
Διπλωματική εργασία

*Προσαρμοζόμενο σύστημα ελέγχου με τη χρήση Τεχνητών
Νευρωνικών Δικτύων για τη βελτιστοποίηση της λειτουργίας
θέρμανσης και ψύξης ενός κατοικημένου χώρου*

Αλεξάνδρα Πολυμενοπούλου

Επιτροπή Καθηγητών:
Καλαϊτζάκης Κωνσταντίνος (Επιβλέπων)
Κολοκοτσά Διονυσία
Σταυρακάκης Γεώργιος

Abstract

The subject of the current thesis project focuses on an adaptive control system development using neural networks, implemented to regulate the indoor temperature of a specifically designed for this purpose residential space. The main purpose of this project is to control the activation or deactivation of the heating and cooling system, in order to ensure the annual reduction of energy cost, compared to a simple thermostat, while maintaining thermal comfort. Firstly, specifications of the residence are defined, and the energy model is simulated for one year, providing the energy data and the behavior of internal temperature, when a simple thermostat is used. After investigating literature, the author constructed neural networks, trained them with data provided from the energy simulation of the residence and used them as models in the control system, to predict the future presence of residents in the area, the indoor temperature and the energy consumption due to heating or cooling operation. The developed control system, simulated for one year, seeks on each simulation timestep the optimal decision for the heating and cooling operation, based on future activity of residents, by calculating the energy cost and the cost of thermal comfort loss for a number of potential time sequences of operation. Then, the annual response of the controller is compared with the output of the energy simulation and results in a reduced energy consumption. Furthermore, additional conclusions are made regarding the efficient usage of multiple neural networks in the control system. Finally, overall suggestions, concerning the optimization of the method developed in this control system, are set to be used for further investigation.

Περίληψη

Η παρούσα διπλωματική εργασία εστιάζει στην ανάπτυξη ενός προσαρμοστικού συστήματος ελέγχου, με χρήση τεχνητών νευρωνικών δικτύων, για τη ρύθμιση της εσωτερικής θερμοκρασίας ενός σχεδιασμένου για το σκοπό αυτό κατοικημένου χώρου. Σκοπός είναι η ενεργοποίηση ή απενεργοποίηση του συστήματος θέρμανσης και ψύξης, προκειμένου να εξασφαλιστεί ετήσια μείωση του ενεργειακού κόστους σε σύγκριση με έναν απλό θερμοστάτη, διατηρώντας παράλληλα τη θερμική άνεση των κατοίκων. Αρχικά, καθορίζονται χαρακτηριστικά της κατοικίας και προσομοιώνεται το ενεργειακό μοντέλο για ένα έτος, εξασφαλίζοντας τα ενεργειακά δεδομένα και τη διαμόρφωση της εσωτερικής θερμοκρασίας όταν χρησιμοποιείται ένας απλός θερμοστάτης. Μετά από έρευνα σχετικής βιβλιογραφίας, κατασκευάζονται νευρωνικά δίκτυα, τα οποία εκπαιδεύονται με δεδομένα που προέρχονται από την ενεργειακή προσομοίωση της κατοικίας και χρησιμοποιούνται ως μοντέλα του συστήματος ελέγχου, για να προβλέψουν τη μελλοντική παρουσία των κατοίκων στο χώρο, την εσωτερική θερμοκρασία και την κατανάλωση ενέργειας λόγω της λειτουργίας θέρμανσης και ψύξης. Το σύστημα ελέγχου, το οποίο προσομοιώνεται για ένα χρόνο, αναζητά κάθε χρονική στιγμή της προσομοίωσης τη βέλτιστη απόφαση για τη λειτουργία θέρμανσης ή ψύξης, λαμβάνοντας υπόψη τη μελλοντική δραστηριότητα των κατοίκων και υπολογίζοντας το ενεργειακό κόστος και το κόστος της απώλειας θερμικής άνεσης για μια σειρά πιθανών χρονικών ακολουθιών λειτουργίας. Η ετήσια απόκριση του ελεγκτή συγκρίνεται με τα αποτελέσματα της ενεργειακής προσομοίωσης και επιτυγχάνεται μείωση της ενεργειακής κατανάλωσης. Επίσης, καταγράφονται επιπλέον συμπεράσματα όσον αφορά την αποδοτικότητα της χρήσης πολλαπλών νευρωνικών δικτύων στο σύστημα. Τέλος, θέτονται προτάσεις για περαιτέρω διερεύνηση, σχετικά με τη βελτιστοποίηση της μεθόδου που αναπτύχθηκε στο σύστημα ελέγχου.

Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή της εργασίας, Κωνσταντίνο Καλαϊτζάκη, για τις συμβουλές του και την κατανόηση που έδειξε στα προβλήματα που αντιμετώπισα μέχρι την ολοκλήρωση της παρούσας εργασίας. Επιπλέον, θα ήθελα να ευχαριστήσω τον δρ. Κωνσταντίνο Γομπάκη για τη σημαντική βοήθεια που μου παρείχε σε ένα μεγάλο μέρος της εργασίας. Ακόμη, ευχαριστώ τον καθηγητή Γιώργο Σταυρακάκη και την αναπληρώτρια καθηγήτρια του τμήματος Μηχανικών Περιβάλλοντος Διονυσία Κολοκοτσά για το χρόνο που μου αφιέρωσαν ως μέλη της επιτροπής. Τέλος, πάνω απ' όλα θα ήθελα να εκφράσω τη βαθιά μου ευγνωμοσύνη στους γονείς μου για ό,τι μου προσέφεραν απλόχερα σε όλη τη διάρκεια των σπουδών μου.

Περιεχόμενα

1	Εισαγωγή	1
2	Σχεδιασμός και ενεργειακή προσομοίωση κατοικίας	3
2.1	Γενικά	3
2.2	Περιβάλλον υλοποίησης	3
2.3	Μοντελοποίηση	4
2.4	Σχεδιασμός κατοικίας	6
2.5	Θερμική ζώνη	10
3	Νευρωνικά Δίκτυα	14
3.1	Τεχνητή Νοημοσύνη	14
3.2	Εισαγωγή στα Τεχνητά Νευρωνικά Δίκτυα	14
3.2.1	Βιολογικά Νευρωνικά Δίκτυα	14
3.2.2	Δομή και λειτουργία Τεχνητού Νευρώνα	15
3.2.3	Δομή Νευρωνικού Δικτύου	17
3.2.4	Τρόπος λειτουργίας Τεχνητών Νευρωνικών Δικτύων	19
3.2.5	Χαρακτηριστικά τεχνητών νευρωνικών δικτύων	20
3.3	Περιβάλλον υλοποίησης	21
3.4	Τα Τεχνητά Νευρωνικά Δίκτυα της εργασίας	22
3.4.1	Function Fitting Νευρωνικό Δίκτυο	22
3.4.2	Αναγνώριση συστήματος για την πρόβλεψη εσωτερικής θερμοκρασίας με fitnet	23
3.4.3	Αναγνώριση συστήματος για την πρόβλεψη ενεργειακής κατανάλωσης με fitnet	26
3.4.4	NARX Νευρωνικό Δίκτυο	29
3.4.5	Αναγνώριση συστήματος για την πρόβλεψη μελλοντικής ανθρώπινης παρουσίας στο χώρο με NARX	31
4	Προσομοίωση Συστήματος	37
4.1	Περιβάλλον υλοποίησης	37
4.2	Γενική ιδέα	38
4.3	Μοντέλο πρόβλεψης μελλοντικής παρουσίας κατοίκων στο χώρο	39
4.3.1	Μεθοδολογία	39
4.3.2	Ανάλυση	40
4.4	Μοντέλο ελέγχου	44
4.4.1	Μεθοδολογία	44
4.4.2	Ανάλυση	45
4.4.3	Κόστος Ενεργειακής Κατανάλωσης	52
4.4.4	Κόστος Απώλειας Θερμικής Άνεσης	54
4.5	Εναλλακτική πολιτική θέρμανσης / ψύξης	55
5	Αποτελέσματα	56
5.1	Αποτελέσματα ενεργειακής προσομοίωσης πριν τη χρήση του ελεγκτή	56
5.2	Αποτελέσματα των εκπαιδευμένων τεχνητών νευρωνικών δικτύων	60
5.2.1	Αποτελέσματα για την πρόβλεψη της εσωτερικής θερμοκρασίας τη χειμερινή περίοδο	60
5.2.2	Αποτελέσματα για την πρόβλεψη της εσωτερικής θερμοκρασίας τη θερινή περίοδο	62
5.2.3	Αποτελέσματα για την πρόβλεψη της ενεργειακής κατανάλωσης τη χειμερινή περίοδο	65

5.2.4	Αποτελέσματα για την πρόβλεψη της ενεργειακής κατανάλωσης τη θερινή περίοδο	68
5.2.5	Αποτελέσματα για την πρόβλεψη της μελλοντικής παρουσίας των κατοίκων στο χώρο	71
5.3	Αποδοτικότητα του συστήματος θέρμανσης/ψύξης	84
5.3.1	Αποδοτικότητα του μοντέλου πρόβλεψης παρουσίας	84
5.3.2	Αποδοτικότητα του μοντέλου του ελεγκτή	84
5.3.3	Αποδοτικότητα του συνολικού συστήματος	88
6	Συμπεράσματα και Μελλοντικές ενέργειες	90

Κεφάλαιο 1

Εισαγωγή

Στις μέρες μας, είναι πλέον δεδομένη η ανάγκη για εξοικονόμηση ενέργειας σε όλους τους τομείς, αφού η σπατάλη ενέργειας αποτελεί ένα τεράστιο περιβαλλοντικό και οικονομικό πλήγμα παγκοσμίως. Το 40% της παγκόσμιας κατανάλωσης ενέργειας οφείλεται στα κτίρια και ένα μεγάλο μέρος αυτής της ενέργειας χρησιμοποιείται για θερμική άνεση στο εσωτερικό των κτιρίων. Καθώς αυτού του είδους η ενεργειακή σπατάλη δεν είναι ένα καινούριο πρόβλημα, η εξοικονόμηση ενεργειακής κατανάλωσης χωρίς εκπτώσεις στην ποιότητα ζωής στο εσωτερικό του κτιρίου αποτελεί το ζητούμενο σχεδιασμού εδώ και πολλά χρόνια. Πιο συγκεκριμένα, το αντικείμενο ελέγχου της ρύθμισης της θερμοκρασίας ενός εσωτερικού χώρου με στόχο τη μείωση της ενεργειακής κατανάλωσης ενώ παράλληλα διατηρείται η θερμοκρασία, για κάποια χρονικά διαστήματα, κάποιες ώρες της ημέρας, σε κάποια επιτρεπτά όρια που διασφαλίζουν θερμική άνεση είναι μία ιδέα που εφαρμόζεται συνεχώς σε χώρους μερικής απασχόλησης π.χ. εγκαταστάσεις γραφείων, όπου το ωράριο απασχόλησης είναι συγκεκριμένο. Όταν η κατασκευή του συστήματος προορίζεται για κατοικία, χρειάζεται ένα σύστημα του οποίου οι κανόνες λειτουργίας βασίζονται πρωτίστως στον τρόπο ζωής των κατοίκων. Τα τελευταία χρόνια η ιδέα των "έξυπνων σπιτιών", της χρήσης "έξυπνων συστημάτων" σε κατοικίσιμους χώρους, είναι ιδιαίτερος διαδεδομένη και έχει αποτελέσει έναν νέο ξεχωριστό τομέα στον αυτοματισμό. Η έξυπνη λειτουργία του συστήματος έγκειται συνήθως στην ικανότητά του να προσαρμόζεται στις τρέχουσες συνθήκες του περιβάλλοντος, στα ιδιαίτερα χαρακτηριστικά της κατοικίας, και φυσικά στη συμπεριφορά των κατοίκων. Η διαφορά μεταξύ ενός παραδοσιακού αυτόματου (ή προγραμματιζόμενου) συστήματος θέρμανσης ή ψύξης και ενός "έξυπνου" είναι ότι ενώ το πρώτο λειτουργεί σύμφωνα με ένα προκαθορισμένο και συνήθως μόνιμο πρόγραμμα, το τελευταίο συνήθως προσαρμόζει τη στρατηγική του ελέγχου στο περιβάλλον του χρήστη. Υπάρχουν πολλές προσεγγίσεις για την ανάπτυξη ενός έξυπνου συστήματος θέρμανσης, όπως ο "Neurothermostat"[20], το σύστημα PreHeat [26] κ.α. [11][12]. Τα νευρωνικά συστήματα αποτελούν έναν τομέα της τεχνητής νοημοσύνης που μπορεί να συντελέσει στη δημιουργία συστημάτων με ευφυή έλεγχο, καθώς παρέχουν τη δυνατότητα πρόβλεψης καταστάσεων, η οποία μπορεί να συμβάλλει στην προσαρμοστικότητα του συστήματος ελέγχου.

Στόχο της παρούσας εργασίας αποτέλεσε η κατασκευή ενός συστήματος ελέγχου για την ετήσια βελτιστοποίηση της ενεργειακής απόδοσης σε ένα μεμονωμένο χώρο μιας κατοικίας διατηρώντας παράλληλα τη θερμική άνεση των ανθρώπων που ζουν εκεί, ανάλογα με τη σπουδαιότητα που έχει για αυτούς η θερμική τους άνεση. Δίνεται η δυνατότητα στο διαχειριστή του συστήματος να αποφασίσει πόσο ελαστικά κρίνει τη θερμική του άνεση. Όσο πιο ελαστικός είναι με τη διατήρηση της θερμοκρασίας που έχει ορίσει στο θερμοστάτη, τόσο περισσότερο μειώνεται το ενεργειακό κόστος. Επιπλέον στοχος είναι η επίτευξη των παραπάνω με ένα σύστημα που λειτουργεί σύμφωνα με τα χαρακ-

τηριστικά και τις ανάγκες της συγκεκριμένης κατοικίας, μαθαίνοντας από τα χαρακτηριστικά αυτά και προσαρμόζοντας τη λειτουργία του σε νέες ανάγκες. Μελετάται κατά πόσο είναι εφικτή μία τέτοια βελτιστοποίηση όταν οι περισσότερες λειτουργίες του συστήματος ελέγχου στηρίζονται σε προβλέψεις εκπαιδευμένων νευρωνικών δικτύων και όχι σε πραγματικά δεδομένα.

Το σύστημα ελέγχου αφορά μόνο ένα χώρο της κατοικίας, αλλά η προσέγγιση είναι η ίδια και για τους υπόλοιπους χώρους. Η εύρεση του συνολικού κόστους στον ελεγκτή έγινε χρησιμοποιώντας ως βάση την προσέγγιση που περιγράφεται στο Neurothermostat [20].

Στο δεύτερο κεφάλαιο περιγράφεται ο σχεδιασμός και η ενεργειακή προσομοίωση μίας κατοικίας που δεν είναι πραγματική αλλά σχεδιάστηκε για τις ανάγκες της εργασίας. Χρησιμοποιούνται τα προγράμματα SketchUp, EnergyPlus και OpenStudio για τα οποία γίνεται μία σύντομη περιγραφή της λειτουργίας τους. Το τρίτο κεφάλαιο αφορά στα νευρωνικά δίκτυα. Παρέχονται πληροφορίες για τη θεωρητική υπόσταση, τη δομή και τον τρόπο λειτουργίας τους και περιγράφονται τα νευρωνικά δίκτυα που κατασκευάστηκαν στην πλατφόρμα της MATLAB για τις ανάγκες της εργασίας, όπως και ο τρόπος εκπαίδευσής τους. Το τέταρτο κεφάλαιο περιγράφει το σύστημα ελέγχου που κατασκευάστηκε στο Simulink, ανταλλάσσοντας πληροφορίες με τη MATLAB. Αφού γίνει μία περιγραφή του τρόπου με τον οποίο χρησιμοποιήθηκε το Simulink και η MATLAB, περιγράφεται η γενική ιδέα του συστήματος ελέγχου και η μεθοδολογία του και αναλύεται η δομή του και η διαδικασία που ακολουθείται στην προσομοίωσή του. Στο πέμπτο κεφάλαιο καταγράφονται τα αποτελέσματα όσων περιγράφονται στα προηγούμενα κεφάλαια. Τέλος, στο έκτο κεφάλαιο αναλύονται τα συμπεράσματα που προέκυψαν από τα αποτελέσματα των προσομοιώσεων και πιθανές μελλοντικές ενέργειες για την κατασκευή ενός πιο ολοκληρωμένου συστήματος ή για την ενίσχυσή του.

Κεφάλαιο 2

Σχεδιασμός και ενεργειακή προσομοίωση κατοικίας

2.1 Γενικά

Η μελέτη που υλοποιήθηκε στην παρούσα εργασία αφορά μία διώροφη κατοικία η οποία σχεδιάστηκε για τις ανάγκες της εργασίας και θεωρήθηκε ότι βρίσκεται στο Νομο Χανίων της Κρήτης. Αφού σχεδιάστηκε η τρισδιάστατη απεικόνισή της, έγινε η ενεργειακή μοντελοποίηση. Από εκεί λάβαμε όλα τα απαραίτητα δεδομένα όσον αφορά την ενεργειακή απόδοση της κατοικίας, κάποια από τα οποία χρησιμοποιήσαμε στη συνέχεια για τη βελτίωσή της. Ουσιαστικά, ο σχεδιασμός της κατοικίας και η ενεργειακή της προσομοίωση έγιναν προκειμένου να συλλέξουμε τα απαραίτητα δεδομένα για την εκπαίδευση των νευρωνικών δικτύων και τη μοντελοποίηση του ελεγκτή για το σύστημα θέρμανσης/ψύξης της κατοικίας, όπως θα δούμε παρακάτω.

2.2 Περιβάλλον υλοποίησης

Το τρισδιάστατο σχέδιο της κατοικίας έγινε στο πρόγραμμα Sketch Up και η ενεργειακή της προσομοίωση έγινε στα προγράμματα ενεργειακής ανάλυσης Open Studio και Energy Plus.

Το Energy Plus TM είναι ένα πρόγραμμα προσομοίωσης ενέργειας που χρησιμοποιούν μηχανικοί, αρχιτέκτονες και ερευνητές για να μοντελοποιούν τόσο την κατανάλωση ενέργειας - για θέρμανση, ψύξη, εξαερισμό και φωτισμό όσο και τη χρήση νερού σε κτίρια. Η χρήση του γίνεται μόνο σε λειτουργία κονσόλας (γι' αυτό και δεν είναι ιδιαίτερα εύχρηστο) και διαβάζει τις εισόδους και καταγράφει τις εξόδους σε αρχεία κειμένου. Έχει ένα πλήθος βοηθημάτων, συμπεριλαμβανομένου του IDF Editor, για τη δημιουργία αρχείων εισόδου χρησιμοποιώντας μια απλή διασύνδεση που μοιάζει με υπολογιστικό φύλλο, το EP-Launch για τη διαχείριση αρχείων εισόδου και εξόδου και την εκτέλεση των προσομοιώσεων και το EP-Compare για τη σύγκριση γραφικών των αποτελεσμάτων διαφορετικών προσομοιώσεων. Τα παραπάνω βοηθήματα θα χρησιμοποιηθούν και στην εργασία. [5]

Το SketchUp είναι λογισμικό σχεδίασης τρισδιάστατων μοντέλων, ιδιαίτερα φιλικό προς το χρήστη που παρέχει τη δυνατότητα δημιουργίας προσομοιώσεων κτιρίων με καθορισμό προσανατολισμού και διαστάσεων.

Το OpenStudio είναι ένα kit ανάπτυξης λογισμικού ανοιχτού κώδικα (SDK) με γραφικές διεπαφές που υποστηρίζει την ενεργειακή μοντελοποίηση των κτιρίων χρησιμοποιώντας το EnergyPlus. Στις γραφικές εφαρμογές περιλαμβάνονται η εφαρμογή OpenStudio, η οποία είναι μια πλήρως εξοπλισμένη γραφική διεπαφή για τα μοντέλα του OpenStudio (που περιλαμβάνει κατασκευαστικά στοιχεία, φορτία, χρονοδιαγράμματα, HVAC κ.α.) και το OpenStudio SketchUp Plug-in, το οποίο είναι μια επέκταση στο εργαλείο μοντελοποίησης SketchUp που επιτρέπει στους χρήστες να δημιουργούν γρήγορα τη γεωμετρία που απαιτείται για το EnergyPlus [5].

Ουσιαστικά, το βασικό εργαλείο ανάλυσης είναι το Energy Plus, αφού τόσο το OpenStudio όσο και το Sketchup, μέσω του OpenStudio SketchUp Plug-in, παρέχουν απλώς ένα φιλικότερο περιβάλλον χρήσης για το ισχυρότατο μεν, σχετικά δύσχρηστο δε EnergyPlus.

2.3 Μοντελοποίηση

Γενικά, οι απαραίτητες ενέργειες για την απόκριση ενεργειακών δεδομένων ενός κτισματος είναι [22] [5] :

- Ο προσδιορισμός της τοποθεσίας του κτίσματος και των εξωτερικών της παραγόντων, όπως το κλίμα της περιοχής και ο προσανατολισμός του κτιρίου
- Ο προσδιορισμός της γεωμετρίας και της φυσικής δομής του κτίσματος. Η καταγραφή διαστάσεων και προσανατολισμού κάθε επιφάνειας, ο προσδιορισμός των κατασκευαστικών υλικών με τα θερμικά τους χαρακτηριστικά
- Ο διαχωρισμός του κτίσματος σε θερμικές ζώνες
- Η περιγραφή των λειτουργιών και της χρήσης κάθε θερμικής ζώνης από τους κατοίκους. Ο προσδιορισμός των χρονοδιαγραμμάτων λειτουργίας και των εσωτερικών φορτίων
- Η εισαγωγή των συνθηκών σχεδιασμού, π.χ. θερμοστατικές ρυθμίσεις
- Η εφαρμογή μοντέλων συστημάτων κλιματισμού


Λόγω του ότι η ενεργειακή προσομοίωση της κατοικίας δεν αποτελεί ένα από τα βασικά αντικείμενα της μελέτης της εργασίας αλλά το μέσο για την υλοποίησή της, καθώς και λόγω του ότι για τη μελέτη ασχοληθήκαμε μόνο με ένα χώρο της κατοικίας, χρησιμοποιήθηκε ως πρότυπο ένα μοντέλο και σε αρκετές παραμέτρους του μοντέλου μας εφαρμόστηκαν οι τιμές του προτύπου. Επιπλέον, το μοντέλο που κατασκευάζεται εδώ είναι αυτό πάνω στο οποίο βασίστηκε όλη η προσπάθεια βελτιστοποίησης της ενεργειακής κατανάλωσης, επομένως δε χρειάζεται να αναφερθούν όλες οι παράμετροι καθώς δεν αφορά τόσο τη συγκεκριμένη μελέτη πώς προέκυψαν τα ενεργειακά δεδομένα, αλλά τα ίδια τα ενεργειακά δεδομένα, τα οποία τελικά θα συγκριθούν με τα δεδομένα που προκύπτουν μετά τη χρήση του ελεγκτή.

Ο προσδιορισμός της τοποθεσίας έγινε στην εφαρμογή του OpenStudio όπου εισάχθηκε ένα αρχείο με κλιματικά δεδομένα που συλλέχθηκαν στη Σούδα Χανίων που αφορούν ένα τυπικό κλιματικό έτος και συγκεκριμένες ημέρες με ακραία κλιματικά δεδομένα για τον υπολογισμό των μέγιστων φορτίων που χρησιμοποιούνται στο σχεδιασμό των διαφόρων συστημάτων HVAC. Επίσης, περιέχει πληροφορίες

για παραμέτρους όπως ωριαία θερμοκρασία, ωριαία υγρασία, ωριαία ταχύτητα και κατεύθυνση ανέμου, ωριαία ατμοσφαιρική πίεση και ωριαία ηλιακή ακτινοβολία. Το αρχείο καιρού είναι το ίδιο που χρησιμοποιήθηκε στο πρότυπο μοντέλο. Τα βασικά χαρακτηριστικά της περιοχής και η εξωτερική θερμοκρασία, όπως προκύπτει από το αρχείο καιρού και όπως μετρήθηκε για τη διάρκεια ενός έτους, φαίνονται παρακάτω:

Location	Souda, Chania , Greece
Latitude [deg]	35,48
Longitude [deg]	24,12
Elevation [m above sea]	151
Hours Simulated [hrs]	8760

Σχήμα 2.1: Χαρακτηριστικά του μετεωρολογικού σταθμού της Σούδας



Σχήμα 2.2: Ετήσιο χρονοδιάγραμμα της θερμοκρασίας του περιβάλλοντος στην περιοχή της κατοικίας


Ο προσδιορισμός του προσανατολισμού της κατοικίας και της γεωμετρίας και το τρισδιάστατο σχέδιο έγινε στο SketchUp. Τα δομικά υλικά κάθε επιφάνειας (εξωτερικοί και εσωτερικοί τοίχοι, πόρτες, παράθυρα, μπαλκονόπορτες, πατώματα κλπ) είναι τα ίδια που χρησιμοποιήθηκαν στο πρότυπο Open Studio Model (osm). Η κατοικία, αφού σχεδιάστηκε, χωρίστηκε σε θερμικές ζώνες, σύμφωνα με το μέγεθος και τον τρόπο χρήσης κάθε χώρου, και για κάθε θερμική ζώνη καθορίστηκαν τα χρονοδιαγράμματα λειτουργίας και μόνο τα απαραίτητα εσωτερικά φορτία.

2.4 Σχεδιασμός κατοικίας


Ξεκινώντας την γεωμετρική κατασκευή του μοντέλου στο SketchUp, αφού έχει πραγματοποιηθεί η διεπαφή του με το OpenStudio, αντί να δημιουργήσουμε ένα νέο SketchUp αρχείο, δημιουργούμε μέσω της επέκτασης ένα μοντέλο του OpenStudio (osm), έτσι ώστε όταν σχεδιάζεται η γεωμετρία στο SketchUp να μεταφράζει τα δεδομένα σε μεταβλητές εισόδου στην εφαρμογή του OpenStudio και στο EnergyPlus.

Η κατοικία είναι συνολικά $156m^2$, χωρίς τα μπαλκόνια και τους εξωτερικούς χώρους. Αποτελείται από το ισόγειο και τον πρώτο όροφο. Το ισόγειο αποτελείται από έναν ενιαίο κεντρικό χώρο για το καθιστικό και την τραπεζαρία, στον οποίο βρίσκεται και η σκάλα που επικοινωνεί με τον άνω όροφο, το δωμάτιο της κουζίνας, ένα δωμάτιο - γραφείο και ένα μικρό WC. Ο πρώτος όροφος αποτελείται από έναν διάδρομο ο οποίος επικοινωνεί με όλα τα δωμάτια και με τον κάτω όροφο μέσω του ανοίγματος της σκάλας, ένα μεγάλο υπνοδωμάτιο με δικό του ξεχωριστό μπάνιο, δύο μικρότερα δωμάτια και ένα μπάνιο ακόμη.


Για την καλύτερη αξιοποίηση της ηλιακής ακτινοβολίας, τα ανοίγματα (παράθυρα και μπαλκονόπορτες) κατασκευάστηκαν εκεί που ικανοποιούνται περισσότερο οι απαιτήσεις των συστημάτων άμεσου κέρδους. Συγκεκριμένα, τοποθετήθηκαν πολλά και μεγάλα ανοίγματα στο Νότο, ενώ στη Δύση, στην Ανατολή και κυρίως στο Βορρά ήταν πιο περιορισμένη η κατασκευή τους, σε μέγεθος και σε πλήθος.




Σχήμα 2.3: Νότια πλευρά της κατοικίας



Σχήμα 2.4: Ανατολική πλευρά της κατοικίας



Σχήμα 2.5: Βόρεια πλευρά της κατοικίας



Σχήμα 2.6: Δυτική πλευρά της κατοικίας





Figure 2.7: Κάτοψη ισογείου

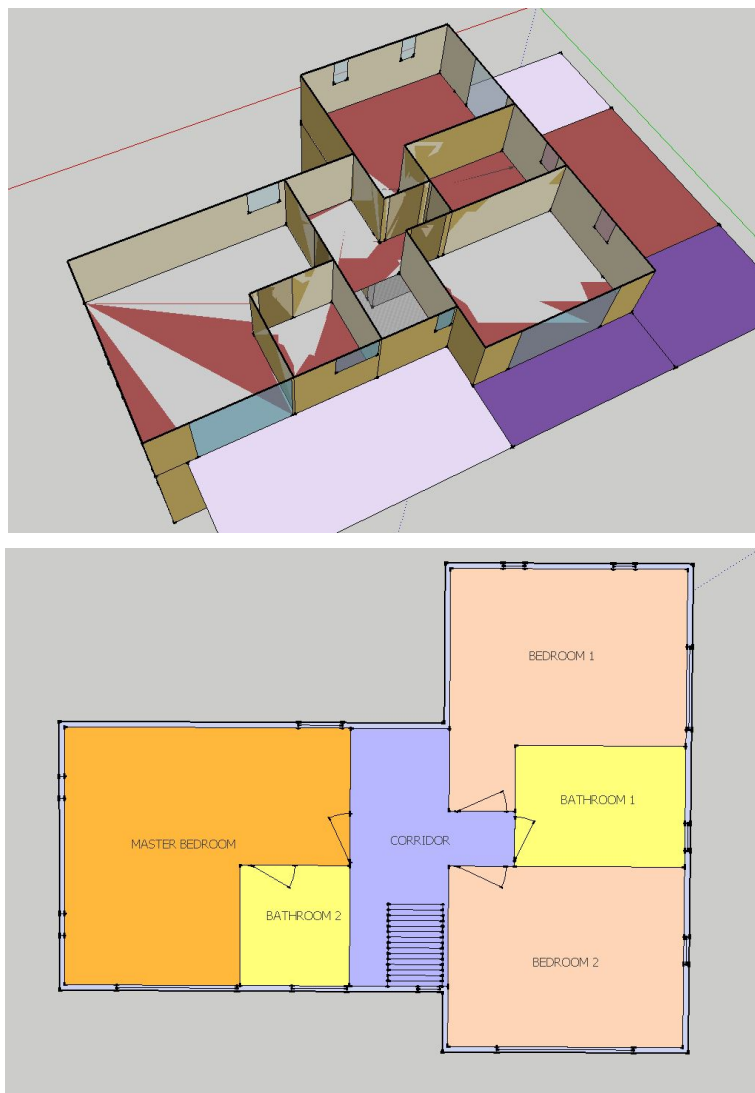




Figure 2.8: Κάτοψη πρώτου ορόφου

Η μελέτη της εργασίας αφορά μόνο τον ενιαίο χώρο καθιστικού και τραπεζαρίας, επομένως παρόλο που ο σχεδιασμός και η ενεργειακή προσομοίωση έγινε για ολόκληρη την κατοικία, θα αναφερθούμε εκτενέστερα μόνο στο χώρο που μας ενδιαφέρει. Ο χώρος του καθιστικού λοιπόν, είναι $51,39m^2$, βρίσκεται στο ισόγειο και επικοινωνεί με όλους τους υπόλοιπους χώρους του ισογείου (με την κουζίνα επικοινωνεί χωρίς φυσικό εμπόδιο) και από το άνοιγμα της σκαλας επικοινωνεί και με τον πάνω όροφο.



Σχήμα 2.9: Χώρος καθιστικού - τραπεζαρίας εξωτερικά



Σχήμα 2.10: Χώρος καθιστικού - τραπεζαρίας εσωτερικά

2.5 Θερμική ζώνη

Στις κατόψεις των δύο ορόφων στις εικόνες 2.7 και 2.8 βλέπουμε τα διαφορετικά χρώματα που δείχνουν το διαχωρισμό σε θερμικές ζώνες. Η θερμική ζώνη στην οποία βρίσκεται ο χώρος του καθιστικού (Living Room), αφορά αποκλειστικά αυτόν το χώρο καθώς είναι ο μεγαλύτερος σε m^2 της κατοικίας και έχει διαφορετικό τρόπο χρήσης από όλους τους υπόλοιπους.

Η θερμική συμπεριφορά της ζώνης καθορίζεται από χρονοδιάγραμματα διάφορων παραμέτρων όπως την κίνηση των κατοίκων στο χώρο, τη λειτουργία των ηλεκτρικών συσκευών και τη λειτουργία του HVAC συστήματος, αλλά και από την επίδραση που της ασκεί το εξωτερικό περιβάλλον, όπως και την αλληλεπίδραση με άλλες ζώνες. Τα χρονοδιαγράμματα που δείχνουν την κίνηση των κατοίκων και τη

δραστηριότητα, Presence (0-1, fractional) και Activity (70W/person - 100W/person), κατασκευάστηκαν με την εξής λογική: Θεωρήθηκε ότι η κατοικία ανήκει σε μία οικογένεια και συγκεκριμένα ένα ζευγάρι με δύο ανήλικα παιδιά. Προφανώς ο χώρος χρησιμοποιείται έστω και ένα άτομο να βρίσκεται εκεί. Θεωρήθηκε ότι τα πρωινά των καθημερινών όλοι απουσιάζουν. Εφόσον στο χώρο βρίσκεται το σαλόνι -

καθιστικό και η τραπεζαρία, θεωρήθηκε ότι οι κάτοικοι σε καθημερινή βάση τρώνε εκεί τα μεσημέρια σχεδόν την ίδια ώρα και τις βραδινές ώρες τουλάχιστον ένα άτομο βρίσκεται στο σαλόνι. Τα Σάββατα και τις Κυριακές ο χώρος συνηθίζεται να χρησιμοποιείται και τα πρωινά. Το ετήσιο χρονοδιάγραμμα παρουσίας/απουσίας των κατοίκων στο χώρο παίζει σημαντικό ρόλο στη μελέτη μας, οπότε προκειμένου να είναι ρεαλιστικό, ακολουθεί μεν ένα σχετικά συγκεκριμένο εβδομαδιαίο μοτίβο, όμως υπάρχουν καθημερινά χρονικές αποκλίσεις, περισσότερες ώρες παρουσίας ή περισσότερες ώρες απουσίας, καθώς δε θα μπορούσε να ήταν απόλυτα ακριβές το καθημερινό πρόγραμμα. Το πρόγραμμα εισάχθηκε στο idf αρχείο της κατοικίας μας ως ένα txt αρχείο.

[0001] Schedule:Constant				
[0003] Schedule:File				
Surface Construction Elements				
Field Description:				
ID: A1				
Enter a alphanumeric value				
This field is required.				
Field	Units	Obj1	Obj2	Obj3
Name		Presence	Operation	Activ
Schedule Type Limits Name		Fractional	OnOff 1	ActivityLevel
File Name		C:\Users\alex_\Des	C:\Users\alex_\Des	C:\Users\alex_\Des
Column Number		1	1	1
Rows to Skip at Top		0	0	0
Number of Hours of Data		8760	8760	8760
Column Separator		Comma	Comma	Comma
Interpolate to Timestep		No	No	No
Minutes per Item		10	10	10

Σχήμα 2.11: Εισαγωγή Idf Schedule File

Για τα εσωτερικά φορτία που απορρέουν από την ανθρώπινη δραστηριότητα και τον ηλεκτρικό εξοπλισμό του χώρου έγιναν οι εξής ρυθμίσεις:

Field	Units	Obj1
Name		People 5
Zone or ZoneList Name		Living Room T
Number of People Schedule Name		NoP Living Room
Number of People Calculation Method		People
Number of People		4
People per Zone Floor Area	person/m2	
Zone Floor Area per Person	m2/person	
Fraction Radiant		0,3
Sensible Heat Fraction		
Activity Level Schedule Name		Activity Living Room

Σχήμα 2.12: (α) Παράμετροι φορτίων

Field	Units	Obj1
Name		Electric Equipment 5
Zone or ZoneList Name		Living Room T
Schedule Name		Electric Equipment LR
Design Level Calculation Method		EquipmentLevel
Design Level	W	140
Watts per Zone Floor Area	W/m2	
Watts per Person	W/person	
Fraction Latent		0,3
Fraction Radiant		0,7

Σχήμα 2.13: (β) Παράμετροι φορτίων

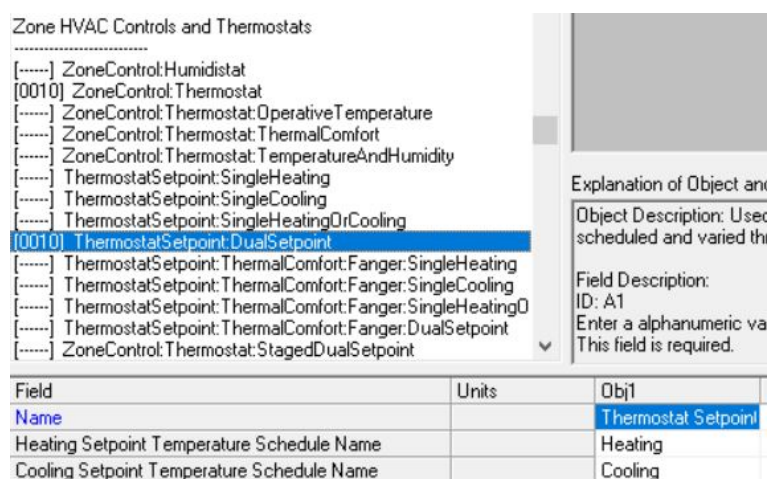
Ο εξοπλισμός του φωτισμού αγνοήθηκε.

Πολύ σημαντικός παράγοντας ρύθμισης της κατανάλωσης ενέργειας στα κτίρια είναι η ροή αέρα

μεταξύ των θερμικών ζωνών ή/και μεταξύ του εσωτερικού και εξωτερικού περιβάλλοντος.

Η διήθηση (infiltration είναι η ακούσια ροή αέρα που προκαλείται από το άνοιγμα και το κλείσιμο των θυρών, από ρωγμές ή σχισμές γύρω από τα πλαίσια των θυρών και σε πολύ μικρές ποσότητες ακόμη και μέσω των δομικών στοιχείων του κτιρίου. Στην περίπτωση μας, ρυθμίστηκε για όλες τις ζώνες να είναι 1

Το έτος έχει διαχωριστεί σε χειμερινή και θερινή περίοδο. Η χειμερινή περίοδος αφορά τις ημέρες του έτους από 1 Ιανουαρίου μέχρι 30 Απριλίου και από 1 Νοεμβρίου μέχρι 31 Δεκεμβρίου, ενώ η θερινή αφορά τις ημέρες από 1 Μαΐου μέχρι 31 Οκτωβρίου. Θεωρήσαμε ότι οι κάτοικοι επέλεξαν για τη χειμερινή περίοδο τους 22°C ως την κατάλληλη εσωτερική θερμοκρασία και για τη θερινή περίοδο τους 26°C. Επομένως, οι θερμοστάτες για οποιοδήποτε HVAC σύστημα ρυθμίστηκαν αναλόγως:



Σχήμα 2.14: Τιμές στους θερμοστάτες

Το χρονοδιάγραμμα Heating της εικόνας είναι για όλη τη χειμερινή περίοδο σταθερό στην τιμή 22 και το χρονοδιάγραμμα Cooling είναι για όλη τη χειμερινή περίοδο σταθερό στην τιμή 26.

Για την κάλυψη των θερμαντικών και ψυκτικών φορτίων, προκειμένου να γίνει η προσομοίωση χρειάζεται να υπολογιστούν οι ενεργειακές ανάγκες ολόκληρης της κατοικίας. Στην περίπτωση μας όμως θέλουμε να αποκτήσουμε δεδομένα για την απόδοση της κατοικίας χωρίς να διαμορφώσουμε ένα πλήρες HVAC σύστημα. Χρησιμοποιήσαμε για όλες τις θερμικές ζώνες, με εξαίρεση τη ζώνη του καθιστικού, το Ideal Loads Air System (Σύστημα Αέρα Ιδανικών Φορτίων), το οποίο εκτελεί τον υπολογισμό των αναγκαίων ενεργειακών αναγκών για την κάλυψη των θερμαντικών και ψυκτικών φορτίων χωρίς να περιορίζεται από την εφαρμογή ενός συγκεκριμένου συστήματος κλιματισμού. Θεωρεί ότι υπάρχει απεριόριστη δυνατότητα παροχής αέρα στις επιθυμητές συνθήκες σχεδιασμού της κατοικίας, που θα καλύπτουν τις ανάγκες.

Zone HVAC Forced Air Units

100081 ZoneHVAC:IdealLoadsAirSystem

ZoneHVAC:FourPipeFanCoil

ZoneHVAC:WindowAirConditioner

required for the ideal system and some controls, some equipment configurations, and the ideal loads system component. This component can be thought of as an ideal unit that mixes zone air with the specified amount of outdoor air and then adds or removes heat and moisture at 100% efficiency in order to meet the specified controls. Energy use is reported as DistrictHeating and DistrictCooling.

Field	Units	Obj1	Obj2	Obj3	Obj4	Obj5	Obj6	Obj7	Obj8
Name		Bathroom 1 Ideal Loads Air S	Bathroom 2 Ideal Loads	Bedroom 1 Ideal Loads	Bedroom 2 Ideal Loads	Diadromos Ideal Load	Kitchen Ideal Loads Su	Office Ideal Loads S	W/C Ideal Loads Supply Ir
Availability Schedule Name		Bathroom 1 Ideal Loads Sup	Bathroom 2 Ideal Loads	Bedroom 1 Ideal Loads	Bedroom 2 Ideal Loads	Diadromos Ideal Load	Kitchen Ideal Loads Su	Office Ideal Loads S	W/C Ideal Loads Supply Ir
Zone Supply Air Node Name									
Zone Exhaust Air Node Name									
Maximum Heating Supply Air Temperature	C	50	50	50	50	50	50	50	50
Minimum Cooling Supply Air Temperature	C	13	13	13	13	13	13	13	13
Maximum Heating Supply Air Humidity Ratio	kgWater/kgDryA	0.0156	0.0156	0.0156	0.0156	0.0156	0.0156	0.0156	0.0156
Minimum Cooling Supply Air Humidity Ratio	kgWater/kgDryA	0.0077	0.0077	0.0077	0.0077	0.0077	0.0077	0.0077	0.0077
Heating Limit		NoLimit	NoLimit	NoLimit	NoLimit	NoLimit	NoLimit	NoLimit	NoLimit
Maximum Heating Air Flow Rate	m3/s								
Maximum Sensible Heating Capacity	W								
Cooling Limit		NoLimit	NoLimit	NoLimit	NoLimit	NoLimit	NoLimit	NoLimit	NoLimit
Maximum Cooling Air Flow Rate	m3/s								
Maximum Total Cooling Capacity	W								
Heating Availability Schedule Name									
Cooling Availability Schedule Name									
Dehumidification Control Type		ConstantSensibleHeatRatio	ConstantSensibleHeatR	ConstantSensibleHeatF	ConstantSensibleHeatR	ConstantSensibleHea	ConstantSensibleHeatF	ConstantSensibleHe	ConstantSensibleHeatRat
Cooling Sensible Heat Ratio	dimensionless	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7
Humidification Control Type		None	None	None	None	None	None	None	None
Design Specification Outdoor Air Object Name									
Outdoor Air Inlet Node Name									
Demand Controlled Ventilation Type		None	None	None	None	None	None	None	None
Outdoor Air Economizer Type		NoEconomizer	NoEconomizer	NoEconomizer	NoEconomizer	NoEconomizer	NoEconomizer	NoEconomizer	NoEconomizer
Heat Recovery Type		None	None	None	None	None	None	None	None
Sensible Heat Recovery Effectiveness	dimensionless	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.7
Latent Heat Recovery Effectiveness	dimensionless	0.65	0.65	0.65	0.65	0.65	0.65	0.65	0.65
Design Specification ZoneHVAC Sizing Object Name									

Σχήμα 2.15: Ideal Loads Air System

Ο κεντρικός αέρας του συστήματος τροφοδοτείται συνήθως σε μια ζώνη μέσω μιας τερματικής μονάδας (Air Terminal Unit), π.χ. έναν αγωγό. Στην περίπτωση της θερμικής ζώνης του καθιστικού είναι επιθυμητό να τροφοδοτείται κεντρικός αέρας απευθείας στη ζώνη χωρίς έλεγχο. Ορίστηκε λοιπόν η τερματική μονάδα για τη συγκεκριμένη ζώνη ως εξής:

Zone HVAC Air Loop Terminal Units

100021 AirTerminal:SingleDuct:Uncontrolled

AirTerminal:SingleDuct:ConstantVolume:Reheat

AirTerminal:SingleDuct:VAV:NoReheat

AirTerminal:SingleDuct:VAV:Reheat

AirTerminal:SingleDuct:VAV:Reheat:VariableSpeedFan

Object Description: Central air system on/off schedule.

Field Description: ID: A1 Enter a alphanumeric value This field is required.

Field	Units	Obj1
Name		Air Terminal Single Duct Uncontrol
Availability Schedule Name		Operation
Zone Supply Air Node Name		Node 15
Maximum Air Flow Rate	m3/s	autosize

Σχήμα 2.16: Air Terminal: Single Duct: Uncontrolled

Έτσι καταφέραμε η ζώνη ελέγχου να δέχεται αέρα τροφοδοσίας απευθείας από το κεντρικό σύστημα, με τη θερμοκρασία του αέρα τροφοδοσίας να έχει ρυθμιστεί ώστε να ελέγχει τη θερμοκρασία στη ζώνη ελέγχου. Το χρονοδιάγραμμα Operation, δηλώνει τη λειτουργία του συστήματος (on/off). Για τη συγκεκριμένη περίπτωση είναι ίδιο με το χρονοδιάγραμμα παρουσίας των κατοίκων στο χώρο, δηλαδή θεωρούμε ότι όσο βρίσκεται κάποιος στο χώρο το σύστημα λειτουργεί και η θερμοκρασία ρυθμίζεται αναλόγα με τις θερμοκρασίες "άνεσης" που έχουν οριστεί.

Τα δεδομένα της προσομοίωσης του ενεργειακού μοντέλου που κατασκευάσαμε χρησιμοποιούνται σε όλες τις επόμενες ενέργειες της μελέτης και στο τέλος αποτελούν και τα δεδομένα σύγκρισης για να διαπιστώσουμε τα αποτελέσματα του συστήματος θέρμανσης/ψύξης που κατασκευάζεται παρακάτω.

Κεφάλαιο 3

Νευρωνικά Δίκτυα

3.1 Τεχνητή Νοημοσύνη


Ο όρος τεχνητή νοημοσύνη αναφέρεται στον κλάδο της πληροφορικής ο οποίος ασχολείται με τη σχεδίαση και την υλοποίηση υπολογιστικών συστημάτων που μιμούνται στοιχεία της ανθρώπινης συμπεριφοράς τα οποία υπονοούν έστω και στοιχειώδη ευφυΐα: μάθηση, προσαρμοστικότητα, εξαγωγή συμπερασμάτων, κατανόηση από συμφραζόμενα, επίλυση προβλημάτων κλπ. Σήμερα αποτελεί ένα από τα πλέον «μαθηματικοποιημένα» και ταχέως εξελισσόμενα πεδία της πληροφορικής [32]. Η τεχνητή νοημοσύνη χωρίζεται σε δύο βασικές κατηγορίες: τη συμβατική, η οποία εμπλέκει μεθόδους μηχανικής μάθησης (machine learning), που χαρακτηρίζονται από αυστηρούς μαθηματικούς αλγόριθμους και στατιστικές μεθόδους ανάλυσης, και την υπολογιστική, που βασίζεται στη μάθηση μέσω επαναληπτικών διαδικασιών (ρύθμιση παραμέτρων). Στην υπολογιστική τεχνητή νοημοσύνη, που στην παρούσα εργασία μας αφορά, η μάθηση βασίζεται σε εμπειρικά δεδομένα και σε μη-συμβολικές μεθόδους [32]. Μια πολύ σημαντική κατηγορία της υπολογιστικής τεχνητής νοημοσύνης αποτελούν τα τεχνητά νευρωνικά δίκτυα, τα οποία μελετήθηκαν και εφαρμόστηκαν για το σκοπό της εργασίας.

3.2 Εισαγωγή στα Τεχνητά Νευρωνικά Δίκτυα

3.2.1 Βιολογικά Νευρωνικά Δίκτυα

Το νευρωνικό δίκτυο είναι ένα δίκτυο από απλούς υπολογιστικούς κόμβους (νευρώνες), διασυνδεδεμένους μεταξύ τους. Η ονομασία του προέρχεται από τα βιολογικά νευρωνικά δίκτυα. Ο νευρώνας, από τον οποίο απαρτίζεται το νευρωνικό δίκτυο, είναι ένας εξειδικευμένος τύπος κυττάρου, που αποτελεί τη βασική μονάδα των συστημάτων επεξεργασίας πληροφοριών που απαρτίζουν το νευρικό σύστημα του ανθρώπου. Ο εγκέφαλος ενός νεογέννητου ανθρώπου αποτελείται από τουλάχιστον 100 δισεκατομμύρια νευρώνες καθε ένας από τους οποίους συνδέεται με τουλάχιστον άλλους 1000 νευρώνες. Εκτιμάται ότι ο μέσος ανθρώπινος εγκέφαλος αποτελείται από 10^9 νευρώνες που συνδέονται μεταξύ τους. Ένας βιολογικός νευρώνας έχει την ικανότητα να αντιδρά σε διάφορα εξωτερικά ερεθίσματα και η αντίδραση αυτή έχει ως συνέπεια την παραγωγή παλμών σύντομης διάρκειας. Αυτοί οι παλμοί είναι οι φορείς πληροφορίας οι οποίοι ταξιδεύουν στους νευρώνες. Σε μια απλοποιημένη μορφή, ο νευρώνας αποτελείται από ένα κυτταρικό σώμα που περιλαμβάνει τον πυρήνα του, τους δενδρίτες που είναι τα σημεία εισόδου ηλεκτρικών σημάτων που προέρχονται από εξωτερικά ερεθίσματα ή από τις εξόδους άλλων νευρώνων, και τους άξονες που είναι η έξοδος των ηλεκτρικών σημάτων των νευρώνων. Τα σημεία σύνδεσης των

νευρώνων ονομάζονται συνάψεις. Ο νευρώνας στέλνει αιχμές της ηλεκτρικής δραστηριότητας μέσω του άξονα, που χωρίζεται σε χιλιάδες κλάδους. Στο τέλος κάθε κλάδου, μετατρέπεται η δραστηριότητα από τον άξονα σε ηλεκτρικά φαινόμενα που αναστέλλουν ή διεγείρουν τη δραστηριότητα στους συνδεδεμένους νευρώνες. Όταν ένας νευρώνας λαμβάνει διέγερση που είναι αρκετά μεγάλη σε σύγκριση με την ανασταλτική εισόδο του, στέλνει μια ακίδα ηλεκτρικής δραστηριότητας κάτω από τον άξονά του. Η εκμάθηση γίνεται με την αλλαγή της αποτελεσματικότητας των συνάψεων έτσι ώστε να αλλάζει η επίδραση ενός νευρώνα σε άλλο (συναπτικά βάρη).[33]



Σχήμα 3.1: Βιολογικό νευρωνικό δίκτυο

3.2.2 Δομή και λειτουργία Τεχνητού Νευρώνα


Το έργο στο επιστημονικό πεδίο των τεχνητών νευρωνικών δικτύων (ΤΝΔ) βασίστηκε στο γεγονός ότι ο ανθρώπινος εγκέφαλος εκτελεί τους υπολογισμούς με τελείως διαφορετικό τρόπο από το συμβατικό υπολογιστή. Τα τεχνητά νευρωνικά δίκτυα είναι εμπνευσμένα από τα βιολογικά νευρωνικά δίκτυα αλλά αντί για ένα τμήμα νευρικού ιστού, πρόκειται για ένα αφηρημένο αλγοριθμικό κατασκευάσμα όπου στόχος είναι η επίλυση κάποιου υπολογιστικού προβλήματος. Αποτελούνται από διασυνδεδεμένα υπολογιστικά στοιχεία που έχουν την ικανότητα να ανταποκρίνονται σε ερεθίσματα που δέχονται στην εισόδο τους και να μαθαίνουν να προσαρμόζονται στο περιβάλλον τους. Έτσι λοιπόν, κάθε κόμβος, δηλαδή κάθε τεχνητός νευρώνας, δέχεται ένα σύνολο αριθμητικών εισόδων από διαφορετικές πηγές (είτε από άλλους νευρώνες, είτε από το περιβάλλον), επιτελεί υπολογισμούς με βάση αυτές τις εισόδους, αλλάζει την εσωτερική του κατάσταση (ενεργοποίηση) και παράγει μία έξοδο, συναρτήσει της εισόδου και της ενεργοποίησης. Η εν λόγω έξοδος είτε κατευθύνεται στο περιβάλλον, είτε τροφοδοτείται ως είσοδος σε άλλους νευρώνες του δικτύου. Το γράφημα που σχηματίζεται με την ένωση των εξόδων κάποιων νευρώνων με τις εισόδους άλλων νευρώνων, μεταβαλλόμενες από συναπτικά βάρη, είναι το νευρωνικό δίκτυο. Τα βάρη και οι συναρτήσεις που υπολογίζουν την ενεργοποίηση διαφοροποιούνται όσο το δίκτυο βρίσκεται στη διαδικασία "εκπαίδευσης".

Ουσιαστικά, τα ΤΝΔ είναι πολύ απλοποιημένα μοντέλα του κεντρικού νευρικού συστήματος του

ανθρώπου. Διατηρούν μόνο τα πολύ αδρά χαρακτηριστικά των λεπτομερών μοντέλων της νευρολογίας [8].

Ο αλγόριθμος για τη βασική λειτουργία ενός τεχνητού νευρώνα ονομάζεται **perceptron** και αναλύεται παρακάτω:

Ο νευρώνας χωρίζεται σε δύο μέρη: τον αθροιστή και τη συνάρτηση ενεργοποίησης. Δέχεται σήματα εισόδου x_1, x_2, \dots, x_n . Κάθε τέτοιο σήμα μεταβάλλεται από μία τιμή βάρους w_i (weight), ο ρόλος της οποίας είναι αντίστοιχος του ρόλου της σύναψης στο βιολογικό νευρώνα. Τα συναπτικά βάρη είναι θετικοί ή αρνητικοί πραγματικοί αριθμοί ανάλογα με το αν πρέπει να είναι επιταχυντική ή επιβραδυντική η λειτουργία της σύναψης. Μόλις τα σήματα εισόδου πολλαπλασιαστούν με τα αντίστοιχα βάρη τους, περνάνε σε έναν αθροιστή, όπου προσθέτονται παράγοντας την ποσότητα S . Το άθροισμα αυτό τροφοδοτείται ως όρισμα σε μία συνάρτηση ενεργοποίησης, ένα μετασχηματιστή που διαμορφώνει την τελική τιμή του σήματος εξόδου y περιορίζοντας το πλάτος της εξόδου του νευρώνα σε κάποια πεπερασμένη τιμή. Το είδος της συνάρτησης ενεργοποίησης διαφέρει ανάλογα με τη λειτουργία του δικτύου (βηματική συνάρτηση, συνάρτηση προσήμου, σιγμοειδής συνάρτηση κ.α.). Σε ένα νευρωνικό δίκτυο μπορεί να υπάρχουν νευρώνες διαφορετικού τύπου (δηλ. με διαφορετικές συναρτήσεις ενεργοποίησης).



Σχήμα 3.2: Τεχνητός Νευρώνας

Η τιμή εξόδου είναι μία για κάθε νευρώνα, δηλαδή ακόμα κι αν υπάρχουν παραπάνω από μία γραμμές-έξοδοι στο νευρώνα, θα έχουν όλες την ίδια τιμή. Επιπλέον, το μοντέλο του νευρώνα περιλαμβάνει μια πόλωση $b = x_0 w_0$, όπου x_0 μία σταθερή είσοδος με τιμή 1 και w_0 το συναπτικό βάρος της. Η πόλωση ανάλογα με το αν είναι αρνητική ή θετική, δηλαδή ανάλογα με το αν το συναπτικό βάρος είναι ενισχυτικό ή ανασταλτικό, έχει ως αποτέλεσμα την αύξηση ή τη μείωση της δικτυακής διέγερσης της συνάρτησης ενεργοποίησης. [31][34]

Επομένως, ένας νευρώνας k με εισόδους x_1, x_2, \dots, x_n , παράγει έξοδο

$$y_k = \varphi(u_k),$$

όπου


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

Ουσιαστικά, ο συνδυασμός των εισόδων κάθε νευρώνα διαμορφωμένος από τα βάρη και αθροισμένος με το δυναμικό της πόλωσης, θα περάσει στο υπόλοιπο δίκτυο και θα ληφθεί υπόψη των επόμενων νευρώνων μόνο αν το αποφασίσει η συνάρτηση ενεργοποίησης, δηλαδή αν το ενεργοποιήσει. Συνεπώς, η

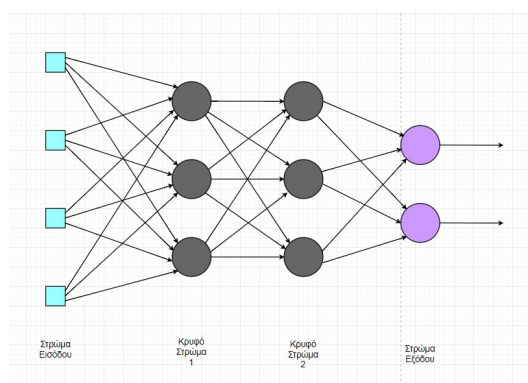
επιλογή της κατάλληλης συνάρτησης ενεργοποίησης έχει πολύ σημαντικό ρόλο στη σωστή λειτουργία του δικτύου.

3.2.3 Δομή Νευρωνικού Δικτύου

Τα νευρωνικά δίκτυα οργανώνονται σε στρώματα (επίπεδα), όπου κάθε στρώμα αποτελείται από διασυνδεδεμένους νευρώνες. Ανάλογα με τη λειτουργία που καλείται να επιτελέσει ένα ΤΝΔ αλλάζει και η διάταξη των νευρώνων του, όπως και ο αριθμός τους και ο τύπος τους. Υπάρχει ένα “στρώμα εισόδου”, το οποίο προωθεί τα σήματα στο υπόλοιπο δίκτυο. Στη συνέχεια, ενδεχομένως να υπάρχουν “κρυμμένοι” υπολογιστικοί νευρώνες, που αποτελούν ένα ή και περισσότερα “κρυμμένα στρώματα” και τέλος, υπάρχει το “στρώμα εξόδου”, το οποίο αποτελείται από τους υπολογιστικούς νευρώνες που παράγουν την αποκριση του δικτύου. Οι νευρώνες εισόδου απλά μεταφέρουν το σήμα χωρίς να κάνουν καμία επεξεργασία.[34]



Σχήμα 3.3: Δίκτυο 1-επιπέδου



Σχήμα 3.4: Δίκτυο πρόσθιας τροφοδότησης 3-επιπέδων

Συνάρτησεις ενεργοποίησης και ο ρόλος τους

Η συνάρτηση ενεργοποίησης χρησιμοποιείται ως το όργανο λήψης αποφάσεων στην έξοδο ενός νευρώνα. Ο νευρώνας μαθαίνει γραμμικά ή μη γραμμικά όρια απόφασης με βάση τη λειτουργία ενεργ-

γοποίησης. Έχει επίσης μια ομαλοποιητική επίδραση στην έξοδο νευρώνων, η οποία εμποδίζει την έξοδο των νευρώνων μετά από αρκετές στρώσεις να γίνουν πολύ μεγάλες.

Ο πιο απλός τρόπος για να φανεί η λειτουργία μιας τέτοιας συνάρτησης είναι το παράδειγμα της βηματικής συνάρτησης. Σε ένα νευρώνα που έχει **βηματική συνάρτηση ενεργοποίησης**, αν η τιμή του y_k είναι μεγαλύτερη από μια καθορισμένη τιμή κατωφλίου, τότε θεωρείται ενεργοποιημένη, διαφορετικά δεν ενεργοποιείται. Στην πράξη, η δυαδική ταξινόμηση που κάνει η βηματική συνάρτηση δεν είναι αρκετή για τα περισσότερα νευρωνικά δίκτυα, καθώς είναι πολύ πιθανό να ενεργοποιηθεί πάνω από ένας νευρώνας.

Μία **γραμμική συνάρτηση ενεργοποίησης**, που είναι αναλογική ως προς την είσοδο και μπορεί να δείξει το ποσοστό ενεργοποίησης, είναι σε θέση να καθορίσει τον ένα νευρώνα που θα ενεργοποιηθεί. Είναι πολύ σύνηθες, ειδικά στους νευρώνες εξόδου να χρησιμοποιείται η γραμμική συνάρτηση. Παρολ' αυτά κάποιες φορές η γραμμικότητα δε βοηθάει. Παραδείγματος χάρη, στην περίπτωση ενός δικτύου με κρυμμένα στρώματα, αν κάθε στρώμα αποτελείται από νευρώνες με γραμμικές συναρτήσεις ενεργοποίησης. Η ενεργοποίηση ενός επιπέδου δίνεται ως είσοδος στο επόμενο στρώμα κι εκεί υπολογίζεται το άθροισμα u_k και το ενεργοποιεί βασισμένο σε μια άλλη συνάρτηση ενεργοποίησης, οπότε τελικά η συνάρτηση του στρώματος εξόδου θα είναι απλά μία γραμμική συνάρτηση του πρώτου στρώματος. [32][29]

Μια μη-γραμμική συνάρτηση ενεργοποίησης που χρησιμοποιείται ευρέως στα νευρωνικά δίκτυα είναι η **σιγμοειδής συνάρτηση**. Προσφέρει τα θετικά της μη γραμμικότητας, ενώ παράλληλα προσφέρει αναλογική ενεργοποίηση, όπως και η γραμμική. Επιπλέον, έχει την τάση να φέρει τις ενεργοποιήσεις στις δύο άκρες της καμπύλης, κάνοντας έτσι σαφείς διακρίσεις στην πρόβλεψη. Επιπλέον, οι εξοδοί της περιορίζονται σε ένα εύρος (0,1), σε αντίθεση με τη γραμμική συνάρτηση που δεν έχει οριακές τιμές. [32][29] Οι συναρτήσεις ενεργοποίησης μπορεί να είναι κι άλλες, όμως θα περιοριστούμε σε αυτές, καθώς αυτές είναι οι τρεις πιο ευρέως χρησιμοποιούμενες.


Κανονικοποίηση

Κάτι πολύ σύνηθες στα ΤΝΔ είναι η κανονικοποίηση των εισόδων. Είναι μερικά δίκτυα στα οποία αυτό είναι απαραίτητο, άλλα στα οποία είναι προαιρετικό και βελτιώνεται σημαντικά η εκπαίδευση και τα αποτελέσματα και άλλα στα οποία θέλει προσοχή γιατί απορρίπτει κάποιες από τις πληροφορίες κατά τη διάρκεια της εκπαίδευσης. Ένας βασικός λόγος για να χρησιμοποιηθεί είναι για να βρίσκονται όλα τα δεδομένα σε ένα συγκρίσιμο εύρος. Αν η μία είσοδος ενός δικτύου έχει εύρος [0,1] και μία άλλη [500, 1000], τότε σε ένα νευρώνα, η πρώτη είσοδος έχει πολύ μικρή επιρροή στην τιμή της εξόδου σε σχέση με τη δεύτερη. Με την ανακατανομή των εισόδων, η μεταβλητότητά τους αντανακλά τη σημασία τους. Το ίδιο ισχύει και για τα δίκτυα που έχουν πάνω από μία εξόδους. Επιπλέον, η κανονικοποίηση των εισόδων λύνει το πρόβλημα της εξάρτησης της κλίμακας από τα αρχικά βάρη. Η κανονικοποίηση των στόχων-εξόδων είναι απαραίτητη όταν η συνάρτηση ενεργοποίησης έχει ένα συγκεκριμένο εύρος, π.χ. ανήκει στην κλίμακα [0,1], αφού όπως είναι λογικό πρέπει να εξασφαλιστεί ότι οι στόχοι δεν κινούνται έξω από αυτές τις τιμές.


Αρχιτεκτονική τεχνητών νευρωνικών δικτύων

Όσον αφορά την αρχιτεκτονική τους, τα νευρωνικά δίκτυα μπορούν να χωριστούν σε δύο κατηγορίες:

- Δίκτυα με απλή τροφοδότηση (feedforward neural networks), στα οποία η πληροφορία κινείται μόνο προς μία κατεύθυνση, από το στρώμα εισόδου προς τα κρυμμένα στρώματα και το στρώμα εξόδου.
- Δίκτυα με ανατροφοδότηση (feedback ή recurrent neural networks), στα οποία υπάρχουν συνδέσεις μεταξύ νευρώνων ενός στρώματος και προηγούμενων στρωμάτων ή του ίδιου στρώματος, δηλαδή σε κάποια σημεία του γραφήματος η πληροφορία κινείται κυκλικά. Κάποιες φορές, οι εξόδοι ενός νευρώνα μπορεί να συνδέονται με τις εισόδους του ίδιου (ανατροφοδότηση).



Σχήμα 3.5: Απλή τροφοδότηση



Σχήμα 3.6: Ανατροφοδότηση

3.2.4 Τρόπος λειτουργίας Τεχνητών Νευρωνικών Δικτύων

Κάθε φορά που το δίκτυο ενημερώνεται με νέα σήματα κατά τη διάρκεια της εκπαίδευσής του, λαμβάνει υπόψη τα σφάλματα στη μέχρι στιγμής εκπαίδευση, ενημερώνει για τα νέα δεδομένα και τροποποιεί την εσωτερική του δομή σε ένα διαρκώς μεταβαλλόμενο περιβάλλον.

Ένας άλλος τρόπος να κατηγοριοποιήσουμε τα ΤΝΔ, είναι όσον αφορά τη μέθοδο μάθησης. Η μάθηση είναι μία επαναληπτική διαδικασία με την οποία αλλάζουν οι ελεύθεροι παράμετροι (βάρη και κατώφλια) ενός ΤΝΔ, έτσι ώστε να μειωθεί το σφάλμα μεταξύ επιθυμητής και πραγματικής εξόδου του δικτύου [33]. Οι βασικές μέθοδοι μάθησης είναι:

- Μάθηση με επίβλεψη (supervised learning), ή αλλιώς μάθηση με εκπαιδευτή, όπου το δίκτυο μαθαίνει να αντιστοιχεί μία έξοδο σε μία είσοδο βασιζόμενο σε παραδείγματα εισόδων - επιθυμητών εξόδων που έχουν χρησιμοποιηθεί στην εκπαίδευση. Το νευρωνικό δίκτυο αντλεί από το περιβάλλον ένα παράδειγμα εισόδου και ο εκπαιδευτής, ο οποίος έχει γνώση του περιβάλλοντος παρέχει στο νευρωνικό δίκτυο μια επιθυμητή απόκριση.

- Μάθηση χωρίς επίβλεψη (supervised learning), στην οποία δεν υπάρχει εξωτερικός εκπαιδευτής που να δίνει την επιθυμητή απόκριση και να επιβλέπει τη διαδικασία μάθησης. Η απόκριση βασίζεται στην αυτο-οργάνωση του δικτύου με βάση τα παραδείγματα εισόδου, χωρίς να υπάρχουν αντίστοιχα παραδείγματα εξόδου.

Στην παρούσα εργασία θα μας απασχολήσουν δίκτυα με επιβλεπόμενη μάθηση. Όλα τα εποπτευόμενα μοντέλα βασίζονται στη θεμελιώδη ιδέα της μάθησης των σχέσεων μεταξύ εισόδων και εξόδων από δεδομένα εκπαίδευσης, που αποτελούν τα παραδείγματα. Οι εισοδοί δίνουν τα χαρακτηριστικά και οι έξοδοι δίνουν τους στόχους. Κατά τη διάρκεια της εκπαίδευσης, στο μοντέλο τροφοδοτούνται συστηματικά τα χαρακτηριστικά και οι στόχοι και μαθαίνει μέσω αλγορίθμων εκπαίδευσης να αντιστοιχεί τα πρώτα στους τελευταίους και να «αντιλαμβάνεται» τη δομή τους και η «γνώση» αυτή εκφράζεται ως κατάλληλες επιλογές συναπτικών βαρών. Ένα εκπαιδευμένο μοντέλο αξιολογείται σε ένα σετ δοκιμών, όπου του δίνουμε μόνο τα χαρακτηριστικά και κάνει προβλέψεις. Συγκρίνουμε τις προβλέψεις με τους γνωστούς στόχους για το σετ δοκιμών για τον υπολογισμό της ακρίβειας.[8],[30]

Το πιο γνωστό παράδειγμα αλγορίθμου εκπαίδευσης νευρωνικού δικτύου είναι ο αλγόριθμος **back-propagation**, ειδικά για feedforward neural networks. Στον αλγόριθμο αυτό, υπολογίζεται ο φορέας κλίσης της επιφάνειας σφάλματος. Αυτό το διάνυσμα δείχνει κατά μήκος της γραμμής της πιο απότομης καθόδου από το σημείο το οποίο διανύεται, οπότε γνωρίζουμε ότι εάν μετακινηθούμε μαζί του σε μια "μικρή" απόσταση, θα μειώσουμε το σφάλμα. Μια ακολουθία τέτοιων κινήσεων (επιβραδύνοντας όσο πλησιάζουμε στον πυθμένα) θα βρει τελικά ένα ελάχιστο. Μεγάλα βήματα μπορεί να συγκλίνουν πιο γρήγορα, αλλά μπορεί επίσης να υπερβούν τη λύση ή να βγουν προς λάθος κατεύθυνση. Αντίθετα, πολύ μικρά βήματα μπορεί να πάνε προς τη σωστή κατεύθυνση, αλλά απαιτούν επίσης μεγάλο αριθμό επαναλήψεων. Στην πράξη, το μέγεθος του βήματος είναι ανάλογο με την κλίση (έτσι ώστε οι αλγόριθμοι να καταλήγουν στο ελάχιστο) και με μια ειδική σταθερά: το ρυθμό εκμάθησης. Η σωστή ρύθμιση για το ρυθμό εκμάθησης εξαρτάται από την εφαρμογή και συνήθως επιλέγεται από το πείραμα. Μπορεί επίσης να είναι χρονικά μεταβαλλόμενος, όλο και μικρότερος καθώς ο αλγόριθμος εξελίσσεται. Ο αλγόριθμος επομένως προχωράει διαδοχικά, μέσα από επαναλήψεις (ή "epochs"). Σε κάθε επανάληψη, οι υποθέσεις της εκπαίδευσης υποβάλλονται ξεχωριστά με τη σειρά στο δίκτυο, συγκρίνονται οι στόχοι και οι πραγματικές έξοδοι και υπολογίζεται το σφάλμα. Αυτό το σφάλμα, μαζί με την κλίση της επιφάνειας σφάλματος, χρησιμοποιείται για την προσαρμογή των βαρών και στη συνέχεια η διαδικασία επαναλαμβάνεται. Η αρχική διαμόρφωση δικτύου είναι τυχαία και η εκπαίδευση σταματά όταν παρέλθει ένας δεδομένος αριθμός εποχών ή όταν το σφάλμα σταματήσει να βελτιώνεται. [24]

Τα ΤΝΔ εφαρμόζονται με μεγάλη επιτυχία σε ένα πολύ μεγάλο φάσμα τομέων της επιστήμης και της τεχνολογίας, κι αυτό γιατί η υπολογιστική τους ισχύ είναι τεράστια. Μοντελοποιούν εξαιρετικά πολύπλοκες λειτουργίες, λύνοντας μη γραμμικά προβλήματα. Ουσιαστικά, τα τεχνητά νευρωνικά δίκτυα εισάγονται οπουδήποτε τίθεται θέμα πρόβλεψης, ταξινόμησης ή ελέγχου [8].

3.2.5 Χαρακτηριστικά τεχνητών νευρωνικών δικτύων

Οι βασικές ιδιότητές τους που τα καθιστούν τόσο επιθυμητά συνίστανται:

- Στη μη-γραμμικότητα που επιτρέπει την καλύτερη προσαρμογή στη βάση δεδομένων.

- Στην ανυπαρξία ευαισθησίας ως προς το «θόρυβο», παρέχοντας ακριβείς προβλέψεις παρουσία ανακριβών δεδομένων.
- Στον υψηλό παραλληλισμό τους που καθιστά την επεξεργασία ταχύτατη.
- Στην εκμάθηση και στην προσαρμοστικότητα που επιτρέπουν στο σύστημα να ανέχεται το σφάλμα και την αποτυχία, να ενημερώνει και να τροποποιεί την εσωτερική του δομή σε ένα διαρκώς μεταβαλλόμενο περιβάλλον.
- Στη **γενίκευση** (generalization) που είναι η ικανότητα του ΤΝΔ να αποδίδει εξίσου καλά, δηλαδή να εκτιμά με επιτυχία τους στόχους για άγνωστα δεδομένα και όχι μόνο για τα δεδομένα που χρησιμοποιήθηκαν στην εκπαίδευση. Πρόκειται για ένα από τα πιο σημαντικά λειτουργικά χαρακτηριστικά του ΤΝΔ, καθώς στα περισσότερα προβλήματα για τα οποία χρησιμοποιούνται ΤΝΔ, δεν μπορούμε να γνωρίζουμε από πριν τις καταστάσεις στις οποίες ενδεχομένως να περιέλθει αυτό.

[8]

Γενίκευση, Overfitting και Underfitting

Η ικανότητα γενίκευσης επηρεάζεται από τον αριθμό των διανυσμάτων εκπαίδευσης και από το αν αυτά αναπαριστούν ικανοποιητικά τον υπερχώρο από τον οποίο προέρχονται (συνήθως όσο περισσότερα παραδείγματα για εκπαίδευση τόσο το καλύτερο), την πολυπλοκότητα του προβλήματος και το μέγεθος του ΤΝΔ. [2]

Το μέγεθος του δικτύου έχει να κάνει με τον αριθμό των κρυφών επιπέδων και τον αριθμό των νευρώνων κάθε επιπέδου. Δεν υπάρχει κάποιος συγκεκριμένος κανόνας που να ορίζει ποιος αριθμός κρυφών νευρώνων είναι κατάλληλος, καθώς εξαρτάται με πολύπλοκο τρόπο από πολλούς παράγοντες, όπως τους αριθμούς των μονάδων εισόδου και εξόδου, τον αριθμό των περιπτώσεων εκπαίδευσης, το ποσό θορύβου στους στόχους, την πολυπλοκότητα της λειτουργίας ή της ταξινόμησης που πρέπει να μάθει, τον τύπο της συνάρτησης ενεργοποίησης του κρυφού δικτύου, τον αλγόριθμο εκπαίδευσης κ.α. Το σημαντικό είναι να υπάρχει μια ισορροπία μεταξύ όλων των παραγόντων, εφόσον είναι αλληλοεξαρτώμενοι. Εάν οι κρυφοί νευρώνες είναι πολύ λίγοι, θα υπάρχει υψηλό σφάλμα εκπαίδευσης και υψηλό σφάλμα γενίκευσης, καθώς το δίκτυο θα είναι πολύ φτωχό για να περιγράψει το στόχο και να αναγνωρίζει παρόμοιες περιπτώσεις. Αυτό το πρόβλημα στην εκπαίδευση των ΤΝΔ ονομάζεται **underfitting** ("υποεκπαίδευση"). Αν οι κρυφοί νευρώνες είναι πάρα πολλοί, μπορεί μεν να είναι χαμηλό το σφάλμα εκπαίδευσης, θα εξακολουθεί δε να υπάρχει υψηλό σφάλμα γενίκευσης εξαιτίας του αντίθετου προβλήματος που ονομάζεται **overfitting** ("υπερεκπαίδευση"). Σε αυτήν την περίπτωση το ΤΝΔ έχει εκπαιδευτεί υπερβολικά και η πολυπλοκότητά του είναι πολύ μεγάλη για να μπορέσει να εκφράσει το στόχο σε άγνωστα δεδομένα. [30] [2]

3.3 Περιβάλλον υλοποίησης

Για την κατασκευή, την εκπαίδευση και την προσομοίωση των δικτύων χρησιμοποιήθηκε το περιβάλλον της MATLAB, το οποίο παρέχει αμέτρητες δυνατότητες, και μπορεί να δεχτεί πολύ μεγάλο αριθμό δεδομένων. Διαθέτει κάποιες έτοιμες συναρτήσεις για την εκπαίδευση των νευρωνικών δικτύων. Επιπλέον διαθέτει το Neural network training tool που παρέχει πληροφορίες για την πρόοδο της εκπαίδευσης και διαγράμματα με την επίδοση, την κατάσταση της εκπαίδευσης, το ιστόγραμμα λάθους.

3.4 Τα Τεχνητά Νευρωνικά Δίκτυα της εργασίας

Για τις ανάγκες του συστήματος της παρούσας εργασίας χρησιμοποιήθηκαν δύο ειδών νευρωνικά δίκτυα:

- ένα μη-γραμμικό δίκτυο με απλή τροφοδότηση προσαρμογής συναρτήσεων (feedforward model) και
- ένα μη-γραμμικό αυτό-ανατροφοδοτούμενο εξωγενές μοντέλο NARX (nonlinear autoregressive exogenous model)

3.4.1 Function Fitting Νευρωνικό Δίκτυο

Γενικά, στόχος ενός feedforward neural network είναι να προσεγγίσει μία συνάρτηση f . Ένα feedforward neural network πολλαπλών στρωμάτων μπορεί να χρησιμοποιηθεί σε ένα μοντέλο όπου σκοπός της εκπαίδευσης είναι η ταξινόμηση νέων παρατηρήσεων μέσω της παρατήρησης ήδη ταξινομημένων δεδομένων (Classification) ή μπορεί να χρησιμοποιηθεί σε ένα μοντέλο όπου σκοπός είναι η περιγραφή της σχέσης μεταξύ μιας μεταβλητής απόκρισης (εξόδου) και μιας ή περισσότερων μεταβλητών πρόβλεψης (εισόδου) (Regression). Στην περιπτωσή μας θα ασχοληθούμε με τη δεύτερη κατηγορία, δηλαδή με “feedforward neural networks for regression”. [27]

Ένα τέτοιο δίκτυο η MATLAB το ονομάζει function fitting neural network, δηλαδή “προσαρμογέα λειτουργιών” και κατασκευάζεται με τη συνάρτηση fitnet. Το fitnet λοιπόν χρησιμοποιείται όταν ο εκπαιδευτής έχει ένα σετ παραμέτρων που εισέρχονται στο δίκτυο μαζί με τις αντιστοιχες αποκρίσεις και σκοπός είναι να βρεθεί, μέσω υπολογισμών, η συναρτησιακή σχέση των εισόδων που θα παράξει την επιθυμητή απόκριση, έτσι ώστε με διαφορετικές τιμές εισόδων να μπορεί να βρεθεί μία απόκριση με τιμή όσο πιο κοντά γίνεται στο επιθυμητό αποτέλεσμα. Το fitnet ουσιαστικά είναι ένα feedforward neural network κατασκευασμένο με μια συγκεκριμένη δομή που, σύμφωνα με τη MATLAB, μπορεί να προσαρμοστεί σωστά σε πολυδιάστατα προβλήματα προσέγγισης συνάρτησης. Ορίζεται ως ένα feedforward δίκτυο δύο στρωμάτων με σιγμοειδείς συναρτήσεις στους κρυφούς νευρώνες και γραμμικές συναρτήσεις στους νευρώνες εξόδου [7].

Συνήθως για την εκπαίδευση ενός feedforward δικτύου, χρησιμοποιείται αλγόριθμος “οπισθοδιάδοσης σφάλματος” (**error backpropagation algorithm**), ο οποίος βασίζεται στον κανόνα μάθησης διόρθωσης του λάθους [33], καθώς είναι ιδιαίτερα αποτελεσματικός και πολύ γρήγορος [7][23][4]. Αρχικά γίνεται διάδοση σήματος προς τα εμπρός και ύστερα οπισθοδιάδοση. Το δίκτυο τροφοδοτείται με σήματα στις εισόδους που μεταδίδονται προς τα κρυμμένα στρώματα και τα στρώματα εξόδου ώσπου να προκύψει μια προβλεπόμενη τιμή στην έξοδο, όπως έχει αναφερθεί και νωρίτερα. Ύστερα, για να υπολογιστεί το σφάλμα, η προβλεπόμενη τιμή συγκρίνεται με την πραγματική τιμή εξόδου. Για να υπολογιστεί η τιμή του λάθους χρησιμοποιείται μία “συνάρτηση απώλειας” (**loss function**), η οποία λαμβάνει υπόψη τις τιμές βάρους όλου του δικτύου. Το σήμα λάθους που προκύπτει διαδίδεται προς τα πίσω¹ στο δίκτυο για να προσαρμόσει τα συναπτικά βάρη, έτσι ώστε η προκύπτουσα απόκριση να πλησιάζει την επιθυμητή, δηλαδή μέχρι το λάθος να γίνει το μικρότερο δυνατό (ονομάζεται και local


¹ Αναφέρεται προς αποφυγή σύγχυσης ότι η διαδικασία οπισθοδιάδοσης λάθους αναφέρεται στον τρόπο εκπαίδευσης και δεν αναιρεί τον όρο feedforward neural network που αναφέρεται στην αρχιτεκτονική του δικτύου.

minima).

Σύμφωνα με όσα αναφέρονται στο [3] όπου συγκρίνονται διάφοροι αλγόριθμοι εκπαίδευσης που διαθέτει η MATLAB σε διαφορετικά προβλήματα, ο αλγόριθμος **Levenberg–Marquardt**, σε προβλήματα προσέγγισης συνάρτησης σαν αυτά που μας αφορούν (όπως θα δούμε στη συνέχεια) και σε δίκτυα που περιέχουν μέχρι μερικές εκατοντάδες βάρη, έχει την ταχύτερη σύγκλιση και είναι σε θέση να διασφαλίσει μικρότερα σφάλματα από οποιονδήποτε από τους άλλους αλγόριθμους που δοκιμάστηκαν. Σε πολλές περιπτώσεις τέτοιου είδους προβλημάτων λειτουργεί αποδοτικά ακόμα κι αν ξεκινάει πολύ μακριά από το τελικό ελάχιστο λάθος [13]. Βέβαια, οι απαιτήσεις αποθήκευσης του Levenberg–Marquardt (trainlm στη MATLAB) είναι μεγαλύτερες από τους άλλους δοκιμασμένους αλγόριθμους, οπότε εάν δε διατίθεται αρκετή μνήμη, για προβλήματα προσέγγισης συνάρτησης θα μπορούσε να χρησιμοποιηθεί ο αλγόριθμος scaled conjugate gradient backpropagation [7]. Στην περίπτωση μας, χρησιμοποιήθηκε ο αλγόριθμος **Levenberg–Marquardt**.

Η MATLAB, όταν καλείται η συνάρτηση fitnet με την εντολή `net = fitnet(N)`, κατασκευάζει ένα function fitting TND δύο στρωμάτων και με N νευρώνες στο κρυμμένο στρώμα. Το προκαθορισμένο αυτό μοντέλο κανονικοποιεί τα δεδομένα ώστε να βρίσκονται στην κλίμακα $[-1,1]$, όχι μόνο για τη βελτιστοποίηση των αποτελεσμάτων της εκπαίδευσης αλλά και λόγω της γραμμικής συνάρτησης ενεργοποίησης.

Στην παρακάτω εικόνα φαίνεται ο σχεδιασμός του TND στο Simulink. Η διαδικασία της κανονικοποίησης υλοποιείται στο Process Input, όταν εισέρχονται τα σήματα στο δίκτυο και πριν περάσουν στο κρυφό επίπεδο Layer 1 και η έξοδος αποκανονικοποιείται στο Process Output όταν εξέλθει από το Layer 2 για να στείλει στο εξωτερικό περιβάλλον μία τιμή που να ανήκει στο σωστό εύρος.



Σχήμα 3.7: Function Fitting Neural Network στο Simulink

Το function fitting neural network χρησιμοποιήθηκε για δύο διαφορετικούς σκοπούς στην παρούσα εργασία, οι οποίοι περιγράφονται στη συνέχεια.

3.4.2 Αναγνώριση συστήματος για την πρόβλεψη εσωτερικής θερμοκρασίας με fitnet

Όπως θα δούμε αργότερα στην περιγραφή του ολοκληρωμένου μοντέλου, ο ελεγκτής που κατασκευάστηκε χρειάζεται σε τρία διαφορετικά σημεία της διαδικασίας σε κάθε timestep τ να κάνει μία εκτίμηση της

μέσης εσωτερικής θερμοκρασίας για κάθε εξεταζόμενο χρονικό διάστημα.

Για το πρόβλημα αυτό κατασκευάστηκαν δύο νευρωνικά δίκτυα function fitting. Το ένα αφορά τη θερινή περίοδο και το άλλο τη χειμερινή. Ο σκόπος και ο τρόπος εκπαίδευσης είναι ο ίδιος για τα δύο δίκτυα, όμως λόγω της διαφοράς στην εξωτερική θερμοκρασία, διαφέρουν στη συναρτησιακή σχέση που πρέπει να μάθει το καθένα. Εκπαιδεύονται να προβλέπουν την εσωτερική θερμοκρασία T_{in} του timestep προσομοίωσης τ , συναρτήσει της εξωτερικής θερμοκρασίας $T_{out}(\tau)$, της λειτουργίας ή μη του συστήματος θέρμανσης/ψύξης $Operation(\tau)$ και της μέσης εσωτερικής θερμοκρασίας του προηγούμενου timestep $T_{in}(\tau-1)$.

Για να εξυπηρετήσει το σκοπό μας, θεωρήσαμε ότι το χρονοδιάγραμμα κίνησης αποτελεί και το ετήσιο χρονοδιάγραμμα λειτουργίας του συστήματος θέρμανσης/ψύξης, δηλαδή ότι όσο βρίσκεται ένας από τους κατοίκους στο χώρο, το σπίτι θερμαίνεται ή ψύχεται αντίστοιχα. Ούτως ή άλλως, εδώ δε μας ενδιαφέρει η υψηλή κατανάλωση ενέργειας ή η απώλεια θερμικής άνεσης, αλλά το πως η λειτουργία του κλιματισμού διαμορφώνει την εσωτερική θερμοκρασία κατά τη διάρκεια του έτους.

Χρησιμοποιήθηκε λοιπόν, το μοντέλο προσομοίωσης που έχουμε κατασκευάσει, για να αποκτήσουμε έναν ικανοποιητικό αριθμό παραδειγμάτων ώστε με αυτά να εκπαιδεύσουμε το δίκτυό μας. (Για την εκπαίδευση χρησιμοποιήθηκαν τα δεδομένα που προέκυψαν από την ενεργειακή προσομοίωση της κατοικίας μας.) Ζητήθηκε στο idf αρχείο EnergyPlus να εξάγει με συχνότητα $T=10\text{min}$ (Output Reporting: Output:Variable) την εξωτερική θερμοκρασία (Site Outdoor Air Drybulb Temperature), την εσωτερική θερμοκρασία της θερμικής ζώνης που εξετάζουμε (Zone Air Temperature) και τη λειτουργία της θέρμανσης/ψύξης (Schedule Value(Operation)).

Field	Units	Obj1	Obj2	Obj3
Key Value		*	Operation	Living Room
Variable Name		Site Outdoor Air Dry	Schedule Value	Zone Air Temperatu
Reporting Frequency		Timestep	Timestep	Timestep
Schedule Name				

Σχήμα 3.8: Idf σήματα εξόδου

Συλλέχθηκαν από το αρχείο out.csv 52560 δεδομένα για κάθε μία από τις τρεις μεταβλητές και μεταφέρθηκαν στη MATLAB, όπου χωρίστηκαν σε αυτά που αφορούν τη χειμερινή περίοδο και αυτά που αφορούν τη θερινή. Στην παρούσα εργασία στο μοντέλο του OpenStudio έχει οριστεί ως χειμερινή η περίοδος του έτους από 1η Οκτωβρίου μέχρι 30 Απριλίου και θερινή η περίοδος από 1η Μαΐου μέχρι 31 Οκτωβρίου, επομένως ορίστηκαν:


- 26064×3 δεδομένα για το δίκτυο της χειμερινής περιόδου
- 26496×3 δεδομένα για το δίκτυο της θερινής περιόδου

Για συντομία, από εδώ και στο εξής το νευρωνικό δίκτυο για την πρόβλεψη της θερμοκρασίας τους χειμερινούς μήνες συχνά θα αναφέρεται ως netTH και το αντίστοιχο για τους θερινούς μήνες θα ονομάζεται netTC.

Πρόβλεψη θερμοκρασίας για τη χειμερινή περίοδο

Ας αναλύσουμε την κατασκευή και την εκπαίδευση του netTH. Από τα 26064 ζευγάρια δεδομένων, εισόδων και στόχων, τα τελευταία 1008, δηλαδή τα δεδομένα μίας εβδομάδας, χρησιμοποιήθηκαν για να

εξεταστεί η λειτουργικότητα του δικτύου αφού εκπαιδευτεί. Επομένως, τα δεδομένα προς εκπαίδευση είναι $26063-1-1008 = 25054$.² Μετά από δοκιμές επιλέχθηκαν 7 υπολογιστικοί νευρώνες στο κρυφό στρώμα του δικτύου. Παρακάτω φαίνεται το δίκτυο netH όπως το κατασκεύασε η MATLAB με την εντολή: `net = fitnet(7)`.



Σχήμα 3.9: Δομή νευρωνικού δικτύου netTH

Στην εκπαίδευση ΤΝΔ πολλαπλών στρωμάτων, η γενική ιδέα είναι ο διαχωρισμός των δεδομένων σε τρία υποσύνολα:

- Τα δεδομένα εκπαίδευσης (training set) χρησιμοποιούνται για να ανανεώνονται τα συναπτικά βάρη και οι τιμές πόλωσης.
- Τα δεδομένα επικύρωσης (validation set) είναι τα δεδομένα των οποίων το σφάλμα παρακολουθείται κατά τη διάρκεια της διαδικασίας εκπαίδευσης. Το σφάλμα επικύρωσης μειώνεται κανονικά κατά την αρχική φάση της εκπαίδευσης, όπως και το σφάλμα του σετ εκπαίδευσης. Ωστόσο, όταν το δίκτυο αρχίζει να "υπερεκπαιδεύεται", το σφάλμα στο σετ επικύρωσης συνήθως αρχίζει να αυξάνεται. Τα συναπτικά βάρη και οι τιμές πόλωσης αποθηκεύονται στο μικρότερο σφάλμα του σετ επικύρωσης.
- Τα δεδομένα δοκιμών (testing set) είναι το σετ του οποίου το σφάλμα δε χρησιμοποιείται κατά τη διάρκεια της εκπαίδευσης, αλλά για να συγκρίνει διαφορετικά μοντέλα. Επίσης, χρησιμοποιείται για να κατευθύνει το σφάλμα επικύρωσης. Αν το σφάλμα στο τεστ δοκιμών έχει την ελάχιστη τιμή του σε έναν πολύ διαφορετικό αριθμό επανάληψης από το σφάλμα επικύρωσης, τότε μάλλον χρειάζεται να γίνει διαφορετικός διαχωρισμός στο συνολικό σετ των δεδομένων.

[25]

Στο δίκτυό μας επιλέχθηκε η μέθοδος *dividerand*, η οποία χωρίζει τυχαία τα δεδομένα σε τρία υποσύνολα, δίνοντας στο χρήστη τη δυνατότητα να διαλέξει το ποσοστό των δεδομένων κάθε υποσυνόλου. Έπειτα από δοκιμές, φάνηκε πως τα προκαθορισμένα ποσοστά 70%,15%,15% για την εκπαίδευση, την επικύρωση και τη δοκιμή αντίστοιχα είναι τα πιο κατάλληλα για την περίπτωση του netTH.


Αφού λοιπόν χωρίστηκαν τα δεδομένα, το δίκτυο μπορεί να ξεκινήσει τη διαδικασία της εκπαίδευσης, με τη συνάρτηση `train`, η οποία λαμβάνει ως παραμέτρους τα δεδομένα εισόδου, τους στόχους και το κατασκευασμένο δίκτυο **net**, όπως έχει οριστεί. Επίσης, όπως έχει ήδη αναφερθεί, ο αλγόριθμος που χρησιμοποιήθηκε για την εκπαίδευση είναι ο **Levenberg-Marquardt** ('`trainlm`' στη MATLAB).

²Το επιπλέον στοιχείο που αφαιρείται οφείλεται στο ότι κάθε χρονική στιγμή τ χρειάζεται την τιμή $\text{PrevTin}(\tau)$ του ακριβώς προηγούμενου στοιχείου της ακολουθίας.

Για καλύτερα αποτελέσματα, ακολουθήσαμε την ίδια διαδικασία εκπαίδευσης για $N_{\text{trials}} = 10$ επαναλήψεις, δίνοντας κάθε φορά μια τυχαία αρχικοποίηση στα συναπτικά βάρη. Από κάθε εκπαίδευση προέκυψε ένα σετ εξόδων και υπολογίστηκε το μέσο τετραγωνικό σφάλμα (MSE, mean squared error). Το MSE μετρά το μέσο όρο των τετραγώνων των σφαλμάτων, δηλαδή τη μέση τετραγωνική διαφορά μεταξύ των εκτιμώμενων τιμών και των πραγματικών. Οι τυχαίες αρχικές τιμές των συνάψεων στην εκπαίδευση με το μικρότερο MSE είναι και αυτές που τελικά χρησιμοποιήθηκαν. Στο εκπαιδευμένο δίκτυο εφαρμόστηκαν τα δεδομένα της μίας εβδομάδας όπως αναφέρθηκε παραπάνω και τα αποτελέσματα που προέκυψαν αναφέρονται στην ενότητα 5.2.1.

Πρόβλεψη θερμοκρασίας για τη θερινή περίοδο

Όπως και στο αντίστοιχο νευρωνικό δίκτυο της χειμερινής περιόδου, από τις 26497 περιπτώσεις, οι τελευταίες 1008, δηλαδή τα δεδομένα μίας εβδομάδας, χρησιμοποιήθηκαν για να εξεταστεί η λειτουργικότητα του δικτύου αφού εκπαιδευτεί. Άρα, τα δεδομένα προς εκπαίδευση είναι $26497 - 1 - 1008 = 25488$. Το TNA netTC κατασκευάστηκε με 7 νευρώνες στο κρυφό στρώμα, καθώς από δοκιμές που έγιναν για πολλά διαφορετικά μεγέθη δικτύου, αυτό το μέγεθος διασφάλιζε την καλύτερη εκπαίδευση, και με ίδιες συναρτήσεις ενεργοποίησης με το netTH. Η εκπαίδευση επίσης έγινε με τον ίδιο τρόπο που έγινε και για το netTH. Τα αποτελέσματα του θα τα δούμε στην ενότητα 5.2.1.



Σχήμα 3.10: Δομή νευρωνικού δικτύου netTC

3.4.3 Αναγνώριση συστήματος για την πρόβλεψη ενεργειακής κατανάλωσης με fitnet

Στην προσομοίωση του ελεγκτή, χρειάζεται σε κάθε timestep τ μία εκτίμηση της ενεργειακής κατανάλωσης του εξεταζόμενου χώρου για κάθε εξεταζόμενο χρονικό διάστημα. Οι παράμετροι που χρησιμοποιήθηκαν για την απόκριση εξόδου είναι η εξωτερική θερμοκρασία $T_{\text{out}}(\tau)$, η εσωτερική θερμοκρασία του εξεταζόμενου χώρου $T_{\text{in}}(\tau)$, η εσωτερική θερμοκρασία του προηγούμενου timestep $T_{\text{in}}(\tau-1)$, η ορισμένη θερμοκρασία άνεσης $T_{\text{set}}(\tau)$ και η λειτουργία του συστήματος θέρμανσης/ψύξης του προηγούμενου timestep $\text{Operation}(\tau-1)$. Προφανώς όταν δεν είναι ενεργοποιημένο το σύστημα θέρμανσης/ψύξης, η ενεργειακή κατανάλωση είναι μηδενική. (Στην παρούσα εργασία μας απασχολεί μόνο η θέρμανση και η ψύξη του χώρου και όχι άλλοι παράγοντες όπως οι ηλεκτρικές συσκευές.) Επομένως, για την εκπαίδευση του δικτύου μας αφορούν μόνο τα timesteps του χρονοδιαγράμματος για τα οποία $\text{Operation}(\tau) = 1$, γι' αυτό και δε χρειαζόμαστε το $\text{Operation}(\tau)$ ως είσοδο. Για το πρόβλημα αυτό χρειάστηκε νευρωνικό δίκτυο function fitting, καθώς κι εδώ ζητάμε από το TNA να καταλάβει και να αναπαραστήσει τη συναρτησιακή σχέση παραμέτρων. Χρειάστηκαν επίσης δύο TNA, ένα για τη θερινή και ένα για τη χειμερινή περίοδο. Ο σκόπος και ο τρόπος εκπαίδευσης είναι ο ίδιος για τα δύο δίκτυα, όμως λόγω της διαφοράς στην εξωτερική θερμοκρασία, διαφέρουν στη συναρτησιακή σχέση που πρέπει να μάθει το καθένα, όπως και για την πρόβλεψη της θερμοκρασίας.

Τα δεδομένα που χρησιμοποιήθηκαν για την εκπαίδευση και τη δοκιμή του δικτύου συγκεντρώθηκαν από το EnergyPlus. Στο idf αρχείο του μοντέλου που προσομοιώσαμε, επιλέχθηκαν διαφορετικές παράμετροι που μπορούν να αποφέρουν περιπτώσεις δεδομένων οι οποίες θα δώσουν μία γενική εικόνα στο δίκτυο για τη συναρτησιακή σχέση που πρέπει να κατανοήσει για να λειτουργεί σωστά.

Για την προσομοίωση της κατοικίας έχει ήδη οριστεί ως χρονοδιάγραμμα της λειτουργίας του συστήματος θέρμανσης/ψύξης το Schedule.txt αρχείο που χρησιμοποιήθηκε για την πρόβλεψη της θερμοκρασίας και καταγράφει ένα τυπικό καθημερινό πρόγραμμα των κατοίκων, θεωρώντας ότι όσο βρίσκεται κάτοικος στο χώρο του καθιστικού, ο χώρος θερμαίνεται ή ψύχεται αντίστοιχα. Επίσης οι θερμοκρασίες που έχουν οριστεί ως επιθυμητές για το χώρο (θεωρώντας ότι τις έχει ορίσει ο κάτοικος στο σύστημα) είναι TsetHeat = 22°C για τη χειμερινή περίοδο του έτους και TsetCool = 26°C για τη θερινή.

Για την επίτευξη του σκοπού μας και τη συγκέντρωση ικανοποιητικού αριθμού δεδομένων προς εκπαίδευση, εκτελέστηκαν ενεργειακές προσομοιώσεις με τις εξής παραλλαγές:

- TsetHeat = 18°C και TsetCool = 23°C
- TsetHeat = 19°C και TsetCool = 24°C
- TsetHeat = 20°C και TsetCool = 25°C
- TsetHeat = 21°C και TsetCool = 26°C
- TsetHeat = 22°C και TsetCool = 27°C
- TsetHeat = 23°C και TsetCool = 28°C
- TsetHeat = 24°C και TsetCool = 29°C
- TsetHeat = 25°C και TsetCool = 30°C
- Ως χρονοδιάγραμμα λειτουργίας συστήματος θέρμανσης/ψύξης ένα τυχαίο χρονοδιαγραμμα
- Ως χρονοδιάγραμμα λειτουργίας συστήματος θέρμανσης/ψύξης ένα χρονοδιαγραμμα με αλλαγή τιμής (0/1) κάθε έξι ώρες

Ζητήθηκε από το EnergyPlus για κάθε προσομοίωση να εξάγει (OutputReporting: Output:Variable) με συχνότητα T=10min την εξωτερική θερμοκρασία (Site Outdoor Air Drybulb Temperature), την εσωτερική θερμοκρασία της θερμικής ζώνης που εξετάζουμε (Zone Air Temperature), τη λειτουργία της θέρμανσης/ψύξης (Schedule Value(Operation)) και τις μεταβλητές Zone Air System Sensible Heating Energy και Zone Air System Sensible Cooling Energy που αντιπροσωπεύουν την αισθητή ενέργεια θέρμανσης και ψύξης αντίστοιχα σε Joules που παρέχεται από το σύστημα στην εξεταζόμενη ζώνη για το χρονικό διάστημα T και είναι ο αισθητός ρυθμός θέρμανσης πολλαπλασιασμένος με το χρόνο προσομοίωσης.

Field	Units	Obj1	Obj2	Obj3	Obj4	Obj5
Key Value		*	Operation	Living Room	Living Room	Living Room
Variable Name		Site Outdoor Air Dry	Schedule Value	Zone Air Temperature	Zone Air System Sensible Heating Energy	Zone Air System Sensible Cooling Energy
Reporting Frequency		Timestep	Timestep	Timestep	Timestep	Timestep
Schedule Name						

Σχήμα 3.11: Idf σήματα εξόδου

Με αυτόν τον τρόπο υπάρχει μία εικόνα για το πως λειτουργεί το σύστημα σε διαφορετικές θερμοκρασιακές ρυθμίσεις. Με το να εκπαιδεύεται το δίκτυο και σε ακραίες περιπτώσεις για το Tset, μπορεί να δι-

αχειριστεί καλύτερα τη μέση οδό των 25 ή 26°C τους καλοκαιρινούς μήνες. Επιπλέον, αν όλες οι περιπτώσεις υπό εκπαίδευση ήταν με κοινό χρονοδιάγραμμα λειτουργίας συστήματος θέρμανσης/ψύξης, τότε ενδεχομένως να μην υπήρχαν παραδείγματα στην εκπαίδευση για κάποιες τιμές του Tout. Με το χρονοδιάγραμμα τυχαίων δυαδικών τιμών ενός έτους το σύστημα μπορεί να λειτουργήσει οποιαδήποτε χρονική στιγμή της μέρας άρα δίνεται περισσότερη πληροφορία στο δίκτυο. Επιπροσθέτως, με το χρονοδιάγραμμα λειτουργίας με αλλαγή τιμής κάθε έξι ώρες, η λειτουργία ή μη του συστήματος έχει μεγάλη διάρκεια με αποτέλεσμα η θερμοκρασία να φτάνει τη θερμοκρασία άνεσης (Tset) και να παραμένει σε αυτήν για όσες ώρες χρειαστεί και ύστερα να αφήνεται να επηρεαστεί από την εξωτερική θερμοκρασία έτσι ώστε (έστω για κάποιες περιπτώσεις) να ενεργοποιείται το σύστημα όταν η θερμοκρασία έχει μεγάλη απόκλιση από τη θερμοκρασία άνεσης.

Πρόβλεψη ενεργειακής κατανάλωσης για τη χειμερινή περίοδο

Για το TNA που αφορά τη χειμερινή περίοδο, το οποίο θα αναφέρουμε ως netEnergyH, τα παραδείγματα που διαθέτουμε από τις προσομοιώσεις είναι 46151. Είναι από κάθε προσομοίωση όλες οι χρονικές στιγμές που αφορούν τη χειμερινή περίοδο (1:17280 και 43777:52560), όταν η λειτουργία θέρμανσης είναι ενεργοποιημένη. Για την εκπαίδευση χρησιμοποιήθηκαν οι περιπτώσεις για TsetHeat = 19°C, TsetHeat = 20°C, TsetHeat = 21°C, TsetHeat = 23°C, TsetHeat = 24°C, TsetHeat = 25°C, , οι περιπτώσεις για τα διαφορετικά χρονοδιαγράμματα λειτουργίας της θέρμανσης και οι περιπτώσεις για TsetHeat = 22°C (46151 περιπτώσεις συνολικά) με εξαίρεση τις 4534 τελευταίες τιμές, που εφαρμόστηκαν μετά την εκπαίδευση στο δίκτυο προκειμένου να διαπιστωθεί η λειτουργικότητά του. Επομένως τα δεδομένα εκπαίδευσης είναι 41616.

Κατασκευάστηκε με τη συνάρτηση fitnet ένα δίκτυο δύο στρωμάτων και μετά από δοκιμές επιλέχθηκαν H=18 κρυφοί νευρώνες. Για το διαχωρισμό των δεδομένων σε δεδομένα εκπαίδευσης, επικύρωσης και δοκιμής επιλέχθηκε και πάλι ο τυχαίος διαχωρισμός με τη μέθοδο dividerand και με ποσοστά 70%,15%,15% αντίστοιχα. Το TNA εκπαιδεύτηκε δέκα φορές με τη χρήση της συνάρτησης train, με διαφορετικές αρχικές τυχαίες τιμές στα συναπτικά βάρη και επιλέχθηκε η εκπαίδευση με την καλύτερη απόδοση, συγκρίνοντας το μέσο τετραγωνικό σφάλμα. Χρησιμοποιήθηκε ο αλγόριθμος **Levenberg-Marquardt** ('trainlm' στη MATLAB), όπως και στα προηγούμενα function fitting TNA. Αφού εκπαιδεύτηκε το δίκτυο, εφαρμόσαμε σε αυτό τα επιπλέον δεδομένα.

Πρόβλεψη ενεργειακής κατανάλωσης για τη θερινή περίοδο

Για το TNA που αφορά τη θερινή περίοδο, το οποίο θα αναφέρουμε ως netEnergyC, τα παραδείγματα που διαθέτουμε από το idf αρχείο είναι 25582. Σε αντιστοιχία με το netEnergyH, είναι από κάθε προσομοίωση όλες οι χρονικές στιγμές που αφορούν τη θερινή περίοδο (17281:43776), όταν η λειτουργία ψύξης είναι ενεργοποιημένη. Για την εκπαίδευση χρησιμοποιήθηκαν οι περιπτώσεις για TsetCool = 23°C, TsetCool = 24°C, TsetCool = 25°C, TsetCool = 27°C, TsetCool = 28°C, TsetCool = 29°C, οι περιπτώσεις για τα διαφορετικά χρονοδιαγράμματα λειτουργίας της ψύξης και οι περιπτώσεις με TsetCool = 26°C με εξαίρεση τις 2090 τελευταίες τιμές που εφαρμόστηκαν στο δίκτυο μετά την εκπαίδευση. Επομένως τα δεδομένα εκπαίδευσης είναι 23491. Η υπόλοιπη διαδικασία κατασκευής του δικτύου και εκπαίδευσης είναι κοινή με το netEnergyH. Ο πιο αποδοτικός αριθμός κρυφών νευρώνων βρέθηκε να είναι H=22.

Τα εκτιμώμενα αποτελέσματα για τα δύο TNA υπάρχουν στις ενότητες 5.2.3 και 5.2.4.


3.4.4 NARX Νευρωνικό Δίκτυο

Η ονομασία NARX προέρχεται από τα αρχικά nonlinear autoregressive exogenous model, και αφορά ένα μη-γραμμικό αυτο-τροφοδοτούμενο μοντέλο με εξωγενείς εισόδους. Ένα ανατροφοδοτούμενο μοντέλο NARX, σε αντίθεση με άλλα ανατροφοδοτούμενα μοντέλα (όπως αυτά έχουν προσδιοριστεί στην υποενότητα 3.2.3) έχουν περιορισμένες αρχιτεκτονικές ανάδρασης που προέρχονται μόνο από τους νευρώνες εξόδου. Είναι ένα επαναλαμβανόμενο δυναμικό ΤΝΔ, με συνδέσεις ανατροφοδότησης που περιλαμβάνουν πολλά στρώματα του δικτύου. Το μοντέλο NARX βασίζεται στο γραμμικό μοντέλο ARX. [10] Χρησιμοποιείται για τη μοντελοποίηση χρονικών ακολουθιών, δηλαδή για ακολουθίες δεδομένων που έχουν καταταχθεί με χρονολογική σειρά. Συσχετίζει την τρέχουσα τιμή μιας χρονικής ακολουθίας με προηγούμενες τιμές της ίδιας ακολουθίας και με τρέχουσες και προηγούμενες τιμές μιας εξωγενούς δηλαδή μιας εξωτερικά καθορισμένης ακολουθίας, που επηρεάζει την ακολουθία που μας ενδιαφέρει.

Ορίζεται ως:

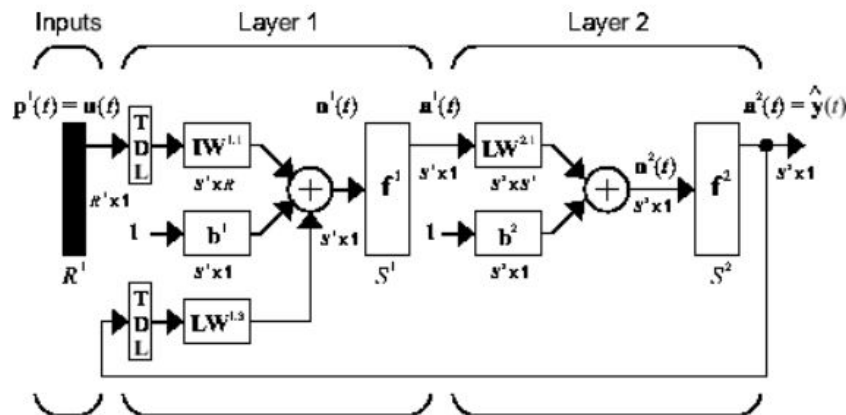
$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n_y), x(t-1), x(t-2), \dots, x(t-n_x))$$

, όπου $y(t)$ είναι η επόμενη τιμή του εξαρτημένου σήματος εξόδου (του σήματος που εξετάζουμε), η οποία παλινδρομεί σε προηγούμενες τιμές του σήματος εξόδου και προηγούμενες τιμές ενός ανεξάρτητου (εξωγενούς) σήματος εισόδου $x(t)$.




Σχήμα 3.12: NARX νευρωνικό δίκτυο

Ουσιαστικά είναι ένα multi-layer perceptron όπως αυτό της απλής τροφοδότησης (feedforward), το οποίο με τις κατάλληλες συνδέσεις, αποκτά την αρχιτεκτονική του NARX.




Σχήμα 3.13: Δομή NARX νευρωνικού δικτύου

IW είναι τα βάρη των συνδέσεων από τις εισόδους προς τα στρώματα (π.χ. $IW^{(2,1)}$ είναι ο πίνακας βαρών από την πρώτη είσοδο προς το δεύτερο στρώμα). Παρομοίως LW είναι ο πίνακας βαρών των συνδέσεων μεταξύ των στρωμάτων και b είναι ο πίνακας βαρών των τάσεων της σταθερής πόλωσης των στρωμάτων. Βλέπουμε ότι χρησιμοποιούνται γραμμές καθυστέρησης (tapped delay lines), τόσο στη είσοδο όσο και στις αναδρομικές συνδέσεις. Στην εκπαίδευση ενός τέτοιου δικτύου, δίνεται η δυνατότητα να χρησιμοποιηθούν δύο αρχιτεκτονικές για την εκπόνηση του βέλτιστου αποτελέσματος. Η έξοδος του NARX, που αποτελεί την εκτίμηση του δικτύου για το μη-γραμμικό δυναμικό σύστημα που θέλουμε να μοντελοποιήσουμε, είδαμε ότι τροφοδοτείται ξανά στο δίκτυο, έτσι όπως ορίζει η αρχιτεκτονική του NARX. Επειδή όμως, είναι επίσης διαθέσιμη η πραγματική έξοδος του συστήματος, υπάρχει η δυνατότητα να χρησιμοποιηθεί εκείνη αντί να ανατροφοδοτείται η εκτιμώμενη τιμή. Δηλαδή, είναι εφικτό να χρησιμοποιήσουμε μία σειριακή-παράλληλη αρχιτεκτονική, τροφοδοτώντας το δίκτυο με τους στόχους $y(t)$ και όταν χρειαστεί να χρησιμοποιήσουμε παράλληλη αρχιτεκτονική.



Σχήμα 3.14: Σειριακή-Παράλληλη αρχιτεκτονική



Σχήμα 3.15: Παράλληλη αρχιτεκτονική

Με αυτήν την τακτική, η παράλληλη αρχιτεκτονική στην εκπαίδευση, λόγω του ότι είναι διαθέσιμες οι επιθυμητές τιμές εξόδων, παρέχει μεγαλύτερη ακρίβεια. Επιπλέον, το τελικό διαμορφωμένο δίκτυο έχει καθαρά αρχιτεκτονική απλής τροφοδότησης και μπορεί να χρησιμοποιηθεί στατική οπισθοδιάδοση backpropagation) για την εκπαίδευση, που είναι ένας πολύ αποτελεσματικός αλγόριθμος [21]. Ένα NARX λοιπόν, πραγματοποιεί όλη τη διαδικασία της εκπαίδευσης με παράλληλη αρχιτεκτονική, χρησιμοποιώντας την ακολουθία y ως είσοδο ($y(t-1), y(t-2), \dots$) αλλά και ως στόχο-έξοδο ($y(t)$). Μόλις το δίκτυο εκπαιδευτεί, μπορεί να γίνει η προσομοίωσή του και να μελετηθούν τα σφάλματα που προέκυψαν. Μέχρι στιγμής και δεδομένου ότι το σφάλμα είναι μικρό και η εκπαίδευση έχει καλή απόδοση, μπορεί να χρησιμοποιηθεί για την πρόβλεψη της αμέσως επόμενης τιμής, δηλαδή ενός βήματος. Αν όμως το δίκτυο αναδιαταχθεί στη σειριακή-παράλληλη μορφή (κλειστός βρόχος) θα μπορεί να πραγματοποιηθεί επανειλημμένη πρόβλεψη σε πολλά χρονικά βήματα. Προκειμένου όμως να υπάρχει ακρίβεια στην επαναλαμβανόμενη πρόβλεψη χωρίς την παρουσία στόχων, είναι σημαντικό το δίκτυο να έχει εκπαιδευτεί καλά (εκπαίδευση-επικύρωση-δοκιμή) στην παράλληλη υλοποίηση της μίας πρόβλεψης και τα σφάλματα να είναι πολύ μικρά, αφού προφανώς η υλοποίηση σε κλειστό βρόχο θα έχει

μικρότερη ακρίβεια αποτελεσμάτων. [14]

3.4.5 Αναγνώριση συστήματος για την πρόβλεψη μελλοντικής ανθρώπινης παρουσίας στο χώρο με NARX

Ο ελεγκτής της εργασίας καθορίζει τη λειτουργία της θέρμανσης και της ψύξης ενός χώρου, βασισμένος στο αν και πόσο κάποιος κάτοικος θα βρίσκεται στο χώρο κάποιες μελλοντικές χρονικές στιγμές για ένα χρονικό ορίζοντα. Ο παράγοντας αυτός είναι ο πιο σημαντικός για τη λειτουργία του ελεγκτή, καθώς γνωρίζοντας τη μελλοντική κίνηση στο χώρο, μπορεί να ενεργήσει προκαταβολικά, θερμαίνοντας ή ψύχοντας πρόωρα το χώρο όταν κρίνεται ότι χρειάζεται. Ένα σύστημα που διαθέτει πληροφορίες για το χρονοδιάγραμμα παρουσίας των κατοίκων στην οικία για ένα ικανοποιητικό χρονικό διάστημα, μπορεί να μάθει τη ρουτίνα τους και να προσπαθήσει να προβλέψει τη συμπεριφορά τους. Εφόσον πρόκειται για ένα πρόβλημα που πρέπει να προβλέψει με βάση το χρόνο, σίγουρα θα χρειαστεί για τη λύση του ένα δυναμικό δίκτυο, δηλαδή ένα δίκτυο με χρονικές καθυστερήσεις ή με ανατροφοδότηση ή και τα δύο. Το narx είναι σε θέση να προβλέψει τις επόμενες τιμές μιας τέτοιας χρονικής ακολουθίας, με δεδομένες τις περασμένες τιμές και τιμές χρήσιμων εξωγενών χρονικών ακολουθιών.

Έχει κατασκευαστεί ένα ετήσιο χρονοδιάγραμμα με την παρουσία/απουσία των κατοίκων στο χώρο, με τιμές 1/0 αντίστοιχα και με περίοδο 10 λεπτών. Υποθέτουμε ότι το χρονοδιάγραμμα προκύπτει από παρατήρηση της πραγματικής κίνησης των κατοίκων για ένα χρόνο, με τη βοήθεια αισθητήρων κίνησης που λαμβάνουν σήματα ανά δέκα λεπτά. Επίσης, για διευκόλυνση θεωρήθηκε ότι οι αισθητήρες λαμβάνουν σήματα στην αρχή του διαστήματος των δέκα λεπτών, δηλαδή αν ο αισθητήρας τη χρονική στιγμή t λάβει την τιμή 1 που δηλώνει παρουσία, θεωρείται πως υπάρχει παρουσία για όλη τη διάρκεια του τρέχοντος χρονικού διαστήματος. Έτσι, εάν ο χώρος "αδειάσει" κάποια στιγμή κατά τη διάρκεια του τρέχοντος διαστήματος των δέκα λεπτών και παραμείνει "άδειος" αφού περάσουμε στη χρονική στιγμή $t+1$, αυτό θα γίνει αντιληπτό από τους αισθητήρες στο $t+1$ και όχι νωρίτερα.

Το timestep επιλέχθηκε να είναι τα δέκα λεπτά της ώρας, χωρίς να δοκιμαστούν άλλες επιλογές, καθώς μια πιο μεγάλη χρονική περίοδος καταγραφής παρουσίας (π.χ. 30 λεπτών) θα ήταν λιγότερο εύστοχη εφόσον στη διάρκεια μισής ώρας είναι πολύ πιθανό συχνά να αλλάζει η κατάσταση, ενώ μια πιο μικρή χρονική περίοδος (πχ πέντε ή δύο λεπτών) θα πολλαπλασίαζε τη διαδικασία χρονικά και θα έπρεπε να ακολουθείται από ένα σύστημα ελεγκτή πολύ γρήγορο στη λήψη αποφάσεων, κάτι που ενδεχομένως να δημιουργούσε πρόβλημα καθώς όπως θα δούμε στη συνέχεια το σύστημα εκτελεί πολλές λειτουργίες.

Για τη λειτουργία του ελεγκτή μας χρειάστηκε να εκτιμηθεί η μελλοντική ακολουθία παρουσίας / απουσίας για ένα χρονικό ορίζοντα μίας εβδομάδας. Έτσι, για τη μοντελοποίηση του προβλήματός χρησιμοποιήθηκε ένα NARX νευρωνικό δίκτυο που κάνει μία πρόβλεψη 1008 βημάτων για την ακολουθία παρουσίας / απουσίας, με δεδομένες τις προηγούμενες τιμές της ακολουθίας και εξωγενείς παράγοντες που βοηθούν στην πρόβλεψη. Η τιμή της ακολουθίας παρουσίας/απουσίας εξαρτάται άμεσα από το χαρακτηριστικό δεκάλεπτο της ημέρας και από τον τύπο της ημέρας, δηλαδή από το αν τη χρονική στιγμή t διανύεται μια καθημερινή ή Σαββατοκύριακο, καθώς οι κάτοικοι ακολουθούν ένα διαφορετικό πρόγραμμα τις καθημερινές από τα Σαββατοκύριακα. Συνεπώς, ορίστηκαν ως εξωγενείς είσοδοι στο δίκτυο μία ακολουθία $x_1(t)$ που για κάθε t έχει την τιμή 2 εάν η ημέρα είναι Σάββατο ή Κυριακή και την τιμή 1 για καθημερινή και μία ακολουθία $x_2(t)$ που αποτελείται από τις τιμές 1 έως 144 επαναλαμβανό-

μενα, ξεκινώντας από το πρώτο δεκάλεπτο της ημέρας (1) μέχρι το τελευταίο (144) για κάθε ημέρα.

Λόγω του ότι η λήψη των δεδομένων - στόχων $y(t)$ είναι μέρος του όλου συστήματος, όπως θα δούμε και στη συνέχεια, υπάρχει η δυνατότητα της επιλογής του αριθμού των δεδομένων προς εκπαίδευση, ανάλογα με το τι είναι βέλτιστο. Η χρήση πολλών δεδομένων θα αυξήσει το χρόνο εκπαίδευσης και πιθανόν να οδηγήσει σε υπερεκπαίδευση. Επιπλέον, κάποια ακραία συμπεριφορά της χρονοσειράς στην προσομοίωση που δεν έχει εμφανιστεί στην εκπαίδευση, είναι πολύ δύσκολο να προβλεφθεί, ακόμα κι αν η χρονοσειρά προς εκπαίδευση είναι αρκετά μεγάλη. Η επιλογή μας θα φανεί στη συνέχεια.

Στις περισσότερες περιπτώσεις, όπως και σε αυτήν, είναι απαραίτητη η προεπεξεργασία των χρονοσειρών για να εξασφαλιστεί η βελτιστοποίηση. Στην περίπτωσή μας, έγινε η κανονικοποίηση των δεδομένων με δύο τρόπους. Έγινε μία κανονικοποίηση για να ανήκουν όλα τα δεδομένα $x(t)$ και $y(t)$ στο εύρος $[-1,1]$ και μία για να ανήκουν στο εύρος $[0,1]$, προκειμένου να είναι σύμφωνες με τις διαφορετικές δομές νευρωνικού δικτύου που δοκιμάστηκαν.

Όσον αφορά τη δομή του νευρωνικού δικτύου, κατά τη διάρκεια της μελέτης εκτελέστηκαν πολλές διαφορετικές προσομοιώσεις για να βρεθεί η κατάλληλη και δεν είναι εφικτό να αναφερθούν εδώ όλες, όμως θα δοθεί έμφαση στις πιο σημαντικές εκτελέσεις, κρίνοντας εκ του αποτελέσματος. Τα αποτελέσματα της πρόβλεψης για κάθε περίπτωση συγκρίθηκαν στατιστικά με το μέσο τετραγωνικό σφάλμα (Mean Square Error - MSE).

Για την εκπαίδευση του δικτύου χρησιμοποιήθηκε οπισθοδιάδοση σφάλματος, που είναι η πιο αποτελεσματική και διαδεδομένη λύση. Για πρόβλεψη και μοντελοποίηση χρονοσειρών, η MATLAB προτείνει ως αλγόριθμο οπισθοδιάδοσης σφάλματος για τα περισσότερα προβλήματα τον αλγόριθμο Levenberg-Marquardt (`trainlm`). Η αποδοτικότητα του σε τέτοιου είδους προβλήματα φαίνεται και στο [1] όπου συγκρίνεται με διάφορους άλλους αλγόριθμους. Για μερικά θορυβώδη και μικρά προβλήματα ο αλγόριθμος Bayesian Regularization (`trainbr`) μπορεί να πάρει περισσότερο χρόνο αλλά να αποκτήσει μια καλύτερη λύση. Για μεγάλα προβλήματα, ωστόσο, η MATLAB συνιστά τον αλγόριθμο "κλιμακωτής συζευγμένης κλίσης" (`trainscg`) καθώς χρησιμοποιεί υπολογισμούς διαβάθμισης οι οποίοι είναι περισσότερο αποδοτικοί στη μνήμη από τους υπολογισμούς που χρησιμοποιούν οι άλλοι δύο αλγόριθμοι. Εκτελέσαμε μία προσομοίωση με Levenberg-Marquardt και μία με Scaled Conjugate Gradient αλγόριθμο.

Η επιλογή της λειτουργίας ενεργοποίησης σε κάθε στρώμα του δικτύου είναι άλλο ένα σημαντικό στοιχείο της επιλογής της βέλτιστης δομής. Το πρότυπο του NARX έχει σιγμοειδείς συναρτήσεις ενεργοποίησης στους κρυφούς νευρώνες (sigmoid ή tan-sigmoid). Στις περισσότερες περιπτώσεις, χρησιμοποιείται γραμμική συνάρτηση ενεργοποίησης στους νευρώνες εξόδου. Ωστόσο, η επιλογή μπορεί να διαφέρει ανάλογα με την εφαρμογή. Στα δεδομένα μας, εφαρμόστηκαν τέσσερις διαφορετικές περιπτώσεις δικτύων, όσον αφορά τις συναρτήσεις ενεργοποίησης:

- σιγμοειδής στο κρυφό στρώμα και γραμμική στο στρώμα εξόδου
- σιγμοειδής στο κρυφό στρώμα και στο στρώμα εξόδου

- εφαπτόμενη σιγμοειδής στο κρυφό στρώμα και γραμμική στο στρώμα εξόδου
- εφαπτόμενη σιγμοειδής στο κρυφό στρώμα και στο στρώμα εξόδου

Η σύγκριση των αποτελεσμάτων για την περίπτωση που φέρει τη βέλτιστη απόδοση στις προβλέψεις μας γίνεται στην ενότητα 5.2.5.

Μπορεί να ξέρουμε τη δομή του δικτύου αλλά δεν μπορούμε να γνωρίζουμε τους ακριβείς υπολογισμούς που εκτελεί στο εσωτερικό του. Έτσι, οι καθυστερήσεις που χρειάζεται για κάθε πρόβλεψη δεν είναι πάντα προφανείς. Ακόμα κι αν μπορούμε να υποθέσουμε τις χρήσιμες καθυστερήσεις με κοινή λογική, χρειάζεται να διαπιστωθεί ότι το δίκτυο ανταποκρίνεται σε αυτή τη λογική. Στην περίπτωση μας, εφόσον πρόκειται για μία χρονική ακολουθία, της οποίας οι τιμές ακολουθούν κάποιο μοτίβο κάθε 24 ώρες και κάποιο άλλο μοτίβο κάθε 7 ημέρες, θα μπορούσαμε να θεωρήσουμε ότι οι σημαντικές καθυστερήσεις για την απόκριση του δικτύου είναι αυτές που αφορούν την ίδια ώρα προηγούμενων ημερών ή την ίδια ώρα ακριβώς μία εβδομάδα νωρίτερα. Έγιναν πολλές δοκιμές για το ιδανικό σετ καθυστερήσεων. Για παράδειγμα, ορίστηκαν ως καθυστερήσεις στην ανατροφοδοτούμενη είσοδο για κάθε timestep οι δεκαπέντε ακριβώς προηγούμενες χρ. στιγμές, οι τιμές για τις αντίστοιχες χρ. στιγμές για τις προηγούμενες πέντε ημέρες της εβδομάδας μαζί και οι δεκαπέντε ακριβώς προηγούμενες χρ. στιγμές για κάθε μία από αυτές (feedbackDelays = [1:15 144:159 288:303 432:447 576:591 720:735]) και ως καθυστερήσεις στις εξωγενείς εισόδους οι τιμές για τις αντίστοιχες χρονικές στιγμές τις τελευταίες πέντε ημέρες της εβδομάδας (inputDelays = [144 288 432 576 720]). Τα αποτελέσματα που προέκυψαν μετά από τις ρυθμίσεις που αναφέρονται στη συνέχεια και την εκπαίδευση ήταν σχετικά ικανοποιητικά αλλά υπήρχε μεγάλο περιθώριο βελτίωσης.

Για να βρεθούν οι σημαντικές καθυστερήσεις που αποφέρουν καλύτερη αποδοτικότητα ικανοποιώντας τις απαιτήσεις του δικτύου, χρησιμοποιήθηκε η συνάρτηση αυτοσυσχέτισης και η συνάρτηση συσχέτισης εισόδων και στόχων.

Η αυτοσυσχέτιση (autocorrelation) είναι ένα μέτρο της εσωτερικής συσχέτισης μιας χρονοσειράς, μία εξήγηση της σχέσης μεταξύ των παρατηρήσεων. Η συνάρτηση αυτοσυσχέτισης περιγράφει τη γενική εξάρτηση των τιμών των στοιχείων ανά πάσα στιγμή με τις τιμές των στοιχείων σε άλλη χρονική στιγμή [28]:

$$R_{xx}(m) = 1/N \sum_{n=1}^{N-m+1} x(n)x(n+m-1)$$

, για $m = 1, 2, \dots, M+1$, όπου M είναι ο αριθμός των καθυστερήσεων και N ο αριθμός των δεδομένων. Ένα διαγράμμα αυτοσυσχέτισης είναι ένα κοινώς χρησιμοποιούμενο εργαλείο για τον έλεγχο της τυχαιότητας σε ένα σύνολο δεδομένων. Με κάθε υπολογισμό αυτοσυσχέτισης για τιμές δεδομένων σε διαφορετικές χρονικές υστερήσεις αναγνωρίζεται ή απορρίπτεται η τυχαιότητα. Εάν η σχέση δύο τιμών είναι τυχαία, η αυτοσυσχέτιση θα πρέπει να είναι σχεδόν μηδενική.

Η συνάρτηση συσχέτισης (cross correlation) μετρά την εξάρτηση των στοιχείων μίας χρονοσειράς με τα στοιχεία μίας άλλης χρονοσειράς [28]:


$$R_{yx}(m) = 1/N \sum_{n=1}^{N-m+1} y(n)x(n+m-1)$$

, για $m = 1, 2, \dots, M+1$, όπου M είναι ο αριθμός των καθυστερήσεων και N ο αριθμός των δεδομένων.

Έτσι λοιπόν, στόχος είναι να βρεθούν για τις εξωγενείς εισόδους οι καθυστερήσεις για τις οποίες η απόλυτη τιμή της συνάρτησης συσχέτισης εισόδου / στόχου υπερβαίνει ένα καθορισμένο όριο και αντίστοιχα για την ανατροφοδότηση οι καθυστερήσεις για τις οποίες η απόλυτη τιμή της συνάρτησης αυτισυσχέτισης στόχου υπερβαίνει ένα καθορισμένο όριο. Το όριο καθορίστηκε χρησιμοποιώντας μία εκτίμηση για το 95% του επιπέδου σημαντικότητας του θορύβου Gauss. [28] [17]

Λαμβάνοντας υπόψη την επιλογή των καθυστερήσεων, χρησιμοποιήσαμε ένα διπλό βρόχο ($h = H_{min}: dH: H_{max}$, $i = 1: N_{trials}$) για να προσδιορίσουμε το μικρότερο αριθμό νευρώνων για το κρυφό στρώμα που οδηγεί σε μια καλή απόδοση. Ο εξωτερικός βρόχος αφορά τα διαφορετικά μεγέθη κρυφού στρώματος που δοκιμάστηκαν και ο εσωτερικός βρόχος, για κάθε h εκπαιδεύει N_{trials} φορές με διαφορετικές τυχαίες αρχικοποιήσεις στα βάρη σε κάθε εκπαίδευση.

Στα δίκτυα που διαχειρίζονται χρονικές ακολουθίες είναι απαραίτητη η μορφοποίηση των δεδομένων από στοιχεία απλών πινάκων σε στοιχεία κελιών. Έτσι, οι εξωγενείς εισοδοί μορφοποιούνται σε ακολουθία κελιών, με κάθε κελί να περιλαμβάνει διάνυσμα δύο θέσεων. Κατασκευάστηκε το παράλληλο (ανοιχτού βρόχου) νευρωνικό δίκτυο NARX με την εντολή: `net = narxnet(inputDelays, feedbackDelays, hiddenLayerSize)`.




Σχήμα 3.16: NARX Neural Network - Open Loop

Χωρίσαμε τα δεδομένα σε τρία μέρη με τη συνάρτηση `net.divideFcn = 'divideblock'`, η οποία χωρίζει τα δεδομένα χωρίς να αλλάζει τη σειρά τους, με το πρώτο 70% να αποτελεί το σετ εκπαίδευσης, το επόμενο 15% το σετ επικύρωσης και το τελευταίο 15% το σετ δοκιμής.

Ένα δίκτυο σαν το NARX που χρησιμοποιεί γραμμές καθυστέρησης και ανατροφοδοτήσεις χρειάζεται σε κάθε νέα περίπτωση δεδομένων επανασχηματισμό των εισόδων και των στόχων. Αυτή η λειτουργία στη MATLAB επιτυγχάνεται εύκολα με τη συνάρτηση `preparets`. Η συνάρτηση αυτή μετακινεί αυτόματα τις χρονικές ακολουθίες εισόδου και στόχων για όσα βήματα απαιτούνται για τις αρχικές καταστάσεις καθυστερήσεων στην είσοδο και στα στρώματα. Πλέον το δίκτυο μπορεί να εκπαιδευτεί. Χρησιμοποιήθηκε η συνάρτηση `train(net,Xs,Ts,Xsi,Asi)`, όπου X_s είναι οι εισόδοι του δικτύου, T_s οι στόχοι, X_{si} οι αρχικές συνθήκες των καθυστερήσεων των εισόδων και A_{si} οι αρχικές συνθήκες καθυστερήσεων των στρωμάτων.

Μετά την εκπαίδευση σε λειτουργία ανοιχτού βρόχου, το δίκτυο προσομοιώθηκε με όλες τις γνωστές τιμές της χρονικής ακολουθίας κι ύστερα μετέβη σε λειτουργία κλειστού βρόχου, προκειμένου να συνεχιστεί η προσομοίωση για να προβλεφθούν όσα βήματα μπροστά επιθυμούνται. Η μετάβαση έγινε


με την εντολή: **netc= closeloop(net,Xsi,Asi)**, όπου **net** είναι το δίκτυο στην αρχική του μορφή, ενώ **netc** είναι το δίκτυο μετά τη μετάβαση.



Σχήμα 3.17: NARX Neural Network - Close Loop

Στο σύστημα μας χρειάστηκε το δίκτυο σε μία προσομοίωση να μπορεί να προβλέπει την παρουσία των κατοίκων για μία εβδομάδα. Αυτό μπορεί να υλοποιηθεί με την επαναλαμβανόμενη πρόβλεψη του **netc**. Επιπλέον όμως, προκειμένου να λαμβάνει ο ελεγκτής τις προβλέψεις εγκαίρως και να παίρνει αποφάσεις, πρέπει η πρόβλεψη να γίνεται πρόωρα.

Στα αρχέτυπα δίκτυα ξέρουμε ότι η έξοδος $y(t+1)$ προκύπτει μόλις δοθεί στο δίκτυο η είσοδος $x(t+1)$. Σε κάποια προβλήματα όπως στα προβλήματα λήψης αποφάσεων, που ένα τέτοιο αντιμετωπίζουμε κι εδώ, είναι πολύ χρήσιμη η κατασκευή δικτύων των οποίων η εκτιμώμενη τιμή $y(t+1)$ προκύπτει την ίδια στιγμή που γίνεται διαθέσιμη η είσοδος $x(t)$ και πριν προκύψει η πραγματική έξοδος $y(t+1)$. Αν υποθέσουμε ότι ο ελεγκτής για να εξάγει μία απόφαση τη χρονική στιγμή t πρέπει να γνωρίζει αν θα βρίσκεται ή όχι στο χώρο κάποιος κάτοικος τη χρονική στιγμή $t+n$, τότε πρέπει τη χρονική στιγμή t , όπου το $x(t)$ εισέρχεται στο δίκτυο, το δίκτυο να εξάγει την εκτιμώμενη τιμή $y(t+n)$. Αυτό είναι εφικτό αν αφαιρεθούν n καθυστερήσεις, εφόσον μιλάμε για ένα ήδη εκπαιδευμένο δίκτυο. Έτσι, με την εντολή: **netr = removedelay(netc,n)**, προκύπτει ένα δίκτυο το οποίο εξάγει τα ίδια ακριβώς αποτελέσματα με το **netc**, με τις εξόδους όμως να μετατοπίζονται n βήματα αριστερά.



Σχήμα 3.18: NARX Neural Network - Early Prediction

Στην περίπτωση μας κρίθηκε ότι χρειάζεται κάθε πρόβλεψη να είναι διαθέσιμη 11 timesteps νωρίτερα. Έστω X_{mp} και T_{mp} το σετ δεδομένων για την προσομοίωση της πρόβλεψης πολλαπλών βημάτων. Αποτελούνται από $1008 + delays$ παραδείγματα, όπου 1008 είναι τα βήματα για τα οποία εφαρμόζεται πρόβλεψη, και $delays$ είναι οι καθυστερήσεις που χρειάζονται για την πρώτη εκτίμηση $Y(delays+1)$. Αφού τα δεδομένα επανασχηματίστηκαν με την εντολή **preparets**, εκτελέστηκε με το **netr** μία πρόωρη

κατά 11 χρονικές στιγμές επαναλαμβανόμενη πρόβλεψη 1008 βημάτων.

Τα αποτελέσματα της εκπαίδευσης καταγράφονται στην ενότητα 5.2.5.

Κεφάλαιο 4

Προσομοίωση Συστήματος

4.1 Περιβάλλον υλοποίησης

Για την υλοποίηση του συστήματος χρησιμοποιήθηκε το Simulink®, το οποίο είναι ένα γραφικό προγραμματιστικό περιβάλλον κατασκευασμένο από το Mathworks, όπως και η MATLAB. Είναι ένα περιβάλλον κατασκευής διαγραμμάτων για προσομοίωση πολλαπλών τομέων και σχεδιασμό μοντέλων. Υποστηρίζει σχεδιασμό σε επίπεδο συστήματος, προσομοίωση, αυτόματη δημιουργία κώδικα και συνεχή έλεγχο και επαλήθευση των ενσωματωμένων συστημάτων. Το Simulink παρέχει έναν γραφικό επεξεργαστή, προσαρμόσιμες βιβλιοθήκες μπλοκ και λύσεις για τη μοντελοποίηση και την προσομοίωση δυναμικών συστημάτων. Είναι ενσωματωμένο με τη MATLAB, επιτρέποντάς να γίνει ενσωμάτωση των αλγορίθμων MATLAB σε μοντέλα και των αποτελεσμάτων προσομοίωσης εξαγωγής στη MATLAB® για περαιτέρω ανάλυση. [18]

Κάτι ιδιαίτερα χρήσιμο που θα χρησιμοποιηθεί σε αυτό το κεφάλαιο είναι ένα είδος αρχείου της MATLAB που ονομάζεται S-Function (system function). Είναι μια περιγραφή ενός μπλοκ Simulink γραμμένο σε MATLAB®, C, C++ ή Fortran. Παρέχει έναν ισχυρό μηχανισμό για την επέκταση των δυνατοτήτων του Simulink. Στην παρούσα εργασία η S-function που χρησιμοποιείται γράφεται σε MATLAB. Οι συναρτήσεις S χρησιμοποιούν μια ειδική σύνταξη κλήσης που ονομάζεται API S-function και επιτρέπει την αλληλεπίδραση με τον κινητήρα του Simulink. Αυτή η αλληλεπίδραση είναι πολύ παρόμοια με την αλληλεπίδραση που λαμβάνει χώρα μεταξύ του κινητήρα και των ενσωματωμένων μπλοκ του Simulink. Εφαρμόζοντας έναν αλγόριθμο σε μια συνάρτηση S, το μπλοκ S-Function που παρέχει το Simulink μπορεί να προστεθεί σε ένα Simulink μοντέλο. Μπορεί να χρησιμοποιηθεί και για διακριτά και για συνεχή συστήματα, όπως και για υβριδικά. Συγκεκριμένα η συνάρτηση S 2ου-επίπεδου, που κατασκευάστηκε στην εργασία, επιτρέπει με τη χρήση της γλώσσας MATLAB τη δημιουργία προσαρμοσμένων μπλοκ με πολλαπλές θύρες εισόδου και εξόδου και το χειρισμό οποιοδήποτε τύπου σήματος παράγεται από ένα μοντέλο Simulink, συμπεριλαμβανομένων των πινάκων πλαισίου οποιουδήποτε τύπου δεδομένων. Η συνάρτηση καθορίζει τις ιδιότητες και τη συμπεριφορά μιας συνιστώσας ενός μπλοκ MATLAB S-Function Level-2 και το μπλοκ παραπέμπει στη συνάρτηση της MATLAB σε ένα μοντέλο του Simulink. Η συνάρτηση λοιπόν περιλαμβάνει ένα σύνολο μεθόδων επανάκλησης που επικαλείται ο κινητήρας Simulink κατά την ενημέρωση ή την προσομοίωση του μοντέλου. Οι μέθοδοι επανάκλησης πραγματοποιούν την πραγματική εργασία της αρχικοποίησης και υπολογισμού των εξόδων του μπλοκ που ορίζονται από τη συνάρτηση.

Η MATLAB S-function 2ου επιπέδου παρέχει τη λειτουργία της επαναφοράς που δίνει τη δυνατότητα στη συνάρτηση να παρακολουθεί πολλαπλά στιγμιότυπα. Αυτό γίνεται με τα διανύσματα DWork. Είναι μπλοκ μνήμης τα οποία μια S-function ζητά από τον κινητήρα Simulink να καταναείμει σε κάθε εμφάνιση της συνάρτησης στο Simulink μοντέλο. [17] [19]

4.2 Γενική ιδέα

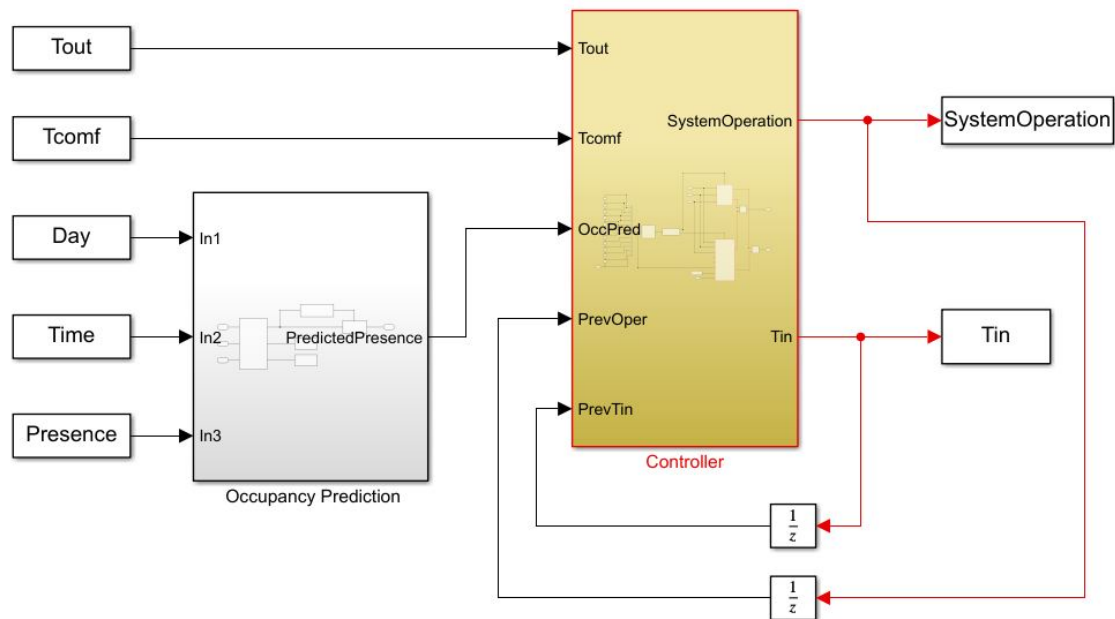
Είναι πλέον βασική αρχή στις ενεργειακές μελέτες ότι οι επιθυμίες του κατοίκου, όπως και το προγράμμα του, είναι το ίδιο σημαντικά με τα ενεργειακά ζητήματα. Συνεπώς, στην περίπτωση μας ορίζουμε ως στόχο μας για τη ρύθμιση της θερμοκρασίας, την αύξηση της άνεσης του κατοίκου και τη μείωση του ενεργειακού κόστους, που διαφορετικά μπορεί να αποδοθεί ως ένα πρόβλημα βελτιστοποίησης, όπου στόχος κατά τη θέρμανση/ψύξη είναι η μείωση του κόστους

$$J = (EnergyCost) + (ComfortCost)$$

Η γενική ιδέα, λοιπόν, είναι ένα σύστημα θέρμανσης/ψύξης το οποίο μαθαίνει να ρυθμίζει αυτόματα την εσωτερική θερμοκρασία του χώρου, παρατηρώντας και διακρίνοντας συγκεκριμένες ακολουθίες στο πρόγραμμα των κατοίκων και στις προτιμήσεις τους περί θερμικής άνεσης. Οι συνέπειες κάθε απόφασής του, όπως είναι λογικό, έχουν μία χρονική καθυστέρηση, καθώς ένας εσωτερικός χώρος δεν είναι δυνατό να θερμανθεί ή να ψυχθεί τη στιγμή ακριβώς που δίνεται η εντολή. Επομένως, ο ελεγκτής θα πρέπει να είναι ελεγκτής πρόβλεψης, προκειμένου να ανταπεξέλθει στις θερμικές απαιτήσεις.

Έτσι, στην υλοποίηση της ιδέας αυτής, κατασκευάστηκε ένα σύστημα με έναν προσαρμοστικό ελεγκτή, ο οποίος, λαμβάνοντας πληροφορίες για την μελλοντική παρουσία ή την απουσία των κατοίκων για ένα χρονικό διάστημα, ρυθμίζει κατάλληλα την εσωτερική θερμοκρασία της κατοικίας, ενεργοποιώντας όποτε χρειάζεται το σύστημα θέρμανσης/ψύξης, ώστε να εξασφαλίζεται εξοικονόμηση ενέργειας ενώ ταυτόχρονα η μέση θερμοκρασία να παραμένει αρκετά κοντά σε μία δεδομένη τιμή, ορισμένη από τον κάτοικο. Στην παρούσα εργασία η μελέτη περιορίζεται στο χώρο του καθιστικού.

Το συνολικό μοντέλο έχει χωριστεί σε δύο βασικά μέρη: το μοντέλο πρόβλεψης της μελλοντικής παρουσίας/απουσίας ανθρώπων και το μοντέλο του ελεγκτή. Το μοντέλο του ελεγκτή ουσιαστικά περιλαμβάνει πολλές ακόμα λειτουργίες που θα δούμε παρακάτω.



Σχήμα 4.1: Συνολικό Μοντέλο

4.3 Μοντέλο πρόβλεψης μελλοντικής παρουσίας κατοίκων στο χώρο

4.3.1 Μεθοδολογία

Επειδή η κατασκευή του συστήματος αφορά κατοικίσιο χώρο, οι ρυθμίσεις του ελεγκτή είναι πολύπλοκες, καθώς οι επιθυμίες του κατοίκου, όπως και το προγραμμα του είναι πολύ βασικοί παράγοντες και επιπλέον μπορεί να διαφοροποιούνται ανά πάσα στιγμή. Έτσι, ένα από τα πιο σημαντικά βήματα για την ορθή λειτουργία του συστήματος είναι η πρόβλεψη της ρουτίνας των κατοίκων όσον αφορά την παρουσία τους στο χώρο. Το μοντέλο που καλείται να υλοποιήσει αυτό το βήμα αποτελεί κομμάτι του συνολικού συστήματος, επομένως ενημερώνεται συνεχώς με δεδομένα πραγματικού χρόνου. Χρειάστηκε λοιπόν να μπορεί να προσαρμόζεται σε τυχόν αλλαγές της καθημερινότητας των κατοίκων κατά τη διάρκεια του έτους.

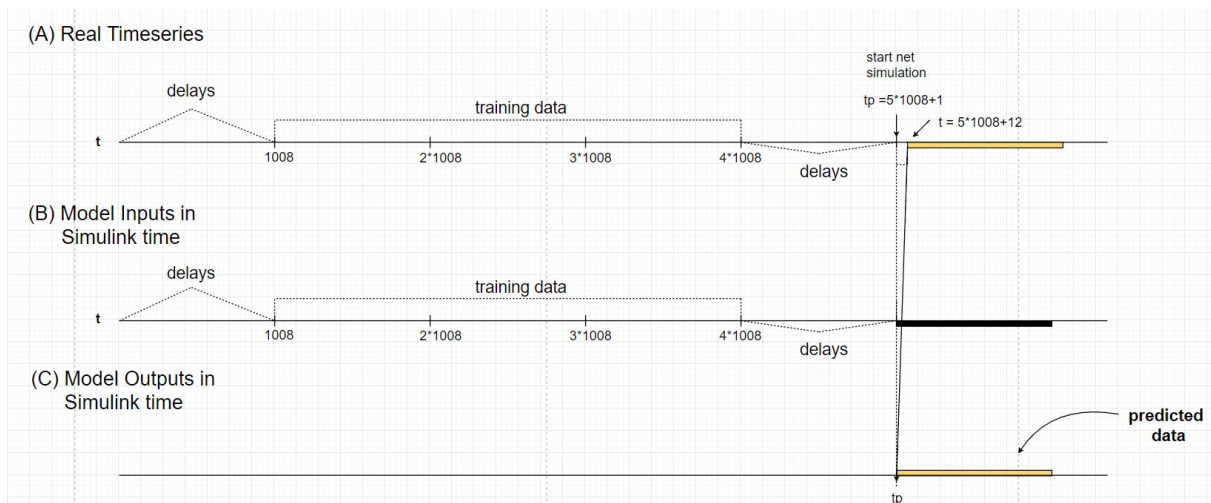
Στο 3.4.5, αναλύθηκε η κατασκευή και η εκπαίδευση ενός νευρωνικού δικτύου NARX το οποίο έχει εκπαιδευτεί με δεδομένα χρονικής διάρκειας τεσσάρων εβδομάδων ($4 \cdot 1008 = 4032$ περιπτώσεις) για να προβλέπει 110 λεπτά νωρίτερα δεδομένα χρονικής διάρκειας μίας εβδομάδας (ακολουθία 1008 τιμών). Για να επιτευχθεί το βήμα της πρόβλεψης για τον έναν χρόνο που εξετάζουμε χρησιμοποιήθηκε το δίκτυο NARX και εκτελέστηκαν δύο ταυτόχρονες διεργασίες:

- Η online εκπαίδευση του νευρωνικού δικτύου, δηλαδή η εκπαίδευση ενώ είναι ενεργοποιημένη η προσομοίωση ολόκληρου του συστήματος στο Simulink
- Η περιοδική εκπαίδευση του νευρωνικού δικτύου με μία διαδικασία κύλισης, ώστε να προκύψουν προβλέψεις για κάθε χρονική στιγμή μέχρι το τέλος της προσομοίωσης του συστήματος.

4.3.2 Ανάλυση

Από τη στιγμή που θα ενεργοποιηθεί το συνολικό σύστημα, κάθε δέκα λεπτά της ώρας δέχεται τις παραμέτρους που έχουν οριστεί στις εισόδους για την κατάσταση της κατοικίας εκείνη τη στιγμή. Άρα κάθε δέκα λεπτά λαμβάνει μία νέα τιμή για την παρουσία ή μη έστω και ενός κατοίκου στο χώρο την τρέχουσα χρονική στιγμή. Εφόσον δεν υπάρχει νωρίτερη καταγραφή των δεδομένων αυτών, το δίκτυο που έχει κατασκευαστεί μπορεί να εκπαιδευτεί και να χρησιμοποιηθεί αφού συγκεντρωθεί ο κατάλληλος αριθμός δεδομένων, όσο το σύστημα "τρέχει".

Πιο αναλυτικά, η διαδικασία έχει ως εξής: Σε κάθε χρονική στιγμή t το μοντέλο λαμβάνει ως σήμα εισόδου πληροφορία για το αν κάποιος κάτοικος βρίσκεται στο χώρο ή όχι την τρέχουσα περίοδο (10 λεπτών). Το μοντέλο θα λάβει την πρώτη είσοδο τη χρονική στιγμή $t = 1$. Για την εκπαίδευση του δικτύου το μοντέλο χρειάζεται πληροφορίες για χρονική ακολουθία 4032 τιμών.¹ Επομένως, τη χρονική στιγμή $t = 4032$ έχουν συγκεντρωθεί τα δεδομένα που χρειάζονται. Επιπλέον όμως, πρέπει να διασφαλιστούν οι καθυστερήσεις για το πρώτο σετ δεδομένων που θα εφαρμοστεί στο εκπαιδευμένο δίκτυο. Έτσι, κρατώνται στη μνήμη και οι επόμενες 1008 τιμές. Τη χρονική στιγμή $t = delays + trainingdata + delays + 1 = 5 \cdot 1008 + 1$ το μοντέλο υλοποιεί την εκπαίδευση του δικτύου με τα πρώτα $4 \cdot 1008$ δεδομένα και είναι πλέον σε θέση να εφαρμόσει στην είσοδο του εκπαιδευμένου δικτύου τα δεδομένα εισόδου της τρέχουσας χρονικής στιγμής και των επόμενων 1007 τιμών, δηλαδή τις εισόδους του δικτύου για μία εβδομάδα. Υπενθυμίζεται ότι οι εισοδοί του δικτύου NARX, όπως αυτό έχει εκπαιδευτεί, είναι ο τύπος της ημέρας (καθημερινή ή Σ/Κ) και ο αριθμός σειράς του δεκάλεπτου της ημέρας (1-144), δηλαδή εξαρτώνται μόνο από τη θέση τους στη χρονική ακολουθία, συνεπώς δε χρειάζεται να φτάσει η προσομοίωση στη χρονική στιγμή στην οποία αναφέρονται για να χρησιμοποιηθούν οι τιμές τους. Το δίκτυο λοιπόν τη χρονική στιγμή $tp = delays + trainingdata + delays + 1$ παρέχει στην έξοδό του προβλέψεις που αφορούν τη χρονική στιγμή $t = delays + trainingdata + delays + 1 + stepsAhead$, όπου $stepsAhead = 11$, και τις επόμενες 1007 τιμές. Η πρώτη πρόβλεψη οδηγείται στην έξοδο του μοντέλου προβλεψής τη χρονική στιγμή tp και οι υπόλοιπες 1007 προβλέψεις αποθηκεύονται στη μνήμη και εξάγονται κάθε μία ξεχωριστά στα 1007 βήματα της προσομοίωσης του συστήματος που ακολουθούν.

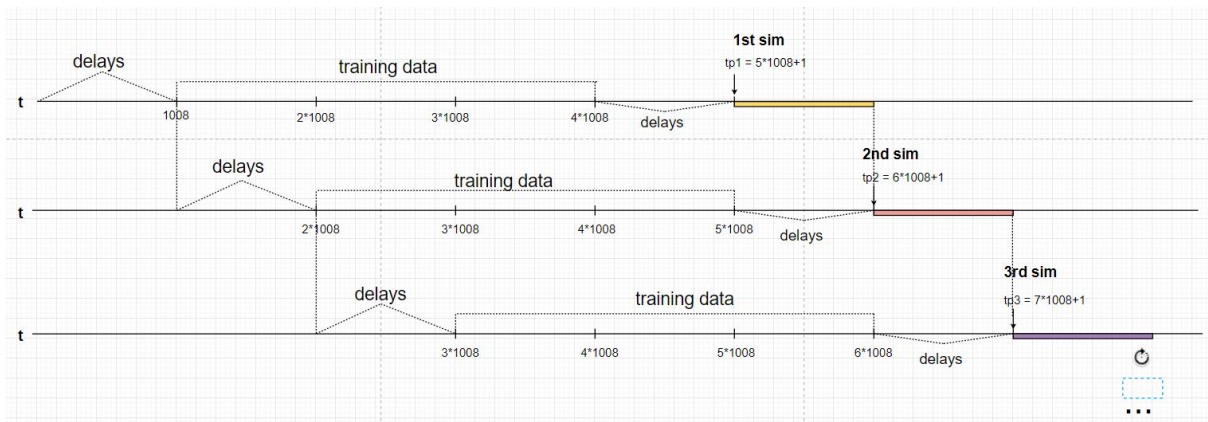


Σχήμα 4.2: Χρονικές ακολουθίες δεδομένων δικτύου του μοντέλου πρόβλεψης

¹Τα δεδομένα της εκπαίδευσης είναι 3024, αλλά εφόσον η πιο μακρινή χρονικά καθυστέρηση που περνάει ως είσοδος στο δίκτυο είναι η 1008η, οι πρώτες 1008 τιμές της χρονικής ακολουθίας χρησιμοποιούνται για να διασφαλιστούν οι απαραίτητες καθυστερήσεις για το πρώτο στοιχείο της εκπαίδευσης, το οποίο θα λαμβάνεται τη χρονική στιγμή $t = 1008 + 1$.

Μέχρι στιγμής το μοντέλο πρόβλεψης μπορεί να δώσει στο περιβάλλον του μία πρόβλεψη τη φορά για 1008 βήματα με τελευταία τη χρονική στιγμή $tp_{end} = tp + 1007 = 6 \cdot 1008$, όπου η πρόβλεψη αφορά την παρουσία κατοίκων τη χρονική στιγμή $t_{end} + 11 = 6 \cdot 1008 + 11$. Προκειμένου να υπάρξουν προβλέψεις για όλο τον υπόλοιπο χρόνο προσομοίωσης ξεκινώντας από την αμέσως επόμενη χρονική στιγμή ($t = 6 \cdot 1008 + 1$), το δίκτυο πρέπει όσο "τρέχει" η προσομοίωση του συστήματος να εκπαιδεύεται περιοδικά με χρονική περίοδο ίση με μία εβδομάδα, δηλαδή κάθε 1008 timesteps, έτσι ώστε σε κάθε timestep της προσομοίωσης του συστήματος να εξάγεται από το μοντέλο πρόβλεψης μία τιμή.

Αναλυτικότερα, για κάθε τ ($=10\text{min}$) που περνάει, δηλαδή για κάθε βήμα της προσομοίωσης, στο σύστημα καταγράφεται η πραγματική τιμή παρουσίας/απουσίας για την τρέχουσα χρονική στιγμή $occ(\tau)$. Σε κάθε βήμα εκτελείται στις χρονικές ακολουθίες των εισόδων και των στόχων του δικτύου μία ολίσθηση προς τα αριστερά, έτσι ώστε να προστίθεται στην ακολουθία κάθε νέα τιμή που καταγράφεται. Όπως έχει αναφερθεί τη στιγμή $tp_1 = 5 \cdot 1008 + 1$ έχουν καταγραφεί όσα δεδομένα χρειάζονται (εξωγενείς εισοδοί δικτύου, στόχοι και καθυστερήσεις), υλοποιείται η πρώτη εκπαίδευση και εξάγεται η πρώτη πρόβλεψη. Μετά από 1008 timesteps, τη χρονική στιγμή $tp_2 = 6 \cdot 1008 + 1$ έχουν εξαχθεί 1008 προβλέψεις (για τις στιγμές $t_1 = 5 \cdot 1008 + 12$ έως $t_{end} = 6 \cdot 1008 + 11$) και το σύστημα έχει ενημερωθεί για τις πραγματικές τιμές 1008 τιμών ($5 \cdot 1008 + 1$ έως $6 \cdot 1008$), επομένως μπορεί να πραγματοποιηθεί η δεύτερη εκπαίδευση, αφού έχουν προσαρμοστεί οι στόχοι και οι εισοδοί του δικτύου ώστε να έχουν αποβάλλει τις πιο μακρινές τιμές των χρονοσειρών τους και να έχουν ενσωματώσει τις πιο πρόσφατες, κι επιπλέον εξάγεται από το δίκτυο μία πρόβλεψη (που αφορά τη χρονική στιγμή $t_2 = 6 \cdot 1008 + 12$). Αντίστοιχα, μετά από 1008 τιμές το δίκτυο πραγματοποιεί την τρίτη εκπαίδευση και ξεκινάει να εξάγει προβλέψεις τη χρονική στιγμή $tp_3 = 7 \cdot 1008 + 1$. Η διαδικασία μπορεί να φανεί στο σχήμα που ακολουθεί:



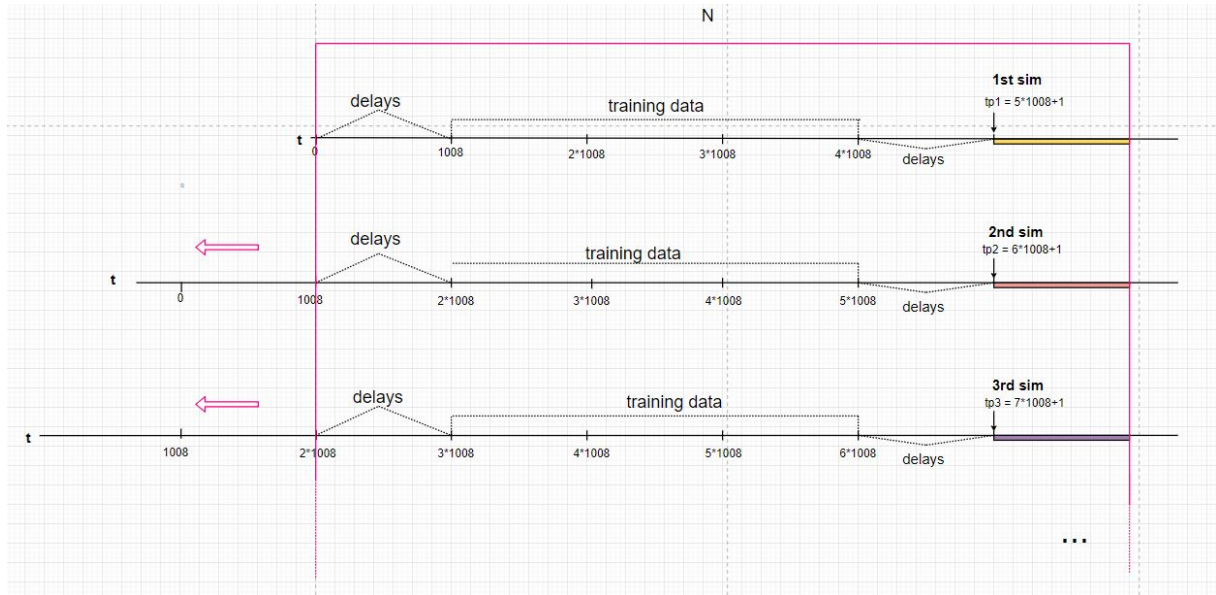
Σχήμα 4.3: Περιοδική εκπαίδευση του δικτύου στο μοντέλο πρόβλεψης

Για να πραγματοποιηθεί online εκπαίδευση νευρωνικού δικτύου στο Simulink χρειάστηκε η κατασκευή μίας S-function. Στο μοντέλο πρόβλεψης χρησιμοποιήθηκε ένα Level-2 MATLAB S-function block, το οποίο υλοποιεί τον αλγόριθμο της συνάρτησης. Σε κάθε χρονική στιγμή τ της προσομοίωσης εισέρχονται στη συνάρτηση οι τιμές που έχουν οριστεί ως εξωγενείς εισοδοί για το δίκτυο (ο τύπος της ημέρας και η στιγμή της ημέρας) και η τιμή για την παρουσία/ απουσία κατοίκων την τρέχουσα χρονική στιγμή.² Όπως έχει ήδη αναφερθεί για την Level-2 MATLAB S-function, υπάρχει η δυνατότητα στη συνάρτηση να κατανέμονται τιμές στα Dwork διανύσματα και στην επόμενη εμφάνιση της S-function, δηλαδή σε επόμενο timestep, να αποσπώνται από το διάνυσμα και να χρησιμοποιούνται. Στη συνάρτησή μας

²Βλ. Υπόθεση 1 6

λοιπόν, κατασκευάστηκαν Dwork διανύσματα με μέγεθος ίσο με $N = delays + trainingData + delays + 1$ και αρχικοποιημένα με μηδενικές τιμές, προκειμένου να αποθηκεύονται εκεί οι είσοδοι και οι στόχοι του χρειάζεται το νευρωνικό δίκτυο. Σε κάθε t , οι τιμές του κάθε διανύσματος μετακινούνται κατά μία θέση προς τα αριστερά και τα νέα σήματα που εισέρχονται αποθηκεύονται στην τελευταία θέση των αντίστοιχων διανυσμάτων. Σε N χρονικές στιγμές από την έναρξη της προσομοίωσης, τα διανύσματα έχουν συμπληρωθεί και υπάρχουν όσα δεδομένα χρειάζονται για να γίνει η πρώτη εκπαίδευση του δικτύου. Αφού υλοποιηθεί όλη η διαδικασία όπως έχει περιγραφεί στο 3.4.5, το δίκτυο παράγει $Nmp = 1008$ (πρώρες κατά stepsAhead χρ. στιγμές) προβλέψεις. Οι τιμές αυτές αποθηκεύονται σε ένα άλλο Dwork διάνυσμα y_{TH} μεγέθους Nmp . Την ίδια χρονική στιγμή tp_1 εξάγεται η πρώτη πρόβλεψη από το μοντέλο, δηλαδή η τιμή $y_{TH}(i)$. Αντίστοιχα, τη χρονική στιγμή $tp_1 + 1$ το μοντέλο πρόβλεψης εξάγει στο υπόλοιπο σύστημα την τιμή $y_{TH}(i+1)$ κ.ο.κ. έως τη χρονική στιγμή $t + Nmp$, όταν οι αποθηκευμένες στο y_{TH} τιμές έχουν όλες περάσει από την έξοδο του μοντέλου και τα υπόλοιπα Dwork διανύσματα έχουν ολισθήσει κατά Nmp θέσεις αριστερά, δηλαδή έχουν διατηρήσει τις Nmp πιο πρόσφατες τιμές εισόδων και στόχων δικτύου και έχουν απαλλαγεί από τις Nmp πιο μακρινές. Πρέπει λοιπόν να γίνουν νέες προβλέψεις. Κατασκευάζεται ένα ίδιο δίκτυο NARX, με την ίδια δομή, και επαναλαμβάνεται η ίδια διαδικασία εκπαίδευσης, με τις ίδιες ρυθμίσεις, αλλά με τα νέα δεδομένα, προκειμένου να αντικατασταθεί το διάνυσμα y_{TH} με νέες τιμές. Κάθε Nmp χρονικές στιγμές κατασκευάζεται και εκπαιδεύεται ένα νέο δίκτυο, μέχρι το τέλος της προσομοίωσης. Η τελευταία πρόβλεψη που αφορά την τελευταία χρονική στιγμή της προσομοίωσης $t=end$ (τα τελευταία λεπτά του έτους) δίνεται ως σήμα στο σύστημα τη χρονική στιγμή $t=end-11$.

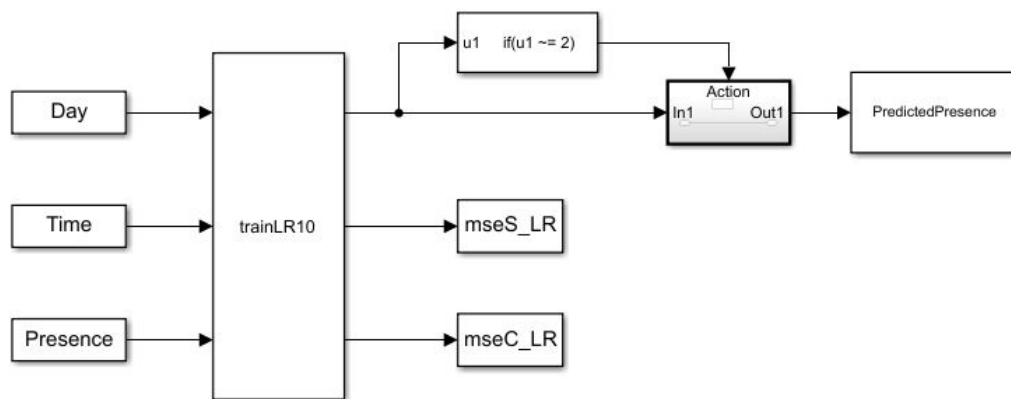
Η απεικόνιση όσων περιγράφηκαν φαίνεται παρακάτω:



Σχήμα 4.4: Κύλιση της χρονικής ακολουθίας για την περιοδική εκπαίδευση

Στην εικόνα 4.5 φαίνεται το μοντέλο πρόβλεψης (PredictionModel). Το συνολικό σύστημα προσομοίωσης ενεργοποιείται και εισέρχονται στο μοντέλο πρόβλεψης τα τρία σήματα εισόδου, που είναι το σήμα για τον τύπο της ημέρας (Day), το σήμα για την αριθμητική σειρά του timestep της ημέρας (Time) και το σήμα για την παρουσία/απουσία του κατοίκου τη δεδομένη στιγμή (Presence). Τα σή-

ματα οδηγούνται στο Level 2 MATLAB S-function block. Στις πρώτες N εμφανίσεις της συνάρτησης S-function, δηλαδή για τις πρώτες N χρονικές στιγμές δε γίνονται προβλέψεις, καθώς πρέπει πρώτα να συγκεντρωθούν δεδομένα για την εκπαίδευση του δικτύου. Για αυτές τις χρονικές στιγμές η συνάρτηση επιστρέφει την τιμή 2. Διαφορετικά επιστρέφει την τιμή 1 αν προβλέπεται παρουσία και την τιμή 0 αν προβλέπεται απουσία. Η έξοδος του S-function block οδηγείται σε ένα if block όπου ελέγχεται η τιμή της και εάν αυτή δεν είναι η τιμή 2, τότε κατευθύνεται στην έξοδο του μοντέλου (PredictedPresence) προκειμένου να οδηγηθεί στον ελεγκτή. Το $mseS_{LR}$ καταγράφει στο Workspace της MATLAB το μέσο τετραγωνικό σφάλμα κάθε εκπαίδευσης NARX ανοιχτού βρόχου και το $mseC_{LR}$ το μέσο τετραγωνικό σφάλμα για κάθε δίκτυο κλειστού βρόχου.



Σχήμα 4.5: Μοντέλο πρόβλεψης παρουσίας στο χώρο - Occupancy Prediction Model

Ένα θέμα που εξετάστηκε στο συγκεκριμένο μοντέλο αφορά την αρχικοποίηση των βαρών. Η προκαθορισμένη διαδικασία είναι να παράγονται βάρη με τυχαίες τιμές πριν ξεκινήσει η εκπαίδευση του δικτύου. Αυτή είναι και η διαδικασία που ακολουθήσαμε στα υπόλοιπα δίκτυα της εργασίας. Παρόλ' αυτά, εφόσον εδώ πρόκειται για περιοδική εκπαίδευση και ακολουθείται ακριβώς η ίδια διαδικασία κατασκευής και εκπαίδευσης, θεωρήσαμε ότι ίσως να χρειάζεται να χρησιμοποιούνται τα ίδια αρχικά βάρη σε κάθε περίοδο.

Έτσι, εξετάστηκαν δύο τρόποι για την παραγωγή προβλέψεων:

- A Παράγονται τυχαία αρχικά βάρη κάθε χρονική στιγμή που πραγματοποιείται κατασκευή και εκπαίδευση του δικτύου.
- B Παράγονται και αποθηκεύονται τα τυχαία αρχικά βάρη την πρώτη φορά που πραγματοποιείται κατασκευή και εκπαίδευση του δικτύου και χρησιμοποιούνται όλες τις επόμενες χρονικές στιγμές που επαναλαμβάνεται η διαδικασία.

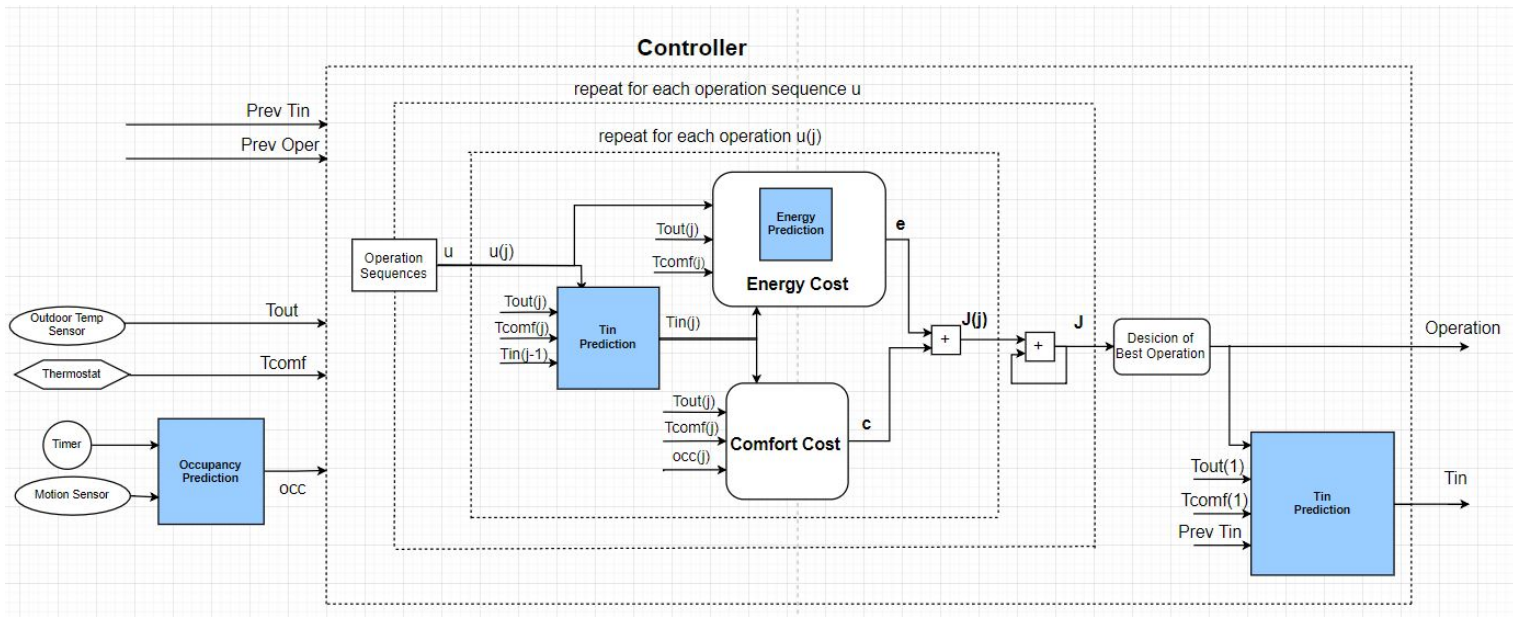
Επισημαίνεται ότι στην πρώτη χρονική στιγμή που γίνεται κατασκευή του δικτύου σε λειτουργία ανοιχτού βρόχου, η εκπαίδευση πραγματοποιείται $N_{trials} = 10$ φορές με καινούριες τυχαίες αρχικοποιήσεις των βαρών κάθε φορά. Όλες οι τιμές των αρχικών βαρών αποθηκεύονται σε έναν πίνακα. Στο τέλος της επαναληπτικής διαδικασίας, η εκπαίδευση γίνεται ξανά με τα αρχικά βάρη που εξασφάλισαν το μικρότερο μέσο τετραγωνικό σφάλμα. Στην υλοποίηση του συνολικού μοντέλου με τον τρόπο (α), κάθε χρονική στιγμή που απαιτείται νέα κατασκευή του δικτύου όλη η διαδικασία των N_{trials} επαναλαμβάνε-

ται. Οπότε συνολικά στην S-function υλοποιούνται $N_{trials} * N_p$ εκπαιδεύσεις, όπου N_p είναι ο αριθμός των χρονικών στιγμών που απαιτείται εκπαίδευση για νέες προβλέψεις. Στην υλοποίηση του συνολικού μοντέλου με τον τρόπο (β), η διαδικασία των N_{trials} υλοποιείται την πρώτη χρονική στιγμή που κατασκευάζεται δίκτυο και τα βάρη αποθηκεύονται στη μνήμη σε ένα Dwork διάνυσμα και επαναχρησιμοποιούνται σε κάθε επόμενη κατασκευή και εκπαίδευση δικτύου.

Τα αποτελέσματα βρίσκονται στο 5.3.1.

4.4 Μοντέλο ελέγχου

4.4.1 Μεθοδολογία



Το μοντέλο ελέγχου που αποτελεί το δευτερο τμήμα του συνολικού συστήματος, σε συγκεκριμένα σταθερά χρονικά διαστήματα τ , αποφασίζει για την άμεση ενεργοποίηση/ απενεργοποίηση (1/0) του συστήματος θέρμανσης/ψύξης.

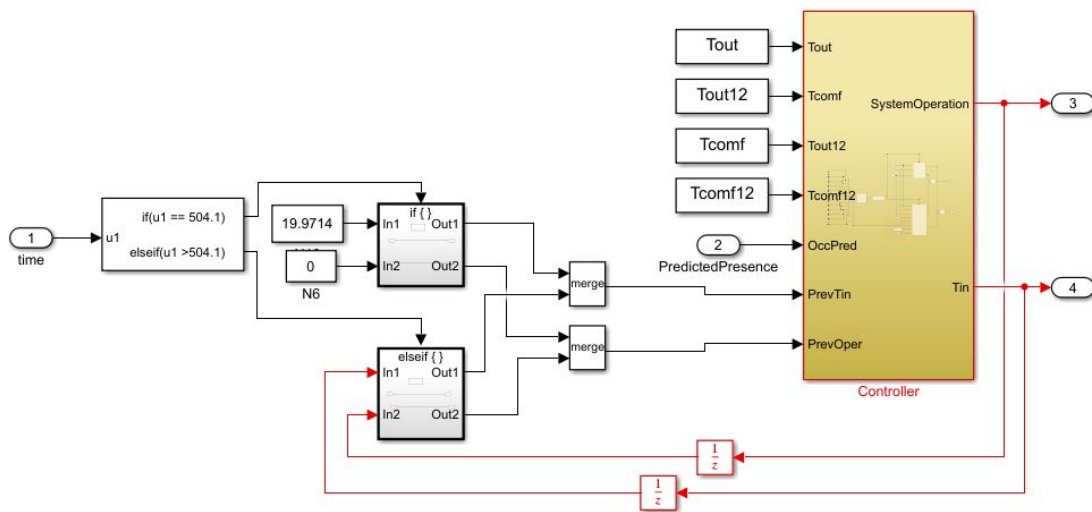
Αρχικά λαμβάνει, με χρονική περίοδο δέκα λεπτών, όπως έχουμε ορίσει στην παρούσα εργασία, τη δυαδική ακολουθία occ 12 σημάτων, που αντιπροσωπεύουν την παρουσία/απουσία (1/0) των κατοίκων για τις επόμενες δύο ώρες, έτσι όπως προβλέπεται από το μοντέλο του νευρωνικού δικτύου. Έχοντας ως δεδομένο το προβλεπόμενο πρόγραμμα των κατοίκων, και λαμβάνοντας επιπλέον πληροφορίες για την θερμοκρασία του εξωτερικού περιβάλλοντος και την τιμή που έχουν ορίσει οι κάτοικοι στο θερμοστάτη, εξετάζει διαφορετικές δυαδικές ακολουθίες, η καθεμία εκ των οποίων αποτελείται από 12 στοιχεία, που αφορούν τη μελλοντική λειτουργία των συσκευών θέρμανσης/ψύξης για το χρονικό ορίζοντα δύο ωρών. Αναζητά την ακολουθία με το βέλτιστο συνδυασμό ενεργειακής εξοικονόμησης και θερμικής άνεσης, δηλαδή αναζητά το μικρότερο κόστος J :

$$J = \sum_{t=t_0}^{t_0+\kappa} e(u_t) + c_u(x_t)$$

, όπου t_0 είναι το τέλος του χρονικού διαστήματος που μόλις προηγήθηκε, n είναι ο αριθμός των στοιχείων της ακολουθίας, u_t είναι η απόφαση του ελεγκτή για το χρονικό διάστημα t (on/off του κλιματιστικού), $e(u_t)$ είναι το ενεργειακό κόστος ανάλογα με την απόφαση u_t , x_t είναι η κατάσταση του περιβάλλοντος χώρου τη χρονική στιγμή t , η οποία περιλαμβάνει την εσωτερική θερμοκρασία T_{in} και την παρουσία/απουσία κατοίκων occ , και $c_u(x_t)$ είναι το κόστος της "δυσφορίας" του κατοίκου ανάλογα με την κατάσταση x_t .

Για κάθε ακολουθία u που εξετάζεται, αρχικά προβλέπεται η εσωτερική θερμοκρασία όπως θα τη διαμόρφωνε η λειτουργία του συστήματος θέρμανσης/ψύξης σύμφωνα με το u . Έπειτα, στηριζόμενος στην πρόβλεψη αυτή και στις υπόλοιπες εισόδους του, ο ελεγκτής υπολογίζει το ενεργειακό κόστος και το κόστος "απώλειας θερμικής άνεσης" και στη συνέχεια το άθροισμά τους. Αφού υπολογιστεί το συνολικό κόστος για κάθε ακολουθία, J_u , ο ελεγκτής εντοπίζει αυτό με τη μικρότερη τιμή κι έτσι έχει προβλέψει τη βέλτιστη ακολουθία. Το πρώτο στοιχείο της βέλτιστης ακολουθίας είναι και το σήμα εξόδου του ελεγκτή, το οποίο θα ενεργοποιήσει ή θα απενεργοποιήσει για τη χρονική περίοδο του τρέχοντος διαστήματος τ το σύστημα θέρμανσης σε χειμερινή περίοδο ή το σύστημα ψύξης σε θερινή περίοδο. Για κάθε νέα χρονική στιγμή της προσομοίωσης, δηλαδή για κάθε χρονικό διάστημα τ που διανύεται, ο ελεγκτής εξάγει μία νέα απόφαση.

4.4.2 Ανάλυση

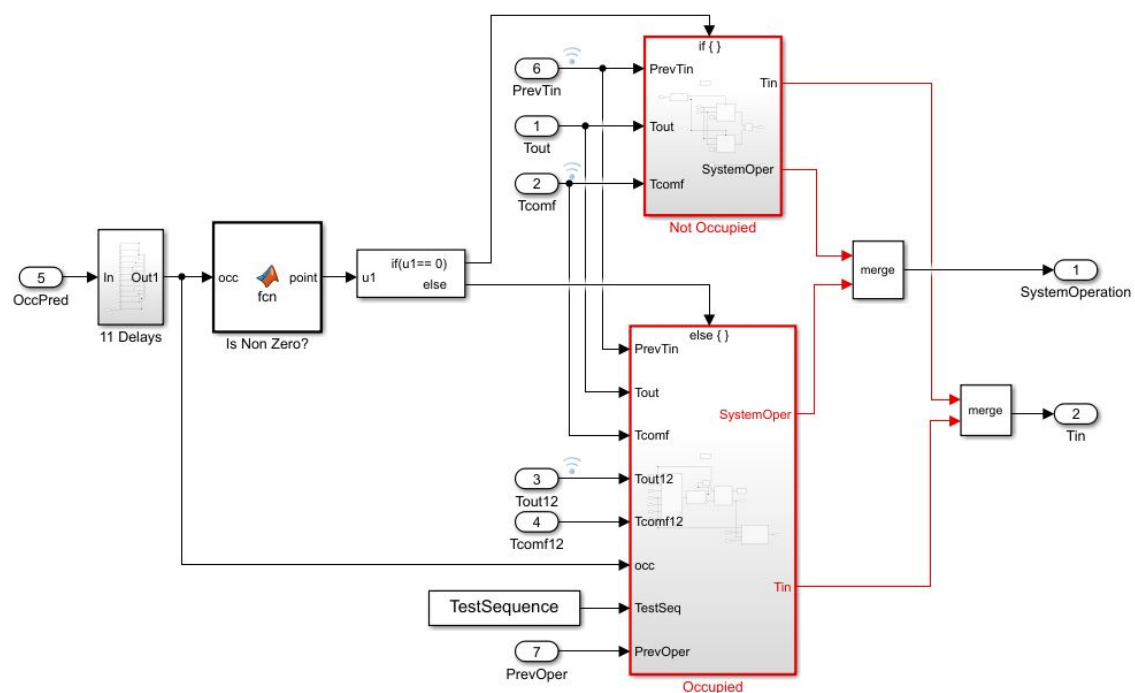


Σχήμα 4.6: Μοντέλο ελέγχου - Control Model

Έχουμε θεωρήσει ότι η εξωτερική θερμοκρασία για όλη τη διάρκεια του έτους είναι γνωστή και έχουμε χρησιμοποιήσει το χρονοδιάγραμμα εξωτερικής θερμοκρασίας του δελτίου καιρού της ενεργειακής προσομοίωσης. Δίνονται λοιπόν στο μοντέλο ως εισόδοι η εξωτερική θερμοκρασία T_{out} για την τρέχουσα στιγμή και ένα διάνυσμα 12 τιμών T_{out12} με την εξωτερική θερμοκρασία για την τρέχουσα στιγμή και τις επόμενες 11 χρονικές στιγμές. Θεωρώντας το ίδιο για τη θερμοκρασία άνεσης των κατοίκων δίνεται η θερμοκρασία άνεσης της τρέχουσας χρονικής στιγμής T_{comf} και ένα διάνυσμα 12 τιμών T_{comf12} με τη θερμοκρασία άνεσης για την τρέχουσα στιγμή και τις επόμενες 11 χρονικές στιγμές. Η χρησιμότητα των διανυσμάτων 12 τιμών θα φανεί αργότερα. Επιπλέον, το Control Model λαμβάνει ως εισόδους την έξοδο του Occupancy Prediction Model, PredictedPresence και με ανατροφοδότηση λαμβάνει την τιμή

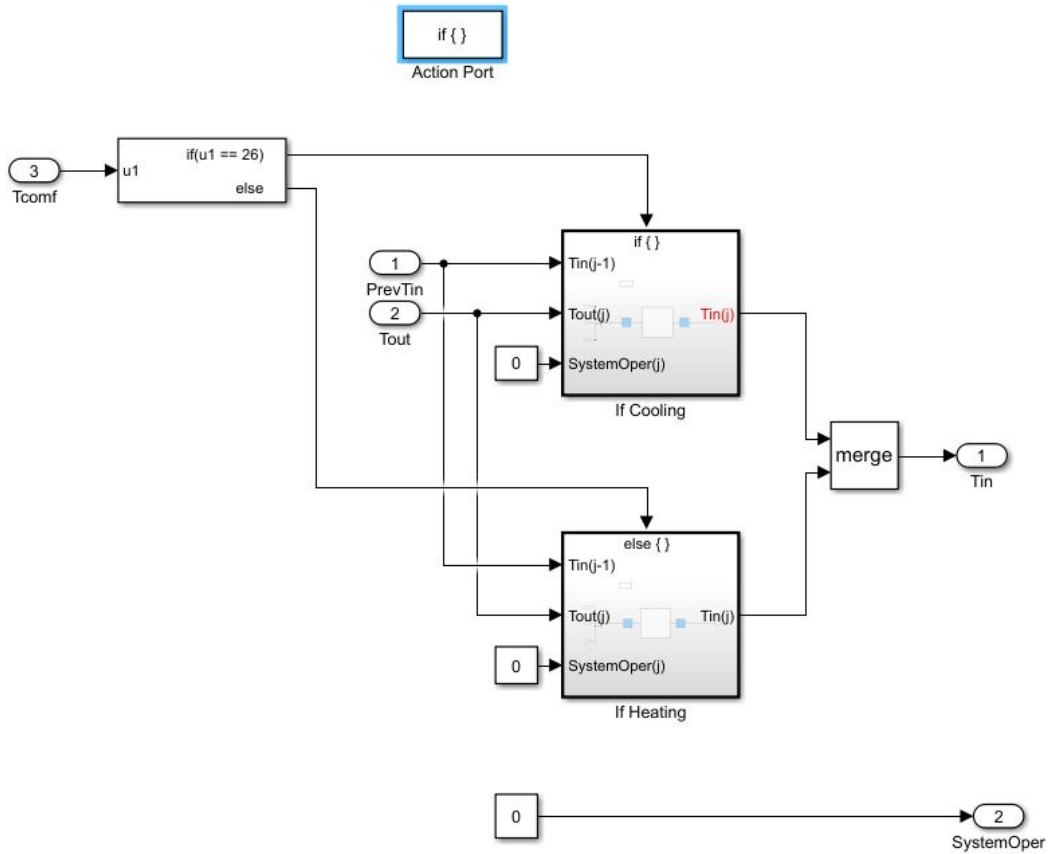
της εσωτερικής θερμοκρασίας της προηγούμενης χρονικής στιγμής όπως ορίστηκε στην έξοδο του μοντέλου.

Σε κάθε χρονική στιγμή τ , το Main Model λαμβάνει σήμα με την προβλέψη ανθρώπινης παρουσίας/απουσίας για τη χρονική στιγμή $\tau+11$. Θεωρούμε ότι τ είναι η τρεχούμενη χρονική στιγμή και ότι το πρώτο στοιχείο της ακολουθίας αποφάσεων του ελεγκτή, που αποτελεί και το σήμα εξόδου του, θα αφορά στη θέρμανση /ψύξη του χώρου για τη χρ. στιγμή τ . Με τη χρήση καθυστερήσεων (11 unit delays), δημιουργείται μία ακολουθία αποτελούμενη από $\kappa = 12$ timesteps. Έτσι, αγνοώντας τις πρώτες 12 προβλέψεις του parx νευρωνικού δικτύου, την χρονική στιγμή τ , ο ελεγκτής δέχεται πληροφορίες για κ timesteps (τ έως $\tau+\kappa-1$).



Σχήμα 4.7: Controller

Αν πρόκειται αποκλειστικά για μία ακολουθία μηδενικών, τότε η απόφαση του ελεγκτή για τη στιγμή τ είναι 0 (off), καθώς δεν υπάρχει λόγος να παραμείνει ανοιχτή ή να ξεκινήσει η λειτουργία θέρμανσης/ψύξης αν δεν προβλέπεται παρουσία του κατοίκου στο χώρο για τις επόμενες δύο ώρες. Επομένως τα σήματα PrevTin , Tout και Tcomf μπαίνουν στο υποσύστημα NotOccupied . Εκεί δίνεται πάντα η τιμή 0 στην έξοδο του SystemOperation και στην έξοδο του Tin δίνεται η πρόβλεψη της εσωτερικής θερμοκρασίας για την τρέχουσα χρονική στιγμή για $\text{SystemOperation} = 0$, όπως προκύπτει από το δίκτυο netTH (3.4.2) στο υποσύστημα IfHeating αν διανύεται χειμερινή περίοδος ή από το δίκτυο netTC (3.4.2) στο υποσύστημα IfCooling αν διανύεται θερινή περίοδος. Η διαδικασία για την πρόβλεψη του Tin αποτελεί το θερμικό μοντέλο το οποίο θα δούμε και στην συνέχεια.

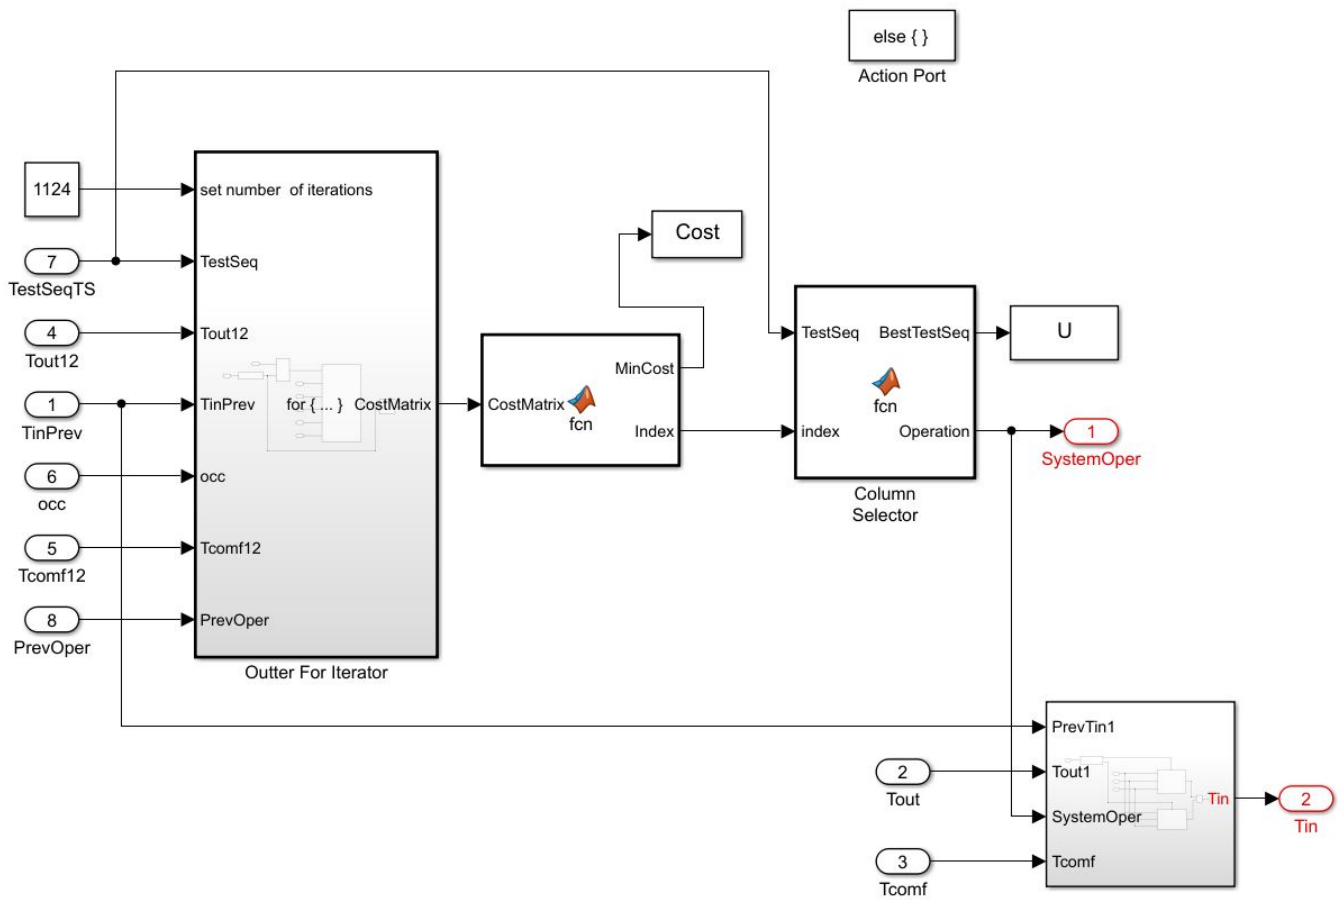


Σχήμα 4.8: Not Occupied Model

Σε περίπτωση που υπάρχει στην ακολουθία πρόβλεψη παρουσίας, τότε τα σήματα εισέρχονται στο μοντέλο Occupied και ξεκινάει η διαδικασία εύρεσης της βέλτιστης ακολουθίας λειτουργίας του συστήματος θέρμανσης/ψύξης. Οι περιπτώσεις που εξετάζονται αρχικά για την ακολουθία λειτουργίας του συστήματος θέρμανσης/ψύξης, ήταν όλοι οι πιθανοί συνδυασμοί για μια ακολουθία 12 δυαδικών στοιχείων, δηλαδή $2^{12} = 4096$ περιπτώσεις. Διαπιστώθηκε όμως ότι εξετάζοντας μόνο τις περιπτώσεις όπου υπάρχει μεταβολή κατάστασης το περισσότερο τέσσερις φορές, εκτός του ότι εξασφαλίζει σημαντική εξοικονόμηση του χρόνου προσομοίωσης, καταλήγει στα ίδια αποτελέσματα, εφόσον η συχνή αλλαγή κατάστασης της συσκευής θέρμανσης/ψύξης σε καμία περίπτωση δεν είναι βέλτιστη, ειδικά όσον αφορά στο ενεργειακό κόστος. Έτσι, οι περιπτώσεις προς εξέταση περιορίστηκαν σε 1124.

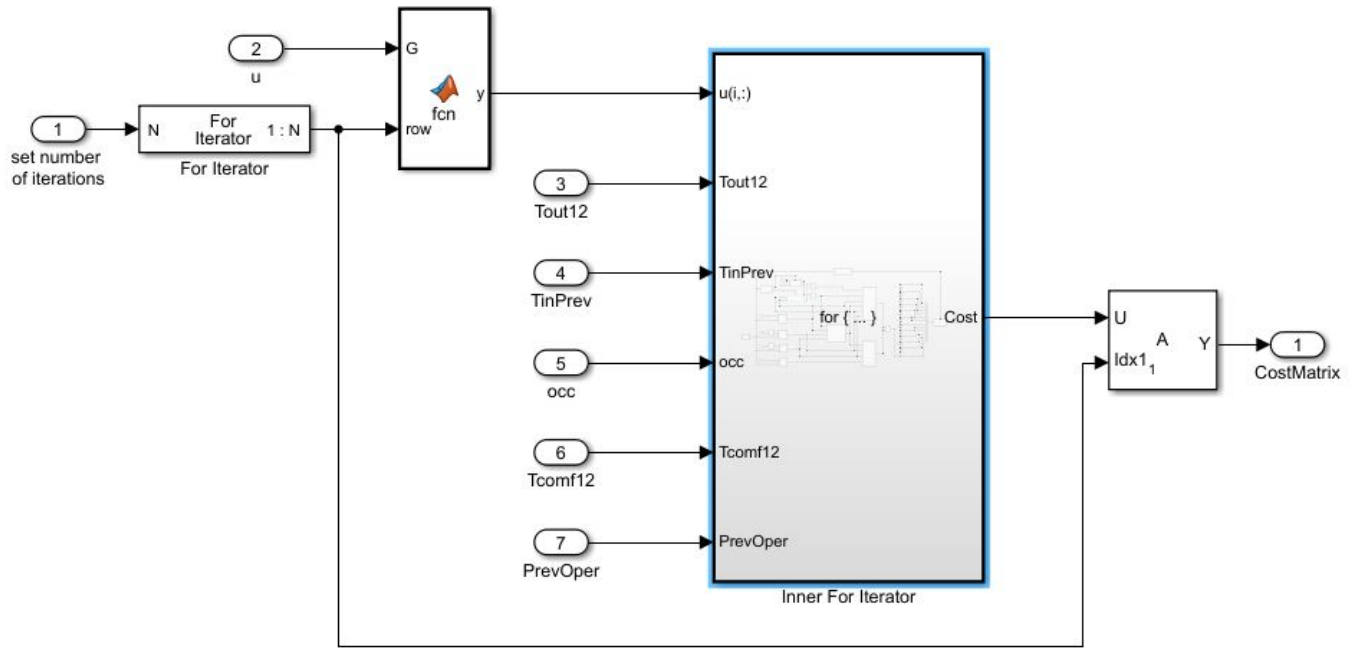
Κατασκευάστηκε λοιπόν ένας πίνακας 1124×12 ($i \times j$), ο οποίος δίνεται ως είσοδος στον ελεγκτή μέσω του Workspace στη MATLAB. Για κάθε μία από αυτές τις περιπτώσεις λειτουργίας της θέρμανσης/ψύξης για τον χρονικό ορίζοντα δύο ωρών (12 timesteps) υπολογίζεται ένα κόστος. Οι υπολογισμοί αυτοί κρατούνται σε έναν πίνακα CostMatrix (1124×1). Εντοπίζοντας το μικρότερο CostMatrix(i), μπορεί να θεωρηθεί ως βέλτιστη η ακολουθία $u(i)$. Συνεπώς, αν τη χρονική στιγμή τ εκτιμάται ότι θα υπάρχει κίνηση στο χώρο του καθιστικού κάποια στιγμή στα επόμενα 120 λεπτά, η έξοδος του ελεγκτή, το δυαδικό σήμα που ορίζει τη λειτουργία θέρμανσης/ψύξης, είναι το πρώτο στοιχείο της ακολουθίας: $u(\tau) = u(i, 1)$.

Επιπλέον, για τη λειτουργία του ελεγκτή στο timestep τ , εκτιμάται η εσωτερική θερμοκρασία $T_{in}(\tau)$. Για αυτό το λόγο χρησιμοποιείται ξανά το θερμικό μοντέλο, στο οποίο οδηγείται η απόφαση λειτουργίας $u(\tau)$, η εξωτερική θερμοκρασία $T_{out}(\tau)$, η θερμοκρασία "άνεσης" T_{comf} και η εσωτερική θερμοκρασία, όπως εκτιμήθηκε από τον ελεγκτή στο προηγούμενο timestep, $T_{in}(\tau - 1)$. Η έξοδος του θερμικού μοντέλου είναι η δεύτερη έξοδος του ελεγκτή.

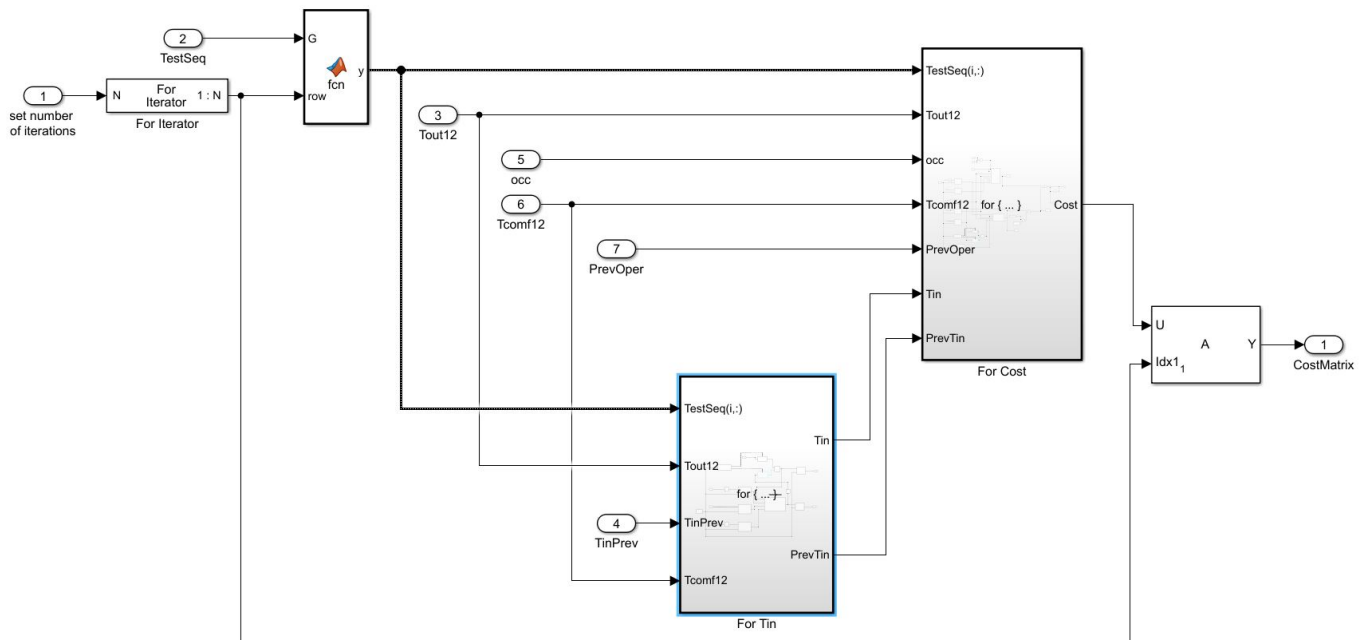


Σχήμα 4.9: Occupied Model

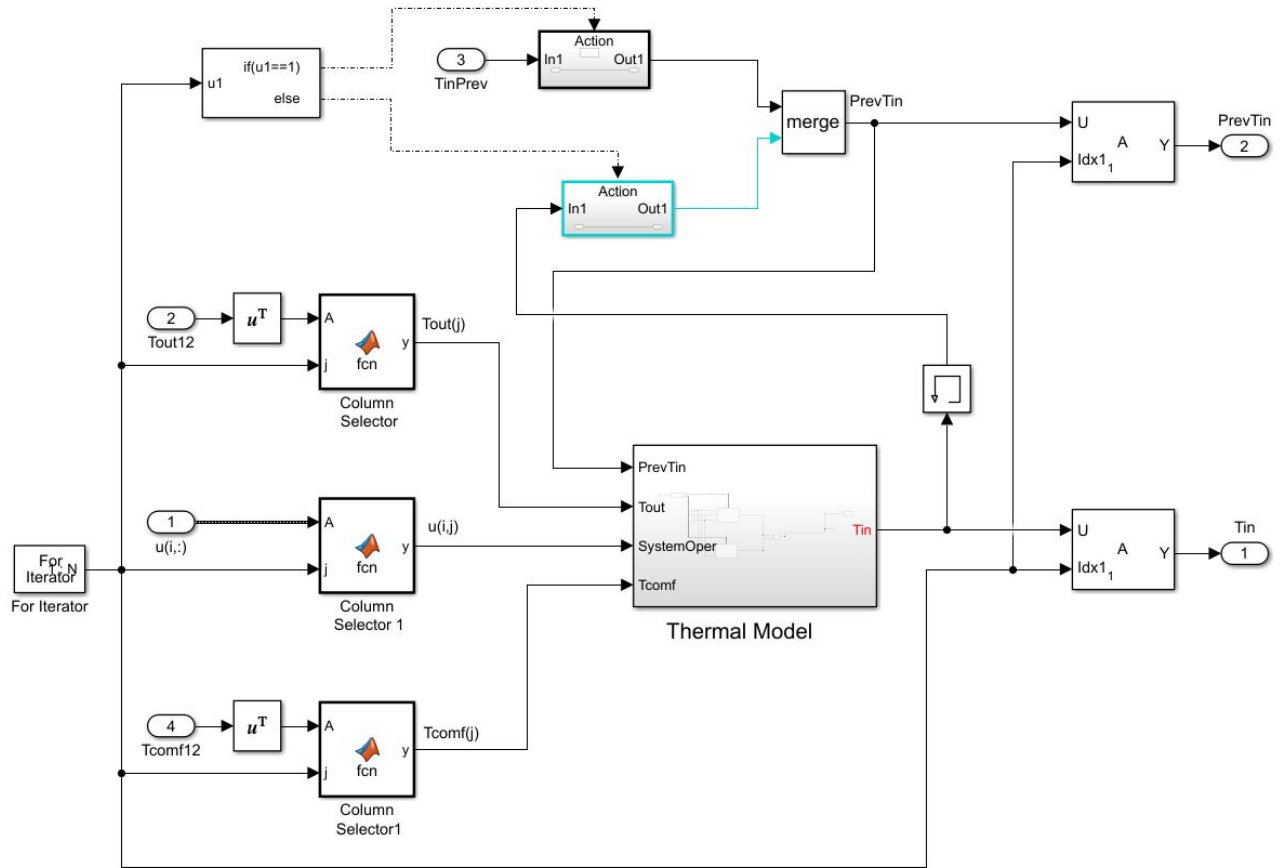
Ακολουθεί η διαδικασία που βρίσκει το συνολικό κόστος των j timesteps. Ο εξωτερικός βρόχος της εικόνας 4.10 επαναλαμβάνεται για κάθε μία από τις i δυαδικές ακολουθίες, δηλαδή εκτελείται i φορές, και σε κάθε κύκλο του υπολογίζεται το κόστος J για κάθε ακολουθία.



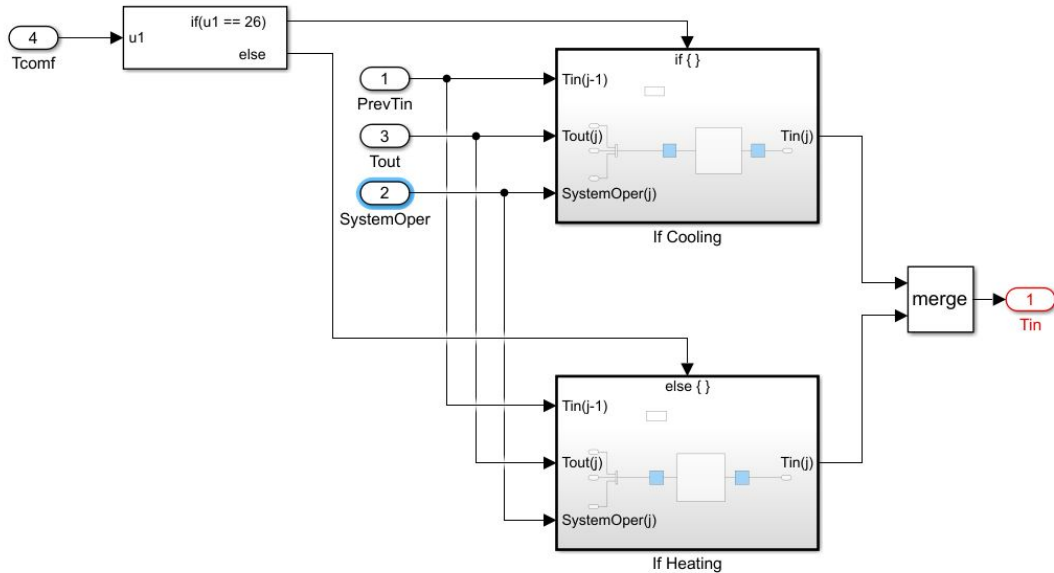
Σχήμα 4.10: Outer For Iterator Model



Σχήμα 4.11: Inner For Iterator Model



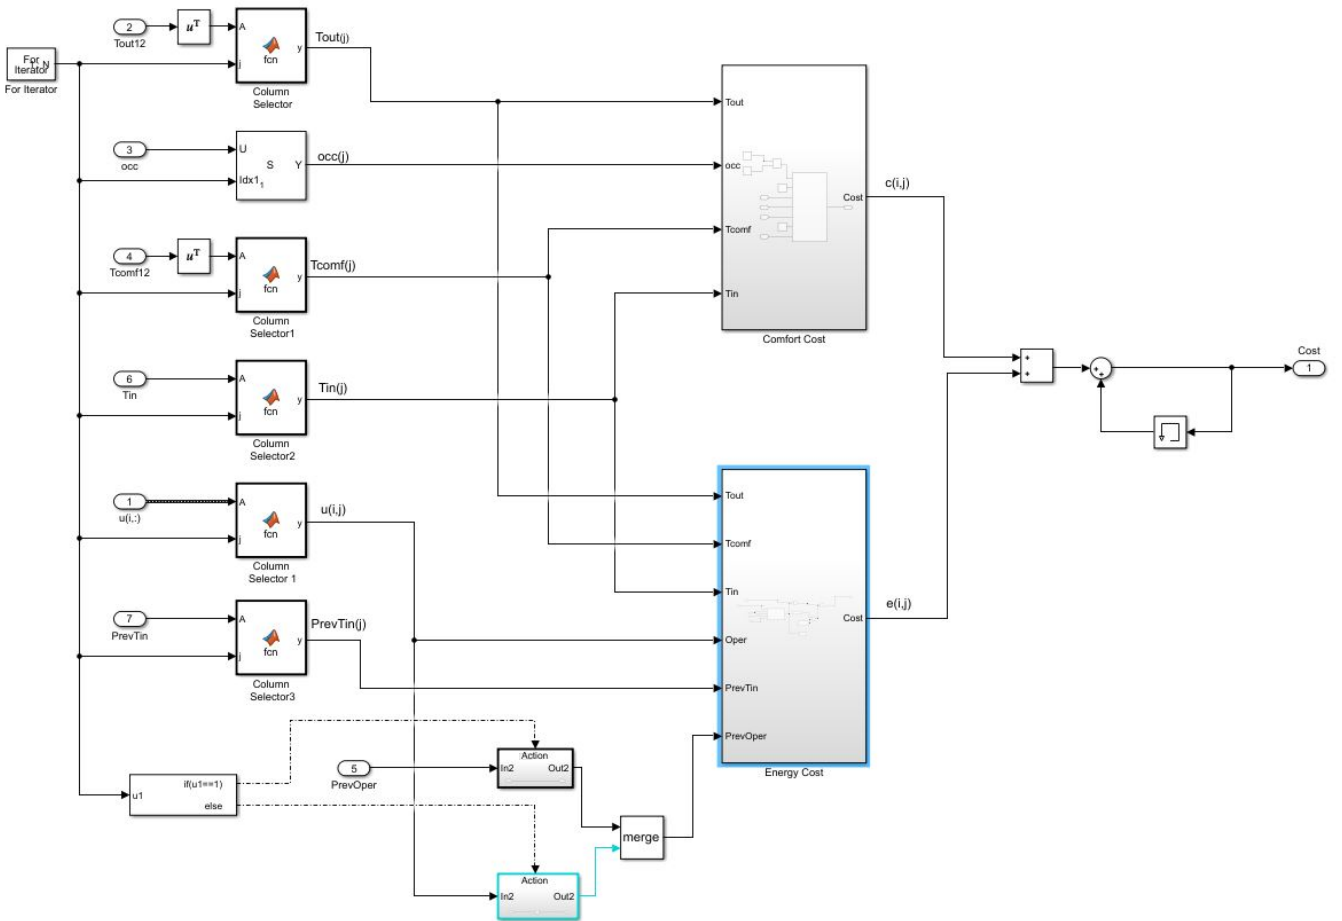
Σχήμα 4.12: For Tin



Σχήμα 4.13: Thermal Model

Στο βρόχο ForTin υπολογίζεται η εσωτερική θερμοκρασία για κάθε j , $Tin_{i,j}(t)$, και οι τιμές που

προκύπτουν αποθηκεύονται σε έναν πίνακα, καθώς χρειάζονται για τον υπολογισμό του κόστους. Για την εκτίμηση της θερμοκρασίας $Tin(i, j)$, χρησιμοποιείται το θερμικό μοντέλο (Thermal Model). Οδηγούνται λοιπόν στην είσοδο του θερμικού μοντέλου η εξεταζόμενη απόφαση $u(i, j)$, η τιμή της εξωτερικής θερμοκρασίας $Tout_j(t)$, που είναι ανεξάρτητη του i , η τιμή της εσωτερικής θερμοκρασίας του αμέσως προηγούμενου χρονικού διαστήματος, που προκύπτει είτε από την εκτιμώμενη Tin της προηγούμενης χρονικής στιγμής προσομοίωσης $t-1$, αν πρόκειται για το πρώτο στοιχείο της εξεταζόμενης ακολουθίας αποφάσεων $j = 1$, είτε από την τιμή που προέκυψε από το θερμικό μοντέλο στον προηγούμενο κύκλο του εσωτερικού βρόγχου $Tin(i, j - 1)$, και τέλος η τιμή της "θερμοκρασίας άνεσης" $Tcomf(j)$, προκειμένου να καθοριστεί αν σκόπος είναι η θέρμανση ή η ψύξη του χώρου. Το μοντέλο διακρίνει μέσω της τιμής του $Tcomf$ αν η χρονική στιγμή t ανήκει σε χειμερινή ή θερινή περίοδο και αναλόγως αποφασίζει, στέλλοντας τα σήματα Tin , $Tout$ και u στο νευρωνικό δίκτυο για τη λειτουργία θέρμανσης ή στο νευρωνικό δίκτυο για τη λειτουργία ψύξης αντίστοιχα.



Σχήμα 4.14: For Cost

Εφόσον βρεθεί το $Tin(i, :)$ για όλα τα j , το σύστημα είναι σε θέση να υπολογίσει το κόστος J .

Σε κάθε κύκλο του βρόγχου ForCost, με βάση την προβλεπόμενη παρουσία ή απουσία $occ_j(t)$ (1 για παρουσία και 0 για απουσία) και την εξεταζόμενη τιμή για on/off του συστήματος θέρμανσης/ψύξης $u_{(i,j)}(t)$ (1 για on και 0 για off), υπολογίζεται το ενεργειακό κόστος $e(i, j)$, στο Energy Cost Model και το κόστος "δυσφορίας" $c(i, j)$, στο Comfort Cost Model. Το κόστος e εξαρτάται μόνο από την απόφαση του ελεγκτή, ενώ το κόστος "δυσφορίας" c εξαρτάται από την ανθρώπινη παρουσία/απουσία $occ_j(t)$

και την εσωτερική θερμοκρασία $Tin_{i,j}(t)$, η οποία όπως είδαμε, χρειάζεται το $u_{i,j}(t)$ για να υπολογιστεί ($Tin(t) = Tin_u(t)$). Συνεπώς το c επίσης εξαρτάται από την απόφαση του ελεγκτή:

$$c_u(occ(t), Tin(t)) = p[o(t) = 1]c(1, Tin_u(t)) + p[o(t) = 0]c(0, Tin_u(t))$$

Αθροίζοντας τις εξόδους των δύο μοντέλων, έχουμε το κόστος για το timestep $\tau + j - 1$ της εξετάζουσας ακολουθίας i :

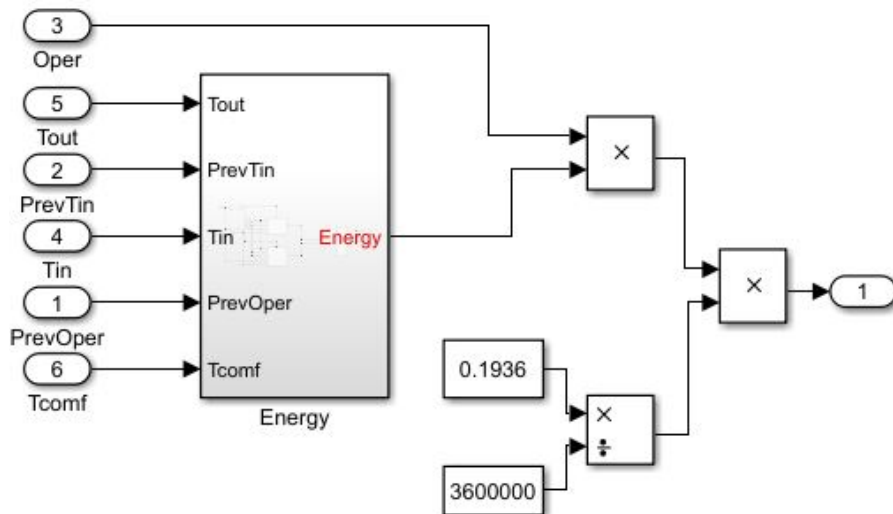
$$e(i, j) + c(i, j) = e_u(i, j) + c_{occ, Tin}(i, j)$$

. Στη συνέχεια, αθροίζονται οι τιμές του κόστους για κάθε j και το άθροισμα αυτό αποτελεί το κόστος J

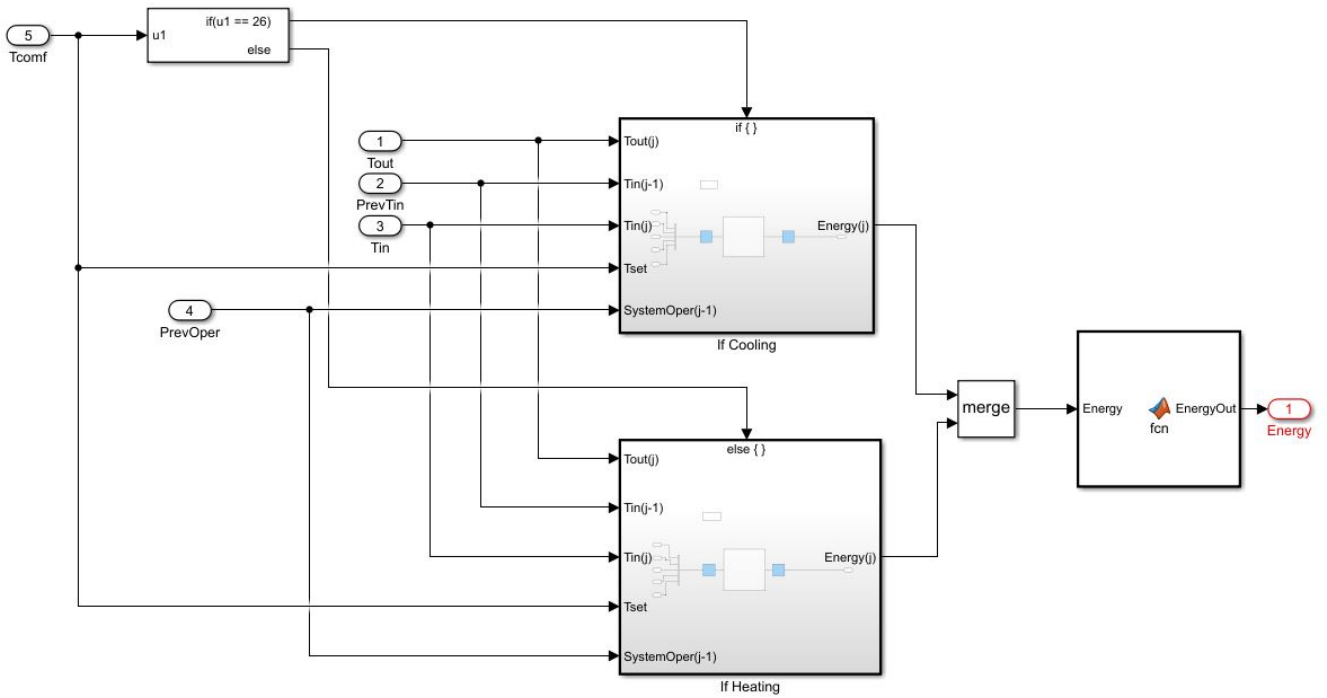
για έναν κύκλο i του εξωτερικού βρόγχου επανάληψης, δηλαδή το κόστος για την ακολουθία αποφάσεων που εξετάζεται. Με την ίδια επαναλαμβανόμενη διαδικασία, υπολογίζεται το κόστος J για κάθε έναν από τους $I=1124$ συνδυασμούς αποφάσεων. Όλα τα J συγκεντρώνονται σε έναν πίνακα, ώστε να συγκριθούν και να βρεθεί αυτό με τη μικρότερη τιμή.

Έτσι, το συνολικό σύστημα που κατασκευάστηκε ζητάει στις εισόδους του κάθε χρονική στιγμή την εξωτερική θερμοκρασία $Tout$, τη θερμοκρασία που επιθυμούν οι κάτοικοι για το χώρο τους $Tcomf$, τον προσδιορισμό της ημέρας της εβδομάδας και του δεκάλεπτου της ημέρας στα οποία ανήκει η τρέχουσα χρονική στιγμή ($Day, Time$) και το σήμα για την παρουσία ή όχι κάποιου στο χώρο και αποφασίζει για την ενεργοποίηση ή απενεργοποίηση της θέρμανσης / ψύξης $SystemOperation$. Για τη διεξαγωγή αποτελεσμάτων για την απόδοση του συστήματος ορίζεται ως έξοδος εκτός από το $SystemOperation$ και το Tin , που είναι οι θερμοκρασίες που προέβλεψε το θερμικό μοντέλο με βάση το $SystemOperation$.

4.4.3 Κόστος Ενεργειακής Κατανάλωσης



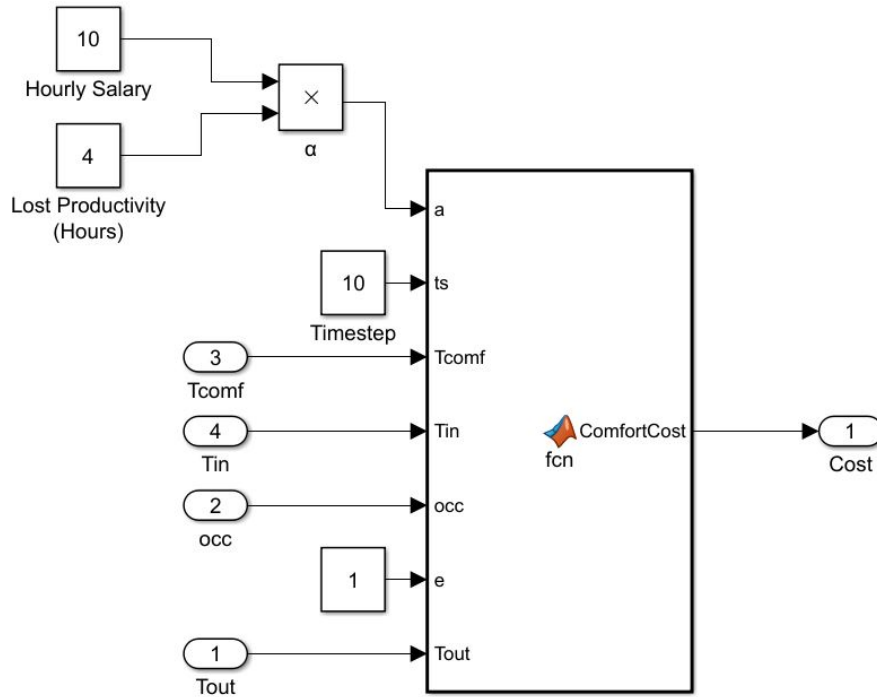
Σχήμα 4.15: Energy Cost Model



Σχήμα 4.16: Energy Model

Για την εκτίμηση του κόστους e , χρησιμοποιήθηκε το $netEnergyH$ για τη χειμερινή περίοδο και το $netEnergyC$ για τη θερινή περίοδο, όπως περιγράφηκαν στην ενότητα 3.4.3. Το κατάλληλο για την τρέχουσα χρονική στιγμή δίκτυο δέχεται για εισόδους τις τιμές των $T_{out}(j)$, $T_{in}(i, j)$, $T_{in}(i, j - 1)$, $T_{comf}(j)$, καθώς και την τιμή της απόφασης του ελεγκτή για το προηγούμενο χρονικό διάστημα, που είναι είτε η απόφαση του προηγούμενου timestep προσομοίωσης $u(\tau - 1)$, είτε το αμέσως προηγούμενο στοιχείο της εξεταζόμενης ακολουθίας αποφάσεων $u_{\tau}(i, j - 1)$. Η έξοδος του Energy Model είναι η ενέργεια σε Joule που καταναλώνεται για τις συγκεκριμένες μεταβλητές περιβάλλοντος. Σύμφωνα με την Επιτροπή Ενέργειας του Ευρωπαϊκού Συμβουλίου και με βάση τα πιο πρόσφατα στοιχεία όπως δημοσιεύονται από τη Eurostat [6], το κόστος της κιλοβατώρας kWh για την Ελλάδα είναι 0,1936€. Έτσι, σε κάθε timestep, για την μετατροπή της κατανάλωσης από Joule σε €, εφόσον σε 3,6MJ αντιστοιχούν 0,1936€, η έξοδος του νευρωνικού δικτύου πολλαπλασιάζεται με τον παράγοντα $\frac{0.1936}{3600000}$ και προκύπτει το Energy Cost $e_u(i, j)$.

4.4.4 Κόστος Απώλειας Θερμικής Άνεσης



Σχήμα 4.17: Comfort Cost Model

Όσον αφορά το κόστος "δυσφορίας", θεωρούμε ότι οι κάτοικοι έχουν ορίσει ως θερμοκρασία με την οποία νιώθουν άνετα στο χώρο του καθιστικού (T_{comf}) τους $22^{\circ}C$ για τους χειμερινούς μήνες και τους $26^{\circ}C$ για τους καλοκαιρινούς. Όταν το σπίτι είναι άδειο, το κόστος είναι μηδενικό, ανεξαρτήτως της θερμοκρασίας. Διαφορετικά, το κόστος είναι μία μονοτονική συνάρτηση της απόκλισης της πραγματικής εσωτερικής θερμοκρασίας από την ορισμένη από τους κατοίκους θερμοκρασία. Καθώς δεν υπάρχει μονάδα μέτρησης της θερμικής άνεσης, έχουν καταγραφεί πολλοί τρόποι για τον υπολογισμό της. Λόγω του ότι θέλουμε να γίνει η μέτρηση του κόστους σε €, ώστε να μπορεί να προστεθεί στο ενεργειακό κόστος e , χρησιμοποιήσαμε την προσέγγιση που έχει δοθεί στο Neurothermostat [20]. Το κόστος δυσφορίας ερμηνεύεται ως η χαμένη παραγωγικότητα ενός ανθρώπου που προσπαθεί να εργαστεί σε ένα σπίτι που είναι κατά $5^{\circ}C$ πιο κάτω ή κατά $5^{\circ}C$ πιο πάνω από την επιθυμητή θερμοκρασία για ένα χειμερινό ή για ένα καλοκαιρινό μήνα αντίστοιχα για το διάστημα 24 ωρών. Αν η απώλεια αυτή ονομαστεί ρ και μετρηθεί σε ώρες και αν θεωρήσουμε ότι γ είναι ο ωριαίος μισθός του ατόμου αυτού, τότε $\alpha = \gamma \cdot \rho$ είναι ο παράγοντας μετατροπής της μονάδας μέτρησης της "δυσφορίας" σε ευρώ. Προκύπτουν λοιπόν, δύο διαφορετικές εξισώσεις, μία για τη χειμερινή και μία για τη θερινή περίοδο. Άρα:

$$c(o, T_{in}) = occ_j(t) \alpha \frac{ts}{24 * 60} \frac{\max(0, |T_{comf} - T_{in}| - \varepsilon)^2}{25}$$

, όταν $T_{comf} = 22^{\circ}C$ και

$$c(o, T_{in}) = occ_j(t) \alpha \frac{ts}{24 * 60} \frac{\max(0, |T_{in} - T_{comf}| - \varepsilon)^2}{25}$$

, όταν $T_{comf} = 26^{\circ}C$,

όπου ο τρίτος παράγοντας κλιμακώνει το κόστος από ένα εικοσιτετράωρο στο διάστημα των 10 λεπτών και το τελευταίο κλάσμα παράγει τη συνάρτηση "δυσφορίας", κλιμακώνοντας έτσι ώστε μία απόκλιση $5^{\circ}C$ να παράγει μία "μονάδα δυσφορίας", με μία νεκρή ζώνη από $T_{comf} - \varepsilon$ μέχρι $T_{comf} + \varepsilon$.

Στην περίπτωση μας, ορίστηκε ο ωριαίος μισθός $\gamma=10\text{€}$, το δυαδικό σήμα εξόδου occ_j όπως λαμβάνεται από την έξοδο του νευρωνικού δικτύου 1, το $t_s = 10min = 600s$, το T_{in} η έξοδος του νευρωνικού δικτύου 2 (Θερμικό μοντέλο) και το "περιθώριο θερμοκρασιακής άνεσης" $\varepsilon = 1$. Η απώλεια παραγωγικότητας μπορεί να τροποποιείται ανάλογα με το πόση σημασία δίνουν οι κάτοικοι στη θερμική τους άνεση και αν έχει προτεραιότητα συγκριτικά με την εξοικονόμηση ενέργειας. Στην εργασία επιλέχθηκε η τιμή $\rho=4$. Η επιλογή της κατάλληλης εξίσωσης για το timestep τ και ο υπολογισμός γίνεται σε μία συνάρτηση (MATLAB function) και στην έξοδό της προκύπτει το Comfort Cost $c_{occ}(j), T_{in}(i, j)$.

4.5 Εναλλακτική πολιτική θέρμανσης / ψύξης

Για να συγκρίνουμε την αποδοτικότητα του συστήματος που κατασκευάσαμε χρησιμοποιήσαμε το idf αρχείο του EnergyPlus στο οποίο η λειτουργία του συστήματος θέρμανσης/ψύξης για το χώρο του καθιστικού, ενεργοποιείται όποτε βρίσκεται κάποιος στο χώρο, και η θερμοκρασία ρυθμίζεται ώστε να μην πέφτει πιο χαμηλά από τους $22^{\circ}C$ για τη χειμερινή περίοδο και να μην ξεπερνά τους $26^{\circ}C$ τη θερινή περίοδο. Πρόκειται για την προσομοίωση που υλοποιήθηκε στο Κεφάλαιο 2. Απο το αρχείο αυτό συγκεντρώσαμε τα προκύπτοντα ετήσια χρονοδιαγράμματα για την εσωτερική θερμοκρασία του χώρου, την ενέργεια που καταναλώνεται για τη θέρμανση του χώρου και την ενέργεια που καταναλώνεται για την ψύξη του χώρου με περίοδο $\tau = 10min$. Πέραν του χρονοδιαγράμματος λειτουργίας του συστήματος θέρμανσης/ψύξης όλες οι άλλες παράμετροι και ρυθμίσεις της ενεργειακής προσομοίωσης είναι κοινές για τις δύο περιπτώσεις, όπως και το δελτίο καιρού.

Κεφάλαιο 5

Αποτελέσματα

5.1 Αποτελέσματα ενεργειακής προσομοίωσης πριν τη χρήση του ελεγκτή

Από την προσομοίωση του μοντέλου της κατοικίας για τη διάρκεια ενός έτους προέκυψε πως η συνολική ετήσια ενεργειακή κατανάλωση είναι **119.25 GJ**.

Όσον αφορά την απόδοση της θερμικής ζώνης Living Room, στον πίνακα που ακολουθεί καταγράφονται τα χαρακτηριστικά της ζώνης όσον αφορά τις επιφάνειες και τα φορτία, όπως προέκυψαν από το γεωμετρικό σχεδιασμό και τις ενεργειακές ρυθμίσεις.

Zone Summary	
Area [m2]	51.39
Volume [m3]	154.17
Above Ground Gross Wall Area [m2]	75.60
Underground Gross Wall Area [m2]	0.00
Window Glass Area [m2]	16.82
People [m2 per person]	12.85
Plug and Process [W/m2]	27.243

Σχήμα 5.1: Χαρακτηριστικά θερμικής ζώνης - Επιφάνειες και φορτία

Ακολουθούν τα χαρακτηριστικά του HVAC συστήματος ψύξης και θέρμανσης.

	Cooling	Heating
Design Load [W]	1953.25	2467.69
Design Load per Area [W/m ²]	38.01	48.02
Design Air Flow [m ³ /s]	0.135	0.114
Date/Time Of Peak {TIMESTAMP}	7/21 17:30	2/21 14:00
Thermostat Setpoint Temperature at Peak Load [C]	26.00	22.00
Indoor Temperature at Peak Load [C]	26.00	22.00
Indoor Humidity Ratio at Peak Load [kgWater/kgAir]	0.00928	0.00715
Outdoor Temperature at Peak Load [C]	34.46	4.80
Outdoor Humidity Ratio at Peak Load [kgWater/kgAir]	0.00948	0.00542
Minimum Outdoor Air Flow Rate [m ³ /s]	0.028	0.028

Σχήμα 5.2: HVAC σύστημα ψύξης και θέρμανσης

Τα ετήσια θερμικά φορτία φαίνονται στον παρακάτω πίνακα:

Annual Sensible Heat Gain	
HVAC Terminal Unit Sensible Air Heating [GJ]	3,333
HVAC Terminal Unit Sensible Air Cooling [GJ]	-2,372
People Sensible Heat Addition [GJ]	1,589
Equipment Sensible Heat Addition [GJ]	0,588
Window Heat Addition [GJ]	13,306
Infiltration Heat Addition [GJ]	0,288
Window Heat Removal [GJ]	-4,154
Infiltration Heat Removal [GJ]	-7,733
Opaque Surface Conduction and Other Heat Removal [GJ]	-4,844


Σχήμα 5.3: Ετήσια θερμικά φορτία

Καταγράφηκαν τα θερμικά κέρδη και οι απώλειες στη ζώνη Living Room για τη χρονική στιγμή όπου εντοπίζονται τα υψηλότερα φορτία (Peak Time):

	Cooling	Heating
Time of Peak {TIMESTAMP}	06-JUN-15:11	16-JAN-16:11
HVAC Terminal Unit Sensible Air Heating [W]	0	9371,67
HVAC Terminal Unit Sensible Air Cooling [W]	-3131,92	0
People Sensible Heat Addition [W]	193,34	0
Window Heat Addition [W]	1105,68	204,09
Infiltration Heat Addition [W]	0	0
Opaque Surface Conduction and Other Heat Addition [W]	1915,13	0
Equipment Sensible Heat Removal [W]	0	0
Window Heat Removal [W]	0	0
Infiltration Heat Removal [W]	-82,23	-320,01
Opaque Surface Conduction and Other Heat Removal [W]	0	-9255,76


Σχήμα 5.4: Θερμικά κέρδη και απώλειες για τη χειμερινή και τη θερινή περίοδο

Η εσωτερική θερμοκρασία όπως διαμορφώνεται καθ' όλη τη διάρκεια του έτους φαίνεται στην εικόνα που ακολουθεί.




Σχήμα 5.5: Θερμοκρασία περιβάλλοντος και Εσωτερική θερμοκρασία με τη χρήση απλού θερμοστάτη

Η κατανάλωση ενέργειας του χώρου που εξετάζουμε όλες τις χρονικές στιγμές της χειμερινής περιόδου φαίνεται παρακάτω (οι χρονικές στιγμές της θερινής περιόδου έχουν παραλειφθεί).



Σχήμα 5.6: Κατανάλωση ενέργειας τη χειμερινή περίοδο

Η κατανάλωση ενέργειας όλες τις χρονικές στιγμές της θερινής περιόδου φαίνεται παρακάτω (αντίστοιχα οι χρονικές στιγμές της χειμερινής περιόδου έχουν παραλειφθεί).



Σχήμα 5.7: Κατανάλωση ενέργειας τη θερινή περίοδο

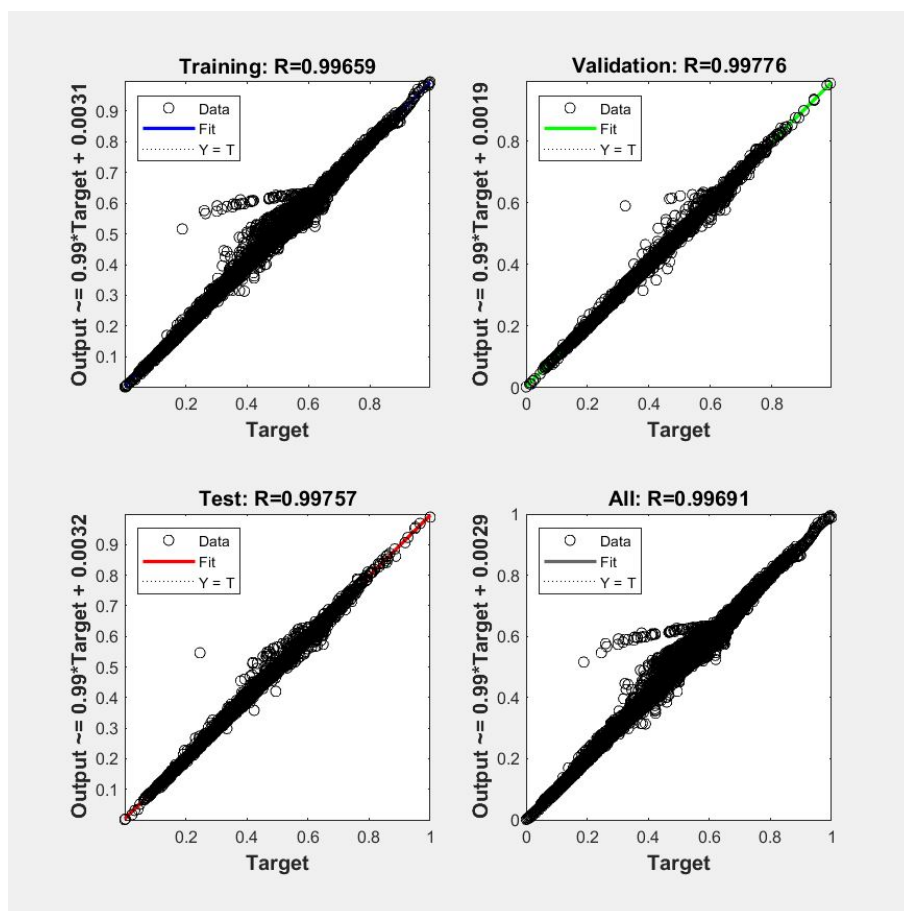
5.2 Αποτελέσματα των εκπαιδευμένων τεχνητών νευρωνικών δικτύων

Για την εκπαίδευση των δικτύων και την εξαγωγή αποτελεσμάτων χρησιμοποιήθηκε το γραφικό περιβάλλον διεπαφής χρήστη (GUI - graphical user interface) που διαθέτει η MATLAB για το σκοπό αυτό, το Neural network training tool. Καλείται με την εντολή `nntraintool`.

5.2.1 Αποτελέσματα για την πρόβλεψη της εσωτερικής θερμοκρασίας τη χειμερινή περίοδο


Από την εκπαίδευση του `netTH`, προέκυψε μέσο τετραγωνικό σφάλμα $mse = 1.7606 * 10^{-4}$. Το ιδανικό μέσο τετραγωνικό σφάλμα, με βάση τον αριθμό των περιπτώσεων προς εκπαίδευση και τις τιμές τους, βρέθηκε ότι είναι $mseGoal = 1.0603 * 10^{-4}$. Η εκπαίδευση δεν έφτασε το στόχο αλλά σταμάτησε όταν το λάθος επικύρωσης απέτυχε να μειωθεί για έξι συνεχόμενες επαναλήψεις.

Στο παρακάτω διάγραμμα φαίνονται οι σχέσεις στόχων - εξόδων για τα σετ εκπαίδευσης, επικύρωσης και δοκιμής και τέλος για το σύνολο. Για τέλεια εφαρμογή, η τιμή R πρέπει να είναι ίση με 1 και τα δεδομένα πρέπει να βρίσκονται πάνω στη γραμμή των 45 μοιρών. Στην περίπτωση μας, η εφαρμογή είναι αρκετά καλή με κάποιες, λίγες για το πλήθος των δεδομένων μας εξόδους, να ξεφεύγουν αρκετά από τη γραμμή των 45 μοιρών.




Σχήμα 5.8: Σχέση στόχων - εξόδων εκπαίδευσης για το `netTH`

Αν υπάρχουν δεδομένα με εφαρμογή σημαντικά χειρότερη από την πλειοψηφία των περιπτώσεων, αυτό μπορεί να φανεί στο ιστόγραμμα λάθους, όταν υπάρχουν τιμές μακριά από το 0. Όπως βλέπουμε από το ιστόγραμμα που ακολουθεί, το οποίο αφορά τα δεδομένα του τεστ δοκιμής, δεν υπάρχει ιδιαίτερο πρόβλημα εφαρμογής, καθώς δε φαίνεται να βρίσκεται κάποιο σφάλμα πολύ μακριά από το 0.




Σχήμα 5.9: Ιστόγραμμα σφάλματος για το netTH


Στο δίκτυο εφαρμόστηκαν τα δεδομένα της μίας εβδομάδας (1008 περιπτώσεις) που δε χρησιμοποιήθηκαν στην εκπαίδευση, προκειμένου να διαπιστώσουμε πως διαχειρίζεται άγνωστα δεδομένα. Παρακάτω βλέπουμε τους στόχους, τις εξόδους και τα σφάλματα για τα δεδομένα αυτά. Φαίνεται ότι για τη συντριπτική πλειοψηφία των τιμών τα σφάλματα είναι ασήμαντα.



Σχήμα 5.10: Στόχοι και έξοδοι για το netTH σ



Σχήμα 5.11: Σφάλματα για το netTH



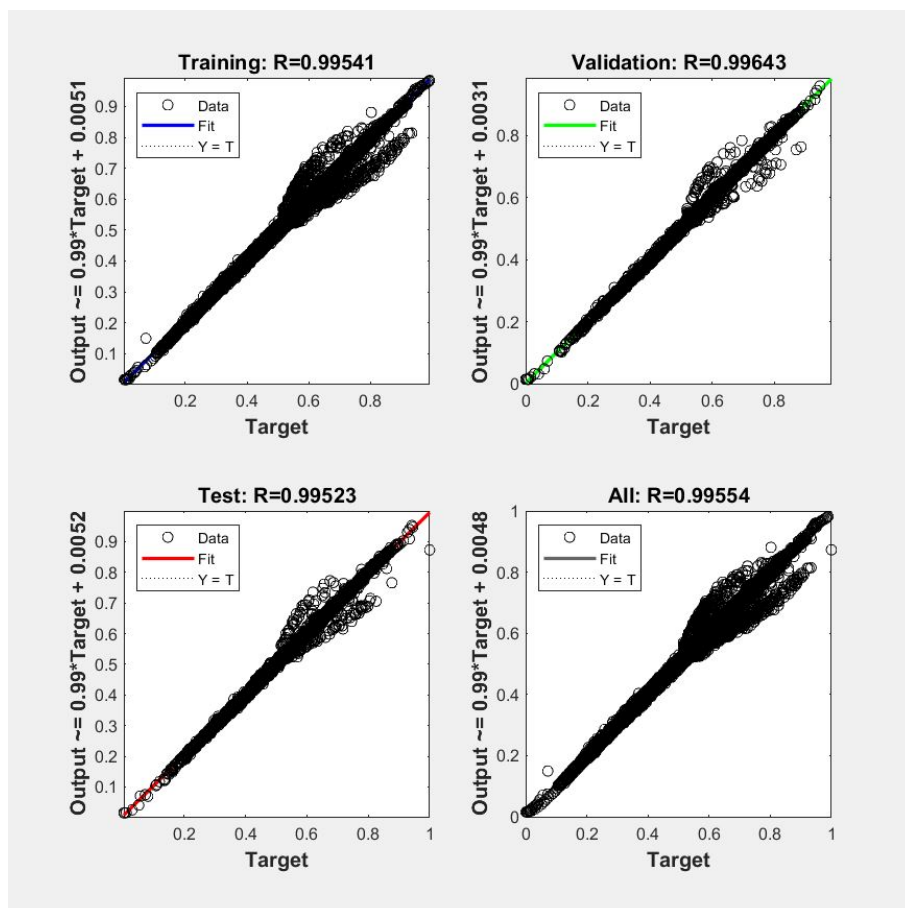
Σχήμα 5.12: Σχέση στόχων - εξόδων προσομοίωσης για το netTH

5.2.2 Αποτελέσματα για την πρόβλεψη της εσωτερικής θερμοκρασίας τη θερινή περίοδο

Για τη θερινή περίοδο, το ιδανικό μέσο τετραγωνικό σφάλμα, υπολογίστηκε ότι είναι $\text{mseGoal} = 8.8494 \times 10^{-5}$. Από την εκπαίδευση, προέκυψε μέσο τετραγωνικό σφάλμα $\text{mse} = 1.9346 \times 10^{-4}$. Η εκπαίδευση δεν έφτασε το στόχο, όμως η απόκλιση είναι αρκετά μικρή, επομένως υπάρχει καλή εφαρμογή των δεδομένων. Όταν το λάθος επικύρωσης απέτυχε να μειωθεί για έξι συνεχόμενες επαναλήψεις, διακόπηκε


και η εκπαίδευση του δικτύου.

Πιο λεπτομερώς, το Regression plot, που μας δείχνει τη σχέση στόχων-εξόδων για όλα τα σετ δεδομένων έχει ως εξής:




Σχήμα 5.13: Σχέση στόχων - εξόδων για το netTC

Το ιστόγραμμα σφάλματος έχει ένα ποσοστό περιπτώσεων που δεν είναι πάνω στην τιμή του μηδενικού σφάλματος, αλλά πρόκειται για ένα μικρό ποσοστό συγκριτικά με τη μεγάλη πλειοψηφία των περιπτώσεων που έχουν μηδενικό σφάλμα:




Σχήμα 5.14: Ιστόγραμμα σφάλματος για το netTC


Εφαρμόστηκαν τα δεδομένα που δε χρησιμοποιήθηκαν στην εκπαίδευση, προκειμένου να δοκιμαστεί το δίκτυο για άγνωστες περιπτώσεις, και οι αποκρίσεις του μαζί με τους αρχικούς στόχους, καθώς και τα σφάλματα της εφαρμογής φαίνονται παρακάτω. Στο πλήθος τους τα λάθη φαίνονται περισσότερα απ'ότι στο netTH, αλλά δεν εντοπίζεται ούτε ένα ζευγάρι στόχων - προβλέψεων με διαφορά μεγαλύτερη του 0,4, επομένως κι εδώ η απόδοση του δικτύου στα δεδομένα μας είναι πολύ καλή,



Σχήμα 5.15: Στόχοι και έξοδοι για το netTC



Σχήμα 5.16: Σφάλματα για το netTC

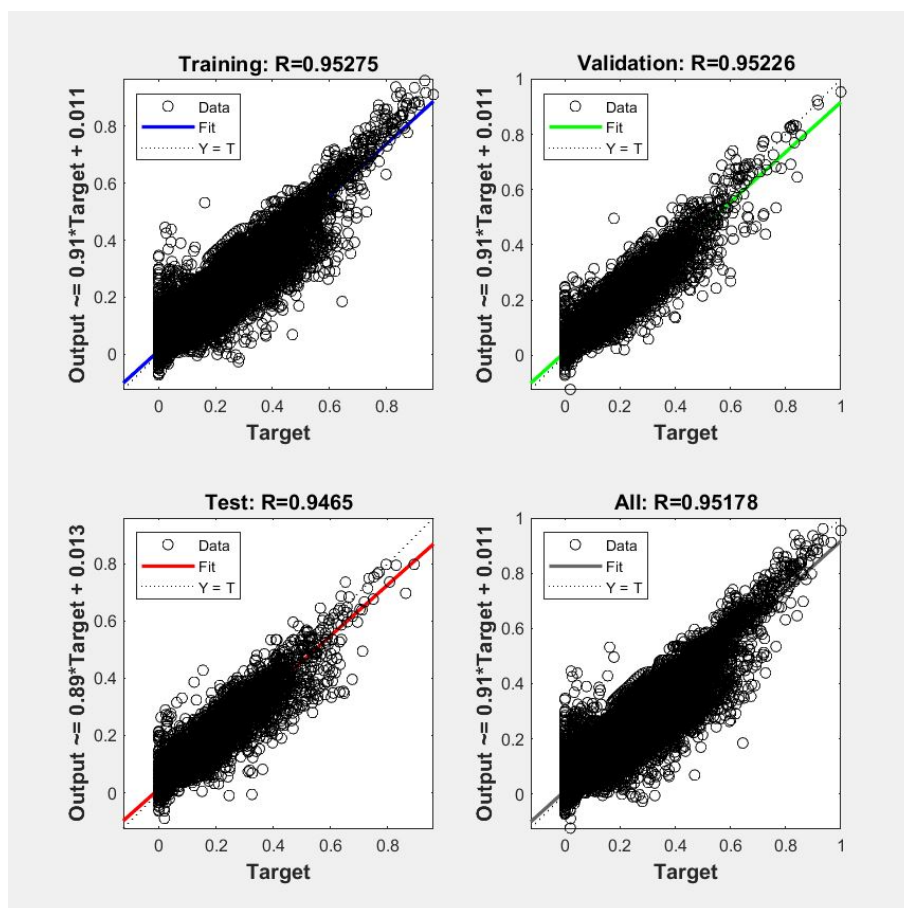


Σχήμα 5.17: Σχέση στόχων - εξόδων προσομοίωσης για το netTC

5.2.3 Αποτελέσματα για την πρόβλεψη της ενεργειακής κατανάλωσης τη χειμερινή περίοδο


Η εκπαίδευση του δικτύου για την πρόβλεψη της ενεργειακής κατανάλωσης του συστήματος θέρμανσης σταμάτησε όταν το σφάλμα επικύρωσης απέτυχε να μειωθεί για 6 συνεχόμενες επαναλήψεις. Το μέσο τετραγωνικό σφάλμα είναι $mse=0.00243$, ενώ το ιδανικό μέσο τετραγωνικό σφάλμα υπολογίστηκε πως είναι $mseGoal=8.0035 \times 10^{-5}$.

Τα διαγράμματα για τη σχέση εξόδων - στόχων για τα σετ εκπαίδευσης - επικύρωσης - δοκιμής ξεχωριστά και για το σύνολο της εκπαίδευσης φαίνονται παρακάτω:




Σχήμα 5.18: Σχέση στόχων - εξόδων για netEnergyH

Τα δεδομένα βρίσκονται σχετικά διάσπορτα πάνω και γύρω από τη γραμμή των 45°, όμως δεν υπάρχουν δεδομένα με πολύ μεγάλη απόκλιση, επομένως θα μπορούσαμε να πούμε ότι η εκπαίδευση είναι ικανοποιητική. Αυτό μπορεί να φανεί και στο ιστόγραμμα σφάλματος, το οποίο δείχνει τη διανομή των σφαλμάτων. Υπάρχουν αρκετές μη μηδενικές τιμές σφάλματος, όμως όλες βρίσκονται κοντά στο μηδέν:




Σχήμα 5.19: Ιστόγραμμα σφάλματος για netEnergyH


Τα αποτελέσματα για τα δεδομένα που εφαρμόστηκαν στο δίκτυο μετά την εκπαίδευση και δείχνουν τους στόχους με τις εξόδους του δικτύου και τα σφάλματα φαίνονται παρακάτω:



Σχήμα 5.20: Στόχοι - έξοδοι για netEnergyH



Σχήμα 5.21: Σφάλματα για netEnergyH

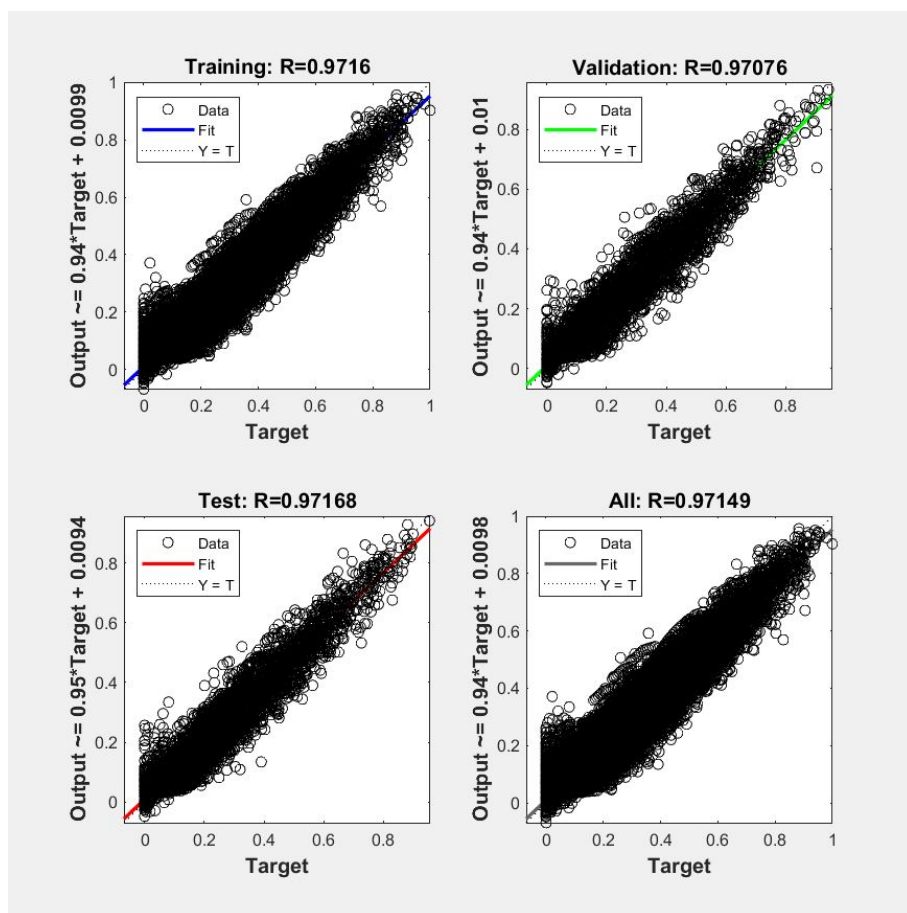


Σχήμα 5.22: Σχέση στόχων - εξόδων προσομοίωσης για το netEnergyH

5.2.4 Αποτελέσματα για την πρόβλεψη της ενεργειακής κατανάλωσης τη θερμική περίοδο


Η εκπαίδευση του δικτύου για την πρόβλεψη της ενεργειακής κατανάλωσης του συστήματος ψύξης επίσης σταμάτησε όταν το σφάλμα επικύρωσης απέτυχε να μειωθεί για 6 συνεχόμενες επαναλήψεις. Το μέσο τετραγωνικό σφάλμα των δεδομένων του δικτύου είναι $mse=0,002945$, ενώ το ιδανικό μέσο τετραγωνικό σφάλμα υπολογίστηκε πως είναι $mseGoal=1,518 \times 10^{-4}$.

Τα διαγράμματα για τη σχέση εξόδων - στόχων για τα σετ εκπαίδευσης - επικύρωσης - δοκιμής ξεχωριστά και για το σύνολο της εκπαίδευσης φαίνονται παρακάτω:




Σχήμα 5.23: Σχέση στόχων - εξόδων για netEnergyC

Τα δεδομένα εφαρμόζουν πιο αποδοτικά απ'ότι στο netEnergyH. Δεν υπάρχουν δεδομένα με μεγάλη απόκλιση, αφού όλα βρίσκονται σχετικά κοντά στη γραμμή των 45°, άρα η εκπαίδευση είναι ικανοποιητική. Αυτό μπορεί να φανεί και στο ιστόγραμμα σφάλματος, το οποίο δείχνει τη διανομή των σφαλμάτων. Υπάρχουν αρκετές μη μηδενικές τιμές σφάλματος, όμως η απόκλισή τους από τη μπάρα στη μηδενική τιμή δεν ξεπερνά το 0,018 (οι τιμές είναι κανονικοποιημένες στο [0,1]).




Σχήμα 5.24: Ιστόγραμμα σφάλματος για netEnergyC


Τα αποτελέσματα για τα δεδομένα που εφαρμόστηκαν στο δίκτυο μετά την εκπαίδευση και δείχνουν τους στόχους με τις εξόδους του δικτύου και τα σφάλματα φαίνονται παρακάτω:



Σχήμα 5.25: Στόχοι - εξόδοι για netEnergyC



Σχήμα 5.26: Σφάλματα για netEnergyC



Σχήμα 5.27: Σχέση στόχων - εξόδων προσομοίωσης για το netEnergyC

5.2.5 Αποτελέσματα για την πρόβλεψη της μελλοντικής παρουσίας των κατοίκων στο χώρο

Επιλογή πλήθους δεδομένων εκπαίδευσης

Δοκιμάστηκαν τρία διαφορετικά μεγέθη για τη χρονική ακολουθία των δεδομένων προς εκπαίδευση, δηλαδή τρία διαφορετικά διαστήματα κατά τα οποία το σύστημα παρατηρεί τη συμπεριφορά των κα-

τοίκων πριν ξεκινήσει τις προβλέψεις. Δόθηκαν προς εκπαίδευση δεδομένα για 4, 8 και 12 εβδομάδες και κάθε περίπτωση εξετάστηκε σε νευρωνικά δίκτυα πολλών διαφορετικών νευρώνων. Η σύγκρισή τους έγινε με το μέσο τετραγωνικό σφάλμα των δεδομένων για το δίκτυο ανοιχτού βρόχου (mseS) και για το δίκτυο κλειστού βρόχου (mseC).

Ntrain	4*1008	8*1008	12*1008
mseS	0,0163	0,0198	0,0218
mseC	0,1885	0,3218	0,1356

Σχήμα 5.28: Σύγκριση απόδοσης δικτύων με διαφορετικό πλήθος δεδομένων εκπαίδευσης

Βλέπουμε ότι οι τιμές για 4 και 11 εβδομάδες δεδομένων είναι πολύ κοντά. Θα προτιμήσουμε να ορίσουμε Ntrain = 4*1008 καθώς οι 12 εβδομάδες είναι για το χρήστη πολύ μεγάλο διάστημα αναμονής μέχρι να ξεκινήσει να βλέπει τα πρώτα αποτελέσματα της λειτουργίας του συστήματος στην κατοικία του.

Επιλογή αλγόριθμου εκπαίδευσης

Τα αποτελέσματα για τις δύο προσομοιώσεις με διαφορετικούς αλγόριθμους εκπαίδευσης (Levenberg-Marquardt και Scaled Conjugate Gradient algorithm) φαίνονται στον πίνακα:


	trainlm	trainscg
mseS	0,0107	0,0133
mseC	0,0357	0,166

Σχήμα 5.29: Σύγκριση απόδοσης δικτύων με διαφορετικό αλγόριθμο εκπαίδευσης

Χρησιμοποιήθηκε ο αλγόριθμος Levenberg-Marquardt που έχει τα μικρότερα σφάλματα.


Επιλογή καθυστερήσεων

Για τις καθυστερήσεις της ανατροφοδοτούμενης εισόδου προέκυψε το εξής:



Σχήμα 5.30: Σημαντικές καθυστερήσεις των στόχων


Παρατηρείται ότι πράγματι πιο σημαντικές είναι οι κοντινές καθυστερήσεις που αφορούν το άμεσο παρελθόν, οι καθυστερήσεις που αφορούν τα αντίστοιχα timesteps των προηγούμενων εβδομάδων (1008,1009,1010,.. και 2016,2017,..) και οι καθυστερήσεις που αφορούν τα αντίστοιχα timesteps των προηγούμενων ημερών (144,145,146... , 288,289,290... κλπ).




Σχήμα 5.31: Υποσύνολο σημαντικών καθυστερήσεων των στόχων

Ορίσαμε ως καθυστερήσεις για την ανατροφοδοτούμενη είσοδο ένα υποσύνολο των όσων προέκυψαν στο διάγραμμα της εικόνας 5.30: `feedbackDelays = [1:10 137:151 283:293 427:437 571:581 716:724 858:870 1000:1008]`

Για τις καθυστερήσεις των δύο εξωγενών εισόδων προέκυψε το εξής:



Σχήμα 5.32: Significant lags of NARX input 1



Σχήμα 5.33: Significant lags of NARX input 2

Ως σημαντικές με βάση τους υπολογισμούς θεωρήθηκαν οι καθυστερήσεις [134:137]. Επειδή όμως βρίσκονται πολύ κοντά στην τιμή κατωφλίου μπορούν και να παραλειφθούν, αφού όπως αποδείχτηκε όταν δοκιμάστηκε να προστεθούν στο δίκτυο, χειροτερεύουν την απόδοση. Ωστόσο δε γίνεται να οριστεί μηδενική τιμή καθυστέρησης γιατί τότε η συνάρτηση `removedelay` θα κατέληγε σε αρνητικό αριθμό καθυστέρησης. Επομένως, κατασκευάστηκε γραμμή 11 καθυστέρησης, όσα είναι και τα βήματα της

πρόωσης πρόβλεψης, και ως καθυστέρηση των εξωγενών εισόδων που εισέρχεται στο δίκτυο ορίστηκε μόνο η 11η.


Επομένως, για να παραμείνουν στη μνήμη του δικτύου και τα πιο μακρινά timesteps, οι γραμμές καθυστερήσεων αποτελούνται από 11 μονάδες καθυστέρησης για τις εξωγενείς εισόδους και 1008 μονάδες καθυστέρησης για την ανατροφοδοτούμενη είσοδο.

Επιλογή συνάρτησης ενεργοποίησης στο στρώμα εξόδου


Για να επιλεγεί η κατάλληλη συνάρτηση ενεργοποίησης έγινε η εφαρμογή των ίδιων δεδομένων σε τέσσερα NARX με συναρτήσεις ενεργοποίησης όπως αναφέρονται στο 3.4.5. Στη MATLAB ονομάζεται 'purelin' η γραμμική συνάρτηση, 'logsig' η σιγμοειδής και 'tansig' η εφαπτόμενη σιγμοειδής. Όλες οι υπόλοιπες παράμετροι της δομής των δικτύων και της εκπαίδευσης είναι κοινές για τα δίκτυα: Ntrain = 4032, delays όπως ορίστηκαν παραπάνω, αλγόριθμος εκπαίδευσης ο Levenberg-Marquardt. Επίσης εξετάστηκαν για κάθε περίπτωση δύο αριθμοί κρυφών νευρώνων H=10 και H=12 και για κάθε H έγιναν 10 εκπαιδεύσεις όπου κάθε φορά τα βάρη του δικτύου είχαν διαφορετικές τυχαίες αρχικές τιμές. Στις περιπτώσεις με γραμμική συνάρτηση μεταφοράς στο στρώμα εξόδου, τα μέσα τετραγωνικά σφάλματα είναι μεγαλύτερα απ' ό,τι στις περιπτώσεις μη-γραμμικής συνάρτησης (Εικόνα 5.34). Επομένως, αποφασίσαμε ότι θα χρησιμοποιηθεί μη-γραμμική συνάρτηση. Η αποδοτικότητα της εκπαίδευσης των περιπτώσεων των δικτύων που περιλαμβάνουν μόνο μη-γραμμικές συναρτήσεις είναι παρόμοια, οπότε εξετάστηκε το ποσοστό επιτυχίας στις προβλέψεις. Η 'tansig' εξασφαλίζει μεγαλύτερο ποσοστό επιτυχίας (Εικόνες 5.34,5.35,5.36). Επιπλέον, η υπεροχή της χρήσης της στο στρώμα εξόδου MLP δικτύων έχει ήδη αποδειχθεί [9]. Έτσι, χρησιμοποιήθηκε εφαπτόμενη σιγμοειδής συνάρτηση στα στρώματα του δικτύου.

Layer(1).transferFun	Layer(2).transferFun	mseS	mseC	success
logsig	linear	0,035	0,0421	92,16%
logsig	logsig	0,0107	0,0357	94,15%
tansig	linear	0,0415	0,093	92,36%
tansig	tansig	0,014	0,0206	94,94%

Σχήμα 5.34: Σύγκριση απόδοσης δικτύων με διαφορετικές συναρτήσεις ενεργοποίησης



Σχήμα 5.35: Προβλέψεις με sigmoid



Σχήμα 5.36: Προβλέψεις με tansig

Επιλογή μεγέθους του κρυφού στρώματος

Εγινε η κατασκευή και η εκπαίδευση δικτύων με κοινές όλες τις παραμέτρους για τον αριθμό δεδομένων, τη δομή και τον τρόπο εκπαίδευσης σύμφωνα με τα ήδη αναφερθέντα αποτελέσματα, αλλά διαφορετικά μεγέθη στο κρυφό στρώμα: $H = 2, 4, 6, 8, 10, 12, 14, 16$. Για κάθε δίκτυο έγιναν $N_{\text{trials}} = 10$ επαναλήψεις της εκπαίδευσης με διαφορετικά και τυχαία αρχικά βάρη για κάθε επανάληψη. Το μικρότερο mse για κάθε H φαίνεται στον παρακάτω πίνακα.

H	2	4	6	8	10	12	14	16
MseS	0,0318	0,0183	0,0167	0,015	0,014	0,0113	0,0116	0,0153
MseC	0,1418	0,1019	0,0285	0,0368	0,0315	0,0307	0,0204	0,0389

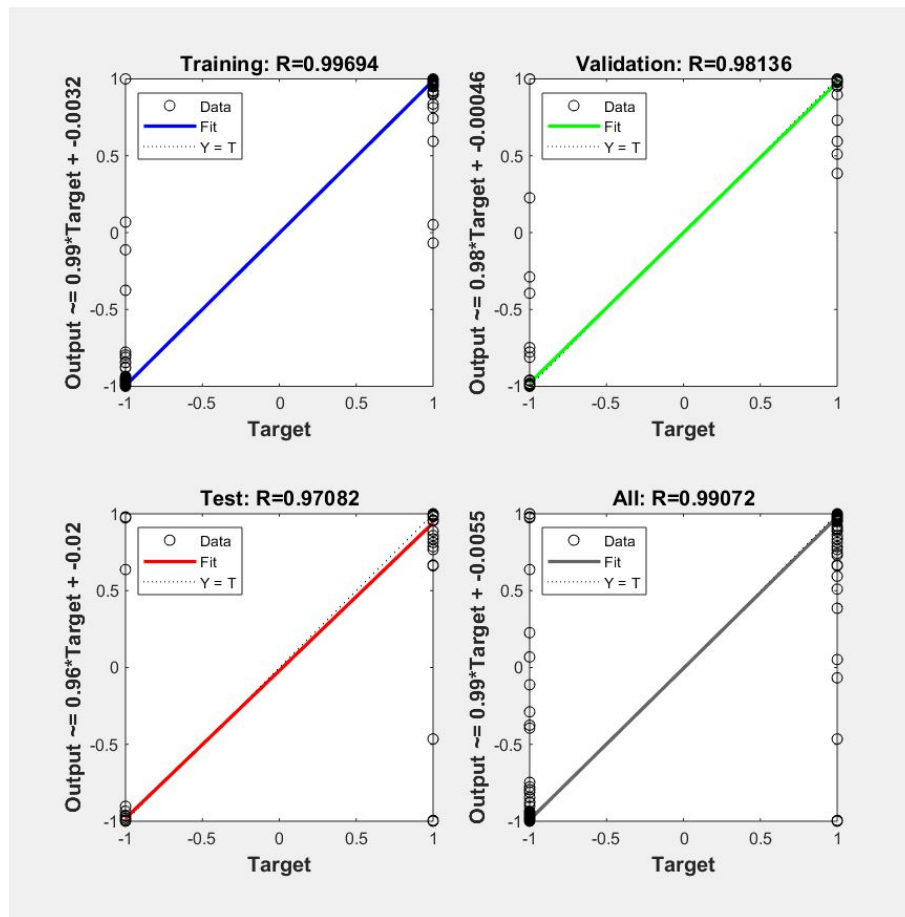
Σχήμα 5.37: Σύγκριση απόδοσης δικτύων για διαφορετικά μεγέθη κρυφού στρώματος δικτύου

Ο πίνακας δείχνει πως η χρήση 8,10,12 ή 14 νευρώνων στο κρυφό στρώμα εξασφαλίζει τα μικρότερα mseS, με πολύ μικρή διαφορά υπέρ του $H=12$. Οι 14 νευρώνες οδηγούν σε καλύτερο μέσο τετραγωνικό σφάλμα αφού εφαρμοστεί η λειτουργία κλειστού βρόχου. Επομένως, ως βέλτιστη λύση θεωρήσαμε την κατασκευή του δικτύου με $H=14$ νευρώνες κρυφού στρώματος με $\text{mseS} = 0.0116$ και $\text{mseC} = 0.0204$.

Αποτελέσματα εκπαίδευσης


Αφού έγιναν οι ρυθμίσεις των παραμέτρων για την κατασκευή και την εκπαίδευση του NARX δικτύου, πραγματοποιήθηκε η εκπαίδευση όσο το δίκτυο βρισκόταν σε λειτουργία ανοιχτού βρόχου (συμπεριλαμβανομένων των βημάτων επικύρωσης και δοκιμής). Το μέσο τετράγωνικό σφάλμα που προέκυψε, όπως είδαμε είναι 0.0116. Η εκπαίδευση σταμάτησε όταν το λάθος επικύρωσης απέτυχε να μειωθεί για έξι συνεχόμενες επαναλήψεις.

Το παρακάτω διάγραμμα χρησιμοποιείται για την επικύρωση της απόδοσης του δικτύου. Όπως έχουμε δει και στην εκπαίδευση των προηγούμενων δικτύων, τα παράθυρα που φαίνονται εμφανίζουν τις εξόδους του δικτύου σε σχέση με τους στόχους για τα σετ εκπαίδευσης, επικύρωσης και δοκιμής και τέλος για το σύνολο. Για τέλεια εφαρμογή, τα δεδομένα πρέπει να βρίσκονται πάνω στη γραμμή των 45 μοιρών, όπου οι εξόδοι είναι ίσες με τους στόχους και η τιμή R να είναι ίση με 1. Για την εκπαίδευσή μας, η εφαρμογή είναι πολύ καλή για όλα τα σύνολα δεδομένων, κυρίως για το σετ εκπαίδευσης.




Σχήμα 5.38: Σχέση στόχων-εξόδων NARX

Το ίδιο βλέπουμε και παρακάτω, όπου απεικονίζεται οι στόχοι, οι εξοδοι και τα σφάλματα συναρτήσεων του χρόνου:



Σχήμα 5.39: Απόκριση Χρονοσειρας

Η σχέση των εξόδων και των στόχων για το τεστ δοκιμής μπορεί να φανεί και στο ιστόγραμμα λάθους που προέκυψε:




Σχήμα 5.40: Ιστόγραμμα λάθους NARX

Το ιστόγραμμα μπορεί να δώσει μια ένδειξη των σημείων δεδομένων όπου η εφαρμογή είναι σημαντικά χειρότερη από την πλειοψηφία των δεδομένων [15]. Στην περίπτωσή μας τα περισσότερα σφάλματα

βρίσκονται πολύ κοντά στο 0.


Στο παρακάτω διάγραμμα απεικονίζεται η συνάρτηση αυτοσυσχέτισης λάθους (**Error Autocorrelation**), που περιγράφει πως συσχετίζονται τα λάθη της πρόβλεψης στο χρόνο.



Σχήμα 5.41: Αυτοσυσχέτιση στόχων

Στην καθυστέρηση 0, βρίσκεται η τιμή του μέσου τετραγώνου σφάλματος. Για να είναι το δίκτυο πρόβλεψης τέλει, θα έπρεπε η τιμή στη μηδενική καθυστέρηση να είναι η μόνη μη μηδενική τιμή, καθώς αυτό θα σήμαινε ότι τα λάθη της πρόβλεψης δε συσχετίζονται καθόλου μεταξύ τους. Εάν υπήρχε σημαντική συσχέτιση στα σφάλματα πρόβλεψης, τότε θα έπρεπε ίσως να αυξηθεί ο αριθμός των καθυστερήσεων στις γραμμές καθυστέρησης που χρησιμοποιήθηκαν. Στην περίπτωση αυτή, οι συσχετισμοί, εκτός από εκείνον που βρίσκεται στο 0, πέφτουν είτε εντός των ορίων εμπιστοσύνης 95% γύρω από το μηδέν, είτε πολύ κοντά στα όρια, οπότε το μοντέλο φαίνεται να είναι επαρκές.[16]

Η παρακάτω συνάρτηση συσχέτισης εισόδου-σφάλματος απεικονίζει τον τρόπο συσχέτισης των σφαλμάτων με τις ακολουθίες των εξωγενών εισόδων:




Σχήμα 5.42: Συσχέτιση εισόδων - στόχων

Για ένα τέλειο μοντέλο πρόβλεψης, όλοι οι συσχετισμοί πρέπει να είναι μηδενικοί. Εάν η είσοδος συσχετίζεται με το σφάλμα, τότε θα πρέπει να είναι δυνατή η βελτίωση της πρόβλεψης, ίσως αυξάνοντας τον αριθμό των καθυστερήσεων στις γραμμές καθυστέρησης που χρησιμοποιήθηκαν.[16] Στην περίπτωση αυτή, όλοι οι συσχετισμοί βρίσκονται μέσα στα όρια εμπιστοσύνης γύρω από το μηδέν.

Μετατρέποντας το δίκτυο σε δίκτυο κλειστού βρόχου και εφαρμόζοντας σε αυτό τα δεδομένα της εκπαίδευσης προέκυψε μέσο τετραγωνικό σφάλμα 0.0204. Παρακάτω φαίνονται οι στόχοι, οι έξοδοι και τα σφάλματα:




Σχήμα 5.43: Στόχοι και έξοδοι για closed-loop NARX




Σχήμα 5.44: Σφάλματα για closed-loop NARX

Αφού άλλαξε η δομή του δικτύου έτσι ώστε να εξάγει την κάθε πρόβλεψη 11 timesteps νωρίτερα, ζητήθηκε από το δίκτυο να εξάγει προβλέψεις για το χρονικό διάστημα μίας εβδομάδες (1008 προβλεψεις) με κάθε προβλεψη να προκύπτει δύο ώρες νωρίτερα:




Σχήμα 5.45: Στόχοι και έξοδοι για την πρόωρη πρόβλεψη πολλαπλών βημάτων



Σχήμα 5.46: Σφάλματα για την πρόωρη πρόβλεψη πολλαπλών βημάτων

Επειδή χρειαζόμαστε δυαδική έξοδο, εφαρμόστηκε ένα κατώφλι, για να μετατραπούν όλες οι τιμές σε 0 ή 1. Το κατώφλι βρέθηκε από το μέσο όρο των τιμών των στόχων της εκπαίδευσης: $\text{threshold} = 0.254$. Τα τελικά αποτελέσματα είναι αρκετά καλά καθώς για την εβδομάδα στην οποία δοκιμάστηκε η αποδοτικότητα υπήρξε 0,9415% επιτυχία:

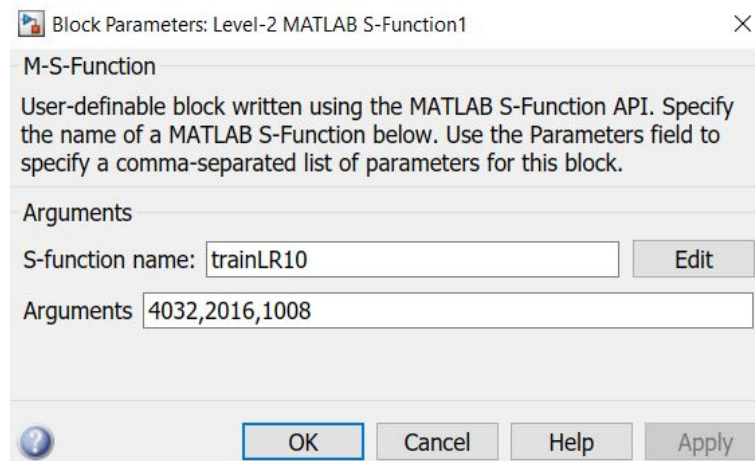


Σχήμα 5.47: Στόχοι και έξοδοι για την πρόωρη πρόβλεψη πολλαπλών βημάτων

5.3 Αποδοτικότητα του συστήματος θέρμανσης/ψύξης

5.3.1 Αποδοτικότητα του μοντέλου πρόβλεψης παρουσίας

Στην παρακάτω εικόνα φαίνεται το παράθυρο με τις παραμέτρους του block στο Simulink. Η πρώτη παράμετρος είναι ο αριθμός των δεδομένων εκπαίδευσης, η δεύτερη παράμετρος είναι ο αριθμός των δεδομένων για τις προβλέψεις της εκπαίδευσης (συμπεριλαμβανομένων των καθυστερήσεων) και η τρίτη είναι ο αριθμός των καθυστερήσεων, όπως τις επιλέξαμε για το μοντέλο.



Σχήμα 5.48: S-function block

Όπως αναφέρθηκε στην ενότητα 4.3.2, δοκιμάστηκαν δύο μέθοδοι και συγκρίθηκαν τα αποτελέσματα τους. Στην (α) μέθοδο, ορίζονται τυχαία αρχικά βάρη για κάθε εκπαίδευση που γίνεται κατά τη διάρκεια της προσομοίωσης του μοντέλου, ενώ στη (β) μέθοδο κάθε δίκτυο που κατασκευάζεται έχει τα ίδια αρχικά βάρη.

Μέθοδος	mseS	mseC	success
α	0,0362	0,1146	91,79%
β	0,0568	0,1455	91,69%

Σχήμα 5.49: Σύγκριση μεθόδων περιοδικής εκπαίδευσης της S-function

Η διαφορά δεν είναι μεγάλη, αλλά όπως φαίνεται το δίκτυο αποδίδει καλύτερα όταν ορίζονται κάθε φορά τυχαία αρχικά βάρη. Επομένως, αυτή είναι και η μέθοδος που εφαρμόστηκε τελικά.

5.3.2 Αποδοτικότητα του μοντέλου του ελεγκτή

Η προσομοίωση στο Simulink έγινε για $\rho=3$, όπου το ρ είναι οι ώρες χαμένης παραγωγικότητας λόγω έλλειψης θερμοκρασιακής άνεσης, όπως αυτή εξηγείται στην ενότητα 4.4.4, έτσι ώστε να δούμε πως διαμορφώνονται τα αποτελέσματα δίνοντας λιγότερη ή περισσότερη αξία στη θερμοκρασιακή άνεση. Το SystemOperation είναι οι αποφάσεις του ελεγκτή και η δεύτερη έξοδος, το Tin, είναι οι τιμές της θερμοκρασίας που το σύστημα προέβλεψε ότι έχει ο χώρος του καδιστικού με την εφαρ-

μογή των αποφάσεων του ελεγκτή στο σύστημα θέρμανσης/ψύξης. Αυτή η πρόβλεψη του Tin είναι απαραίτητη γιατί η τιμή της κάθε χρονικής στιγμής της προσομοίωσης δίνεται ως είσοδος στο μοντέλο την επόμενη χρονική στιγμή. Οι πραγματικές τιμές της εσωτερικής θερμοκρασίας με την εφαρμογή των αποφάσεων του ελεγκτή λήφθηκαν από το EnergyPlus. Το ίδιο ισχύει και για την απόρροια του SystemOperation σε ενεργειακό κόστος. Επομένως δίνοντας στο idf αρχείο της κατοικίας μας το SystemOperation που προκύπτει από το Simulink μοντέλο, λαμβάνουμε την εσωτερική θερμοκρασία Tin και το ενεργειακό κόστος με το Zone Air System Sensible Heating Energy και το Zone Air System Sensible Cooling Energy, με Timestep = 10 και Thermal Zone το Living Room.¹

[0001] Schedule.Constant				
[0003] Schedule.File				
Surface Construction Elements				
Field Description:				
ID: A1				
Enter a alphanumeric value				
This field is required.				
Field	Units	Obj1	Obj2	Obj3
Name		Presence	Operation	Activ
Schedule Type Limits Name		Fractional	OnOff 1	ActivityLevel
File Name		C:\Users\alex_\Des	C:\Users\alex_\Des	C:\Users\alex_\Des
Column Number		1	1	1
Rows to Skip at Top		0	0	0
Number of Hours of Data		8760	8760	8760
Column Separator		Comma	Comma	Comma
Interpolate to Timestep		No	No	No
Minutes per Item		10	10	10

Σχήμα 5.50: IDF Schedule File

Class List		Comments from IDF		
[.....] Output:Schedules	<div>⌵</div> <div>Explanation of Object and Current Field</div> <div>Object Description: each Output:Variable command picks variables to be put onto the standard output file (.eso) some variables may not be reported for every simulation. a list of variables that can be reported are available after a run on the report dictionary file (.idd) if the Output:VariableDictionary has been requested.</div> <div>Field Description: use "" (without quotes) to apply this variable to all keys</div> <div>ID: A1</div> <div>⌴</div>			
[.....] Output:Constructions				
[.....] Output:EnergyManagementSystem				
[.....] Output:Control:SurfaceColorScheme				
[0001] Output:Table:SummaryReports				
[.....] Output:Table:TimeBins				
[0008] Output:Table:Monthly				
[.....] Output:Table:Annual				
[0001] Output:Control:Table:Style				
[0001] Output:Control:ReportingTolerances				
[0003] Output:Variable				
[0004] Output:Meter				
[.....] Output:Meter:MeterFileOnly				
[.....] Output:Meter:Cumulative				
[.....] Output:Meter:Cumulative:MeterFileOnly				
[.....] Meter:Custom				
[.....] Meter:CustomDecrement				
[0001] Output:SQLite				
Field	Units	Obj1	Obj2	Obj3
Key Value		Living Room	Living Room	Living Room
Variable Name		Zone Air Temperature	Zone Air System Sensible Heating Energy	Zone Air System Sensible Cooling Energy
Reporting Frequency		Timestep	Timestep	Timestep
Schedule Name				

Σχήμα 5.51: IDF Output Variable

Για να διαπιστωθεί η λειτουργία του ελεγκτή μόνο, ανεξάρτητα από τις προβλέψεις παρουσίας/απουσίας, έγινε η προσομοίωση του Controller Model δίνοντας στην είσοδο που προορίζεται για τις προβλέψεις παρουσίας/απουσίας τις πραγματικές τιμές παρουσίας/απουσίας κατοίκων. Η απόκριση του μοντέλου στην έξοδο του SystemOperation εισάχθηκε στο idf και από την ενεργειακή προσομοίωση λάβαμε τις εσωτερικές θερμοκρασίες και την ενεργειακή κατανάλωση. Τα δεδομένα συγκρίθηκαν με τα δεδομένα της ενεργειακής προσομοίωσης χωρίς ελεγκτή.

Υπολογίστηκε:

- το Energy Gain, το ποσοστό εξοικονόμησης ενέργειας που εξασφαλίζει η χρήση του ελεγκτή, συγκριτικά με το κόστος της λειτουργίας του συστήματος θέρμανσης/ψύξης χωρίς τη χρήση ελεγκτή.
- το Comfort Success, το ετήσιο ποσοστό επιτυχίας θερμοκρασιακής άνεσης τις ώρες που κάποιος

¹Θεωρούμε ότι μέχρι να εξάγει το μοντέλο πρόβλεψης παρουσίας την πρώτη του πρόβλεψη το σύστημα θέρμανσης λειτουργεί χωρίς ελεγκτή όπως στο 2ο κεφάλαιο, επομένως το Schedule File με το χρονοδιάγραμμα λειτουργίας έχει μέχρι τη στιγμή της πρώτης πρόβλεψης τις ίδιες τιμές με το χρονοδιάγραμμα παρουσίας/απουσίας.

κάτοικος βρίσκεται στο χώρο, δηλαδή το ποσοστό των χρονικών στιγμών που ένας κάτοικος βρίσκεται στο χώρο και η εσωτερική θερμοκρασία:

- δεν πέφτει χαμηλότερα της θερμοκρασίας $T_{comf} - \varepsilon$ για τη χειμερινή περίοδο, όπου στην περίπτωση μας $T_{comf}=22^{\circ}\text{C}$ και $\varepsilon=1$,
- δεν ξεπερνά τη θερμοκρασία $T_{comf} + \varepsilon$ για τη θερινή περίοδο όπου στην περίπτωση μας $T_{comf}=26^{\circ}\text{C}$ και $\varepsilon=1$.


Υπενθυμίζεται ότι όλα τα δεδομένα που έχουν χρησιμοποιηθεί για την εκπαίδευση των νευρωνικών δικτύων προέρχονται από το idf του 2ου κεφαλαίου, στο οποίο η λειτουργία της θέρμανσης ή της ψύξης ενεργοποιείται τη χρονική στιγμή που εντοπίζεται κίνηση στο χώρο, αν η θερμοκρασία του χώρου μέχρι εκείνη τη στιγμή δεν είναι η επιθυμητή. Επομένως, υπάρχει καθ'όλη τη διάρκεια του έτους θερμική άνεση, με εξαίρεση πολύ λίγες χρονικές στιγμές π.χ. όταν ο χρήστης μόλις έχει εισέλθει στο χώρο, η θερμοκρασία διαφέρει αρκετά από την επιθυμητή και η ενεργοποίηση της θέρμανσης/ ψύξης δεν είναι αρκετή για να φτάσει το επιθυμητό επίπεδο μέσα σε λίγα λεπτά, αλλά ενδεχομένως να χρειάζεται να περάσουν 1 ή 2 timesteps. Έτσι, για το μοντέλο αυτό, το ποσοστό θερμικής άνεσης είναι 98.98% για τη χειμερινή περίοδο και 94% για τη θερινή περίοδο.

Η διατήρηση της θερμικής άνεσης στα αποτελέσματα που ακολουθούν κρίνεται με βάση τα παραπάνω δεδομένα.

	Heating	Cooling
Energy Gain (%)	19,90	17,03


Σχήμα 5.52: Αποτελέσματα της λειτουργίας του ελεγκτή με πραγματικά δεδομένα παρουσίας

Για τη χειμερινή περίοδο, βρέθηκε 19,90% ενεργειακό κέρδος. Ο χώρος παρέχει θερμική άνεση στους κατοίκους για το 89.32% των περιπτώσεων. Για τις υπόλοιπες περιπτώσεις η πλειοψηφία των τιμών είναι άνω των 19°C . Στο ιστόγραμμα που ακολουθεί κατηγοριοποιούνται οι χρονικές στιγμές που η θερμοκρασία δε φτάνει την επιθυμητή.



Σχήμα 5.53: Ιστόγραμμα θερμικής απόδοσης του “ποσοστού λάθους” της χειμερινής περιόδου με αληθινά δεδομένα παρουσίας

Για τη θερινή περίοδο, προέκυψε ενεργειακό κέρδος 17.03%. Εδώ, υπάρχει θερμική άνεση σε ποσοστό 86.47%. , Όσο μεγαλώνει η τιμή της θερμοκρασίας, ο αριθμός των χρονικών στιγμών που της αντιστοιχούν μειώνεται εκθετικά. Βλέπουμε ότι η πλειοψηφία των περιπτώσεων δεν απομακρύνεται ιδιαίτερα από τα όρια της επιθυμητής θερμοκρασίας.



Σχήμα 5.54: Ιστόγραμμα θερμικής απόδοσης του “ποσοστού λάθους” της θερινής περιόδου με αληθινά δεδομένα παρουσίας


5.3.3 Αποδοτικότητα του συνολικού συστήματος

Εφοδιάζοντας τον ελεγκτή με τις προβλέψεις του μοντέλου πρόβλεψης παρουσίας, όπως ορίζεται κανονικά στο συνολικό μοντέλο και ακολουθώντας την ίδια διαδικασία, προκύπτει η ενεργειακή απόδοση που φαίνεται παρακάτω:

	Heating	Cooling
Energy Gain (%)	15,81	14,67


Σχήμα 5.55: Αποτελέσματα της λειτουργίας του ελεγκτή με προβλέψεις δεδομένων παρουσίας

Για τη χειμερινή περίοδο, προέκυψε 15,81% ενεργειακό κέρδος. Για το 87,88% των περιπτώσεων που υπάρχει κίνηση στο χώρο, η θερμοκρασία βρίσκεται πάνω από το όριο και διασφαλίζει θερμική άνεση. Για τις υπόλοιπες περιπτώσεις οι τιμές της θερμοκρασίας και το πλήθος των χρονικών στιγμών που τους αντιστοιχεί φαίνεται στις παρακάτω εικόνες. Οι περισσότερες χρονικές στιγμές που καταγράφονται αντιστοιχούν σε θερμοκρασιακές τιμές πολύ κοντά στην επιθυμητή τιμή.



Σχήμα 5.56: Ιστόγραμμα θερμικής απόδοσης του "ποσοστού λάθους" της χειμερινής περιόδου με προβλέψεις δεδομένων παρουσίας

Για τη θερινή περίοδο, το ενεργειακό κέρδος είναι 14,67%. Εξασφαλίζεται θερμική άνεση στο 88,24% των χρονικών στιγμών. Όπως και για τη χειμερινή περίοδο, στο διάγραμμα 5.57 φαίνεται το εύρος των τιμών της εσωτερικής θερμοκρασίας για όλες τις χρονικές στιγμές που υπάρχει κίνηση στο χώρο και η θερμοκρασία δε φτάνει την επιθυμητή. Για τις χρονικές στιγμές που ανήκουν στο ποσοστό "δυσφορίας", η θερμοκρασία συνήθως κυμαίνεται σε τιμές χαμηλότερες των 28°C.



Σχήμα 5.57: Ιστόγραμμα θερμικής απόδοσης του "ποσοστού λάθους" της θερινής περιόδου με προβλέψεις δεδομένων παρουσίας

Κεφάλαιο 6

Συμπεράσματα και Μελλοντικές ενέργειες

Έχει κατασκευαστεί ένα μοντέλο στο οποίο δεν χρειάζεται η ανθρώπινη παρέμβαση κατά τη διάρκεια λειτουργίας, παρά μόνο κατά την αρχική του ενεργοποίηση προκειμένου να οριστούν οι προτιμήσεις των κατοίκων. Μόλις το σύστημα ενεργοποιηθεί, παρακολουθεί την κίνηση των κατοίκων στο χώρο, εκπαιδεύεται και ξεκινά αυτόματα να λαμβάνει αποφάσεις, έχοντας την ικανότητα να προβλέπει και να προσαρμόζεται σε τυχόν αλλαγές. Το μοντέλο πρόβλεψης κίνησης (νευρωνικό δίκτυο *parx*) είναι αυτό που δίνει τη δυνατότητα προσαρμογής στον ελεγκτή, καθώς επανεκπαιδεύεται συνεχώς κάθε μία εβδομάδα, υπολογίζοντας κάθε φορά το πιο πρόσφατο πρόγραμμα των κατοίκων. Ενημερώνοντας τον ελεγκτή για μελλοντικές ενέργειες, του παρέχει τη δυνατότητα να δράσει πρόωρα για να ανταποκριθεί στις ενεργειακές και θερμικές απαιτήσεις. Από την άλλη μεριά, τα υπόλοιπα νευρωνικά δίκτυα, είναι εκπαιδευμένα εκ των προτέρων με τα δεδομένα του ενεργειακού μοντέλου της κατοικίας και κατά τη διάρκεια της λειτουργίας του συστήματος απλώς δέχονται τις κατάλληλες εισόδους και υπολογίζουν την εσωτερική θερμοκρασία και την ενεργειακή κατανάλωση.

Πριν τη χρήση του ελεγκτή, διαθέτοντας μόνο τον απλό θερμοστάτη, η ενέργεια που καταναλώθηκε συνολικά για τη θέρμανση και την ψύξη στο χώρο τον οποίο μελετήσαμε (καθιστικό και τραπεζαρία) για ένα έτος υπολογίστηκε 4.53255 GJ, δηλαδή κόστισε 243,75€, ενώ με τη χρήση του ελεγκτή καταναλώθηκαν είναι 3.8439 GJ, δηλαδή το ενεργειακό κόστος είναι 206,71€¹. Επομένως, **το ετήσιο ποσοστό μείωσης του ενεργειακού κόστους είναι 15.19%.**

Κάθε απόφαση του συστήματος ελέγχου που κατασκευάστηκε βασίζεται σε προβλέψεις πέντε διαφορετικών νευρωνικών δικτύων. Είναι γεγονός πως μία λάθος πρόβλεψη θα επηρεάσει τις αποκρίσεις των υπόλοιπων νευρωνικών δικτύων και ενδεχομένως να δημιουργήσει ένα “ντόμινο” λάνθασμένων προβλέψεων που οδηγούν τελικά σε μία λάνθασμένη απόφαση του ελεγκτή. Επομένως, η χρήση σειράς νευρωνικών δικτύων είναι ριψοκίνδυνη απόπειρα.

Η πολύ καλή εκπαίδευση των δικτύων είναι το πρωταρχικό ζήτημα για την επίτευξη του στόχου μας. Μία απόδειξη αυτού είναι η διαφορά των αποτελεσμάτων (εικόνες 5.52 και 5.55, όταν το σύστημα βασίζεται στις προβλέψεις νευρωνικού δικτύου όσον αφορά τη μελλοντική παρουσία των κατοίκων στο χώρο κι όταν λειτουργεί έχοντας δεδομένο το αληθινό χρονοδιάγραμμα. Οι προβλέψεις, αν και αρκετά καλές, όπως μπορεί να φανεί και στα αποτελέσματα της εκπαίδευσης του δικτύου *parx*, είχαν σφάλματα που οδήγησαν σε μία μη αμελητέα διαφορά στη συνολική απόδοση του συστήματος ελέγχου. Επιπλέον, η δυσκολία εκπαίδευσης από δίκτυο σε δίκτυο διαφέρει και σε αυτό φαίνεται να παίζει σημαντικό ρόλο

¹Για τη μετατροπή των Joule σε € χρησιμοποιήθηκε ο παράγοντας $(0.1936)/(3600000)$, όπως στο 4.4.3.

η φύση των δεδομένων. Παραδείγματος χάρη, τα νευρωνικά δίκτυα που χρησιμοποιήθηκαν για τις προβλέψεις της εσωτερικής θερμοκρασίας με τα νευρωνικά δίκτυα για τις προβλέψεις της ενεργειακής κατανάλωσης έχουν εκπαιδευτεί με την ίδια λογική, όμως αφορούν τελείως διαφορετικά δεδομένα. Προφανώς η κανονικοποίηση στην είσοδο κάθε δικτύου κάνει τα δεδομένα συγκρίσιμα, όμως στην πρώτη περίπτωση, οι προβλέψεις αφορούν °C, ενώ στη δεύτερη περίπτωση πρόκειται για Joule και μάλιστα σε ένα ευρύς τιμών εκατομμυρίων Joule. Ενδεχομένως, στην εκπαίδευση των δικτύων της ενεργειακής κατανάλωσης, να χρειαζόταν μεγαλύτερο πλήθος δεδομένων για να εξασφαλιστεί μεγαλύτερη ακρίβεια. Δυστυχώς, η μεθοδολογία του συστήματος ελέγχου είναι τέτοια που δε μας δίνει τη δυνατότητα να απομονώσουμε τη λειτουργία των συγκεκριμένων δικτύων όπως έγινε στην περίπτωση του `parx`, προκειμένου να φανεί κατά πόσο η ακρίβεια ή μη των προβλέψεων επηρέασε την απόδοση, όμως είναι προφανές πως μία τιμή σφάλματος 0.2 (κανονικοποιημένων δεδομένων) δημιουργεί μεγαλύτερο πρόβλημα στο σύνολο του συστήματος όταν πρόκειται για Joule απ' ό,τι όταν πρόκειται για °C. Παρά τις παραπάνω δυσκολίες, ο ελεγκτής καταφέρνει να εξασφαλίσει μία εξοικονόμηση στο ενεργειακό κόστος.

Περαιτέρω ενέργειες που θα μπορούσαν να υλοποιηθούν στο μέλλον είναι:

- Λόγω του περιορισμού 1 (6), τα νευρωνικά δίκτυα για την πρόβλεψη της εσωτερικής θερμοκρασίας και της ενεργειακής κατανάλωσης αντικατέστησαν κατά τη διάρκεια της προσομοίωσης το EnergyPlus, από το οποίο θα μπορούσε το σύστημα ελέγχου να δέχεται τις πραγματικές τιμές. Μελλοντικά, μπορεί να μελετηθεί ένας τρόπος να επιτευχθεί αυτή η online ανταλλαγή πληροφοριών μεταξύ Simulink και EnergyPlus, μειώνοντας την πολυπλοκότητα του συστήματος ελέγχου, κι έτσι να περιοριστεί η χρήση νευρωνικών δικτύων και αυτομάτως η εξάρτηση του συνολικού συστήματος σε προβλέψεις.
- Η ίδια μελέτη και η χρήση του συστήματος θέρμανσης/ψύξης με τον τρόπο που το κατασκευάσαμε θα μπορούσε επίσης να γίνει για άλλους χώρους της κατοικίας με διαφορετικές ανάγκες λόγω διαφορετικής χρήσης από τους κατοίκους, π.χ. η κρεβατοκάμαρα που χρησιμοποιείται κυρίως τις ώρες ύπνου, οπότε και η θερμοκρασία άνεσης είναι διαφορετική. Αφού έχει κατασκευαστεί το σχέδιο και η ενεργειακή προσομοίωση ολόκληρης της κατοικίας, τα χρονοδιαγράμματα και τα ενεργειακά δεδομένα για τα υπόλοιπα δωμάτια είναι διαθέσιμα.
- Όσον αφορά το μοντέλο πρόβλεψης `parx` για την παρουσία των κατοίκων στο χώρο, αντί για τη μέθοδο του periodical batch training που τελικά χρησιμοποιήθηκε, μπορεί να μελετηθεί αν η μέθοδος του online training, η οποία διαρκεί όσο το δίκτυο δέχεται νέα δεδομένα και τα βάρη προσαρμόζονται για κάθε στοιχείο των δεδομένων εκπαίδευσης, θα μπορούσε να χρησιμοποιηθεί στην περίπτωση μας. Αν αποδειχθεί εφικτό, ενδεχομένως να εξασφάλιζε καλύτερες προβλέψεις, κι έτσι να υπήρχε μία βελτιστοποίηση του συστήματος ελέγχου.

Περιορισμοί

Περιορισμός 1

Όσον αφορά το σύστημα ελέγχου, αρχικά, σκοπός ήταν το σύστημα ελέγχου στο Simulink να ανταλλάσσει πληροφορίες με το EnergyPlus, ώστε για κάθε υποψήφια απόφαση για τη λειτουργία της θέρμανσης ή της ψύξης να έχουμε διαθέσιμες τις πραγματικές τιμές της εσωτερικής θερμοκρασίας και της ενεργειακής κατανάλωσης που προέρχονται από την ενεργειακή προσομοίωση. Όμως, αυτό σημαίνει πως τα δύο προγράμματα θα έπρεπε να ανταλλάσσουν δεδομένα πάνω από 1100 φορές σε κάθε timestep, κάτι που είναι πρακτικά μη εφικτό. Επομένως, τα νευρωνικά δίκτυα για την πρόβλεψη της εσωτερικής θερμοκρασίας και της ενεργειακής κατανάλωσης, έχοντας εκπαιδευτεί με τα δεδομένα του ενεργειακού μοντέλου, αντικαθιστούν κατά τη διάρκεια της προσομοίωσης τη λειτουργία του EnergyPlus.

Περιορισμός 2

Όσον αφορά το μοντέλο πρόβλεψης $parx$ για την παρουσία των κατοίκων στο χώρο, εφόσον χρειάζεται κάθε χρονική στιγμή στο μοντέλο της πρόβλεψης να είναι γνωστές οι εισοδοί του δικτύου που αφορούν την τρέχουσα χρονική στιγμή και η απόκριση του δικτύου χρειάζεται να είναι μία πρόβλεψη για την παρουσία ή μη μόνο τη χρονική στιγμή που βρίσκεται 11 βήματα μπροστά, θεωρητικά η πρόβλεψη των 1008 βημάτων δεν είναι απαραίτητη. Θα μπορούσε να είναι πρόβλεψη ενός βήματος και πιθανόν να εξασφάλιζε πιο ακριβή αποτελέσματα (αφού η πρόβλεψη πολλαπλών βημάτων γίνεται με *close-loop net* και για να παράγει πρόβλεψη σε κάθε βήμα χρησιμοποιεί την πρόβλεψη του προηγούμενου βήματος). Όμως η S-function δε δίνει τη δυνατότητα αποθήκευσης του δικτύου, καθώς υποστηρίζει κάθε τύπο δεδομένων που υποστηρίζεται από το λογισμικό του Simulink και ο τύπος *network* δεν είναι μέσα σε αυτούς. Παρ'όλα αυτά, υπάρχει η δυνατότητα να αποθηκευθεί ένας πίνακας τιμών τύπου *double*. Επομένως, εφαρμόζοντας στην είσοδο του δικτύου τα δεδομένα για πρόβλεψη των τιμών παρουσίας/απουσίας για ολόκληρη την εβδομάδα στο ίδιο βήμα προσομοίωσης που το δίκτυο κατασκευάζεται και εκπαδεύεται, και κρατώντας στη μνήμη τις τιμές των προβλέψεων, είναι εφικτό κάθε πρόβλεψη να οδηγείται στο περιβάλλον του μοντέλου όταν χρειάζεται.

Περιορισμός 3

Λόγω έλλειψης χώρου στη RAM δεν ήταν δύνατη η προσομοίωση ολόκληρου του μοντέλου για ένα έτος. Επομένως το μοντέλο χωρίστηκε σε πέντε "κομμάτια". Το πρώτο μοντέλο περιλαμβάνει μόνο το μοντέλο *Occupancy Prediction* και ο χρόνος προσομοίωσης είναι ένα έτος. Αποθηκεύσαμε τη χρονοσειρά της εξόδου του στο *Workspace* της MATLAB και από εκεί τα επόμενα μοντέλα έλαβαν όλες τις τιμές των προβλέψεων με τον ίδιο τρόπο που θα γινόταν αν βρισκόντουσαν σε κοινό μοντέλο. Τα υπόλοιπα τέσσερα "κομμάτια" αποτελούνται από το ίδιο μοντέλο του *Controller* με το καθένα να έχει υποτετραπλάσιο του ετήσιου χρόνου προσομοίωσης.

Περιορισμός 4

Κάποιες ενέργειες του μοντέλου στο Simulink έχουν παραλειφθεί για την αποφυγή υπερβολικά μεγάλων διαγραμμάτων που δε θα μπορούσαν να χωρέσουν στις εικόνες. Επιπλέον, ό,τι παραλείφθηκε αφορά διαδικαστικές ενέργειες για τη λειτουργία του Simulink και δεν έχει να κάνει με τη δομή του συστήματος που είναι και αυτό που μας ενδιαφέρει να φανεί.

Υποθέσεις

Υπόθεση 1

Έχουμε υποθέσει ότι η καταγραφή παρουσίας γίνεται ανάλογα με το αν βρίσκεται κάποιος στο χώρο τη στιγμή εκκίνησης του τρεχούμενου χρονικού διαστήματος. Έστω ότι η χρονική στιγμή τ αφορά την ώρα 08:10 κάποιας ημέρας. Αν ο χώρος είναι "άδειος" στις 08:10 που ενημερώνεται το σύστημα, και εισέλθει κάποιος στις 08:12 το σύστημα θα ενημερωθεί για την αλλαγή κατάστασης τη χρονική στιγμή $\tau+1$, δηλαδή ώρα 08:20, εάν βέβαια ο κάτοικος βρίσκεται ακόμα στο χώρο.

Υπόθεση 2

Το ετήσιο χρονοδιάγραμμα της εξωτερικής θερμοκρασίας θεωρείται γνωστό εκ των προτέρων και οι τιμές του είναι οι τιμές του αρχείου καιρού της ενεργειακής προσομοίωσης της κατοικίας μας στο Open Studio.

Βιβλιογραφία

- [1] Omaima N A Al-Allaf and Shahlla A Abdalkader. *NONLINEAR AUTOREGRESSIVE NEURAL NETWORK FOR ESTIMATION SOIL TEMPERATURE: A COMPARISON OF DIFFERENT OPTIMIZATION NEURAL NETWORK ALGORITHMS*. Tech. rep. URL: www.ubicc.org.
- [2] Christopher M. Bishop. *Neural networks for pattern recognition*. Clarendon Press, 1995, p. 482. URL: <https://global.oup.com/academic/product/neural-networks-for-pattern-recognition-9780198538646?cc=gr%7B%5C%7Dlang=en%7B%5C%7D>.
- [3] *Choose a Multilayer Neural Network Training Function - MATLAB & Simulink - MathWorks*. URL: <https://ch.mathworks.com/help/deeplearning/ug/choose-a-multilayer-neural-network-training-function.html>.
- [4] *Deep Learning: Back Propagation – Towards Data Science*. URL: <https://towardsdatascience.com/back-propagation-414ec0043d7>.
- [5] *EnergyPlus*. URL: <https://energyplus.net/>.
- [6] *Eurostat*. URL: <https://ec.europa.eu/eurostat/web/energy/data/main-tables>.
- [7] *Fit Data with a Shallow Neural Network - MATLAB & Simulink - MathWorks*. URL: <https://ch.mathworks.com/help/deeplearning/gs/fit-data-with-a-neural-network.html>.
- [8] Simon S. Haykin. *Neural networks : a comprehensive foundation*. Prentice Hall, 1999. URL: <https://books.google.gr/books/about/Neural%7B%5C%7DNetworks.html?id=M5abQgAACAAJ%7B%5C%7Dredir%7B%5C%7Ddesc=y>.
- [9] Bekir Karlik and A Vehbi Olgac. *Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks*. Tech. rep. URL: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.740.9413%7B%5C%7Drep=rep1%7B%5C%7Dtype=pdf>.
- [10] Azme Khamis and Siti Nabilah Syuhada Binti Abdullah. *Forecasting Wheat Price Using Backpropagation And NARX Neural Network*. Tech. rep. URL: www.theijes.com.
- [11] Wilhelm Kleiminger, Friedemann Mattern, and Silvia Santini. “Predicting household occupancy for smart heating control: A comparative performance analysis of state-of-the-art approaches”. In: *Energy and Buildings* (2014), pp. 493–505.
- [12] Jiakang Lu et al. “The Smart Thermostat: Using Occupancy Sensors to Save Energy in Homes”. In: *Proceedings of the 8th ACM Conference on Embedded Networked Sensor Systems*. ACM, 2010, pp. 211–224. URL: <http://doi.acm.org/10.1145/1869983.1870005>.

-
- [13] Donald W. Marquardt. "An Algorithm for Least-Squares Estimation of Nonlinear Parameters". In: *Journal of the Society for Industrial and Applied Mathematics* 11.2 (June 1963), pp. 431–441. URL: <http://epubs.siam.org/doi/10.1137/0111030>.
- [14] Mathworks. *Divide Data for Optimal Neural Network Training, Documentation*. 2018. URL: <https://www.mathworks.com/help/deeplearning/ug/divide-data-for-optimal-neural-network-training.html>.
- [15] Mathworks. *Documentation - Fit Data with a Shallow Neural Network*. 2018. URL: <https://ch.mathworks.com/help/deeplearning/gs/fit-data-with-a-neural-network.html>.
- [16] Mathworks. *Documentation - Shallow Neural Network Time-Series Prediction and Modeling*. 2018. URL: <https://www.mathworks.com/help/deeplearning/gs/neural-network-time-series-prediction-and-modeling.html>.
- [17] Mathworks. *Mathworks Answers*. 2018. URL: <https://ch.mathworks.com/matlabcentral/answers/142478-how-can-find-the-optimal-delays-and-number-of-hidden-nodes-in-narnet-for-forecasting-task>.
- [18] Mathworks. *Simulink - Simulation and Model-Based Design*. 2018. URL: <https://www.mathworks.com/products/simulink.html>.
- [19] Mathworks. *Use DWork Vectors in S-Functions*. 2018. URL: <https://ch.mathworks.com/help/simulink/sfg/dwork-matlab.html>.
- [20] Michael C Mozer, Lucky Vidmar, and Robert H Dodier. *The Neurothermostat: Predictive Optimal Control of Residential Heating Systems*. Tech. rep. URL: <https://papers.nips.cc/paper/1299-the-neurothermostat-predictive-optimal-control-of-residential-heating-systems.pdf>.
- [21] K S Narendra and K Parthasarathy. *Identification and control of dynamical systems using neural networks*. 1990. URL: <http://ieeexplore.ieee.org/articleDetails.jsp?arnumber=80202>.
- [22] OpenStudio. URL: <https://www.openstudio.net/>.
- [23] Lynne E Parker. *Notes on Multilayer, Feedforward Neural Networks CS494/594: Machine Learning Fall 2007*. Tech. rep. URL: <http://web.eecs.utk.edu/%7B~%7Dleparker/Courses/CS594-fall07/handouts/Neural-net-notes.pdf>.
- [24] D. Patterson. *Artificial Neural Networks*. Prentice Hall, 1996, p. 482. URL: <https://global.oup.com/academic/product/neural-networks-for-pattern-recognition-9780198538646?cc=gr%7B%5C%7Dlang=en%7B%5C%7D>.
- [25] W. S. Sarle. *Neural Network FAQ*. 2002. URL: <http://www.faqs.org/faqs/ai-faq/neural-nets/part3/section-10.html>.
- [26] James Scott et al. *PreHeat: Controlling Home Heating Using Occupancy Prediction*. 2011. URL: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.221.3771%7B%5C%7Drep=rep1%7B%5C%7Dtype=pdf>.
- [27] *Statistics and Machine Learning Toolbox Documentation*. URL: <https://ch.mathworks.com/help/stats/index.html>.

-
- [28] S R Taghizadeh. *Digital Signal Processing - Part 3 Discrete-Time Signals & Systems Case Studies*. Tech. rep. 2000. URL: <http://aparatelth.ucv.ro/POPA/Matla/matlabsignal.pdf>.
- [29] Avinash Sharma V. *Understanding Activation Functions in Neural Networks*. 2017. URL: <https://medium.com/the-theory-of-everything/understanding-activation-functions-in-neural-networks-9491262884e0>.
- [30] Koehrsen William. *Overfitting vs. Underfitting: A Complete Example*. 2018. URL: <https://towardsdatascience.com/overfitting-vs-underfitting-a-complete-example-d05dd7e19765>.
- [31] Κωνσταντίνος Διαμαντάρας. *Τεχνητά νευρωνικά δίκτυα*. Ed. by Εκδόσεις Κλειδάριθμος, 2007.
- [32] Βλαχάβας Ι. και Κεφαλός Π. και Βασιλειάδης Ν. και Κόκκορας Φ. και Σακελλαρίου Η. *Τεχνητή Νοημοσύνη*. Εκδόσεις Παν/μίου Μακεδονίας, 2011.
- [33] Θεοδόση - Κοκκίνου Λάουρα. “Τεχνητά Νευρωνικά Δίκτυα και εφαρμογές στα Συστήματα Αυτομάτου Ελέγχου”. Διπλωματική Εργασία Ηλεκτρολόγων Μηχανικών και Τεχνολογίας Υπολογιστών. 2013.
- [34] Γιάννης Ρεφανίδης. *Νευρωνικά Δίκτυα*. Tech. rep. 2011.