



**ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ**  
TECHNICAL UNIVERSITY OF CRETE

**ΣΧΟΛΗ ΧΗΜΙΚΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΠΕΡΙΒΑΛΛΟΝΤΟΣ**

**“ΑΞΙΟΠΟΙΗΣΗ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΓΙΑ ΤΗΝ ΕΚΤΙΜΗΣΗ  
ΤΗΣ ΑΠΟΔΟΣΗΣ ΕΝΟΣ ΣΥΣΤΗΜΑΤΟΣ ΑΝΤΛΙΩΝ ΘΕΡΜΟΤΗΤΑΣ ΕΝΤΟΣ  
ΜΙΑΣ ΠΤΗΝΟΤΡΟΦΙΚΗΣ ΕΓΚΑΤΑΣΤΑΣΗΣ”**

**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**

**Αλέξανδρος Χάχαλης**

**ΤΡΙΜΕΛΗΣ ΕΠΙΤΡΟΠΗ**

Καθηγητής Καρατζάς Γεώργιος (Επιβλέπων)

Καθηγητής Νικολαΐδης Νικόλαος

Αναπληρωτής Καθηγητής Μανωλάκος Δημήτριος (Γεωπονικό Πανεπιστήμιο Αθηνών)

**XANIA, 2023**

**Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για μη κερδοσκοπικό σκοπό, εκπαιδευτικού ή ερευνητικού χαρακτήρα, με την προϋπόθεση να αναφέρεται η πηγή προέλευσης. Ερωτήματα που αφορούν τη χρήση της εργασίας για άλλη χρήση θα πρέπει να απευθύνονται προς το συγγραφέα. Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Πολυτεχνείου Κρήτης.**

## Περίληψη

Στα πλαίσια της παρούσας διπλωματικής εργασίας, αξιοποιούνται και εκπαιδεύονται τεχνητά νευρωνικά δίκτυα (ΤΝΔ) για την εκτίμηση του συντελεστή απόδοσης (COP) του συστήματος αντλιών θερμότητας εντός μιας πτηνοτροφικής εγκατάστασης. Το σύστημα αντλιών θερμότητας αξιοποιείται για την κάλυψη των θερμικών αναγκών της πτηνοτροφικής εγκατάστασης που στεγάζει 10000 νεαρά πουλερικά (broilers) στην περιοχή της Καβάλας.

Τα σχεδιαζόμενα τεχνητά νευρωνικά δίκτυα προσομοιώνουν τον συντελεστή απόδοσης (COP) της αντλίας θερμότητας που χρησιμοποιείται σε κάθε περίπτωση για θέρμανση, ψύξη και αφύγρανση. Ο σχεδιασμός των ΤΝΔ ξεκινά χρησιμοποιώντας τα δεδομένα που λήφθηκαν από τους *Tyris et.al, 2023*, οι οποίοι σχεδίασαν και μελέτησαν το σύστημα αντλιών θερμότητας, και περιλαμβάνουν τιμές για την εσωτερική θερμοκρασία και σχετική υγρασία εντός της εγκατάστασης, το θερμικό φορτίο των ζώων καθώς και τις τιμές του COP που υπολόγισε το δυναμικό μοντέλο τους. Αρχικά, δημιουργήθηκαν ο πίνακας εισόδου και το διάνυσμα στόχου, τα οποία αξιοποιεί το ΤΝΔ για την εκπαίδευση του. Ο πίνακας εισόδου αποτελείται από τα δεδομένα εσωτερικής θερμοκρασίας και σχετικής υγρασίας εντός της εγκατάστασης καθώς και το θερμικό φορτίο των ζώων. Επιπλέον, για την ταχύτερη σύγκλιση του ΤΝΔ πραγματοποιήθηκε προεπεξεργασία με κανονικοποίηση των δεδομένων εισόδου με την μέθοδο Z-score standardization. Το διάνυσμα στόχου, περιέχει τις προσομοιωμένες τιμές του συντελεστή απόδοσης που εκτίμησε το δυναμικό μοντέλο των *Tyris et.al, 2023*. Τα παραπάνω δεδομένα βάσει των οποίων εκπαιδεύονται τα ΤΝΔ αφορούν τις περιόδους (διάρκειας 35 ημερών) του χειμώνα (1/1- 5/2) και του καλοκαιριού (31/5-5/7) και περιλαμβάνουν για κάθε περίοδο 50400 τιμές καθώς το χρονικό βήμα μεταξύ μετρήσεων-δεδομένων είναι 1 λεπτό.

Ολοκληρώνοντας την προεπεξεργασία των δεδομένων εισόδου, πραγματοποιήθηκε η εκπαίδευση των ΤΝΔ με το εργαλείο Neural Fitting Tool (nftool) της Matlab και ο αλγόριθμος εκπαίδευσης που χρησιμοποιήθηκε ήταν ο Levenberg-Marquardt (LMA). Η εκπαίδευση των ΤΝΔ έλαβε χώρα για διαφορετικές παραμέτρους σε κάθε δοκιμή/προσομοίωση αυξάνοντας των αριθμός των κρυφών κόμβων ή αλλάζοντας τα ποσοστά εκπαίδευσης.

Στόχος της εκπαίδευσης των νευρωνικών δικτύων είναι η εύρεση του μοντέλου και των παραμέτρων του που δίνουν τα βέλτιστα αποτελέσματα με κριτήρια επιλογής αυτών την τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) και τον συντελεστή συσχέτισης(R). Συγκεκριμένα, είναι επιθυμητό το RMSE να είναι το ελάχιστο ενώ το R το μέγιστο μεταξύ των επιλεγμένων κρυφών κόμβων και ποσοστών εκπαίδευσης.

Στην συγκεκριμένη διπλωματική εργασία τα ΤΝΔ εκπαιδεύονται για την λειτουργία του συστήματος αντλιών θερμότητας κατά τις περιόδους του χειμώνα και του καλοκαιριού όπου λειτουργεί η θέρμανση και η ψύξη αντίστοιχα ενώ σε αμφότερες τις περιόδους χρησιμοποιείται και η αφύγρανση.

Από τα διαγράμματα διασποράς εξάγεται το συμπέρασμα ότι τα νευρωνικά δίκτυα δεν μπορούν να εκτιμήσουν κάποιες μεμονωμένες τιμές (outliers) χωρίς όμως αυτό να επηρεάζει τις τιμές του συντελεστή συσχέτισης. Συνολικά, ο αλγόριθμος Levenberg-Marquardt παρουσίασε πολύ ικανοποιητικά αποτελέσματα, για όλες τις περιόδους και θερμικές λειτουργίες, παρουσιάζοντας τιμές της τάξεως  $10^{-2}$  και 0.999 για σφάλματα RMSE και συντελεστή συσχέτισης, αντίστοιχα.

## Abstract

In the context of this thesis, the utilization and training of artificial neural networks is examined to simulate the coefficient of performance (COP) of a heat pump (HP) system inside a broiler house. The heat pump system aims to cover the thermal needs of the broiler house that is located in Kavala and is housing a total of 10000 broilers.

Artificial neural networks simulate the coefficient of performance of the heat pump being utilized for heating, cooling and dehumidifying each time. As a first step, the dataset being used to design the ANN is provided by *Tyris et.al*, 2023, the research team that designed and studied the heat pump system, and includes values of indoor temperature and relative humidity, broilers' thermal loads as well as the simulated values of COP that their dynamic model calculated. Initially, the input table and the target vector which the ANN utilizes for training, were created. The input table consists of the indoor temperature and relative humidity data within the facility as well as the heat load of the animals. In addition, for faster convergence of the ANN, preprocessing was performed by normalizing the input data using the Z-score standardization method. The target vector, contains the simulated values of the coefficient of performance estimated by the dynamic model of *Tyris et.al*, 2023. The above data on which the ANN are trained cover the periods (35 days duration) of winter (1/1- 5/2) and summer (31/5-5/7) and include 50400 values for each period as the time step between data is 1 minute.

After completing the preprocessing of the input data, the training of the ANN was performed using Matlab's Neural Fitting Tool (nftool) and the training algorithm used was Levenberg-Marquardt (LMA). Training of the ANN took place for different parameters in each test/simulation by increasing the number of hidden nodes or changing the training percentages.

The objective of neural network training is to find the model and its parameters that give the optimal results with the selection criteria of these being the root mean square error (RMSE) and the correlation coefficient (R). More specifically, it is desirable that RMSE is the minimum and R is the maximum among the selected hidden nodes and training percentages.

In this thesis, the ANN are trained for the operation of the heat pump system during the winter and summer periods when heating and cooling are used respectively, while in both periods dehumidification is also used.

From the presented regression plots, it is concluded that the neural networks cannot estimate only a minimal number of individual values (ouliers), that have a very negligible effect on the values of the correlation coefficient. Overall, the Levenberg-Marquardt algorithm showed very satisfactory results, for all periods and thermal modes, showing values of  $10^{-2}$  and 0.999 for RMSE and correlation coefficient, respectively.

## Ευχαριστίες

Με την εκπόνηση της παρούσας διπλωματικής εργασίας θα ήθελα να ευχαριστήσω θερμά, πρωτίστως ,τον καθηγητή κ. Γεώργιο Καρατζά για την πολύτιμη καθοδήγηση και τις στοχευμένες παρατηρήσεις του.

Επιπλέον , θα ήθελα να ευχαριστήσω τον αναπληρωτή καθηγητή κ. Δημήτριο Μανωλάκο που ανέλαβε να με υποστηρίξει και να μου παρέχει τα απαραίτητα δεδομένα για τις αντλίες θερμότητας τα οποία αξιοποίησα για την εκπαίδευση των τεχνητών νευρωνικών δικτύων.

Πολύτιμη επίσης υπήρξε η βοήθεια του Δημήτρη Τύρη, διδακτορικού φοιτητή του κ. Μανωλάκου, ο οποίος με καθοδήγησε και μου παρείχε τόσο το σετ δεδομένων όσο και τις απαραίτητες υποδείξεις για την κατανόηση του.

Οφείλω ιδιαίτερες ευχαριστίες στον Ηλία Λάνδρο που με βοήθησε να κατανοήσω την λειτουργία των τεχνητών νευρωνικών δικτύων και να τα αξιοποιήσω για το συγκεκριμένο πρόβλημα.

Επίσης θα ήθελα να ευχαριστήσω θερμά την τριμελή επιτροπή που διέθεσαν χρόνο για την διόρθωση και την βελτίωση της διπλωματικής εργασίας.

Ολοκληρώνοντας, θα ήθελα να ευχαριστήσω από καρδιάς τα αδέρφια μου, την κοπέλα μου και ιδίως τους γονείς μου για την αμέριστη και πολύτιμη στήριξη τους που υπήρξε καταλυτική για την απόκτηση του διπλώματος του Μηχανικού Περιβάλλοντος.

## Περιεχόμενα

Κεφάλαιο 1 .....	13
Εισαγωγή.....	13
Κεφάλαιο 2.....	20
Θεωρητικό Υπόβαθρο.....	20
2.1 Ανθρώπινος εγκέφαλος.....	20
2.1.1 Νευρώνας: Το θεμέλιο ενός νευρωνικού δικτύου.....	20
2.2 Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ) .....	21
2.2.1 Multi-Layer Perceptrons .....	23
2.3 Συναρτήσεις ενεργοποίησης .....	23
2.3.1 Σιγμοειδής Συνάρτηση .....	24
2.3.2 Ανορθωμένη Γραμμική ή Συνάρτηση Ράμπας (ReLU) .....	24
2.3.3 Υπερβολική Συνάρτηση Εφαπτομένης (tanh).....	25
2.4 Αλγόριθμος εκπαίδευσης Levenberg-Marquardt.....	26
2.5 Κριτήρια Αξιολόγησης .....	28
2.6 Πλεονεκτήματα ΤΝΔ.....	29
2.7 Πρόωρη Διακοπή(Early Stopping).....	32
2.8 Πόλωση- Μεροληψία (Bias) .....	33
2.9 Υπερπροσαρμογή (Overfitting) .....	34
ΚΕΦΑΛΑΙΟ 3 .....	36
ΑΝΤΛΙΑ ΘΕΡΜΟΤΗΤΑΣ ΚΑΙ ΔΕΔΟΜΕΝΑ.....	36
3.1 Δυναμικό Μοντέλο Αντλίας Θερμότητας (ΑΘ).....	36
3.2 Ζώα και Εγκατάσταση.....	37
3.3 Σημεία Ρύθμισης (Setpoints) .....	37
3.4 Εσωτερική θερμοκρασία και σχετική υγρασία.....	38
3.5 Θερμικά Φορτία Ζώων .....	39
3.6 (Εποχικοί) Συντελεστές απόδοσης (COP/EER).....	41
ΚΕΦΑΛΑΙΟ 4 .....	43
Μεθοδολογία για το Νευρωνικό Δίκτυο.....	43
4.1 Δημιουργία μεταβλητών εισόδου/εξόδου .....	45
4.2 Βήματα εκπαίδευσης νευρωνικών δικτύων το Neural Fitting tool.....	46
Κεφάλαιο 5.....	50
Αποτελέσματα.....	50
5.1 Προκαθορισμένα ποσοστά εκπαίδευσης,ελέγχου και επικύρωσης.....	50
5.1.1 Χειμερινή Περίοδος (PP1) .....	50

5.1.2 Καλοκαιρινή Περίοδος (PP4).....	70
5.2 Μεταβλητά Ποσοστά εκπαίδευσης, ελέγχου και επικύρωσης .....	88
5.2.1 Χειμερινή Περίοδος .....	88
5.2.2 Καλοκαιρινή Περίοδος.....	96
Κεφάλαιο 6.....	104
Συζήτηση .....	104
Κεφάλαιο 7 .....	107
Συμπεράσματα.....	107
Βιβλιογραφία.....	108

## Κατάλογος Πινάκων

Πίνακας 1: Μέσες τιμές συντελεστών απόδοσης και λόγων εποχικής ενεργειακής απόδοσης (Tyriss et al.,2023) .....	17
Πίνακας 2: Παράμετροι Αλγορίθμου LM και προκαθορισμένες τιμές τους( <a href="https://www.mathworks.com/help/deeplearning/ref/trainlm.html">https://www.mathworks.com/help/deeplearning/ref/trainlm.html</a> ) .....	27
Πίνακας 3: Συντελεστές για υπολογισμό μάζας ζώων (Tyriss et al.,2023) .....	40
Πίνακας 4: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt.....	58
Πίνακας 5: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης(R).....	58
Πίνακας 6: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE).....	59
Πίνακας 7: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt.....	68
Πίνακας 8: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R .....	68
Πίνακας 9: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE).....	69
Πίνακας 10: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt.....	77
Πίνακας 11: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R .....	77
Πίνακας 12: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE). .....	78
Πίνακας 13: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt.....	86
Πίνακας 14: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R .....	86
Πίνακας 15: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE). .....	87
Πίνακας 16: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt με διαφορετικά ποσοστά (percentages).....	91
Πίνακας 17: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R .....	91
Πίνακας 18: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE). .....	91
Πίνακας 19: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt με διαφορετικά ποσοστά (percentages).....	95



Πίνακας 20: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R .....	95
Πίνακας 21: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE). ....	95
Πίνακας 22: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt με διαφορετικά ποσοστά (percentages).....	99
Πίνακας 23: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R .....	99
Πίνακας 24: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE). ....	99
Πίνακας 25 : Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt με διαφορετικά ποσοστά (percentages).....	103
Πίνακας 26: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R .....	103
Πίνακας 27: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE). ....	103

## Κατάλογος Διαγραμμάτων

[illegible]



## Κατάλογος Εικόνων

Εικόνα 1.1 : Μια ΑΘ αποσκοπεί στην παροχή θερμότητας QH στον θερμαινόμενο χώρο (Cengel & Boles.(2018),Θερμοδυναμική για Μηχανικούς).....	14
Εικόνα 1.2: Διάταξη μιας αντλίας θερμότητας (Cengel & Boles.(2018), Θερμοδυναμική για Μηχανικούς) .....	15
Εικόνα 2.3: Σχηματική απεικόνιση του ανθρώπινου νευρικού συστήματος (S.Haykin, Neural Networks and learning machines ,1999) .....	20
Εικόνα 2.4: Απεικόνιση στρωμάτων ενός νευρωνικού δικτύου του ανθρώπινου φλοιού (Lopez,O.A.M.,Lopez,A.M.,&Crossa,J.(2022),Fundamentals of Artificial Neural Networks and Deep Learning) .....	21
Εικόνα 2.5: Γενικό μοντέλο ενός τεχνητού νευρώνα (López, O. A. M., López, A. M., & Crossa, J. (2022, January 1). Fundamentals of Artificial Neural Networks and Deep Learning) .....	22
Εικόνα 2.6: Αναπαράσταση της σιγμοειδούς συνάρτησης ενεργοποίησης (López, O. A. M., López, A. M., & Crossa, J. (2022, January 1). Fundamentals of Artificial Neural Networks and Deep Learning) .....	24
Εικόνα 2.7: Αναπαράσταση της συνάρτησης ενεργοποίησης ReLu (López, O. A. M., López, A. M., & Crossa, J. (2022, January 1). Fundamentals of Artificial Neural Networks and Deep Learning) .....	25
Εικόνα 2.8: Αναπαράσταση της συνάρτησης ενεργοποίησης tanh (López, O. A. M., López, A. M., & Crossa, J. (2022, January 1). Fundamentals of Artificial Neural Networks and Deep Learning) .....	26
Εικόνα 2.9: Αναπαράσταση της μεθόδου πρόωρης διακοπής (S.Haykin, Neural networks and learning machines,1999) .....	33
Εικόνα 2.10: Η πόλωση μετατοπίζει οριζόντια την συνάρτηση ενεργοποίησης (Βλαχάβας, Κεφαλάς, Κόκκορας, & Σακελλαρίου. (2020, June). <i>Τεχνητή Νοημοσύνη</i> (4η)).....	34
Εικόνα 2.11 : Διάφορα επίπεδα προσαρμογής με βάση τα ίδια δεδομένα εκπαίδευσης (Βλαχάβας, Κεφαλάς, Κόκκορας, & Σακελλαρίου. (2020, June). <i>Τεχνητή Νοημοσύνη</i> (4η)) .....	35
Εικόνα 3.12 : Διάγραμμα Ροής (Flowchart) του μοντέλου ( <i>Tyris et al.,2023</i> ).....	37
Εικόνα 3.13 : Μεταβολές σχετικής υγρασίας και εσωτερικής θερμοκρασίας κατά την 1 <sup>η</sup> περίοδο παραγωγής (01.01-05.02) ( <i>Tyris et al.,2023</i> ) .....	39
Εικόνα 3.14: Μεταβολές σχετικής υγρασίας και εσωτερικής θερμοκρασίας κατά την 4 <sup>η</sup> περίοδο παραγωγής (31.05-05.07) ( <i>Tyris et al.,2023</i> ) .....	39
Εικόνα 3.15 : Μάζα (kg) και θερμικά φορτία (kW)των ζώων συναρτήσει του χρόνου (ημέρες) κατά την περίοδο παραγωγής PP1 ( <i>Tyris et al.,2023</i> ).....	40
Εικόνα 3.16: Μάζα (kg) και θερμικά φορτία (kW)των ζώων συναρτήσει του χρόνου (ημέρες) κατά την περίοδο παραγωγής PP4 ( <i>Tyris et al.,2023</i> ).....	41
Εικόνα 3.17: Διακύμανση της θερμοχωρητικότητας και του συντελεστή απόδοσης (COP) μεταξύ του δυναμικού μοντέλου και της αναμενόμενης απόδοσης του συμπιεστή ( <i>Tyris et al.,2023</i> ).....	42
Εικόνα 4.18: Στιγμιότυπο από το Workspace της Matlab που περιλαμβάνει τις απαραίτητες μεταβλητές (θέρμανση κατά τον χειμώνα, περίοδος PP1).....	45

## Κεφάλαιο 1

### Εισαγωγή


Ο σκοπός της παρούσας διπλωματικής εργασίας είναι η αξιοποίηση και η εξοικείωση με τα τεχνητά νευρωνικά δίκτυα (ΤΝΔ) ,τα οποία αποτελούν κλάδο της Μηχανικής Μάθησης (Machine Learning). Τα ΤΝΔ ,ή αλλιώς Artificial Neural Networks (ANN), αποτελούν υπολογιστικά μοντέλα τα οποία αξιοποιούν δεδομένα εισόδου και εξόδου σχηματίζοντας συσχετίσεις μεταξύ αυτών. Στην συγκεκριμένη περίπτωση τα Τεχνητά Νευρωνικά Δίκτυα χρησιμοποιούνται για την εκτίμηση του συντελεστή απόδοσης (COP) του συστήματος των αντλιών θερμότητας εντός μιας πτηνοτροφικής εγκατάστασης στην περιοχή της Καβάλας. Τα δεδομένα εισόδου προέρχονται από τις μετρήσεις και την επεξεργασία που πραγματοποίησε η ερευνητική ομάδα που μελέτησε και σχεδίασε το σύστημα αντλιών θερμότητας. Η εκπαίδευση του τεχνητού νευρωνικού δικτύου πραγματοποιείται βάσει αυτών των δεδομένων και των προσομοιωμένων τιμών του COP που υπολογίζει το δυναμικό μοντέλο της ερευνητικής ομάδας. Ο αλγόριθμος εκπαίδευσης που επιλέχθηκε είναι ο Levenberg-Marquardt και αποσκοπεί στην εκτίμηση του συντελεστή απόδοσης με το ελάχιστο δυνατό σφάλμα. Τα νευρωνικά δίκτυα αξιολογούνται βάσει του μέσου τετραγωνικού σφάλματος και του συντελεστή συσχέτισης και με αυτόν τον τρόπο επιλέγονται οι βέλτιστες παράμετροι εκπαίδευσης.

Η αντλία θερμότητας (ΑΘ), όπως απεικονίζεται στην **Εικόνα 1.1**, πρόκειται για μία συσκευή που μεταφέρει θερμότητα από ένα μέσο χαμηλής θερμοκρασίας προς κάποιο άλλο υψηλής.

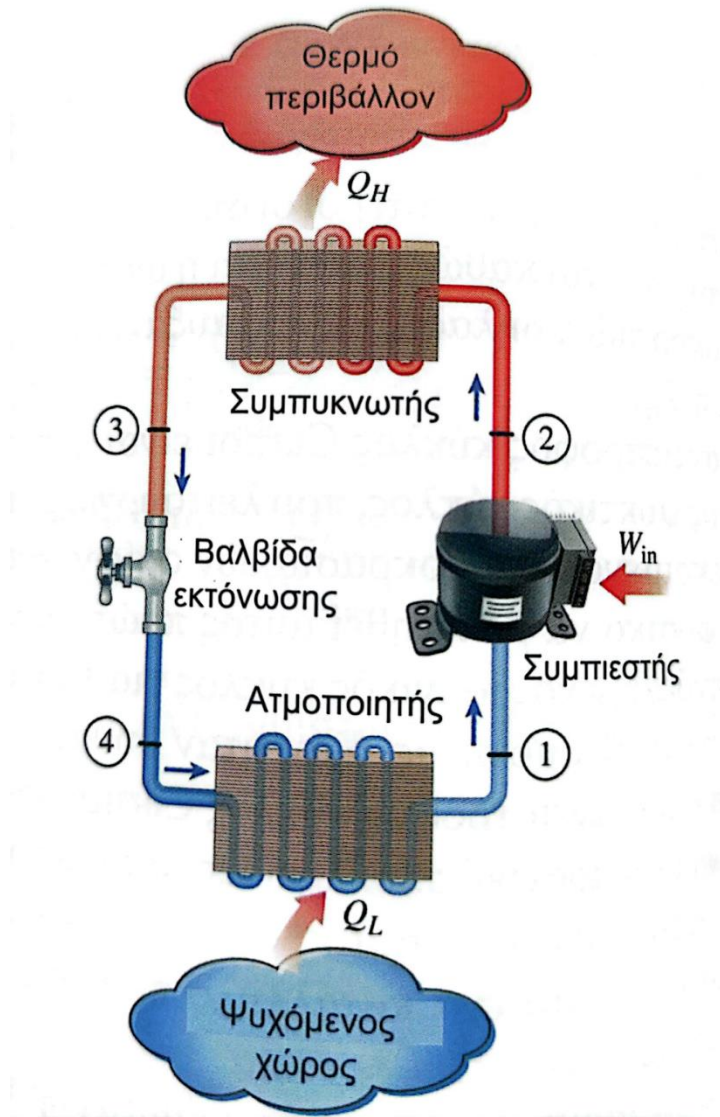
Βασικός στόχος αποτελεί η διατήρηση ενός θερμαινόμενου χώρου σε υψηλή θερμοκρασία, το οποίο επιτυγχάνεται απορροφώντας θερμότητα από μια πηγή χαμηλής θερμοκρασίας, όπως είναι νερό φρεάτων ή ψυχρός αέρας του περιβάλλοντος, και η παροχή της θερμότητας αυτής στο μέσο υψηλής θερμοκρασίας, όπως μια οικία ή εγκατάσταση.

Η διάταξη της ΑΘ ,όπως παρουσιάζεται στην **Εικόνα 1.2** , απαρτίζεται από το ψυκτικό υγρό, τον εξατμιστή (ή ατμοποιητή) , τον συμπιεστή , τον συμπυκνωτή και την βαλβίδα εκτόνωσης . Το πρώτο είναι το ρευστό που ρέει εντός του συστήματος και απορροφά θερμότητα μέσω της εξάτμισης σε χαμηλή πίεση και θερμοκρασία από τον εξατμιστή εκλύοντας την μέσω συμπύκνωσης σε υψηλή θερμοκρασία και πίεση στον συμπυκνωτή. Ένα εκ των πιο διαδεδομένων ψυκτικών υγρών είναι το R134a το οποίο και χρησιμοποιήθηκε στην λειτουργία των αντλιών θερμότητας από τους *Tyris et,al.* 2023. Ο εξατμιστής αποτελεί έναν εναλλάκτη θερμότητας για μεταφορά αυτής από τον πηγή θερμότητας στο ψυκτικό υγρό. Πιο συγκεκριμένα, το ψυχρό ψυκτικό υγρό απορροφά θερμότητα από μια πηγή χαμηλής θερμοκρασίας και πραγματοποιείται βρασμός του. Ακολουθεί ο συμπιεστής εντός του οποίου το υπέρθερμο αέριο που έχει εξέλθει από τον εξατμιστή συμπιέζεται οδηγώντας σε αύξηση της θερμοκρασίας και της πίεσης του. Στην συνέχεια , αυτό το θερμό συμπιεσμένο αέριο εισέρχεται στον συμπυκνωτή ώστε να μεταφερθεί θερμότητα στον αποδέκτη (νερό ή αέρας). Τέλος, το ψυκτικό υγρό διέρχεται μέσα από την βαλβίδα εκτόνωσης η οποία ρυθμίζει την ροή του από τον συμπυκνωτή στον εξατμιστή [Μαλαματένιος,2014].

Οι ΑΘ ανάλογα με την πηγή ενέργειας που αξιοποιούν διακρίνονται σε γεωθερμικές (ground source heat pumps, GSHP) , αέρος (air source,ASHP) , νερού (water source) και απαερίων (exhaust air heat pump,EAHP). Μεταξύ αυτών πιο διαδεδομένη είναι η ASHP η οποία συνήθως καταλαμβάνει μικρότερο χώρο και χρησιμοποιείται για την κάλυψη οικιακών αναγκών.



Εικόνα 1.1 : Μια ΑΘ αποσκοπεί στην παροχή θερμότητας  $Q_H$  στον θερμαινόμενο χώρο (Cengel & Boles.(2018),Θερμοδυναμική για Μηχανικούς)



Εικόνα 1.2: Διάταξη μιας αντλίας θερμότητας (Cengel & Boles.(2018), Θερμοδυναμική για Μηχανικούς)

Ο βαθμός απόδοσης μιας ΑΘ (**Εξίσωση 1.1**) γενικότερα αποτελεί τον λόγο της επιθυμητής ενέργειας εξόδου που παρέχει στον αποδέκτη προς την απαιτούμενη ενέργεια εισόδου για την επίτευξη αυτής. Για την λειτουργία της θέρμανσης η ωφέλιμη ενέργεια ταυτίζεται με την ενέργεια που παρέχεται στο θερμαινόμενο χώρο ( $Q_H$ ) ενώ για την ψύξη με την ενέργεια που αφαιρείται από τον ψυχόμενο χώρο ( $Q_C$ ). Ο βαθμός απόδοσης για τις λειτουργίες της θέρμανσης ( $COP_{HP}$ ) και της ψύξης ( $COP_R$ ) δίνεται από τις **Εξισώσεις 1.2 και 1.3** αντίστοιχα.

$$COP = \frac{\text{επιθυμητή έξοδος}}{\text{απαιτούμενη έξοδος}} = \frac{Q_H}{W_{net,in}} \quad (1.1)$$

$$COP_{HP} = \frac{Q_H}{W} \quad (1.2)$$

$$COP_R = \frac{Q_C}{W} \quad (1.3)$$

Κατά την χειμερινή περίοδο η πλειονότητα των ΑΘ χρησιμοποιεί ως πηγή θερμότητας τον εξωτερικό ψυχρό αέρα και αναφέρονται ως *αντλίες θερμότητας αέρα* με τιμή COP περίπου 3. Σε περιπτώσεις ιδιαίτερα ψυχρών κλιμάτων προτιμάται η χρήση γεωθερμικών αντλιών θερμότητας (εδάφους) χρησιμοποιώντας το έδαφος ως πηγή θέρμανσης. Τέτοιες αντλίες είναι περισσότερο αποδοτικές εμφανίζοντας συντελεστή απόδοσης έως και 6 κατά την λειτουργία της ψύξης. Η αξιολόγηση μιας ΑΘ συγκριτικά με συμβατικά συστήματα θέρμανσης βάσει του συντελεστή COP βασίζεται στα παρακάτω κριτήρια [Ν.Γιαννάκος, 2014] :

- Η ΑΘ είναι ενεργειακά ισοδύναμη με ένα συμβατικό σύστημα θέρμανσης (όπως ο λεβητας αερίου) αν λειτουργεί με βαθμό απόδοσης  $COP=3$ .
- Η ΑΘ είναι ενεργειακά κατώτερη από ένα συμβατικό σύστημα θέρμανσης αν λειτουργεί με βαθμό απόδοσης  $COP<3$ .
- Η ΑΘ είναι ενεργειακά ανώτερη από ένα συμβατικό σύστημα θέρμανσης αν λειτουργεί με βαθμό απόδοσης  $COP>3$ .

Εναλλακτική έκφραση της αποδοτικότητας μιας αντλίας θερμότητας είναι ο *λόγος ενεργειακής απόδοσης* (energy efficiency ratio , EER) ή ο *λόγος εποχικής ενεργειακής απόδοσης* (Seasonal energy efficiency ratio, SEER). Ο συντελεστής SEER αφορά την ποσότητα θερμότητας που απομακρύνεται από μια αντλία θερμότητας κατά την διάρκεια μιας τυπικής περιόδου κλιματισμού (σε Btu) προς την συνολική καταναλισκόμενη ηλεκτρική ενέργεια (σε Wh). Αντίστοιχα , ο συντελεστής EER αφορά στιγμιαία απόδοση και προκύπτει με διαίρεση του ρυθμού απομάκρυνσης θερμότητας από τον ψυχρό χώρο προς τον ρυθμό κατανάλωσης ενέργειας. Είναι επιθυμητό μια ΑΘ να εμφανίζει τιμή SEER μεγαλύτερη του τρία (3) ώστε να συγκαταλέγεται στις ΑΠΕ. Επιπλέον , ο λόγος EER (ή SEER) και συντελεστής απόδοσης ψύξης συνδέονται με την παρακάτω **Εξίσωση 1.4** [Cengel &Boles, 2018]:

$$EER = 3.412 * COP_R \quad (1.4)$$

Στον **Πίνακα 1** παρουσιάζονται ενδεικτικά οι μέσες τιμές συντελεστών απόδοσης και λόγων εποχικής ενεργειακής απόδοσης για όλες τις θερμικές λειτουργίες των περιόδων καλοκαιριού και χειμώνα όπως υπολογίστηκαν από τους *Tyris et al., 2023*.



**Πίνακας 1: Μέσες τιμές συντελεστών απόδοσης και λόγων εποχικής ενεργειακής απόδοσης (Tyrís et al.,2023)**

Period	Mode	Average COP
SUMMER	COOL1	3.89
	COOL2	3.38
	HEAT1	3.32
	DEH_HP1	4.96
	DEH_HP2	4.60
	DEH_HP3	4.61
WINTER	COOL1	5.94
	COOL2	-
	HEAT1	3.11
	DEH_HP1	7.42
	DEH_HP2	6.09
	DEH_HP3	6.34

Τα ΤΝΔ αποτελούν μαθηματικά μοντέλα που χρησιμοποιούν τις αρχές της οργάνωσης και λειτουργίας των βιολογικών νευρωνικών δικτύων για μοντελοποίηση πολύπλοκων μη γραμμικών σχέσεων. Τα ελάχιστα σφάλματα και η ταχύς παράλληλη επεξεργασία που παρέχουν τα ΤΝΔ τα καθιστά ιδανικό εργαλείο μοντελοποίησης της απόδοσης και κατανάλωσης αντλιών θερμότητας.

Μια δημοσίευση των *Esen et al., 2008* αποσκοπούσε στην πρόβλεψη της απόδοσης μιας αντλίας θερμότητας εδάφους (GCHP) μελέτησε την καταλληλότητα των ΤΝΔ για τον σκοπό αυτό. Πιο συγκεκριμένα, τα νευρωνικά δίκτυα εκπαιδεύτηκαν με δεδομένα εισόδου θερμοκρασίες αέρος και εδάφους και δεδομένα εξόδου τον συντελεστή απόδοσης συστήματος (COPS). Με την ολοκλήρωση της εκπαίδευσης, η τιμή του ριζικού μέσου σφάλματος (RMS) ήταν 1%, ο συντελεστής συσχέτισης (R2) ήταν 99.999% και το ποσοστό συντελεστή απόκλισης (COV) 28.62%. Συνεπώς, τα νευρωνικά δίκτυα παρέχουν αξιόπιστα αποτελέσματα για την πρόβλεψη της τιμής COPS για αντλίες θερμότητας.

Στην έρευνα των *Arcaklioğlu et al.,2004* τα τεχνητά νευρωνικά δίκτυα χρησιμοποιήθηκαν για την μελέτη της απόδοσης του εξατμιστή μιας αντλίας

θερμότητας υπολογίζοντας τις τιμές των συντελεστών COP και RE (Rational Efficiency) για διαφορετικές αναλογίες ψυκτικών μειγμάτων R12/R22. Στην εκπαίδευση των δικτύων χρησιμοποιήθηκαν τρεις διαφορετικές εκδοχές του αλγορίθμου οπισθοδρομικής διάδοσης (Back propagation) και λογιστική σιγμοειδής συνάρτηση. Τα ΤΝΔ παρουσίασαν τιμές 0.9999 και 0.006 για R2 και RMS αντίστοιχα συνιστώντας έτσι μια ακριβή μέθοδο πρόβλεψης τιμών COP και RE για την αντλία θερμότητας.

Στην μελέτη των *Puttige et al., 2021* για ένα γεωθερμικού συστήματος θέρμανσης, αποτελούμενο από τρεις ΑΘ, στην Σουηδία, χρησιμοποιήθηκαν μετρήσεις πεδίου για σύγκριση της απόδοσης ΤΝΔ και μοντέλων παλινδρόμησης (regression). Η συγκεκριμένη έρευνα κατέδειξε ότι παρότι τα μοντέλα παλινδρόμησης είναι καταλληλότερα όταν δίνονται δεδομένα μόνο από τον κατασκευαστή, τα ΤΝΔ υπερτερούν όταν είναι διαθέσιμος μεγάλος όγκος πειραματικών δεδομένων. Επιπρόσθετο πλεονέκτημα των ΤΝΔ ήταν η ευελιξία στην επιλογή δεδομένων εισόδου και εξόδου, η οποία προτιμάται σε περιπτώσεις όπου απαιτούνται επιπλέον δεδομένα εισόδου για την μοντελοποίηση μιας ΑΘ.

Στην ανασκόπηση (review) της παρούσας βιβλιογραφίας που συνέταξαν οι *Mohanraj et al., 2012* σχετικά με την εφαρμογή των ΤΝΔ για ανάλυση της ενέργειας και του έργου (exergy) για ψύξη, κλιματισμό και συστήματα ΑΘ (RACHP) εξέτασε πάνω από 90 δημοσιευμένα άρθρα. Το συμπέρασμα της ήταν ότι τα ΤΝΔ μπορούν να χρησιμοποιηθούν επιτυχώς για εφαρμογές RACHP παρουσιάζοντας ικανοποιητική ακρίβεια. Επιπλέον, υβριδικά μοντέλα που χρησιμοποιούν ΤΝΔ συνδυαστικά με έμπειρα συστήματα (expert systems) παρουσιάζουν ακόμα καλύτερη απόδοση.

Τα υπόλοιπα κεφάλαια της παρούσας διπλωματικής οργανώνονται ως εξής: στο Κεφάλαιο 2 παρουσιάζεται το θεωρητικό υπόβαθρο που αφορά τα τεχνητά νευρωνικά δίκτυα και τις ιδιότητες τους.

Στο Κεφάλαιο 3, παρουσιάζονται, εν συντομία τα αποτελέσματα της ερευνητικής ομάδας του Εργαστηρίου Γεωργικής Μηχανολογίας του Γεωπονικού Πανεπιστημίου Αθηνών, τα οποία αξιοποίησα ως δεδομένα για την εκπαίδευση των τεχνητών νευρωνικών δικτύων. Επιπλέον δίνεται μια περιγραφή του πτηνοτροφείου κρεοπαγωγής, τις θερμικές ανάγκες του οποίου πρέπει να καλύψει το σύστημα αντλιών θερμότητας.

Ακολουθεί το Κεφάλαιο 4 όπου παρουσιάζεται η μεθοδολογία της διπλωματικής εργασίας ξεκινώντας με την δημιουργία των μεταβλητών εισόδου (εσωτερική θερμοκρασία, σχετική υγρασία και θερμικά φορτία των ζώων) και εξόδου (συντελεστής απόδοσης αντλίας θερμότητας) και συνεχίζοντας με την εκπαίδευση των νευρωνικών δικτύων με χρήση του εργαλείου Neural Fitting Tool (nftool) της Matlab.

Στο Κεφάλαιο 5 παρουσιάζονται τα αποτελέσματα -σε μορφή πινάκων και διαγραμμάτων διασποράς- των τεχνητών νευρωνικών δικτύων με δοκιμές αυξανόμενου αριθμού κρυφών κόμβων για τις χρονικές περιόδους χειμώνα και καλοκαιριού και για την θέρμανση, την ψύξη και την αφύγρανση που βρίσκονται σε λειτουργία κατά την διάρκεια τους. Σε δεύτερο βήμα, παρουσιάζονται τα αποτελέσματα των νευρωνικών δικτύων χρησιμοποιώντας τον αριθμό κρυφών

κόμβων της βέλτιστης εκπαίδευσης αλλά με διαφορετικά ποσοστά εκπαίδευσης , επικύρωσης και ελέγχου.

Το Κεφάλαιο 6 , γίνεται η συζήτηση των αποτελεσμάτων που απέδωσαν οι εκπαιδεύσεις και αξιολογούνται βάσει των τιμών του συντελεστή συσχέτισης ( $R$  ) και της τετραγωνικής ρίζας του μέσου τετραγωνικού σφάλματος (RMSE).

Ολοκληρώνοντας, στο Κεφάλαιο 7 εξάγονται τα συμπεράσματα που προκύπτουν από τις εκπαιδεύσεις των νευρωνικών δικτύων για διαφορετικό αριθμό κρυφών κόμβων καθώς και για διαφορετικά ποσοστά εκπαίδευσης , επικύρωσης και ελέγχου.


## Κεφάλαιο 2

### Θεωρητικό Υπόβαθρο

#### 2.1 Ανθρώπινος εγκέφαλος

Το ανθρώπινο νευρικό σύστημα μπορεί να παρουσιαστεί ως ένα σύστημα τριών σταδίων όπως παρουσιάζεται στη **Εικόνα 2.3** (Arbib,1987). Κεντρικό ρόλο σε αυτό διαδραματίζει ο εγκέφαλος , ο οποίος διαθέτει την ικανότητα εκτέλεσης ιδιαίτερα σύνθετης, μη γραμμικής και παράλληλης επεξεργασίας όπως αυτή που απαιτείται για ακριβείς προβλέψεις, αναγνώριση μοτίβων, αντίληψη και έλεγχο της κίνησης.

Στο διάγραμμα απεικόνισης του νευρικού συστήματος υπάρχουν δυο είδη βελών, με κατεύθυνση προς τα δεξιά και προς τα αριστερά και υποδεικνύουν την προς τα εμπρός (forward) και την ανατροφοδοτούμενη (feedback) μετάδοση σημάτων πληροφορίας στο σύστημα αντίστοιχα. Πιο συγκεκριμένα , οι υποδοχείς (receptors) λαμβάνουν ερεθίσματα (είτε από το περιβάλλον είτε από το ανθρώπινο σώμα) και τα μετατρέπουν σε ηλεκτρικά σήματα παρέχοντας πληροφορίες στον εγκέφαλο (neural net). Στη συνέχεια ,τα κύτταρα τελεστές (effectors) μετατρέπουν την ηλεκτρική ώση που έλαβαν από τον εγκέφαλο σε αισθητές αποκρίσεις οι οποίες αποτελούν και έξοδο του συστήματος [Haykin,1999].




**Εικόνα 2.3: Σχηματική απεικόνιση του ανθρώπινου νευρικού συστήματος (S.Haykin, Neural Networks and learning machines ,1999)**

##### 2.1.1 Νευρώνες: Το θεμέλιο ενός νευρωνικού δικτύου

Καταλυτικό στοιχείο για την κατανόηση του εγκεφάλου υπήρξε η έρευνα του Ramón y Cajal (1911), ο οποίος εισήγαγε την έννοια του νευρώνα ως δομικό στοιχείο αυτού. Έχει -πλέον- εκτιμηθεί ότι ο ανθρώπινος φλοιός (cortex) διαθέτει 10 δισεκατομμύρια νευρώνες και 60 τρισεκατομμύρια συνάψεις ή συνδέσεις μεταξύ αυτών (Shepherd and Koch, 1990). Είναι αξιοσημείωτο το γεγονός ότι ενώ ο εγκέφαλος υστερεί σε ταχύτητα επεξεργασίας έναντι των λογικών πυλών πυριτίου που διαθέτουν οι ηλεκτρονικοί υπολογιστές, το αντισταθμίζει με τον εντυπωσιακό αριθμό νευρώνων και συνδέσεων τους, που διαθέτει. Ως αποτέλεσμα , ο εγκέφαλος συνιστά μια εξαιρετικά αποδοτική κατασκευή με εκτιμώμενη αποδοτικότητα (efficiency)  $10^{-16}$  joules(J) ανά λειτουργία ανά δευτερόλεπτο.

Απαραίτητες για την επικοινωνία των νευρώνων είναι οι συνάψεις ή νευρικές απολήξεις, οι οποίες αποτελούν δομικά και λειτουργικά στοιχεία που μεσολαβούν μεταξύ νευρώνων. Η λειτουργία τους βασίζεται στην παρουσία χημικών ουσιών (νευροδιαβιβαστές) για την μεταβίβαση ή την παρεμπόδιση σημάτων μεταξύ νευρώνων. Πιο συγκεκριμένα, εάν το ολικό ηλεκτρικό σήμα είναι επαρκές τότε υπερβαίνει το δυναμικό ενέργειας (action potential) και επομένως ο νευρώνας που λαμβάνει το σήμα ενεργοποιείται ενώ σε αντίθετη περίπτωση παραμένει ανενεργός [López et al., 2022].




**Εικόνα 2.4: Απεικόνιση στρωμάτων ενός νευρωνικού δικτύου του ανθρώπινου φλοιού (Lopez,O.A.M.,Lopez,A.M.,&Crossa,J.(2022),Fundamentals of Artificial Neural Networks and Deep Learning)**

## 2.2 Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ)

Η πρώτη προσπάθεια επεξήγησης των βιολογικών νευρωνικών δικτύων υπήρξε το πρώιμο μοντέλο που ανέπτυξαν οι McCulloch & Pitts (1943), το οποίο αποσκοπούσε στην επεξήγηση φαινομένων νευροφυσιολογίας που απορρέουν από την δράση των βιολογικών νευρώνων [McCulloch & Pitts, 1943].

Στην Εικόνα 2.6 παρουσιάζεται μια απλοποιημένη γενική δομή ενός τεχνητού νευρωνικού δικτύου και τα μέρη που το αποτελούν. Ο τεχνητός νευρώνας αποτελείται κυρίως από το επίπεδο εισόδου (input layer,  $V_0$ ), το κρυμμένο επίπεδο (πιθανώς παραπάνω από ένα) (hidden layer) και το επίπεδο εξόδου (output layer,  $V_1$ ). Τα δεδομένα εισόδου  $x_0, \dots, x_r$  λαμβάνονται είτε ως εξωτερικά ερεθίσματα είτε μέσω των συνδεδεμένων νευρώνων. Τα συναπτικά βάρη  $w_0, \dots, w_r$  αποτελούν διανύσματα που μεταβάλλουν τις ληφθείσες πληροφορίες αυξάνοντας ή μειώνοντας τις τιμές που μεταβιβάζουν στον νευρώνα. Η συνάρτηση άθροισης (Summing function) χρησιμοποιείται για άθροιση των τιμών εισόδου πολλαπλασιασμένων επί το αντίστοιχο βάρος προς μια τελική τιμή  $u$ . Η παράμετρος της μεροληψίας (bias( $b$ )) μπορεί να λάβει θετικές ή αρνητικές τιμές επηρεάζοντας έτσι την τιμή εισόδου της συνάρτησης ενεργοποίησης. Ο συμβολισμός  $\phi()$  αντιστοιχεί στην συνάρτηση ενεργοποίησης (activation function) η οποία περιορίζει το αποτέλεσμα εξόδου στο διάστημα  $[0,1]$  ή  $[-1,1]$ . Ολοκληρώνοντας, το σήμα εξόδου (Output) που παράγεται από το νευρωνικό δίκτυο συμβολίζεται με  $y_k$  (ή  $y$ ) [López et al., 2022].



**Εικόνα 2.5: Γενικό μοντέλο ενός τεχνητού νευρώνα (López, O. A. M., López, A. M., & Crossa, J. (2022, January 1). Fundamentals of Artificial Neural Networks and Deep Learning)**

Η τιμή εισόδου (net input) που λαμβάνει ο νευρώνας και καθορίζει αν θα ενεργοποιηθεί αυτός δίνεται από την **Εξίσωση 2.5** Η ενεργοποίηση του νευρώνα πραγματοποιείται από την συνάρτηση ενεργοποίησης η οποία αξιολογεί την τιμή εισόδου και αποδίδει την τιμή εξόδου του ΤΝΔ όπως περιγράφεται από την **Εξίσωση 2.6**.

$$u_j = \sum_{j=1}^p (w_{ij} * x_j) \quad (2.5)$$

$$y_i = g(u_i) \quad (2.6)$$

### 2.2.1 Multi-Layer Perceptrons

Η έννοια του Perceptron ,που προτάθηκε και αποδείχθηκε από τον Rosenblatt το 1959 , αποτελεί στην απλή του μορφή ένα δίκτυο  $N$  επιπέδων εισόδου (retina) το οποίο τροφοδοτεί ένα επίπεδο με  $M$  μονάδες φη και με ένα αποτέλεσμα (output). Το perceptron επιχειρεί να μάθει τον μετασχηματισμό της **Εξίσωσης 2.7** έχοντας ως δεδομένα  $x$  και αντιστοιχιζόμενα αποτελέσματα της μορφής  $y=d(x)$  ενώ επιλέγει τα κατάλληλα τροποποιημένα βάρη για την περίπτωση  $y \neq d(x)$  [Kröse , 1996].

$$d:\{1,1\}^N \rightarrow \{1,1\} \quad (2.7)$$

Βάσει του παραπάνω μοντέλου του Perceptron ενός νευρώνα αναπτύχθηκαν τα perceptron πολλαπλών επιπέδων (Multi-layer perceptrons ή MLP) . Τα MLP είναι νευρωνικά δίκτυα πρόσθιας τροφοδότησης με πλήθος νευρώνων οργανωμένων σε στρώματα ή επίπεδα (layers). Το πρώτο επίπεδο ονομάζεται επίπεδο εισόδου (Input layer) και σε αυτό εισάγονται τα δεδομένα εισόδου. Επειδή τα στοιχεία αυτού δεν εκτελούν υπολογισμούς (δεν διαθέτουν βάρη εισόδου ούτε συνάρτηση ενεργοποίησης) δεν αποτελούν νευρώνες. Έπονται ένα ή περισσότερα κρυφά επίπεδα (hidden layers) ενώ στο τέλος βρίσκεται το επίπεδο εξόδου (output layer) [Βλαχάβας κ.α., 2020]

Επιπλέον το πολυεπίπεδο perceptron χαρακτηρίζεται από υψηλή συνδεσιμότητα ο βαθμός της οποίας καθορίζεται από τα συναπτικά βάρη του δικτύου και από παραγωγίσιμες συναρτήσεις ενεργοποίησης για κάθε νευρώνα.

Τα σήματα στα πολυεπίπεδα perceptron διαχωρίζονται σε λειτουργικά σήματα (function signals) και τα σήματα σφάλματος (error signals). Τα σήματα εισόδου εισέρχονται στο δίκτυο και μεταφέρονται με κατεύθυνση από αριστερά προς τα δεξιά μέχρι την έξοδο του. Αυτά τα σήματα καταφθάνουν σε κάθε νευρώνα και υπολογίζονται βάσει των εισόδων του νευρώνα και των βαρών τους. Όσων αφορά τα σήματα σφάλματος , αυτά δημιουργούνται στην έξοδο του δικτύου με κατεύθυνση προς τα πίσω περνώντας από διαδοχικά επίπεδα [Haykin,1999].

### 2.3 Συναρτήσεις ενεργοποίησης

Οι συναρτήσεις ενεργοποίησης ( $\varphi_k$  ή  $\varphi$ ) χρησιμοποιούνται για την αντιστοίχιση μεταξύ των δεδομένων εισόδου (inputs) και ενός κρυφού στρώματος (hidden layer) σε ένα ΤΝΔ.

Ειδικότερα, χρησιμοποιούν την συνολική είσοδο  $s_k(t)$  και την τρέχουσα τιμή ενεργοποίησης  $y_k(t)$  παράγοντας μια νέα τιμή ενεργοποίησης του στοιχείου  $k$ . Η νέα τιμή ενεργοποίησης δίνεται από την **Εξίσωση 2.8** [Kröse, 1996].

Οι συνηθέστερες συναρτήσεις ενεργοποίησης  $\varphi_k(u)$  είναι η σιγμοειδής , η ReLu Και η Tanh.


$$y_k(t+1)=\varphi_k(y_k(t),s_k(t)) \quad (2.8)$$

### 2.3.1 Σιγμοειδής Συνάρτηση

Η σιγμοειδής (sigmoid) συνάρτηση ενεργοποίησης συνιστά την πιο ευρέως διαδεδομένη συνάρτηση ενεργοποίησης στα ΤΝΔ και έχει ως στόχο την μετατροπή ανεξάρτητων μεταβλητών σε πιθανότητες που λαμβάνουν τιμές 0 και 1. Η ευχρηστία της αποδίδεται στο γεγονός ότι εξισορροπεί μεταξύ μιας γραμμικής και μη γραμμικής συμπεριφοράς [Haykin, 1999].

Η **Εξίσωση 2.9** περιγράφει την σιγμοειδή συνάρτηση και η **Εικόνα 2.6** παρουσιάζει την γραφική της απεικόνιση [López et al., 2022].

$$y_k = f(s_k) = (1 + e^{-s_k})^{-1} \quad (2.9)$$




**Εικόνα 2.6:** Αναπαράσταση της σιγμοειδούς συνάρτησης ενεργοποίησης (López, O. A. M., López, A. M., & Crossa, J. (2022, January 1). Fundamentals of Artificial Neural Networks and Deep Learning)

### 2.3.2 Ανορθωμένη Γραμμική ή Συνάρτηση Ράμπας (ReLU)

Η μη γραμμική συνάρτηση ReLU, μια εκ των πιο διαδεδομένων συναρτήσεων ενεργοποίησης, έχει ως ιδιότητα ότι ενεργοποιεί έναν κόμβο (node) μόνο εάν η τιμή εισόδου που λαμβάνει είναι μεγαλύτερη μίας ποσότητας. Συγκεκριμένα, δίνει ως αποτέλεσμα μηδενική τιμή για τιμές εισόδου μικρότερες ή ίσες του μηδενός ενώ για τιμές ανώτερες ενός κατωφλίου παρουσιάζει γραμμική συμπεριφορά όπως περιγράφουν η **Εξίσωση 2.9** και η **Εικόνα 2.7** :

$$g(z) = \max(0, z) \quad (2.9)$$






**Εικόνα 2.7:** Αναπαράσταση της συνάρτησης ενεργοποίησης ReLu (López, O. A. M., López, A. M., & Crossa, J. (2022, January 1). *Fundamentals of Artificial Neural Networks and Deep Learning*)

### 2.3.3 Υπερβολική Συνάρτηση Εφαπτομένης (tanh)

Η υπερβολική (hyperbolic) συνάρτηση εφαπτομένης tanh ορίζεται από την **Εξίσωση 2.10** και παρουσιάζει σιγμοειδή συμπεριφορά της **Εικόνας 2.8** δίνοντας ως αποτέλεσμα τιμές μεταξύ -1 και 1. Τα πλεονεκτήματα χρήσης της συνάρτησης tanh είναι το σύνολο τιμών της (-1,1), καθώς λόγω αυτού προτιμάται για τα κρυφά επίπεδα (hidden layers) ενός ΤΝΔ, και ο χειρισμός των αρνητικών τιμών που μπορεί να εκτελέσει [López et al., 2022].

$$\tanh(z) = \frac{\sinh(z)}{\cosh(z)} = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (2.10)$$



**Εικόνα 2.8: Αναπαράσταση της συνάρτησης ενεργοποίησης tanh (López, O. A. M., López, A. M., & Crossa, J. (2022, January 1). Fundamentals of Artificial Neural Networks and Deep Learning)**

## 2.4 Αλγόριθμος εκπαίδευσης Levenberg-Marquardt

Ο αλγόριθμος Levenberg-Marquardt (LM) πρωτοεμφανίστηκε το 1963 και αποτελεί έναν αλγόριθμο προσέγγισης των ελαχίστων τετραγώνων για μη γραμμικές παραμέτρους. Πιο συγκεκριμένα, υπολογίζει την βέλτιστη παρεμβολή μεταξύ της μεθόδου των σειρών Taylor και της μεθόδου κλίσης (gradient method) [Marquardt, 1963].

Κατά την εκπαίδευση με τον αλγόριθμο LM το δίκτυο ενημερώνει τις τιμές βάρους και μεροληψίας (bias) βάσει της βελτιστοποίησης που πραγματοποιεί ο αλγόριθμος. Επιπλέον, ο αλγόριθμός LM αποτελεί τον ταχύτερο αλγόριθμο backpropagation (οπισθοδρομικής διάδοσης) στην εργαλειοθήκη της matlab και συνίσταται για την εκπαίδευση ΤΝΔ παρότι καταλαμβάνει περισσότερη μνήμη από τους υπόλοιπους αλγορίθμους [*Levenberg-Marquardt Backpropagation - MATLAB Trainlm*, n.d.].

Η εκπαίδευση των νευρωνικών δικτύων με τον αλγόριθμο LM στηρίζεται στις παραμέτρους και τις προκαθορισμένες τιμές αυτών όπως παρουσιάζονται στον **Πίνακα 2.**(<https://www.mathworks.com/help/deeplearning/ref/trainlm.html>)

**Πίνακας 2: Παράμετροι Αλγορίθμου LM και προκαθορισμένες τιμές τους**(<https://www.mathworks.com/help/deeplearning/ref/trainlm.html>)

<code>net.trainParam.epochs</code>	1000	Maximum number of epochs to train
<code>net.trainParam.goal</code>	0	Performance goal
<code>net.trainParam.max_fail</code>	6	Maximum validation failures
<code>net.trainParam.min_grad</code>	1e-7	Minimum performance gradient
<code>net.trainParam.mu</code>	0.001	Initial mu
<code>net.trainParam.mu_dec</code>	0.1	Decrease factor for mu
<code>net.trainParam.mu_inc</code>	10	Increase factor for mu
<code>net.trainParam.mu_max</code>	1e10	Maximum value for mu
<code>net.trainParam.show</code>	25	Epochs between displays (NaN for no displays)
<code>net.trainParam.showCommandLine</code>	false	Generate command-line output
<code>net.trainParam.showWindow</code>	true	Show training GUI
<code>net.trainParam.time</code>	inf	Maximum time to train in seconds

Κατά την εκπαίδευση, με χρήση του αλγορίθμου LM χρησιμοποιούνται διανύσματα επικύρωσης για την λήξη της εκπαίδευσης. Εάν η απόδοση του δικτύου δεν βελτιώνεται ή παραμένει ίδια για εποχές `max_fail` σε σειρά τότε σημαίνει την λήξη της εκπαίδευσης. Επιπλέον ,χρησιμοποιούνται διανύσματα ελέγχου τα οποία αν και δεν επηρεάζουν άμεσα την εκπαίδευση αποτελούν επιπλέον δοκιμή της ικανότητας του δικτύου να γενικεύει.

Η εκπαίδευση με τον αλγόριθμο LM περιορίζεται από το γεγονός ότι χρησιμοποιείται ο πίνακας Jacobian για τους, υπολογισμούς, ο οποίος υποθέτει ότι η απόδοση είναι η μέση τιμή ή το άθροισμα των τετραγωνικών σφαλμάτων.

Ο αλγόριθμος LM ,όπως και οι μέθοδοι quasi-Newton ,σχεδιάστηκε για την προσέγγιση της ταχύτητας εκπαίδευσης δεύτερης τάξης χωρίς τον υπολογισμό του πίνακα Hessian. Όταν η συνάρτηση απόδοσης είναι της μορφής αθροίσματος τετραγώνων , όπως στην εκπαίδευση feedforward(πρόσθιας τροφοδότησης) δικτύων, τότε ο πίνακας Hessian μπορεί να προσεγγιστεί από την **Εξίσωση 2.11** και η κλίση από την **Εξίσωση 2.12** :

$$H = J^T J \quad (2.11)$$

$$g = J^T e \quad (2.12)$$

Όπου J ο Jacobian πίνακας που περιέχει τις πρώτες παραγώγους των σφαλμάτων του δικτύου σε σχέση με τα βάρη και την μεροληψία και e ένα διάνυσμα των σφαλμάτων του δικτύου. Η προτίμηση για τον υπολογισμό του Jacobian πίνακα στηρίζεται στον ευκολότερο

υπολογισμό του μέσω μιας τυπικής τεχνικής backpropagation [Hagan and Menhaj ,1994] έναντι του πολύπλοκου υπολογισμού του πίνακα Hessian.

Ο αλγόριθμος LM χρησιμοποιεί αυτήν την προσέγγιση του Εσσιανού (Hessian) πίνακα στην παρακάτω **Εξίσωση 2.13** η οποία είναι μια νέα έκδοση τύπου Newton.

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (2.13)$$

Όταν το μονόμετρο μέγεθος  $\mu$  έχει τιμή μηδέν τότε πρόκειται για την μέθοδο Newton όπου χρησιμοποιείται ο προσεγγιστικός Εσσιανός πίνακας. Για μεγάλη τιμή του  $\mu$  , προκύπτει κλιμακωτή κάθοδος (Gradient Descent) με μικρό μέγεθος βήματος. Καθώς η μέθοδος Newton είναι ταχύτερη και ακριβέστερη κοντά στο ελάχιστο σφάλμα είναι επιθυμητή η μετάβαση σε αυτήν το συντομότερο δυνατό. Ως εκ τούτου , το  $\mu$  μειώνεται έπειτα από κάθε επιτυχημένο βήμα (που συνεπάγεται μείωση της συνάρτησης απόδοσης) ενώ αυξάνεται μόνο όταν κάποιο βήμα οδηγεί σε αύξηση της συνάρτησης απόδοσης. Επομένως , με κάθε επιτυχημένη επανάληψη του αλγορίθμου πραγματοποιείται μείωση της συνάρτησης απόδοσης [Levenberg-Marquardt Backpropagation - MATLAB Trainlm, n.d.].

Η εκπαίδευση με τον αλγόριθμο LM σταματάει όταν:

- Η εκπαίδευση φτάνει τον μέγιστο αριθμό εποχών(επαναλήψεων)
- Το χρονικό όριο υπερβαίνει το μέγιστο προκαθορισμένο όριο
- Η απόδοση ελαχιστοποιείται στο στόχο
- Η κλίση της απόδοσης πέφτει υπό το min\_grad
- Η τιμή  $\mu$  υπερβαίνει το  $\mu_{max}$
- Το σφάλμα επικύρωσης είναι μεγαλύτερο κατά συντελεστή τιμής max\_fail από τότε όταν μειώθηκε.

## 2.5 Κριτήρια Αξιολόγησης

Η ακρίβεια πρόβλεψης ενός ΤΝΔ βασίζεται στα μέτρα ακριβείας (accuracy metrics) τα οποία αποτελούν δείκτες αξιολόγησης της αποτελεσματικότητας και εγκυρότητας αυτού. Διακρίνονται σε μέτρα συσχέτισης (correlation based) ,τάξης (scale depended) και ποσοστού (percentage depended). Τα μέτρα συσχέτισης περιλαμβάνουν τον συντελεστή συσχέτισης (correlation coefficient ,R) και τον συντελεστή προσδιορισμού (coefficient of determination , R<sup>2</sup>). Οι συντελεστές R (**Εξίσωση 2.14**) και R<sup>2</sup> (**Εξίσωση 2.15**) λαμβάνουν τιμές εύρους [-1,+1] και [0,1] αντίστοιχα. Τα μέτρα τάξης βασίζονται σε απόλυτα ή ριζικά σφάλματα και σε αυτά συγκαταλέγονται κυρίως το μέσο τετραγωνικό σφάλμα (MSE) και το ριζικό του (RMSE) τα οποία υπολογίζονται από τις **Εξισώσεις 2.16 και 2.17** αντίστοιχα. Το μέτρο MSE υπολογίζει την μέση διαφορά των τετραγώνων μεταξύ προβλεπόμενων και πραγματικών τιμών διαιρούμενη με τον αριθμό τους. Το εύρος τιμών του MSE είναι (0,+∞) ενώ όσο πλησιέστερη στο 0 είναι η τιμή του τόσο ακριβέστερες είναι οι προβλέψεις του μοντέλου. Τα μέτρα ποσοστού δεν λαμβάνουν μονάδες μέτρησης παρέχοντας την δυνατότητα σύγκρισης προβλέψεων διαφορετικών μονάδων μέτρησης. Τα συνηθέστερα μέτρα ποσοστού είναι το MAPE και το SMAPE [Jierula et al., 2021].

$$R = \frac{\frac{1}{n} \sum (Dact - \bar{Dact})(Dpre - \bar{Dpre})}{\sqrt{\frac{1}{n} \sum (Dact - \bar{Dact})^2} \sqrt{\frac{1}{n} \sum (Dpre - \bar{Dpre})^2}} \quad (2.14)$$

$$R^2 = 1 - \frac{\sum_1^n (Dact - Dpre)^2}{\sum_1^n (Dact - \bar{Dact})^2} \quad (2.15)$$

$$MSE = \frac{1}{n} \sum_1^n (Dpre - Dact)^2 \quad (2.16)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_1^n (Dpre - Dact)^2} \quad (2.17)$$

Στις παραπάνω εξισώσεις και στα πλαίσια της εργασίας η Dact αντιστοιχεί στην υπολογισμένη (από το δυναμικό μοντέλο της αντλίας θερμότητας) τιμή του COP, η Dpre στην προσομοιωμένη μεταβλητή, η Dact στην μέση τιμή της υπολογιζόμενης μεταβλητής, η Dpre στην μέση τιμή της προσομοιωμένης μεταβλητής και το n στο σύνολο των τιμών. Στην συγκεκριμένη εργασία αξιοποιούνται οι δείκτες R και RMSE για αξιολόγηση της ικανότητας πρόβλεψης του συντελεστή COP με τα ΤΝΔ.

## 2.6 Πλεονεκτήματα ΤΝΔ

Η ελκυστικότητα των ΤΝΔ για την επίλυση σύνθετων πραγματικών προβλημάτων πηγάζει από την εκπληκτική δυνατότητα επεξεργασίας πληροφοριών που διαθέτουν η οποία αποδίδεται στα χαρακτηριστικά της μη γραμμικότητας, του υψηλού παραλληλισμού, της ανθεκτικότητας σε σφάλματα και θόρυβο καθώς και της ικανότητας μάθησης και γενίκευσης [Basheer & Hamjeer, 2000].

Τα τεχνητά νευρωνικά δίκτυα παρουσιάζουν τις παρακάτω δυνατότητες [Haykin, 1999]:

1. Μη γραμμικότητα
2. Αντιστοίχιση Εισόδου-Εξόδου
3. Προσαρμοστικότητα
4. Ενδεικτική Απόκριση
5. Πληροφορίες σχετικά με το περιεχόμενο
6. Ανοχή σφαλμάτων
7. Συμβατότητα με VLSI
8. Ομοιομορφία ανάλυσης και σχεδίασης
9. Αντιστοιχία με την νευροβιολογία

## 1. Μη γραμμικότητα

Ένας τεχνητός νευρώνας μπορεί να είναι γραμμικός ή μη γραμμικός ενώ ένα νευρωνικό δίκτυο, το οποίο αποτελείται από μια σύνδεση μη γραμμικών νευρώνων, είναι από μόνο του μη γραμμικό. Η ιδιότητα της μη γραμμικότητας που διαθέτουν τα νευρωνικά δίκτυα είναι υψίστης σημασίας ιδίως αν ο μηχανισμός παραγωγής δεδομένων εισόδου (όπως η ομιλία) είναι εξ ορισμού μη γραμμικός [Haykin, 1999].

## 2. Αντιστοίχιση Εισόδου-Εξόδου

Η συγκεκριμένη ιδιότητα έχει ιδιαίτερη σημασία κατά την μάθηση υπό επίβλεψη, όπου αξιοποιούνται παραδείγματα εκπαίδευσης για να τροποποιηθούν τα συναπτικά βάρη του νευρωνικού δικτύου. Κάθε παράδειγμα αποτελείται από ένα μοναδικό σήμα εισόδου και την αντίστοιχη επιθυμητή απόκριση. Η τροποποίηση των συναπτικών βαρών πραγματοποιείται σύμφωνα με ένα στατιστικό κριτήριο και αποσκοπεί στην ελαχιστοποίηση της διαφοράς μεταξύ επιθυμητής απόκρισης και πραγματικής απόκρισης του δικτύου που παράγεται από το σήμα εισόδου. Το δίκτυο τροφοδοτείται με ένα υποσύνολο δεδομένων που επιλέγεται τυχαία από το σύνολο δεδομένων μέχρι να φτάσει σε μια σταθερή κατάσταση χωρίς μεταβολές στα συναπτικά βάρη. Στα πλαίσια της εκπαίδευσης ένα παράδειγμα μπορεί να χρησιμοποιηθεί εκ νέου αλλά με άλλη σειρά. Με αυτόν τον τρόπο το δίκτυο δημιουργεί μια απεικόνιση εισόδου-εξόδου την οποία αξιοποιεί για να μαθαίνει για το εκάστοτε πρόβλημα που ζητείται [Haykin, 1999].

Αυτή η προσέγγιση βρίσκει εφαρμογή στον μη παραμετρικό στατιστικό συμπερασμό, ο οποίος αποτελεί πεδίο της στατιστικής, και επικεντρώνεται στην εκτίμηση χωρίς μοντέλα, ή, από βιολογική άποψη, στη μάθηση *tabula rasa* (Geman et al., 1992). Ο όρος "μη παραμετρική" χρησιμοποιείται εδώ για να δηλώσει την απουσία οποιωνδήποτε προηγούμενων υποθέσεων σχετικά με ένα στατιστικό μοντέλο για τα δεδομένα εισόδου.

## 3. Προσαρμοστικότητα

Τα ΤΝΔ διαθέτουν την ικανότητα να μεταβάλλουν τα συναπτικά βάρη ανάλογα με τις αλλαγές του περιβάλλοντος. Πιο συγκεκριμένα, ένα ΤΝΔ εκπαιδευμένο σε ένα συγκεκριμένο περιβάλλον μπορεί να επανεκπαιδευτεί για να αντιμετωπίζει μικρές αλλαγές στις περιβαλλοντικές συνθήκες. Επιπροσθέτως, όταν πρόκειται για ένα μη στατικό περιβάλλον (μεταβολές με τον χρόνο) το νευρωνικό δίκτυο διαθέτει την ικανότητα να αλλάζει τα συναπτικά βάρη του σε πραγματικό χρόνο. Γενικότερα, όσο πιο προσαρμοστικό κάνουμε ένα σύστημα, διασφαλίζοντας την σταθερότητα του, τόσο πιο εύρωστο θα είναι όταν κληθεί να λειτουργήσει σε ένα μη σταθερό περιβάλλον [Haykin, 1999].

Αξίζει, όμως, να σημειωθεί ότι η προσαρμοστικότητα δεν οδηγεί πάντα σε ευρωστία ενώ μπορεί να κάνει και το αντίθετο. Το δίλημμα σταθερότητας-πλαστικότητας αναφέρεται σε ένα προσαρμοστικό σύστημα με ταχείες αλλαγές που είναι πιθανότερο να αντιδράσει σε πλασματικές διαταραχές οδηγώντας σε απότομη πτώση της απόδοσης του συστήματος [Grossberg, 1988].

#### **4. Ενδεικτική Απόκριση**

Στο πλαίσιο της ταξινόμησης μοτίβων , ένα νευρωνικό δίκτυο μπορεί να παρέχει πληροφορίες πέραν από το μοτίβο που επιλέγει και για τον βαθμό εμπιστοσύνης με τον οποίο επιλέγει. Με αυτό τον τρόπο μπορεί να απορρίψει αμφιλεγόμενα μοτίβα και να βελτιώσει την ικανότητα κατηγοριοποίησης του δικτύου [Haykin,1999].

#### **5. Πληροφορία σχετική με το περιεχόμενο**

Η γνώση σε ένα ΤΝΔ προκύπτει από την δομή και την κατάσταση ενεργοποίησης του δικτύου. Η καθολική δραστηριότητα όλων των νευρώνων του δικτύου μπορεί να επηρεάσει έναν συγκεκριμένο νευρώνα. Συνεπώς ,η πληροφορία σχετική με το περιεχόμενο χρησιμοποιείται με φυσικό τρόπο από το νευρωνικό δίκτυο [Haykin,1999].

#### **6. Ανοχή σφαλμάτων**

Ένα πλεονέκτημα ενός ΤΝΔ είναι η έμφυτη ανθεκτικότητα σε σφάλματα η οποία αντιστοιχεί σε δυνατότητα εύρωστων υπολογισμών όπου η απόδοση υπό αντίξοες συνθήκες, ναι μεν μειώνεται αλλά με βαθμιαίο ρυθμό. Η ικανότητα αυτή σε συνδυασμό με την αποκεντρωμένη αποθήκευση πληροφοριών εντός του δικτύου επιτρέπει σε ένα ΤΝΔ την ομαλή μείωση της απόδοσης σε περίπτωση βλάβης και όχι την καταστροφική αποτυχία [Haykin,1999]. Για την διασφάλιση της ανθεκτικότητας ενός ΤΝΔ σε σφάλματα απαιτείται ενδεχομένως η λήψη διορθωτικών μέτρων κατά την σχεδίαση του αλγορίθμου που θα εκπαιδεύσει το δίκτυο [Kerlirzin & Vallet,1993]

#### **7. Συμβατότητα με VLSI**

Ένα ΤΝΔ μπορεί να χρησιμοποιηθεί σε τεχνολογίες VLSI (Very Large Scale Integration) λόγω της παράλληλης αρχιτεκτονικής που διαθέτει και του επιτρέπει να κάνει γρήγορους υπολογισμούς [Haykin,1999]. Η αξιοποίηση τεχνολογιών VLSI παρέχει την δυνατότητα σύλληψης ιδιαίτερα πολύπλοκης συμπεριφοράς με έντονη ιεράρχηση [Mead,1989].

#### **8. Ομοιομορφία ανάλυσης και σχεδίασης**

Τα νευρωνικά δίκτυα εκτιμώνται ευρέως για την επεξεργασία πληροφορίας που παρέχουν. Η συγκεκριμένη ιδιότητα εκφράζεται με τους παρακάτω τρόπους:

- 1.Οι νευρώνες αντιπροσωπεύουν ένα κοινό στοιχείο όλων των νευρωνικών δικτύων
- 2.Η παραπάνω ομοιότητα επιτρέπει την κοινή χρήση θεωριών και αλγορίθμων για διάφορες εφαρμογές των νευρωνικών δικτύων
- 3.Πολυμηματικά δίκτυα μπορούν να φτιαχτούν με την ανεμπόδιση ενοποίηση των επιμέρους τμημάτων

#### **9. Αντιστοιχία με την νευροβιολογία**

Ο σχεδιασμός νευρωνικών δικτύων που εμπνεύστηκε από τη λειτουργία του εγκεφάλου αποτελεί απόδειξη ότι η ανθεκτική σε σφάλματα παράλληλη επεξεργασία δεν είναι απλά δυνατή αλλά ταχεία και ισχυρή. Αυτό επιτρέπει στους νευροβιολόγους να χρησιμοποιούν τεχνητά νευρωνικά δίκτυα ως ερευνητικό εργαλείο για την ερμηνεία φαινομένων νευροβιολογίας. Αμφίδρομα, η ίδια η νευροβιολογία παρέχει καινοτόμες ιδέες για την επίλυση πολύπλοκων προβλημάτων στα οποία αδυνατούν να προσφέρουν λύσεις οι συμβατικές τεχνικές [Haykin, 1999].

Ένα τέτοιο παράδειγμα είναι ο αμφιβληστροειδής χιτώνας (retina) στον οποίο πραγματοποιείται η πρώτη συσχέτιση του φυσικού κόσμου, μέσω των εικόνων που τροφοδοτούνται σε πληθώρα υποδοχέων, με νευρωνικές εικόνες. Η συναπτική οργάνωση του αμφιβληστροειδούς χιτώνα μαρτυρά την πολυπλοκότητα της παραπάνω διεργασίας.

Η μετατροπή των οπτικών εικόνων σε νευρωνικές απαιτεί σε όλα τα σπονδυλωτά την ολοκλήρωση τριών βημάτων [Sterling, 1990]:


- (i) Μεταγωγή προσλαμβανόμενων εικόνων από ένα στρώμα νευρώνων υποδοχέων
- (ii) Μετάδοση του παραγόμενου σήματος (ως αντίδραση στο φως) από χημικού νευρώνες σε ένα στρώμα διπολικών κυττάρων
- (iii) Μετάδοση αυτών των σημάτων, επίσης από χημικές συνάψεις, σε νευρώνες εξόδου που ονομάζονται γαγγλιακά κύτταρα.

## 2.7 Πρόωρη Διακοπή(Early Stopping)

Η επικύρωση χρησιμοποιείται για τον εντοπισμό του σημείου υπερπροσαρμογής (overfitting) κατά την εκπαίδευση του ΤΝΔ. Σε μια τυπική περίπτωση, το μέσο ριζικό σφάλμα (mean squared error) μειώνεται με την αύξηση των εποχών που χρησιμοποιούνται για την εκπαίδευση. Πιο συγκεκριμένα, ξεκινά από μια υψηλή τιμή και αρχικά μειώνεται απότομα και έπειτα συνεχίζει να μειώνεται με πιο αργό ρυθμό καθώς το νευρωνικό δίκτυο προσπαθεί να εντοπίσει ένα τοπικό ελάχιστο. Η καμπύλη του σφάλματος εκπαίδευσης δεν αποτελεί όμως αξιόπιστο κριτήριο για την λήξη της εκπαίδευσης και την επίτευξη καλής γενίκευσης. Για τον εντοπισμό του σημείου εμφάνισης υπερπροσαρμογής διαχωρίζονται τα δεδομένα εκπαίδευσης σε υποσύνολα εκτίμησης (estimation) και επικύρωσης (validation). Στην **Εικόνα 2.9** παρουσιάζονται οι καμπύλες σφάλματος του δείγματος εκτίμησης (validation-sample error) και δείγματος εκπαίδευσης (training-sample error). Η καμπύλη σφάλματος δείγματος εκτίμησης μειώνεται μονοτονικά με την αύξηση των εποχών συγκλίνοντας στον άξονα  $x$ . Σε αντίθεση, η καμπύλη σφάλματος δείγματος επικύρωσης μειώνεται μονοτονικά μέχρι μια ελάχιστη τιμή, η οποία ονομάζεται σημείο πρόωρου τερματισμού (early stopping point) και έπειτα αυξάνεται με την πάροδο της εκπαίδευσης και των εποχών. Η μέθοδος που βασίζεται σε αυτό το σημείο στο οποίο αλλάζει η συμπεριφορά της καμπύλης δείγματος επικύρωσης και οδηγεί σε λήξη της εκπαίδευσης ονομάζεται μέθοδος πρόωρης διακοπής (Early stopping). Αξίζει να σημειωθεί ότι ενώ φαινομενικά το δίκτυο βελτιώνεται με εκπαίδευση πέραν του ελαχίστου της πρόωρης διακοπής, στην πραγματικότητα αυτή η μάθηση είναι θόρυβος (noise)




που περιέχεται στα δεδομένα εκπαίδευσης. Η μέθοδος της πρόωρης διακοπής είναι απλή , εφαρμόζεται ευρέως και συνιστά ένα πολύ αξιόπιστο κριτήριο για την λήξη της εκπαίδευσης των ΤΝΔ [Haykin ,1999].



Εικόνα 2.9: Αναπαράσταση της μεθόδου πρόωρης διακοπής (S.Haykin, Neural networks and learning machines,1999)

## 2.8 Πόλωση- Μεροληψία (Bias)


Όπως παρουσιάζεται στο μοντέλο του τεχνητού νευρώνα της **Εικόνας 2.5** η ειδική είσοδος που δέχεται αυτός ονομάζεται πόλωση (bias) και επειδή το σήμα εισόδου λαμβάνει πάντα τιμή  $x_0=1$  η τιμή του βάρους ταυτίζεται με αυτή της πόλωσης στο  $x_0$ . Η **Εικόνα 2.10** απεικονίζει την οριζόντια μετατόπιση μιας λογιστικής συνάρτησης ενεργοποίησης για διαφορετικές της πόλωσης. Με απουσία πόλωσης εμφανίζεται η μεσαία καμπύλη του σχήματος ενώ για μη μηδενική πόλωση η καμπύλη μετατοπίζεται -σύμφωνα με το πρόσημο του βάρους (b) - αριστερά (θετικό b) ή δεξιά (αρνητικό b). Το μέγεθος αυτής της μετατόπισης προκύπτει κατά την εκπαίδευση του ΤΝΔ και συντελεί στην καλύτερη εκπαίδευση του [Βλαχάβας κ.α., 2020].



Εικόνα 2.10: Η πόλωση μετατοπίζει οριζόντια την συνάρτηση ενεργοποίησης (Βλαχάβας, Κεφαλάς, Κόκκορας, & Σακελλαρίου. (2020, June). *Τεχνητή Νοημοσύνη*(4η))

## 2.9 Υπερπροσαρμογή (Overfitting)

Το φαινόμενο της υπερπροσαρμογής παρατηρείται στα ΤΝΔ τα οποία παρότι παρουσιάζουν ικανοποιητική μείωση του μέσου τετραγωνικού σφάλματος (MSE) των δεδομένων εκπαίδευσης (χαμηλή μεροληψία -low bias) αποτυγχάνουν για δεδομένα που δεν συμμετείχαν στην εκπαίδευση εμφανίζοντας μεγάλο σφάλμα. Με αυτό τον τρόπο το ΤΝΔ αδυνατεί να προβλέψει και να γενικεύσει και εξειδικεύεται αποκλειστικά στα παρεχόμενα δεδομένα εκπαίδευσης τα οποία μπορεί να περιέχουν θόρυβο. Στην **Εικόνα 2.11** παρουσιάζονται οι περιπτώσεις υποπροσαρμογής (underfitting), υπερπροσαρμογής (overfitting) και καλής προσαρμογής για τα ίδια δεδομένα εκπαίδευσης όπου το σφάλμα είναι η απόσταση των σημείων από την ευθεία. Στην πρώτη περίπτωση, η μοντελοποίηση δεν επαρκεί και το σφάλμα είναι μεγάλο ενδεχομένως λόγω κακής επιλογής δεδομένων εκπαίδευσης ή κακής επιλογής μοντέλου. Στο μεσαίο διάγραμμα εμφανίζεται η περίπτωση της υπερπροσαρμογής η οποία χαρακτηρίζεται από μηδαμινό σφάλμα εκπαίδευσης, οπότε χαμηλή μεροληψία (low bias), και χαμηλής ποιότητας πρόβλεψη για δεδομένα εκτός αυτών της εκπαίδευσης. Η επιθυμητή προσαρμογή (δεξιά διάγραμμα) συνδυάζει χαμηλό σφάλμα εκπαίδευσης (καλή μεροληψία) και καλή συμπεριφορά για τα δεδομένα ελέγχου (καλή διακύμανση) [Βλαχάβας κ.α, 2020]



**Εικόνα 2.11 : Διάφορα επίπεδα προσαρμογής με βάση τα ίδια δεδομένα εκπαίδευσης (Βλαχάβας, Κεφαλάς, Κόκκορας, & Σακελλαρίου. (2020, June). Τεχνητή Νοημοσύνη(4η))**

## ΚΕΦΑΛΑΙΟ 3

### ΑΝΤΛΙΑ ΘΕΡΜΟΤΗΤΑΣ ΚΑΙ ΔΕΔΟΜΕΝΑ

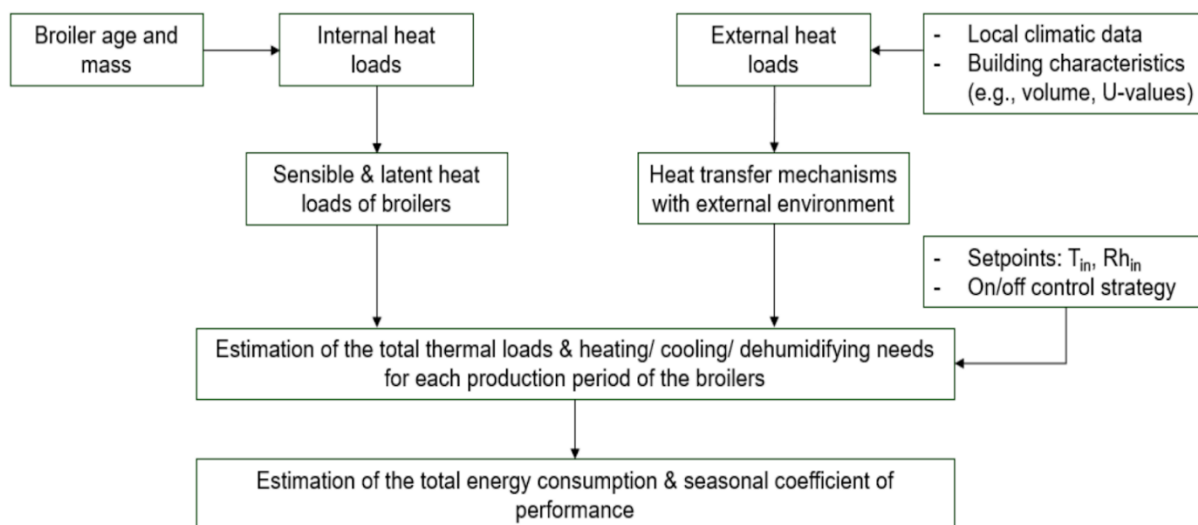
#### 3.1 Δυναμικό Μοντέλο Αντλίας Θερμότητας (ΑΘ)

Στα πλαίσια της παρούσας διπλωματικής εργασίας, αξιοποιούνται τα δεδομένα και το δυναμικό μοντέλο που αναπτύχθηκε στο πλαίσιο των ερευνητικών δραστηριοτήτων του Εργαστηρίου Γεωργικής Μηχανολογίας του Γεωπονικού Πανεπιστημίου Αθηνών (Tyris et al., 2023, Manolakos et al., 2019). Παρακάτω παρουσιάζεται εν συντομία η μεθοδολογία της δημοσίευσης βάσει της οποίας προέκυψαν τα δεδομένα θερμοκρασίας, σχετικής υγρασίας, θερμικών φορτίων και συντελεστή απόδοσης, και τα οποία αξιοποιήθηκαν για την εκπαίδευση των ΤΝΔ στην παρούσα διπλωματική.

Το μαθηματικό μοντέλο αναπτύχθηκε σε περιβάλλον Mathworks Simulink/Simscape με σκοπό την προσομοίωση των θερμικών φορτίων εντός ενός πτηνοτροφείου κρεοπαραγωγής (broiler house) και της λειτουργίας ενός συστήματος δυναμικών ΑΘ. Το εξεταζόμενο πτηνοτροφείο προσομοιώθηκε ως ένα ανοιχτό θερμοδυναμικό σύστημα εντός του οποίου διενεργείται ελεγχόμενη μεταφορά μάζας και ενέργειας. Το σύστημα ΑΘ αποσκοπεί στην κάλυψη των αναγκών θέρμανσης (heating), ψύξης (cooling) και αφύγρανσης (dehumidifying) της εγκατάστασης. Πιο συγκεκριμένα, το μοντέλο λαμβάνει υπόψιν τα εσωτερικά και εξωτερικά θερμικά φορτία, προβλέπει σε πραγματικό χρόνο τις συνθήκες εντός αυτής, και ρυθμίζει το σύστημα κλιματισμού (HVAC) ώστε να δημιουργεί τις ιδανικές συνθήκες για την βέλτιστη ανάπτυξη των νεαρών πουλερικών (broilers). Τα εσωτερικά θερμικά φορτία προκύπτουν από τον αριθμό των πουλερικών και το στάδιο ανάπτυξης τους, καθώς αυτό συνδέεται με την μάζα αυτών η οποία επηρεάζει τα λανθάνοντα και αισθητά θερμικά φορτία.

Στα αισθητά θερμικά φορτία των ζώων συγκαταλέγονται οι απώλειες θερμότητας αυτών μέσω συναγωγής, μεταφοράς και ακτινοβολίας ενώ στα λανθάνοντα η εξάτμιση του νερού δια μέσου του αναπνευστικού συστήματος και του δέρματος τους [DeShazer et al., 2009]

Όσον αφορά, τα εξωτερικά θερμικά φορτία αυτά εξαρτώνται από κλιματικά στοιχεία της περιοχής και τους μηχανισμούς μεταφοράς θερμότητας. Οι τρόποι μεταφοράς θερμότητας που λήφθηκαν υπόψιν περιλαμβάνουν την ηλιακή ακτινοβολία που προσπίπτει στις εξωτερικές επιφάνειες του κτιρίου, την συναγωγή (μεταξύ εξωτερικών τοίχων και εξωτερικού αέρα, καθώς και εσωτερικών τοίχων και εσωτερικού αέρα) και την αγωγή (μεταξύ των υλικών κατασκευής). Ολοκληρώνοντας, εκτιμήθηκαν οι συνολικές και οι τμηματικές (για κάθε θερμική λειτουργία) ενεργειακές ανάγκες της ΑΘ και υπολογίστηκαν οι συντελεστές απόδοσης SCOP (Seasonal Coefficient of Performance) και SEER (Seasonal Energy Efficiency Ratio).



**Εικόνα 3.12 : Διάγραμμα Ροής (Flowchart) του μοντέλου (Tyris et al.,2023)**

### 3.2 Ζώα και Εγκατάσταση

Η εξεταζόμενη εγκατάσταση στεγάζει 10,000 ζώα (broilers) ανά περίοδο παραγωγής και βρίσκεται στην Βόρεια Ελλάδα στην περιοχή της Καβάλας (  $40.94^{\circ} N$  ,  $24.42^{\circ} E$  ). Η συγκεκριμένη περιοχή χαρακτηρίζεται από υψηλή υγρασία , κρύους χειμώνες και θερμά καλοκαίρια. Τα πτηνοτροφεία κρεοπαραγωγής (broiler houses) όπως και το συγκεκριμένο ,εν γένει χαρακτηρίζονται από μεταβαλλόμενα θερμικά φορτία λόγω του ταχέως ρυθμού ανάπτυξης και του υψηλού πληθυσμού των στεγαζόμενων ζώων.

### 3.3 Σημεία Ρύθμισης (Setpoints)

Το σύστημα της ΑΘ που προσομοιώθηκε από το παραπάνω δυναμικό μοντέλο αποτελείται από τρεις αερόψυκτες μονάδες (air cooled units) με ψυκτικό υγρό R134a. Για την διατήρηση βέλτιστων συνθηκών για τα πουλερικά και την ρύθμιση της λειτουργίας της ΑΘ είναι απαραίτητη η θέσπιση ενός σημείου ρύθμισης (Setpoint) το οποίο θα αποτελεί όριο για την εσωτερική θερμοκρασία και την σχετική υγρασία της πτηνοτροφικής μονάδας. Συνεπώς , η λειτουργία της θέρμανσης ενεργοποιείται όταν η εσωτερική θερμοκρασία πέσει  $2^{\circ}C$  κάτω (-) από το setpoint και απενεργοποιείται όταν φτάσει πάλι αυτό. Η ψύξη, από την άλλη, ενεργοποιείται όταν προκύψει διαφορά θερμοκρασίας  $+2^{\circ}C$  μεταξύ εσωτερικής θερμοκρασίας και setpoint. Επιπλέον ,υπάρχει η δυνατότητα ενεργοποίησης μιας δεύτερης ΑΘ για ψύξη σε περίπτωση που η προηγούμενη διαφορά αυξηθεί παραπάνω από  $3^{\circ}C$ . Για την ρύθμιση της σχετικής υγρασίας υπάρχει η δυνατότητα λειτουργίας έως και των τριών ΑΘ για αφύγρανση και έτσι κάθε μία εξ αυτών ενεργοποιείται όταν υπάρξει διαφορά  $+1\%$  ,  $+2\%$  και  $+3\%$  αντίστοιχα μεταξύ της σχετικής υγρασίας του εσωτερικού και του φρέσκου αέρα. Οι εξεταζόμενες ΑΘ ενεργοποιούνται και απενεργοποιούνται βάσει των παραπάνω συνθηκών


οδηγώντας σε κυμαινόμενες συνθήκες. Θα πρέπει να τονιστεί ότι η μεταβολή της ηλικίας και κατ' επέκταση της μάζας των ζώων απαιτεί συνεχή παρακολούθηση για τη ρύθμιση των συνθηκών και συνεπώς οδηγεί στις μεταβολές των setpoints που παρουσιάζονται παρακάτω.

### 3.4 Εσωτερική θερμοκρασία και σχετική υγρασία


Παρακάτω παρουσιάζονται τα προφίλ της εσωτερικής θερμοκρασίας και σχετικής υγρασίας όπως προσομοιώνονται στην δημοσίευση των *Tyris et al., 2023* για τις εξεταζόμενες περιόδους του χειμώνα και του καλοκαιριού. Θα πρέπει να τονιστεί ότι παρότι η δημοσίευση προσομοιώνει την λειτουργία του συστήματος ΑΘ για επτά περιόδους παραγωγής (Production Periods) στα πλαίσια της παρούσας εργασίας εξετάζονται αποκλειστικά οι περίοδοι PP1 και PP4 που αντιστοιχούν σε χειμώνα και καλοκαίρι. Αυτό συμβαίνει διότι σε αυτές τις περιόδους είναι πιο έντονες οι επιδράσεις της εποχής (θερμό και ψυχρό κλίμα) στα δεδομένα που εξετάζονται και επιπλέον δίνεται η δυνατότητα μιας βαθύτερης αξιοποίησης και δοκιμής παραμέτρων των ΤΝΔ.

Οι διακυμάνσεις της εσωτερικής θερμοκρασίας και σχετικής υγρασίας για την περίοδο PP1 (01.01-05.02) παρουσιάζονται στην **Εικόνα 3.13**. Η μετρούμενη εξωτερική θερμοκρασία περιβάλλοντος παρουσίασε τιμές από -5.90 μέχρι 14.8°C (με μέση τιμή 4.01) και η σχετική υγρασία τιμές από 37.6 μέχρι 99.5 % (με μέση τιμή 80.1%). Από την άλλη, η εσωτερική θερμοκρασία παρουσίασε μέγιστη διακύμανση -2.5 °C από την θερμοκρασία setpoint τις πρώτες 20 ημέρες και +2.1 °C τις τελευταίες 5 ημέρες όταν η εξωτερική θερμοκρασία ανήλθε. Η εσωτερική σχετική υγρασία βρισκόταν ως επί το πλείστον εντός των επιθυμητών ορίων (ανώτατου και κατώτατου) υπερβαίνοντας το μονάχα τις τελευταίες 5 ημέρες κατά +2.2%. Τόσο η θερμοκρασία setpoint εύρους 34-19°C όσο και η εσωτερική σχετική υγρασία ,εύρους 30-50% (κατώτατο) και 50-70 % (ανώτατο), ρυθμίζονται συναρτήσει της μάζας των ζώων [*Tyris et al., 2023*].

Οι μεταβολές της εσωτερικής σχετικής υγρασίας και θερμοκρασίας κατά την θερινή περίοδο PP4 (31.05-05.07) παρουσιάζονται στην **Εικόνα 3.14**. Παρατηρήθηκε ότι η εξωτερική θερμοκρασία κυμαίνεται μεταξύ 14 και 32.8 °C (μέση τιμή 23.5) και η σχετική υγρασία μεταξύ 29.6 και 86.8 % (μέση τιμή 60.9%). Λόγω μιας αισθητής απόκλισης +5°C μεταξύ της εσωτερικής θερμοκρασίας και της θερμοκρασίας setpoint τις τελευταίες 2 ημέρες της περιόδου ,η ΑΘ δεν μπόρεσε να καλύψει τις ανάγκες ψύξης για αυτές. Η συγκεκριμένη απόκλιση αποδίδεται στην υψηλή εξωτερική θερμοκρασία και το αυξημένο (πλέον) μέγεθος των ζώων τα οποία αυξάνουν τα εσωτερικά θερμικά φορτία και τις ανάγκες αερισμού. Εν τέλει, η εσωτερική σχετική υγρασία αποκλίνει ελάχιστα και προσωρινά από τα αποδεκτά όρια [*Tyris et al., 2023*].



**Εικόνα 3.13 : Μεταβολές σχετικής υγρασίας και εσωτερικής θερμοκρασίας κατά την 1<sup>η</sup> περίοδο παραγωγής (01.01-05.02) (Tyriss et al.,2023)**



**Εικόνα 3.14: Μεταβολές σχετικής υγρασίας και εσωτερικής θερμοκρασίας κατά την 4<sup>η</sup> περίοδο παραγωγής (31.05-05.07) (Tyriss et al.,2023)**

### 3.5 Θερμικά Φορτία Ζώων

Πέραν της εσωτερικής θερμοκρασίας και σχετικής υγρασίας βασική παράμετρος του δυναμικού μοντέλου υπήρξε το θερμικό φορτίο των ζώων. Η μάζα των ζώων,  $m_{br}(kg)$ , για κάθε ημέρα μιας περιόδου παραγωγή υπολογίστηκε βάσει της παρακάτω **Εξίσωσης 3.18**:

$$m_{br} = f1 * d3 + f2 * d2 + f3 * d + f4 \quad (3.18)$$


όπου οι συντελεστές  $f_i$ ,  $i=1,2,3,4$  δίνονται από τον **Πίνακα 3**

Ειδικότερα, σε αμφότερες τις περιόδους παραγωγής PP1 και PP4 , η εκτιμώμενη μάζα των ζώων και τα θερμικά φορτία (αισθητά και λανθάνοντα) αυτών παρουσίασαν μεγάλη αύξηση η οποία παρουσιάζεται παρακάτω στις **Εικόνες 3.15** και **3.16**.

**Πίνακας 3: Συντελεστές για υπολογισμό μάζας ζώων (Tyriss et al.,2023)**


**Table 3.** Factors for broiler mass calculation.

Factor	Value	Units
$f_1$	$-2.1164 \times 10^{-5}$	[kg/day <sup>3</sup> ]
$f_2$	$+2.5608 \times 10^{-3}$	[kg/day <sup>2</sup> ]
$f_3$	$-5.3002 \times 10^{-3}$	[kg/day]
$f_4$	$+7.0839 \times 10^{-2}$	[kg]



**Εικόνα 3.15 : Μάζα (kg) και θερμικά φορτία (kW) των ζώων συναρτήσει του χρόνου (ημέρες) κατά την περίοδο παραγωγής PP1 (Tyriss et al.,2023).**





**Εικόνα 3.16: Μάζα (kg) και θερμικά φορτία (kW) των ζώων συναρτήσει του χρόνου (ημέρες) κατά την περίοδο παραγωγής PP4 (Tyrís et al., 2023).**

### 3.6 (Εποχικοί) Συντελεστές απόδοσης (COP/EER)

Το δυναμικό μοντέλο της ΑΘ των Tyrís et al., 2023 λαμβάνοντας ως δεδομένα τα παραπάνω στοιχεία εκτίμησε τις τιμές των συντελεστών απόδοσης COP και EER για την θέρμανση και ψύξη αντίστοιχα. Οι υπολογισμοί βασίστηκαν στην ισχύ που καταναλώνει ο συμπιεστής της ΑΘ για την παρεχόμενη και απορριπτόμενη θερμότητα όπως εκφράζονται και στις παρακάτω Εξισώσεις 3.19 & 3.20:

$$COP = \frac{Q_{heat}}{W_{comp}} \quad (3.19)$$


$$EER = \frac{Q_{cooling}}{W_{comp}} \quad (3.20)$$

Για την εξακρίβωση της εγκυρότητας του συντελεστή COP που υπολογίστηκε από το δυναμικό μοντέλο έγινε σύγκριση με τις τιμές COP που παρέχει το λογισμικό του κατασκευαστή του συμπιεστή. Οι αποκλίσεις μεταξύ θερμοχωρητικότητας και COP για σταθερές συνθήκες υπό διαφορετικές συνθήκες λειτουργίας υπολογίζονται και παρουσιάζονται παρακάτω [Tyrís et al., 2023].

Πιο συγκεκριμένα, η απόκλιση (D %) μεταξύ των υπολογιζόμενων τιμών COP (M) και των τιμών του λογισμικού του κατασκευαστή (S) δίνονται από την παρακάτω σχέση:

$$D = \left( \frac{M-S}{S} \right) * 100\% \quad (3.21)$$

Όπως παρουσιάζεται στην **Εικόνα 3.17**, η απόκλιση μεταξύ των αναμενόμενων τιμών COP από το δυναμικό μοντέλο και το λογισμικό του κατασκευαστή εμφανίζεται κάτω από 2% και επομένως είναι αποδεκτή και το μοντέλο μπορεί να προσομοιώσει ικανοποιητικά την λειτουργία και απόδοση της ΑΘ.



**Εικόνα 3.17: Διακύμανση της θερμοχωρητικότητας και του συντελεστή απόδοσης (COP) μεταξύ του δυναμικού μοντέλου και της αναμενόμενης απόδοσης του συμπιεστή (Tyrís et al.,2023).**

Επιπλέον υπολογίστηκαν και οι εποχικοί συντελεστές απόδοσης της ΑΘ για κάθε θερμική λειτουργία. Αυτοί περιλαμβάνουν τον συντελεστή SCOP για την θέρμανση και την αφύγρανση και τον συντελεστή SEER. Ως αποτέλεσμα, για την περίοδο παραγωγής PP1 (χειμώνας) ο συντελεστής απόδοσης για θέρμανση και την αφύγρανση υπολογίστηκε 3.1 και 7 αντίστοιχα. Για την περίοδο παραγωγής PP4 (καλοκαίρι), από την άλλη, ο συντελεστής απόδοσης για την ψύξη και την αφύγρανση βρέθηκε 3.7 και 4.8 αντίστοιχα.

## ΚΕΦΑΛΑΙΟ 4

### Μεθοδολογία για το Νευρωνικό Δίκτυο

Με την ολοκλήρωση του κεφαλαίου της θερμοδυναμικής και την περιγραφή του δυναμικού μοντέλου της αντλίας θερμότητας, που υπήρξε κρίσιμο καθώς παρείχε τα αναγκαία δεδομένα, ακολουθεί το κυρίως μέρος της διπλωματικής εργασίας που αφορά την εκπαίδευση των τεχνητών νευρωνικών δικτύων.

Αρχικά, τα δεδομένα που επεξεργάστηκαν στα πλαίσια της παρούσας εργασίας αφορούν τον συντελεστή απόδοσης της αντλίας θερμότητας (COP) καθώς και τις παραμέτρους εισόδου που αποτελούνται από τα θερμικά φορτία των ζώων (αισθητά και λανθάνοντα), την εσωτερική σχετική υγρασία καθώς και την εσωτερική θερμοκρασία ρύθμισης (setpoint) της εγκατάστασης. Τα χρονικά διαστήματα που εξετάστηκαν αφορούν τόσο την χειμερινή (01.01-05.02) όσο και τη θερινή περίοδο (31.05-05.07). Για την εκπαίδευση των ΤΝΔ ήταν απαραίτητη η δημιουργία ενός πίνακα εισόδου καθώς και ενός διανύσματος στόχου, τα οποία και παρουσιάζονται παρακάτω. Αποσκοπώντας στην ταχύτερη σύγκλιση του νευρωνικού δικτύου πραγματοποιήθηκε κανονικοποίηση (z score standardization) των δεδομένων εισόδου βάσει της παρακάτω **Εξίσωσης 4.22**:

$$z=(X-\mu)/\sigma \quad (4.22)$$

όπου  $X$  η εκάστοτε τιμή των δεδομένων εισόδου,  $\mu$  η μέση τιμή αυτών και  $\sigma$  η τυπική απόκλιση τους.

Με αυτό τον τρόπο δημιουργήθηκαν 3 στήλες κανονικοποιημένων δεδομένων εισόδου:

- Η 1η στήλη αφορά την εσωτερική θερμοκρασία Setpoint (ρύθμισης) της εγκατάστασης
- Η 2η στήλη αφορά την εσωτερική σχετική υγρασία της εγκατάστασης
- Η 3η στήλη αφορά τα θερμικά φορτία των ζώων

Το διάνυσμα στόχου COP περιέχει τις προσομοιωμένες τιμές του COP για την αντλία θερμότητας όπως αυτός υπολογίστηκε από το δυναμικό μοντέλο των *Manolakos et al., 2019* και *Tyris et al., 2023*. Η λήψη μετρήσεων πεδίου για τον συντελεστή απόδοσης δεν κατέστη δυνατή στα πλαίσια της παρούσας εργασίας οπότε έπρεπε να βασιστούμε στις τιμές που υπολογίζει το συγκεκριμένο μοντέλο. Να σημειωθεί ότι ενώ το συγκεκριμένο μοντέλο υπολογίζει τον μέσο συντελεστή εποχιακής απόδοσης (COP/SEER) για κάθε περίοδο παραγωγής (Production Period), η οποία διαρκεί 35 ημέρες, πραγματοποιήθηκαν τροποποιήσεις από τον κ. Τύρη σε αυτό, με σκοπό την παροχή τιμών απόδοσης COP για κάθε χρονικό βήμα (ανά λεπτό). Αυτό είναι απαραίτητο για την εκπαίδευση του νευρωνικών δικτύων καθώς απαιτείται τα δεδομένα εισόδου (οι τιμές των οποίων μετρήθηκαν και υπολογίστηκαν ανά λεπτό) να είναι σε αντίστοιχη κλίμακα με τον συντελεστή απόδοσης ώστε να πραγματοποιηθεί η εκπαίδευση.

Στα πλαίσια του συγκεκριμένου μοντέλου της αντλίας θερμότητας και για την κάλυψη των αναγκών ψύξης, θέρμανσης και αφύγρανσης του εξεταζόμενου κτιρίου αξιοποιείται ένα σύστημα τριών αντλιών θερμότητας. Αυτό έχει ως αποτέλεσμα, αν το απαιτούν οι συνθήκες εντός του κτιρίου να ενεργοποιούνται παραπάνω από μια ΑΘ ή και για παραπάνω από μία

λειτουργία ταυτοχρόνως. Ειδικότερα, για ορισμένα χρονικά διαστήματα λειτουργούν 2 ή 3 ΑΘ ταυτοχρόνως για κάλυψη των αναγκών της αφύγρανσης οπότε λαμβάνεται ο μέσος όρος του συντελεστή απόδοσης τους στον οποίο δεν συνυπολογίζεται αν κάποια τιμή COP ισούται με μηδέν (οπότε η ΑΘ δεν βρίσκεται σε λειτουργία). Από την άλλη για την κάλυψη των αναγκών των λειτουργιών της θέρμανσης απαιτείται κάθε φορά μία ΑΘ οπότε δεν υπολογίζεται κάποιος μέσος όρος ενώ για την ψύξη υπολογίζεται η μέση τιμή του συντελεστή COP για ορισμένα διαστήματα.

Με βάση τις παραπάνω επεξηγήσεις για τον συντελεστή απόδοσης της ΑΘ το διάνυσμα στόχου (COP) αναλόγως την εξεταζόμενη περίοδο λαμβάνει τις παρακάτω τιμές:

Για την χειμερινή περίοδο παραγωγής (PP1) λαμβάνει τιμές για θέρμανση και αφύγρανση ενώ δεν υπολογίζονται τιμές για ψύξη καθώς οι ανάγκες είναι μηδαμινές. Αντιστρόφως, για την θερινή περίοδο παραγωγής (PP4) λαμβάνει τιμές για ψύξη και τιμές για αφύγρανση ενώ δεν υπολογίζονται τιμές για θέρμανση καθώς οι ανάγκες είναι μηδαμινές.

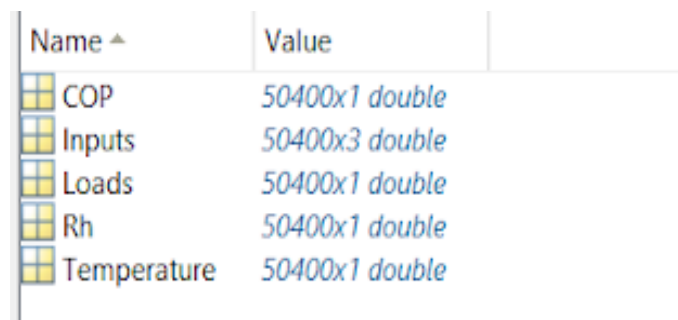
Με βάση τις παραπάνω παραδοχές και με σκοπό να εξεταστεί κάθε θερμική λειτουργία ξεχωριστά, σχεδιάστηκαν διακριτά νευρωνικά δίκτυα για θέρμανση, ψύξη και αφύγρανση. Πιο συγκεκριμένα, για την χειμερινή περίοδο σχεδιάστηκαν δύο είδη νευρωνικών δικτύων με διάνυσμα στόχου μιας στήλης το καθένα όπου το ένα έλαβε τις τιμές του συντελεστή απόδοσης της ΑΘ για θέρμανση και το άλλο την μέση τιμή του για την αφύγρανση. Αντίστοιχα, για την θερινή περίοδο τα διανύσματα στόχου των δύο ειδών νευρωνικών δικτύων έλαβαν τις τιμές του συντελεστή απόδοσης της ΑΘ για ψύξη και την μέση τιμή του για την αφύγρανση.

## 4.1 Δημιουργία μεταβλητών εισόδου/εξόδου

Η μεθοδολογία για την δημιουργία των μεταβλητών εισόδου στην Matlab και την εκπαίδευση των ΤΝΔ υπήρξε η ίδια για όλες τις περιόδους και τις θερμικές λειτουργίες που εξετάζονται οπότε στην παρούσα ενότητα παρουσιάζεται ενδεικτικά μόνο η περίπτωση της θέρμανσης την χειμερινή περίοδο διάρκειας 35 ημερών. Για τις περιπτώσεις της ψύξης κατά την καλοκαιρινή περίοδο καθώς και της αφύγρανσης την χειμερινή και την καλοκαιρινή περίοδο ακολουθήθηκαν τα παρακάτω βήματα με την διαφοροποίηση ότι η μεταβλητή COP λάμβανε κάθε φορά τις τιμές για την αντίστοιχη θερμική λειτουργία.

Οι μεταβλητές εισόδου (κανονικοποιημένες) και εξόδου που χρησιμοποιήθηκαν για την εκπαίδευση των νευρωνικών δικτύων παρουσιάζονται παρακάτω. Να σημειωθεί ότι όλες οι μεταβλητές εισάγονται έχοντας κανονικοποιηθεί στην Matlab με μορφή numeric matrix και περιέχουν τιμές ανά ένα λεπτό.

- Η μεταβλητή “Loads” (διαστάσεων 50400x1) περιέχει τα δεδομένα των θερμικών φορτίων των ζώων.
- Η μεταβλητή “Rh” (διαστάσεων 50400x1) περιέχει τα δεδομένα της σχετικής υγρασίας εντός του κτιρίου.
- Η μεταβλητή “Temperature” (διαστάσεων 50400x1) περιέχει τα δεδομένα της θερμοκρασίας ρύθμισης (setpoint) εντός του κτιρίου.
- Η μεταβλητή “Inputs” (διαστάσεων 50400x3) περιλαμβάνει και τις τρεις παραπάνω μεταβλητές σε μία νέα που χρησιμοποιείται ως δεδομένο εισόδου κατά την εκπαίδευση.
- Η μεταβλητή “COP” (διαστάσεων 50400x1) και περιλαμβάνει τις τιμές της απόδοσης (COP) της ΑΘ για την θέρμανση ,όπως προέκυψαν από τις δοκιμές (runs) του δυναμικού μοντέλου που εξετάστηκε στο προηγούμενο κεφάλαιο.



Name ▲	Value
COP	50400x1 double
Inputs	50400x3 double
Loads	50400x1 double
Rh	50400x1 double
Temperature	50400x1 double

**Εικόνα 4.18: Στιγμιότυπο από το Workspace της Matlab που περιλαμβάνει τις απαραίτητες μεταβλητές (θέρμανση κατά τον χειμώνα, περίοδος PP1).**

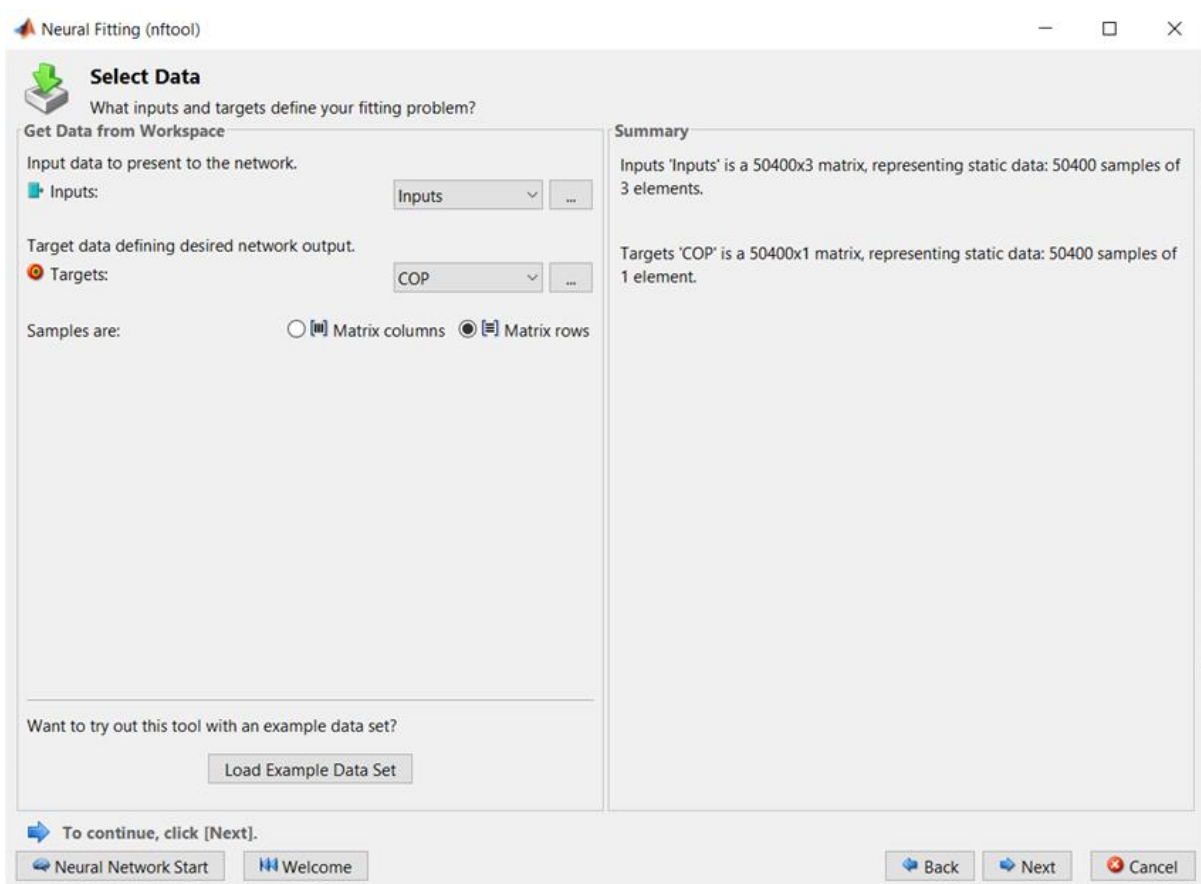
Βάσει των παραπάνω μεταβλητών εκπαιδεύτηκαν τεχνητά νευρωνικά δίκτυα με χρήση του αλγορίθμου Levenberg-Marquardt.

## 4.2 Βήματα εκπαίδευσης νευρωνικών δικτύων το Neural Fitting tool

Για την εκπαίδευση των νευρωνικών δικτύων χρησιμοποιήθηκε το περιβάλλον της Matlab και συγκεκριμένα το εργαλείο Neural Fitting (nftool) ακολουθώντας τα βήματα που παρουσιάζονται.

### Βημα 1: Επιλογή πίνακα εισόδου και διανύσματος στόχου

Η μεταβλητή “Inputs” διαστάσεων 50400x3 επιλέγεται για τα Inputs του nftool και η μεταβλητή “COP” διαστάσεων 50400x1 για τα Targets του nftool. Ο πίνακας εισόδου και το διάνυσμα στόχου έχουν ίδιο αριθμό γραμμών, το οποίο είναι απαραίτητο για την ορθή λειτουργία του ΤΝΔ και για αυτό επιλέγεται το “Matrix rows” στο nftool.

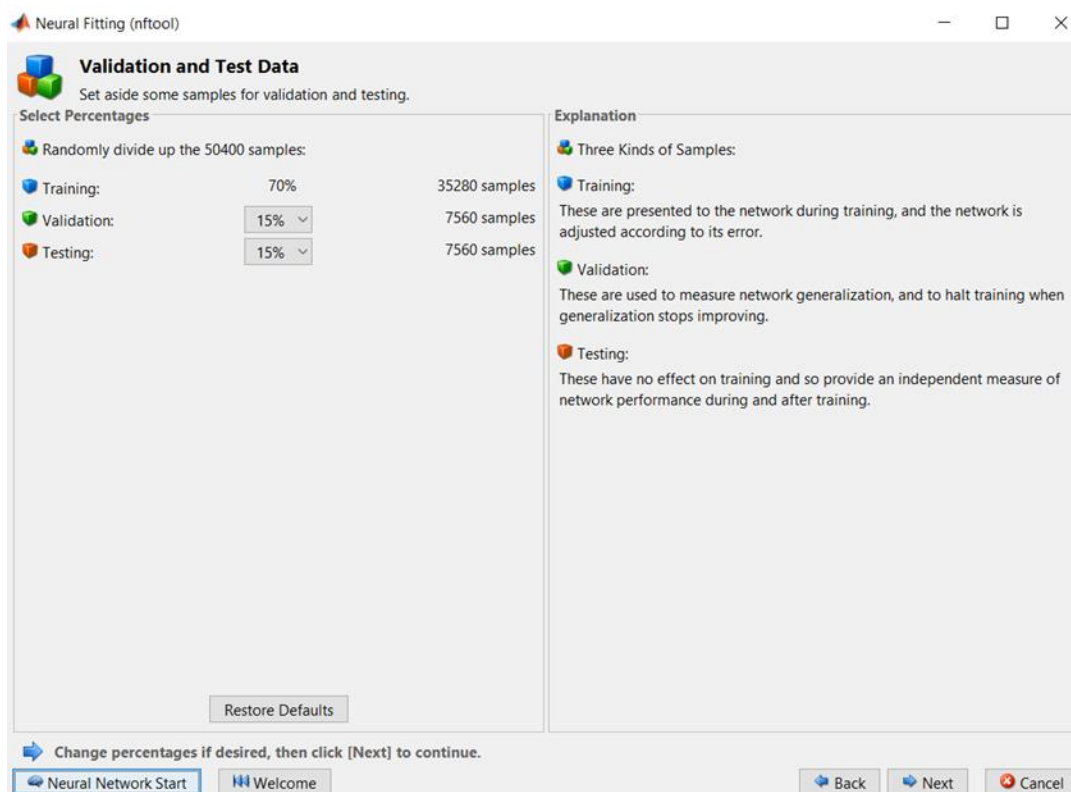


**Βήμα 1 : Εισαγωγή δεδομένων εισόδου και στόχου**

## **Βήμα 2: Πραγματοποιείται τυχαίος διαχωρισμός δεδομένων προς εκπαίδευση(Training), επικύρωση (Validation) και έλεγχο (testing).**

Για την αποτελεσματική εκπαίδευση των ΤΝΔ και την διατήρηση της ευρωστίας(robustness) τους είναι απαραίτητος ο διαχωρισμός των δεδομένων σε 3 υποσύνολα. Πιο συγκεκριμένα , γίνεται τυχαίος διαχωρισμός των δεδομένων για εκπαίδευση(Training), επικύρωση (Validation) και έλεγχο (testing). Τα δεδομένα εκπαίδευσης παρέχονται στο δίκτυο κατά την εκπαίδευση και αυτό προσαρμόζεται βάσει του σφάλματος (training MSE). Τα δεδομένα επικύρωσης χρησιμοποιούνται για την μέτρηση της γενίκευσης του δικτύου και η εκπαίδευση σταματά όταν η γενίκευση παύσει να βελτιώνεται. Από την άλλη πλευρά ,τα δεδομένα για έλεγχο δεν επηρεάζουν την εκπαίδευση αλλά αποτελούν ένα μέτρο της απόδοσης του δικτύου τόσο κατά την διάρκεια όσο και μετά την εκπαίδευση.

Τα αποτελέσματα στην πρώτη φάση δοκιμών (για όλες τις θερμικές λειτουργίες και τις περιόδους) λήφθηκαν λαμβάνοντας τα προκαθορισμένα ποσοστά 70% , 15% και 15% για την εκπαίδευση , την επικύρωση και τον έλεγχο του ΤΝΔ αντίστοιχα.



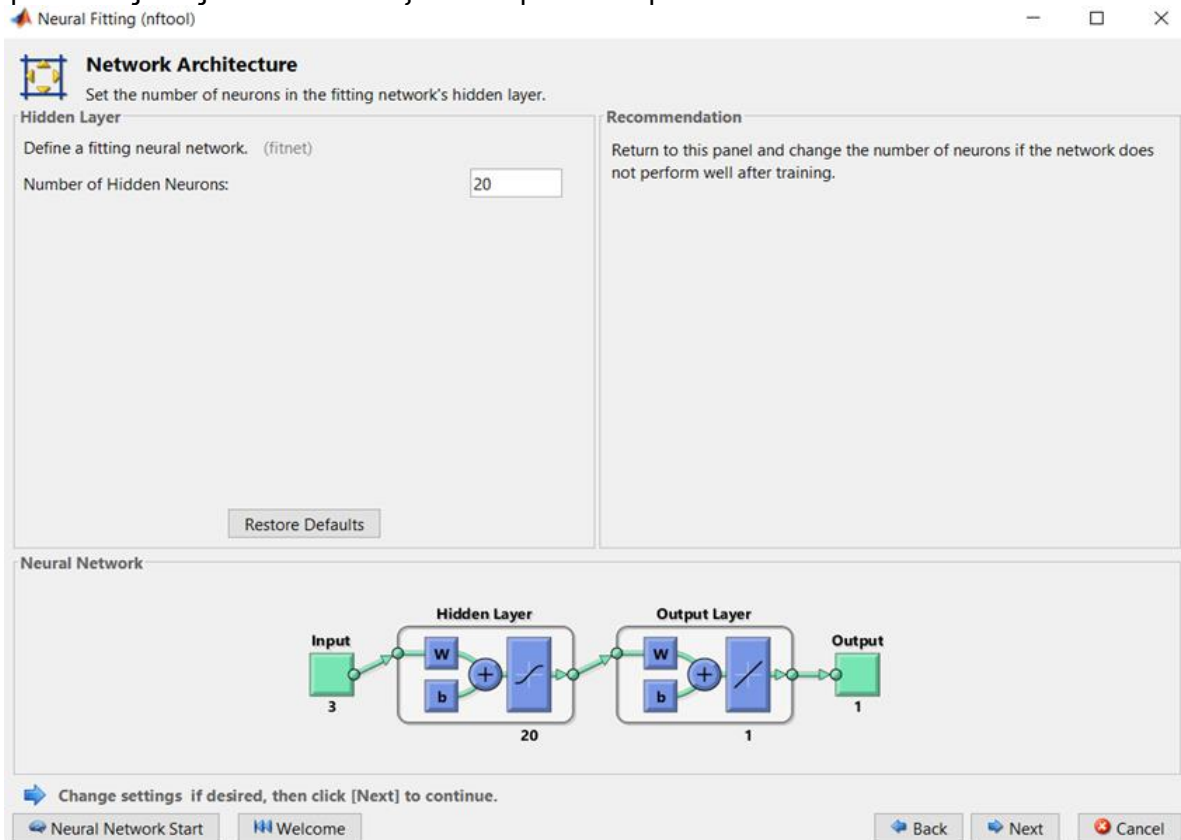
**Βήμα 2 : Επιλογή ποσοστών εκπαίδευσης, επικύρωσης και ελέγχου**

### **Βήμα 3ο: Επιλογή κρυφών κόμβων**

Σε αυτό το βήμα επιλέχθηκαν οι κρυφοί κόμβοι του ΤΝΔ , οι οποίοι μεσολαβούν μεταξύ των δεδομένων εισόδου και εξόδου και ο αριθμός τους επηρεάζει άμεσα την απόδοση και αξιοπιστία του ΤΝΔ.

Όπως φαίνεται και από τις εικόνες από το nftool μεταξύ των δεδομένων εισόδου και εξόδου υπάρχουν δύο επίπεδα ,το κρυφό (Hidden Layer) και το επίπεδο εξόδου (Output Layer). Το πρώτο δέχεται τον αριθμό νευρώνων-κόμβων που του δίνουμε σε κάθε δοκιμή ενώ το επίπεδο εξόδου έχει έναν κόμβο.

Σε κάθε δοκιμή άλλαζε ο αριθμός των κρυφών κόμβων ξεκινώντας από 10 ή 20 κόμβους και φτάνοντας τους 100 ώστε να εξεταστεί η απόδοση του ΤΝΔ.

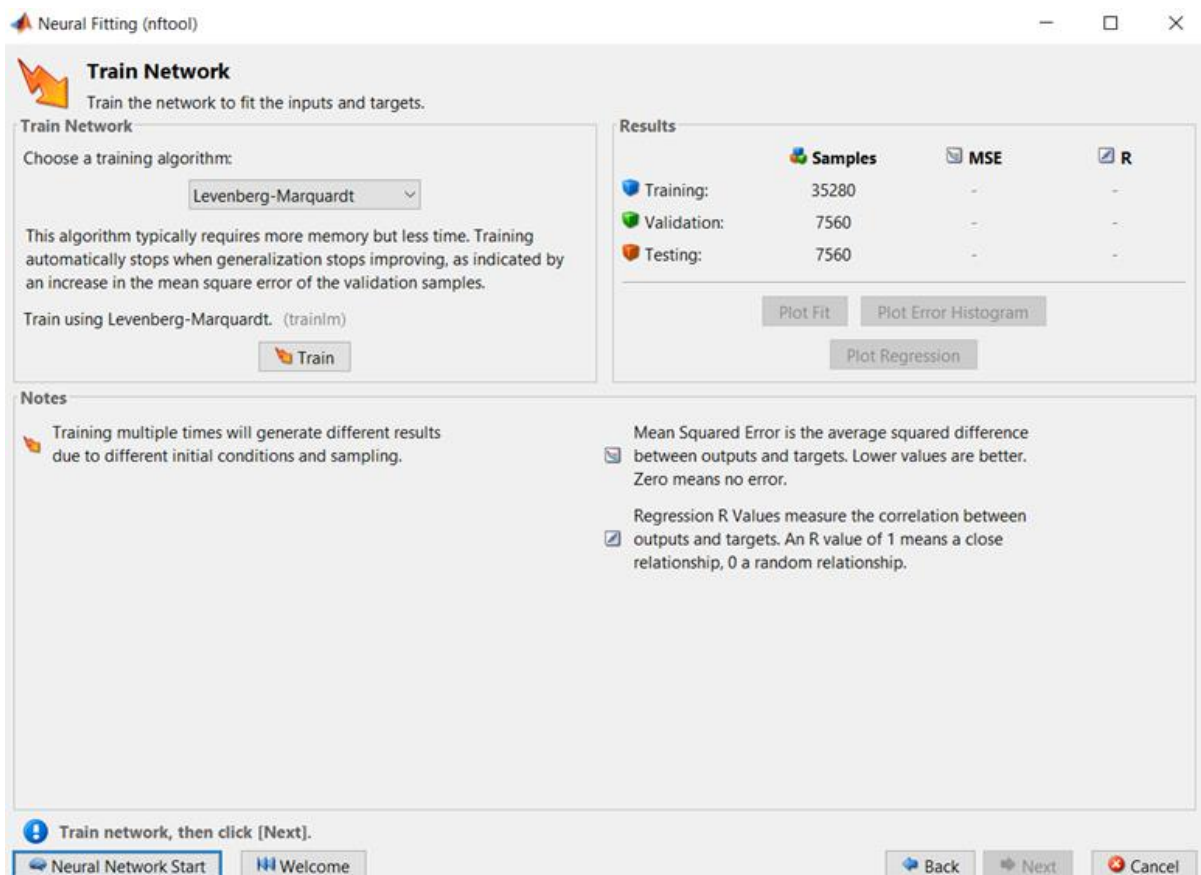


**Βήμα 3 : Επιλογή των κρυφών κόμβων**



## Βήμα 4ο: Αλγόριθμος Εκπαίδευσης

Ο αλγόριθμος Levenberg-Marquardt (LM) που χρησιμοποιήθηκε αποτελεί τον ταχύτερο αλγόριθμο backpropagation (οπισθοδρομικής διάδοσης) στην εργαλειοθήκη της matlab και συνίσταται για την εκπαίδευση ΤΝΔ παρότι καταλαμβάνει περισσότερη μνήμη από τους υπόλοιπους αλγορίθμους (<https://www.mathworks.com/help/deeplearning/ref/trainlm.html>) . Οι παράμετροι που χρησιμοποιήθηκαν για την εκπαίδευση του νευρωνικού δικτύου περιλαμβάνουν τόσο τους κρυφούς κόμβους όσο και τα ποσοστά εκπαίδευσης, επικύρωσης και ελέγχου.



Βήμα 4 : Επιλογή αλγορίθμου εκπαίδευσης

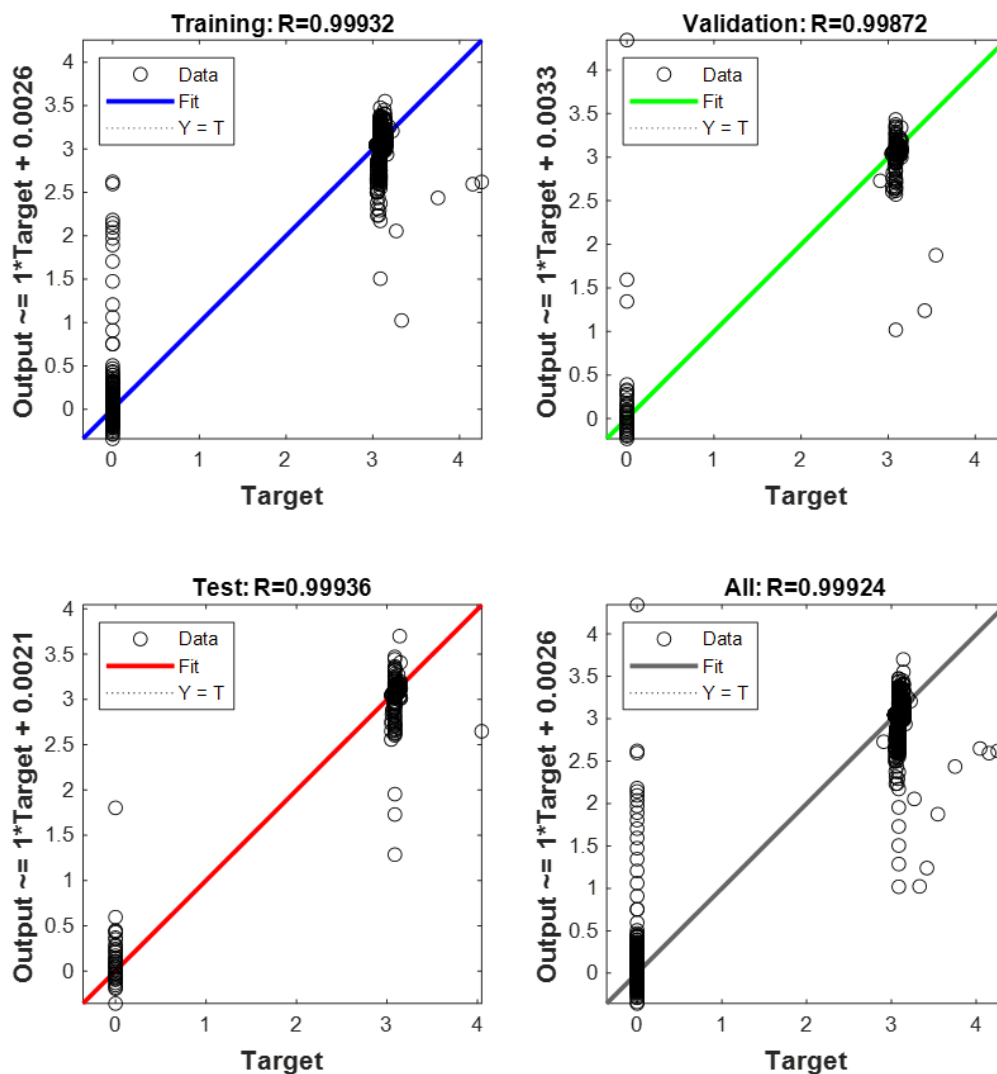
## Κεφάλαιο 5

### Αποτελέσματα

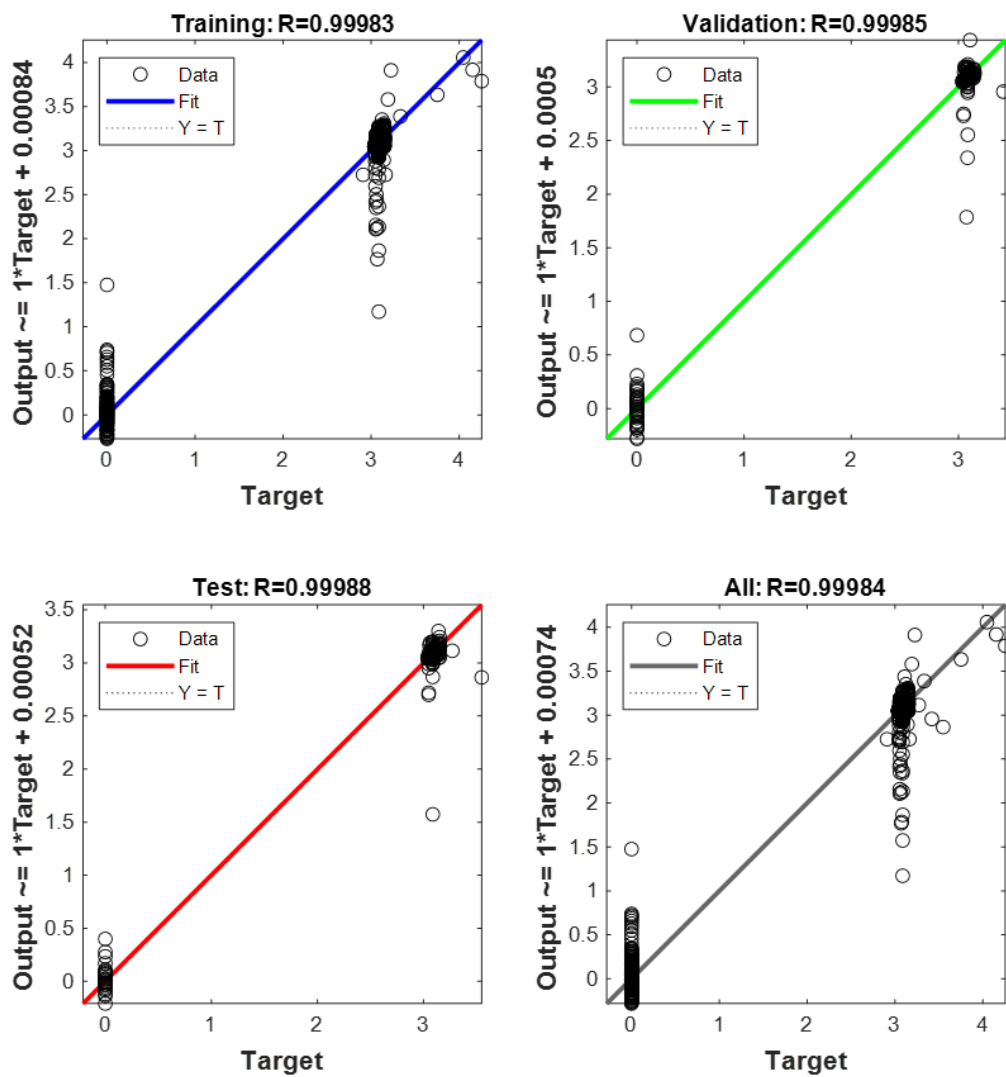
#### 5.1 Προκαθορισμένα ποσοστά εκπαίδευσης,ελέγχου και επικύρωσης

##### 5.1.1 Χειμερινή Περίοδος (PP1)

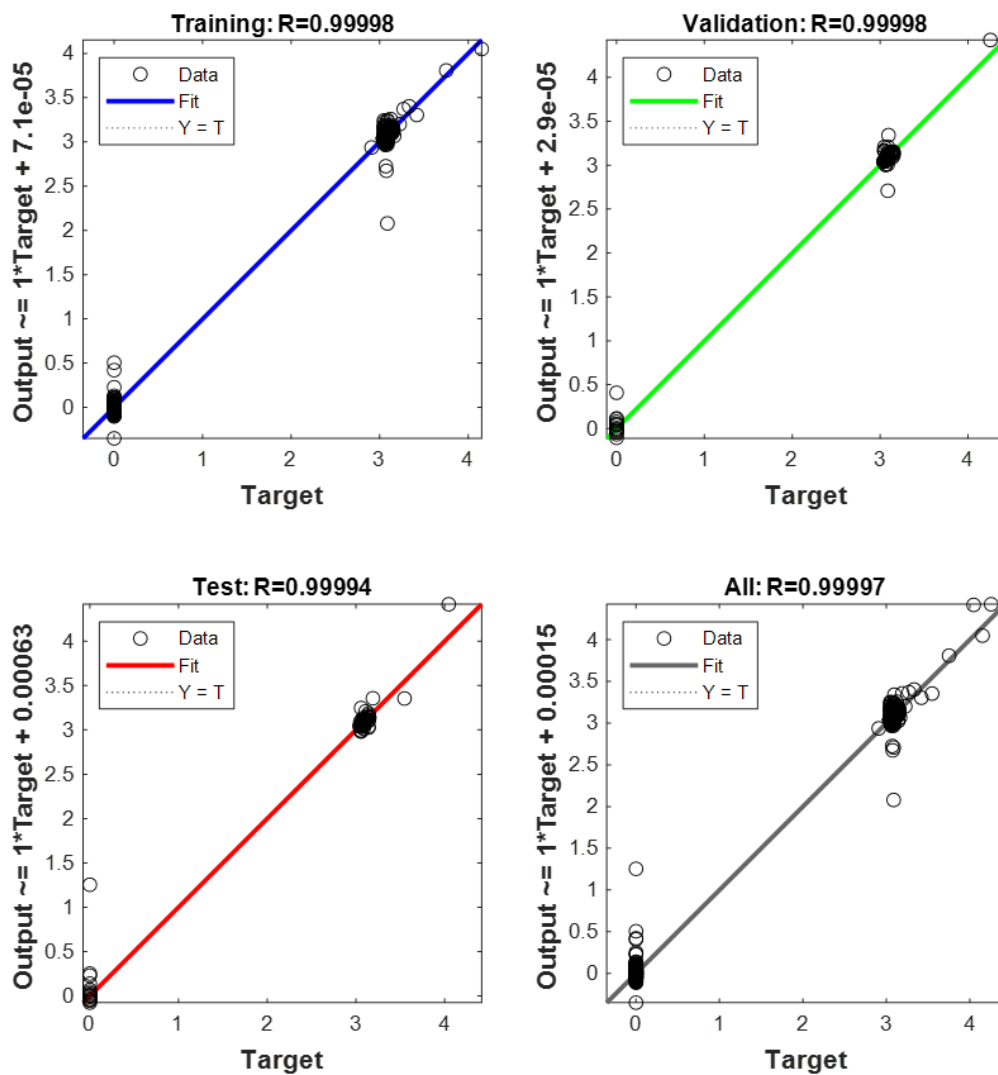
###### Θέρμανση



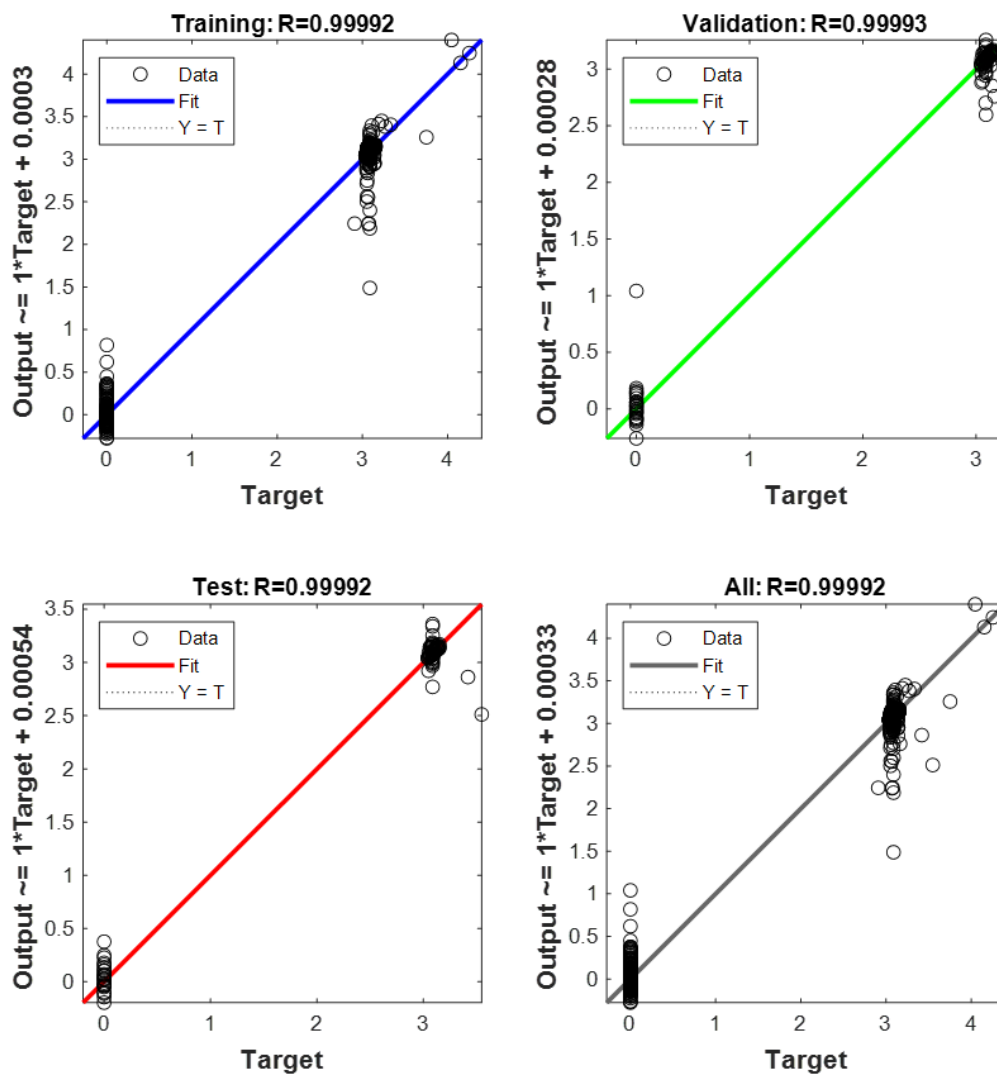
**Διάγραμμα 1: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα θέρμανσης με 10 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**



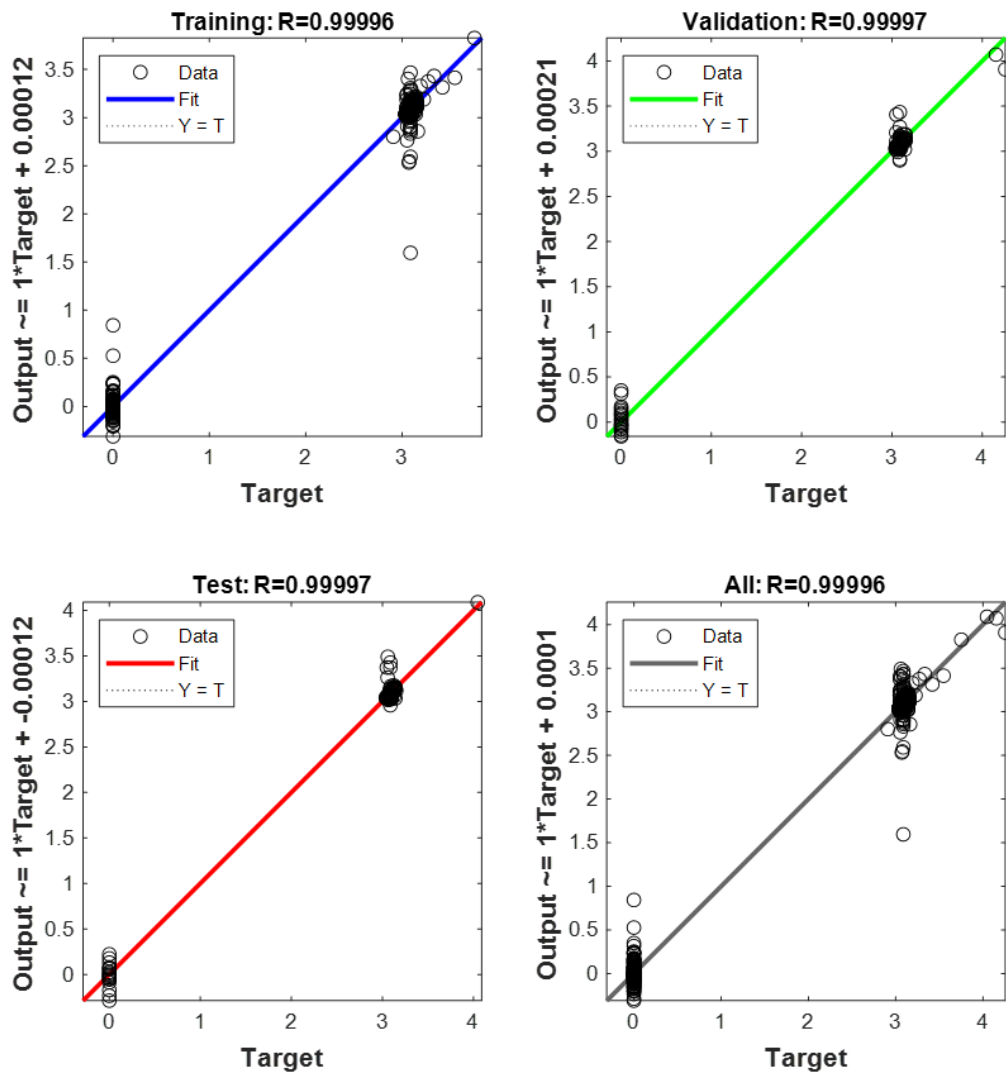
**Διάγραμμα 2: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα θέρμανσης με 20 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**



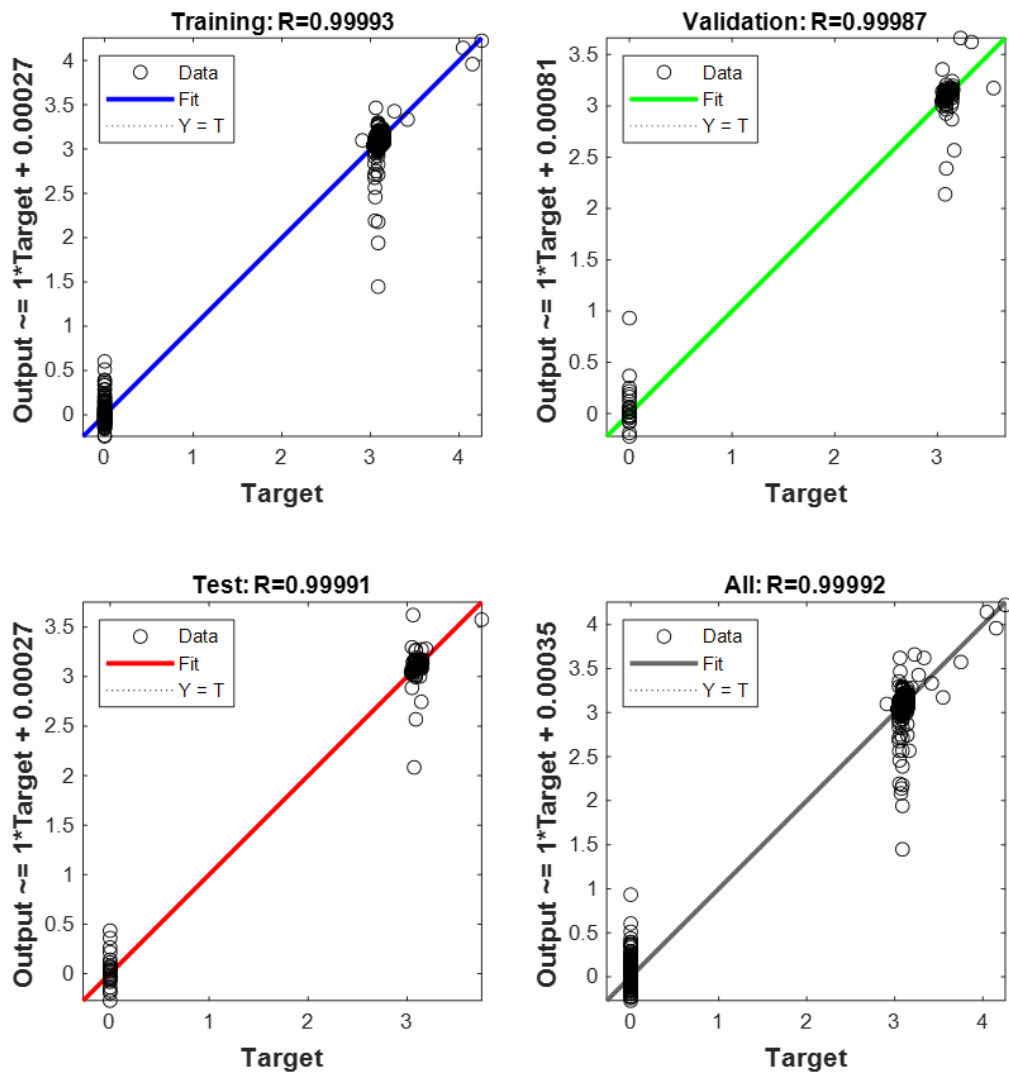
**Διάγραμμα 3: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα θέρμανσης με 25 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing**



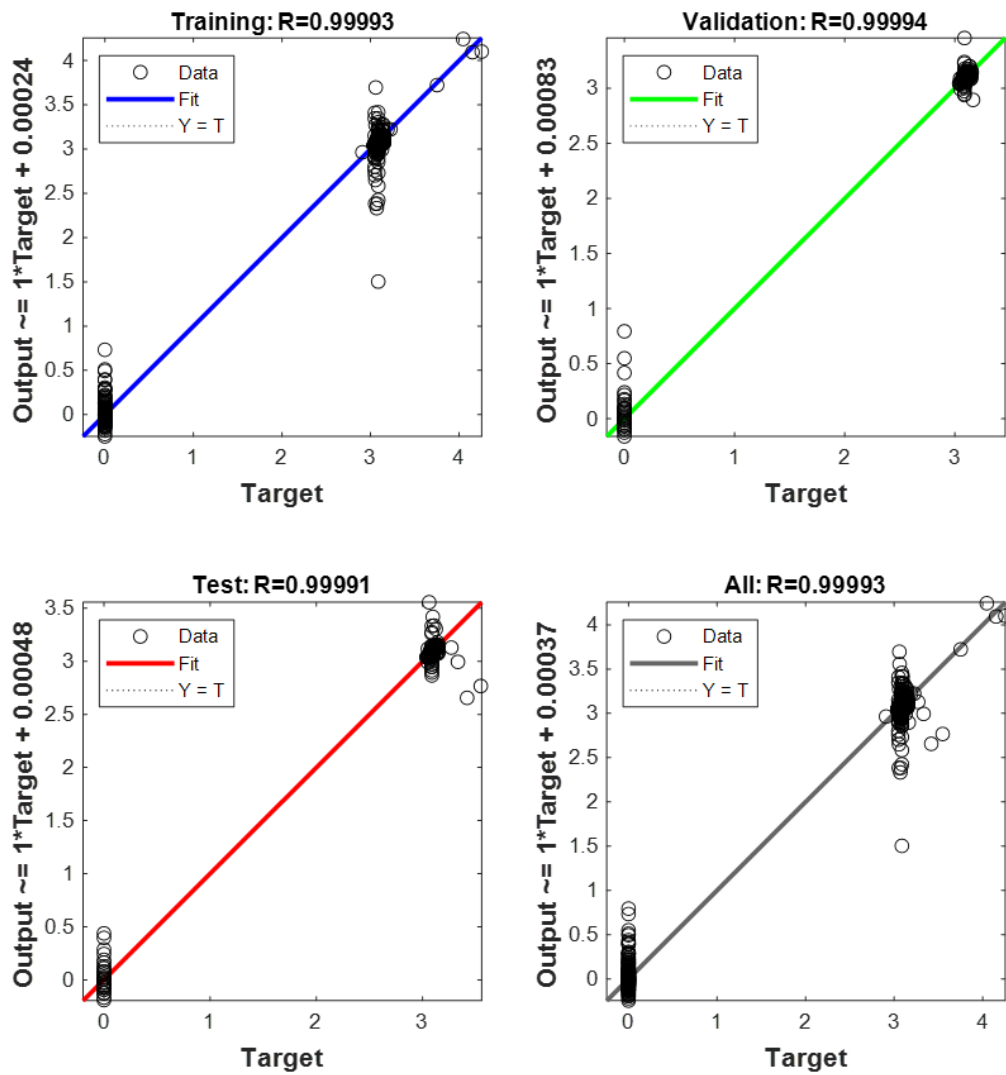
**Διάγραμμα 4: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα θέρμανσης με 30 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing**



**Διάγραμμα 5 :Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα θέρμανσης με 35 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing**

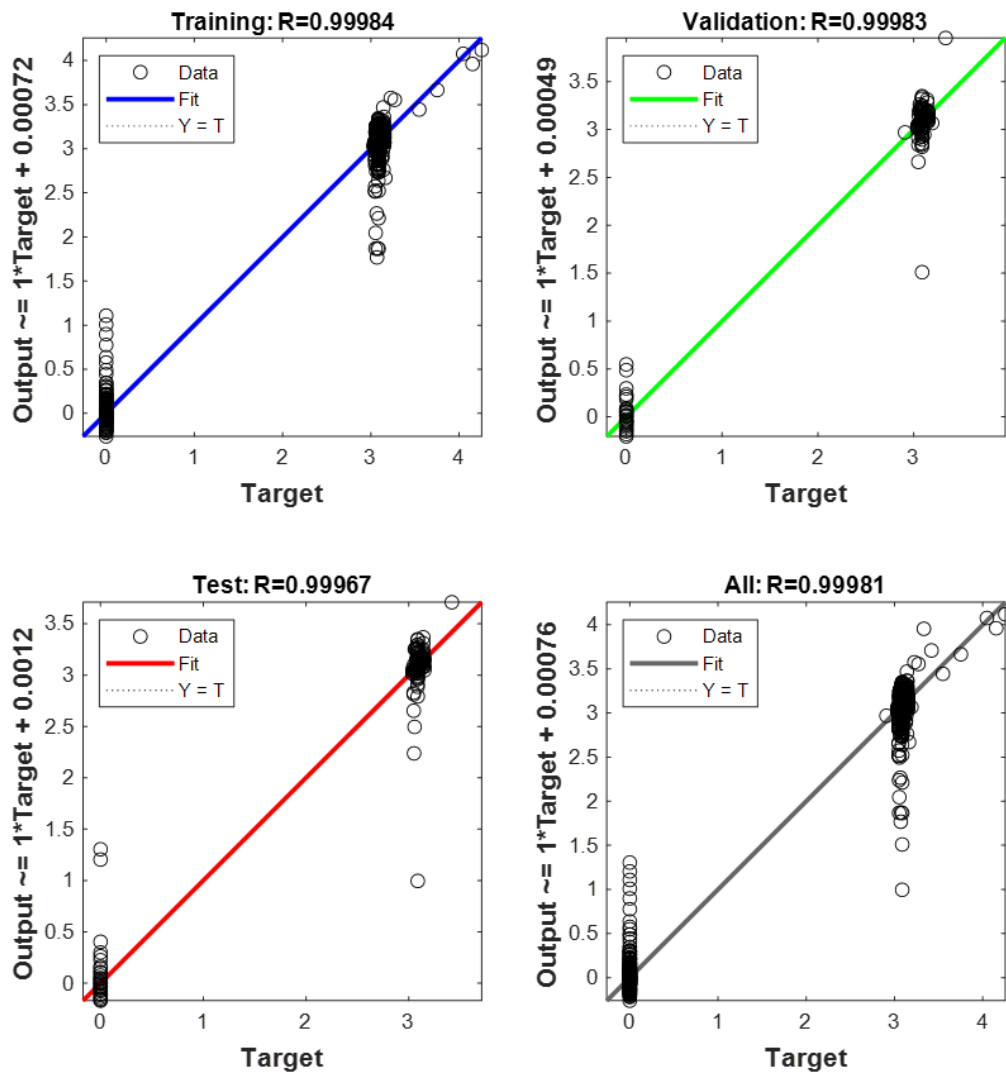


**Διάγραμμα 6: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα θέρμανσης με 50 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing**



**Διάγραμμα 7: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα θέρμανσης με 80 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing**





**Διάγραμμα 8: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα θέρμανσης με 100 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing**

**Πίνακες αποτελεσμάτων για θέρμανση την χειμερινή περίοδο (PP1)**

**Πίνακας 4: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt**

Διάγραμμα	Κρυφοί Κόμβοι	Percentages			Epochs
		Training	Validation	Testing	
1	10	70 %	15%	15%	1000
2	20	70 %	15%	15%	1000
3	25	70 %	15%	15%	1000
4	30	70 %	15%	15%	1000
5	35	70 %	15%	15%	1000
6	50	70 %	15%	15%	1000
7	80	70 %	15%	15%	1000
8	100	70 %	15%	15%	1000

**Πίνακας 5: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης(R).**

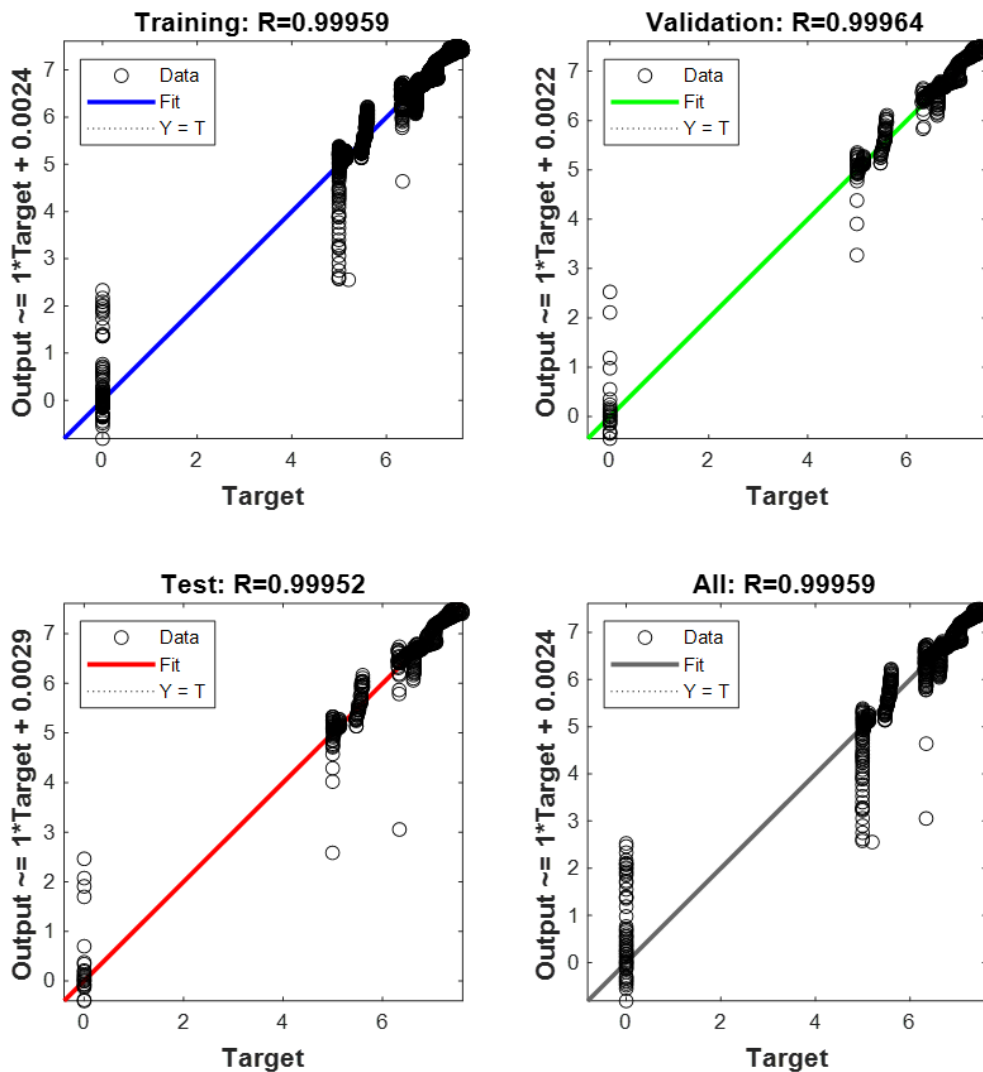
Διάγραμμα	Κρυφοί Κόμβοι	MSE			R		
		Training	Validation	Testing	Training	Validation	Testing
1	10	0.00305902	0.00578709	0.002869	0.999321	0.998715	0.999361
2	20	0.000772806	0.000657289	0.000561	0.999828	0.999854	0.999875
3	25	0.000084267	8.92984E-05	0.000289	0.999981	0.99998	0.999936
4	30	0.000357013	0.00031768	0.000338	0.99992	0.999929	0.999924
5	35	0.000195064	0.00015425	0.000151	0.999956	0.999965	0.999966
6	50	0.00324788	0.000571337	0.000396	0.999928	0.999872	0.999911

7	80	0.000298827	0.000271177	0.000409	0.999933	0.999939	0.999909
8	100	0.000724815	0.000771084	0.001493	0.999839	0.999828	0.999671

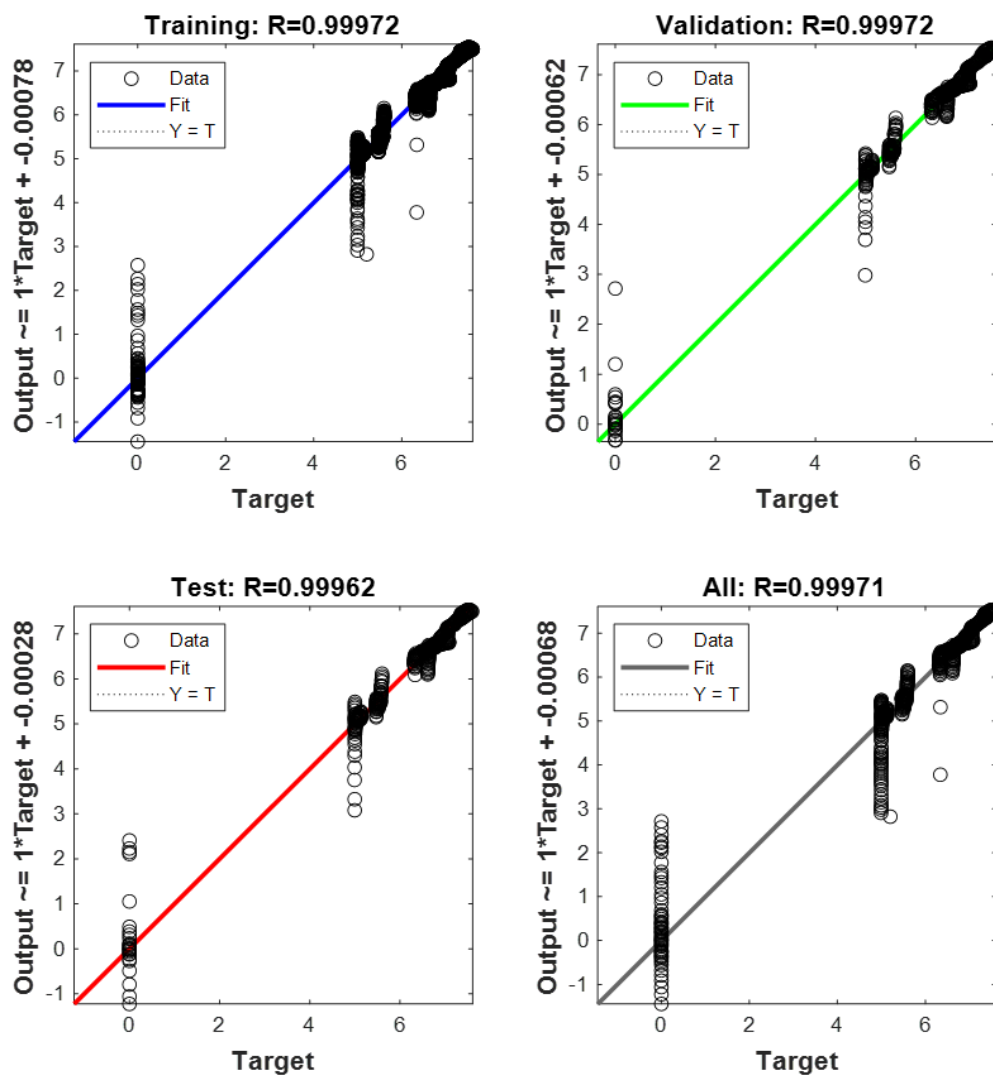
**Πίνακας 6: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE).**

Κρυφοί Κόμβοι	Reached Epochs (Iterations)	Running Time (hh:mm:ss)	Validation Checks (max=6)	RMSE		
				Training	Validation	Testing
10	108	00:00:06	6 6	0.055308	0.0760729	0.0535625
20	327	00:00:28	6 6	0.027799	0.0256376	0.0236926
25	1000	00:01:52	0 6	0.00918	0.0094498	0.0169963
30	443	00:01:07	6 6	0.018895	0.0178236	0.0183722
35	811	00:02:04	6 6	0.013967	0.0124197	0.0122788
50	350	00:01:24	6 6	0.05699	0.0239027	0.0198934
80	1000	00:08:06	0 6	0.017287	0.0164675	0.0202316
100	979	00:11:36	6 6	0.026922	0.0277684	0.038636

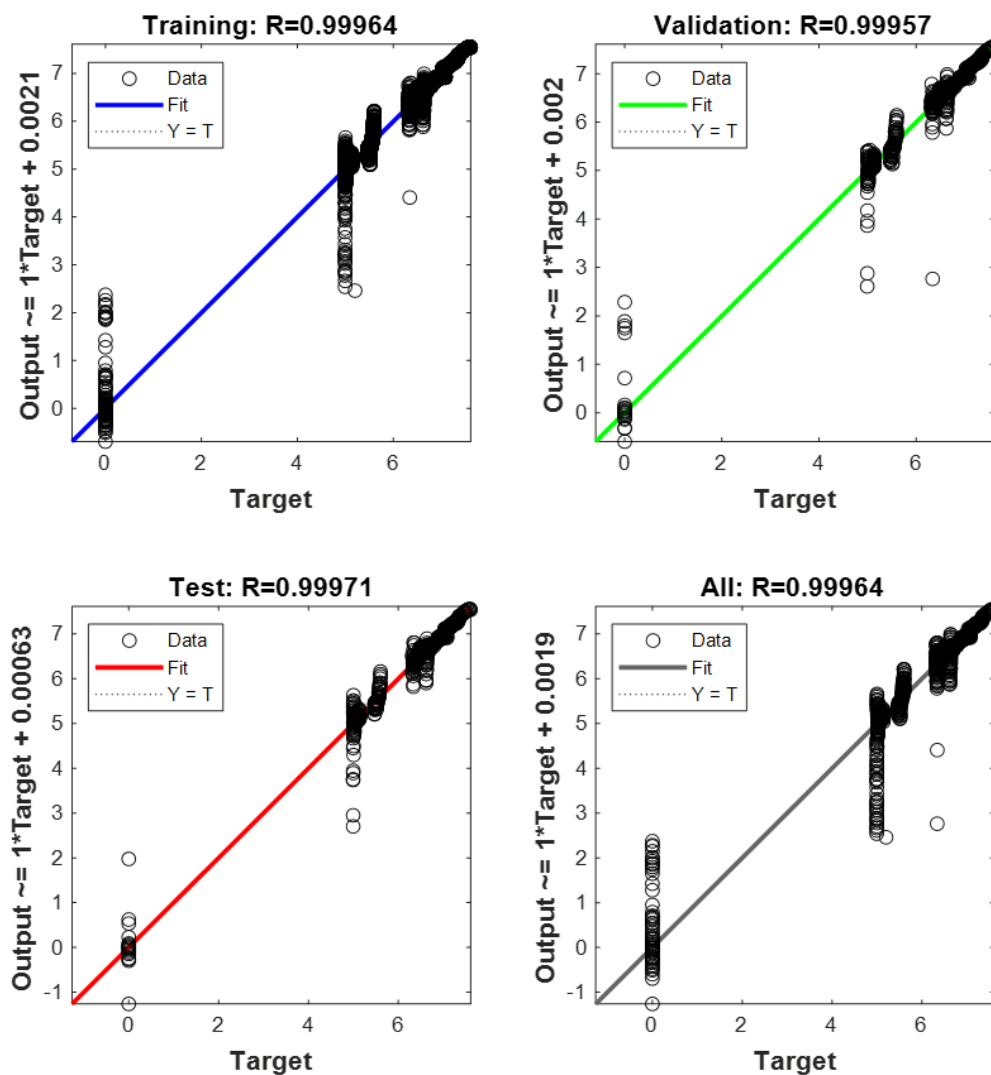
## Αφύγγρανση



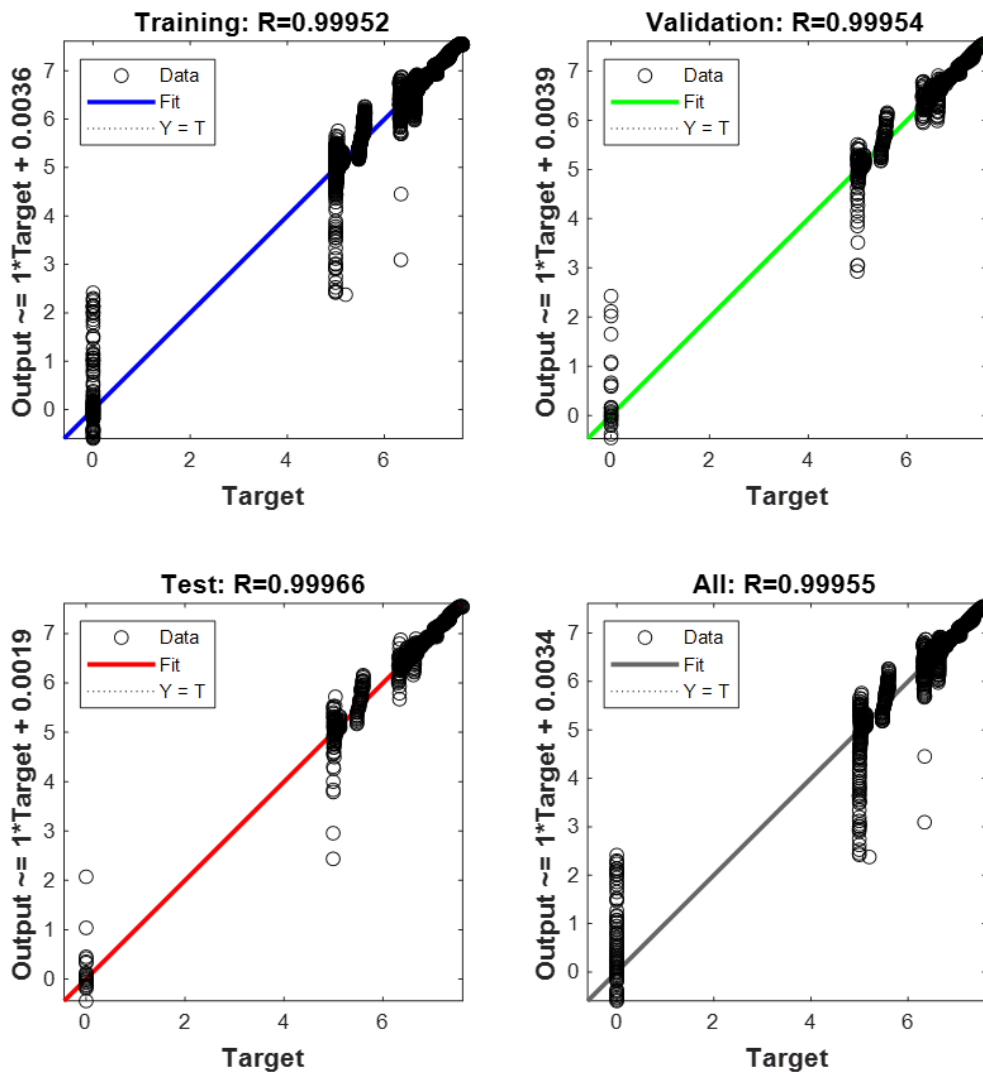
**Διάγραμμα 9: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγγρανσης με 10 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**



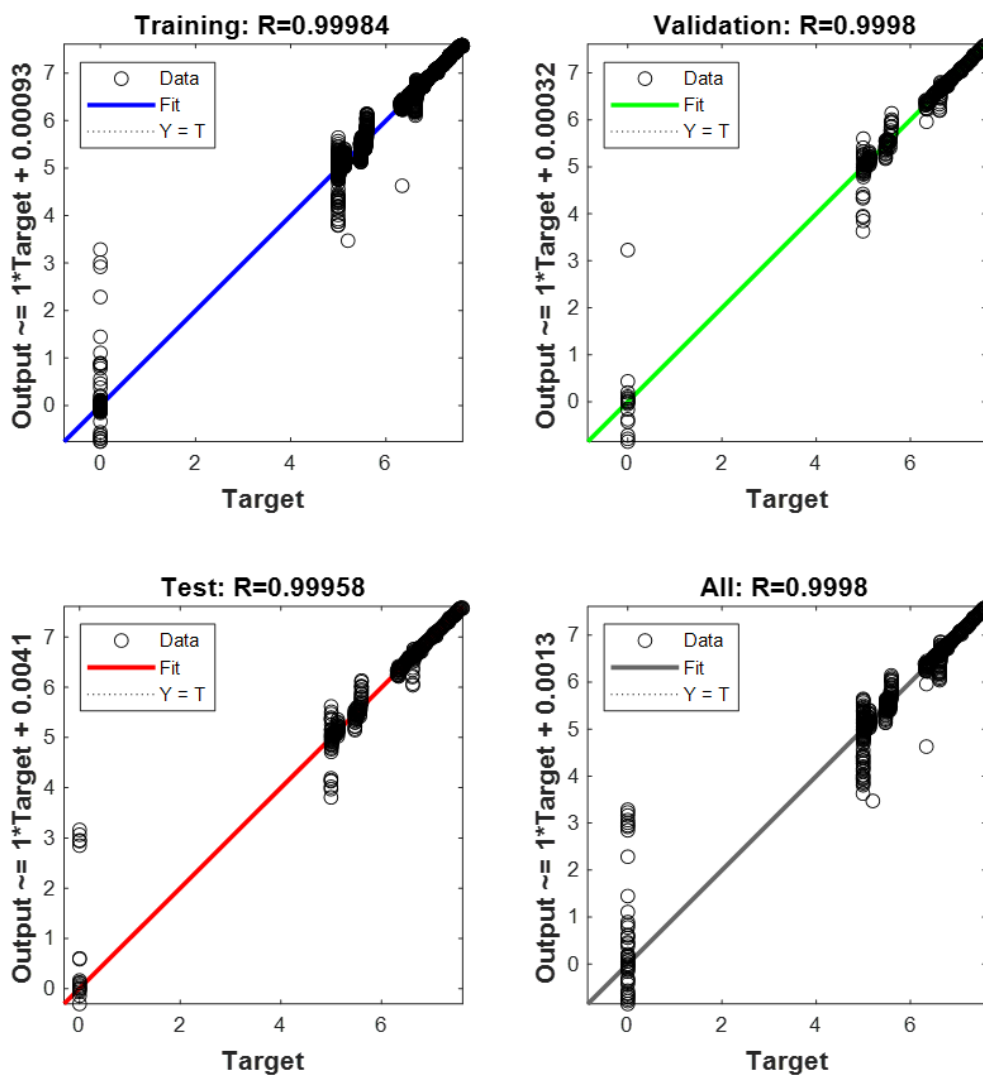
**Διάγραμμα 10: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγνωσης με 20 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**



**Διάγραμμα 11: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγνωσης με 25 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**

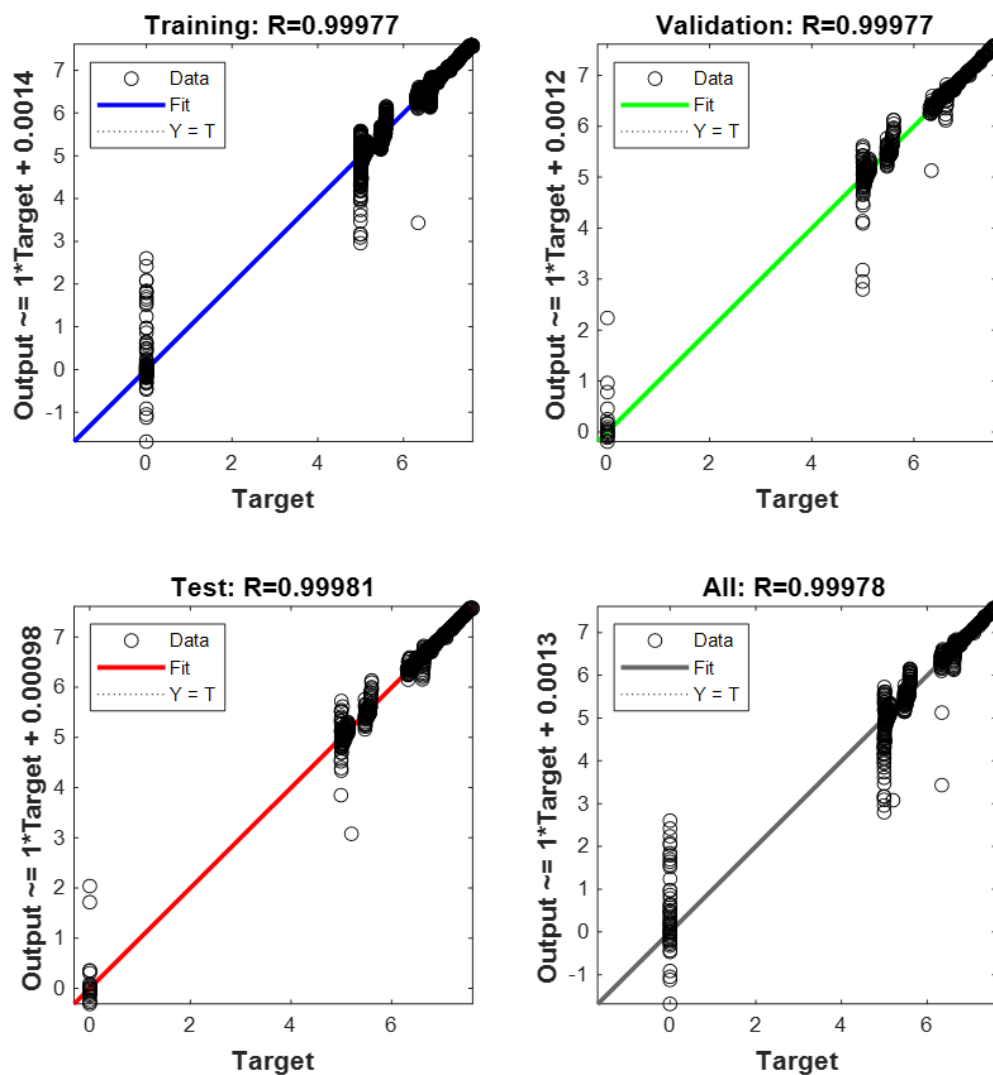


**Διάγραμμα 12: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 30 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**

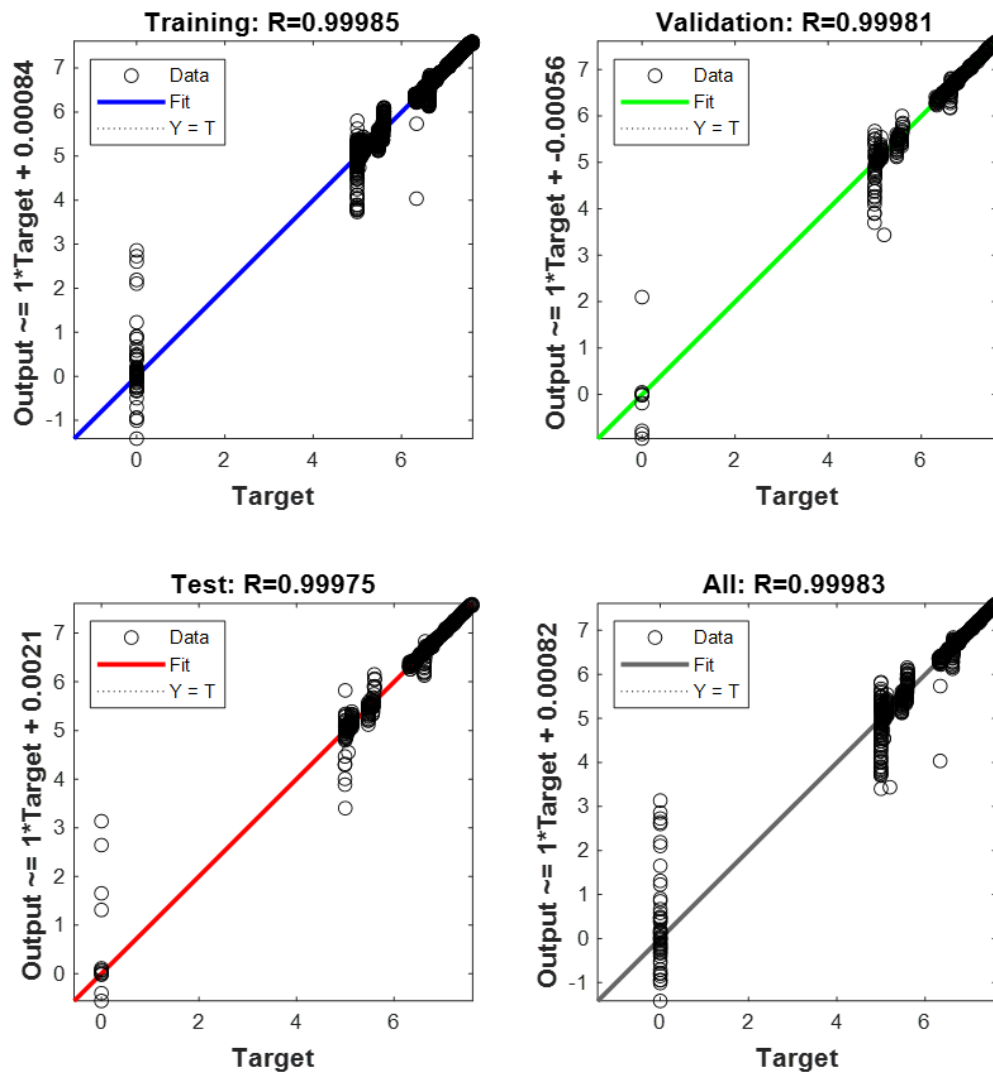


**Διάγραμμα 13: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 35 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**

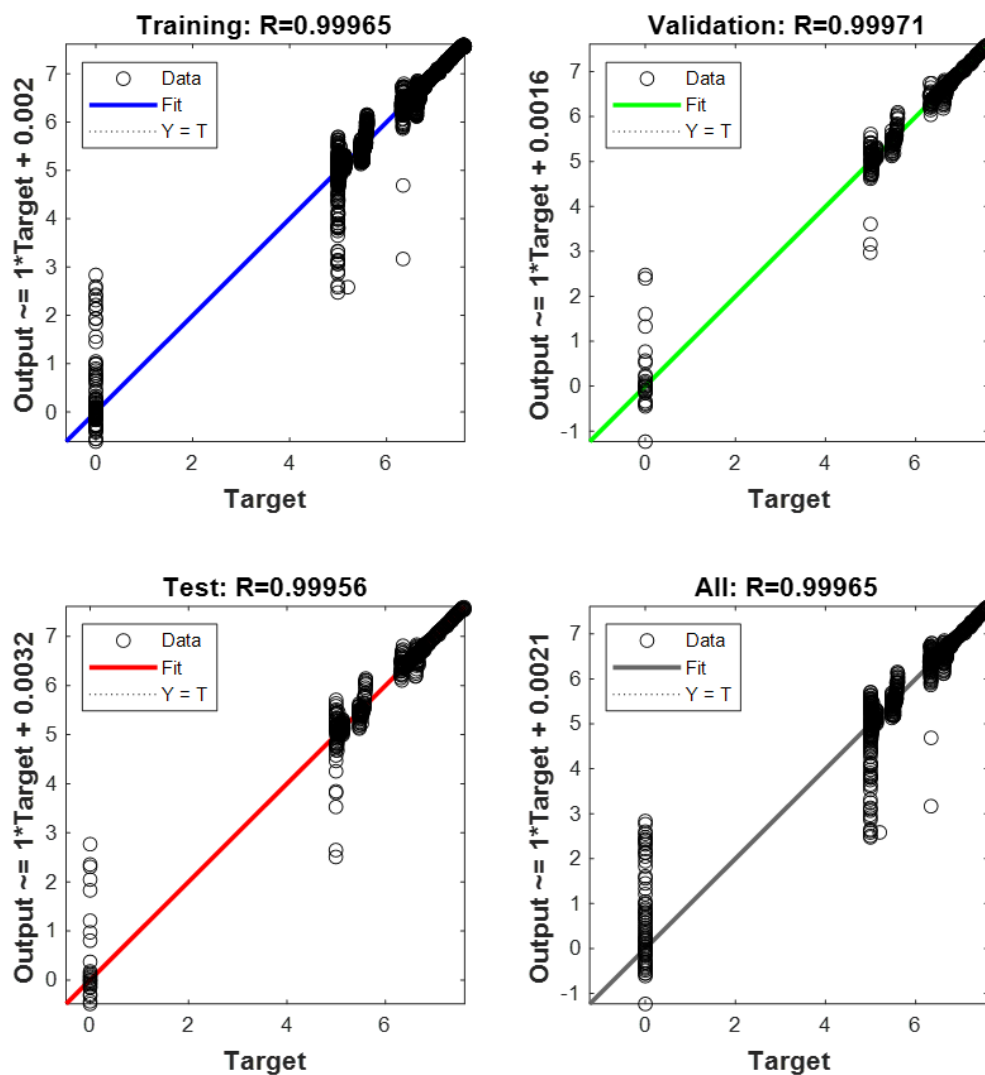




**Διάγραμμα 14: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγνωσης με 50 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**



**Διάγραμμα 15: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 80 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**



**Διάγραμμα 16: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 100 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**

**Πίνακες αποτελεσμάτων για αφύγρανση την χειμερινή περίοδο (PP1)**

**Πίνακας 7: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt**

<i>Διάγραμμα</i>	<i>Κρυφοί Κόμβοι</i>	<i>Percentages</i>			<i>Epochs</i>
		<i>Training</i>	<i>Validation</i>	<i>Testing</i>	
9	10	70 %	15%	15%	1000
10	20	70 %	15%	15%	1000
11	25	70 %	15%	15%	1000
12	30	70 %	15%	15%	1000
13	35	70 %	15%	15%	1000
14	50	70 %	15%	15%	1000
15	80	70 %	15%	15%	1000
16	100	70 %	15%	15%	1000

**Πίνακας 8: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R**

<b>Διάγραμμα</b>	<b>Κρυφοί Κόμβοι</b>	<b>MSE</b>			<b>R</b>		
		<b>Training</b>	<b>Validation</b>	<b>Testing</b>	<b>Training</b>	<b>Validatio n</b>	<b>Testing</b>
9	10	0.00829556	0.00738968	0.009793	0.999592	0.999638	0.999519
10	20	0.00570814	0.00575437	0.007603	0.999719	0.999719	0.999624
11	25	0.007258	0.00864923	0.005906	0.999643	0.999574	0.99971
12	30	0.00968669	0.00939332	0.006939	0.999524	0.999538	0.999659
13	35	0.0032016	0.0039939	0.008466	0.999842	0.999803	0.999583

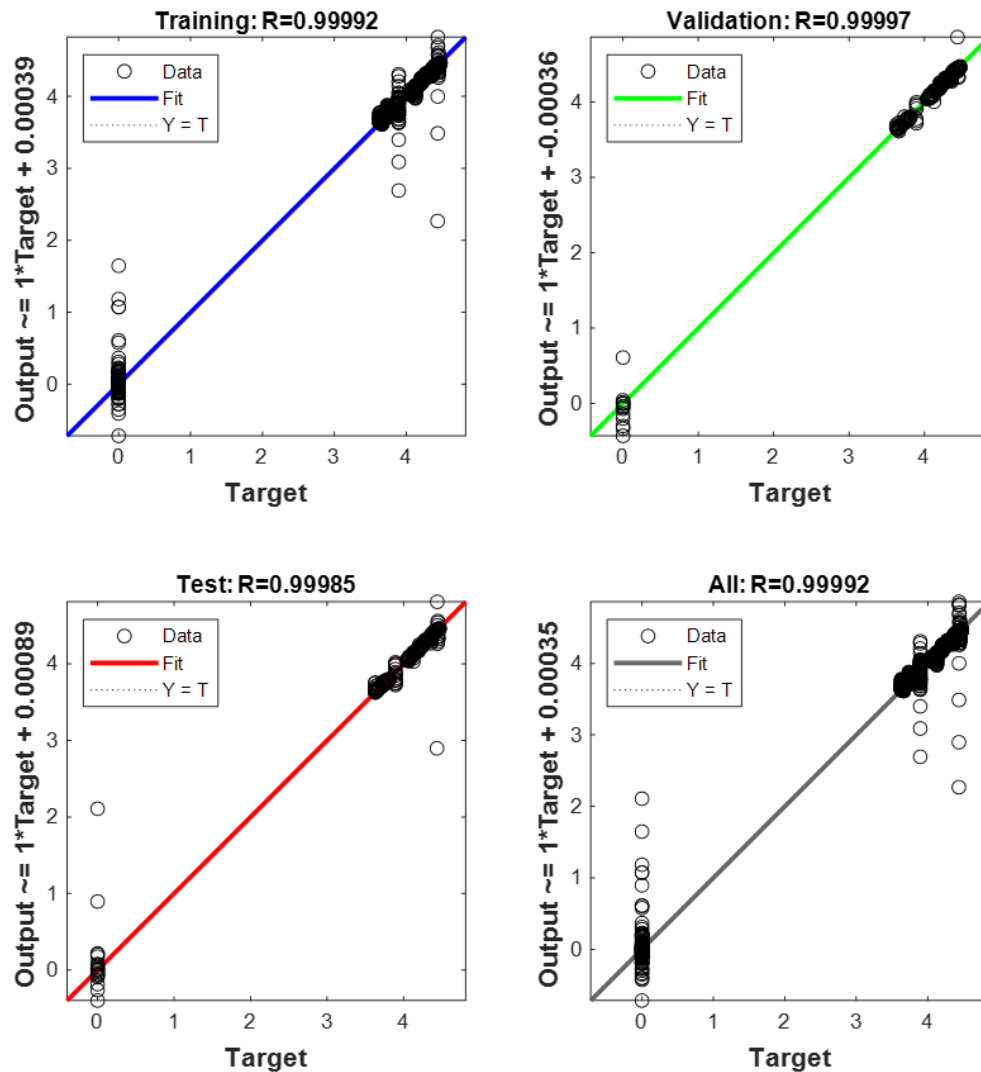
14	50	0.00461752	0.00471681	0.003947	0.999773	0.999766	0.999805
15	80	0.00303599	0.00383525	0.005101	0.99985	0.999812	0.999751
16	100	0.00704407	0.0058651	0.008834	0.999654	0.999712	0.999564

**Πίνακας 9: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE).**

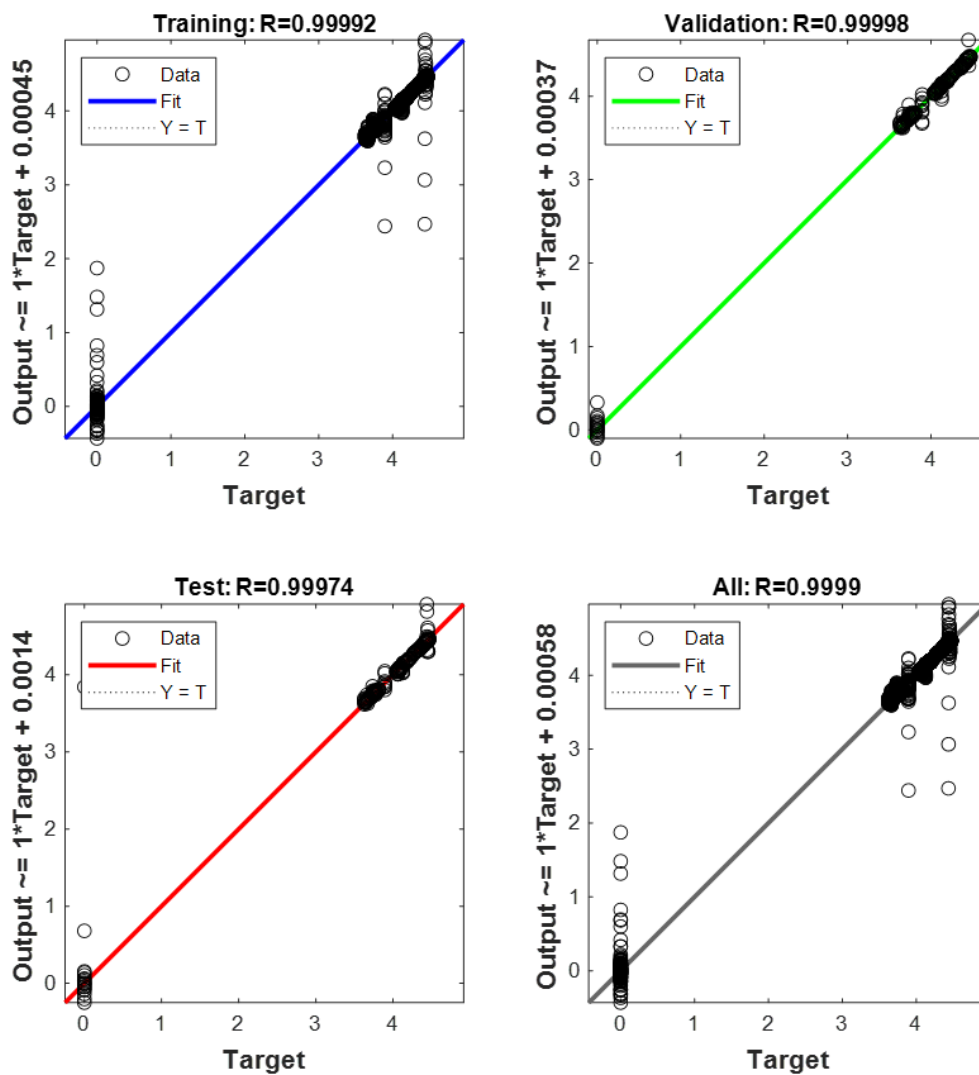
<i><b>Κρυφοί Κόμβοι</b></i>	<i><b>Reached Epochs (Iterations)</b></i>	<i><b>Running Time (hh:mm:ss)</b></i>	<i><b>Validation Checks (max=6)</b></i>	<i><b>RMSE</b></i>		
				<i><b>Training</b></i>	<i><b>Validation</b></i>	<i><b>Testing</b></i>
10	439	00:00:26	6 6	0.09108	0.0859632	0.0989614
20	744	00:01:15	6 6	0.075552	0.0758576	0.0871978
25	1000	00:02:11	0 6	0.085194	0.0930012	0.0768536
30	480	00:01:15	6 6	0.098421	0.0969191	0.0833018
35	809	00:02:22	6 6	0.056583	0.0631973	0.0920105
50	853	00:04:07	6 6	0.067952	0.068679	0.0628242
80	1000	00:09:52	0 6	0.0551	0.0619294	0.0714238
100	526	00:07:55	6 6	0.083929	0.0765839	0.0939868

### 5.1.2 Καλοκαιρινή Περίοδος (PP4)

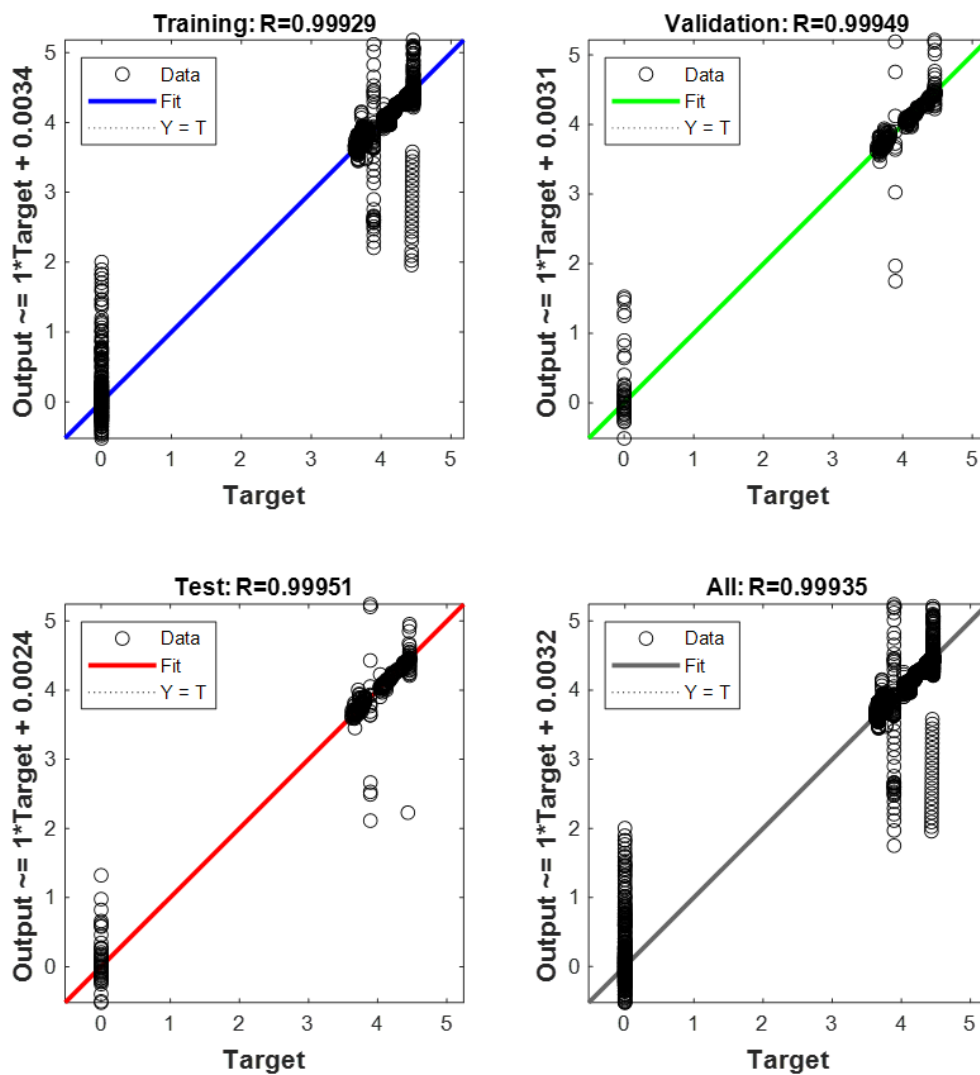
#### Ψύξη



**Διάγραμμα 17: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα ψύξης με 20 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**

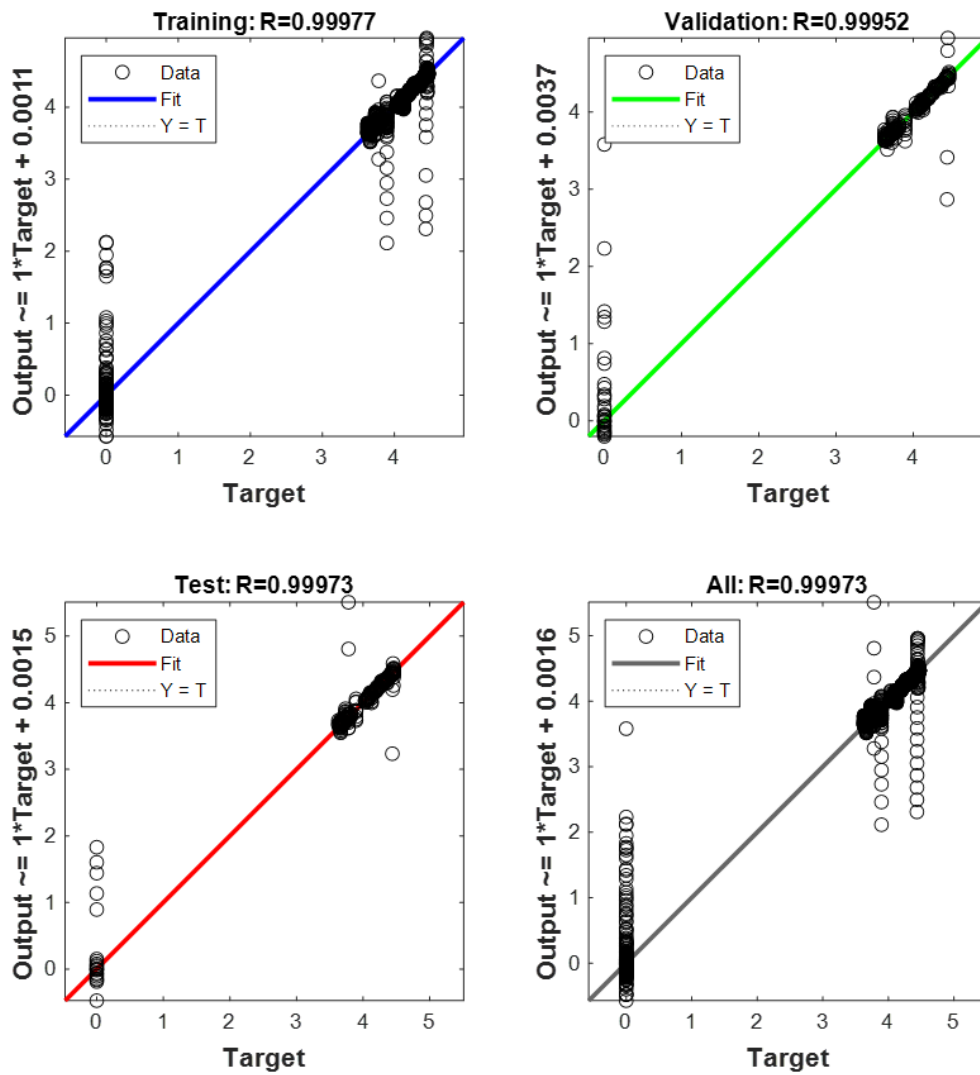


**Διάγραμμα 18: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα ψύξης με 25 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**

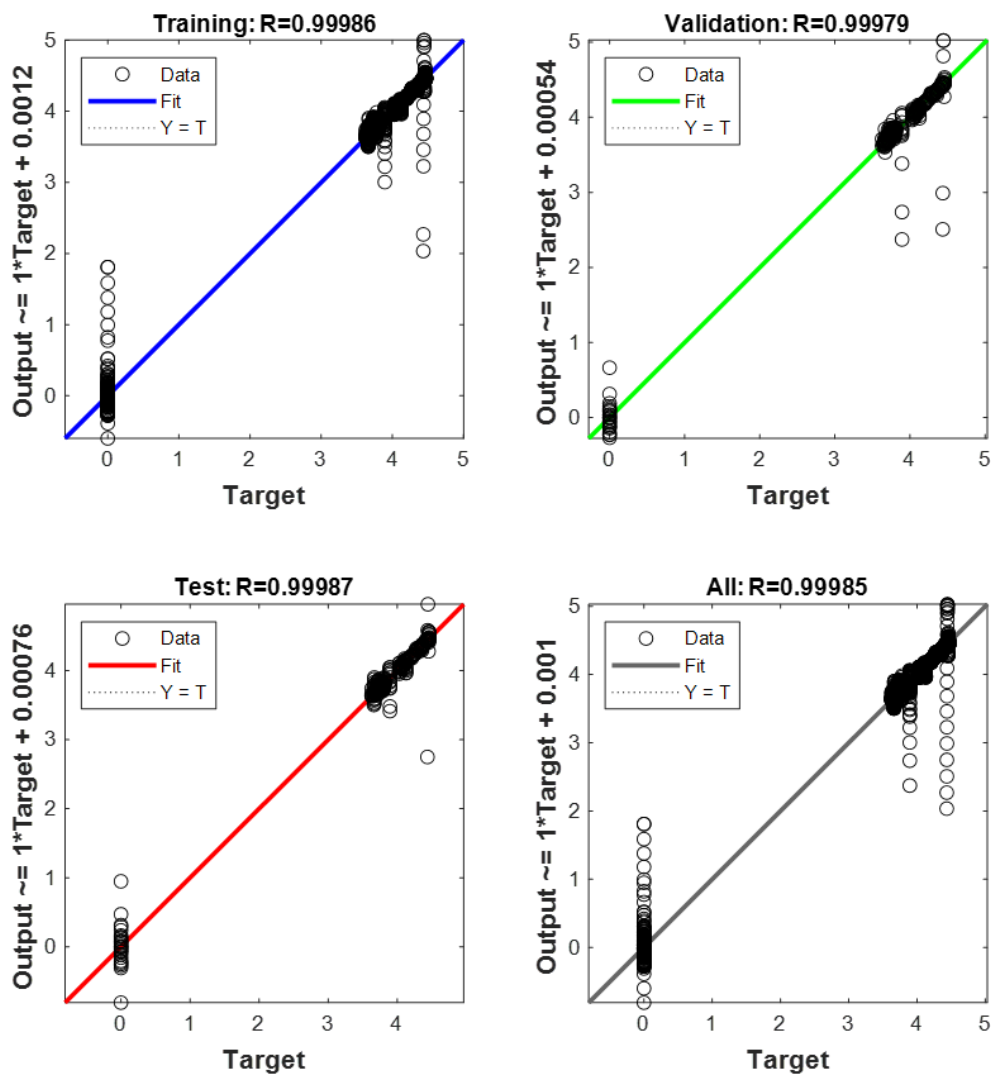


**Διάγραμμα 19: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα ψύξης με 30 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**

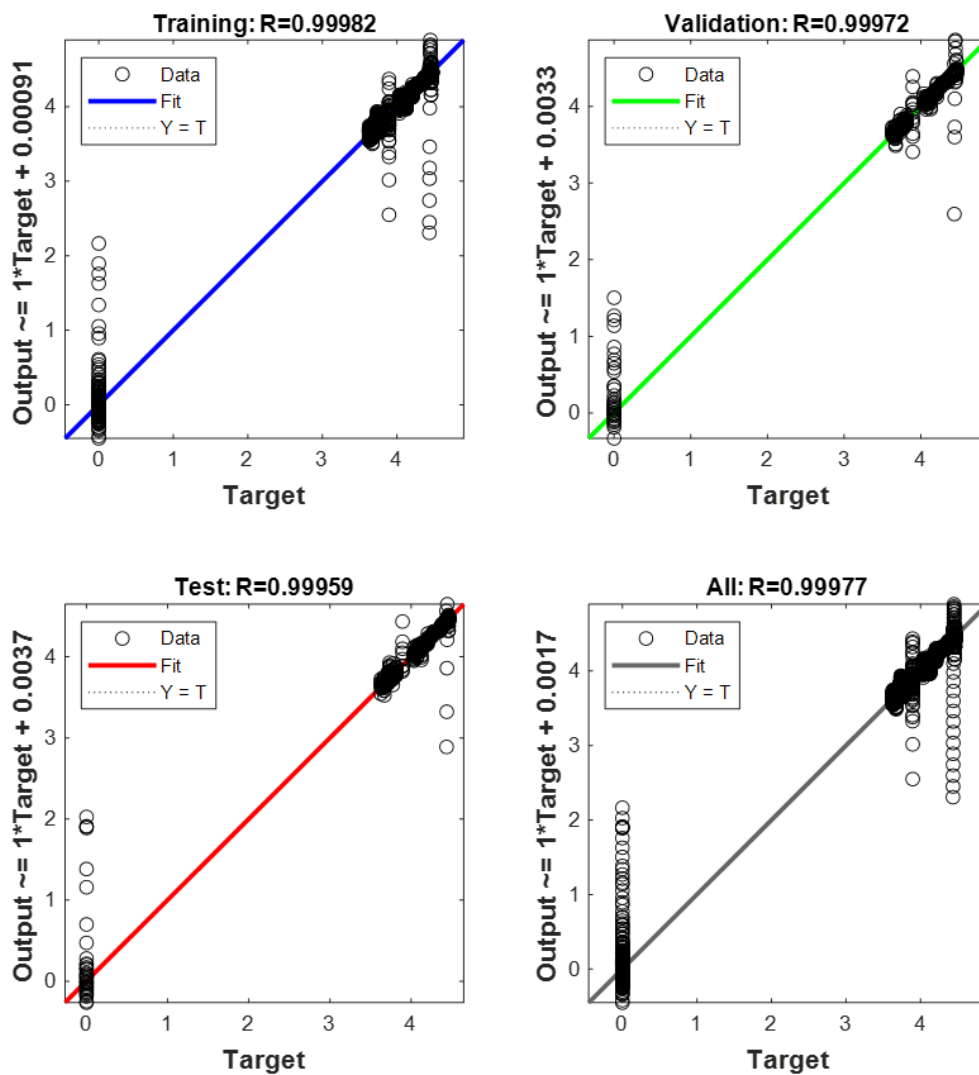




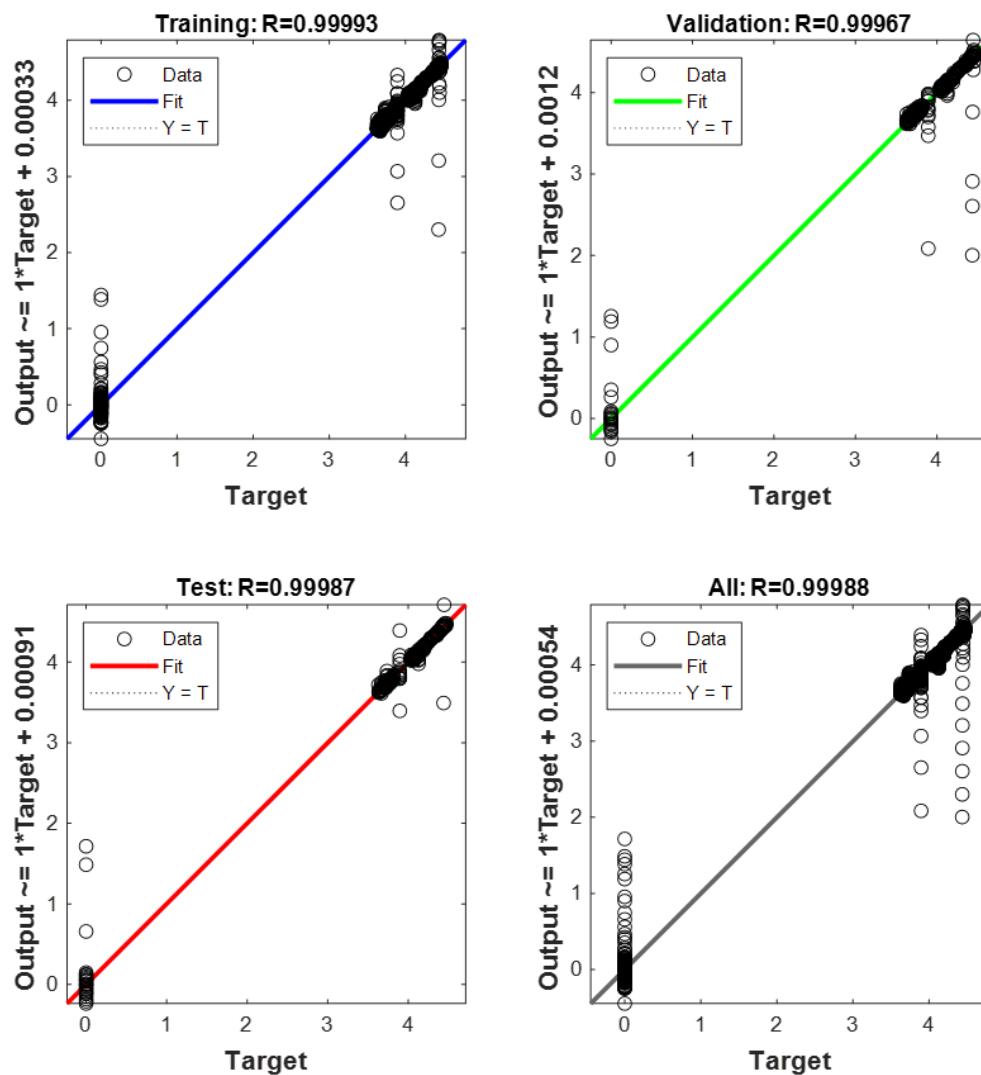
**Διάγραμμα 20: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα ψύξης με 35 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**



**Διάγραμμα 21: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα ψύξης με 50 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**



**Διάγραμμα 22: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα ψύξης με 80 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**



**Διάγραμμα 23 : Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα ψύξης με 100 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**

**Πίνακες αποτελεσμάτων για ψύξη την καλοκαιρινή περίοδο (PP4)**

**Πίνακας 10: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt**

<b>Διάγραμμα</b>	<b>Κρυφοί Κόμβοι</b>	<b>Percentages</b>			<b>Epochs</b>
		<b>Training</b>	<b>Validation</b>	<b>Testing</b>	
17	20	70 %	15%	15%	1000
18	25	70 %	15%	15%	1000
19	30	70 %	15%	15%	1000
20	35	70 %	15%	15%	1000
21	50	70 %	15%	15%	1000
22	80	70 %	15%	15%	1000
23	100	70 %	15%	15%	1000

**Πίνακας 11: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R**

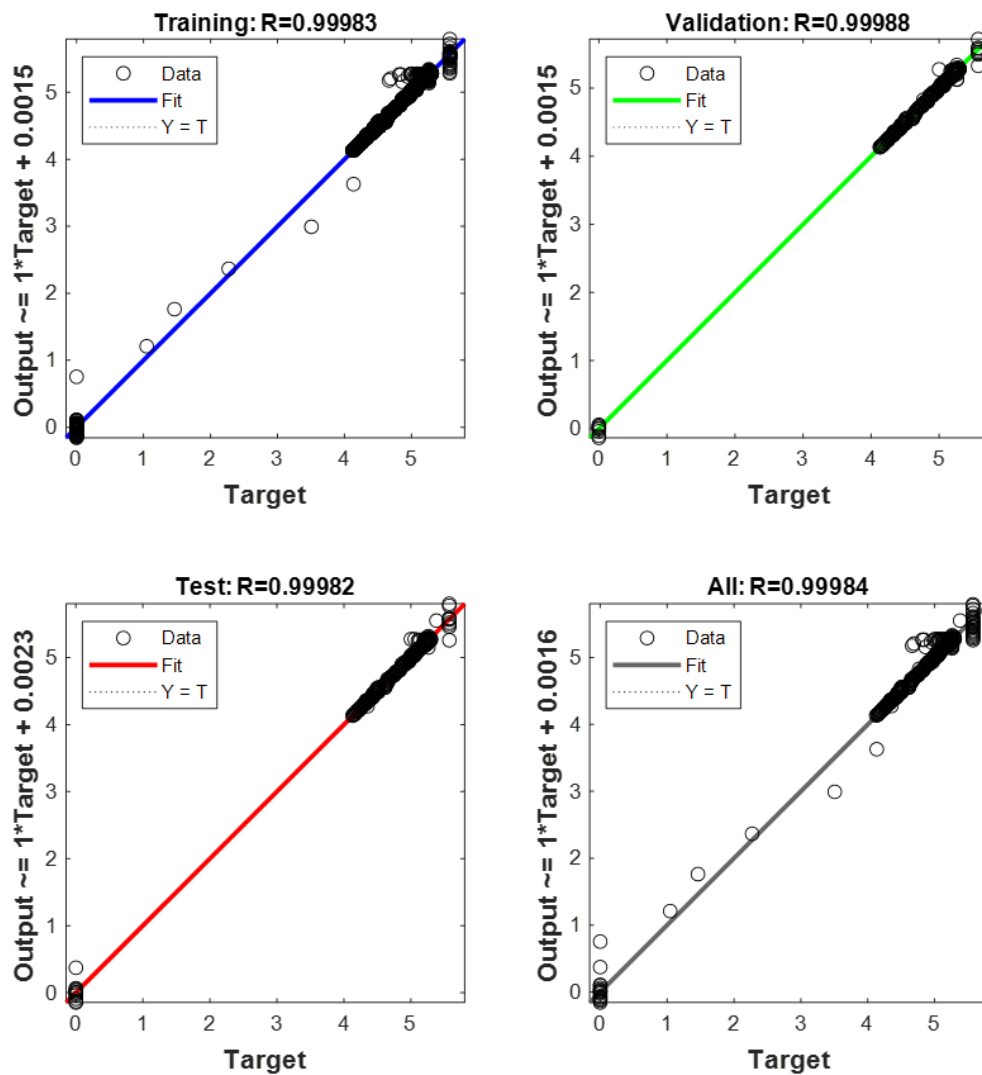
<b>Διάγραμμα</b>	<b>Κρυφοί Κόμβοι</b>	<b>MSE</b>			<b>R</b>		
		<b>Training</b>	<b>Validation</b>	<b>Testing</b>	<b>Training</b>	<b>Validatio n</b>	<b>Testing</b>
17	20	0.000639	0.000245	0.000123	0.999923	0.99997	0.999853
18	25	0.000666	0.000128	0.00218	0.99992	0.999984	0.99974
19	30	0.005985	0.00431	0.004167	0.999286	0.999488	0.999505
20	35	0.001908	0.004059	0.002306	0.999772	0.999515	0.999726
21	50	0.001201	0.001769	0.001056	0.999857	0.999788	0.999874

22	80	0.001513	0.002392	0.003422	0.999819	0.999716	0.999594
23	100	0.000577	0.002733	0.001081	0.999931	0.999673	0.99987

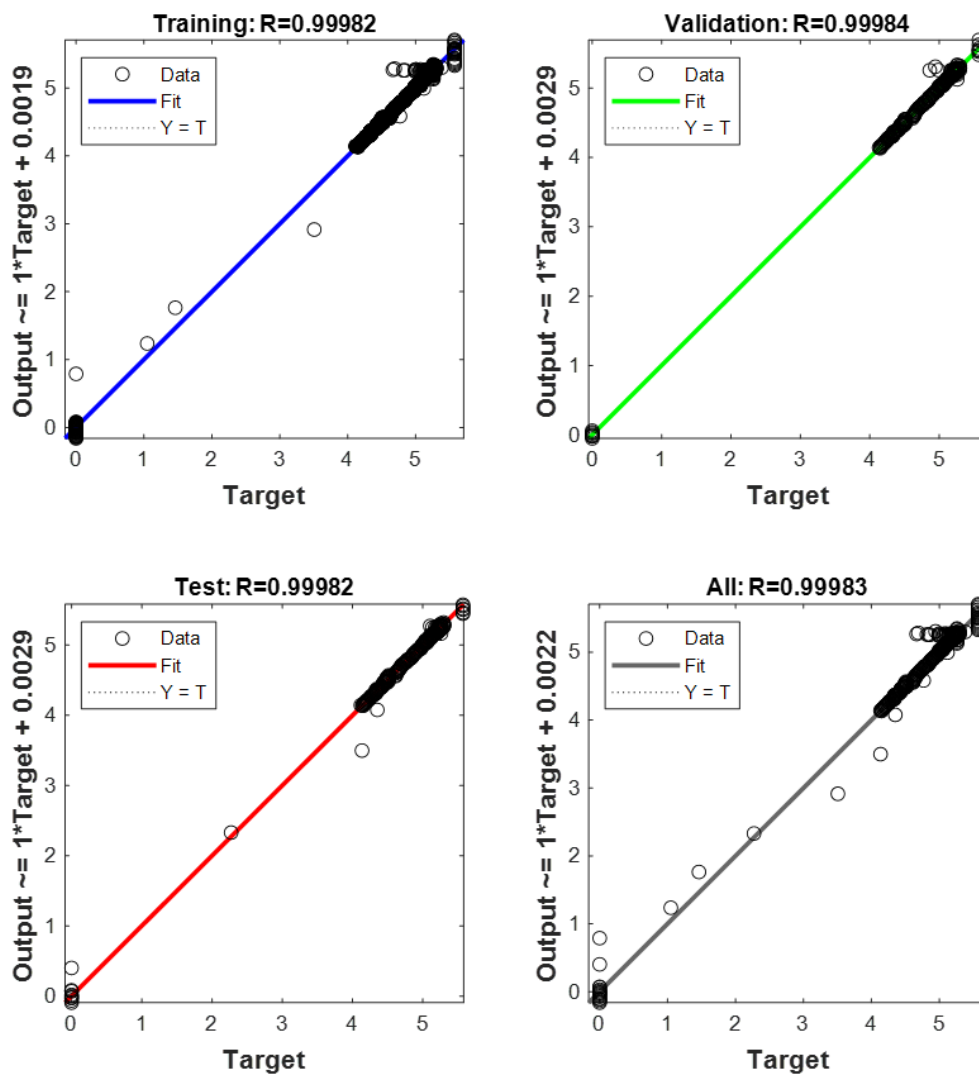
**Πίνακας 12: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE).**

<i><b>Κρυφοί Κόμβοι</b></i>	<i><b>Reached Epochs (Iterations)</b></i>	<i><b>Running Time (hh:mm:ss)</b></i>	<i><b>Validation Checks (max=6)</b></i>	<i><b>RMSE</b></i>		
				<i><b>Training</b></i>	<i><b>Validation</b></i>	<i><b>Testing</b></i>
20	267	00:00:22	6 6	0.025278	0.015642	0.011109
25	401	00:00:42	6 6	0.025814	0.0113	0.04669
30	128	00:00:16	6 6	0.077366	0.065654	0.064552
35	355	00:01:07	6 6	0.04368	0.063708	0.048021
50	530	00:02:37	6 6	0.03466	0.042063	0.03249
80	728	00:07:01	6 6	0.038904	0.048912	0.058497
100	889	00:10:26	6 6	0.024023	0.052279	0.032883

## Αφύγρανση

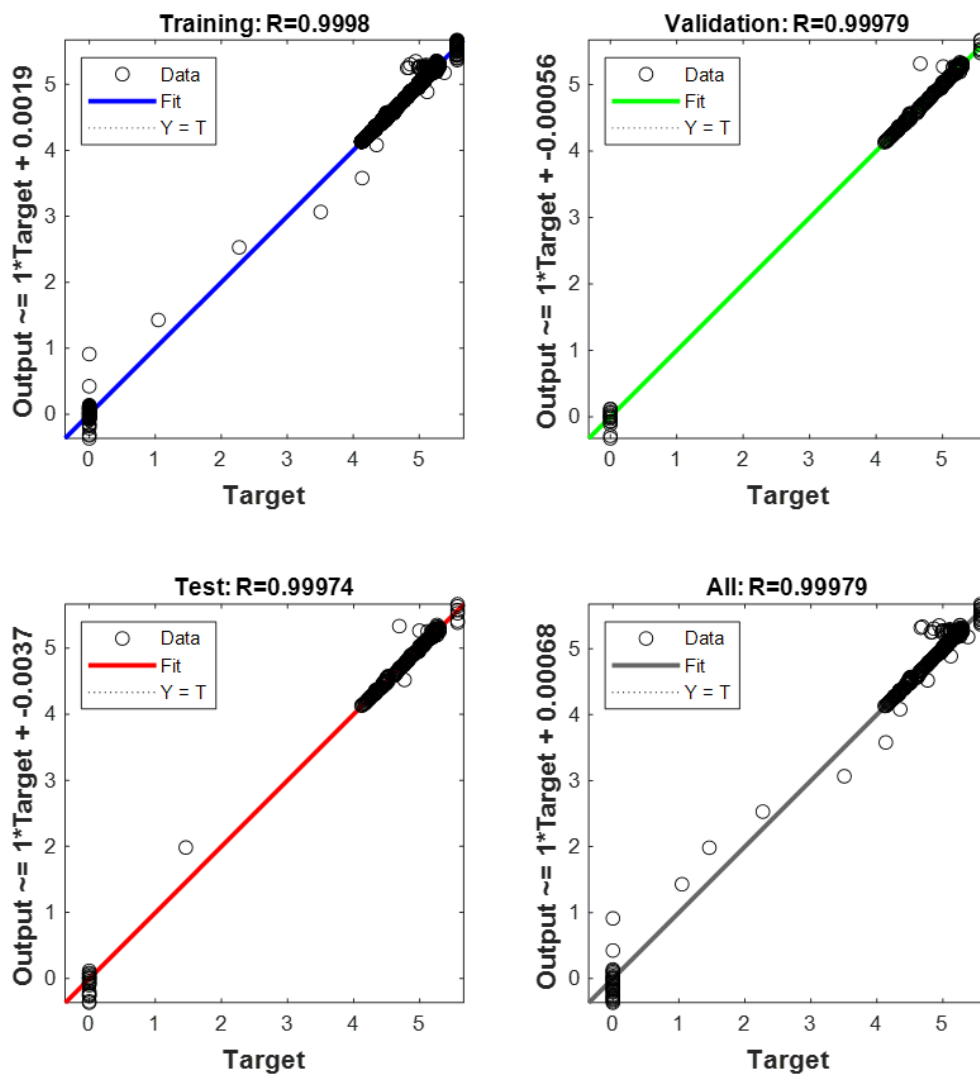


**Διάγραμμα 24: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 20 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**

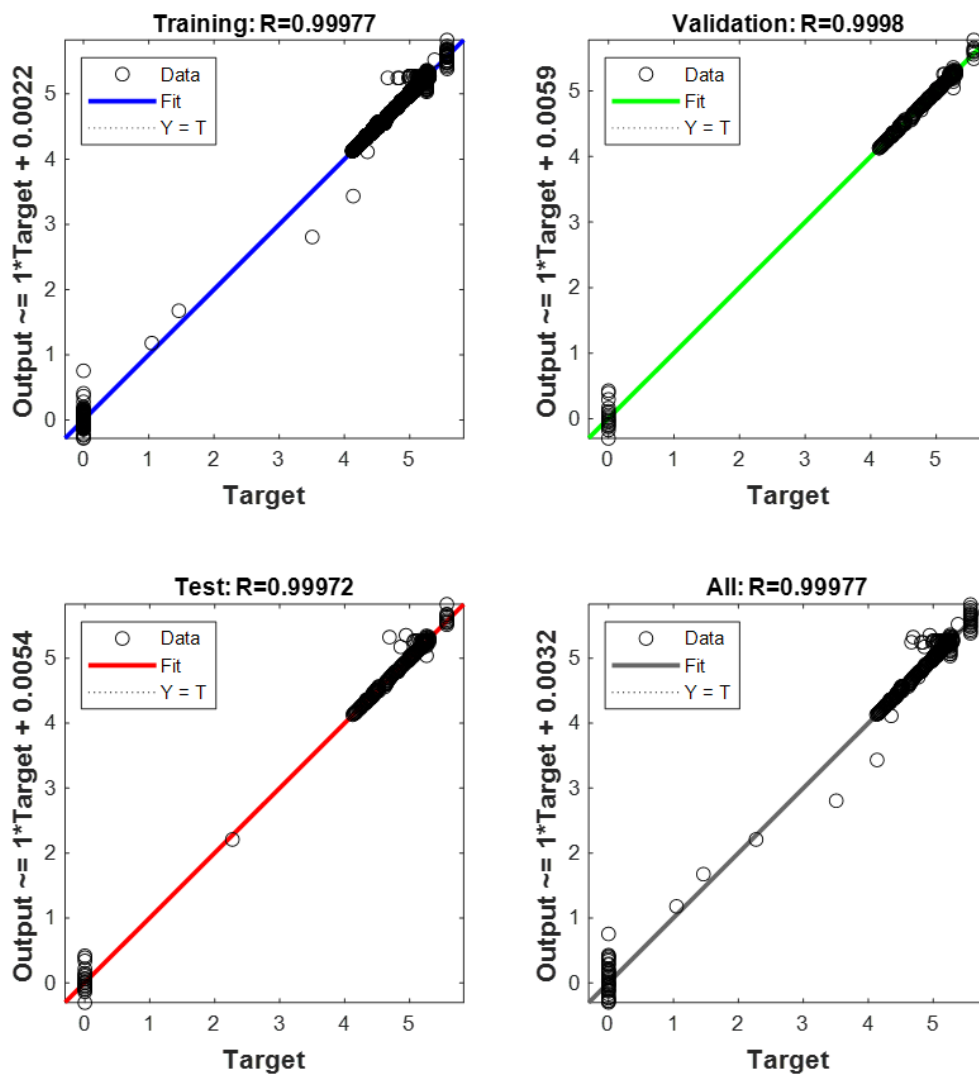


**Διάγραμμα 25: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 25 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**

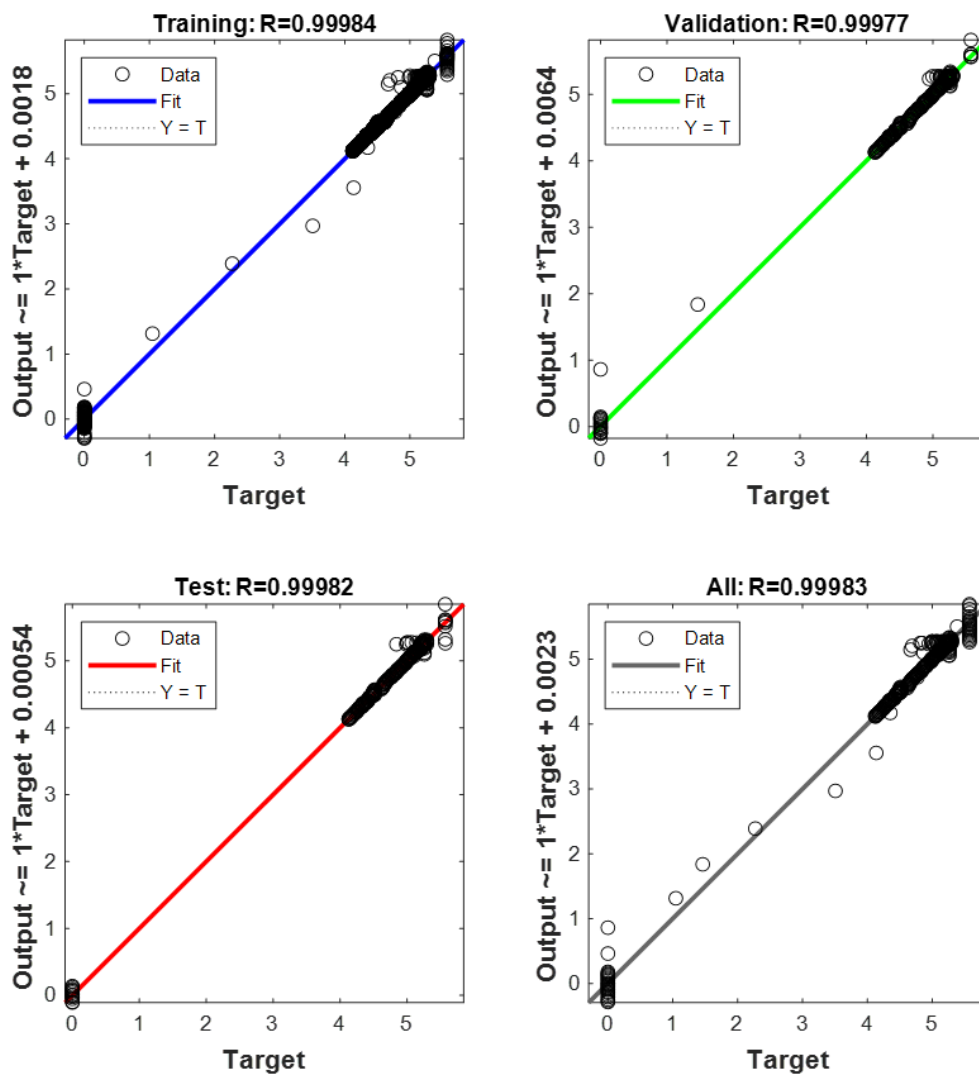




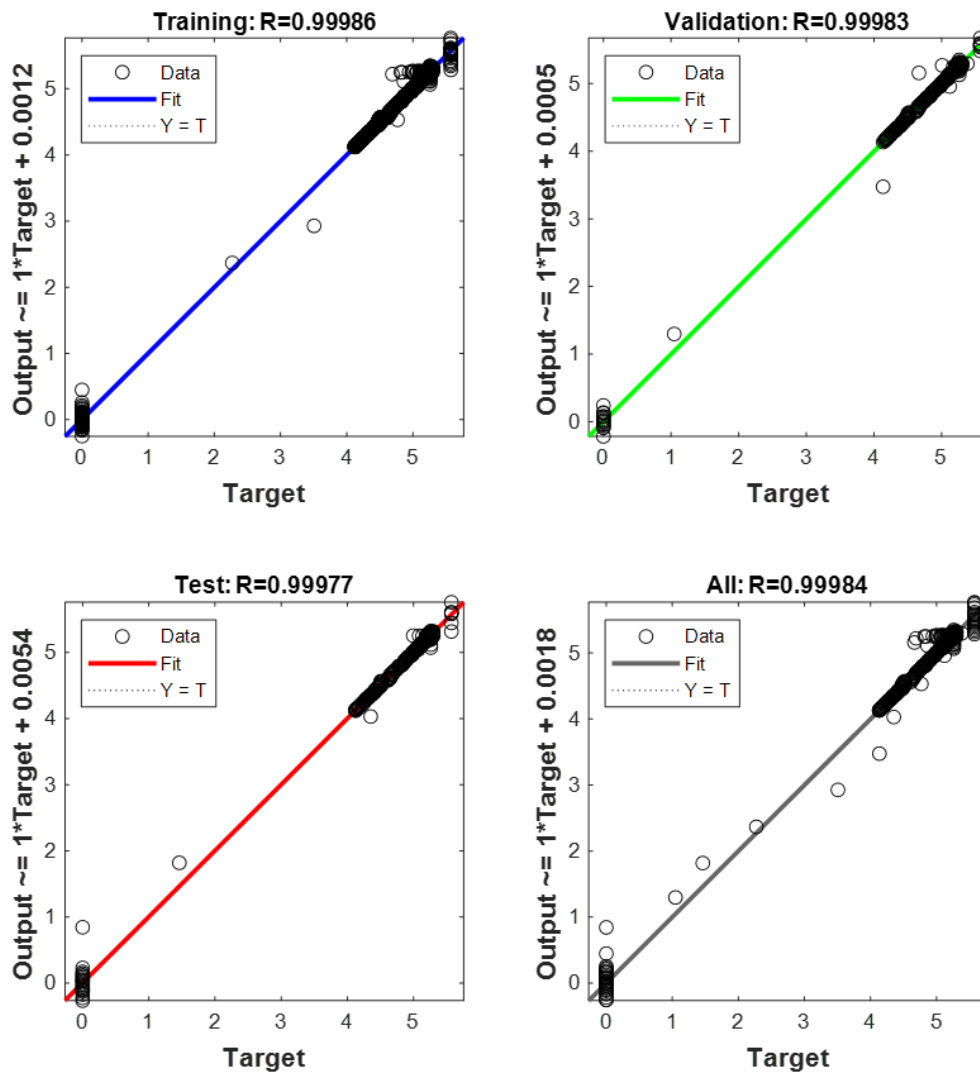
**Διάγραμμα 26 : Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 30 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**



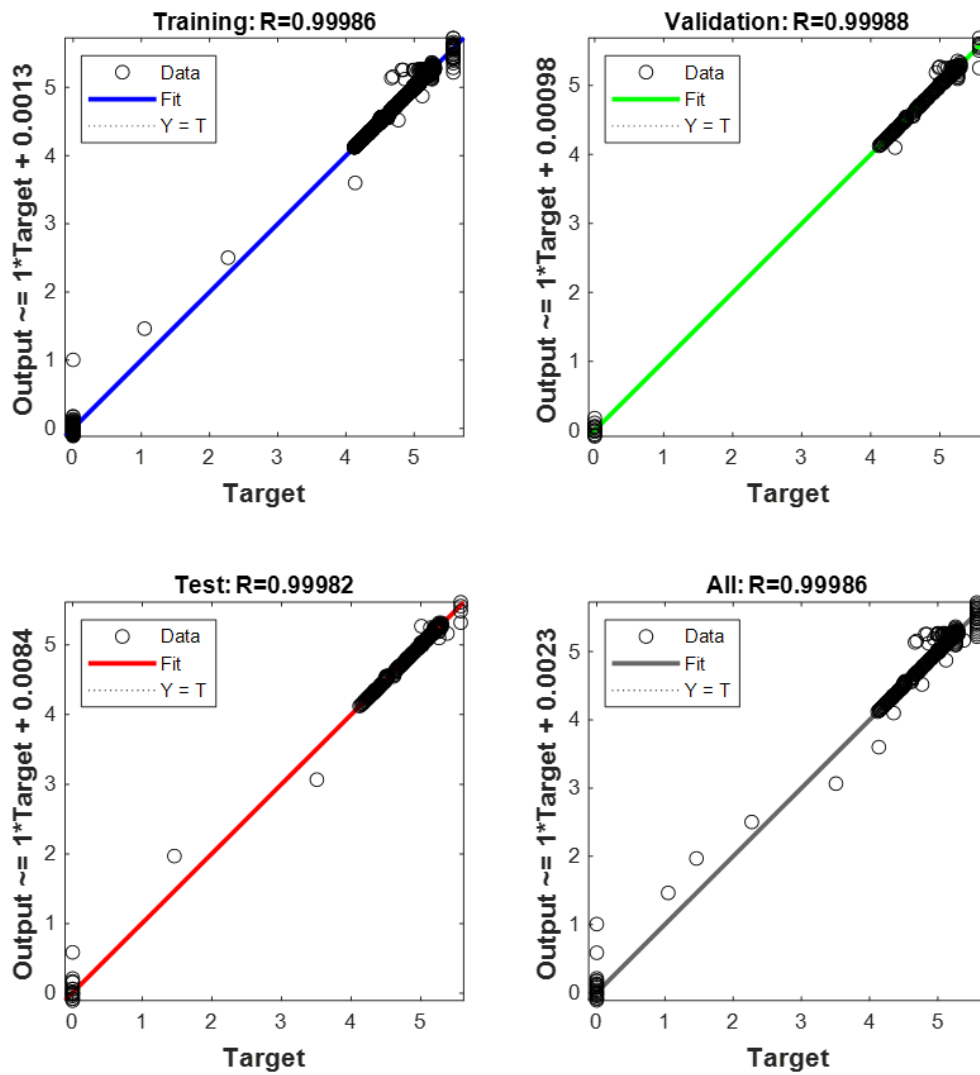
**Διάγραμμα 27: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγνωσης με 35 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**



**Διάγραμμα 28: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 50 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**



**Διάγραμμα 29: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 80 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**



**Διάγραμμα 30: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 100 κρυφούς κόμβους (hidden nodes) , με ποσοστά 70% Training , 15% Validation και 15% Testing.**

**Πίνακες αποτελεσμάτων για αφύγρανση την καλοκαιρινή περίοδο (PP4)**

**Πίνακας 13: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt**

<i>Διάγραμμα</i>	<i>Κρυφοί Κόμβοι</i>	<i>Percentages</i>			<i>Epochs</i>
		<i>Training</i>	<i>Validation</i>	<i>Testing</i>	
24	20	70 %	15%	15%	1000
25	25	70 %	15%	15%	1000
26	30	70 %	15%	15%	1000
27	35	70 %	15%	15%	1000
28	50	70 %	15%	15%	1000
29	80	70 %	15%	15%	1000
30	100	70 %	15%	15%	1000

**Πίνακας 14: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R**

<b>Διάγραμμα</b>	<b>Κρυφοί Κόμβοι</b>	<b>MSE</b>			<b>R</b>		
		<b>Training</b>	<b>Validation</b>	<b>Testing</b>	<b>Training</b>	<b>Validatio n</b>	<b>Testing</b>
24	20	0.000221	0.000152	0.000205	0.999834	0.999883	0.999823
25	25	0.000234	0.000196	0.00023	0.999823	0.999838	0.999824
26	30	0.000268	0.000257	0.000338	0.999796	0.99979	0.999744
27	35	0.000296	0.00026	0.00038	0.99977	0.999801	0.999723
28	50	0.000216	0.0003	0.000214	0.999837	0.999773	0.999818
29	80	0.000175	0.000231	0.000317	0.999862	0.999827	0.999774
30	100	0.000184	0.000152	0.000228	0.999861	0.999875	0.99982

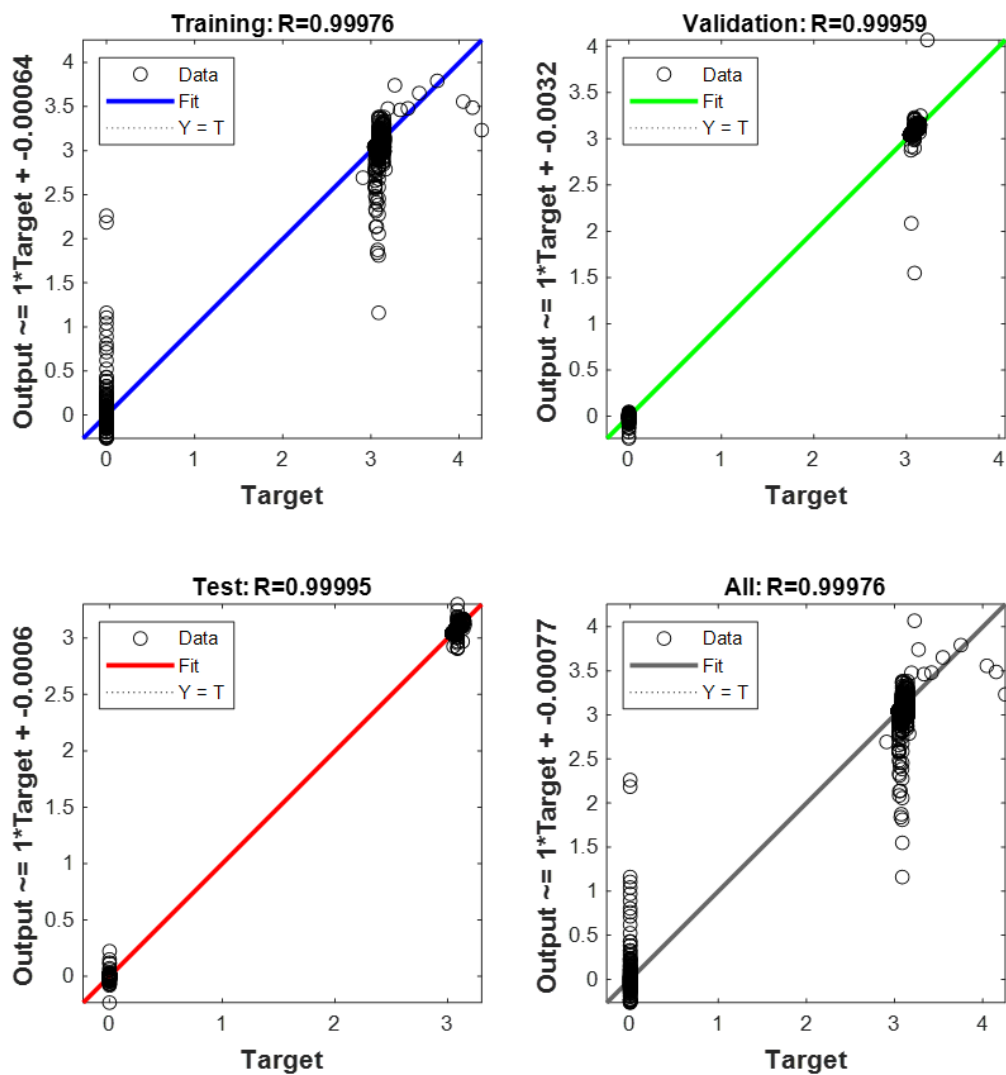
**Πίνακας 15: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE).**

<i><b>Κρυφοί Κόμβοι</b></i>	<i><b>Reached Epochs (Iterations)</b></i>	<i><b>Running Time (hh:mm:ss)</b></i>	<i><b>Validation Checks (max=6)</b></i>	<i><b>RMSE</b></i>		
				<i><b>Training</b></i>	<i><b>Validation</b></i>	<i><b>Testing</b></i>
20	724	00:01:10	6 6	0.014852	0.01231	0.014323
25	789	00:02:16	6 6	0.015298	0.013994	0.015168
30	1000	00:03:04	0 6	0.016369	0.016027	0.018377
35	1000	00:03:27	0 6	0.017192	0.016113	0.019503
50	1000	00:05:54	0 6	0.014691	0.017322	0.014629
80	1000	00:11:31	0 6	0.013228	0.0152	0.017797
100	1000	00:17:47	0 6	0.013567	0.01232	0.015113

## 5.2 Μεταβλητά Ποσοστά εκπαίδευσης, ελέγχου και επικύρωσης

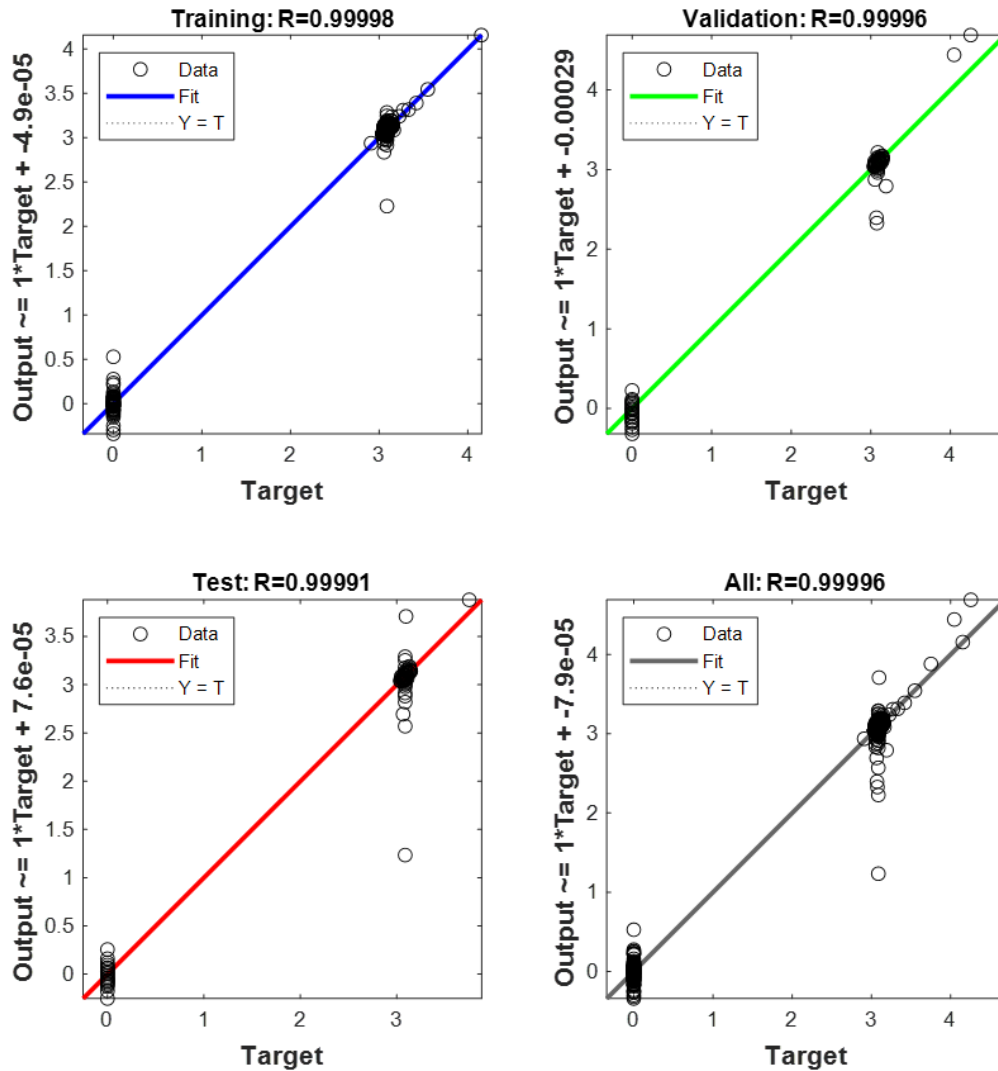
### 5.2.1 Χειμερινή Περίοδος

#### ΘΕΡΜΑΝΣΗ







**Διάγραμμα 31: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα θέρμανσης με 35 κρυφούς κόμβους (hidden nodes) , με ποσοστά 90% Training , 5% Validation και 5% Testing.**





**Διάγραμμα 32: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα θέρμανσης με 35 κρυφούς κόμβους (hidden nodes) , με ποσοστά 50% Training , 25% Validation και 25% Testing.**



**Διάγραμμα 33: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα θέρμανσης με 35 κρυφούς κόμβους (hidden nodes) , με ποσοστά 30% Training , 35% Validation και 35% Testing.**

**Πίνακες αποτελεσμάτων για θέρμανση την χειμερινή περίοδο (PP1)**

**Πίνακας 16: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt με διαφορετικά ποσοστά (percentages)**

Διάγραμμα	Κρυφοί Κόμβοι	Percentages			Epochs
		Training	Validation	Testing	
31	35	90 %	5%	5%	1000
32	35	50 %	25%	25%	1000
33	35	30 %	35%	35%	1000

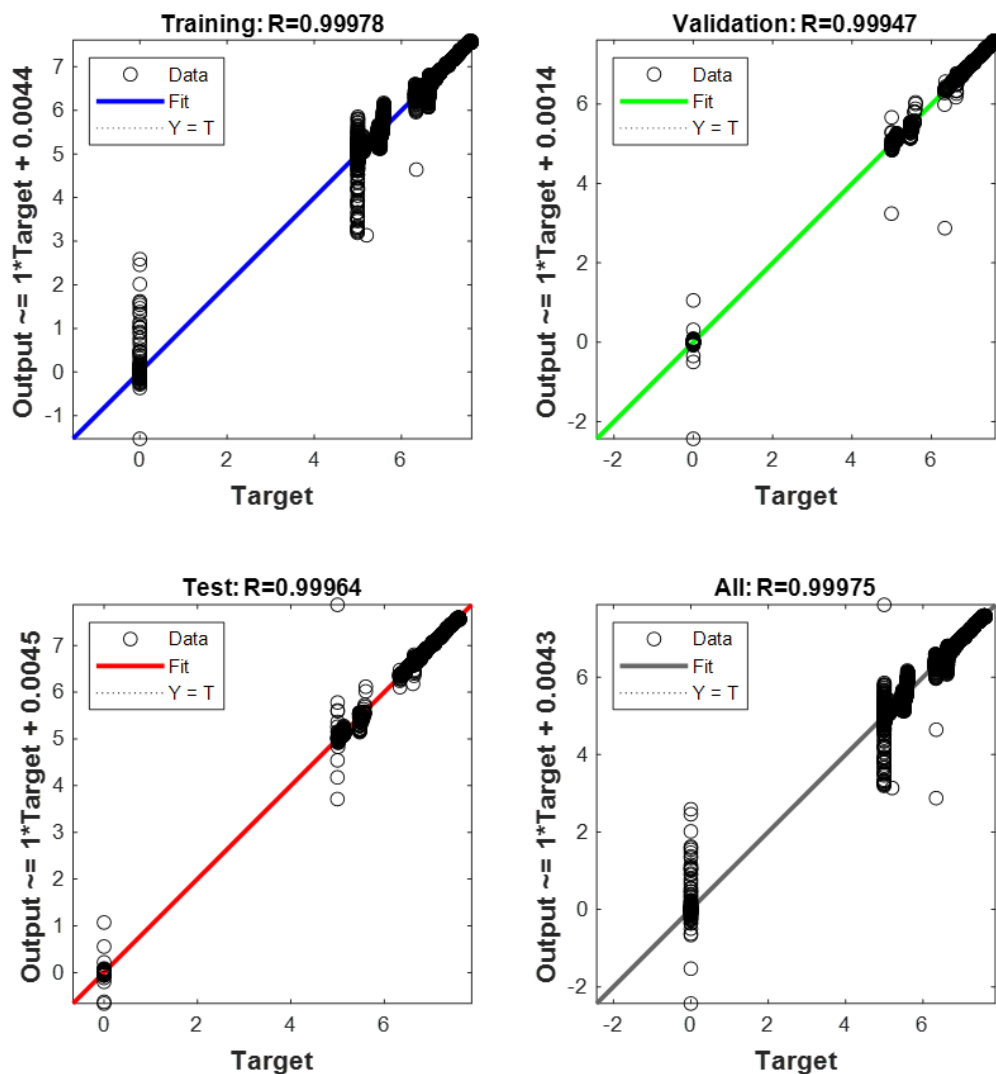
**Πίνακας 17: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R**

Διάγραμμα	Κρυφοί Κόμβοι	MSE			R		
		Training	Validation	Testing	Training	Validation n	Testing
31	35	0.00107604	0.001831	0.000242	0.999761	0.999592	0.999946
32	35	9.41779E-05	0.00019	0.000402	0.999979	0.999957	0.999911
33	35	0.000773235	0.003251	0.002633	0.999829	0.999281	0.999413

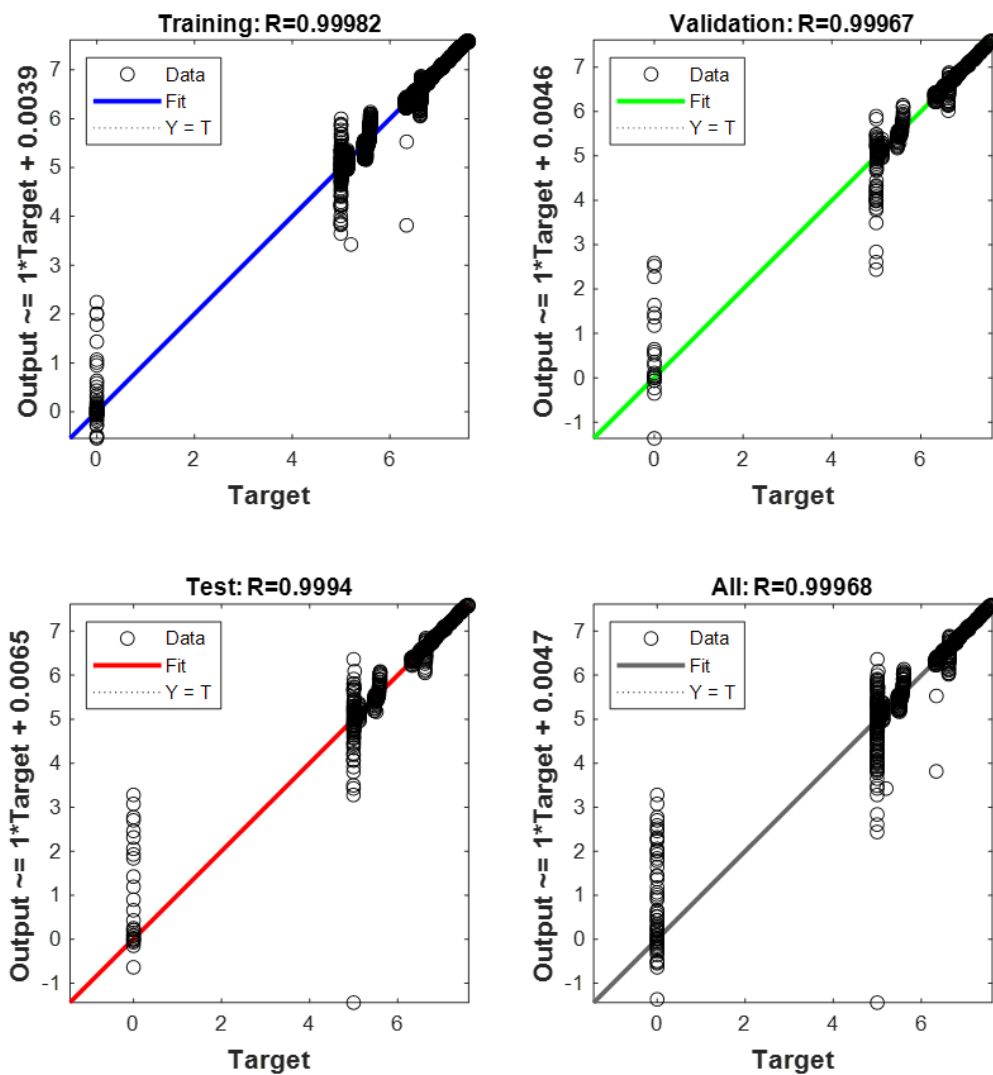
**Πίνακας 18: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE).**

Κρυφοί Κόμβοι	Reached Epochs (Iterations)	Running Time (hh:mm:ss)	Validation Checks (max=6)	RMSE		
				Training	Validation	Testing
35	213	00:00:40	6 6	0.032803	0.04279	0.015542
35	842	00:03:25	6 6	0.009705	0.013798	0.020049
35	260	00:00:51	6 6	0.027807	0.05702	0.051312

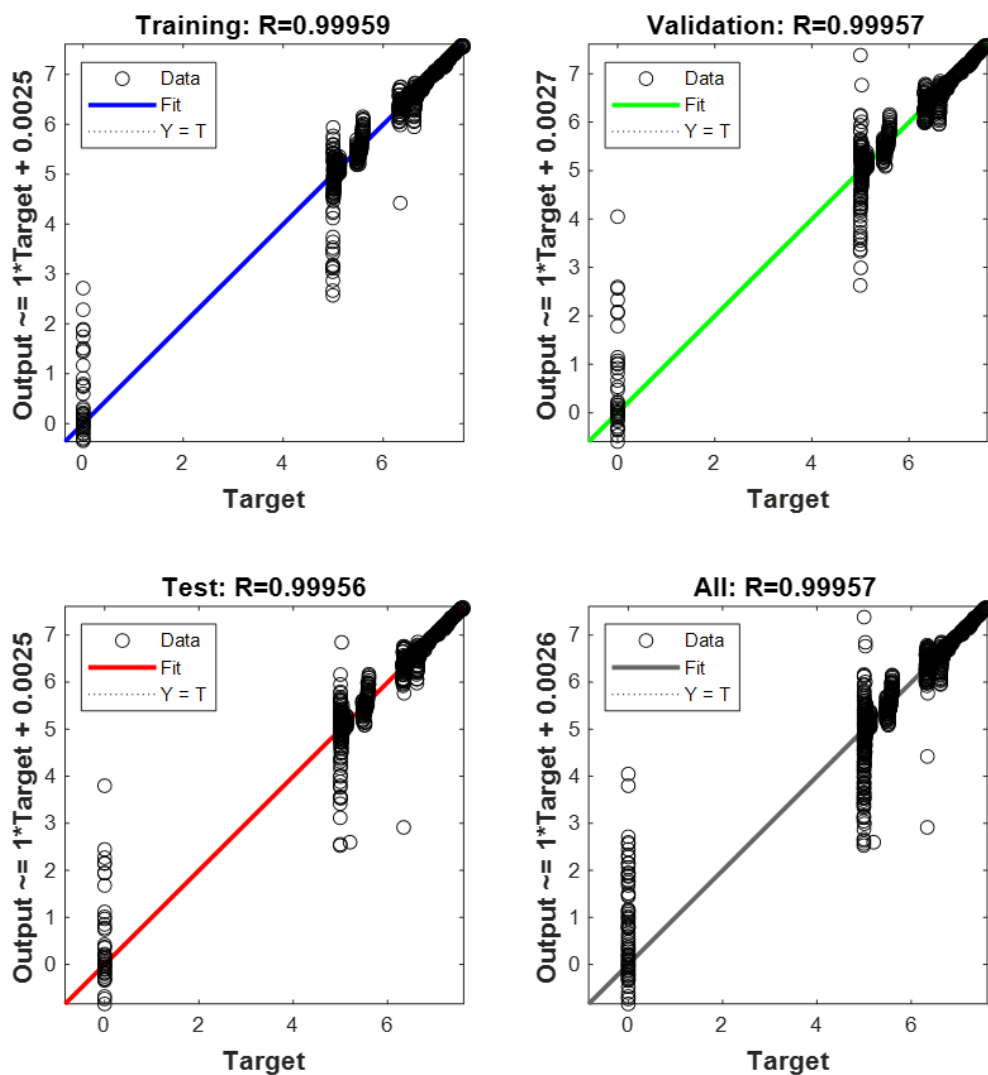
## ΑΦΥΓΡΑΝΣΗ



**Διάγραμμα 34: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 50 κρυφούς κόμβους (hidden nodes) , με ποσοστά 90% Training , 5% Validation και 5% Testing.**



**Διάγραμμα 35: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 50 κρυφούς κόμβους (hidden nodes) , με ποσοστά 50% Training , 25% Validation και 25% Testing.**



**Διάγραμμα 36: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 50 κρυφούς κόμβους (hidden nodes) , με ποσοστά 30% Training , 35% Validation και 35% Testing.**

**Πίνακες αποτελεσμάτων για αφύγρανση την χειμερινή περίοδο (PP1)**

**Πίνακας 19: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt με διαφορετικά ποσοστά (percentages)**

Διάγραμμα	Κρυφοί Κόμβοι	Percentages			Epochs
		Training	Validation	Testing	
34	50	90 %	5%	5%	1000
35	50	50 %	25%	25%	1000
36	50	30 %	35%	35%	1000

**Πίνακας 20: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R**

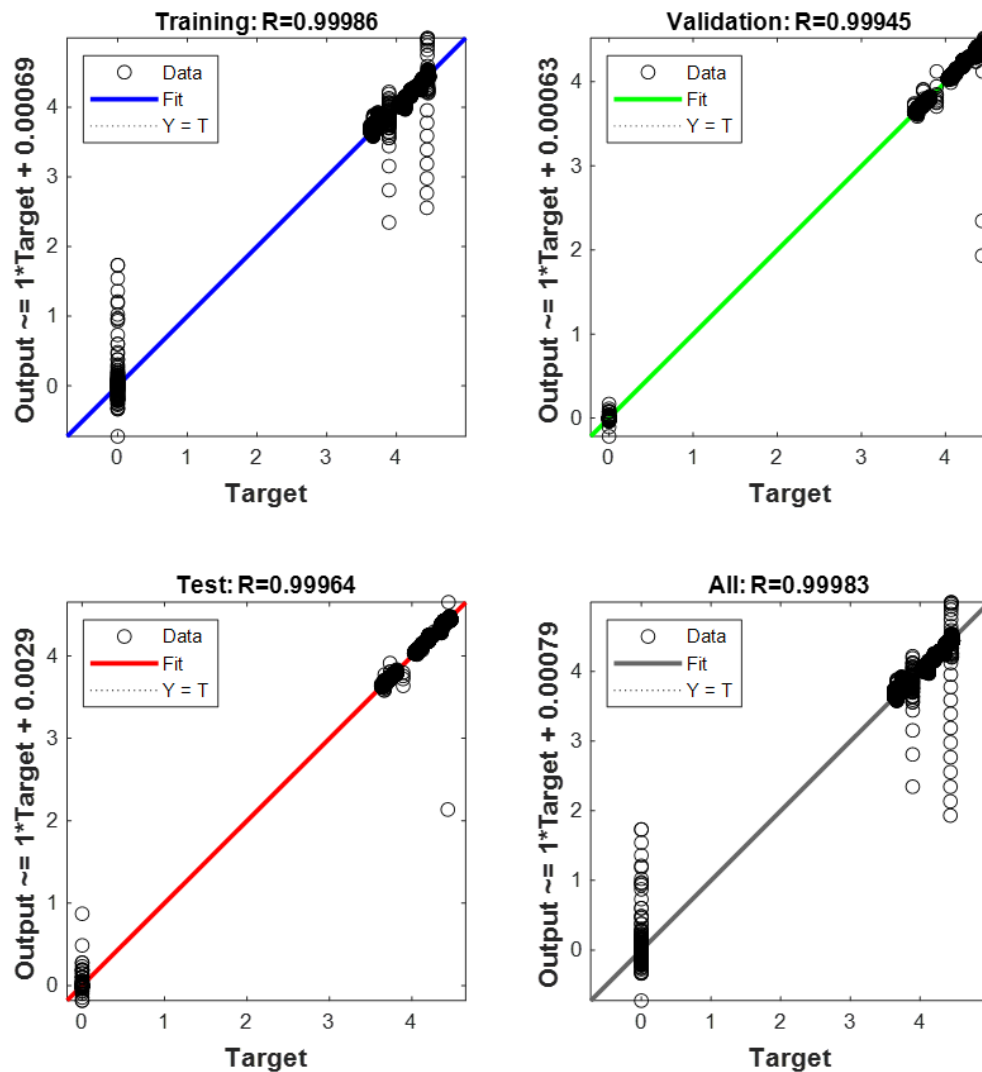
Διάγραμμα	Κρυφοί Κόμβοι	MSE			R		
		Training	Validation	Testing	Training	Validation	Testing
34	50	0.0045501	0.010971	0.007205	0.999776	0.999467	0.999642
35	50	0.00375105	0.006802	0.012128	0.999816	0.999667	0.999402
36	50	0.00825133	0.008683	0.008988	0.999592	0.999574	0.999559

**Πίνακας 21: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE).**

Κρυφοί Κόμβοι	Reached Epochs (Iterations)	Running Time (hh:mm:ss)	Validation Checks (max=6)	RMSE		
				Training	Validation	Testing
50	504	00:02:30	6 6	0.067454	0.104744	0.084881
50	568	00:02:49	6 6	0.061246	0.082475	0.110129
50	541	00:02:07	6 6	0.090837	0.093181	0.094805

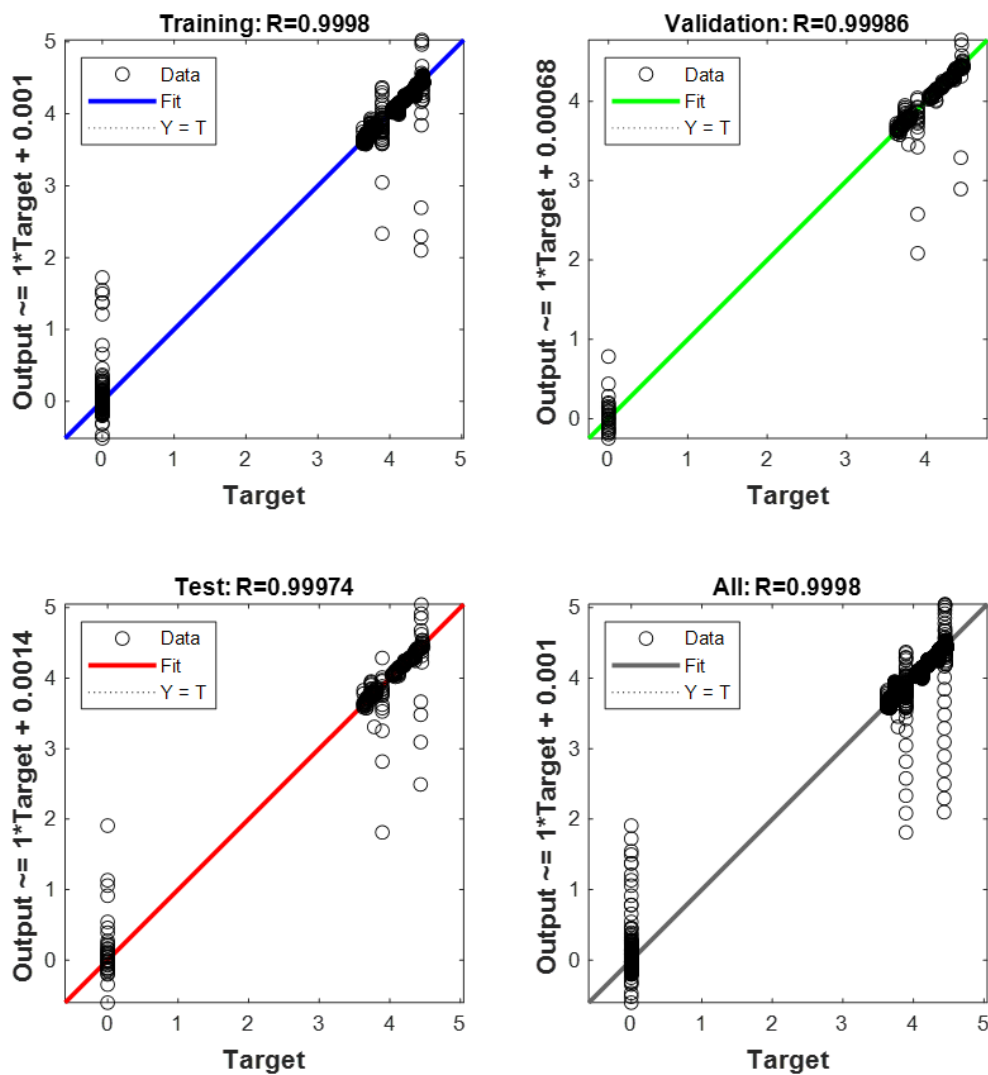
## 5.2.2 Καλοκαιρινή Περίοδος

ΨΥΞΗ

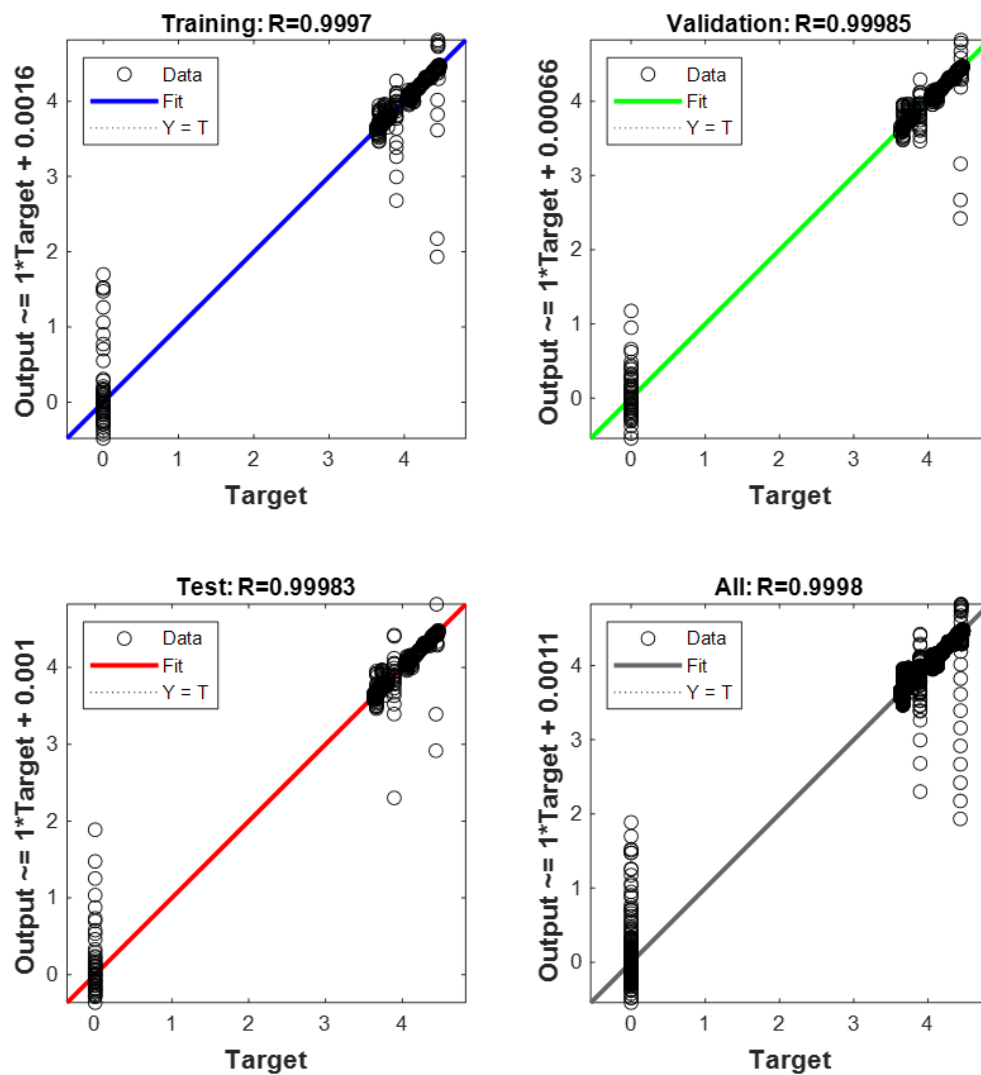


**Διάγραμμα 37: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα ψύξης με 25 κρυφούς κόμβους (hidden nodes) , με ποσοστά 90% Training , 5% Validation και 5% Testing.**





**Διάγραμμα 38: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα ψύξης με 25 κρυφούς κόμβους (hidden nodes) , με ποσοστά 50% Training , 25% Validation και 25% Testing.**



**Διάγραμμα 39: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα ψύξης με 25 κρυφούς κόμβους (hidden nodes) , με ποσοστά 30% Training , 35% Validation και 35% Testing.**

**Πίνακες αποτελεσμάτων για ψύξη την καλοκαιρινή περίοδο (PP4)**

**Πίνακας 22: Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt με διαφορετικά ποσοστά (percentages)**

Διάγραμμα	Κρυφοί Κόμβοι	Percentages			Epochs
		Training	Validation	Testing	
37	25	90 %	5%	5%	1000
38	25	50 %	25%	25%	1000
39	25	30 %	35%	35%	1000

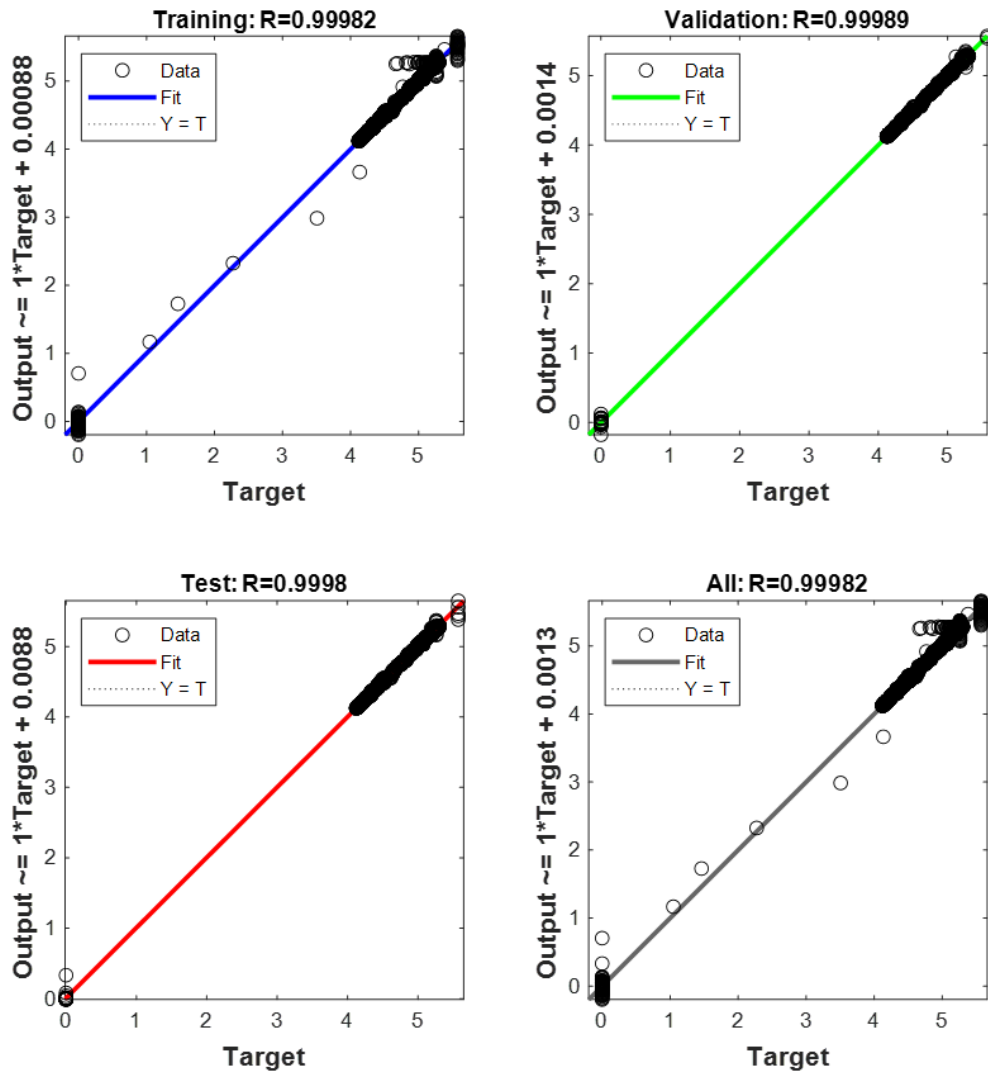
**Πίνακας 23: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R**

Διάγραμμα	Κρυφοί Κόμβοι	MSE			R		
		Training	Validation	Testing	Training	Validation n	Testing
37	25	0.001207	0.004649	0.003017	0.999856	0.999448	0.999637
38	25	0.001694	0.001148	0.002184	0.999798	0.999863	0.999739
39	25	0.002513	0.001258	0.00141	0.9997	0.999849	0.999832

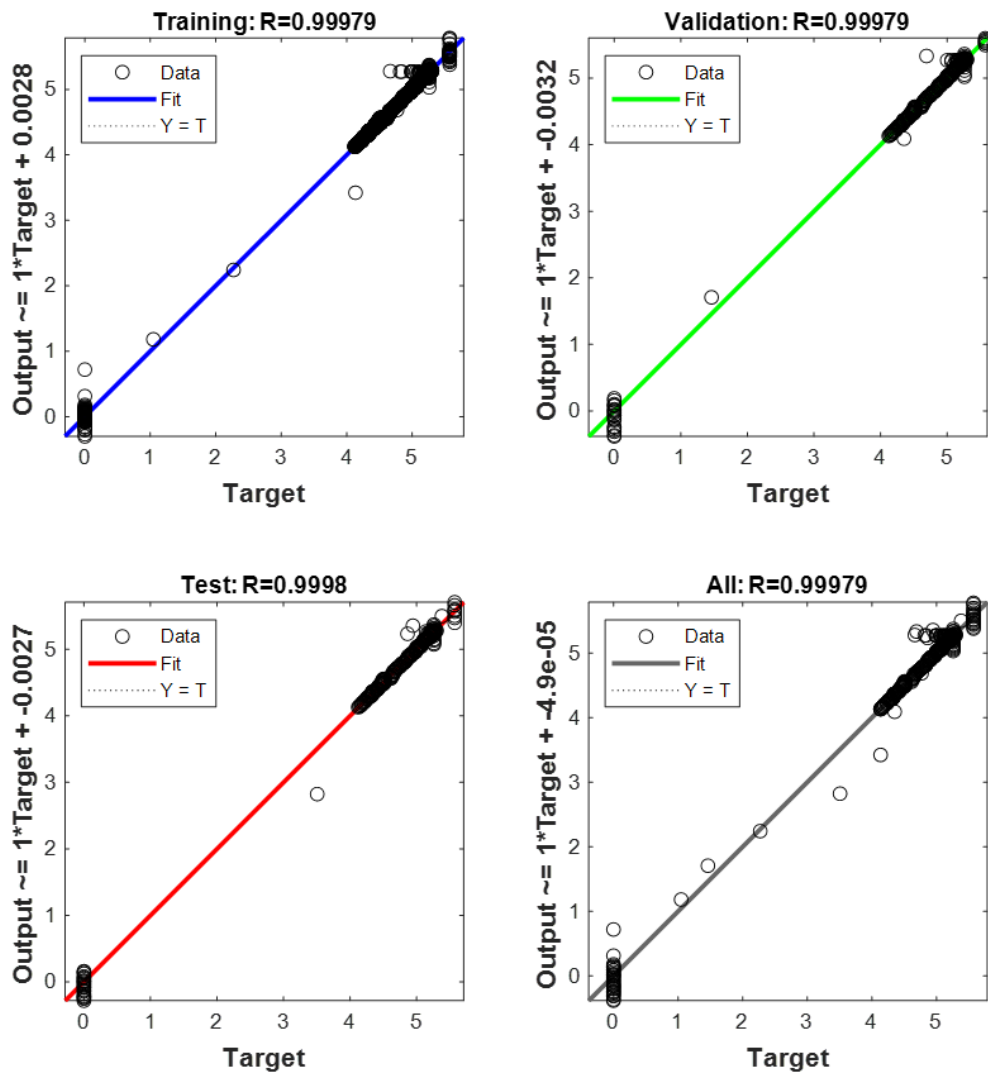
**Πίνακας 24: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE).**

Κρυφοί Κόμβοι	Reached Epochs (Iterations)	Running Time (hh:mm:ss)	Validation Checks (max=6)	RMSE		
				Training	Validation	Testing
50	318	00:00:42	6 6	0.034735	0.068181	0.054931
50	1000	00:02:15	0 6	0.041161	0.033882	0.046738
50	317	00:00:46	6 6	0.050126	0.035464	0.03755


## ΑΦΥΓΡΑΝΣΗ



**Διάγραμμα 40: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 20 κρυφούς κόμβους (hidden nodes) , με ποσοστά 90% Training , 5% Validation και 5% Testing.**



**Διάγραμμα 41: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 20 κρυφούς κόμβους (hidden nodes) , με ποσοστά 50% Training , 25% Validation και 25% Testing.**



**Διάγραμμα 42: Παλινδρόμηση εκπαίδευσης (Training Regression) για δεδομένα αφύγρανσης με 20 κρυφούς κόμβους (hidden nodes) , με ποσοστά 30% Training , 35% Validation και 35% Testing.**

**Πίνακες αποτελεσμάτων για αφύγρανση την καλοκαιρινή περίοδο (PP4)**

**Πίνακας 25 : Απαραίτητοι παράμετροι για τον αλγόριθμο Levenberg-Marquardt με διαφορετικά ποσοστά (percentages)**

<i>Διάγραμμα</i>	<i>Κρυφοί Κόμβοι</i>	<i>Percentages</i>			<i>Epochs</i>
		<i>Training</i>	<i>Validation</i>	<i>Testing</i>	
40	20	90 %	5%	5%	1000
41	20	50 %	25%	25%	1000
42	20	30 %	35%	35%	1000

**Πίνακας 26: Αποτελέσματα για το μέσο τετραγωνικό σφάλμα (MSE) και τον συντελεστή συσχέτισης R**

<b>Διάγραμμα</b>	<b>Κρυφοί Κόμβοι</b>	<b>MSE</b>			<b>R</b>		
		<b>Training</b>	<b>Validation</b>	<b>Testing</b>	<b>Training</b>	<b>Validatio n</b>	<b>Testing</b>
40	20	0.000233	0.000174	0.000229	0.99982	0.999889	0.999798
41	20	0.00028	0.000274	0.000255	0.999788	0.99979	0.999799
42	20	0.00031	0.000376	0.000409	0.99974	0.999722	0.999695

**Πίνακας 27: Αποτελέσματα για τον αριθμό εποχών (iteration) ,τον χρόνο εκπαίδευσης (Running time) ,τους ελέγχους επικύρωσης( validation checks) και το ριζικό του μέσου τετραγωνικού σφάλματος (RMSE).**

<i>Κρυφοί Κόμβοι</i>	<i>Reached Epochs (Iterations)</i>	<i>Running Time (hh:mm:ss)</i>	<i>Validation Checks (max=6)</i>	<i>RMSE</i>		
				<i>Training</i>	<i>Validation</i>	<i>Testing</i>
20	964	00:01:36	6 6	0.015259	0.013201	0.015129
20	665	00:01:05	6 6	0.016719	0.016566	0.015964
20	724	00:01:13	6 6	0.017619	0.019403	0.020212

## Κεφάλαιο 6

### Συζήτηση

Στην παρούσα μελέτη ,αρχικά , τα νευρωνικά δίκτυα που σχεδιάστηκαν αφορούσαν τις περιόδους χειμώνα (01.01-05.02) και καλοκαιριού (31.05-05.07) για τις οποίες λειτουργούν κυρίως η θέρμανση και η ψύξη αντίστοιχα, ενώ σε αμφοότερες τις περιόδους χρησιμοποιείται και η αφύγρανση. Αρχικά ,τα νευρωνικά δίκτυα που παρουσιάζονται στα **Διαγράμματα 1-8** αφορούν την χειμερινή περίοδο και την λειτουργία της θέρμανσης και σχεδιάστηκαν αξιοποιώντας τον αλγόριθμο Levenberg-Marquardt με αρχικά ποσοστά 70% εκπαίδευσης(Training),15% επικύρωσης (Validation) και 15% ελέγχου (Testing). Η αξιολόγηση των νευρωνικών δικτύων βασίζεται στις τιμές του ριζικού μέσου τετραγωνικού σφάλματος (RMSE) και του συντελεστή συσχέτισης ( $R$ ) για κάθε προσομοίωση. Η τιμή του συντελεστή  $R$  υποδεικνύει την αξιοπιστία της πρόβλεψης που πραγματοποιεί το νευρωνικό δίκτυο και είναι επιθυμητό να παρουσιάζει τιμές όσο το δυνατόν πλησιέστερες στην μονάδα(1). Στην πρώτη φάση εκπαίδευσης των ΤΝΔ τα παραπάνω ποσοστά (70/15/15) διατηρούνται σταθερά για όλες τις περιόδους και λειτουργίες ενώ στην δεύτερη πραγματοποιούνται δοκιμές αυτών βάσει της βέλτιστης εκπαίδευσης για κάθε λειτουργία και χρονική περίοδο της πρώτης φάσης. Θα πρέπει να σημειωθεί ότι η βέλτιστη λύση μεταξύ των προσομοιώσεων ,για αυξανόμενο αριθμό κρυφών κόμβων, βρέθηκε συγκρίνοντας τις τιμές RMSE και  $R$  που απέδωσαν κάθε φορά.

Για κάθε νευρωνικό δίκτυο, ο αριθμός των κρυφών κόμβων αλλάζει ενώ ο αριθμός εποχών διατηρείται σταθερός με μέγιστο τις 1000 εποχές. Η εκπαίδευση συνήθως απαιτεί το μεγαλύτερο κομμάτι των δεδομένων ώστε το νευρωνικό δίκτυο να δίνει αξιόπιστα αποτελέσματα.

Όπως φαίνεται και στο **Διάγραμμα 1** το πρώτο νευρωνικό δίκτυο εκπαιδεύεται με 10 κρυφούς κόμβους και παρουσιάζει πολύ υψηλό συντελεστή συσχέτισης (~99.9%) και πολύ χαμηλό μέσο τετραγωνικό σφάλμα (MSE) για εκπαίδευση, επικύρωση και έλεγχο των τιμών. Επιπλέον, το ριζικό σφάλμα (RMSE) εμφανίζει τιμή 0.055308, 0.076073 και 0.053562 για Training, Validation και Testing αντίστοιχα όπως παρουσιάζονται και στον συνοπτικό **Πίνακα 5** ,ενώ ο συνολικός αριθμός εποχών που χρειάστηκαν για την εκπαίδευση του ήταν 108 (με μέγιστες τις 1000) βάσει του **Πίνακα 6**.

Με αύξουσα επιλογή των κρυφών κόμβων, παρατηρήθηκε ελάχιστη βελτίωση στον συντελεστή συσχέτισης  $R$  ενώ το σφάλμα RMSE έλαβε ελάχιστη τιμή για τους 35 κόμβους και έπειτα παρουσίασε μικρή αύξηση. Επιπλέον ο χρόνος εκπαίδευσης (running time) παρέμεινε σχετικά σταθερός και ελάχιστος (~1 min) έως τους 80 και 100 κόμβους όπου ανέβηκε στα 08:16 min και 11:36 min αντίστοιχα. Θα πρέπει να επισημανθεί, ότι η εκπαίδευση με 25 και 80 κρυφούς κόμβους σταμάτησε επειδή έφτασε τον μέγιστο αριθμό εποχών(1000) προς αποφυγή υπερεκπαίδευσης.Η βέλτιστη εκπαίδευση ήταν για 35 κρυφούς κόμβους, χρόνο εκπαίδευσης 02:04 min και σφάλματα (RMSE) 0.013967, 0.01242 και 0.012279 για training, validation και testing αντίστοιχα.

Η εκπαίδευση για κρυφούς κόμβους άνω των 100 δεν συνεχίστηκε καθώς ήδη τα σφάλματα δεν παρουσιάζουν βελτίωση μετά τους 35 κόμβους και ο απαιτούμενος χρόνος εκπαίδευσης αυξάνεται αισθητά.

Συνεπώς η βέλτιστη εκπαίδευση για την θέρμανση την χειμερινή περίοδο με τον αλγόριθμο LM παρουσιάζεται για **35 κρυφούς κόμβους** οπότε και παρατηρήθηκε ελάχιστο σφάλμα MSE.

Ακολούθως πραγματοποιήθηκε εκπαίδευση ΤΝΔ για την αφύγρανση την χειμερινή περίοδο και τα αποτελέσματα παρουσιάζονται στα **Διαγράμματα 9-16**. Πιο συγκεκριμένα, η εκπαίδευση του πρώτου ΤΝΔ πραγματοποιείται με 10 κρυφούς κόμβους παρουσιάζοντας



πολύ υψηλό συντελεστή συσχέτισης (~99.9%) και πολύ χαμηλό ριζικό μέσου τετραγωνικού σφάλματος (RMSE) με τιμές 0.09108, 0.0859632 και 0.0989614 για εκπαίδευση, επικύρωση και έλεγχο αντίστοιχα. Όπως παρουσιάζεται και στον **Πίνακα 9**, οι απαιτούμενες εποχές για την εκπαίδευση του ανήλθαν στις 439/1000. Με χρήση επιπλέον κρυφών κόμβων (20,25,30,35,50,80 και 100), όπως και στην θέρμανση, παρατηρήθηκε μικρή αύξηση στον συντελεστή συσχέτισης R, με μέγιστη τιμή στους 80 κόμβους (για training και validation αλλά όχι για testing). Επιπροσθέτως, στους 80 κόμβους το ριζικό μέσου τετραγωνικού σφάλματος (RMSE) παρουσίασε ελάχιστη τιμή (για training και validation αλλά όχι για testing) όμως με μέγιστο χρόνο εκπαίδευσης 09:52 min. Συνολικά, ο μέγιστος αριθμός των 1000 εποχών έφτασε στην περίπτωση των 25 και 80 κρυφών κόμβων οπότε και σταμάτησε η εκπαίδευση. Συνεπώς, συγκρίνοντας τις αποδόσεις που παρουσιάζονται στους **Πίνακες 8 & 9** για την χειμερινή αφύγρυνση, επιλέγεται ως βέλτιστη η εκπαίδευση με τους **50 κρυφούς κόμβους**.

Έπειτα εξετάστηκε η συμπεριφορά του νευρωνικού δικτύου για την θερινή περίοδο (PP4) για τις περιπτώσεις της ψύξης και της αφύγρυνσης. Στην περίπτωση της ψύξης, οι δοκιμές για τους κόμβους 20-100 (ίδιος αριθμός κόμβων με την χειμερινή περίοδο) παρουσιάζονται στα **Διαγράμματα 17-23** και επιλέγεται ως βέλτιστη εκπαίδευση αυτή με τους **25 κόμβους** ενώ η αύξηση των κόμβων πέραν αυτών δεν οδηγεί σε περαιτέρω βελτιώσεις παρά την αύξηση του χρόνου εκπαίδευσης. Θα πρέπει να τονιστεί ότι αν και για τους 20 κρυφούς κόμβους βρέθηκε μικρότερο σφάλμα ειδικά για τον έλεγχο (testing) προτιμήθηκε ως βέλτιστη η εκπαίδευση με τους 25 κόμβους καθώς συνυπολογίστηκε και ο συντελεστής συσχέτισης. Πιο συγκεκριμένα, τα σφάλματα RMSE για τους 25 κόμβους ήταν 0.025814, 0.0113 και 0.04669 για training, validation και testing αντίστοιχα.

Όσον αφορά την αφύγρυνση την θερινή περίοδο (PP4), τα αποτελέσματα της οποίας παρουσιάζονται στα **Διαγράμματα 24-30**, παρατηρήθηκε ότι η εκπαίδευση έφτασε τον μέγιστο αριθμό εποχών για τις περισσότερες δοκιμές με κρυφούς κόμβους με εξαίρεση τους 20 και 25. Μεταξύ αυτών καλύτερα αποτελέσματα παρουσίασε η προσομοίωση με χρήση **20 κρυφών κόμβων** με σφάλματα RMSE ίσα με 0.014852, 0.01231 και 0.014323 για εκπαίδευση, επικύρωση και έλεγχο αντίστοιχα.

Σε **δεύτερο βήμα** επιλέχθηκαν οι βέλτιστες εκπαιδεύσεις των παραπάνω περιόδων και θερμικών λειτουργιών και πραγματοποιήθηκαν δοκιμές ποσοστών training, validation και testing όπως παρουσιάζονται στα **Διαγράμματα 31-42**. Οι περαιτέρω δοκιμές με διαφορετικά ποσοστά εκπαίδευσης, επικύρωσης και ελέγχου προτιμήθηκαν αντί για αύξηση των εποχών άνω των 1000 καθώς ο αυξημένος αριθμός εποχών μπορεί να οδηγήσει σε υπερεκπαίδευση του δικτύου. Ο διαχωρισμός ποσοστών (split) που επιλέχθηκε ήταν διαφορετικός από τον προκαθορισμένο (70%/30%/30%) ώστε να εξεταστούν οι περιπτώσεις όπου το νευρωνικό δίκτυο δοκιμάζεται για πολύ υψηλό ποσοστό εκπαίδευσης (90%), για πιο μετριοπαθή εκπαίδευση (50%) και για ισοκαταμεμημένα ποσοστά (30%/35%/35%).

Αρχικά για την περίπτωση της θέρμανσης την χειμερινή περίοδο, όπως παρουσιάζεται και στα **Διαγράμματα 31-33**, οι δοκιμές για διαφορετικά ποσοστά συνολικά δεν απέδωσαν καλύτερα αποτελέσματα σε σχέση με την βέλτιστη εκπαίδευση του προκαθορισμένου ποσοστού. Στους **Πίνακες 17 & 18** παρουσιάζονται αναλυτικά οι τιμές RMSE και R για τις δοκιμές με διαφορετικά ποσοστά και παρατηρείται ότι μόνο για την περίπτωση της εκπαίδευσης (αλλά όχι της επικύρωσης και του ελέγχου) με ποσοστά 50/25/25 (%) εμφανίζεται μικρότερο σφάλμα και υψηλότερο συντελεστής συσχέτισης συγκριτικά με την εκπαίδευση με ποσοστά 70/15/15 (%). Συγκεκριμένα, ο συντελεστής R και το σφάλμα RMSE βρέθηκαν 0.999979 και 0.009705 αντίστοιχα.

Παρόμοιο μοτίβο παρατηρείται και για την περίπτωση της αφύγρυνσης την χειμερινή περίοδο όπου όπως παρουσιάζεται στα **Διαγράμματα 34-36** και τους **Πίνακες 20 & 21**. Συγκεκριμένα, τα προκαθορισμένα ποσοστά 70/15/15 εμφανίζουν καλύτερα αποτελέσματα έναντι όλων των άλλων ποσοστών πέραν της εκπαίδευσης (αλλά όχι της επικύρωσης και του ελέγχου) με ποσοστά 50/25/25 (%) που παρουσίασε RMSE=0.061246 και R=0.999816.

Ακολούθως, εξετάστηκε η λειτουργία της ψύξης κατά την θερινή περίοδο και όπως φαίνεται από τα **Διαγράμματα 37-39** και τους **Πίνακες 23 & 24**, η εκπαίδευση με τα αρχικά ποσοστά

70/15/15 παρουσίασε καλύτερα αποτελέσματα για R και RMSE από όλες τις υπόλοιπες εκπαιδεύσεις με μεταβλητά ποσοστά.

Για την αφύγρανση της ίδιας περιόδου, τα προκαθορισμένα ποσοστά 70/15/15 παρουσίασαν ξανά καλύτερα αποτελέσματα για τους δύο δείκτες με εξαίρεση την επικύρωση με ποσοστά 90/5/5 που παρουσίασε ελαφρά υψηλότερο συντελεστή συσχέτισης (0.999889) όπως φαίνεται στον **Πίνακα 26**.

Γενικότερα διαπιστώνουμε ότι αν και για διαφορετικούς διαχωρισμούς ποσοστών (κυρίως το σετ 50%/25%/25%) παρατηρείται ορισμένες φορές μικρή βελτίωση στα σφάλματα της εκπαίδευσης, κατά κανόνα το προκαθορισμένο ποσοστό 70/15/15 παρουσιάζει καλύτερα αποτελέσματα.

Σταθερό μοτίβο που γίνεται εμφανές παρατηρώντας τα διαγράμματα διασποράς που εξετάζονται στην παρούσα ενότητα είναι ότι ενώ τα νευρωνικά δίκτυα παρουσιάζουν πολύ υψηλό συντελεστή συσχέτισης, δεν μπορούν να προσομοιώσουν ικανοποιητικά τις ακραίες τιμές. Η συγκεκριμένη παρατήρηση είναι ιδιαίτερα έντονη για τα αποτελέσματα της χειμερινής περιόδου. Αντιθέτως, για την καλοκαιρινή περίοδο και ιδίως την αφύγρανση δεν διακρίνονται έντονα ακραίες τιμές. Επιπλέον, οι τιμές που δίνει ως αποτέλεσμα το νευρωνικό δίκτυο τείνουν να συσσωρεύονται στην αρχή και το τέλος των διαγραμμάτων. Αυτό συμβαίνει καθώς με την έναρξη της κάθε περιόδου παραγωγής και για μεγάλο χρονικό διάστημα η αντλία θερμότητας δεν ενεργοποιείται (δεν έχει γίνει υπέρβαση των σημείων ρύθμισης) και επομένως η απόδοση της (ανενεργούς) ΑΘ ισοδυναμεί με μηδέν ( $COP=0$ ). Συνεπώς, για τιμές των δεδομένων εξόδου (Target) ίσες με μηδέν, οι τιμές που δίνει το νευρωνικό δίκτυο (Output) συσσωρεύονται γύρω από το μηδέν. Με την ενεργοποίηση της ΑΘ για μια θερμική λειτουργία, ο συντελεστής απόδοσης συνήθως λαμβάνει τιμές μεγαλύτερες του τρία ( $COP>3$ ) και με αυτό τον τρόπο εμφανίζεται αυτό το κενό διάστημα τιμών στα διαγράμματα.

Μια αξιοπρόσεκτη παρατήρηση σχετικά με τις προσομοιώσεις των συγκεκριμένων νευρωνικών δικτύων είναι ότι η χρήση επιπλέον κρυφών κόμβων σπάνια βελτιώνει τις αποδόσεις τους με αποτέλεσμα ο μικρότερος (ή μεσαίος) αριθμός κρυφών κόμβων να είναι συχνά πιο επιθυμητός.

Συνοψίζοντας, θα πρέπει να τονιστεί ότι τόσο τα σφάλματα (MSE, RMSE) όσο και ο συντελεστής συσχέτισης (R) παρουσίασαν πολύ ικανοποιητικές τιμές για όλες τις προσομοιώσεις με τα τεχνητά νευρωνικά δίκτυα. Αυτές οι εξαιρετικές αποδόσεις δεν μπορούν να καταλογιστούν μόνο στην ικανότητα των ΤΝΔ να μαθαίνουν και να γενικεύουν αλλά και στο ίδιο το σύνολο δεδομένων το οποίο υπήρξε προϊόν ενός δυναμικού μοντέλου. Οι τιμές του συντελεστή απόδοσης (COP) έχουν υπολογιστεί στην έρευνα των *Tyris et al. 2023* και χρησιμοποιήθηκαν στην παρούσα εργασία ως δεδομένα εξόδου για την εκπαίδευση των ΤΝΔ. Σε διαφορετική περίπτωση, όπου θα είχαν πραγματοποιηθεί μετρήσεις πεδίου για τον συντελεστή COP ενδεχομένως το σετ δεδομένων να περιείχε περισσότερο θόρυβο και έτσι η εκπαίδευση με τα τεχνητά νευρωνικά δίκτυα να απέδιδε μεγαλύτερα σφάλματα.

Περαιτέρω βελτιώσεις της εκπαίδευσης με νευρωνικά δίκτυα που πραγματοποιήθηκε στην παρούσα εργασία αποτελούν η χρήση επιπλέον αλγορίθμων που περιλαμβάνει η εργαλειοθήκη της Matlab πέραν του Levenberg-Marquardt, η χρήση του εργαλείου nntool της Matlab που επιτρέπει την δοκιμή επιπλέον συνθηκών εκπαίδευσης (αλλαγή μέγιστων εποχών) και η κανονικοποίηση των δεδομένων εισόδου με διαφορετικές μεθόδους.

## Κεφάλαιο 7

### Συμπεράσματα

Στην παρούσα διπλωματική εργασία πραγματοποιήθηκε μελέτη της απόδοσης ενός συστήματος αντλιών θερμότητας εντός μιας πτηνοτροφικής μονάδας με χρήση τεχνητών νευρωνικών δικτύων. Η απόδοση των νευρωνικών δικτύων που εκπαιδεύτηκαν παρουσίασε για όλες τις περιπτώσεις πολύ υψηλή ακρίβεια και ελάχιστο απαιτούμενο χρόνο εκπαίδευσης. Η εκπαίδευση των τεχνητών νευρωνικών δικτύων πραγματοποιήθηκε στο περιβάλλον προσομοίωσης της Matlab αξιοποιώντας το εργαλείο nftool.

Αρχικά, οι εκπαιδεύσεις των νευρωνικών δικτύων πραγματοποιήθηκαν με χρήση αυξανόμενου αριθμού κρυφών κόμβων για όλες τις περιόδους και τις θερμικές λειτουργίες ώστε να βρεθεί η βέλτιστη εκπαίδευση βάσει των δεικτών του ριζικού μέσου σφάλματος (RMSE) και του συντελεστή συσχέτισης ( $R$ ).

Ακολούθως, χρησιμοποιώντας τον αριθμό των κρυφών κόμβων για την βέλτιστη εκπαίδευση των παραπάνω λειτουργιών και περιόδων εκπαιδεύτηκαν εκ νέου νευρωνικά δίκτυα υπό διαφορετικά ποσοστά εκπαίδευσης, επικύρωσης και ελέγχου. Με αυτόν τον τρόπο πραγματοποιήθηκε σύγκριση μεταξύ των προκαθορισμένων (70/15/15 %) και μεταβαλλόμενων ποσοστών. Για κάθε περίοδο και θερμική λειτουργία εξετάστηκαν τα ποσοστά 90/5/5 (%), 50/25/25 (%) και 30/35/35 (%). Οι παραπάνω δοκιμές μαρτυρούν ότι παρότι η χρήση των προκαθορισμένων ποσοστών εκπαίδευσης, επικύρωσης και ελέγχου δίνει σχεδόν καθολικά καλύτερα αποτελέσματα δεν θα πρέπει να αποκλείονται ως μέθοδος βελτιστοποίησης των παραμέτρων ενός τεχνητού νευρωνικού δικτύου.

Με την ολοκλήρωση της εκπαίδευσης πολλών νευρωνικών δικτύων με τον αλγόριθμο Levenberg-Marquardt (LMA) για διαφορετικό αριθμό κρυφών κόμβων και ποσοστών εκπαίδευσης επιτεύχθηκαν σφάλματα τάξης  $10^{-2}$  και συντελεστής συσχέτισης μεγαλύτερος του 0.999 (ή 99.9%).

Βασικό συμπέρασμα που εξάγεται από τα αποτελέσματα της εργασίας είναι ότι τα νευρωνικά δίκτυα και ο αλγόριθμος Levenberg-Marquardt αποτελούν ισχυρά εργαλεία για την μοντελοποίηση της λειτουργίας μιας δυναμικής αντλίας θερμότητας που καλείται να καλύψει με βέλτιστο τρόπο τις ανάγκες των πτηνών.

## Βιβλιογραφία

### Ξενόγλωσση

- López, O. A. M., López, A. M., & Crossa, J. (2022, January 1). *Fundamentals of Artificial Neural Networks and Deep Learning*. Springer eBooks.  
[https://doi.org/10.1007/978-3-030-89010-0\\_10](https://doi.org/10.1007/978-3-030-89010-0_10)
- López, O. A. M., López, A. M., & Crossa, J. (2022, February 14). *Multivariate Statistical Machine Learning Methods for Genomic Prediction*. Springer Nature.
- Shepherd, G. M. (1990). Introduction to synaptic circuits. *The Synaptic Organization of the Brain.*, 3-31.
- McCulloch, W.S., Pitts, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics* 5, 115–133 (1943).  
<https://doi.org/10.1007/BF02478259>
- Kröse, B. (1996). *An introduction to Neural Networks*. An Introduction to Neural Networks - Ghent University Library.  
<https://lib.ugent.be/catalog/ebk01:12250000001017123>
- Arbib, M. A. (1964, January 1). *Brains, Machines and Mathematics*.
- Grossberg, S. (1992, January 1). *Neural Networks and Natural Intelligence*. Bradford Books.
- Kerlirzin, P., & Vallet, F. (1993, May). Robustness in Multilayer Perceptrons. *Neural Computation*, 5(3), 473–482. <https://doi.org/10.1162/neco.1993.5.3.473>
- Haykin, S. S. (1999, January 1). *Neural Networks and Learning Machines*. Upper Saddle River, N.J. : Prentice Hall.
- Sterling, Peter, and Jonathan B. Demb, 'Retina', in Gordon M. Shepherd (ed.), *The Synaptic Organization of the Brain*, 5th edn (New York, 2004; online edn, Oxford Academic, 1 May 2009),  
<https://doi.org/10.1093/acprof:oso/9780195159561.003.0006>,
- Marquardt, D. W. (1963, June). An Algorithm for Least-Squares Estimation of Nonlinear Parameters. *Journal of the Society for Industrial and Applied Mathematics*, 11(2), 431–441. <https://doi.org/10.1137/0111030>
- Hagan, M., & Menhaj, M. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989–993.  
<https://doi.org/10.1109/72.329697>
- Mahowald, M. and Mead, C. (1989) *Analog VLSI and Neural Systems*. Silicon Retina, Addison-Wesley, Reading, 257-27
- Basheer, I., & Hajmeer, M. (2000, December). Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3–31. [https://doi.org/10.1016/s0167-7012\(00\)00201-3](https://doi.org/10.1016/s0167-7012(00)00201-3)
- Jierula, A., Wang, S., OH, T. M., & Wang, P. (2021, March 5). Study on Accuracy Metrics for Evaluating the Predictions of Damage Locations in Deep Piles Using Artificial Neural Networks with Acoustic Emission Data. *Applied Sciences*, 11(5), 2314. <https://doi.org/10.3390/app11052314>
- Hudson Beale, Hagan, & Demuth. (1992, June). 04\_Neural\_Network\_Toolbox\_Getting\_Started\_Guide.pdf. [www.mathworks.com](http://www.mathworks.com). Retrieved March 24, 2023, from

[https://ge0mllib.com/papers/Books/04\\_Neural\\_Network\\_Toolbox\\_Getting\\_Started\\_Guide.pdf](https://ge0mllib.com/papers/Books/04_Neural_Network_Toolbox_Getting_Started_Guide.pdf)

- Prechelt, L. (1998, January 1). Early Stopping - But When? Lecture Notes in Computer Science. [https://doi.org/10.1007/3-540-49430-8\\_3](https://doi.org/10.1007/3-540-49430-8_3)
- Carroll, P., Chesser, M., & Lyons, P. (2020, December). Air Source Heat Pumps field studies: A systematic literature review. *Renewable and Sustainable Energy Reviews*, 134, 110275. <https://doi.org/10.1016/j.rser.2020.110275>
- Esen, H., Inalli, M., Sengur, A., & Esen, M. (2008, November). Performance prediction of a ground-coupled heat pump system using artificial neural networks. *Expert Systems With Applications*, 35(4), 1940–1948. <https://doi.org/10.1016/j.eswa.2007.08.081>
- Arcaklioğlu, E., Erişen, A., & Yilmaz, R. (2004, July). Artificial neural network analysis of heat pumps using refrigerant mixtures. *Energy Conversion and Management*, 45(11–12), 1917–1929. <https://doi.org/10.1016/j.enconman.2003.09.028>
- Puttige, A. R., Andersson, S., Östin, R., & Olofsson, T. (2021, March 22). Application of Regression and ANN Models for Heat Pumps with Field Measurements. *Energies*, 14(6), 1750. <https://doi.org/10.3390/en14061750>
- Mohanraj, M., Jayaraj, S., & Muraleedharan, C. (2012, February). Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems—A review. *Renewable and Sustainable Energy Reviews*, 16(2), 1340–1358. <https://doi.org/10.1016/j.rser.2011.10.015>
- Tyrís D, Gkountas A, Bakalis P, Panagakís P, Manolákós D. A Dynamic Heat Pump Model for Indoor Climate Control of a Broiler House. *Energies*. 2023; 16(6):2770. <https://doi.org/10.3390/en16062770>
- Tyrís D., Gkountas A., Bakalis P., Panagakís P., Manolákós D., (Berlin, Germany, 22–23 November 2022). A dynamic heat pump model for precise environmental control in a broiler house in Northern Greece [Powerpoint]. Γεωπονικό Πανεπιστήμιο Αθηνών
- Costantino, A., & Fabrizio, E. (2020). Building Design for Energy Efficient Livestock Housing. In Holden, N. M., Wolfe, M. L., Ogejo, J. A., & Cummins, E. J. (Ed.), *Introduction to Biosystems Engineering*. [https://doi.org/10.21061/IntroBiosystemsEngineering/Livestock\\_Housing\\_Energy](https://doi.org/10.21061/IntroBiosystemsEngineering/Livestock_Housing_Energy)
- Costantino, A.; Fabrizio, E.; Ghiggini, A.; Bariani, M. Climate control in broiler houses: A thermal model for the calculation of the energy use and indoor environmental conditions. *Energy Build*. 2018
- Kalogirou, S. A., & Bojić, M. (2000, May 1). Artificial neural networks for the prediction of the energy consumption of a passive solar building. *Energy*; Elsevier BV. [https://doi.org/10.1016/s0360-5442\(99\)00086-9](https://doi.org/10.1016/s0360-5442(99)00086-9)
- Manolákós, D., Panagakís, P., Bartzanas, T., & Bouzianas, K. (2019, August 1). Use of heat pumps in HVAC systems for precise environment control in broiler houses: System's modeling and calculation of the basic design parameters. *Computers and Electronics in Agriculture*; Elsevier BV. <https://doi.org/10.1016/j.compag.2019.104876>
- 

## Ελληνόγλωσση

- Βλαχάβας, Κεφαλάς, Κόκκορας, & Σακελλαρίου. (2020, June). Τεχνητή Νοημοσύνη (4η). Εκδόσεις Πανεπιστημίου Μακεδονίας.

- Cengel, & Boles. (2018). *Θερμοδυναμική για Μηχανικούς* (8th ed.). ΕΚΔΟΣΕΙΣ ΤΖΙΟΛΑ.
- Ηλίας Λάνδρος, "Εκτίμηση της στάθμης υπογείων υδάτων στην ευρύτερη περιοχή του Ποταμού Δούναβη με χρήση τεχνητών νευρωνικών δικτύων", Διπλωματική Εργασία, Σχολή Μηχανικών Περιβάλλοντος, Πολυτεχνείο Κρήτης, Χανιά, Ελλάς, 2019 <https://doi.org/10.26233/heallink.tuc.82411>
- Γιαννάκος, Ν. (2014). ΑΝΤΛΙΕΣ ΘΕΡΜΟΤΗΤΑΣ ΣΕ ΣΥΣΤΗΜΑΤΑ ΘΕΡΜΑΝΣΗΣ ΣΧΕΔΙΑΣΜΟΣ - ΕΝΕΡΓΕΙΑΚΗ ΑΞΙΟΛΟΓΗΣΗ [Προπτυχιακή Διπλωματική Εργασία]. Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης
- Μαλαματένιος .(2014). " Γεωθερμία-Ηλιοθερμία// Τεχνικές εξοικονόμησης ενέργειας". Εκδόσεις ΓΣΕΒΒΕ-Ινστιτούτο Μικρών Επιχειρήσεων

### Ιστοσελίδες

- <https://www.mathworks.com/help/deeplearning/ref/trainlm.html> (Accessed 20/5/2023)
- Wikipedia, [https://en.wikipedia.org/wiki/Artificial\\_neural\\_network](https://en.wikipedia.org/wiki/Artificial_neural_network) (Accessed 30/3/2023)