,18%	58,70%	-0,29%	42,37%	62,50%
	T5 left	-27,59%	15,41%	40,09%	-0,38%	3,27%	41,67%
	T5 right	-8,70%	49,75%	79,70%	-0,34%	-23,02%	-15,91%
	T5 up	-27,59%	44,02%	84,96%	-0,46%	-20,60%	8,57%
	EGT	-27,59%	31,94%	54,67%	-0,23%	10,13%	46,63%
ΩΣΗ	THRUST	-47,62%	112,24%	147,37%	-0,06%	-18,44%	-8,51%
AVERAGE		297,22%	314,29%	-0,03%	110,31%	104,76%	16,67%
MAX DCREASE		-93,75%	-	-	-0,03%	-23,02%	-22,22%
MIN DCREASE		-8,70%	-	-	-0,46%	-3,74%	-8,51%
MAX INCREASE		16,67%	297,22%	314,29%	-	110,31%	104,76%
MIN INCREASE		0,00%	15,41%	36,89%	-	3,27%	2,63%

Πίνακας 5-7: Μεταβολή μεγεθών συνδυασμού Trainbfg–Purelin συναρτήσεως του συνδυασμού Trainbfg–Purelin.

Για τον ίδιο λόγο απορρίπτεται και η εκπαίδευση με την μέθοδο Trainbfg και συνάρτηση μεταφοράς στρώματος εξόδου Purelin. Ο αισθητήρας T5 left παρουσιάζει σχετικά μικρή αύξηση στο σφάλμα δοκιμής. Μολοταύτα, η μεγάλη αύξηση του σφάλματος εκπαίδευσης (περίπου 40%), αποτελεί σημαντικό κριτήριο για την απόρριψη του συγκεκριμένου συνδυασμού, αν και υπάρχει βελτίωση στο πλήθος των κόμβων (-27,59%) και τα υπόλοιπα μεγέθη έχουν πολύ μικρή σχετική μεταβολή. Το ίδιο ακριβώς παρατηρείται και για τον αισθητήρα T4 και απορρίπτεται για τους ίδιους ακριβώς λόγους με τον T5 left.

Συνεπώς, παραμένει η σύγκριση μεταξύ χρήσης των συνδυασμών με μέθοδο εκπαίδευσης Trainlm και συναρτήσεις μεταφοράς Purelin και Tansig, η οποία δίνεται στον επόμενο πίνακα.

(Trainlm - Purelin) vs. (Trainlm - Tansig)							
Αισθητήρας		No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ	P3 left	-50,00%	18,18%	33,33%	-0,03%	69,20%	157,14%
	P3 right	-36,36%	17,50%	30,00%	-0,02%	12,23%	54,17%
	P5 down	-30,77%	30,77%	53,79%	-0,17%	-18,29%	13,16%
	P5 up	-13,04%	32,17%	50,84%	-0,38%	-7,74%	2,78%
	Pt3 left	-22,22%	15,28%	19,64%	-0,02%	39,93%	63,64%
	Pt3 right	-40,91%	21,52%	27,12%	-0,01%	20,33%	70,37%
	Pt4	-38,89%	18,57%	30,19%	-0,01%	40,12%	80,00%
	Pt5 down	-34,78%	56,04%	103,23%	-0,12%	14,32%	53,19%
	Pt5 up	-16,67%	38,32%	60,00%	-0,08%	-17,73%	-5,56%
ΘΕΡΜΟΚΡΑΣΙΕΣ	T3 left	-52,94%	13,41%	21,21%	-0,01%	29,18%	76,19%
	T3 right	-50,00%	14,67%	28,07%	-0,01%	-14,98%	16,67%
	T4	-65,22%	41,11%	65,05%	-0,60%	-7,52%	66,67%
	T5 down	-64,00%	55,15%	87,68%	-0,47%	-5,92%	75,00%
	T5 left	-65,52%	20,13%	48,20%	-0,62%	-21,58%	62,50%
	T5 right	-4,35%	77,16%	123,31%	-1,00%	-33,31%	-29,55%
	T5 up	-72,41%	45,93%	105,26%	-0,93%	-31,75%	54,29%
	EGT	-68,97%	68,39%	115,33%	-0,77%	-6,72%	102,11%
ΩΣΗ	THRUST	-47,62%	42,86%	63,16%	-0,03%	-4,72%	38,30%
AVERAGE		-4,35%	77,16%	123,31%	-0,01%	69,20%	157,14%
MAX DCREASE		-72,41%	-	-	-1,00%	-33,31%	-29,55%
MIN DCREASE		-4,35%	-	-	-0,01%	-4,72%	-5,56%
MAX INCREASE		-	77,16%	123,31%	-	69,20%	157,14%
MIN INCREASE		-	13,41%	19,64%	-	12,23%	2,78%

Πίνακας 5-8: Μεταβολή μεγεθών συνδυασμού Trainlm–Tansig συναρτήσεως του συνδυασμού Trainlm–Purelin.

Από τον παραπάνω πίνακα παρατηρείται πως ο συνδυασμός με μέθοδο εκπαίδευσης Trainlm και συνάρτηση μεταφοράς εξόδου Tansig παρουσιάζει πολύ καλά αποτελέσματα, αλλά ο συνδυασμός Trainlm και Purelin εξακολουθεί να είναι ο καλύτερος. Πιο συγκεκριμένα, για τους αισθητήρες P5down, P5up, Pt5down, Pt5up, T4, T5down, T5right, T5up, EGT και THRUST, ο συνδυασμός Trainlm και Tansig απορρίπτεται εξ αρχής, διότι παρουσιάζει σημαντική αύξηση στο σφάλμα δοκιμής. Οι υπόλοιποι αισθητήρες παρουσιάζουν μικρή αύξηση στο σφάλμα δοκιμής, αλλά σημαντική μείωση στο πλήθος των απαιτούμενων κόμβων, κάτι το οποίο είναι επιθυμητό. Όμως με τον συνδυασμό Trainlm και Tansig, για τους ίδιους αισθητήρες, παρατηρείται αύξηση στο σφάλμα εκπαίδευσης, στον χρόνο εκπαίδευσης και δοκιμής των δικτύων και στον αριθμός των επαναλήψεων, σε βαθμό που δεν μπορεί να αμεληθεί. Σημειώνεται πως το ποσοστό αύξησης 20% σε σφάλμα μπορεί να φαίνεται μικρό, όμως η διαφορά μεταξύ επιθυμητών εξόδων και εξόδων του δικτύου είναι αρκετά σημαντική. Αυτό θα αποδειχτεί στην συνέχεια, όπου θα δοθούν τα διαγράμματα επιθυμητών εξόδων και εξόδων δικτύου, συναρτήσεως της εισόδου, για έναν αισθητήρα, καθώς μεταβάλλεται το πλήθος των κόμβων και μικραίνει το σφάλμα, σε ποσοστά μεταβολής μικρότερα του 20%.

5.2.2. Τελική επιλογή νευρωνικών δικτύων μίας εξόδου

Από την παραπάνω συγκριτική μελέτη όλων των συνδυασμών μεθόδου εκπαίδευσης και συνάρτηση μεταφοράς εξόδου, προκύπτει πως η καλύτερη είναι η Trainlm – Purelin. Στους πίνακες που ακολουθούν δίνονται για κάθε αισθητήρα η μέθοδο εκπαίδευσης, η συνάρτηση μεταφοράς στο στρώμα εξόδου, το πλήθος των κόμβων στο κρυφό υπόστρωμα, το RMSE σφάλμα της δοκιμής και της εκπαίδευσης, η συσχέτιση, ο χρόνος εκπαίδευσης-δοκιμής και το πλήθος των επαναλήψεων που απαιτήθηκαν.

Τελική Επιλογή Νευρωνικών Δικτύων μίας Εξόδου						
Αισθητήρας		Μέθοδος Εκπαίδευσης	Συν. Μετ. Στρ. Εξόδου	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING
ΠΙΕΣΕΙΣ	P3 left	trainlm	purelin	22	0,0077	0,0057
	P3 right	trainlm	purelin	22	0,0080	0,0060
	P5 down	trainlm	purelin	26	0,0195	0,0132
	P5 up	trainlm	purelin	23	0,0258	0,0179
	Pt3 left	trainlm	purelin	18	0,0072	0,0056
	Pt3 right	trainlm	purelin	22	0,0079	0,0059
	Pt4	trainlm	purelin	18	0,0070	0,0053
	Pt5 down	trainlm	purelin	23	0,0091	0,0062
	Pt5 up	trainlm	purelin	18	0,0107	0,0080
ΘΕΡΜΟΚΡΑΣΙΕΣ	T3 left	trainlm	purelin	17	0,0082	0,0066
	T3 right	trainlm	purelin	16	0,0075	0,0057
	T4	trainlm	purelin	23	0,0270	0,0206
	T5 down	trainlm	purelin	25	0,0194	0,0138
	T5 left	trainlm	purelin	29	0,0318	0,0222
	T5 right	trainlm	purelin	23	0,0197	0,0133
	T5 up	trainlm	purelin	29	0,0209	0,0133
	EGT	trainlm	purelin	29	0,0217	0,0150
ΩΣΗ	THRUST	trainlm	purelin	21	0,0049	0,0038
AVERAGE				22	0,0147	0,0104
MAX				29	0,0318	0,0222
MIN				16	0,0049	0,0038

Πίνακας 5-9: Τελική επιλογή νευρωνικών δικτύων μίας εξόδου.

Τελική Επιλογή Νευρωνικών Δικτύων μίας Εξόδου						
Αισθητήρας		Μέθοδος Εκπαίδευσης	Συν. Μετ. Στρ. Εξόδου	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ	P3 left	trainlm	purelin	0,9998	0,067	21
	P3 right	trainlm	purelin	0,9998	0,074	24
	P5 down	trainlm	purelin	0,9984	0,144	38
	P5 up	trainlm	purelin	0,9970	0,118	36
	Pt3 left	trainlm	purelin	0,9998	0,059	22
	Pt3 right	trainlm	purelin	0,9998	0,084	27
	Pt4	trainlm	purelin	0,9998	0,066	25
	Pt5 down	trainlm	purelin	0,9996	0,154	47
	Pt5 up	trainlm	purelin	0,9996	0,148	54
ΘΕΡΜΟΚΡΑΣΙΕΣ	T3 left	trainlm	purelin	0,9997	0,051	21
	T3 right	trainlm	purelin	0,9998	0,074	30
	T4	trainlm	purelin	0,9967	0,079	24
	T5 down	trainlm	purelin	0,9975	0,085	24
	T5 left	trainlm	purelin	0,9939	0,101	24
	T5 right	trainlm	purelin	0,9982	0,147	44
	T5 up	trainlm	purelin	0,9971	0,147	35
	EGT	trainlm	purelin	0,9977	0,104	25
ΩΣΗ	THRUST	trainlm	purelin	0,9999	0,140	47
AVERAGE				0,9986	0,10225	32
MAX				0,9999	0,1536	54
MIN				0,9939	0,0514	21

Πίνακας 5-10: Τελική επιλογή νευρωνικών δικτύων μίας εξόδου.

Συνεπώς παρατηρείται:

- το πλήθος των κόμβων στο κρυφό υπόστρωμα, που απαιτήθηκε, κυμαίνεται μεταξύ των 22 κόμβων με μέγιστη τιμή τους 29 κόμβους για τον αισθητήρα EGT και ελάχιστο 16 κόμβους για τον αισθητήρα T3right.
- Το RMSE σφάλμα δοκιμής έχει μέση τιμή 0,0147, το οποίο είναι πάρα πολύ μικρό, με μέγιστη τιμή την 0,0318 για τον αισθητήρα T5left και μικρότερη την 0,0049 για τον αισθητήρα THRUST.
- Το RMSE σφάλμα εκπαίδευσης κυμαίνεται σε λίγο μικρότερες τιμές από το αντίστοιχο σφάλμα δοκιμής, καθώς παρουσιάζει μέση τιμή 0,0104, με μέγιστη την 0,0222 για τον αισθητήρα T5left και ελάχιστη την 0,0038 για τον αισθητήρα THRUST.
- Η συσχέτιση μεταξύ επιθυμητών εξόδων και εξόδων των νευρωνικών δικτύων βρίσκεται σε πολύ καλό επίπεδο, καθώς έχει μέση τιμή 0,9986, με μέγιστη 0,9999 στον αισθητήρα THRUST και ελάχιστη 0,9936 στον αισθητήρα T5left.

- Ο χρόνος εκπαίδευσης και δοκιμής του νευρωνικού δικτύου είναι αρκετά μικρός, αλλά όπως και αναφέρθηκε σε προηγούμενη ενότητα είναι ανάλογος των υπολογιστικών δυνατοτήτων και ο μόνος λόγος που αναφέρθηκε είναι η συγκριτική μελέτη των συνδυασμών μεθόδου εκπαίδευσης και συνάρτησης μεταφοράς στο στρώμα εξόδου, καθώς όλα τα αποτελέσματα διεξήχθησαν από τον ίδιο υπολογιστή.
- Το πλήθος των επαναλήψεων που απαιτήθηκαν είναι σημαντικά μικρός, καθώς κυμαίνεται στις 32 επαναλήψεις, με μέγιστη τιμή τις 54 για τον αισθητήρα Pt5up και ελάχιστη τις 21 για τον αισθητήρα T3left. Το μικρό πλήθος επαναλήψεων οφείλεται χάρης στην χρήση του κριτηρίου σταματημού validation, όπως αποδείχθηκε προηγουμένως.


Ακολουθούν τα αποτελέσματα εκπαίδευσης των νευρωνικών δικτύων, καθώς και τα διαγράμματα επιθυμητών εξόδων και εξόδων δικτύου, συναρτήσει της εισόδου, για κάθε αισθητήρα.

5.2.3. Διαγράμματα αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου

P3 left:

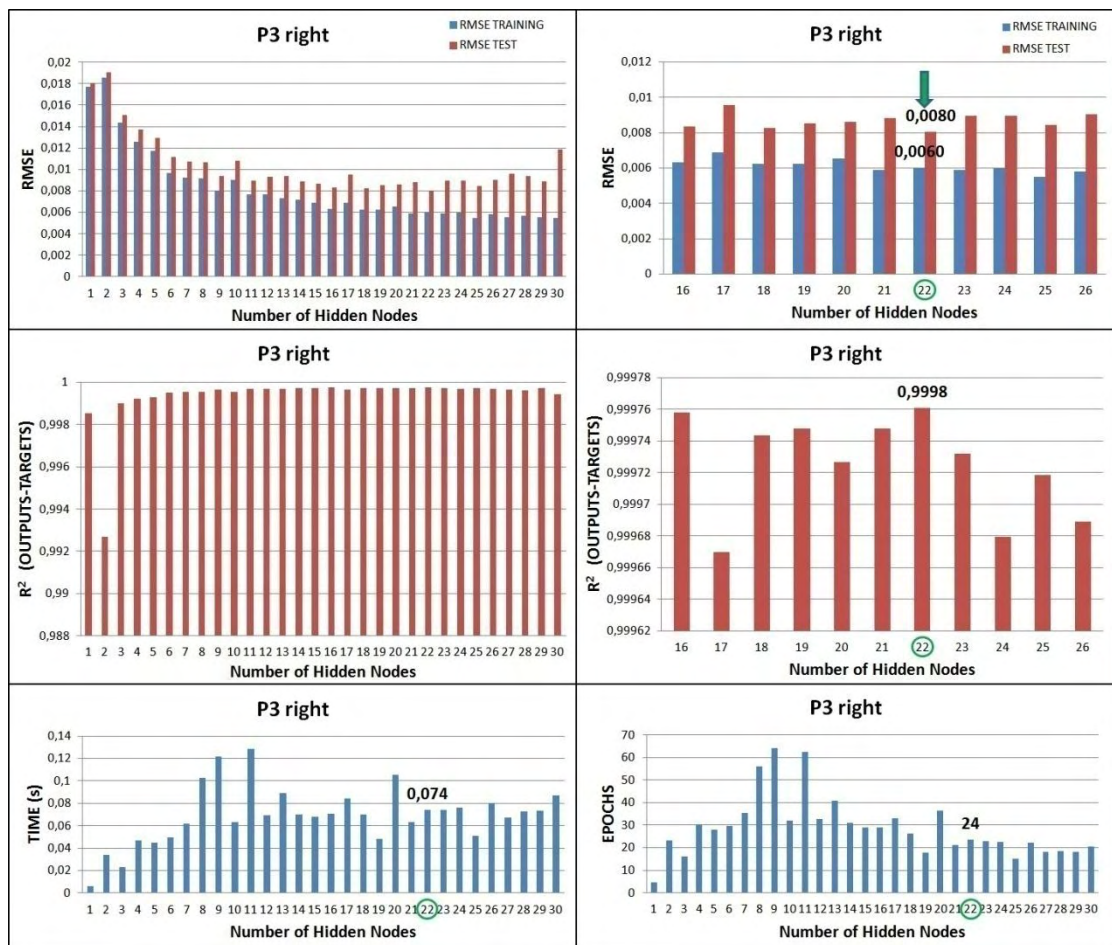


Σχήμα 5-2: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα P3 left.




Σχήμα 5-3: Διάγραμμα targets – outputs για τον αισθητήρα P3 left.

P3 right:

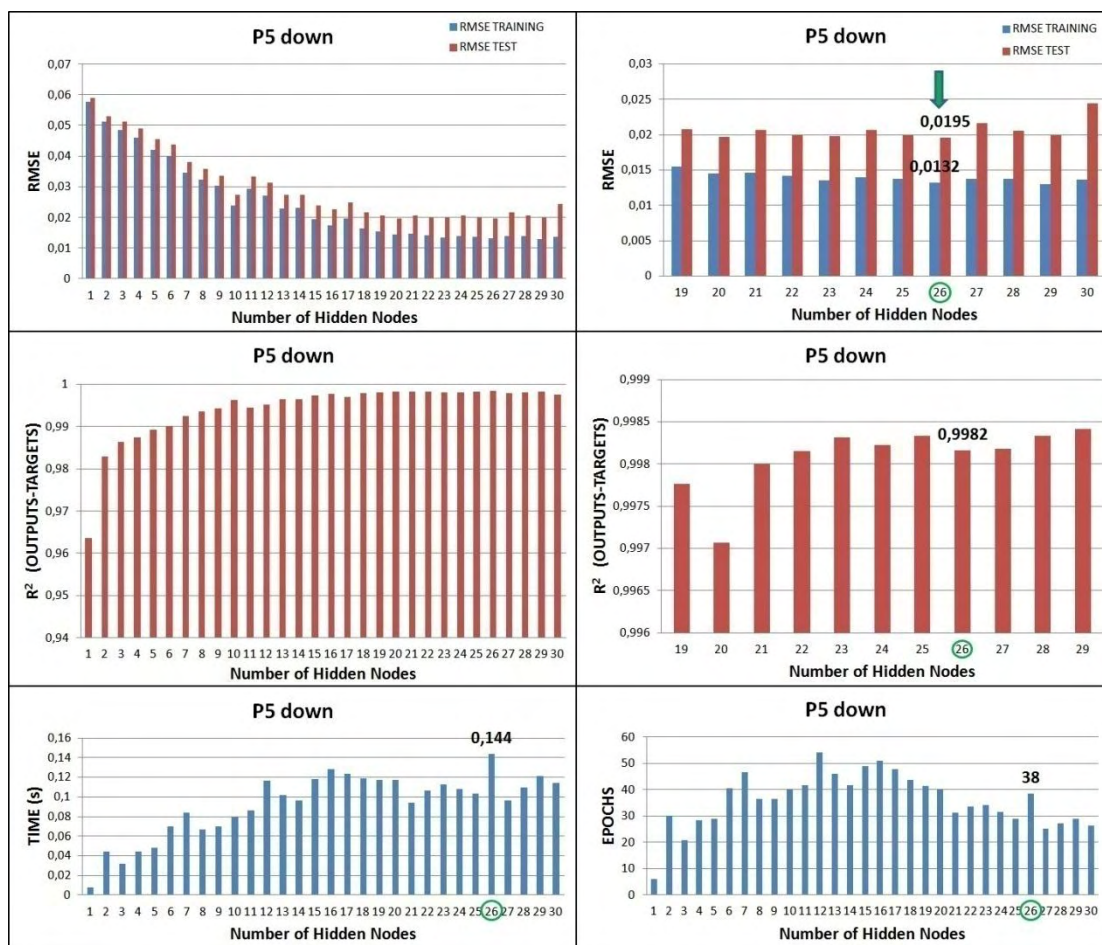


Σχήμα 5-4: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα P3 right.




Σχήμα 5-5: Διάγραμμα targets – outputs για τον αισθητήρα P3 right.

P5 down:

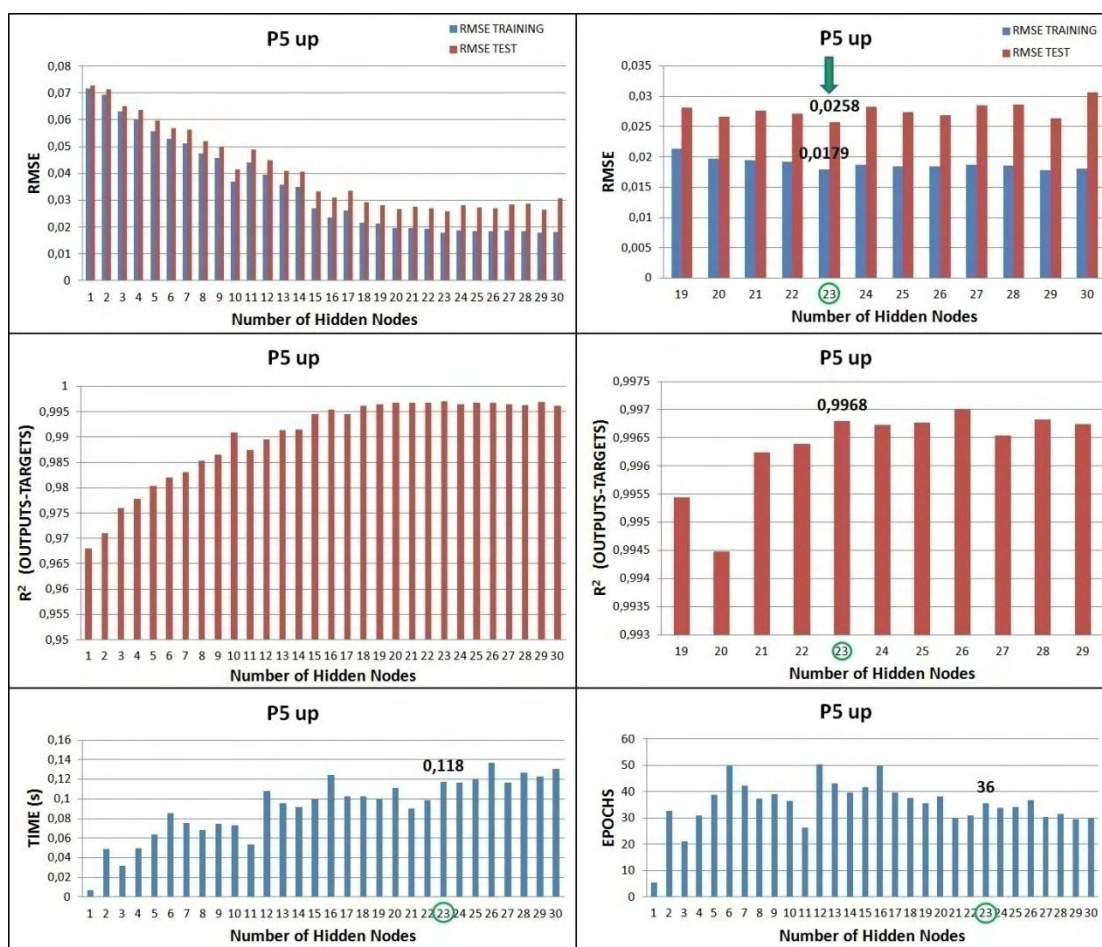


Σχήμα 5-6: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα P5 down.




Σχήμα 5-7: Διάγραμμα targets – outputs για τον αισθητήρα P5 down.

P5 up:

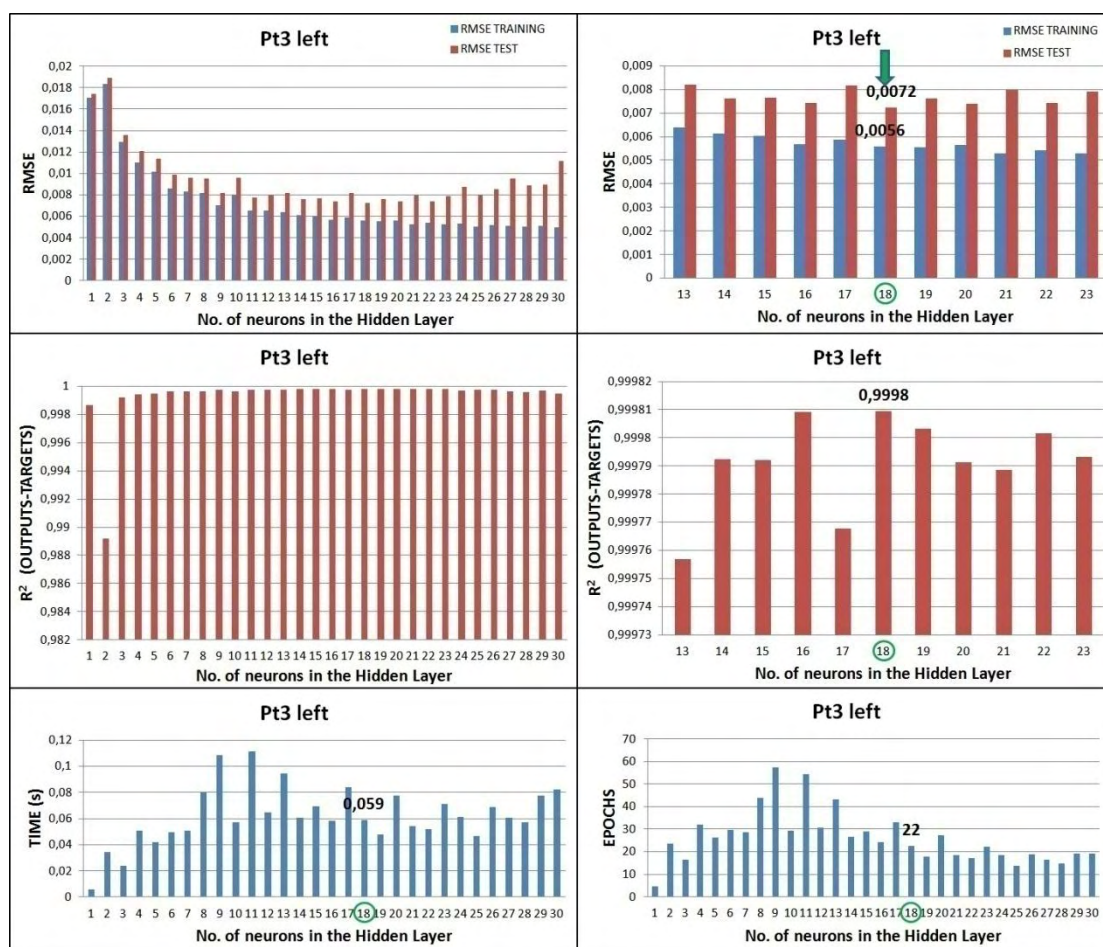


Σχήμα 5-8: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα P5 up.




Σχήμα 5-9: Διάγραμμα targets – outputs για τον αισθητήρα P5 up.

Pt3 left:

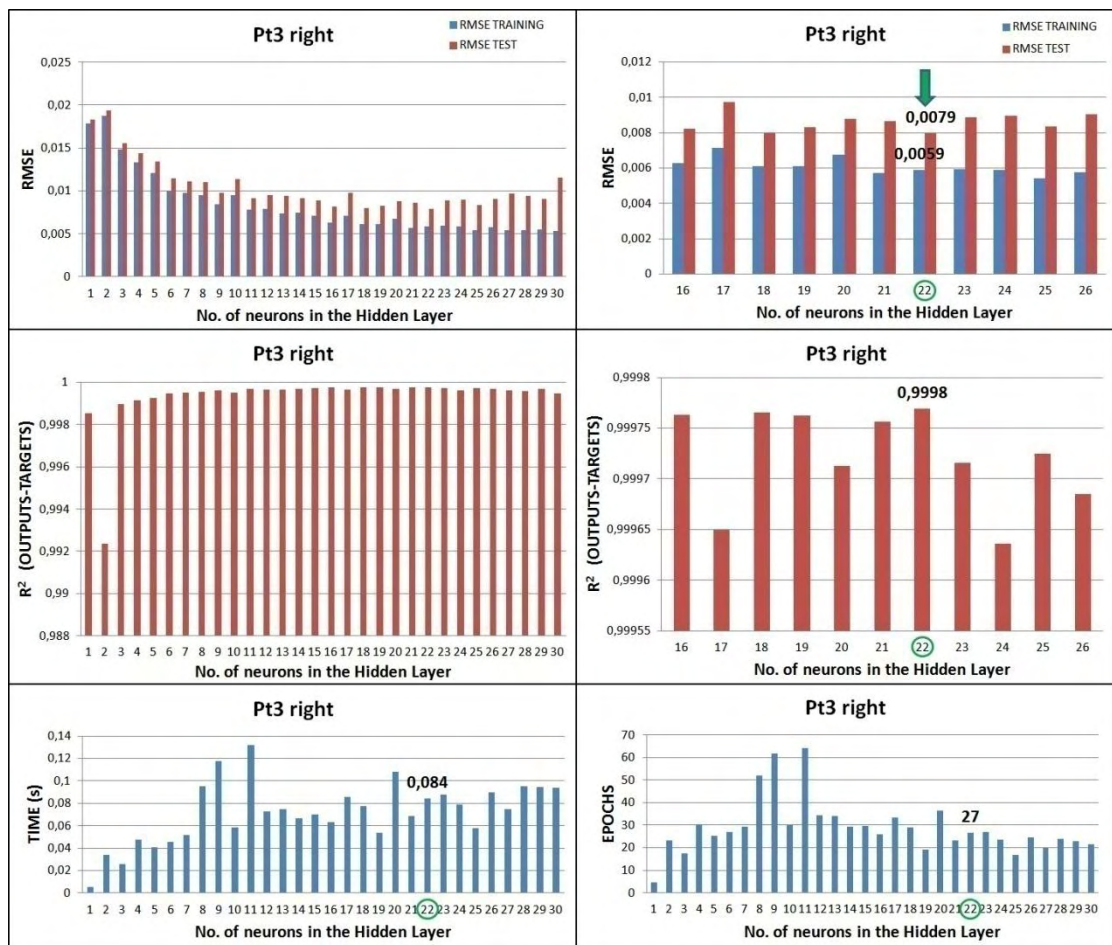


Σχήμα 5-10: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα Pt3 left.




Σχήμα 5-11: Διάγραμμα targets – outputs για τον αισθητήρα Pt3 left.

Pt3 right:

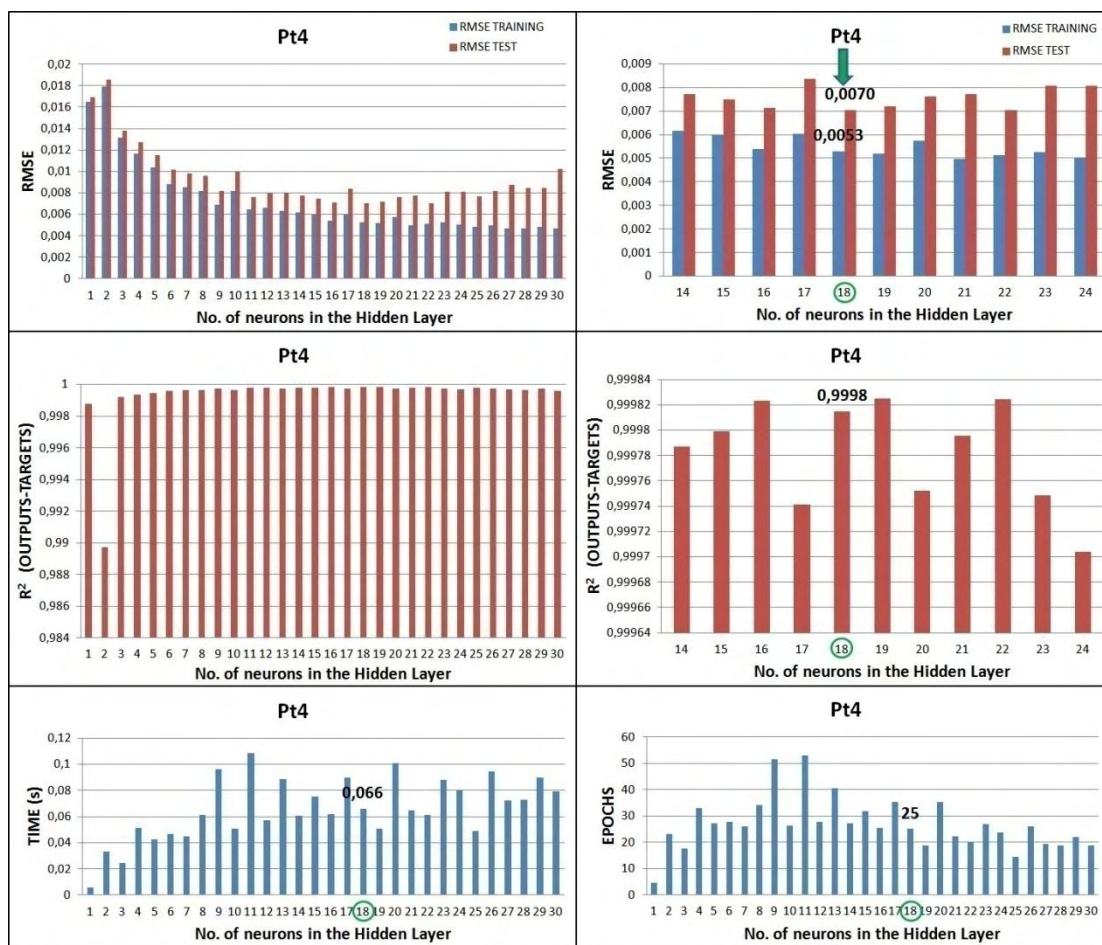


Σχήμα 5-12: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα Pt3 right.




Σχήμα 5-13: Διάγραμμα targets – outputs για τον αισθητήρα Pt3 right.

Pt4:

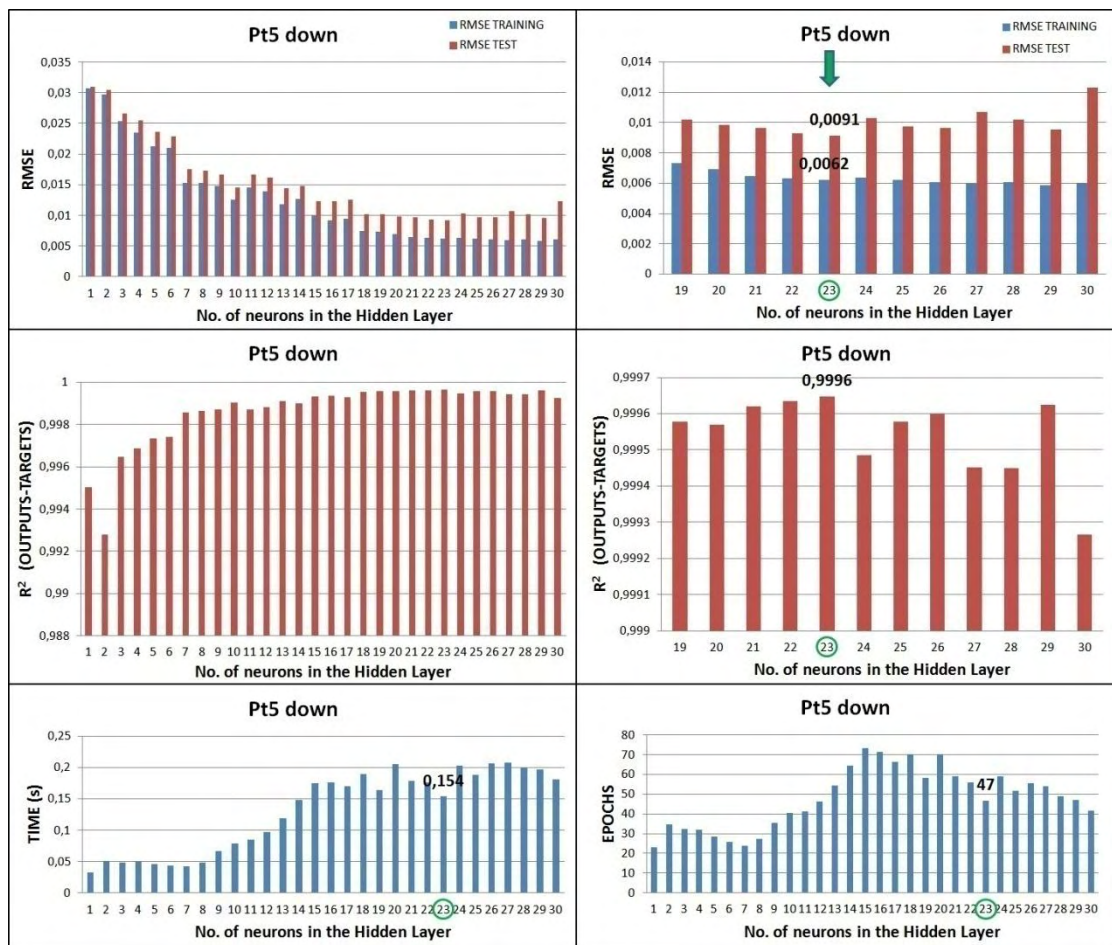


Σχήμα 5-14: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα Pt4.




Σχήμα 5-15: Διάγραμμα targets – outputs για τον αισθητήρα Pt4.

Pt5 down:

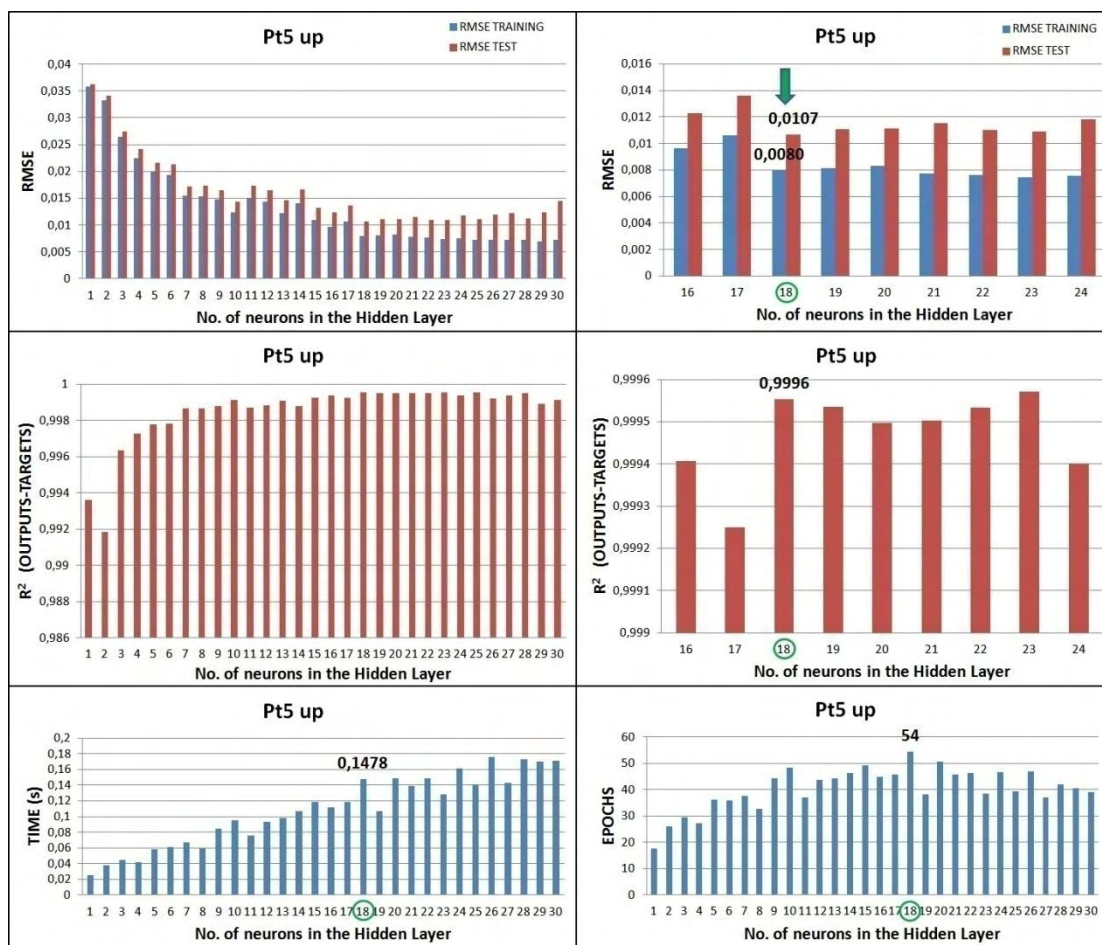


Σχήμα 5-16: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα Pt5 down.




Σχήμα 5-17: Διάγραμμα targets – outputs για τον αισθητήρα Pt5 down.

Pt5 up:

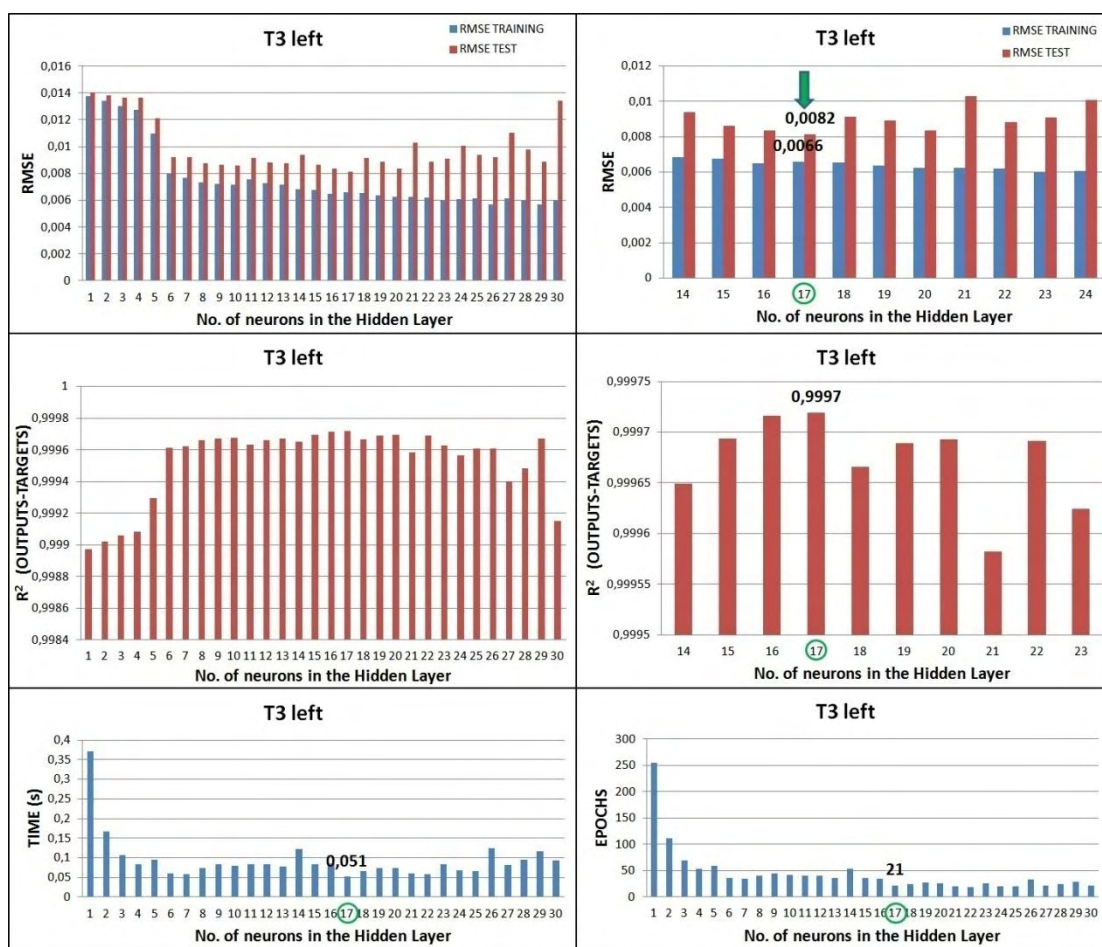


Σχήμα 5-18: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα Pt5 up.




Σχήμα 5-19: Διάγραμμα targets – outputs για τον αισθητήρα Pt5 up.

T3 left:

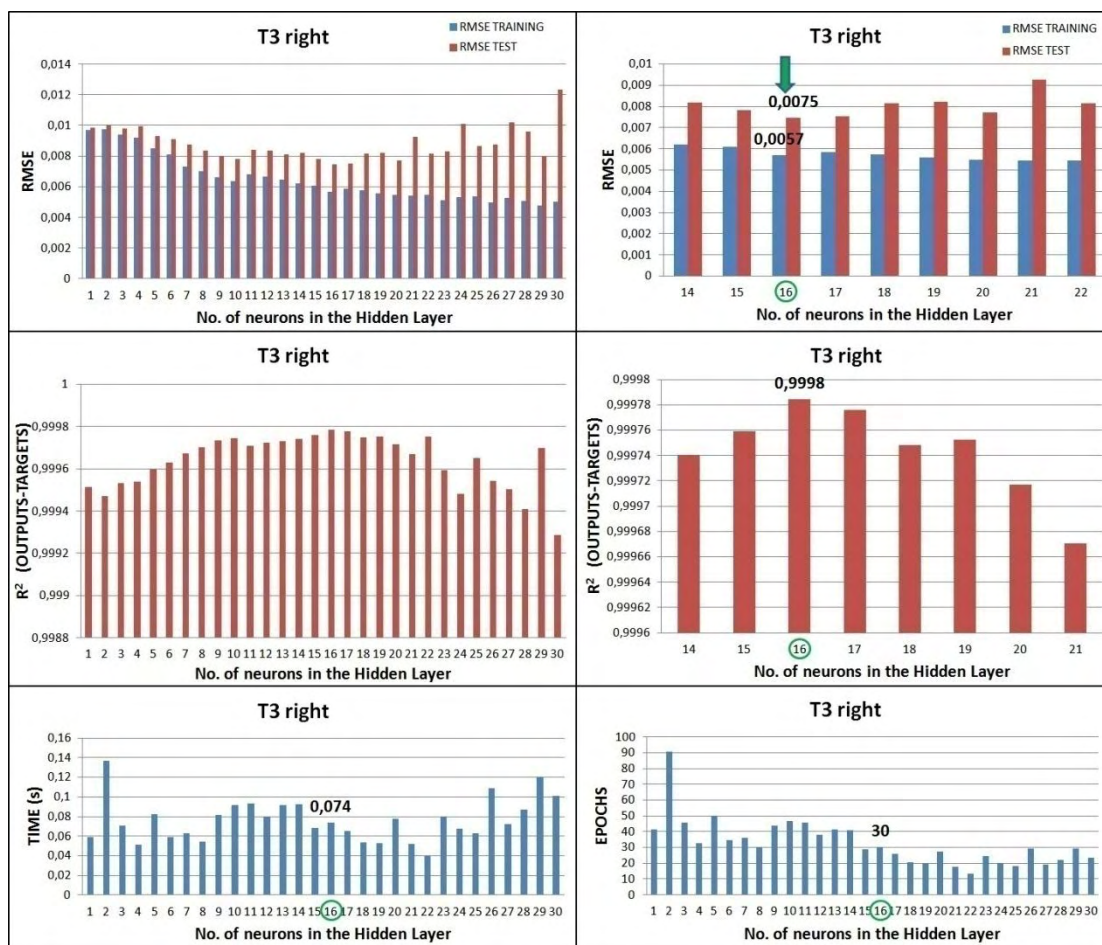


Σχήμα 5-20: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T3 left.




Σχήμα 5-21: Διάγραμμα targets – outputs για τον αισθητήρα T3 left.

T3 right:

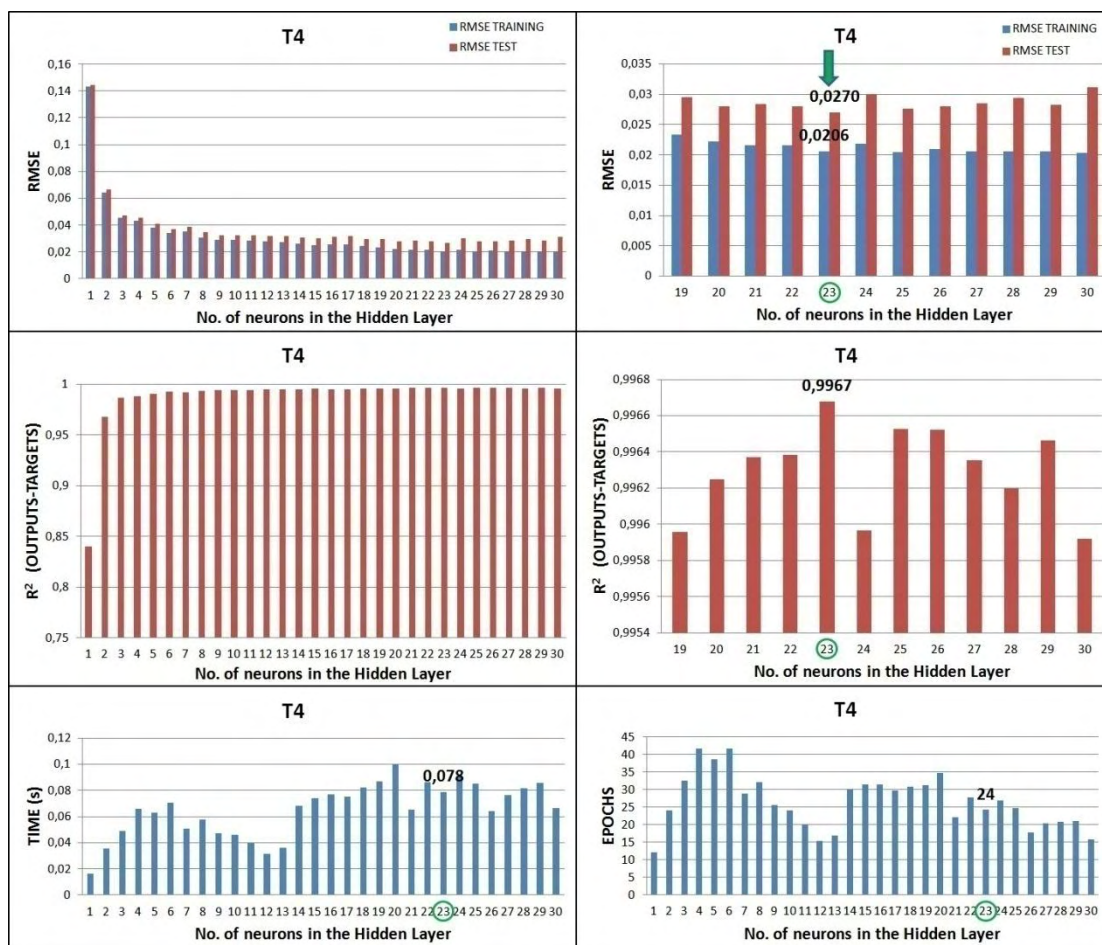


Σχήμα 5-22: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T3 right.




Σχήμα 5-23: Διάγραμμα targets – outputs για τον αισθητήρα T3 right.

T4:

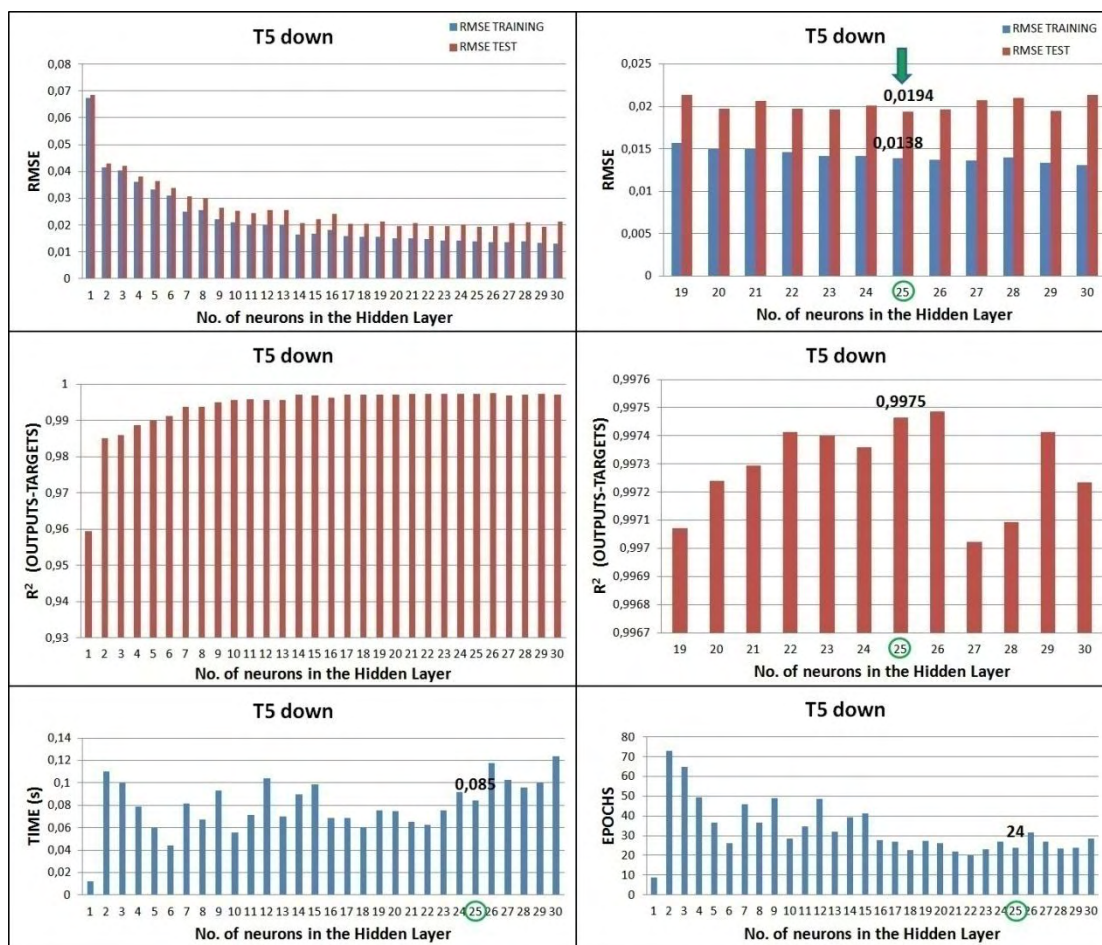


Σχήμα 5-24: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T4.




Σχήμα 5-25: Διάγραμμα targets – outputs για τον αισθητήρα T4.

T5 down:

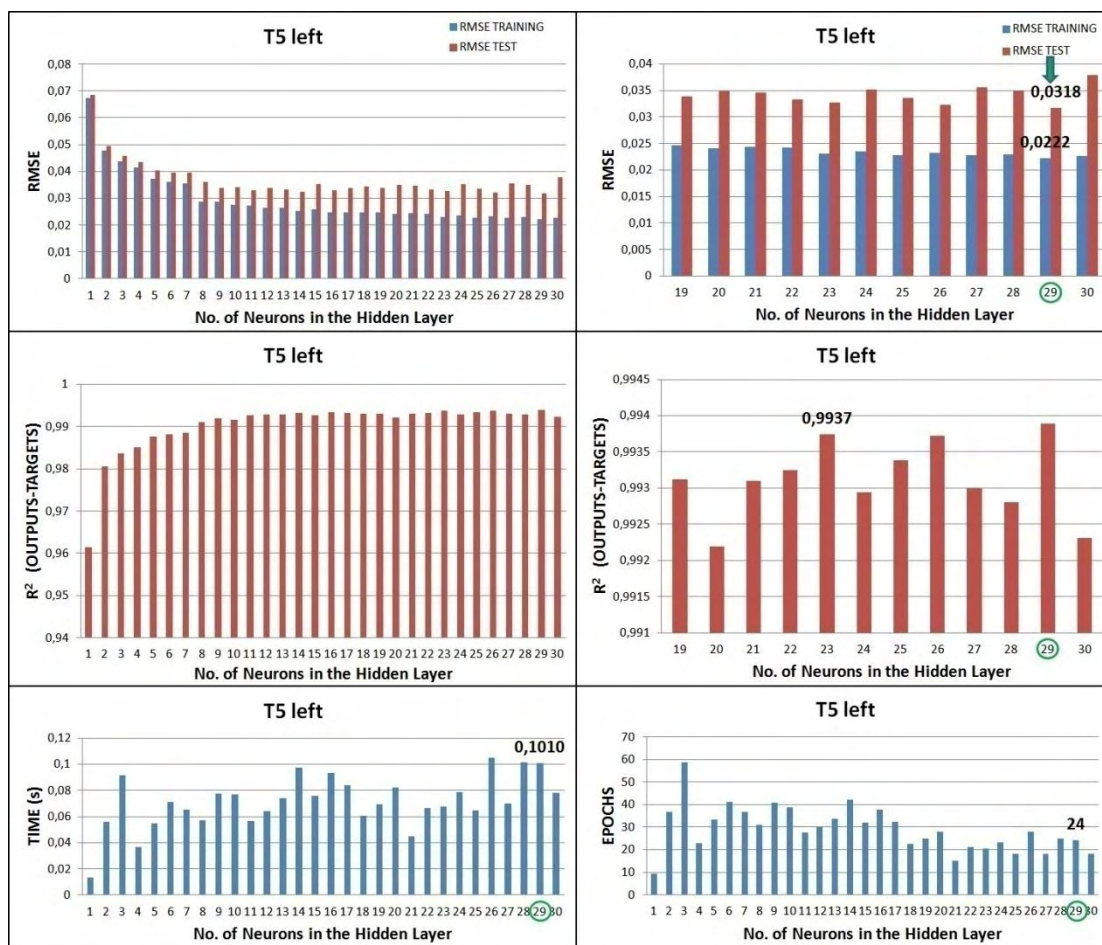


Σχήμα 5-26: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T5 down.




Σχήμα 5-27: Διάγραμμα targets – outputs για τον αισθητήρα T5 down.

T5 left:

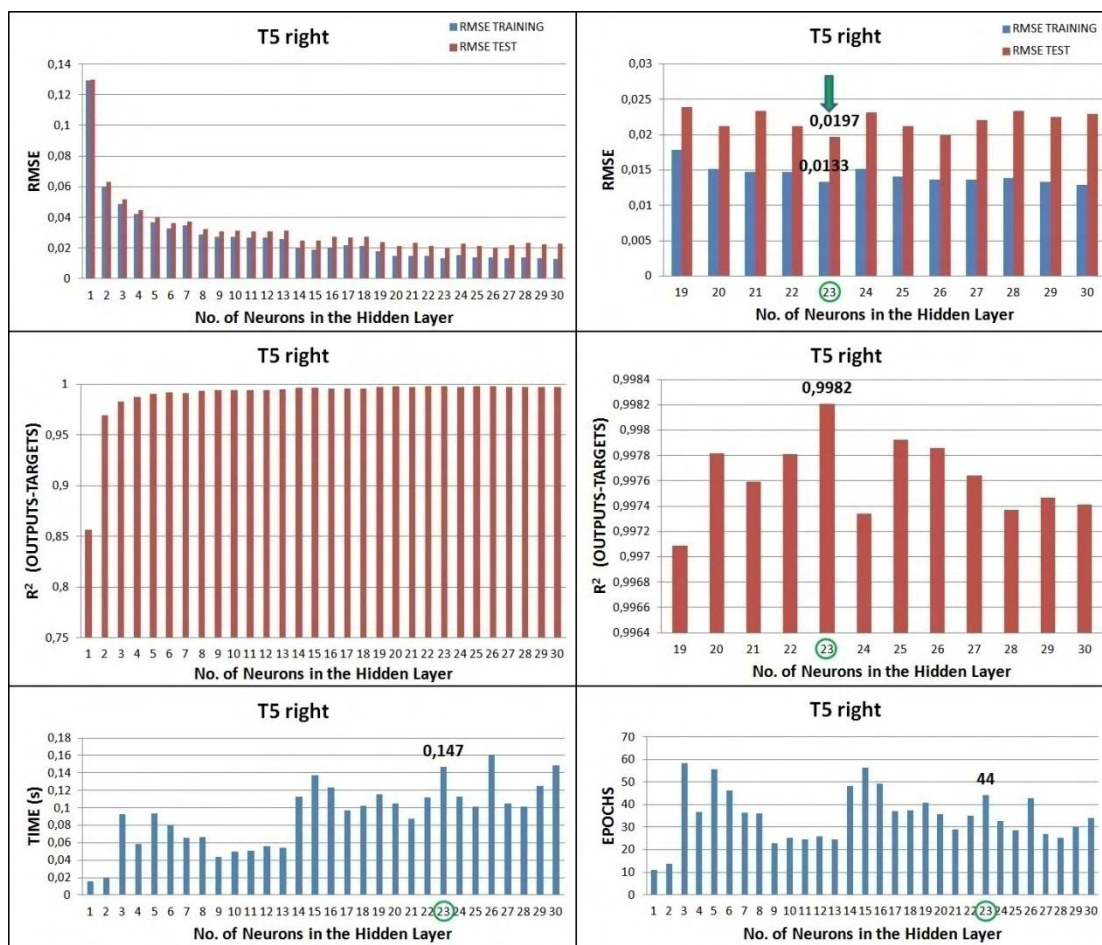


Σχήμα 5-28: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T5 left.




Σχήμα 5-29: Διάγραμμα targets – outputs για τον αισθητήρα T5 left.

T5 right:

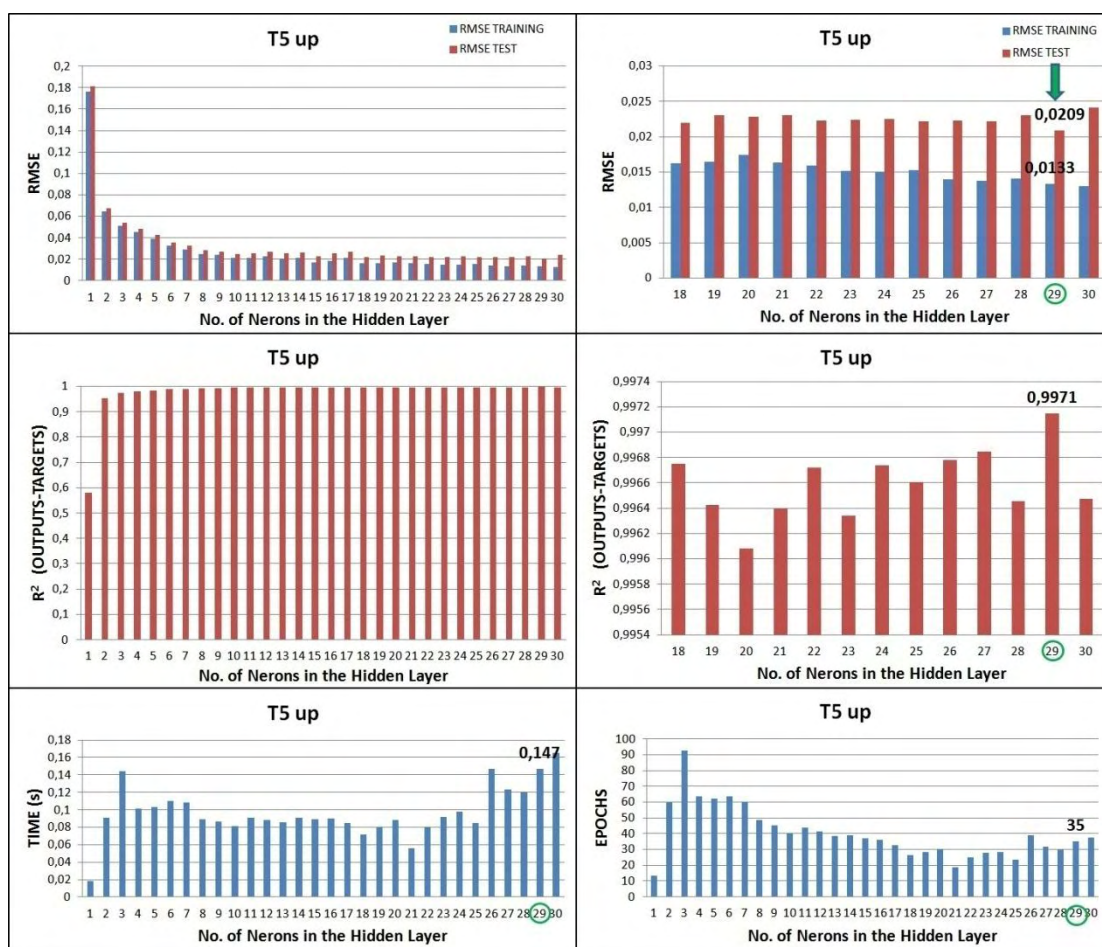


Σχήμα 5-30: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T5 right.




Σχήμα 5-31: Διάγραμμα targets – outputs για τον αισθητήρα T5 right.

T5 up:

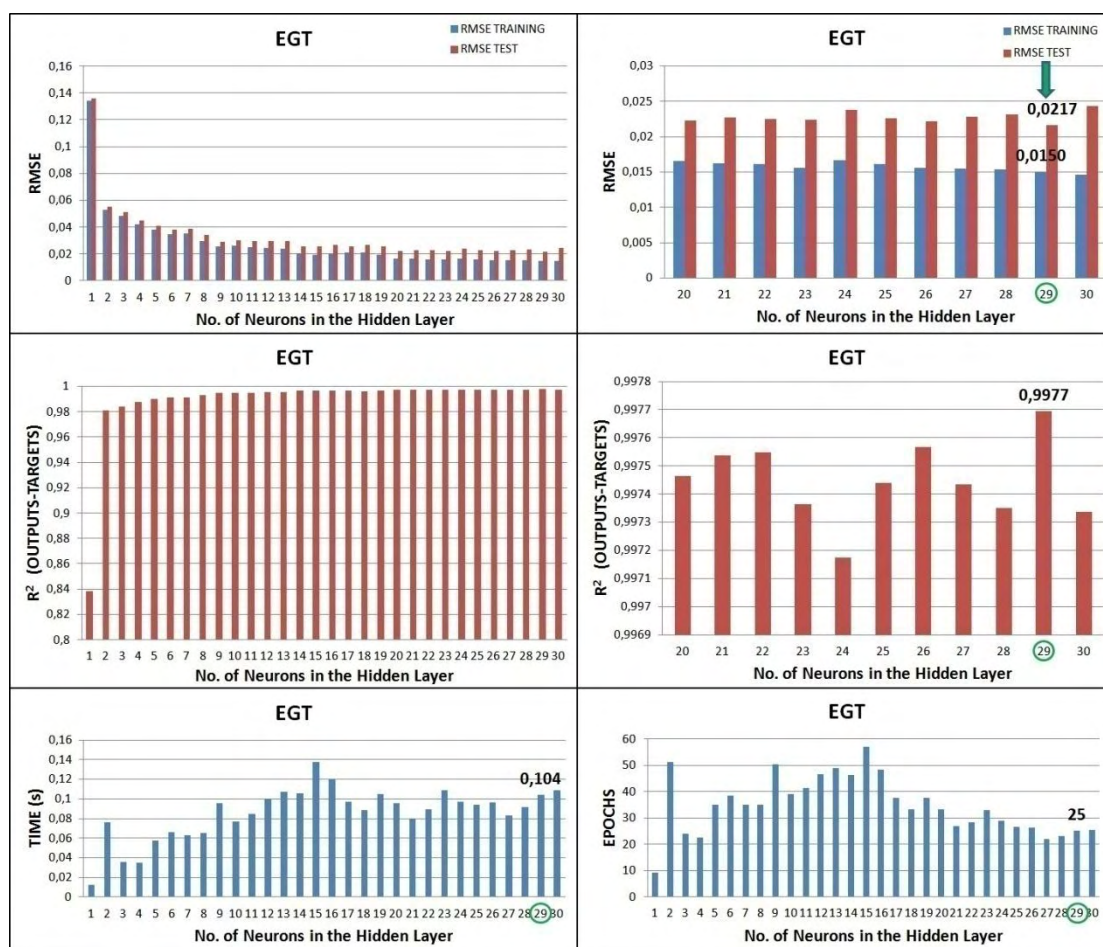


Σχήμα 5-32: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T5 up.




Σχήμα 5-33: Διάγραμμα targets – outputs για τον αισθητήρα T5 up.

EGT:

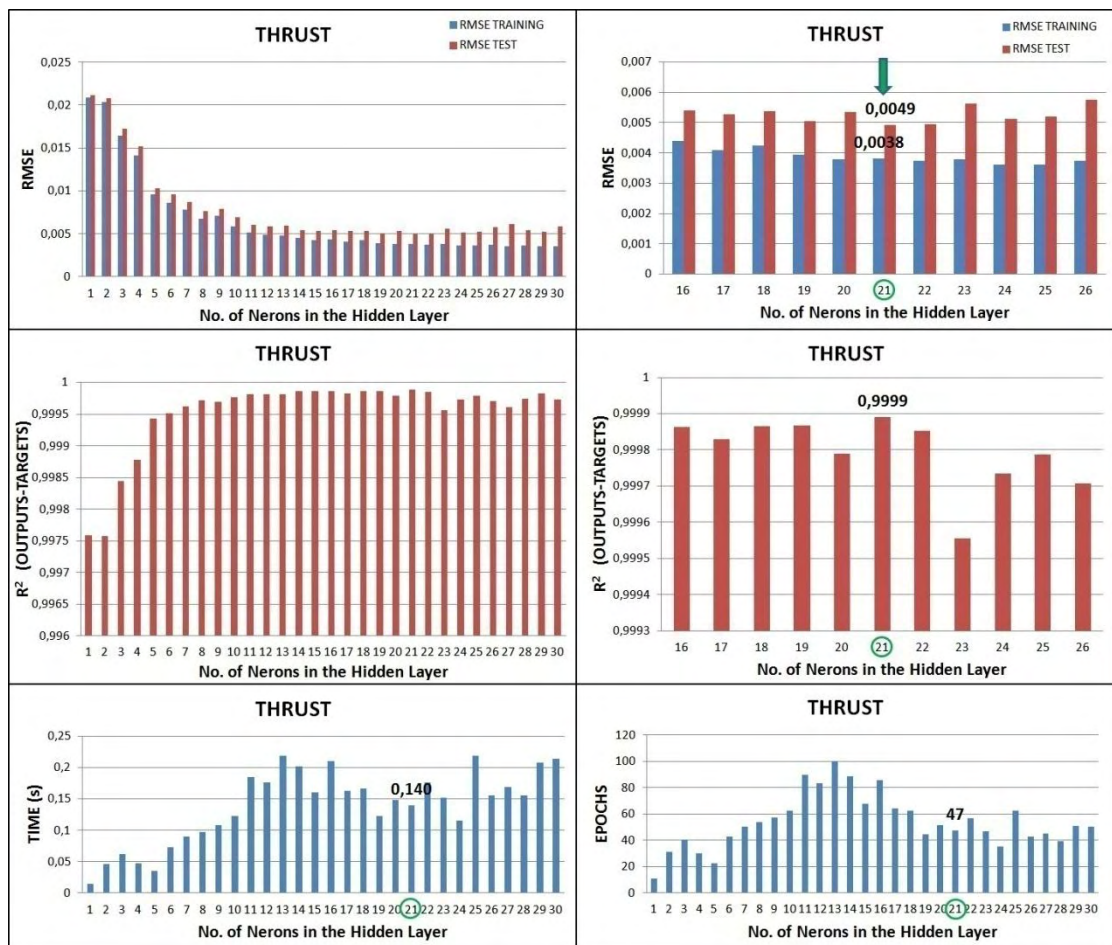


Σχήμα 5-34: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα EGT.




Σχήμα 5-35: Διάγραμμα targets – outputs για τον αισθητήρα EGT.

THRUST:



Σχήμα 5-36: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα THRUST.



Σχήμα 5-37: Διάγραμμα targets – outputs για τον αισθητήρα THRUST.

5.3. Αποτελέσματα για εκπαίδευση νευρωνικού δικτύου με πολλαπλές εξόδους

Ακολουθούν οι πίνακες αποτελεσμάτων για την εκπαίδευση και δοκιμή των νευρωνικών δικτύων με πολλαπλές εξόδους των συνόλων των αισθητήρων μέτρησης όμοιου μεγέθους, με την ακόλουθη σειρά:

- Trainlm-Purelin
- Trainlm-Tansig
- Trainbfg-Purelin
- Trainbfg-Tansig

Trainlm - Purelin						
ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ						
P3	16	0,0081	0,0062	0,9998	0,083	25
P5	23	0,0227	0,0160	0,9977	0,196	39
Pt3	18	0,0077	0,0059	0,9998	0,101	27
Pt5	21	0,0103	0,0069	0,9996	0,250	55
ΘΕΡΜΟΚΡΑΣΙΕΣ						
T3	17	0,0081	0,0063	0,9997	0,067	19
T5	23	0,0244	0,0175	0,9964	0,338	29

Πίνακας 5-11: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με εξόδους το πλήθος των όμοιων αισθητήρων με μέθοδο εκπαίδευσης trainlm και συνάρτηση μεταφοράς στρώματος εξόδου purelin.

Trainlm - Tansig						
ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ						
P3	8	0,0105	0,0090	0,9995	0,091	42
P5	19	0,0311	0,0260	0,9933	0,158	39
Pt3	9	0,0106	0,0091	0,9989	0,117	52
Pt5	13	0,0171	0,0148	0,9980	0,173	60
ΘΕΡΜΟΚΡΑΣΙΕΣ						
T3	8	0,0097	0,0083	0,9995	0,104	48
T5	14	0,0316	0,0271	0,9909	0,325	57

Πίνακας 5-12: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με εξόδους το πλήθος των όμοιων αισθητήρων με μέθοδο εκπαίδευσης trainlm και συνάρτηση μεταφοράς στρώματος εξόδου tansig.

Trainbfg - Purelin						
ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ						
P3	14	0,0121	0,0104	0,9993	0,187	62
P5	21	0,0355	0,0289	0,9938	0,199	53
Pt3	14	0,0117	0,0101	0,9994	0,189	62
Pt5	14	0,0200	0,0180	0,9980	0,181	59
ΘΕΡΜΟΚΡΑΣΙΕΣ						
T3	21	0,0104	0,0058	0,9988	0,267	65
T5	21	0,0331	0,0259	0,9929	0,355	69

Πίνακας 5-13: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με εξόδους το πλήθος των όμοιων αισθητήρων με μέθοδο εκπαίδευσης trainbfg και συνάρτηση μεταφοράς στρώματος εξόδου purelin.

Trainbfg - Tansig						
ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ						
P3	22	0,0369	0,0350	0,9908	0,375	81
P5	22	0,0736	0,0710	0,9740	0,318	67
Pt3	30	0,0352	0,0323	0,9906	0,469	87
Pt5	19	0,0464	0,0446	0,9858	0,312	74
ΘΕΡΜΟΚΡΑΣΙΕΣ						
T3	28	0,0350	0,0317	0,9897	0,439	86
T5	22	0,0646	0,0615	0,9635	0,712	112

Πίνακας 5-14: Πίνακας αποτελεσμάτων για νευρωνικό δίκτυο με εξόδους το πλήθος των όμοιων αισθητήρων με μέθοδο εκπαίδευσης trainbfg και συνάρτηση μεταφοράς στρώματος εξόδου tansig.

Από την συγκριτική μελέτη των παραπάνω τεσσάρων διαγραμμάτων ως προς το σφάλμα εκπαίδευσης (RMSE TEST), ξεκινώντας από το καλύτερο, δηλαδή αυτό με το μικρότερο σφάλμα, παρατηρείται η ακόλουθη σειρά:

Αύξηση RMSE TEST	Μέθοδος Εκπαίδευσης	Συνάρτηση μεταφοράς Στρώματος εξόδου
↓	1.	Trainlm
	2.	Trainlm
	3.	Trainbfg
	4.	Trainbfg

Πίνακας 5-15: Σύγκριση των τεσσάρων μεθόδων εκπαίδευσης ως προς το σφάλμα εξόδου.

5.3.1. Συγκριτική μελέτη των συνδυασμών εκπαίδευσης

Όπως προκύπτει από τον παραπάνω πίνακα ο συνδυασμός μεθόδου εκπαίδευσης-συνάρτησης μεταφοράς με το καλύτερο σφάλμα έγινε με την μέθοδο Trainlm και συνάρτηση μεταφοράς στρώματος εξόδου την Purelin. Οπότε η σύγκριση των υπολοίπων συνδυασμών θα γίνει με βάση αυτή για την τελική επιλογή για κάθε μέγεθος. Ακολουθούν τα συγκριτικά διαγράμματα του καλύτερου συνδυασμού μεθόδου-συνάρτησης με τους υπόλοιπους τρεις.

(Trainlm - Purelin) vs. (Trainbfg - Tansig)						
ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time	Epochs
ΠΙΕΣΕΙΣ						
P3	37,50%	355,56%	464,52%	-0,90%	350,84%	224,00%
P5	-4,35%	224,23%	343,75%	-2,38%	61,81%	71,79%
Pt3	66,67%	357,14%	447,46%	-0,92%	365,90%	222,22%
Pt5	-9,52%	350,49%	546,38%	-1,38%	24,79%	34,55%
ΘΕΡΜΟΚΡΑΣΙΕΣ						
T3	64,71%	332,10%	403,17%	-1,00%	557,87%	352,63%
T5	-4,35%	164,75%	251,43%	-3,30%	110,47%	286,21%
AVERAGE	25,11%	297,38%	409,45%	-1,65%	245,28%	198,57%
MAX	66,67%	357,14%	546,38%	-0,90%	557,87%	352,63%
MIN	-9,52%	164,75%	251,43%	-3,30%	24,79%	34,55%

Πίνακας 5-16: Μεταβολή μεγεθών συνδυασμού Trainbfg–Tansig συναρτήσεως του συνδυασμού Trainlm–Purelin.

Από τον πίνακα 5-15 απορρίπτεται η εκπαίδευση με την μέθοδο Trainbfg και συνάρτηση μεταφοράς εξόδου Tansig, καθώς η αύξηση στο σφάλμα δοκιμής, καθώς και στο σφάλμα εκπαίδευσης, είναι πολύ μεγάλη, φτάνοντας μέχρι και 357% για την Pt3 σε σχέση με τον πρώτο συνδυασμό εκπαίδευσης.

(Trainlm - Purelin) vs. (Trainbfg - Purelin)						
ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time	Epochs
ΠΙΕΣΕΙΣ						
P3	-12,50%	49,38%	67,74%	-0,05%	125,12%	148,00%
P5	-8,70%	56,39%	80,63%	-0,39%	1,22%	35,90%
Pt3	-22,22%	51,95%	71,19%	-0,04%	87,67%	129,63%
Pt5	-33,33%	94,17%	160,87%	-0,16%	-27,59%	7,27%
ΘΕΡΜΟΚΡΑΣΙΕΣ						
T3	23,53%	28,40%	-7,94%	-0,09%	299,70%	242,11%
T5	-8,70%	35,66%	48,00%	-0,35%	5,00%	137,93%
AVERAGE	-10,32%	52,66%	70,08%	-0,18%	81,85%	116,81%
MAX	23,53%	94,17%	160,87%	-0,04%	299,70%	242,11%
MIN	-33,33%	28,40%	-7,94%	-0,39%	-27,59%	7,27%

Πίνακας 5-17: Μεταβολή μεγεθών συνδυασμού Trainbfg–Purelin συναρτήσεως του συνδυασμού Trainlm–Purelin.

Για τον ίδιο λόγο απορρίπτεται και η εκπαίδευση με την μέθοδο Trainbfg και συνάρτηση μεταφοράς εξόδου Purelin. Μόνο το μέγεθος T3 έχει σχετικά μικρή αύξηση στο σφάλμα δοκιμής. Μολοταύτα, η μικρή μείωση του σφάλματος εκπαίδευσης, η αύξηση του πλήθους των κόμβων (από 17 σε 21), καθώς και η ραγδαία ποσοστιαία αύξηση του χρόνου και των αριθμών επαναλήψεων, 299,70% και 242,11% αντίστοιχα, αποτελούν σημαντικά κριτήρια για την απόρριψη του συγκεκριμένου συνδυασμού.

Συνεπώς, παραμένει η σύγκριση μεταξύ χρήσης των συνδυασμών με μέθοδο εκπαίδευσης Trainlm και συναρτήσεις μεταφοράς Purelin και Tansig, η οποία δίνεται στον επόμενο πίνακα.

(Trainlm - Purelin) vs. (Trainlm - Tansig)						
ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R²	Time	Epochs
ΠΙΕΣΕΙΣ						
P3	-50,00%	29,63%	45,16%	-0,03%	9,01%	68,00%
P5	-17,39%	37,00%	62,50%	-0,44%	-19,50%	0,00%
Pt3	-50,00%	37,66%	54,24%	-0,09%	16,20%	92,59%
Pt5	-38,10%	66,02%	114,49%	-0,16%	-30,72%	9,09%
ΘΕΡΜΟΚΡΑΣΙΕΣ						
T3	-52,94%	19,75%	31,75%	-0,02%	55,32%	152,63%
T5	-39,13%	29,51%	54,86%	-0,55%	-3,99%	96,55%
AVERAGE	-41,26%	36,60%	60,50%	-0,22%	4,39%	69,81%
MAX	-17,39%	66,02%	114,49%	-0,02%	55,32%	152,63%
MIN	-52,94%	19,75%	31,75%	-0,55%	-30,72%	0,00%

Πίνακας 5-18: Μεταβολή μεγεθών συνδυασμού Trainlm–Tansig συναρτήσει του συνδυασμού Trainlm–Purelin.

5.3.2. Τελική επιλογή νευρωνικών δικτύων πολλαπλών εξόδων

Από την παραπάνω συγκριτική μελέτη όλων των συνδυασμών μεθόδου εκπαίδευσης και συνάρτηση μεταφοράς εξόδου, προκύπτει πως η καλύτερη είναι η Trainlm – Purelin. Στους πίνακες που ακολουθούν δίνονται για κάθε αισθητήρα η μέθοδο εκπαίδευσης, η συνάρτηση μεταφοράς στο στρώμα εξόδου, το πλήθος των κόμβων στο κρυφό υπόστρωμα, το RMSE σφάλμα της δοκιμής και της εκπαίδευσης, η συσχέτιση, ο χρόνος εκπαίδευσης-δοκιμής και το πλήθος των επαναλήψεων που απαιτήθηκαν.

ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ		Μέθοδος Εκπαίδευσης	Συν. Μετ. Στρ. Εξόδου	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING
ΠΙΕΣΕΙΣ	P3	Levenberg-Marquardt	Purelin	16	0,0081	0,0062
	P5	Levenberg-Marquardt	Purelin	23	0,0227	0,0160
	Pt3	Levenberg-Marquardt	Purelin	18	0,0077	0,0059
	Pt5	Levenberg-Marquardt	Purelin	21	0,0103	0,0069
ΘΕΡΜΟΚΡΑΣΙΕΣ	T3	Levenberg-Marquardt	Purelin	17	0,0081	0,0063
	T5	Levenberg-Marquardt	Purelin	23	0,0244	0,0175
AVERAGE				20	0,0136	0,0098
MAX				23	0,0244	0,0175
MIN				16	0,0077	0,0059

Πίνακας 5-19: Τελική επιλογή νευρωνικών δικτύων πολλαπλής εξόδου.

ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ		Μέθοδος Εκπαίδευσης	Συν. Μετ. Στρ. Εξόδου	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ	P3	Levenberg-Marquardt	Purelin	0,9998	0,083	25
	P5	Levenberg-Marquardt	Purelin	0,9977	0,196	39
	Pt3	Levenberg-Marquardt	Purelin	0,9998	0,101	27
	Pt5	Levenberg-Marquardt	Purelin	0,9996	0,250	55
ΘΕΡΜΟΚΡΑΣΙΕΣ	T3	Trainlm	Purelin	0,9997	0,067	19
	T5	Trainlm	Purelin	0,9964	0,338	29
AVERAGE				0,9988	0,172	32
MAX				0,9998	0,338	55
MIN				0,9964	0,067	19

Πίνακας 5-20: Τελική επιλογή νευρωνικών δικτύων πολλαπλής εξόδου.

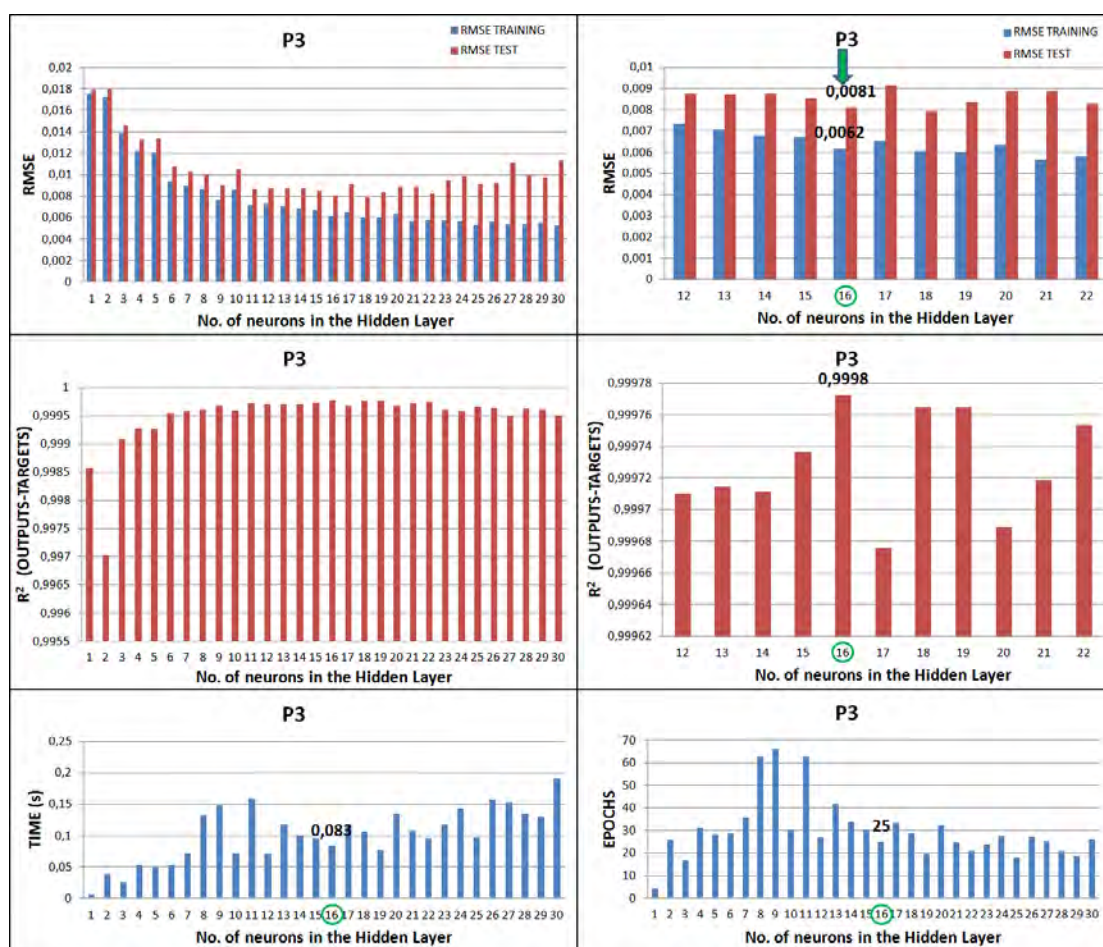
Συνεπώς παρατηρείται:

- το πλήθος των κόμβων στο κρυφό υπόστρωμα, που απαιτήθηκε, κυμαίνεται μεταξύ των 20 κόμβων με μέγιστη τιμή τους 23 κόμβους για τον αισθητήρα T5 και ελάχιστο 16 κόμβους για τον αισθητήρα P3.
- Το RMSE σφάλμα δοκιμής έχει μέση τιμή 0,0136, το οποίο είναι πάρα πολύ μικρό, με μέγιστη τιμή την 0,0244 για τον αισθητήρα T5 και μικρότερη την 0,0077 για τον αισθητήρα Pt3.
- Το RMSE σφάλμα εκπαίδευσης κυμαίνεται σε λίγο μικρότερες τιμές από το αντίστοιχο σφάλμα δοκιμής, καθώς παρουσιάζει μέση τιμή 0,0098, με μέγιστη την 0,0175 για τον αισθητήρα T5 και ελάχιστη την 0,0059 για τον αισθητήρα Pt3.
- Η συσχέτιση μεταξύ επιθυμητών εξόδων και εξόδων των νευρωνικών δικτύων βρίσκεται σε πολύ καλό επίπεδο, καθώς έχει μέση τιμή 0,9988, με μέγιστη 0,9998 στον αισθητήρα P3 και ελάχιστη 0,9964 στον αισθητήρα T5.
- Ο χρόνος εκπαίδευσης και δοκιμής του νευρωνικού δικτύου είναι αρκετά μικρός, αλλά όπως και αναφέρθηκε σε προηγούμενη ενότητα είναι ανάλογος των υπολογιστικών δυνατοτήτων και ο μόνος λόγος που αναφέρθηκε είναι η συγκριτική μελέτη των συνδυασμών μεθόδου εκπαίδευσης και συνάρτησης μεταφοράς στο στρώμα εξόδου, καθώς όλα τα αποτελέσματα διεξήχθησαν από τον ίδιο υπολογιστή.
- Το πλήθος των επαναλήψεων που απαιτήθηκαν είναι σημαντικά μικρός, καθώς κυμαίνεται στις 32 επαναλήψεις, με μέγιστη τιμή τις 55 για τον αισθητήρα Pt5up και ελάχιστη τις 19 για τον αισθητήρα T3. Το μικρό πλήθος επαναλήψεων οφείλεται χάρης στην χρήση του κριτηρίου σταματημού validation, όπως αποδείχθηκε προηγουμένως.


Ακολουθούν τα αποτελέσματα εκπαίδευσης των νευρωνικών δικτύων, καθώς και τα διαγράμματα επιθυμητών εξόδων και εξόδων δικτύου, συναρτήσει της εισόδου, για κάθε αισθητήρα.

5.3.3. Διαγράμματα αποτελεσμάτων νευρωνικών δικτύων πολλαπλών εξόδων

P3:

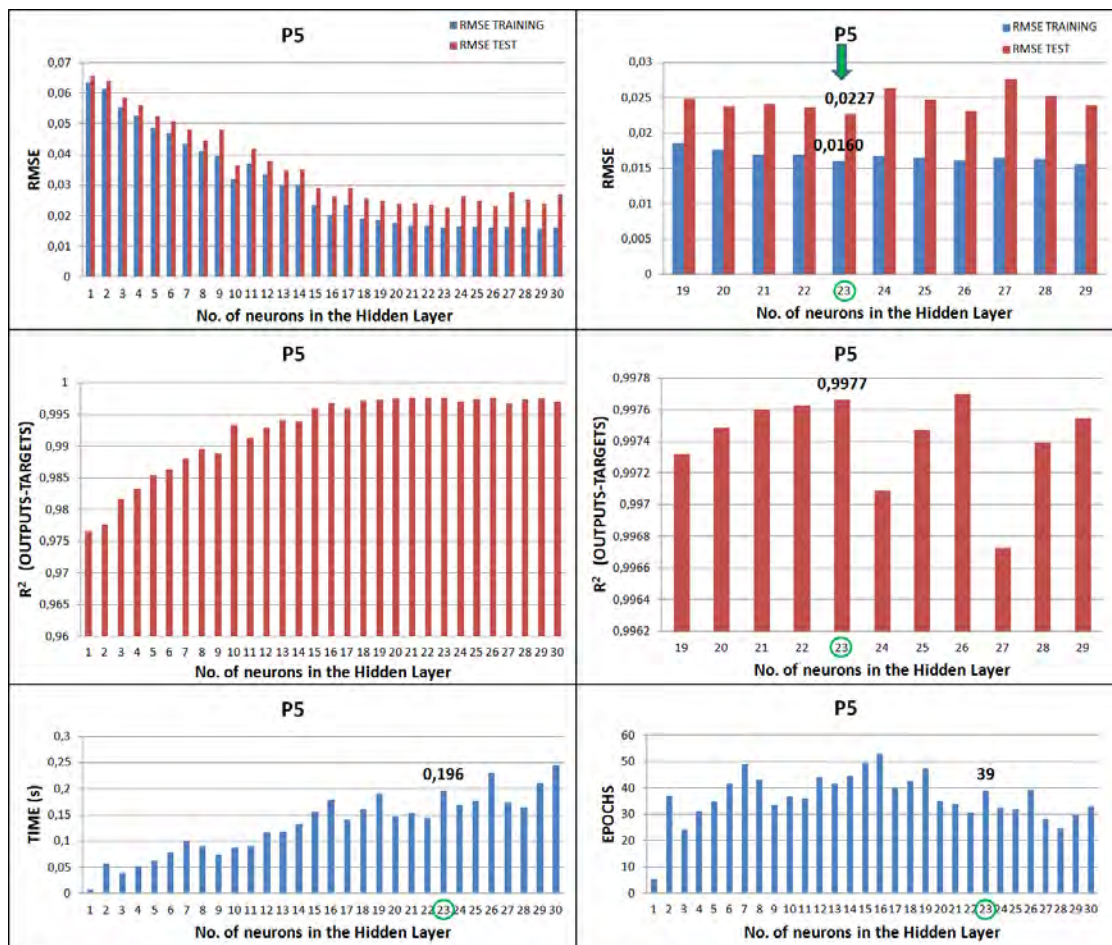


Σχήμα 5-38: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες P3.




Σχήμα 5-39: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες P3.

P5:

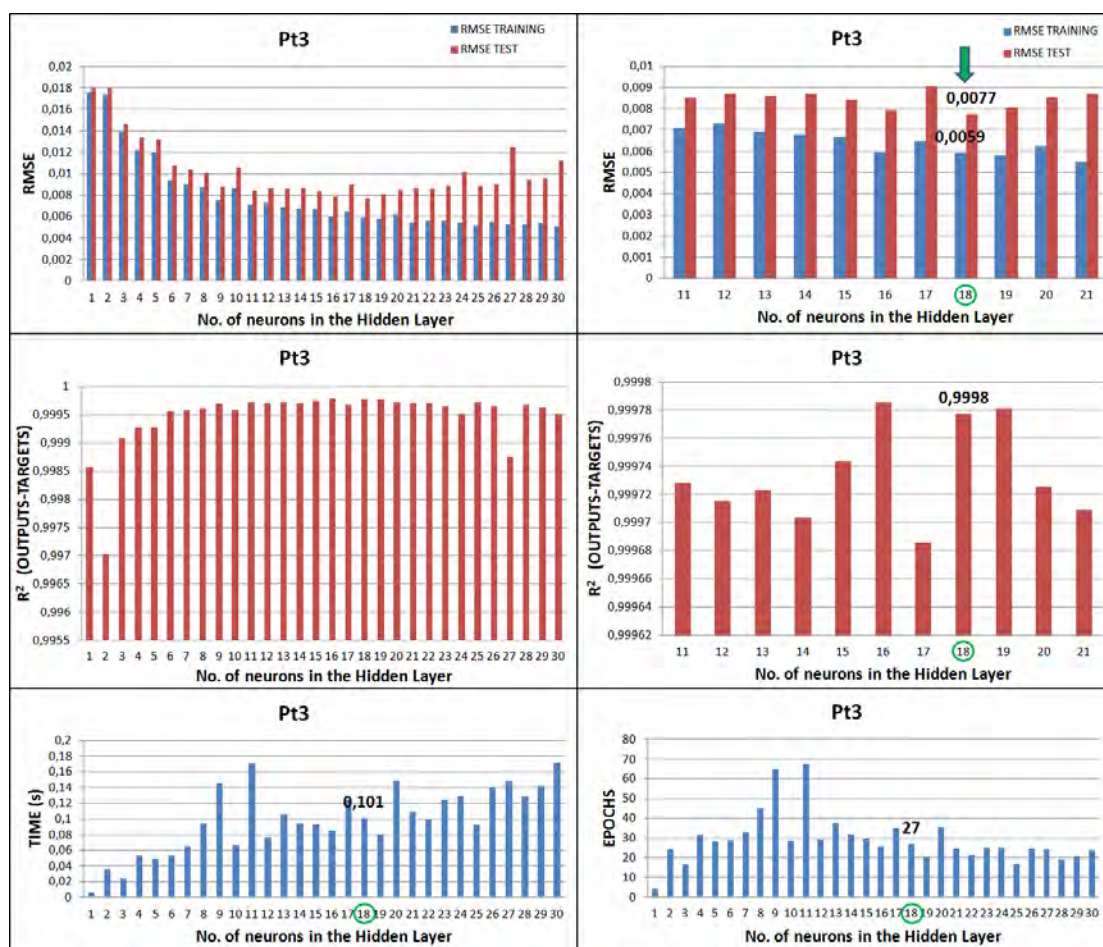


Σχήμα 5-40: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες P5.




Σχήμα 5-41: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες P5.

Pt3:



Σχήμα 5-42: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες Pt3.




Σχήμα 5-43: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες Pt3.

Pt5:



Σχήμα 5-44: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες Pt5.




Σχήμα 5-45: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες Pt5.

T3:

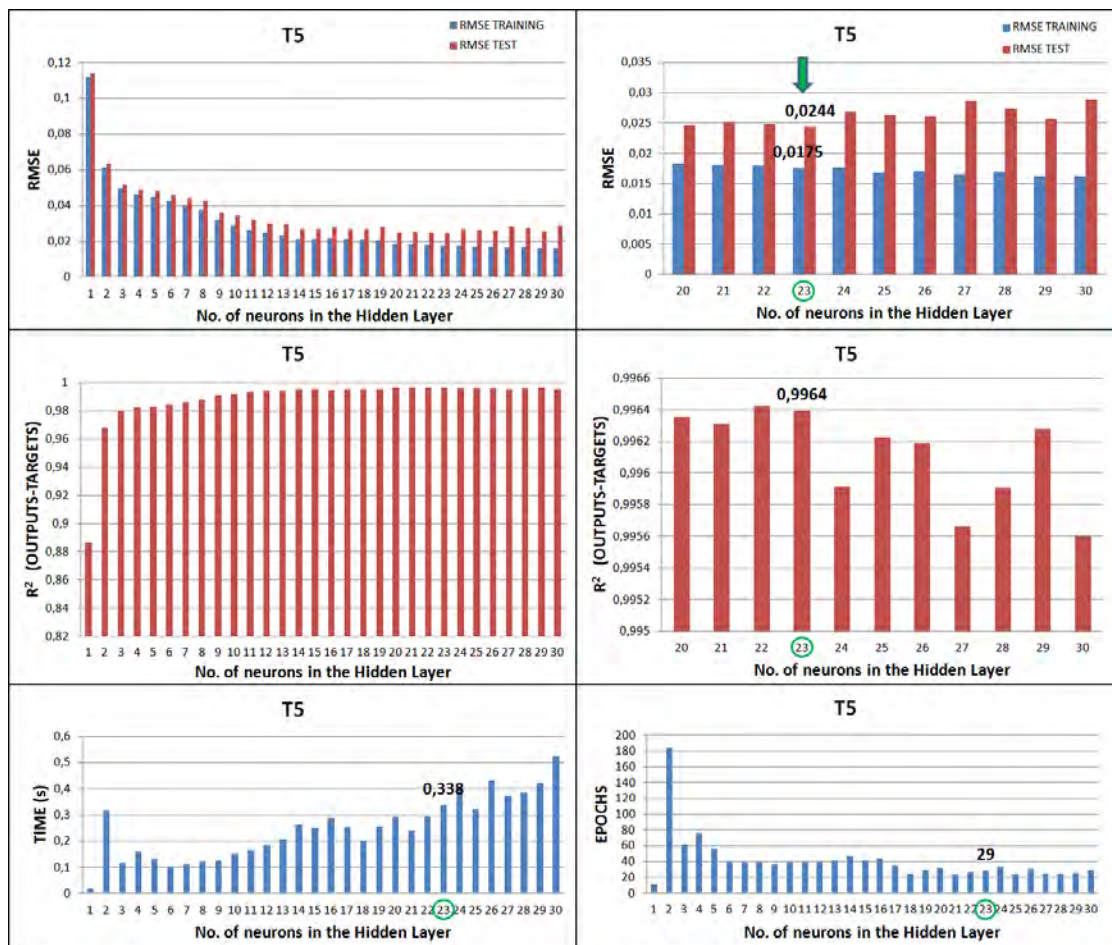


Σχήμα 5-46: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες T3.




Σχήμα 5-47: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες T3.

T5:



Σχήμα 5-48: Αποτελέσματα εκπαίδευσης-δοκιμής για τον αισθητήρα T5.



Σχήμα 5-49: Αποτελέσματα εκπαίδευσης-δοκιμής για τους αισθητήρες T5.

5.4. Σύγκριση νευρωνικών δικτύων μόνης και πολλαπλής εξόδου

Στην συνέχεια συγκρίνονται οι καλύτεροι συνδυασμοί μεθόδου εκπαίδευσης και συνάρτησης μεταφοράς στρώματος εξόδου για νευρωνικά δίκτυα μίας εξόδου και πολλαπλών εξόδων για τα μετρούμενα μεγέθη P3, P5, Pt3, Pt5, T3 και T5. Σκοπός είναι ο προσδιορισμός του καλύτερου τρόπου προσομοίωσης των αισθητήρων όταν ο κάθε αισθητήρας προσομοιώνεται ξεχωριστά (με ένα νευρωνικό δίκτυο ο καθένας) και όταν προσομοιώνονται όλοι μαζί οι αισθητήρες ίδιου μεγέθους (ένα νευρωνικό δίκτυο για τους όμοιους αισθητήρες).

Για αυτόν τον σκοπό συγκρίνονται τα ακόλουθα για κάθε 'οικογένεια αισθητήρων:

- Το σύνολο (άθροισμα) των απαιτούμενων κόμβων, του χρόνου και των επαναλήψεων των νευρωνικών δικτύων μίας εξόδου και το αντίστοιχο πλήθος για το δίκτυο πολλαπλών εξόδων του αντίστοιχου μεγέθους.
- Το μέσο RMSE σφάλμα δοκιμής και εκπαίδευσης και η μέση τιμή συσχέτισης των νευρωνικών δικτύων μίας εξόδου και οι αντίστοιχες μέσες τιμές του δικτύου πολλαπλών εξόδων του αντίστοιχου μεγέθους.

Πίεση P3:

ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΑΠΟΤΕΛΕΣΜΑΤΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ						
TRAINLM - PURELIN						
P3 left	22	0,0077	0,0057	0,9998	0,067	21
P3 right	22	0,0080	0,0060	0,9998	0,074	24
AVERAGE	22	0,0079	0,0059	0,9998	0,071	23
MAX	22	0,0080	0,0060	0,9998	0,074	24
MIN	22	0,0077	0,0057	0,9998	0,067	21
SUM	44	-	-	-	0,142	45
ΑΠΟΤΕΛΕΣΜΑΤΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ						
TRAINLM - PURELIN						
P3	16	0,0081	0,0062	0,9998	0,083	25
ΜΕΤΑΒΟΛΗ (%) ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ ΣΥΝΑΡΤΗΣΕΙ ΠΟΛΛΑΠΛΩΝ						
ΜΕΤΑΒΟΛΗ:	-63,64%	3,18%	5,98%	0,00%	-41,24%	-44,44%

Πίνακας 5-21: Μεταβολή αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου συναρτήσει πολλαπλών για το μέγεθος P3.

Πίεση P5:

ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΑΠΟΤΕΛΕΣΜΑΤΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ						
TRAINLM - PURELIN						
P5 down	26	0,0195	0,0132	0,9984	0,144	38
P5 up	23	0,0258	0,0179	0,9970	0,118	36
AVERAGE	25	0,0227	0,0156	0,998	0,131	37
MAX	26	0,0258	0,0179	0,9984	0,144	38
MIN	23	0,0195	0,0132	0,9970	0,118	36
SUM	49	-	-	-	0,261	74
ΑΠΟΤΕΛΕΣΜΑΤΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ						
TRAINLM - PURELIN						
P5	23	0,0227	0,0160	0,9977	0,196	39
ΜΕΤΑΒΟΛΗ (%) ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ ΣΥΝΑΡΤΗΣΕΙ ΠΟΛΛΑΠΛΩΝ						
ΜΕΤΑΒΟΛΗ:	-53,06%	0,22%	2,89%	0,00%	-24,87%	-47,30%

Πίνακας 5-22: Μεταβολή αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου συναρτήσεως πολλαπλών για το μέγεθος P5.

Πίεση Pt3:

ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΑΠΟΤΕΛΕΣΜΑΤΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ						
TRAINLM - PURELIN						
Pt3 left	18	0,0072	0,0056	0,9998	0,059	22
Pt3 right	22	0,0079	0,0059	0,9998	0,084	27
AVERAGE	20	0,0076	0,0058	0,9998	0,072	25
MAX	22	0,0079	0,0059	0,9998	0,084	27
MIN	18	0,0072	0,0056	0,9998	0,059	22
SUM	40	-	-	-	0,143	49
ΑΠΟΤΕΛΕΣΜΑΤΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ						
TRAINLM - PURELIN						
Pt3	18	0,0077	0,0059	0,9998	0,101	27
ΜΕΤΑΒΟΛΗ (%) ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ ΣΥΝΑΡΤΗΣΕΙ ΠΟΛΛΑΠΛΩΝ						
ΜΕΤΑΒΟΛΗ:	-55,00%	1,99%	2,61%	0,00%	-29,75%	-44,90%

Πίνακας 5-23: Μεταβολή αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου συναρτήσεως πολλαπλών για το μέγεθος Pt3.

Πίεση Pt5:

ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΑΠΟΤΕΛΕΣΜΑΤΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ						
TRAINLM - PURELIN						
Pt5 down	23	0,0091	0,0062	0,9996	0,154	47
Pt5 up	18	0,0107	0,0080	0,9996	0,148	54
AVERAGE	21	0,0099	0,0071	0,9996	0,151	51
MAX	23	0,0107	0,0080	0,9996	0,154	54
MIN	18	0,0091	0,0062	0,9996	0,148	47
SUM	41	-	-	-	0,301	101
ΑΠΟΤΕΛΕΣΜΑΤΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ						
TRAINLM - PURELIN						
Pt5	21	0,0103	0,0069	0,9996	0,250	55
ΜΕΤΑΒΟΛΗ (%) ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ ΣΥΝΑΡΤΗΣΕΙ ΠΟΛΛΑΠΛΩΝ						
ΜΕΤΑΒΟΛΗ:	-48,78%	4,04%	-2,82%	0,00%	-17,15%	-45,54%

Πίνακας 5-24: Μεταβολή αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου συναρτήσει πολλαπλών για το μέγεθος Pt5.

Θερμοκρασία T3:

ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΑΠΟΤΕΛΕΣΜΑΤΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ						
TRAINLM - PURELIN						
T3 left	17	0,0082	0,0066	0,9997	0,051	21
T3 right	16	0,0075	0,0057	0,9998	0,074	30
AVERAGE	17	0,0079	0,0062	0,9998	0,063	26
MAX	17	0,0082	0,0066	0,9998	0,074	30
MIN	16	0,0075	0,0057	0,9997	0,051	21
SUM	33	-	-	-	0,126	51
ΑΠΟΤΕΛΕΣΜΑΤΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ						
TRAINLM - PURELIN						
T3	17	0,0081	0,0063	0,9997	0,067	19
ΜΕΤΑΒΟΛΗ (%) ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ ΣΥΝΑΡΤΗΣΕΙ ΠΟΛΛΑΠΛΩΝ						
ΜΕΤΑΒΟΛΗ:	-48,48%	3,18%	2,44%	-0,01%	-46,85%	-62,75%

Πίνακας 5-25: Μεταβολή αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου συναρτήσει πολλαπλών για το μέγεθος T3.

Θερμοκρασία T5:

ΜΕΤΡΟΥΜΕΝΟ ΜΕΓΕΘΟΣ	No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΑΠΟΤΕΛΕΣΜΑΤΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ						
TRAINLM - PURELIN						
T5 down	25	0,0194	0,0138	0,9975	0,085	24
T5 left	29	0,0318	0,0222	0,9939	0,101	24
T5 right	23	0,0197	0,0133	0,9982	0,147	44
T5 up	29	0,0209	0,0133	0,9971	0,147	35
AVERAGE	27	0,0256	0,0180	0,9957	0,120	24
MAX	29	0,0318	0,0222	0,9982	0,147	44
MIN	23	0,0194	0,0133	0,9939	0,085	24
SUM	106	-	-	-	0,479	127
ΑΠΟΤΕΛΕΣΜΑΤΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ						
TRAINLM - PURELIN						
T5	23	0,0244	0,0175	0,9964	0,338	29
ΜΕΤΑΒΟΛΗ (%) ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΜΙΑΣ ΕΞΟΔΟΥ ΣΥΝΑΡΤΗΣΕΙ ΠΟΛΛΑΠΛΩΝ						
ΜΕΤΑΒΟΛΗ:	-78,30%	-4,69%	-2,78%	0,07%	-29,45%	-77,17%

Πίνακας 5-26: Μεταβολή αποτελεσμάτων νευρωνικών δικτύων μίας εξόδου συναρτήσει πολλαπλών για το μέγεθος T5.

Από τους παραπάνω έξι πίνακες προτείνεται, για τα μεγέθη που μετρούνται με δύο ή παραπάνω αισθητήρες, η χρήση νευρωνικών δικτύων πολλαπλών εξόδων, απ'ότι η χρήση για κάθε αισθητήρα ένα νευρωνικό δίκτυο. Οι λόγοι είναι οι ακόλουθοι:

- Το πλήθος των κόμβων μειώνεται σε υπερβολικό βαθμό, υποδιπλασιάζοντας το απαιτούμενο πλήθος σε όλα τα μεγέθη, καθώς και για την θερμοκρασία T5 το αντίστοιχο πλήθος υποτετραπλασιάζεται.
- Το σφάλμα RMSE δοκιμής αυξάνεται σε πολύ μικρό βαθμό που δεν ξεπερνά το 4%, ενώ για την θερμοκρασία T5 παρουσιάζει βελτίωση ίση περίπου με 4,7%
- Το σφάλμα RMSE εκπαίδευσης παρουσιάζει τα ίδια χαρακτηριστικά με αυτό της δοκιμής, καθώς δεν ξεπερνά το 6%, ενώ στην πίεση Pt5 και στη θερμοκρασία T5 παρουσιάζεται βελτίωση έως και 2,8%
- Η συσχέτιση μεταξύ επιθυμητών τιμών εξόδου και εξόδων των δικτύου μπορεί να θεωρηθεί αμετάβλητη.
- Ο χρόνος εκπαίδευσης και δοκιμής βελτιώνεται σε σημαντικό βαθμό (πραγματοποιείται πιο γρήγορα η διαδικασία), φτάνοντας μέχρι και 47% για τον την θερμοκρασία T3.
- Το πλήθος των επαναλήψεων βελτιώνεται εξίσου σημαντικά (απαιτούνται λιγότερες επαναλήψεις), με αξιοσημείωτο το απαιτούμενο πλήθος επαναλήψεων για την θερμοκρασία T5 που φτάνει το 77%.

Αφού τα σφάλματα RMSE δοκιμής και εκπαίδευσης και η συσχέτιση εξόδων παραμένει αμετάβλητη, τα κριτήρια του πλήθους των κόμβων, του χρόνου εκπαίδευσης-δοκιμής και το πλήθος των επαναλήψεων λήφθηκαν υπόψιν, διότι λαμβάνεται λιγότερη μνήμη του υπολογιστή, η διαδικασία πραγματοποιείται γρηγορότερα και τα αποτελέσματα της μοντελοποίησης παραμένουν τα ίδια.

5.5. Τελική επιλογή μοντελοποίησης με χρήση νευρωνικών δικτύων

Από τα παραπάνω συμπεράσματα επιλέγονται:

- Νευρωνικά δίκτυα ενός κρυφού στρώματος και μονής εξόδου για τα μεγέθη που μετρούνται από έναν αισθητήρα
- Νευρωνικά δίκτυα ενός κρυφού στρώματος και πολλαπλής εξόδου για τους αισθητήρες που μετράνε το ίδιο μέγεθος σε διαφορετικές θέσεις περιμετρικά του κινητήρα


Και στα δύο είδη νευρωνικών δικτύων επιλέγονται:

- ως μέθοδος εκπαίδευσης η Levenberg – Marquardt
- ως συνάρτηση μεταφοράς κρυφού στρώματος η υπερβολική εφραπτόμενη σιγμοειδής (Hyperbolic Tangent Sigmoid)
- ως συνάρτηση μεταφοράς στρώματος εξόδου η γραμμική (Purelin)

Στον ακόλουθο πίνακα δίνεται το πλήθος το κόμβων στο κρυφό στρώμα που απέδωσαν τα βέλτιστα αποτελέσματα, για τα νευρωνικά δίκτυα με τα παραπάνω χαρακτηριστικά, ως προς το σφάλμα εκπαίδευσης και δοκιμής, καθώς και της συσχέτισης των επιθυμητών εξόδων με τις εξόδους των δικτύων. Επίσης δίνονται και οι αντίστοιχες τιμές για τα επιλεχθέντα πλήθη κόμβων των σφαλμάτων rmse για την δοκιμή και εκπαίδευσης, της συσχέτισης, του χρόνου εκπαίδευσης και δοκιμής, και του πλήθους των επαναλήψεων.

ΤΕΛΙΚΗ ΕΠΙΛΟΓΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ							
Μέθοδος εκπαίδευσης:				Levenberg - Marquardt			
Συνάρτηση μεταφοράς κρυφού στρώματος:				Hyperbolic Tangent Sigmoid			
Συνάρτηση μεταφοράς στρώματος εξόδου:				Purelin			
Αισθητήρας		No. of Neurons in the Hidden Layer	RMSE TEST	RMSE TRAINING	R ²	Time (sec)	Epochs
ΠΙΕΣΕΙΣ	P3 (left+right)	16	0,0081	0,0062	0,9998	0,083	25
	P5 (down+up)	23	0,0227	0,0160	0,9977	0,196	39
	Pt3 (left+right)	18	0,0077	0,0059	0,9998	0,101	27
	Pt4	18	0,0070	0,0053	0,9998	0,066	25
	Pt5 (down+up)	21	0,0103	0,0069	0,9996	0,250	55
ΘΕΡΜΟΚΡΑΣΙΕΣ	T3 (left+right)	17	0,0081	0,0063	0,9997	0,067	19
	T4	23	0,0270	0,0206	0,9967	0,079	24
	T5 (down+left+right+up)	23	0,0244	0,0175	0,9964	0,338	29
	EGT	29	0,0217	0,0150	0,9977	0,104	25
ΩΣΗ	THRUST	21	0,0049	0,0038	0,9999	0,140	47

Πίνακας 5-27: Τελική επιλογή είδους νευρωνικού δικτύου, μεθόδου εκπαίδευσης και χρήσης συναρτήσεων μεταφοράς για τους αισθητήρες του κινητήρα Olympus HP ES.



Σχήμα 5-50: Χαρακτηριστικά των νευρωνικών δικτύων των αισθητήρων του κινητήρα Olympus HP ES.

6. Ανακεφαλαίωση – Συμπεράσματα –Προτάσεις

Στο κεφάλαιο αυτό ανακεφαλαιώνεται το αντικείμενο μελέτης της μεταπτυχιακής εργασίας, αναφέρονται τα συμπεράσματα που προέκυψαν και δίνονται προτάσεις για περεταίρω έρευνα.

6.1. Ανακεφαλαίωση

Τα κύρια σημεία μελέτης της παρούσας μεταπτυχιακής εργασίας ήταν τα ακόλουθα:

- Συσχέτιση των βιολογικών με των τεχνητών νευρωνικών δικτύων.
- Αναφορά στην λειτουργία, στην εκπαίδευση, στα βασικά χαρακτηριστικά και στις εφαρμογές των νευρωνικών δικτύων.
- Εκτενής επεξήγηση της αρχής λειτουργίας των νευρωνικών δικτύων Back Propagation, με βάση του οποίου πραγματοποιήθηκε η μοντελοποίηση του κινητήρα, καθώς και αναφορά στις υπάρχουσες παραλλαγές αυτού.
- Παρουσίαση των μικροστροβίλων και ειδικότερα του μικροστροβίλου Olympus HP ES, καθώς και η λειτουργία της πειραματικής διάταξης του συγκεκριμένου κινητήρα των εργαστηρίων Θερμοδυναμικής και Θερμικών Μηχανών των Μηχανολόγων Μηχανικών του Πανεπιστημίου Θεσσαλίας.
- Παρουσίαση των αναφορών στην διεθνή βιβλιογραφία γύρω από το θέμα της μοντελοποίησης αεροστροβίλων με χρήση νευρωνικών δικτύων.
- Προσομοίωση των αισθητήρων του κινητήρα, εξετάζοντας τη χρήση των μεθόδων εκπαίδευσης Levenberg-Marquardt και BFGS quasi-Newton του εμπορικού υπολογιστικού πακέτου Matlab R2012b. Σε κάθε μέθοδο μεταβλήθηκε η συνάρτηση μεταφοράς του στρώματος εξόδου μεταξύ της γραμμικής και της υπερβολικής εφαπτόμενης σιγμοειδής.
- Εξέταση μοντελοποίησης, για τους αισθητήρες που περιγράφουν το ίδιο μέγεθος σε διαφορετικά σημεία περιμετρικά του κινητήρα, η χρήση νευρωνικών δικτύων μονής (για κάθε αισθητήρα) και πολλαπλής εξόδου (για όλους τους κοινούς αισθητήρες μαζί).
- Παρουσίαση των αποτελεσμάτων των μοντελοποιήσεων.
- Συγκριτική μελέτη των αποτελεσμάτων και επιλογή της βέλτιστης μεθόδου μοντελοποίησης για τα μετρούμενα μεγέθη.

6.2. Συμπεράσματα

Τα βασικά συμπεράσματα που προέκυψαν από την παρούσα πτυχιακή εργασία συνοψίζονται στα ακόλουθα βασικά σημεία:

1. Η μοντελοποίηση της λειτουργίας μη γραμμικών συστημάτων, όπως είναι οι στροβιλοκινητήρες είναι δυνατή να γίνει με χρήση νευρωνικών δικτύων τύπου Back Propagation, με σημαντικά μεγάλη ακρίβεια.
2. Η μέθοδος εκπαίδευσης Levenberg-Marquardt επιφέρει μεγαλύτερη ακρίβεια στην μοντελοποίηση των αισθητήρων του κινητήρα από την μέθοδο BFGS quasi-Newton, του εμπορικού υπολογιστικού πακέτου Matlab R2012b, σε βαθμό που δεν μπορεί να αγνοηθεί.
3. Σε δίκτυα ενός κρυφού στρώματος, που χρησιμοποιήθηκαν κατά την μοντελοποίηση, έχοντας ως συνάρτηση μεταφοράς την υπερβολική εφαπτόμενη σιγμοειδή, εναλλάσσοντας την συνάρτηση μεταφοράς του στρώματος εξόδου μεταξύ της γραμμικής και της υπερβολικής εφαπτόμενης, μεταβάλλονταν τα αποτελέσματα, με καλύτερα και για τις δύο μεθόδους εκπαίδευσης όταν χρησιμοποιήθηκε η γραμμική.
4. Τα καλύτερα αποτελέσματα μοντελοποίησης, τόσο για τα δίκτυα μονής όσο και για τα πολλαπλής εξόδου, διεξήχθησαν με τον συνδυασμό μεθόδου εκπαίδευσης Levenberg – Marquardt και συνάρτησης μεταφοράς εξόδου την γραμμική. Έπειτα ακολούθησαν οι υπόλοιποι συνδυασμοί, με την σειρά που απεικονίζονται στον επόμενο πίνακα.

Σφάλμα RMSE		Μέθοδος Εκπαίδευσης	Συνάρτηση Μεταφοράς Στρώματος Εξόδου
<div>↓</div>	1.	Levenberg - Marquardt	Linear
	2.	Levenberg - Marquardt	Hyperbolic Tangent Sigmoid
	3.	BFGS quasi - Newton	Linear
	4.	BFGS quasi - Newton	Hyperbolic Tangent Sigmoid

5. Για τους αισθητήρες που περιγράφουν το ίδιο μέγεθος, σε διαφορετικά σημεία περιμετρικά του κινητήρα, χρησιμοποιήθηκαν νευρωνικά δίκτυα μονής εξόδου (για κάθε αισθητήρα) και πολλαπλής εξόδου (για όλους τους όμοιους αισθητήρες μαζί). Τα διεξαγόμενα σφάλματα rmse εκπαίδευσης και δοκιμής ήταν ακριβώς τα ίδια, όπως και η συσχέτιση των εξόδων, όμως σημαντική διαφορά παρουσιάστηκε στο απαιτούμενο πλήθος κόμβων στο κρυφό στρώμα. Ειδικότερα, με τα δίκτυα μονής εξόδου απαιτείται το διπλάσιο, αλλά και τετραπλάσιο, πλήθος κόμβων αθροιστικά σε σχέση με τα πολλαπλής εξόδου.
6. Για τους παραπάνω λόγους επιλέχθηκαν για την μοντελοποίηση:
 - Νευρωνικά δίκτυα ενός κρυφού στρώματος και μονής εξόδου για τα μεγέθη που μετρούνται από έναν αισθητήρα

- Νευρωνικά δίκτυα ενός κρυφού στρώματος και πολλαπλής εξόδου για τους αισθητήρες που μετράνε το ίδιο μέγεθος σε διαφορετικές θέσεις περιμετρικά του κινητήρα
7. Και στα δύο είδη νευρωνικών δικτύων επιλέχθηκαν:
- ως μέθοδος εκπαίδευσης η Levenberg – Marquardt
 - ως συνάρτηση μεταφοράς κρυφού στρώματος η υπερβολική εφαπτόμενη σιγμοειδής (Hyperbolic Tangent Sigmoid)
 - ως συνάρτηση μεταφοράς στρώματος εξόδου η γραμμική (Purelin)
8. Όσο αυξάνεται το πλήθος των κόμβων το σφάλμα εκπαίδευσης (rmse training) πέφτει σε μία ελάχιστη τιμή και έπειτα διακυμαίνεται γύρω από αυτήν την τιμή.
9. Το σφάλμα δοκιμής (rmse test) μειώνεται σε μία ελάχιστη τιμή και έπειτα αυξάνεται εκ νέου, με την αύξηση του πλήθους των κόμβων. Αυτό μπορεί να αποδοθεί στο γεγονός ότι το δίκτυο από την ελάχιστη τιμή και έπειτα «ειδικεύεται» στις τιμές της εκπαίδευσης και οπότε χάνεται η δυνατότητα «γενίκευσης» στο να δίνει σωστές εξόδους σε άγνωστες εισόδους.
10. Τα αποτελέσματα των νευρωνικών δικτύων που επιλέχθηκαν (σφάλμα δοκιμής και εκπαίδευσης και συσχέτιση επιθυμητών εξόδων με εξόδων δικτύου) κυμαίνονται σε πολύ καλά επίπεδα.

	RMSE TEST	RMSE TRAINING	R ²
AVERAGE	0,0142	0,0103	0,9987
MAX	0,0270	0,0206	0,9999
MIN	0,0049	0,0038	0,9964

11. Η ταχύτητα εκπαίδευσης και δοκιμής δεν εξαρτάται από το πλήθος των κόμβων στο κρυφό υπόστρωμα, καθώς η κατανομή του χρόνου συναρτίζεται του πλήθους των κόμβων είναι εντελώς τυχαία, εκτός από ελάχιστες περιπτώσεις όπου τείνει να αυξηθεί γραμμικά με την αύξηση του πλήθους. Αυτό μπορεί να αποδοθεί στην συμβολή της τυχαίας αρχικοποίησης των τιμών των βαρών κατά την φάση εκπαίδευσης.
12. Η ίδια τυχαία κατανομή, με αυτή του χρόνου εκπαίδευσης και δοκιμής, παρατηρήθηκε και στο πλήθος των επαναλήψεων, με την διαφορά ότι σε ορισμένες περιπτώσεις τείνει να μειωθεί γραμμικά με την αύξηση του πλήθους των κόμβων.

6.3. Προτάσεις

Σκόπιμη θεωρείται η περεταίρω διερεύνηση στα ακόλουθα θέματα:

- Χρήση νευρωνικών δικτύων με δύο ή περισσότερα κρυφά στρώματα και σύγκριση των αποτελεσμάτων με τα αντίστοιχα τις παρούσας μεταπτυχιακής εργασίας.
- Μοντελοποίηση της λειτουργίας του μικροστροβίλου Olympus HP ES κατά την φάση απογείωσης και προσγείωσης
- Κατασκευή – μοντελοποίηση των χαρτών λειτουργίας τους μικροστροβίλου μικροστρόβιλο Olympus HP ES, με την χρήση νευρωνικών δικτύων.
- Κατάστρωση διαγνωστικής διαδικασίας για τον μικροστρόβιλο Olympus HP ES, μοντελοποιώντας διάφορες βλάβες.
- Μετατροπή των προγραμμάτων που αναπτύχθηκαν στο πλαίσιο της παρούσας εργασίας σε SIMULINK και την σύνδεσή τους με τα ήδη υπάρχοντα του εργαστηρίου Θερμοδυναμικής και Θερμικών Μηχανών των Μηχανολόγων Μηχανικών του Πανεπιστημίου Θεσσαλίας.
- Συνδυασμός των δικτύων που αναπτύχθηκαν και που προτείνονται να αναπτυχθούν κατά την φάση μοντελοποίησης και διάγνωσης του μικροστροβίλου Olympus HP ES σε ένα ολοκληρωμένο διαγνωστικό πρόγραμμα ελέγχου της λειτουργίας του.

Βιβλιογραφία

1. <http://www.mazi.org.gr/Κατάθλιψη/Φαρμακευτική-αγωγή?showall=1>, τελευταία επίσκεψη 13/6/12.
2. <http://el.wikipedia.org/wiki/Νευρώνας>, τελευταία επίσκεψη 13/6/12.
3. <http://www.myoskeletiko.com/farmaka/myoskeletiko-vivlio-farmakologiki-vasi-farmakeftikou-marketing/myoskeletiko-farmakodynamikh/neyriko-systimaoi-mixanismoι-kai-i-therapeia-tou-ponou.html>, τελευταία επίσκεψη 16/6/12.
4. <http://18gym-athin.att.sch.gr/Old-site/students-pages/organism.htm>, τελευταία επίσκεψη 16/6/12.
5. Δ. Σταθοπούλου, Πάτρα 2010, «Σύγκριση Μεθόδων Εκπαίδευσης Τεχνητών Νευρωνικών Δικτύων».
6. http://el.wikipedia.org/wiki/Τεχνητά_νευρωνικά_δίκτυα, τελευταία επίσκεψη 29/7/12.
7. Alex M. Remennikova, Timothy A. Rose, Predicting the effectiveness of blast wall barriers using neural networks
8. <http://www.cranfield.ac.uk/library/cranfield/about/archive/ww2/page28819.html>, τελευταία επίσκεψη 6/10/2012
9. <http://www.jetagemuseum.btck.co.uk/Aircraft/GlosterE2839>, τελευταία επίσκεψη 6/10/2012
10. <http://www.aer.ita.br/~bmattos/mundo/ww2/he178.htm>, τελευταία επίσκεψη 6/10/2012
11. C. Bao, M. Ouyang, B. Yi, J Power Sour, 156 (2) (2006), pp. 232–243, «Modeling and optimization of the air system in polymer exchange membrane fuel cell system».
12. Y. Yu, L. Chen, F. Sun, C. Wu, J Appl Energy, 84 (1) (2007), pp. 48–55, «Neural network based analysis and prediction of a compressor's characteristic performance map».
13. <http://www.switched.com/2007/12/17/two-hour-flights-from-new-york-to-tokyo-coming-soon/>
14. N.S. Sisworahardjo, M.Y. El-Sharkh, M.S. Alam, Electric Power Syst Res, 78 (8) (2008), pp. 1378–1384, «Neural network controller for microturbine power plants».
15. K. Kanelopoulos, A. Stamatis, K. Mathioudakis, ASME 97-GT-35, 1997, «Incorporating Neural Networks into Gas Turbine Performance Diagnostics».
16. Π.Ν. Κωτσιόπουλος, «Προωθητικά Συστήματα – Τόμος Ι – Αρχές Λειτουργίας Αεροκινητήρων – Θερμοδυναμική – Πρόωση –επιδόσεις».
17. H.H. Saravanamuttoo, G.F.C. Rogers, H. Cohen, P.V. Stranzicky, Pearson Education 2009, «Gas Turbine Theory, Sixth Edition».

18. <http://www.geaviation.com/engines/>, τελευταία επίσκεψη 24/10/2012
19. <http://www.qsl.net/wb0ydi/j79.html>, τελευταία επίσκεψη 24/10/2012
20. <http://www.aerospaceweb.org/question/propulsion/q0033.shtml>, τελευταία επίσκεψη 24/10/2012
21. <http://mb-soft.com/public2/alaskapl.html>, τελευταία επίσκεψη 24/10/2012
22. N. Flynn, S. Mcloone, G.W. Irwin, M.D. Brown, E. Swidenbank, B.W. Hogg, Automatica, 33 (11) (1997), pp. 1961-1973, «Neural control of turbogenerator systems».
23. J.E. Yoon, J.J. Lee, T.S. Kim, J.L. Sohn, Appl Energy, 86 (1) (2009), pp.9-17, «Development and multi-utility of an ANN model for an industrial gas turbine».
24. P. Moraal, I. Kolmanovsky, SAE Trans, 108 (1999), pp. 1324-1338, «Turbocharger modeling for automotive control application».
25. Α. Σταμάτης, Πανεπιστήμιο Θεσσαλίας, Τμήμα Μηχανολόγων Μηχανικών Βιομηχανίας, διαλέξεις μαθήματος, «Σχεδιασμός Ενεργειακών Συστημάτων».
26. Α. Αναστασιάδης, Θεσσαλονίκη 2004, «Μετατροπή του Αεροπορικού Κινητήρα GE-90-85B σε Βιομηχανικό Αεριοστρόβιλο για την Παραγωγή Ηλεκτρικής Ενέργειας – Μελέτη του Συνδυασμένου Κύκλου – Καύση και Καύσιμα »
27. Ε. Καρέλας, Ι. Τριαντάφυλλος, Γ. Φρέσκος, Αθήνα 2004, «Κινητήρες Αεροσκαφών Ι Ι».
28. <http://www.modeljetclub.co.uk/turbines.htm>, τελευταία επίσκεψη 4/11/2012
29. Instruction Manual 12V Kerosene Start System, Part Number: KS-1, Altecure.
30. <http://www.jetcatusa.com>, τελευταία επίσκεψη 4/11/2012
31. <http://www.rchelicopterfun.com/turbine-rc-helicopter.html>, τελευταία επίσκεψη 4/11/2012
32. <http://www.rc-airplanes-simplified.com/model-jet-engines.html>, τελευταία επίσκεψη 4/11/2012
33. <http://jetmodelproducts.com/> , τελευταία επίσκεψη 4/11/2012
34. Graham Warwick 18 Sep 2009, «Stealth, Hybrid Power, Modular Wings - Skunks' MQ-X», (<http://www.aviationweek.com>)
35. AMT Netherlands b.v., June 2009, «Olympus HP gas-turbine».
36. <http://www.jetman.com>
37. Goor. B. v. d., Manual Olympus HP E-START. AMT Netherlands 2005.
38. Δ. Μπακάλης, Βόλος, Ιούλιος 2008, «Μελέτη εγκαταστάσεων μικρών αεροστροβίλων».
39. SAE, Aircraft propulsion system performance station designation and nomenclature. AS 755.

40. A. G. Stamatis, D. P. Bakalis, Proceeding of ASME Turbo Expo 2010: Power for Land, Sea and Air GT2010-22837, 14-18 June 2010, Glasgow UK, «Extended instrumentation and model calibration for a small micro-turbine».
41. WIKA Instrument Corporation, Lawrenceville, «Electronic Pressure Measurement, General Purpose Pressure Transmitters Type A-10».
42. Analog Devices, Inc., Norwood U.S.A. 1999, «Monolithic Thermocouple Amplifiers with Cold Junction Compensation AD594/AD595».
43. National Instruments Corporation, United States, (866) 531-6285, «M Series Multifunction DAQ for USB - 16-Bit, 250 kS/s, up to 80 Analog Inputs».
44. AMT Netherlands b.v., Netherlands 2008, «EDT data».
45. http://galaxy.agh.edu.pl/~vlsi/AI/backp_t_en/backprop.html, τελευταία επίσκεψη 3/12/11.
46. Kishan Mehrotra, Chilukuri K. Mohan and Sanjay Ranka, October 1996, «Elements of Artificial Neural Networks».
47. Raul Rojas, Berlin, 1996, «Neural Networks - A Systematic Introduction».
48. D. Asha, G. Chamundeswari, R. Deepa Lakshmi, Madras University – Department of Computer Science, «Artificial Neural Networks – Adaline and Madaline».
49. Toshinori Munakata, Springer-Verlag London Limited 2008, «Fundamentals of the New Artificial Intelligence – Second Edition».
50. http://en.wikipedia.org/wiki/Hopfield_network, τελευταία επίσκεψη 8/12/2012
51. Dr. M. Turhan (Tury) Taner, Rock Solid Images, November 1997, «Kohonen's SELF Organizing Networks With "Conscience"».
52. Donald F. Specht, IEEE Transactions of Neural Networks, Vol.2 No.6, November 1991, «A General Regression Neural Network».
53. <http://www.dtreg.com/pnn.htm>, τελευταία επίσκεψη 13/12/11.
54. Soteris A. Kalogirou, Applied Energy 67 (2000) 17-35, «Applications of artificial neural-networks for energy systems».
55. C.M. Bartolini, F. Caresana, G. Comodi, L. Pelagalli, M. Renzi, S. Vagni, Energy Conversion and Management, Elsevier Ltd. 2010, «Application of artificial neural networks to micro gas turbines».
56. Praveen Shankar, Rama K. Yedavalli, ASME Turbo Expo 2006: Power for Land, Sea and Air, May 2006, Barcelona, Spain «A Neural Network Based Adaptive Observer for Turbine Engine Parameter Estimation».
57. C. Boccaletti, G. Cerri, B. Seyedan, ASME Vol.123, April 2001, «A Neural Network Simulator of a Gas Turbine With a Waste Heat Recovery Section».
58. K. Ghorbanian, M. Gholamrezaei, Applied Energy 86 (2009) 1210–1221, «An artificial neural network approach to compressor performance prediction».

59. O. Cortus, G. Urquiza, J.A. Hernandez, *Applied Energy* 86 (2009) 2487–2493, « Optimization of operating conditions for compressor performance by means of neural network inverse».
60. J. Smrekar, M.Assadi, M.Fast, I.Kustrin, S.De, *Energy* 34 (2009) 144–152, « Development of artificial neural network model for a coal-fired boiler using real plant data »
61. MGholamrezaei, K Ghorbanian, *Proc. IMechE Vol. 224 Part A: J. Power and Energy*, May 2009, «Compressor map generation using a feed-forward neural network and rig data».
62. A. Lazzarett, A. Toffolo, *Int.J. Applied Thermodynamics*, Vol.4, (No.4), pp.173-182, December 2001, «Analytical and Neural Network Models for Gas Turbine Design andOff-Design Simulation».


Παραρτήματα

Π.1 Σχηματική επεξήγηση λειτουργίας Backpropagation

Στο συγκεκριμένο παράρτημα επεξηγείται βηματικά η βασική αρχή λειτουργίας του αλγορίθμου backpropagation για την εκπαίδευση ενός νευρωνικού δικτύου πολλαπλών στρώματων. [45]

Για την επεξήγηση της λειτουργίας θα γίνει χρήση ενός νευρωνικού δικτύου, το οποίο απεικονίζεται στην συνέχεια, με τα ακόλουθα χαρακτηριστικά:

- δύο εισόδους (inputs)
- μία έξοδος (output)
- δύο κρυφά στρώματα (hidden layers)
 - το πρώτο κρυφό στρώμα με τρεις κόμβους⁷ (nodes)
 - το δεύτερο κρυφό στρώμα με δύο κόμβους (nodes)



Κάθε κόμβος αποτελείται από δύο τμήματα:

- Το πρώτο τμήμα προσθέτει το γινόμενο των εισόδων του κόμβου με τα αντίστοιχα βάρη τους, δηλαδή πραγματοποιεί το σταθμισμένο άθροισμα του στρώματος εισόδου σύμφωνα με την σχέση:

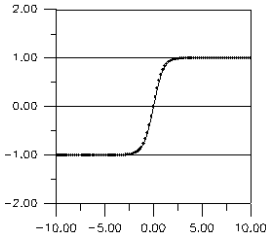
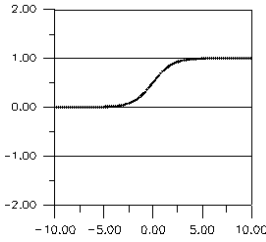
$$e_j = \sum_{i=1}^n x_i \cdot w_{ij}$$

x_i : η τιμή του κόμβου εισόδου i

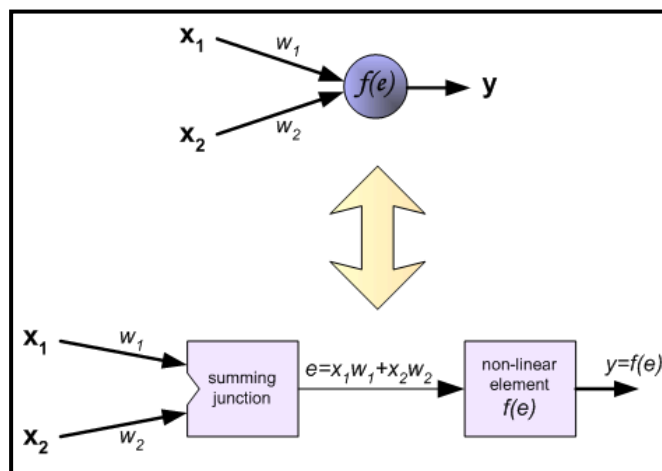
w_{ij} : το βάρος σύνδεσης μεταξύ του κόμβου εισόδου i , και του κόμβου εξόδου j .

- Το δεύτερο τμήμα αποτελείται από την ενεργοποίηση μίας συνεχής και παραγωγίσιμης συνάρτησης, η οποία έχει ως είσοδο το σταθμισμένο άθροισμα e_j . Οι πιο συχνά χρησιμοποιούμενες τέτοιες μη γραμμικές συναρτήσεις είναι η υπερβολική εφαπτομένη και η σιγμοειδής.


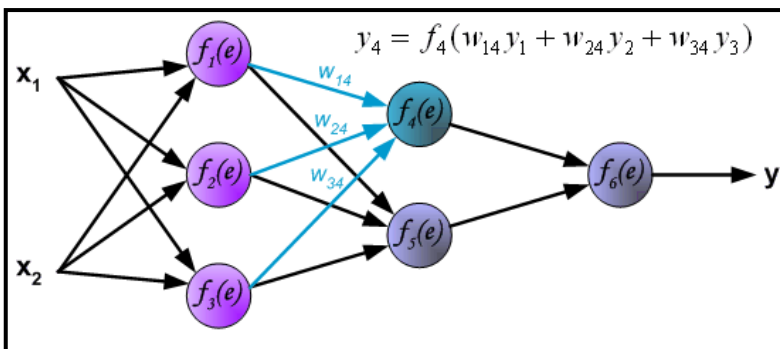



⁷ Υπενθυμίζεται: ο κόμβος (node) νευρωνικού δικτύου (neural network) στην παγκόσμια βιβλιογραφία πολλές φορές χαρακτηρίζεται και ως τεχνητός νευρώνας (artificial neuron)


Υπερβολική εφαπτομένη	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	
Σιγμοειδής	$f(x) = \frac{1}{1 + e^{-a \cdot x + b}}$	
Στην προκειμένη περίπτωση $x = e_j$		

Το σήμα e_j είναι το αθροιστικό σήμα εξόδου και η έξοδος $y_j = f(e_j)$ είναι το σήμα εξόδου μία μη γραμμικής συνάρτησης. Το σήμα y_j αποκαλείται και ως έξοδος του κόμβου.




Για την εκπαίδευση ενός νευρωνικού δικτύου απαιτείται η ύπαρξη ενός πακέτου δεδομένων (data set). Το πακέτο εκπαίδευσης αποτελείται από τα σήματα εισόδου (x_1 και x_2) και τις επιθυμητές εξόδους – στόχους (desired outputs – targets) z . Η εκπαίδευση του δικτύου είναι μία επαναληπτική διαδικασία. Σε κάθε επανάληψη οι τιμές των βαρών των κόμβων αλλάζουν χρησιμοποιώντας καινούρια δεδομένα από το πακέτο εκπαίδευσης. Οι αλλαγές πραγματοποιούνται με βάση τον ακόλουθο αλγόριθμο: κάθε βήμα εκπαίδευσης ξεκινάει με σήματα εισόδου τιμές από το πακέτο εκπαίδευσης. Μετά από αυτό το στάδιο υπολογίζεται η τιμή εξόδου του κάθε κόμβου σε κάθε στρώμα. Στις παρακάτω εικόνες αναπαριστάται πως διαδίδεται το σήμα στο δίκτυο. Τα σύμβολα που ακολουθούν επεξηγήθηκαν πιο πάνω.







Στο ακόλουθο βήμα το σήμα εξόδου y του δικτύου συγκρίνεται με την τιμή της επιθυμητής εξόδου (target value), η οποία αντλείται από το πακέτο δεδομένων εκπαίδευσης. Η διαφορά ονομάζεται σφάλμα εξόδου δ ($\delta = z - y$) της εξόδου του δικτύου.






Είναι αδύνατος ο υπολογισμός του σφάλματος για τους εσωτερικούς νευρώνες, διότι οι τιμές εξόδου αυτών των νευρώνων είναι άγνωστες. Για πολλά χρόνια η αποτελεσματική μέθοδος εκπαίδευσης δικτύων με πολλαπλές στρώσεις παρέμενε άγνωστος. Στα μέσα της δεκαετίας του ογδόντα ο αλγόριθμος οπίσθιας διάδοσης (backpropagation algorithm) έδωσε την λύση. Η ιδέα ήταν να διαδοθεί το σφάλμα εξόδου (που υπολογίζεται σε κάθε βήμα εκπαίδευσης) πίσω στους νευρώνες, των οποίων τα σήματα εξόδου ήταν είσοδοι για τον υπολογισμό της τιμής εξόδου.





Οι συντελεστές των βαρών w_{ij} που χρησιμοποιούνται για την προς τα πίσω διάδοση του σφάλματος είναι οι ίδιοι με αυτούς που χρησιμοποιήθηκαν κατά την διαδικασία του υπολογισμού της εξόδου. Μόνο η φορά της ροής των δεδομένων αλλάζει (τα σήματα διαδίδονται από την έξοδο προς την είσοδο το ένα μετά το άλλο). Αυτή η τεχνική χρησιμοποιείται για όλα τα στρώματα του δικτύου. Αν τα διαδιδόμενα σήματα σφάλματος σε έναν κόμβο προέρχονται από περισσότερους από έναν κόμβους τότε προστίθενται. Η διαδικασία απεικονίζεται στην συνέχεια:





Όταν το σήμα σφάλματος του κάθε νευρώνα έχει υπολογιστεί, τα βάρη των τιμών εισόδου του δικτύου τροποποιούνται σύμφωνα με την ακόλουθη σχέση:

$$w'_{ij} = w_{ij} + \eta \delta_j \frac{df_j(e)}{de} x_i$$

w_{ij} : το βάρος σύνδεσης μεταξύ του κόμβου εισόδου i , και του κόμβου εξόδου j .

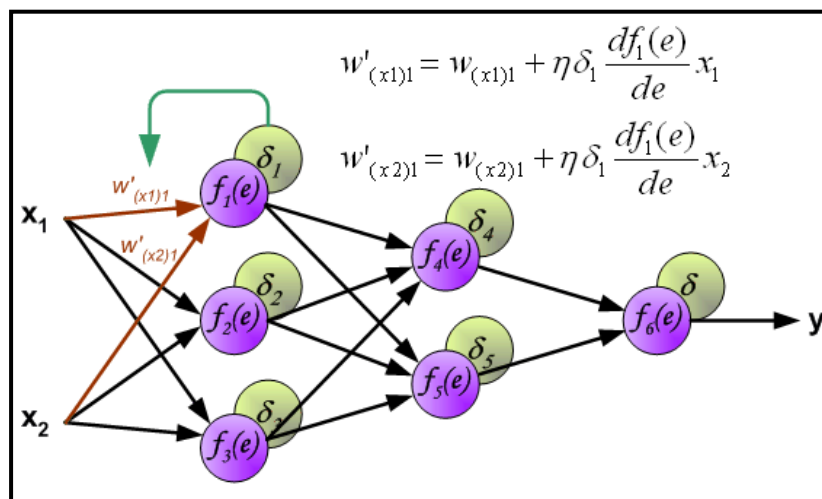
w'_{ij} : το καινούριο-διορθωμένο βάρος σύνδεσης μεταξύ του κόμβου εισόδου i , και του κόμβου εξόδου j .

η : ρυθμός εκμάθησης (learning rate), τιμές: 0,25-0,75, αντικατοπτρίζει την ταχύτητα εκπαίδευσης του δικτύου.⁸

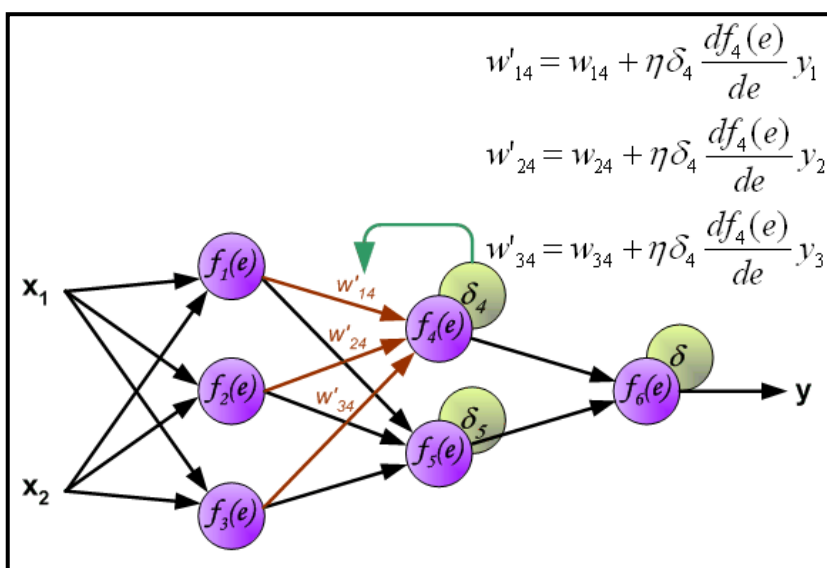
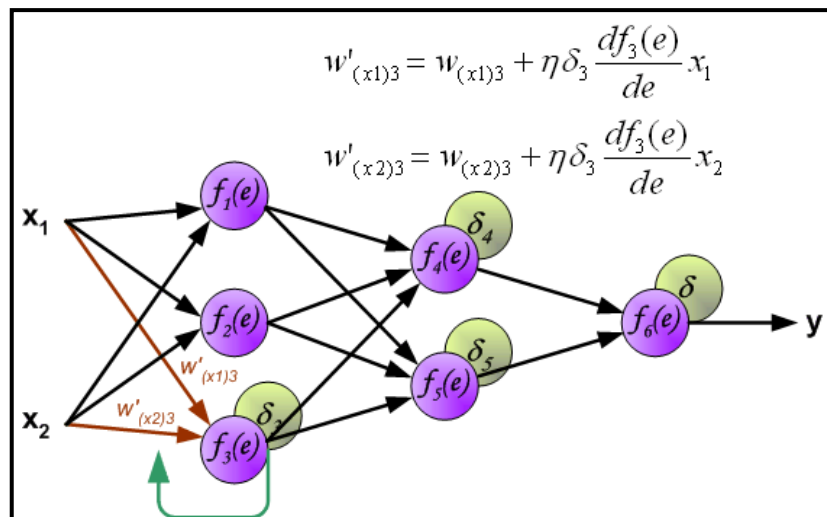
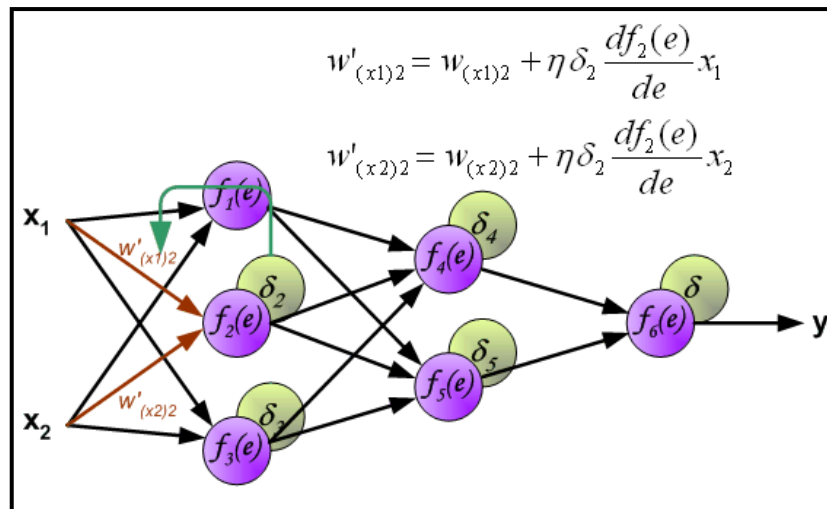
δ_j : το σφάλμα εξόδου του κάθε κόμβου.

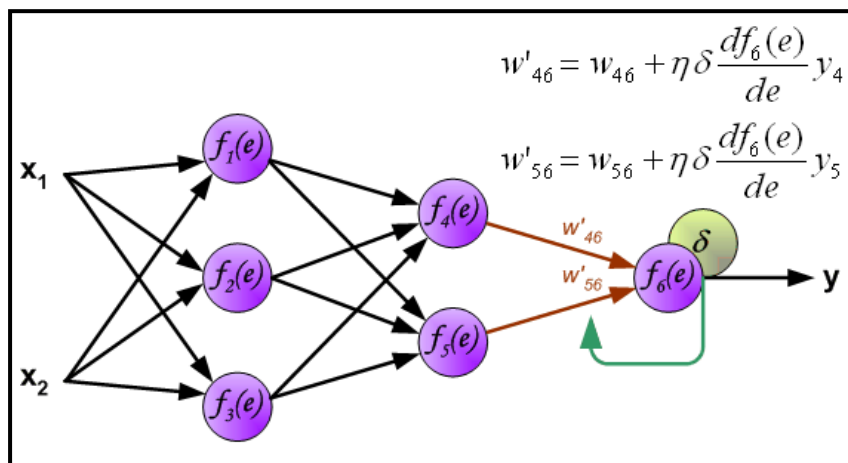
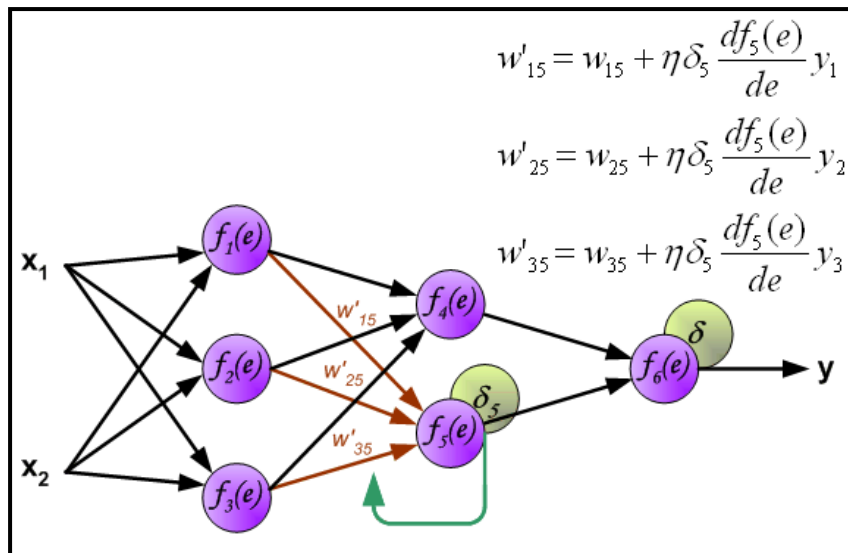
$\frac{df_j(e)}{de}$: η παράγωγος της συνάρτησης ενεργοποίησης $f_j(e)$.

x_i : τιμή του κόμβου εισόδου i .



⁸ Υπάρχουν δύο τρόποι επιλογής αυτής της παραμέτρου. Ο πρώτος είναι η επιλογή εξ αρχής μεγάλη τιμής και καθώς οι τιμές των βαρών υπολογίζονται η παράμετρος εκπαίδευσης σταδιακά μειώνεται. Η δεύτερη μέθοδος (πιο πολύπλοκη) ξεκινά εκπαιδύοντας το δίκτυο με μικρές τιμές του η , οι οποίες αυξάνονται καθώς εκπαιδεύεται το δίκτυο και μειώνονται ξανά στο τελευταίο στάδιο της εκπαίδευσης.





Η παραπάνω διαδικασία εκπαίδευσης αποτελεί μία επανάληψη εκπαίδευσης του νευρωνικού δικτύου. Ο ρυθμός των επαναλήψεων μέχρι το τέλος της εκπαίδευσης εξαρτάται από το επιθυμητό ανεκτό σφάλμα που έχει οριστεί αρχικά.

Π.2 Περιγραφή κώδικα

Στο συγκεκριμένο παράρτημα γίνεται αναφορά στα τμήματα κώδικα που αναπτύχθηκαν και χρησιμοποιήθηκαν για την εκπαίδευση των νευρωνικών δικτύων. Έγινε χρήση του εμπορικού πακέτου Matlab (Matlab R2012b). Από μόνο του το Matlab έχει ορισμένες έτοιμες υπορουτίνες στην ηλεκτρονική βιβλιοθήκη. Στο πλαίσιο της συγκεκριμένης μεταπτυχιακής εργασίας, για την διεξαγωγή των παραπάνω αποτελεσμάτων αναπτύχθηκαν νέες υπορουτίνες, καθώς και τα ανάλογα προγράμματα, τα οποία αποτελούνται κυρίως από υπορουτίνες. Στη συνέχεια γίνεται εκτενής αναφορά στις υπορουτίνες και έπειτα στα κύρια προγράμματα.

Π.2.1. Πρόγραμμα `nn_trainlm_purelin.m`

1. Σκοπός

Σκοπός του προγράμματος είναι η διεξαγωγή των παραπάνω αποτελεσμάτων με μέθοδο εκπαίδευσης `trainlm` και συνάρτηση μεταφοράς στρώματος εξόδου `purelin`.

2. Εντολές

Περιλαμβάνει όλες τις υπορουτίνες του παραρτήματος, με ιδιαιτερότητα:

- `net.trainFcn = 'trainlm';`
- `net.layers{2}.transferFcn='purelin';`

Π.2.2. Πρόγραμμα `nn_trainlm_tansig.m`

1. Σκοπός

Σκοπός του προγράμματος είναι η διεξαγωγή των παραπάνω αποτελεσμάτων με μέθοδο εκπαίδευσης `trainlm` και συνάρτηση μεταφοράς στρώματος εξόδου `tansig`.

2. Εντολές

Περιλαμβάνει όλες τις υπορουτίνες του παραρτήματος, με ιδιαιτερότητα:

- `net.trainFcn = 'trainlm';`
- `net.layers{2}.transferFcn='tansig';`

Π.2.3. Πρόγραμμα `nn_trainbfg_purelin.m`

1. Σκοπός

Σκοπός του προγράμματος είναι η διεξαγωγή των παραπάνω αποτελεσμάτων με μέθοδο εκπαίδευσης `trainbfg` και συνάρτηση μεταφοράς στρώματος εξόδου `purelin`.

2. Εντολές

Περιλαμβάνει όλες τις υπορουτίνες του παραρτήματος, με ιδιαιτερότητα:

- `net.trainFcn = 'trainbfg';`
- `net.layers{2}.transferFcn='purelin';`

Π.2.4. Πρόγραμμα `nn_trainbfg_tansig.m`

1. Σκοπός

Σκοπός του προγράμματος είναι η διεξαγωγή των παραπάνω αποτελεσμάτων με μέθοδο εκπαίδευσης `trainbfg` και συνάρτηση μεταφοράς στρώματος εξόδου `tansig`.

2. Εντολές

Περιλαμβάνει όλες τις υπορουτίνες του παραρτήματος, με ιδιαιτερότητα:

- `net.trainFcn = 'trainbfg';`
- `net.layers{2}.transferFcn='tansig';`

Π.2.5. Υπορουτίνα `xlsread.m`

1. Σκοπός

Προορίζεται για την εισαγωγή των δεδομένων που υπάρχουν σε αρχείο Microsoft Excel (.xls).

2. Κάλεσμα

Κατά την διάρκεια των προγραμμάτων καλείται 4 φορές συνολικά.

- `data = xlsread('inputs');` Για την εισαγωγή των τιμών εισόδου
- `data = xlsread(' targets ');` Για την εισαγωγή των επιθυμητών τιμών εξόδου
- `LS=xlsread('layersize');` Για την εισαγωγή του πλήθους των κόμβων στο κρυφό στρώμα
- `ep=xlsread('epanalipseis');` Για την εισαγωγή του πλήθους των επαναλήψεων που επιθυμεί ο χρήστης να επαναλάβει την διαδικασία για κάθε διαφορετικό πλήθος κόμβων

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
inputs	real	Πίνακας, όπου κάθε στήλη αντιπροσωπεύει διαφορετική μεταβλητή εισόδου και κάθε σειρά διαφορετική τιμή της κάθε μεταβλητής εισόδου
targets	real	Πίνακας, όπου κάθε στήλη αντιπροσωπεύει διαφορετική μεταβλητή επιθυμητής εξόδου και κάθε σειρά διαφορετική τιμή της κάθε μεταβλητής εξόδου
layersize	real	Πίνακας αποτελούμενος από μία στήλη. Κάθε σειρά αποτελεί το πλήθος των εξεταζόμενων κρυφών κόμβων για τους οποίους επιθυμούμε να εκπαιδευτεί το νευρωνικό δίκτυο
epanalipseis	real	Πίνακας αποτελούμενος από ένα στοιχείο, το οποίο ρυθμίζει το μέγιστο αριθμό επαναλήψεων της εκπαίδευσης για κάθε πλήθος κόμβων

Π.2.6. Υπορουτίνα **adiast1.m**

1. Σκοπός

Προορίζεται για την αδιαστατοποίηση των δεδομένων εισόδου, με εύρος αδιαστατοποίησης [-1,1].

2. Κάλεσμα

- [A,B,inputs]=adiast1(data);

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
data	real	Αποτελεί των πίνακα με τις τιμές εισόδου
inputs	real	Επιστροφή: πίνακας με αδιαστατοποιημένες τιμές εισόδου
A	real	Επιστροφή: παράμετρος αδιαστατοποίησης (βλέπε αντίστοιχο κεφάλαιο)
B	real	Επιστροφή: παράμετρος αδιαστατοποίησης (βλέπε αντίστοιχο κεφάλαιο)

Π.2.7. Υπορουτίνα **adiast0.m**

1. Σκοπός

Προορίζεται για την αδιαστατοποίηση των επιθυμητών δεδομένων εξόδου, με εύρος αδιαστατοποίησης [0,1].

2. Κάλεσμα

- [C,D,targets]=adiast0(data);

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
data	real	Αποτελεί των πίνακα με τις επιθυμητές τιμές εξόδου
targets	real	Επιστροφή: πίνακας με αδιαστατοποιημένες τιμές επιθυμητών εξόδων
C	real	Επιστροφή: παράμετρος αδιαστατοποίησης (βλέπε αντίστοιχο κεφάλαιο)
D	real	Επιστροφή: παράμετρος αδιαστατοποίησης (βλέπε αντίστοιχο κεφάλαιο)

Π.2.8. Υπορουτίνα **fitnet.m**

1. Σκοπός

Προορίζεται για την δημιουργία νευρωνικού δικτύου με συγκεκριμένο πλήθος κόμβων στο κρυφό στρώμα.

2. Κάλεσμα

- `net = fitnet(hiddenLayerSize);`

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
hiddenLayerSize	real	Αποτελεί το πλήθος των εξεταζόμενων κρυφών κόμβων για τους οποίους επιθυμούμε να εκπαιδευτεί το νευρωνικό δίκτυο
net	object	Επιστροφή: το νευρωνικό δίκτυο που δημιουργήθηκε

Π.2.9. Υπορουτίνα **deviderand.m**

1. Σκοπός

Προορίζεται για τον τυχαίο διαχωρισμό των δεδομένων για τις φάσεις εκπαίδευσης, επαλήθευσης και δοκιμής.

2. Κάλεσμα

- `net.divideFcn = 'dividerand';`

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
net.divideFcn	real	Εισαγωγή στην δομή του δικτύου τα δεδομένα που εισήχθησαν χωρισμένα κατά τυχαίο τρόπο σε τρεις κατηγορίες

Π.2.10. Υπορουτίνα `trainlm.m`

1. Σκοπός

Προορίζεται για την εκπαίδευση του δικτύου με βάση την μέθοδο Levenberg-Marquardt backpropagation.

2. Κάλεσμα

- `net.trainFcn = 'trainlm';`

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
<code>net.trainFcn</code>	real	Εισαγωγή στην δομή του δικτύου της μεθόδου εκπαίδευσης

Π.2.11. Υπορουτίνα `trainbfg.m`

1. Σκοπός

Προορίζεται για την εκπαίδευση του δικτύου με βάση την μέθοδο BFGS quasi-Newton backpropagation.

2. Κάλεσμα

- `net.trainFcn = 'trainbfg';`

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
<code>net.trainFcn</code>	real	Εισαγωγή στην δομή του δικτύου του είδους του σφάλματος που θα υπολογιστεί

Π.2.12. Υπορουτίνα `purelin.m`

1. Σκοπός

Προορίζεται για τον ορισμό της συνάρτησης μεταφοράς με βάσει την γραμμική συνάρτηση μεταφοράς `purelin`.

2. Κάλεσμα

- `net.layers{2}.transferFcn='purelin';`

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
<code>purelin</code>	function	Γραμμική συνάρτηση μεταφοράς <code>Purelin</code>
<code>net.layers{2}.transferFcn</code>	real	Ορισμός στρώματος εφαρμογής της συνάρτησης στο δίκτυο

Π.2.13. Υπορουτίνα tansig.m

1. Σκοπός

Προορίζεται για τον ορισμό της συνάρτησης μεταφοράς με βάση την υπερβολική εφαπτόμενη συνάρτηση μεταφοράς tansig.

2. Κάλεσμα

- `net.layers{2}.transferFcn='tansig';`

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
tansig	function	Υπερβολική εφαπτόμενη συνάρτηση μεταφοράς
net.layers{2}.transferFcn	real	Ορισμός στρώματος εφαρμογής της συνάρτησης στο δίκτυο

Π.2.14. Υπορουτίνα mse.m

1. Σκοπός

Προορίζεται για τον υπολογισμό του μέσου τετραγωνικού σφάλματος μεταξύ των επιθυμητών εξόδων και των εξόδων που προέκυψαν από την εκπαίδευση και δοκιμή.

2. Κάλεσμα

- `net.performFcn = 'mse';`

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
mse	function	Υπολογισμός mse
net.performFcn	real	Ορισμός μεθόδου υπολογισμού που θα χρησιμοποιήσει το δίκτυο

Π.2.15. Υπορουτίνα train.m

1. Σκοπός

Προορίζεται για την εκπαίδευση και δοκιμή του δικτύου με βάση της παραμέτρους που ορίστηκαν από τις προηγούμενες υπορουτίνες.

2. Κάλεσμα

- `[net,tr] = train(net,inputs,targets);`

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
net	real	Περιλαμβάνει τις παραμέτρους εκπαίδευσης
inputs	real	Πίνακας εισόδων δικτύου
targets	real	Πίνακας επιθυμητών εξόδων δικτύου
net	real	Επιστροφή: περιλαμβάνει τις πληροφορίες εκπαίδευσης
tr	real	Επιστροφή: πλήθος πινάκων που περιλαμβάνουν τα αποτελέσματα εκπαίδευσης

Π.2.16. Υπορουτίνα gsubtract.m

1. Σκοπός

Προορίζεται για τον υπολογισμό τις διαφορές μεταξύ δύο πινάκων

2. Κάλεσμα

- errors = gsubtract(targets,outputs);

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
targets	real	Πίνακας με τις αδιαστατοποιημένες επιθυμητές τιμές εξόδου
outputs	real	Πίνακας με τις τιμές εξόδου του δικτύου
errors	real	Πίνακας με τις διαφορές των τιμών των πινάκων targets και outputs

Π.2.17. Υπορουτίνα perform.m

1. Σκοπός

Προορίζεται για τον υπολογισμό της απόδοσης του νευρωνικού δικτύου, δηλαδή τα σφάλματα εκπαίδευσης, επαλήθευσης και δοκιμής.

2. Κάλεσμα

- performance = perform(net,targets,outputs);

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
net	real	Περιλαμβάνει τις παραμέτρους εκπαίδευσης
targets	real	Πίνακας επιθυμητών εξόδων δικτύου
outputs	real	Πίνακας εξόδων δικτύου
performance	real	Επιστροφή: των σφαλμάτων εκπαίδευσης

Π.2.18. Υπορουτίνα regression.m

1. Σκοπός

Προορίζεται για τον υπολογισμό της γραμμικής συσχέτισης μεταξύ εξόδων και επιθυμητών εξόδων του δικτύου.

2. Κάλεσμα

- `[r,m,b]=regression(targets,outputs,'one');`

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
targets	real	Πίνακας επιθυμητών εξόδων δικτύου
outputs	real	Πίνακας εξόδων δικτύου
r	real	Επιστροφή: αποτελέσματος συσχέτισης μεταξύ των επιθυμητών εξόδων και των εξόδων του δικτύου
m	real	Επιστροφή: συντελεστής συσχέτισης της εξίσωσης $Output \cong m \cdot Target + b$
b	real	Επιστροφή: συντελεστής συσχέτισης της εξίσωσης $Output \cong m \cdot Target + b$

Π.2.19. Υπορουτίνα plotouttar.m

1. Σκοπός

Προορίζεται για την δημιουργία διαγράμματος μεταξύ τιμών εισόδου κι τιμών εξόδου (τιμών επιθυμητών εξόδων και εξόδων δικτύου), αφού πρώτα έχει μετατρέψει τα αδιαστατοποιημένα στοιχεία στην αρχική τους μορφή.

2. Κάλεσμα

- `plotouttar(inputs,outputs,targets,LSS,A,B,C,D)`

ΣΥΜΒΟΛΟ	ΤΥΠΟΣ	ΣΧΟΛΙΑ
inputs	real	Πίνακας εισόδων δικτύου
targets	real	Πίνακας επιθυμητών εξόδων δικτύου
outputs	real	Πίνακας εξόδων δικτύου
A	real	Παράμετρος αδιαστατοποίησης της <code>adiast1.m</code>
B	real	Παράμετρος αδιαστατοποίησης της <code>adiast1.m</code>
C	real	Παράμετρος αδιαστατοποίησης της <code>adiast0.m</code>
D	real	Παράμετρος αδιαστατοποίησης της <code>adiast0.m</code>
LSS	real	Πλήθος των κόμβων στο κρυφό στρώμα

Π.3 Χαρακτηριστικά ηλεκτρονικού υπολογιστή

Όπως αναφέρθηκε και στην ενότητα 4.3, ο χρόνος εκτέλεσης του αλγορίθμου εξαρτάται άμεσα από τις δυνατότητες του υπολογιστικού μηχανήματος. οπότε και ο χρόνος εκτέλεσης που δόθηκε στις προηγούμενες μοντελοποιήσεις, αποσκοπούσε μόνο στην συγκριτικής μελέτης των συνδυασμών εκπαίδευσης. Συνεπώς, κρίνεται σκόπιμο η αναφορά των χαρακτηριστικών του η ηλεκτρονικού υπολογιστή, αφού όλα τα αποτελέσματα διεξήχθησαν από τον ίδιο υπολογιστή.

Χαρακτηριστικά ηλεκτρονικού υπολογιστή	
Επεξεργαστής	Intel Core I3 - 3220 3.30G LGA1155
Μνήμη	Kingston HX DDR3 4GB @ 1600MHz
Μητρική	Asus P8B75-M LE
Δίσκος	SSD Kingston V+200 120GB
Τροφοδοτικό	Aerocool 450W VP450


Κατά την φάση της εκπαίδευσης και δοκιμής, για να επιτευχθεί η απαιτούμενη ακρίβεια των μετρήσεων του χρόνου, δεν εκτελούνταν καμία άλλη εφαρμογή, ενώ όλα τα προγράμματα (π.χ. antivirus) καθώς και άλλες διεργασίες (π.χ. αυτόματες ενημερώσεις), απενεργοποιήθηκαν.

Οι θερμοκρασίες λειτουργίας σημαντικών τμημάτων της λειτουργίας του αλγορίθμου, ήταν σταθερές και ίδιες για όλους τους.


Θερμοκρασία τμημάτων Η/Υ κατά την λειτουργία των αλγορίθμων	
Επεξεργαστής	31°C
Μητρική	33 °C
Δίσκος	29 °C

Οι τιμές των θερμοκρασιών δόθηκαν, διότι οι επιδόσεις ενός ηλεκτρονικού υπολογιστή μεταβάλλονται και από την αναπτυσσόμενη θερμοκρασία.

Π.4 Φωτογραφίες δοκιμαστηρίου




Εικόνα Π-1: Γενική άποψη πειραματικής διάταξης και δοκιμαστηρίου.




Εικόνα Π-2: Γενική άποψη πειραματικής διάταξης και δοκιμαστηρίου




Εικόνα Π-3: Το δοκιμαστήριο εν ώρα λειτουργίας.




Εικόνα Π-4: Ο κινητήρας με τα μετρικά όργανα (μπροστινή όψη).



Εικόνα Π-5: Ο κινητήρας με τα μετρικά όργανα (πλαϊνή όψη).



Εικόνα Π-6: Κυψελίδα φόρτισης και βάση του κινητήρα.



Εικόνα Π-7: Η βάση στήριξης του κινητήρα.