

Πανεπιστήμιο Δυτικής Μακεδονίας
Τμήμα Ηλεκτρολόγων Μηχανικών & Μηχανικών
Υπολογιστών

Βελτιστοποίηση ενεργειακών
συστημάτων κτηρίων

Αχιλλέας Γραμμένος (ΑΜ: 1312)
Επιβλέπων Καθηγητής: Νικόλαος Πλόσκας

Εργαστήριο Ευφρών Συστημάτων & Βελτιστοποίησης
23 Οκτωβρίου 2022

Περίληψη

Ένα μεγάλο ποσοστό της κατανάλωσης ενέργειας παγκοσμίως οφείλεται στα ενεργειακά συστήματα κτηρίων. Σε αυτά εντάσσονται τα συστήματα θέρμανσης και κλιματισμού εσωτερικών χώρων τα οποία εξασφαλίζουν ένα βιώσιμο και άνετο περιβάλλον για τους ανθρώπους. Ζητούμενο είναι η ελαχιστοποίηση της κατανάλωσης ενέργειας των συστημάτων αυτών, χωρίς να θυσιαστεί η θερμική άνεση. Για την επίτευξη αυτού του στόχου, οι ερευνητές κατέφυγαν στη δημιουργία μεθόδων μοντελοποίησης για να πετύχουν καλύτερη εποπτεία της θερμικής συμπεριφοράς των κτηρίων. Σε αυτή την κατεύθυνση, είναι απαραίτητος ο υπολογισμός του θερμικού βαθμού απόδοσης κτηρίων. Ο υπολογισμός του απαιτεί δεδομένα που προκύπτουν από μετρήσεις αισθητηρίων. Στην παρούσα εργασία κατασκευάστηκαν Βαθιά Νευρωνικά Δίκτυα με στόχο τον προσδιορισμό του θερμικού βαθμού απόδοσης ακόμα και σε περιπτώσεις που δεν υπάρχουν όλες οι απαραίτητες μετρήσεις. Με την πειραματική διαδικασία αποδεικνύεται ότι με χρήση των νευρωνικών δικτύων που υλοποιήθηκαν, είναι εφικτή η προσέγγιση του θερμικού βαθμού απόδοσης με αρκετά μεγάλη ακρίβεια για διάφορους συνδυασμούς μετρήσεων και δεδομένων.

Λέξεις κλειδιά: Μηχανική μάθηση, Βαθιά Νευρωνικά Δίκτυα, Παλινδρόμηση, Ενεργειακά συστήματα κτηρίων, Python

Abstract

A large percentage of energy consumption worldwide is due to building energy systems. These include indoor heating and air conditioning systems that ensure a healthy and comfortable environment for people. The aim is to minimize the energy consumption of these systems, without reducing thermal comfort. To achieve this goal, researchers created modeling methods in order to have well supervision of the buildings thermal behavior. A step to achieve this is the calculation of buildings thermal efficiency. Its calculation requires data resulting from sensor measurements. In this work, Deep Neural Networks were constructed with the aim of determining the thermal efficiency even in cases where not all the necessary measurements are available. Through the experimental process, it is proven that using the implemented Neural Networks, it is possible to approximate the thermal efficiency with enough accuracy for various measurements and data.

Keywords: Machine learning, Deep Neural Networks, Regression, Building energy systems, Python

Δήλωση Πνευματικών Δικαιωμάτων

Δήλωση Πνευματικών Δικαιωμάτων Δηλώνω ρητά ότι, σύμφωνα με το άρθρο 8 του Ν. 1599/1986 και τα άρθρα 2,4,6 παρ. 3 του Ν. 1256/1982, η παρούσα Διπλωματική Εργασία με τίτλο "Βελτιστοποίηση ενεργειακών συστημάτων κτηρίων" καθώς και τα ηλεκτρονικά αρχεία και πηγαίοι κώδικες που αναπτύχθηκαν ή τροποποιήθηκαν στα πλαίσια αυτής της εργασίας και αναφέρονται ρητώς μέσα στο κείμενο που συνοδεύουν, και η οποία έχει εκπονηθεί στο Τμήμα Ηλεκτρολόγων Μηχανικών & Μηχανικών Υπολογιστών του Πανεπιστημίου Δυτικής Μακεδονίας, υπό την επίβλεψη του μέλους του Τμήματος κ. Νικολάου Πλόσκα αποτελεί αποκλειστικά προϊόν προσωπικής εργασίας και δεν προσβάλλει κάθε μορφής πνευματικά δικαιώματα τρίτων και δεν είναι προϊόν μερικής ή ολικής αντιγραφής, οι πηγές δε που χρησιμοποιήθηκαν περιορίζονται στις βιβλιογραφικές αναφορές και μόνον. Τα σημεία όπου έχω χρησιμοποιήσει ιδέες, κείμενο, αρχεία ή / και πηγές άλλων συγγραφέων, αναφέρονται ευδιάκριτα στο κείμενο με την κατάλληλη παραπομπή και η σχετική αναφορά περιλαμβάνεται στο τμήμα των βιβλιογραφικών αναφορών με πλήρη περιγραφή.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα. Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και μόνο.

Copyright (C) Αχιλλέας Γραμμένος & Νικόλαος Πλόσκας, 2022, Κοζάνη

Υπογραφή Φοιτητή

Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον κ. Νικόλαο Πλόσκα, Επίκουρο Καθηγητή του Τμήματος Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών. Χωρίς την καθοδήγησή του, η εκπόνηση της παρούσας εργασίας θα ήταν αδύνατη. Επιπλέον, θέλω να ευχαριστήσω την οικογένειά μου για τη στήριξή της σε κάθε μου προσπάθεια.

Περιεχόμενα

1	Εισαγωγή	11
1.1	Ορισμός προβλήματος	11
1.2	Κίνητρο και στόχοι	13
1.3	Διάρθρωση κειμένου	13
2	Νευρωνικά Δίκτυα	14
2.1	Εισαγωγή στα νευρωνικά δίκτυα	14
2.1.1	Κατηγορίες προβλημάτων	14
2.1.2	Τρόποι εκπαίδευσης	15
2.2	Feedforward Neural Networks	17
2.3	Recurrent Neural Networks	19
2.3.1	Simple Recurrent Neural Networks	19
2.3.2	Long Short-Term Memory	20
2.3.3	Bidirectional Long Short-Term Memory	20
3	Βιβλιογραφική Ανασκόπηση	22
3.1	Εισαγωγή	22
3.2	Πρόβλεψη κατανάλωσης ενέργειας συστημάτων θέρμανσης	22
3.3	Προσδιορισμός θερμικών φορτίων κτηρίων	23
3.4	Πρόβλεψη κατανάλωσης ενέργειας σε συστήματα κλιματισμού	24
3.5	Πρόβλεψη θερμοκρασίας εσωτερικού χώρου	25
3.6	Πρόβλεψη ζήτησης ενέργειας συστημάτων θέρμανσης και κλιματισμού	26
3.7	Πρόβλεψη ηλεκτρικού φορτίου συστημάτων θέρμανσης και κλιματισμού	27
3.8	Προβλέψεις θερμοκρασίας και υγρασίας κτηρίων	27
3.9	Προσδιορισμός ενεργειακής κατανάλωσης συστήματος θέρμανσης	28

4	Πειραματικό Μέρος	30
4.1	Ορισμός προβλήματος	30
4.2	Βαθμός απόδοσης συστημάτων θέρμανσης	30
4.3	Εργαλεία	31
4.3.1	Python	31
4.3.2	Tensorflow.Keras	32
4.4	Σύνολα δεδομένων	32
4.5	Είδη αλγορίθμων	33
4.6	Παράμετροι νευρωνικών δικτύων	34
4.7	Πειράματα	35
4.8	Περιγραφή κώδικα	36
4.8.1	Εισαγωγή	36
4.8.2	Κύριο μέρος	36
4.8.3	Βοηθητικές συναρτήσεις	38
4.9	Μετρικές αξιολόγησης	38
4.10	Αποτελέσματα	40
5	Σχολιασμός - Συμπεράσματα	50
5.1	Σχολιασμός αποτελεσμάτων	50
5.2	Συμπεράσματα	52
5.3	Μελλοντικές προεκτάσεις	53

Κατάλογος σχημάτων

2.1	Πρόβλημα κατηγοριοποίησης [1]	15
2.2	Πρόβλημα παλινδρόμησης [2]	15
2.3	Μάθηση με επίβλεψη [1]	16
2.4	Μη επιβλεπόμενη μάθηση [3]	16
2.5	Παράδειγμα ενισχυτικής μάθησης [4]	17
2.6	Απεικόνιση Feedforward Neural Network [5]	18
2.7	Ξεδίπλωμα μονάδας Recurrent Neural Network [6]	19
2.8	Σύγκριση LSTM - RNN [7]	21
3.1	Αποτελέσματα Kalogirou & Bojic [8]	23
3.2	Διάγραμμα ισοτιμίας Turhan et al. [9]	24
3.3	Αποτελέσματα Zhou et. al. [10]	25
3.4	Αποτελέσματα Fatma et. al. [11]	26
3.5	Αποτελέσματα Cheng et. al. [12]	28
4.1	Κύκλωμα θέρμανσης	31
4.2	Box plots πρώτου συνόλου δεδομένων	33
4.3	Box plots δευτέρου συνόλου δεδομένων	33
4.4	Fitting accuracy - Πρώτο πείραμα	41
4.5	Fitting accuracy - Δεύτερο πείραμα	43
4.6	Fitting accuracy - Τρίτο πείραμα	44
4.7	Fitting accuracy - Τέταρτο πείραμα	45
4.8	Fitting accuracy - Πέμπτο πείραμα	46
4.9	Fitting accuracy - Έκτο πείραμα	47
4.10	Τιμές μέσου απολύτου σφάλματος για 10 εκτελέσεις - Χρήση δευτέρου συνόλου δεδομένων και πέντε μεταβλητών εισόδου	47

4.11 Τιμές μέσου απολύτου σφάλματος για 10 εκτελέσεις - Χρήση δευτέ- ρου συνόλου δεδομένων και τεσσάρων μεταβλητών εισόδου	48
4.12 Τιμές μέσου απολύτου σφάλματος για 10 εκτελέσεις - Χρήση δυο συνόλων δεδομένων και πέντε μεταβλητών εισόδου	48
4.13 Τιμές μέσου απολύτου σφάλματος για 10 εκτελέσεις - Χρήση δυο συνόλων δεδομένων και τεσσάρων μεταβλητών εισόδου	48
4.14 Χρόνος εκπαίδευσης σε δευτερόλεπτα - Δυο σύνολα δεδομένων, τέσ- σερις μεταβλητές	49

Κατάλογος αλγορίθμων

1	Κύριος αλγόριθμος	39
---	-----------------------------	----

Κατάλογος πινάκων

4.1	Παράδειγμα συνόλου δεδομένων	33
4.2	Χρήση πρώτου συνόλου δεδομένων - Πέντε μεταβλητές εισόδου	41
4.3	Χρήση δεύτερου συνόλου δεδομένων - Πέντε μεταβλητές εισόδου . . .	42
4.4	Χρήση δυο συνόλων δεδομένων - Πέντε μεταβλητές εισόδου	42
4.5	Χρήση πρώτου συνόλου δεδομένων - Τέσσερις μεταβλητές εισόδου . .	43
4.6	Χρήση δεύτερου συνόλου δεδομένων - Τέσσερις μεταβλητές εισόδου .	46
4.7	Χρήση δυο συνόλων δεδομένων - Τέσσερις μεταβλητές εισόδου	46

Κεφάλαιο 1

Εισαγωγή

1.1 Ορισμός προβλήματος

Σύμφωνα με στοιχεία της Ευρωπαϊκής Ένωσης, ένα σημαντικό ποσοστό της συνολικής παγκόσμιας ενέργειας καταναλώνεται στα κτήρια [13] κυρίως σε συστήματα θέρμανσης, εξαερισμού και κλιματισμού (ΘΕΚ). Τα τελευταία χρόνια ζητούμενο είναι η δημιουργία άνετου περιβάλλοντος εντός των κτηρίων με την ελάχιστη κατανάλωση ενέργειας. Στην κατεύθυνση αυτή είναι ιδιαίτερα βοηθητική η ύπαρξη καλύτερου ελέγχου θερμοκίνης συμπεριφοράς και απόδοσης κτηρίων μέσω μεθόδων μοντελοποίησης [14]. Η μοντελοποίηση μπορεί να παρέχει πληροφορίες σχετικές με τα θερμικά φορτία, να υπολογίζει την κατανάλωση ενέργειας και την απόδοση ενός συστήματος ΘΕΚ.

Οι συνεχώς αυξανόμενες ανάγκες των ανθρώπων οδηγούν στην αύξηση κατανάλωσης ενέργειας. Ένα σημαντικό ποσό ενέργειας δαπανάται κάθε χρόνο στα κτήρια. Συγκεκριμένα, το 2020 η κατανάλωση στην Ευρωπαϊκή Ένωση έφτασε περίπου το 40% της συνολικής ενέργειας [13]. Η υψηλή κατανάλωση ενέργειας οδηγεί στην κλιματική αλλαγή δηλαδή ύπαρξη ακραίων θερμοκρασιών, την αύξηση συγκέντρωσης αερίων του θερμοκηπίου και σε πολλά άλλα προβλήματα [15]. Επομένως, είναι απαραίτητη η μείωση κατανάλωσης ενέργειας ώστε να βελτιωθούν οι συνθήκες διαβίωσης και να αποφευχθούν μελλοντικές περιβαλλοντικές καταστροφές.

Το άλλο ζητούμενο είναι η άνεση. Ένα άνετο περιβάλλον οδηγεί σε υψηλότερη ικανοποίηση, παραγωγικότητα και ευημερία των ανθρώπων που κατοικούν σε αυτό. Η αίσθηση άνεσης σε έναν εσωτερικό χώρο εξαρτάται από τις παρακάτω παραμέτρους: τη θερμική άνεση, την ποιότητα αέρα, την ακουστική άνεση και την οπτική

άνεση [16]. Η ποιότητα αέρα ορίζεται από τη συγκέντρωση του αέρα σε CO₂ [17], σε σωματίδια PM_{2.5}, σε πτητικές οργανικές ενώσεις και φορμαλδεΰδη. Η ακουστική και οπτική άνεση προσδιορίζονται από τη στάθμη ήχου και επίπεδα φωτεινότητας, αντίστοιχα [18]. Από τους παραπάνω παράγοντες, η θερμική άνεση επηρεάζει περισσότερο την υγεία και την ευημερία των ανθρώπων [18]. Η θερμική άνεση σχετίζεται με παράγοντες που αφορούν τη θερμική προσαρμογή του κάθε ανθρώπου, όπως η γεωγραφική θέση και το κλίμα, εποχή του χρόνου, φύλο, φυλή και ηλικία [19]. Το ανθρώπινο σώμα προσπαθεί να διατηρήσει μια θερμοκρασία περίπου 37 °C. Η θερμοκρασία διατηρείται μέσω ανταλλαγής θερμότητας μεταξύ του ανθρώπινου σώματος και του περιβάλλοντος. Επηρεάζεται από περιβαλλοντικούς και προσωπικούς παράγοντες. Οι περιβαλλοντικοί είναι η θερμοκρασία του αέρα, η σχετική υγρασία του αέρα και η ταχύτητα του αέρα. Οι προσωπικοί παράγοντες περιλαμβάνουν τον μεταβολισμό του κάθε ανθρώπου και τη μόνωση που προκαλεί ο ρουχισμός [20]. Τέλος, η θερμική άνεση μπορεί να οριστεί σύμφωνα με τα πρότυπα ASHRAE 55 (2010) και ISO 7730 (1994), ως «η κατάσταση του νου που εκφράζει ικανοποίηση για το θερμικό περιβάλλον στο οποίο βρίσκεται» [21].

Για την επίτευξη άνετου περιβάλλοντος με την ελάχιστη δαπάνη ενέργειας, είναι απαραίτητη η καλή εποπτεία των συστημάτων που την καθορίζουν. Δεδομένου ότι υπάρχουν πολλές παράμετροι που πρέπει να ληφθούν υπόψη, γίνεται αντιληπτό ότι πρόκειται για ένα εξαιρετικά πολύπλοκο και χρονοβόρο υπολογιστικό πρόβλημα. Το πρόβλημα αυτό μπορεί να απλοποιηθεί με χρήση μεθόδων μοντελοποίησης. Η μοντελοποίηση βοηθά στην παροχή πληροφοριών σχετικών με τη θερμότητα σε έναν χώρο, την κατανάλωση ενέργειας, την απόδοση των συστημάτων ΘΕΚ και σε πολλά άλλα. Υπάρχουν πολλά παραδείγματα χρήσης μεθόδων μοντελοποίησης που αφορούν ενεργειακά συστήματα κτηρίων. Ένα παράδειγμα είναι η χρήση αλγορίθμου για την εύρεση της χρυσής τομής μεταξύ άνεσης και ενεργειακού κόστους σε συστήματα ΘΕΚ [22]. Άλλο σύστημα χρησιμοποιήθηκε για σχεδιασμό κατοικιών χαμηλών εκπομπών, κυρίως ελαχιστοποιώντας την εκπομπή διοξειδίου του άνθρακα και μειώνοντας το κόστος χρήσης συστημάτων ΘΕΚ [23].

1.2 Κίνητρο και στόχοι

Η κατανάλωση ενέργειας σε συστήματα ΘΕΚ κτηρίων είναι πολύ μεγάλη. Σήμερα υπάρχει όσο ποτέ άλλοτε ανάγκη να μειωθεί στο ελάχιστο. Ταυτόχρονα καλό είναι να συνεχίσουν να καλύπτονται ικανοποιητικά οι ανάγκες των ανθρώπων για θέρμανση και ψύξη. Για να πραγματοποιηθούν οι δυο προαναφερθείσες ανάγκες, απαιτούνται ενέργειες που θα εξασφαλίσουν αποδοτικότερα συστήματα. Η βελτίωση της ενεργειακής απόδοσης των συστημάτων ΘΕΚ, προϋποθέτει καλή εποπτεία των υπάρχοντων συστημάτων. Μια από τις σημαντικότερες παραμέτρους που πρέπει να λαμβάνεται υπόψη είναι ο θερμικός βαθμός απόδοσης. Στόχος της παρούσας εργασίας είναι λαμβάνοντας δεδομένα που αφορούν συστήματα θέρμανσης από αισθητήρια, να προσδιορίζεται με χρήση νευρωνικών δικτύων η τιμή του θερμικού βαθμού απόδοσης.

1.3 Διάρθρωση κειμένου

Η παρούσα εργασία χωρίζεται σε πέντε κεφάλαια. Στο δεύτερο κεφάλαιο γίνεται μια εισαγωγή στα νευρωνικά δίκτυα και περιγράφονται ορισμένες από τις κατηγορίες αυτών. Το τρίτο κεφάλαιο αποτελείται από παρουσιάσεις σχετικών άρθρων και των αποτελεσμάτων τους, που αφορούν χρήση νευρωνικών δικτύων σε προβλήματα ενεργειακών συστημάτων κτηρίων. Στο τέταρτο κεφάλαιο περιγράφονται τα πειράματα. Ορίζεται το πρόβλημα, περιγράφονται τα δεδομένα και οι τεχνικές που χρησιμοποιήθηκαν και παρουσιάζονται οι τρόποι αξιολόγησης των αποτελεσμάτων. Τέλος, στο πέμπτο κεφάλαιο παρουσιάζονται και σχολιάζονται τα αποτελέσματα των πειραμάτων και αναφέρονται μελλοντικές προεκτάσεις αυτών.

Κεφάλαιο 2

Νευρωνικά Δίκτυα

2.1 Εισαγωγή στα νευρωνικά δίκτυα

Τα νευρωνικά δίκτυα αποτελούν μια σημαντική ενότητα της μηχανικής μάθησης. Είναι αλγόριθμοι με στόχο την εύρεση σχέσεων μεταξύ σειρών δεδομένων. Για την επίτευξη αυτού του στόχου μιμούνται τη δομή και τη λειτουργία των νευρώνων του εγκεφάλου από τους οποίους πήραν και το όνομά τους. Η μάθηση είναι η ικανότητα του εγκεφάλου να προσαρμόζεται με βάση ερεθίσματα και πληροφορίες που δέχεται, με σκοπό την επίλυση προβλημάτων. Σε αυτή βασίστηκαν το 1943 οι Warren McCulloch και Walter Pitts για να δημιουργήσουν το πρώτο ηλεκτρικό κύκλωμα με δυνατότητα μάθησης [24].

Τα νευρωνικά δίκτυα ακολουθώντας τη λογική εκμάθησης του ανθρωπίνου εγκεφάλου, χρειάζονται εκπαίδευση πριν την έναρξη επίλυσης οποιουδήποτε προβλήματος. Ως προς τη δομή τους μπορούν να χωριστούν σε τρεις μεγάλες κατηγορίες:

- Feedforward Neural Networks (FNN)
- Recurrent Neural Networks (RNN)
- Convolutional Neural Networks (CNN)


2.1.1 Κατηγορίες προβλημάτων

Τα είδη των προβλημάτων που επιλύουν ανήκουν στις παρακάτω κατηγορίες:

- Κατηγοριοποίηση (classification)
- Παλινδρόμηση (regression)


Στα προβλήματα κατηγοριοποίησης, σκοπός είναι η τοποθέτηση μιας μεταβλητής σε κάποια κατηγορία. Ορισμένα παραδείγματα είναι: κατηγοριοποίηση ιατρικών εικόνων (ακτινογραφιών κ.α.) [25][26], κατηγοριοποίηση κειμένων [27][28], η κατηγοριοποίηση email [29][30] κ.α. Παράδειγμα του αποτελέσματος ενός προβλήματος κατηγοριοποίησης φαίνεται στο Σχήμα 2.1.

Σχήμα 2.1: Πρόβλημα κατηγοριοποίησης [1]



Η παλινδρόμηση αφορά προβλήματα στα οποία η τιμή της μεταβλητής εξόδου είναι συνεχής [31]. Παραδείγματα είναι η πρόβλεψη του αριθμού πωλήσεων ενός προϊόντος σε δεδομένο χρονικό διάστημα [32], η πρόβλεψη ηλικίας ενός ανθρώπου [33] [34], πρόβλεψη τιμής ακινήτου μετά από κάποιο χρονικό διάστημα [35] [36] κ.α. Στο Σχήμα 2.2 υπάρχει ένα διάγραμμα ισοτιμίας που αφορά πρόβλημα παλινδρόμησης.

Σχήμα 2.2: Πρόβλημα παλινδρόμησης [2]




2.1.2 Τρόποι εκπαίδευσης

Τα νευρωνικά δίκτυα δύνανται να χωριστούν σε τρεις κατηγορίες ανάλογα με τον τρόπο που εκπαιδεύονται.

Ο πρώτος τρόπος εκπαίδευσης είναι η επιβλεπόμενη μάθηση (supervised learning) [37]. Στην επιβλεπόμενη μάθηση, παρέχονται στο νευρωνικό δίκτυο σειρές δεδομέ-

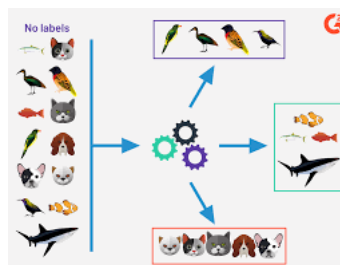
νων εισόδου και εξόδου κατά τη διάρκεια της εκπαίδευσης. Αρχικά, χρησιμοποιεί τις τιμές εισόδου της πρώτης σειράς δεδομένων για να προβλέψει την τιμή εξόδου και στη συνέχεια τη συγκρίνει με την πραγματική τιμή εξόδου. Βλέποντας την απόσταση από το σωστό αποτέλεσμα εκτελεί ορισμένες μαθηματικές πράξεις ώστε στην επόμενη προσπάθεια να πλησιάσει περισσότερο το σωστό αποτέλεσμα. Έπειτα εκτελεί την ίδια διαδικασία για όλες τις σειρές δεδομένων. Με το πέρας της εκπαίδευσης το νευρωνικό δίκτυο πρέπει να είναι ικανό δεχόμενο αποκλειστικά μεταβλητές εισόδου, να προβλέπει την έξοδο με την απαιτούμενη ακρίβεια. Στο Σχήμα 2.3 παρουσιάζεται ένα σχεδιάγραμμα που δείχνει τη διαδικασία της μάθησης με επίβλεψη.

Σχήμα 2.3: Μάθηση με επίβλεψη [1]



Ο δεύτερος τρόπος εκπαίδευσης είναι η μη επιβλεπόμενη μάθηση (unsupervised learning). Σε αυτό τον τύπο εκπαίδευσης δεν απαιτούνται δεδομένα εκπαίδευσης. Η μη επιβλεπόμενη μάθηση μπορεί να χρησιμοποιηθεί μόνο για κατηγοριοποίηση, καθώς στην περίπτωση αυτή το νευρωνικό δίκτυο ανακαλύπτει μοτίβα στα δεδομένα εισόδου με σκοπό την τοποθέτησή τους σε κατηγορίες. Ένα παράδειγμα είναι η κατηγοριοποίηση εικόνων ζώων ανά είδος [38] (Σχήμα 2.4).


Σχήμα 2.4: Μη επιβλεπόμενη μάθηση [3]



Ο τρίτος τρόπος εκπαίδευσης είναι η ενισχυτική μάθηση (reinforcement learning) [39]. Πρόκειται για μέθοδο που βασίζεται στη λήψη κατάλληλων αποφάσεων για τη βελτιστοποίηση του αποτελέσματος σε ένα πρόβλημα. Με άλλα λόγια το σύστημα

μαθαίνει από την εμπειρία του χωρίς να του παραχθούν δεδομένα εκπαίδευσης. Θα μπορούσε να χαρακτηριστεί και ως ένα είδος μη εποπτευόμενης μάθησης. Παραδείγματα αποτελούν η δρομολόγηση οχημάτων [40][41] και η δρομολόγηση ρομπότ [42]. Στο Σχήμα 2.5, υπάρχει μια οπτική απεικόνιση εφαρμογής ενισχυτικής μάθησης.

Σχήμα 2.5: Παράδειγμα ενισχυτικής μάθησης [4]




2.2 Feedforward Neural Networks

Μια γενική κατηγορία νευρωνικών δικτύων είναι τα Feedforward Neural Networks (FNN). Αυτά τα νευρωνικά δίκτυα όπως φαίνεται και στο Σχήμα 2.6 αποτελούνται από τρία κύρια μέρη: ένα στρώμα εισόδου (input layer), το κρυφό στρώμα (hidden layer)-όχι υποχρεωτικά- και ένα στρώμα εξόδου (output layer) [43][44]. Το κυριότερο χαρακτηριστικό των FNNs είναι η μονόδρομη πορεία από το στρώμα εισόδου προς το στρώμα εξόδου. Πιο αναλυτικά: το στρώμα εισόδου εισάγει το διάνυσμα αρχικών τιμών στο νευρωνικό δίκτυο και τα προωθεί στο κρυφό στρώμα το οποίο επεξεργάζεται με τη βοήθεια μαθηματικών πράξεων που θα εξηγήσουμε παρακάτω τις τιμές εισόδου για να τις φέρει στην επιθυμητή μορφή, ενώ το στρώμα εξόδου προκύπτει από την ενίσχυση του αποτελέσματος του κρυφού στρώματος και αποτελεί το τελικό αποτέλεσμα επεξεργασίας του νευρωνικού.

Η πιο απλή μορφή FNN είναι το single-layer perceptron στο οποίο οι τιμές του στρώματος εισόδου προωθούνται ενισχυμένες στο στρώμα εξόδου [45]. Με άλλα λόγια δεν υπάρχει κρυφό στρώμα. Η χρήση των συγκεκριμένων νευρωνικών δικτύων περιορίζεται στην επίλυση γραμμικά διαχωρίσιμων προβλημάτων.

Τα FNNs που περιλαμβάνουν και κρυφό στρώμα είναι ικανά να λύσουν μεγαλύτερη ποικιλία προβλημάτων, όπως το πρόβλημα XOR και η πρόβλεψη τιμής συνάρτησης. Όταν ένα νευρωνικό δίκτυο περιέχει περισσότερα από ένα κρυφά στρώματα, μιλάμε για βαθιά μάθηση (deep learning). Σε αυτή την περίπτωση, καθένα από τα κρυφά στρώματα μπορεί να έχει έναν ή περισσότερους κόμβους όπως φαίνεται στο Σχήμα 2.6. Για τις ανάγκες της εκπαίδευσης προσφέρονται στο δίκτυο διανύσματα X τα οποία περιλαμβάνουν τιμές των χαρακτηριστικών της προς πρόβλεψη συνάρτησης και τιμές y που αποτελούν τα σωστά αποτελέσματα της συνάρτησης. Τα νευρωνικά δίκτυα που δέχονται τέτοιου είδους δεδομένα ονομάζονται δίκτυα επιβλεπόμενης μάθησης (supervised learning) [43]. Η εκπαίδευση ενός νευρωνικού δικτύου αυτής της κατηγορίας χωρίζεται σε εποχές (epochs) και πραγματοποιείται ως εξής: Σε κάθε εποχή το διάνυσμα εισόδου εισάγεται σε κάθε κόμβο του πρώτου κρυφού στρώματος και πολλαπλασιάζεται με έναν αριθμό που ονομάζεται βάρος (weight). Το αποτέλεσμα, πολλαπλασιασμένο με μια συνάρτηση ενεργοποίησης (activation function)[44], προωθείται στο επόμενο κρυφό στρώμα και επαναλαμβάνεται η ίδια διαδικασία έως ότου φτάσουμε στο τελευταίο κρυφό στρώμα, το αποτέλεσμα του οποίου πολλαπλασιάζεται με μια συνάρτηση ενεργοποίησης και δίνεται στο στρώμα εξόδου ως τιμή που προέβλεψε το δίκτυο. Ακολουθώντας με τη βοήθεια μιας συνάρτησης υπολογισμού σφάλματος (loss function) υπολογίζεται η απόσταση της προβλεπόμενης τιμής από την αναμενόμενη [44]. Σε αυτό το σημείο τελειώνει η πρώτη εποχή. Σημειώνεται ότι ο στόχος είναι να μηδενιστεί το σφάλμα. Για να επιτευχθεί αυτό, πριν μεταβούμε στην επόμενη εποχή, ενημερώνονται οι τιμές των βαρών με τη χρήση ενός αλγορίθμου που ονομάζεται Backpropagation [43]. Η ανωτέρω διαδικασία επαναλαμβάνεται για κάθε εποχή.

Σχήμα 2.6: Απεικόνιση Feedforward Neural Network [5]



2.3 Recurrent Neural Networks


2.3.1 Simple Recurrent Neural Networks

Μια άλλη κατηγορία νευρωνικών δικτύων είναι τα Recurrent Neural Networks (RNN). Η κυριότερη διαφορά από τα FNN είναι ότι έχουν ένα είδος «μνήμης» [46][47]. Στα FNN όλες οι εισοδοί είναι ανεξάρτητες η μια από την άλλη [43]. Αντίθετα, τα RNN χρησιμοποιούν παραγόμενες τιμές επαναλαμβανόμενα επειδή εκτελούν την ίδια εργασία για κάθε στοιχείο μιας ακολουθίας, με την έξοδο να εξαρτάται από τους προηγούμενους υπολογισμούς [46]. Πιο συγκεκριμένα σε ένα RNN τα δεδομένα εισόδου εισέρχονται σε ένα ή περισσότερα αναδρομικά τμήματα και το αποτέλεσμα των πράξεων που πραγματοποιούνται προωθείται σε ένα στρώμα Feedforward στο οποίο υπολογίζεται το τελικό αποτέλεσμα [48].

Θέλοντας να εξετάσουμε αναλυτικότερα το αναδρομικό τμήμα του RNN, θα πρέπει να το «ξεδιπλώσουμε» συναρτήσει του χρόνου όπως φαίνεται στο Σχήμα 2.7 [47]. Το h_t είναι ένα διάνυσμα που αντιπροσωπεύει τις τιμές των βαρών των κρυμμένων καταστάσεων. Σε κάθε μονάδα του αναδρομικού τμήματος εισάγονται οι τιμές των βαρών του προηγούμενου διαδίδοντας την ήδη αποκτηθείσα «γνώση». Για την εκπαίδευση για τη σωστή ενημέρωση των βαρών χρησιμοποιείται ο αλγόριθμος Backpropagation Through Time [49].

Η παραπάνω διάταξη αποτελεί την πιο γενική και απλή μορφή RNN που ονομάζεται Simple RNN και προτάθηκε από τον Elman το 1990 [50].

Σχήμα 2.7: Ξεδίπλωμα μονάδας Recurrent Neural Network [6]



2.3.2 Long Short-Term Memory

Μια εξέλιξη του Simple RNN αποτελεί το Long short-term memory (LSTM) [51]. Σε αυτή την περίπτωση, σε κάθε αναδρομικό τμήμα προστίθενται τρεις πύλες οι οποίες βοηθούν στην εξάλειψη πολλών προβλημάτων που δημιουργούνται στα απλά RNN [46]. Οι πύλες αυτές είναι: πύλη εισόδου, πύλη εξόδου και πύλη λήθης. Οι πύλες αυτές συμβάλουν στη μη διάδοση σφαλμάτων που προκύπτουν κατά τη διάρκεια της εκπαίδευσης.

Το LSTM χρησιμοποιεί ένα διάνυσμα που ονομάζεται διάνυσμα κατάστασης. Οι πύλες αξιοποιούνται για την ενημέρωση του διανύσματος αυτού.

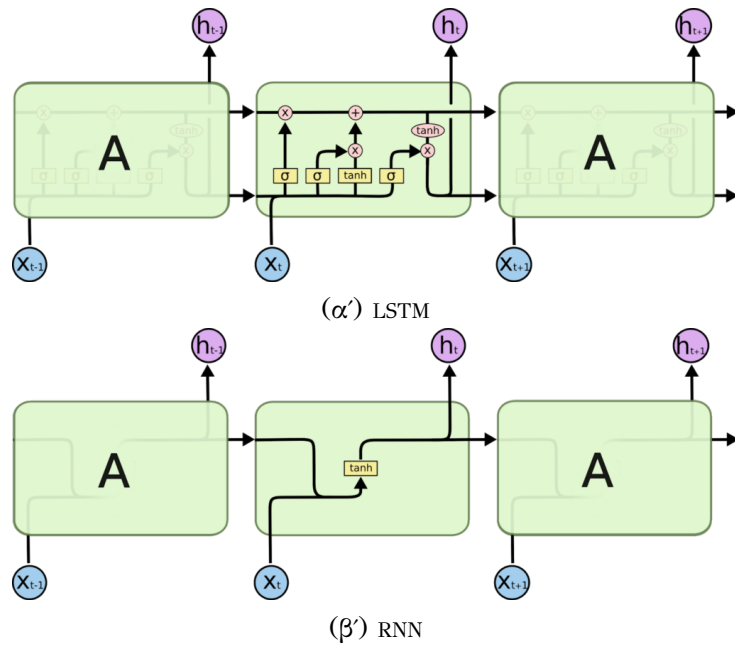
Αρχικά το LSTM αποφασίζει ποιες πληροφορίες θα διαγραφούν από το διάνυσμα κατάστασης. Αυτή η απόφαση λαμβάνεται από ένα στρώμα που ονομάζεται στρώμα της πύλης λήθης [51][52]. Εξετάζεται το διάνυσμα βαρών h_{t-1} και το διάνυσμα εισόδου X_t και βγάζει μια τιμή 0 ή 1 για κάθε προβλεπόμενη τιμή. Το 1 αντιπροσωπεύει διατήρηση της προβλεπόμενης τιμής ενώ το 0 αντιπροσωπεύει τη διαγραφή αυτής.

Στη συνέχεια λαμβάνεται απόφαση για το ποιες νέες πληροφορίες θα αποθηκευτούν. Αυτή η διαδικασία αποτελείται από δυο μέρη: ένα στρώμα που ονομάζεται στρώμα πύλης εισόδου [51] στο οποίο αποφασίζεται ποιες τιμές θα ενημερωθούν και ένα επίπεδο \tanh δημιουργεί ένα διάνυσμα νέων υποψήφιων τιμών που θα μπορούσαν να προστεθούν στην κατάσταση.

Λαμβάνοντας υπόψη το ενημερωμένο πλέον διάνυσμα κατάστασης γίνεται ο προσδιορισμός της νέας τιμής. Έτσι οι νέες υποψήφιες τιμές προκύπτουν με πιο ομαλό τρόπο προς αποφυγή διάδοσης σφαλμάτων. Στο Σχήμα 2.8 φαίνονται η δομή του LSTM και η διαφορά του από το απλό RNN.

2.3.3 Bidirectional Long Short-Term Memory

Το μονόδρομο LSTM διατηρεί αποκλειστικά πληροφορίες του παρελθόντος επειδή οι μόνες εισοδοί που έχει δεχθεί είναι από το παρελθόν. Στο αμφίδρομο (Bidirectional) LSTM, αντί να εκπαιδευτεί ένα μόνο μοντέλο, εισάγονται δύο. Το πρώτο μοντέλο μαθαίνει την ακολουθία της εισόδου που παρέχεται, όπως το μονόδρομο LSTM (από το παρελθόν προς το μέλλον), και το δεύτερο μοντέλο μαθαίνει το αντίστροφο αυτής της ακολουθίας (από το μέλλον προς το παρελθόν). Εφόσον τα εκπαιδευμένα μο-



Σχήμα 2.8: Σύγκριση LSTM - RNN [7]

ντέλα είναι δυο, πρέπει με κάποιον τρόπο να συνδυαστούν. Αυτό πραγματοποιείται συνήθως με την πράξη της σύνδεσης (concatenation). Το Bidirectional LSTM είναι πολύ αποδοτικό σε εφαρμογές στις οποίες τα δεδομένα είναι σειριακά όπως η ανάλυση βίντεο [53][54] και η αναγνώριση ομιλίας [55][56].

Κεφάλαιο 3

Βιβλιογραφική Ανασκόπηση


3.1 Εισαγωγή

Αρκετές έρευνες στον τομέα των ενεργειακών συστημάτων κτηρίων πραγματοποιήθηκαν με τη βοήθεια τεχνικών μηχανικής μάθησης και ιδιαίτερα των νευρωνικών δικτύων. Η χρήση αυτών των μεθόδων έγινε από τους ερευνητές στην προσπάθεια μοντελοποίησης των συστημάτων ΘΕΚ των κτηρίων. Στο κεφάλαιο αυτό παρουσιάζονται μερικές από τις έρευνες αυτού του τομέα, με έμφαση στα δεδομένα και στις μεθόδους που χρησιμοποιήθηκαν.


3.2 Πρόβλεψη κατανάλωσης ενέργειας συστημάτων θέρμανσης

Οι Kalogirou & Bojic [8] χρησιμοποίησαν νευρωνικά δίκτυα για την πρόβλεψη κατανάλωσης ενέργειας συστημάτων θέρμανσης κτηρίων. Συγκεκριμένα, τα πειράματα έγιναν με Feedforward και Recurrent νευρωνικά δίκτυα. Τα νευρωνικά δίκτυα που κατασκευάστηκαν, δέχονται ως είσοδο πέντε μεταβλητές: την εποχή του χρόνου, το πλήθος των τοίχων του κτηρίου που χρησιμοποιήθηκε θερμομόνωση, το πάχος τοιχοποιίας, μια δυαδική μεταβλητή που φανερώνει αν ο συντελεστής μεταφοράς θερμότητας είναι σταθερός ή μεταβλητός και η ώρα της ημέρας. Η έξοδος που προκύπτει είναι η τιμή της κατανάλωσης ενέργειας του κτηρίου που προσομοιώθηκε σε kWh. Για την εκπαίδευση των νευρωνικών δικτύων, αξιοποιήθηκαν δεδομένα που προέκυψαν από την εκτέλεση του προγράμματος ZID [57]. Το ZID είναι ένα μαθηματικό μοντέλο που χρησιμοποιεί νόμους της Φυσικής για να υπολογίσει αριθμητικά θερμικά στοιχεία κτηρίων. Για να το πετύχει αυτό, λαμβάνει υπόψη τις διακυμάνσεις της εξωτερικής θερμοκρασίας σε συνάρτηση με τον χρόνο,

την επίδραση της ηλιακής ακτινοβολίας κ.α. Στην εκπαίδευση χρησιμοποιήθηκαν 401 εγγραφές του συνόλου δεδομένων και 55 για τη δοκιμή. Στο Σχήμα 3.1 παρουσιάζονται δυο γραφικές παραστάσεις που απεικονίζουν τις τιμές κατανάλωσης ενέργειας που προέβλεψε το νευρωνικό δίκτυο και τις πραγματικές συναρτήσεις του χρόνου. Η πρώτη γραφική παράσταση αφορά ένα συγκεκριμένο κτήριο τον χειμώνα και η δεύτερη το ίδιο κτήριο το καλοκαίρι.



(α') Χειμώνας



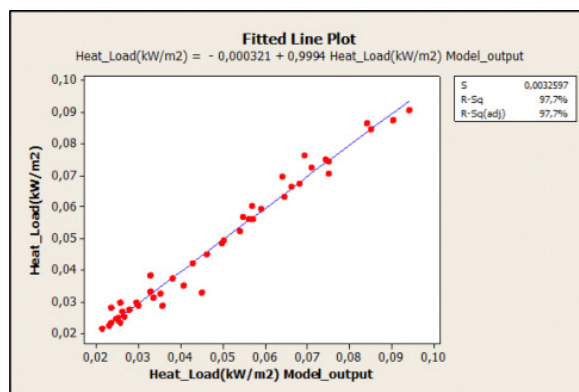
(β') Καλοκαίρι

Σχήμα 3.1: Αποτελέσματα Kalogirou & Bojic [8]

3.3 Προσδιορισμός θερμικών φορτίων κτηρίων

Οι Turhan et al. [9] ασχολήθηκαν με ένα πρόβλημα παλινδρόμησης που λύθηκε με τη βοήθεια νευρωνικών δικτύων. Στόχος της συγκεκριμένης έρευνας ήταν ο προσδιορισμός των θερμικών φορτίων σε εσωτερικούς χώρους κτηρίων. Κατασκευάστηκε ένα FNN, το οποίο δέχεται πέντε μεταβλητές εισόδου και στην έξοδο βγάζει την τιμή του θερμικού φορτίου σε kW/m^2 . Οι μεταβλητές εισόδου είναι: ο λόγος πλάτους/μήκους του κτηρίου (W/L), ο συνολικός συντελεστής μεταφοράς θερμότητας τοίχου (U) ($\text{W/m}^2 \text{K}$) που χρησιμοποιείται για τον υπολογισμό της συνολικής μεταφοράς θερμότητας μέσω ενός τοίχου, η αναλογία εμβαδού/όγκου (A/V) (m^2/m^3) του κτηρίου, η συνολική εξωτερική επιφάνεια (m^2) που προσδιορίζεται από την εξωτερική περίμετρο και το ύψος από το έδαφος μέχρι την οροφή ενός κτιρίου και ο λόγος συνολικής επιφάνειας παραθύρου προς τη συνολική εξωτερική επιφάνεια ($TWA/TESA$). Τα δεδομένα που χρησιμοποιήθηκαν προέρχονται από 148 αστικά κτήρια που αποτελούνται από 2136 διαμερίσματα. Από αυτά τα δεδομένα από τα 103 κτήρια αξιοποιήθηκαν στην εκπαίδευση και από τα υπόλοιπα στις δοκιμές. Μετά από αρκετές δοκιμές κατέληξαν σε ένα FNN με συνολικά 17 νευρώνες. Το συγκεκριμένο νευρωνικό δίκτυο, έδωσε $\text{MSE } 1.03 \times 10^{-5}$ και $R^2 0.977$. Το διάγραμμα ισοτιμίας που προέκυψε από τη διαδικασία της δοκιμής φαίνεται στο Σχήμα 3.2.

Σχήμα 3.2: Διάγραμμα ισοτιμίας Turhan et al. [9]




3.4 Πρόβλεψη κατανάλωσης ενέργειας σε συστήματα κλιματισμού

Οι Zhou et. al. [10] κατασκεύασαν ένα νευρωνικό δίκτυο που προβλέπει την κατανάλωση ενέργειας συστήματος κλιματισμού ενός συγκεκριμένου κτηρίου. Το πείραμα αφορούσε το κτήριο της πανεπιστημιακής βιβλιοθήκης της Guangzhou. Τα δεδομένα που είχαν διαθέσιμα ήταν οι τιμές κατανάλωσης ενέργειας από διάφορες χρονικές στιγμές και ο στόχος να προβλεφθούν μελλοντικές τιμές κατανάλωσης ενέργειας αυτών των συστημάτων. Το πείραμα χωρίζεται σε δυο μέρη: στο πρώτο χρησιμοποιήθηκαν δεδομένα που περιείχαν τιμές ημερησίων καταναλώσεων και στο δεύτερο δεδομένα ωριαίων τιμών. Έτσι οι προβλέψεις του νευρωνικού δικτύου χωρίζονται σε ημερήσιες και ωριαίες. Ο τύπος νευρωνικού δικτύου που επιλέχθηκε ήταν το LSTM. Τα αποτελέσματα συγκρίθηκαν με αυτά δυο άλλων μεθόδων. Συγκεκριμένα, με ένα Backpropagation Neural Network (BPNN) και το μοντέλο Autoregressive Integrated Moving Average (ARIMA). Η σύγκριση έγινε βάση του Μέσου Απόλυτου Ποσοστιαίου σφάλματος (Mean Absolute Percentage Error-MAPE), το Μέσο Τετραγωνικό Σφάλμα (Root Mean Squared Error-RMSE) και τη Μέση Απόλυτη Απόκλιση (Mean Absolute Deviation-MAD). Το LSTM αποδείχθηκε η αποδοτικότερη μέθοδος με τον MAPE στην ημερήσια πρόβλεψη κατανάλωσης ενέργειας να είναι μικρότερος κατά 11,2% και 49% σε σύγκριση με τα μοντέλα νευρωνικών δικτύων ARIMA και BPNN αντίστοιχα. Επιπλέον, στην ωριαία πρόβλεψη κατανάλωση ο MAPE για την υλοποίηση με το LSTM είναι μειωμένος κατά 16,31% και 36,61% αντίστοιχα. Στο Σχήμα 3.3 παρουσιάζονται συγκριτικά οι τιμές

που προέβλεψαν τα τρία μοντέλα σε σχέση με τις πραγματικές τιμές.

Σχήμα 3.3: Αποτελέσματα Zhou et. al. [10]

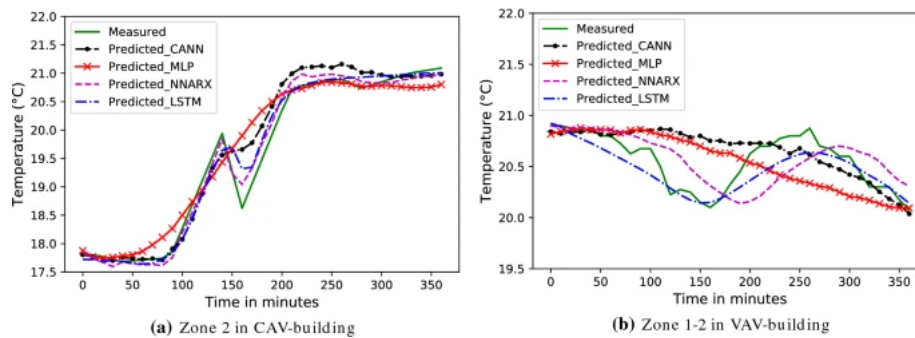


3.5 Πρόβλεψη θερμοκρασίας εσωτερικού χώρου

Οι Mtibaa et. al. [11] επιχείρησαν να προβλέψουν τιμές θερμοκρασιών εσωτερικών χώρων χρησιμοποιώντας νευρωνικά δίκτυα. Τα διαθέσιμα δεδομένα προέρχονται από δυο διαφορετικούς χώρους: ο πρώτος είναι κατάσταση με σταθερό όγκο αέρα (Constant Air Volume-CAV) και ο δεύτερος πρόκειται για ισόγειο ξενοδοχείου με μεταβλητό όγκο αέρα (Variable Air Volume-VAV). Οι χώροι χωρίζονται σε ζώνες (ο πρώτος σε τρεις ο δεύτερος σε πέντε) στις οποίες θα προβλέπεται η θερμοκρασία. Στα πειράματα που πραγματοποιήθηκαν, κατασκευάστηκε ένα LSTM νευρωνικό δίκτυο και συγκρίθηκε με ένα Multi Layer Perceptron, ένα μοντέλο Context-Aware Neural Network (CANN) [58] και ένα Autoregressive Network with Exogenous Inputs (NNARX) [59]. Τα νευρωνικά δίκτυα τροφοδοτήθηκαν με τις εξής πληροφορίες: ημέρα της εβδομάδας, ώρα, υγρασία στη ζώνη αναφοράς, εξωτερική θερμοκρασία, προβλεπόμενη εξωτερική θερμοκρασία και ισχύς που χρησιμοποιείται στη ζώνη αναφοράς σε συστήματα θέρμανσης και κλιματισμού. Στόχος τους είναι η πρόβλεψη της εσωτερικής θερμοκρασίας στη χωρική ζώνη αναφοράς σε μισή, δυο, τέσσερις ή έξι ώρες από τη στιγμή της πρόβλεψης, αναλόγως τη χρονική έκταση των δεδομένων εισόδου. Τα νευρωνικά δίκτυα κατασκευάστηκαν με δυο στρατηγικές: πολλαπλή είσοδος-μονή έξοδος (Multi Input-Single Output-MISO) και πολλαπλή είσοδος-πολλαπλή έξοδος (Multi Input-Multi Output-MIMO). Στην πρώτη, σε κάθε εκτέλεση προβλέπεται η θερμοκρασία μιας ζώνης του χώρου, ενώ στη δεύτερη προ-

βλέπεται η θερμοκρασία όλων των ζωνών ταυτόχρονα. Τα αποτελέσματα έδειξαν ότι το LSTM έχει την καλύτερη απόδοση. Στο Σχήμα 3.4 φαίνεται η διαφορά των προβλέψεων και των πραγματικών τιμών κάθε μεθόδου σε ζώνες CAV και VAV χώρων. Το μοντέλο MISO αποδείχθηκε πιο αποτελεσματικό για χώρους VAV. Ωστόσο, στους χώρους CAV διαπιστώθηκε ότι η συνολική ακρίβεια πρόβλεψης αυξάνεται χρησιμοποιώντας το μοντέλο MIMO.

Σχήμα 3.4: Αποτελέσματα Fatma et. al. [11]



3.6 Πρόβλεψη ζήτησης ενέργειας συστημάτων θέρμανσης και κλιματισμού

Οι Singaravel et. al. [60] χρησιμοποίησαν τεχνικές Μηχανικής Μάθησης με στόχο την πρόβλεψη της απαιτούμενης ενέργειας σε συστήματα θέρμανσης και κλιματισμού. Τα δεδομένα του πειράματος προέκυψαν δίνοντας στοιχεία ενός πραγματικού τριώροφου κτηρίου στο πρόγραμμα προσομοίωσης EnergyPlus [61]. Μερικά από τα δεδομένα που χρησιμοποιήθηκαν είναι οι διαστάσεις των χώρων, ο προσανατολισμός των παραθύρων, οι συντελεστές μεταφοράς θερμότητας των τοίχων, των παραθύρων και του πατώματος κ.α.. Τα πειράματα που πραγματοποιήθηκαν χωρίζονται σε τρεις κατηγορίες. Στην πρώτη κατηγορία, στην οποία γίνεται πρόβλεψη μόνο για συστήματα θέρμανσης, έγινε σύγκριση μεταξύ τριών υλοποιήσεων LSTM νευρωνικού δικτύου και ενός απλού Artificial Neural Network (ANN). Στην πρώτη LSTM υλοποίηση, χρησιμοποιήθηκε ένα απλό LSTM στρώμα, στη δεύτερη ένα στρώμα LSTM με ένα απλό κρυφό στρώμα και η τρίτη ένα στρώμα LSTM με δυο απλά κρυφά στρώματα. Στη δεύτερη κατηγορία πειραμάτων, στην οποία γίνεται πρόβλεψη μόνο για συστήματα κλιματισμού, στα υπάρχοντα νευρωνικά δίκτυα χρησιμοποιήθηκε η τεχνική του Transfer Learning [62]. Στην τρίτη και τελευταία

κατηγορία πειραμάτων, έγινε πρόβλεψη για ζήτηση ενέργειας στα συστήματα θέρμανσης και κλιματισμού ταυτόχρονα. Σε αυτά τα πειράματα χρησιμοποιήθηκε η τεχνική του Multi-Task Learning (MTL). Στα πρώτα πειράματα, το R^2 ήταν πολύ υψηλό ειδικά στις LSTM υλοποιήσεις. Στα δεύτερα πειράματα, όπου προστέθηκε το Transfer Learning, ο χρόνος εκτέλεσης μειώθηκε κατά 65–73%. Το MLT είχε πολύ καλή απόδοση ως προς το R^2 . Αποδείχθηκε ότι με τη χρήση του MLT ο χρόνος εκτέλεσης για τα δυο προβλήματα θέρμανσης και κλιματισμού είναι μικρότερος από ότι αν τα δυο προβλήματα λυθούν ξεχωριστά.


3.7 Πρόβλεψη ηλεκτρικού φορτίου συστημάτων θέρμανσης και κλιματισμού

Οι Liu et. al. [63] ανέπτυξαν αλγόριθμο πρόβλεψης του ηλεκτρικού φορτίου που απαιτούν συστήματα θέρμανσης και κλιματισμού όπως επίσης και θερμικών και ψυχρών φορτίων. Στην έρευνα χρησιμοποιήθηκε μοντέλο LSTM. Τα δεδομένα προέρχονται από ένα πανεπιστημιακό συγκρότημα που βρίσκεται στην πόλη Phoenix των Η.Π.Α.. Η μεταβλητές εισόδου του νευρωνικού δικτύου είναι η θερμοκρασία, ιστορικά δεδομένα θερμικών, ψυχρών και ηλεκτρικών φορτίων καθώς και η χρονική απόσταση από τη στιγμή λήψης των δεδομένων έως τη στιγμή για την οποία γίνεται η πρόβλεψη. Η μέθοδος αξιολογήθηκε με βάση το Μέσο Τετραγωνικό Σφάλμα (RMSE) και συγκρίθηκε με άλλες υλοποιήσεις νευρωνικών δικτύων. Συγκεκριμένα, συγκρίθηκε με τον αλγόριθμο Support Vector Regression (SVR) [64] και το Back Propagation Neural Network. Το LSTM είχε καλύτερη απόδοση από τα άλλα δυο μοντέλα με RMSE ίσο με 0.0044, 0.003, 0.002 για την πρόβλεψη ηλεκτρικού, θερμικού και ψυχρού φορτίου, αντίστοιχα.

3.8 Προβλέψεις θερμοκρασίας και υγρασίας κτηρίων

Οι Cheng et. al. [12] κατασκεύασαν ένα μοντέλο πρόβλεψης τιμών θερμοκρασίας και υγρασίας κτηρίων, παίρνοντας δεδομένα από αισθητήρες. Στο κτήριο αναφοράς τοποθετήθηκαν σε διάφορα σημεία 54 συστοιχίες αισθητήρων θερμοκρασίας, υγρασίας, φωτεινότητας και μέτρησης ηλεκτρικής τάσης. Στόχος του του μοντέλου είναι η μακρινή ή μετρίου χρόνου πρόβλεψη (πρόβλεψη πολλαπλών βημάτων) της ένδειξης

θερμοκρασίας ή υγρασίας ενός αισθητήρα λαμβάνοντας υπόψη ιστορικά δεδομένα ορισμένων γειτονικών συστοιχιών. Για να έχει καλύτερο αποτέλεσμα, αξιοποιούνται και οι συσχετίσεις τιμών μεταξύ των διαφόρων συστοιχιών αισθητήρων. Το μοντέλο που κατασκευάστηκε περιλαμβάνει ένα Συνελικτικό Νευρωνικό Δίκτυο μιας διάστασης (1-D CNN) ακολουθούμενο από στρώματα Bidirectional LSTM. Στην παρουσίαση των αποτελεσμάτων χρησιμοποιούνται διάφοροι συνδυασμοί δεδομένων όπως οι τιμές των συστοιχιών αισθητήρων 7 και 10 ως είσοδος για να προβλεφθούν οι τιμές θερμοκρασίας και υγρασίας της συστοιχίας 4 (Σχήμα 3.5). Σε αυτή την περίπτωση το R^2 ήταν 96.4% και το Μέσο Απόλυτο Σφάλμα 0.437. Τέλος, το προτεινόμενο μοντέλο συγκρίνεται με ένα CNN μοντέλο, ένα Bidirectional LSTM και ένα Gated Recurrent Unit Network (GRU), με το προτεινόμενο μοντέλο να υπερσχύει όλων των άλλων.



Σχήμα 3.5: Αποτελέσματα Cheng et. al. [12]

3.9 Προσδιορισμός ενεργειακής κατανάλωσης συστήματος θέρμανσης

Οι Alamin et. al. [65] κατασκεύασαν ένα νευρωνικό δίκτυο για τον προσδιορισμό ενεργειακής κατανάλωσης συστήματος θέρμανσης ενός δωρόροφου κτηρίου της πανεπιστημιούπολης της Ισπανικής πόλης Almeria. Το συγκεκριμένο κτήριο θερμαίνεται με fan-coils. Τα δεδομένα εισόδου του νευρωνικού δικτύου είναι για διάφορες χρονικές στιγμές: η εσωτερική θερμοκρασία του κτηρίου, η ταχύτητα του ανέμου και η κατανάλωση ενέργειας του συστήματος θέρμανσης για μια και δυο ημέρες

αναφοράς. Στην προεπεξεργασία των δεδομένων χρησιμοποιήθηκε συνάρτηση που απορρίπτει τις ακραίες τιμές. Το σύνολο δεδομένων χωρίστηκε σε δυο μέρη: στα δεδομένα που προέρχονται από τους χειμερινούς και αυτά που προέρχονται από τους καλοκαιρινούς μήνες. Στόχος είναι οι προβλέψεις κατανάλωσης ενέργειας για κοντινές χρονικές στιγμές. Στο πειραματικό μέρος κατασκευάστηκαν πέντε διαφορετικά μοντέλα ANN που πραγματοποιούν προβλέψεις ξεχωριστά για κάθε εποχή του χρόνου, τα οποία αξιολογήθηκαν ως προς το Normalized Mean Root Error (NRMSE), Mean Absolute Error (MAE), Mean Relative Error (MRE), Maximum Absolute Error (MaxAE), Standard Deviation Error (StDE) και Normalized Mean Absolute Error (NMAE). Το καλύτερο μοντέλο για προβλέψεις τον Χειμώνα είχε NMRSE 0.2058 για πρόβλεψη μετά από 15 βήματα χρόνου ενώ το αντίστοιχο για το Καλοκαίρι είχε NMRSE 0.1752.

Κεφάλαιο 4

Πειραματικό Μέρος

4.1 Ορισμός προβλήματος

Σε όλες τις εφαρμογές μοντελοποίησης συστημάτων ενέργειας κτηρίων απαιτείται η γνώση του βαθμού απόδοσης των συστημάτων θέρμανσης. Ο υπολογισμός του βαθμού απόδοσης προϋποθέτει αρκετές διαδοχικές μαθηματικές πράξεις. Πολλές φορές, για διάφορους λόγους (όπως χαλασμένα αισθητήρια) δεν υπάρχουν όλα τα απαραίτητα δεδομένα για τον υπολογισμό του. Έτσι, έγινε κατασκευή νευρωνικών δικτύων για την πρόβλεψη του άκομα και σε τέτοιες περιπτώσεις. Το πρόβλημα που καλείται να λύσει το νευρωνικό δίκτυο είναι πρόβλημα παλινδρόμησης [31], καθώς απαιτείται ο προσδιορισμός μιας συνεχούς μεταβλητής.

4.2 Βαθμός απόδοσης συστημάτων θέρμανσης

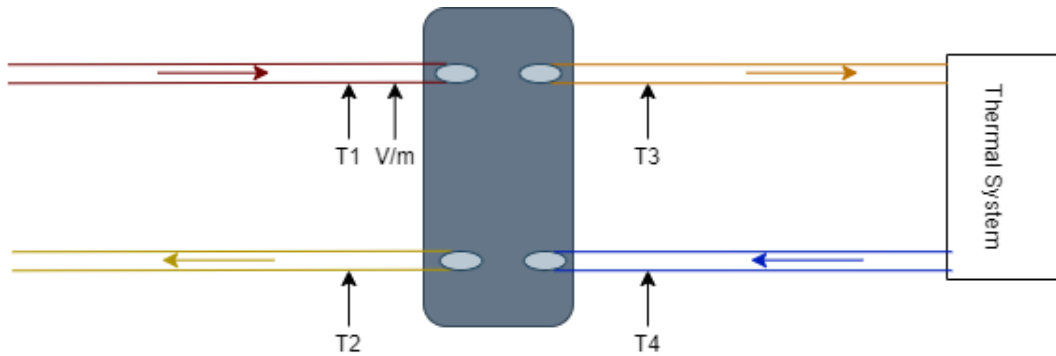
Ο υπολογισμός του βαθμού απόδοσης συστημάτων θέρμανσης απαιτεί δεδομένα που λαμβάνονται από αισθητήρια θερμοκρασίας και μετρητές παροχής. Όπως φαίνεται και στο Σχήμα 4.1, θεωρούμε ένα κύκλωμα θέρμανσης με κυκλοφορία νερού στο οποίο υπάρχουν τοποθετημένα αισθητήρια στα κατάλληλα σημεία. Για τον προσδιορισμό του βαθμού απόδοσης υπολογίζονται αρχικά οι παροχές μάζας (kg/s) του πρωτεύοντος και δευτερεύοντος αγωγού νερού ως εξής:

$$\dot{m}_1 = d_w \frac{V1}{3600},$$
$$\dot{m}_2 = \frac{\dot{m}_1 C_p (T_1 - T_2)}{C_p (T_3 - T_4)}$$

όπου d_w η πυκνότητα του νερού, C_p η θερμική χωρητικότητα του νερού, όπου T_1 η θερμοκρασία του νερού στον κύριο αγωγό εισόδου, T_2 η θερμοκρασία στον κύριο αγωγό εξόδου, T_3 η θερμοκρασία στον δευτερεύοντα αγωγό εισόδου και T_4 η θερμοκρασία στον δευτερεύοντα αγωγό εξόδου. Τελικά, γίνεται ο υπολογισμός του βαθμού απόδοσης:

$$\varepsilon = \frac{\dot{m}_1 C_p (T_1 - T_2)}{\dot{m}_{min} C_p (T_1 - T_4)}$$

Σχήμα 4.1: Κύκλωμα θέρμανσης



4.3 Εργαλεία

4.3.1 Python

Για την υλοποίηση των πειραμάτων χρησιμοποιήθηκε η γλώσσα προγραμματισμού Python. Η Python είναι μια από τις πιο δημοφιλείς γλώσσες τα τελευταία χρόνια [66] και χρησιμοποιείται για κατασκευή αλγορίθμων πολλών κατηγοριών. Είναι μια γλώσσα προγραμματισμού υψηλού επιπέδου και σχεδιασμένη με έμφαση στην αναγνωσιμότητα κώδικα. Μπορεί να χρησιμοποιηθεί σε πολλά είδη προγραμματισμού, όπως του δομημένου, του αντικειμενοστρεφούς και του λειτουργικού προγραμματισμού. Κυκλοφόρησε για πρώτη φορά το 1991 ως Python 0.9.0. Ο λόγος που επιλέχθηκε είναι οι πολύ χρήσιμες βιβλιοθήκες που διαθέτει για μηχανική μάθηση. Παραδείγματα αυτών των βιβλιοθηκών αποτελούν: Tensorflow [67], Keras, Pytorch, και Scikit-learn.

4.3.2 Tensorflow.Keras

Το TensorFlow είναι μια δωρεάν βιβλιοθήκη λογισμικού ανοιχτού κώδικα για μηχανική μάθηση και τεχνητή νοημοσύνη [68]. Μπορεί να χρησιμοποιηθεί στη σχεδίαση διαφόρων κατηγοριών εφαρμογών, με την κυριότερη να είναι η εκπαίδευση και εξαγωγή συμπερασμάτων σε βαθιά νευρωνικά δίκτυα. Το TensorFlow αναπτύχθηκε από την ομάδα Google Brain για εσωτερική χρήση της Google [67]. Το TensorFlow μπορεί να χρησιμοποιηθεί σε αρκετές γλώσσες προγραμματισμού, συμπεριλαμβανομένης και της Python. Μια από τις βιβλιοθήκες Τεχνητής Νοημοσύνης που περιλαμβάνει είναι η Keras [69]. Η βιβλιοθήκη Keras περιέχει πολυάριθμες υλοποιήσεις δομικών στοιχείων νευρωνικών δικτύων, όπως στρώματα, συναρτήσεις ενεργοποίησης, βελτιστοποιητές κ.α.. Μπορεί να χρησιμοποιηθεί για την κατασκευή πολλών τύπων νευρωνικών δικτύων όπως FNN, RNN και LSTM. Επιπλέον, υποστηρίζει μοντέλα βαθιάς μάθησης με χρήση μονάδων επεξεργασίας γραφικών (GPU).


4.4 Σύνολα δεδομένων

Για την περάτωση των πειραμάτων χρησιμοποιήθηκαν δυο σύνολα δεδομένων (datasets). Το κάθε σύνολο δεδομένων περιλαμβάνει μετρήσεις θερμοκρασιών και παροχής από ένα συγκεκριμένο κτήριο, καθώς και τις αντίστοιχες τιμές θερμικής απόδοσης. Τα δυο κτήρια βρίσκονται στην πόλη της Κοζάνης. Το πρώτο, είναι πολύ μεγάλο και περιλαμβάνει πολλά γραφεία. Το δεύτερο είναι μια διώροφη κατοικία με τις διαστάσεις του να είναι αρκετά μικρότερες από του πρώτου. Οι τιμές που παρέχονται είναι αυτές των θερμοκρασιών που αναφέρονται στην ενότητα 4.2: T_1 , T_2 , T_3 , T_4 σε $^{\circ}C$ καθώς και η παροχή νερού V_1 σε m^3/h για διάφορες χρονικές στιγμές. Το πρώτο σύνολο περιέχει τα δεδομένα του πρώτου κτηρίου, αφορούν το χρονικό διάστημα 10/2/2022 – 16/2/2022, ενώ το δεύτερο έχει δεδομένα που αφορούν το δεύτερο κτήριο στο χρονικό διάστημα 5/3/2022 – 21/3/2022. Σημειώνεται ότι στο δεύτερο σύνολο δεδομένων πραγματοποιήθηκε προεπεξεργασία. Οι εγγραφές αυτού του συνόλου είναι πολλές και σε αρκετές περιπτώσεις οι γειτονικές είναι σχεδόν ίδιες καθώς οι μετρήσεις από τις οποίες προήλθαν απείχαν χρονικά λίγα δευτερόλεπτα. Έτσι, για τις ανάγκες των πειραμάτων, ανά έξι εγγραφές λαμβανόταν υπόψη η μια. Ο Πίνακας 4.1 αποτελεί δείγμα του πρώτου συνόλου δεδομένων. Στα Σχήματα


4.2 και 4.3 υπάρχουν box plots που παρέχουν πληροφορίες σχετικές με τα σύνολα δεδομένων όπως η έκταση τιμών και μέσοι όροι.

Πίνακας 4.1: Παράδειγμα συνόλου δεδομένων

Date	Time	$T_1(^{\circ}C)$	$T_2(^{\circ}C)$	$T_3(^{\circ}C)$	$T_4(^{\circ}C)$	$V/h(m^3/h)$
10/2/2022	10:48:46 AM	96.66	71.53	63.13	59.50	3.11
10/2/2022	11:19:26 AM	96.52	72.01	63.69	60.31	1.87




(α') Δεδομένα θερμοκρασιών




(β') Δεδομένα παροχής νερού

Σχήμα 4.2: Box plots πρώτου συνόλου δεδομένων



(α') Δεδομένα θερμοκρασιών



(β') Δεδομένα παροχής νερού

Σχήμα 4.3: Box plots δεύτερου συνόλου δεδομένων

4.5 Είδη αλγορίθμων

Στα πλαίσια των πειραμάτων, κατασκευάστηκαν βαθιά νευρωνικά δίκτυα διαφόρων κατηγοριών: FNN, RNN, LSTM, Bidirectional LSTM τα οποία αναφέρθηκαν στις ενότητες 2.2 και 2.3. Η εκπαίδευση έγινε με τη μέθοδο της επιβλεπόμενης μάθησης. Υπάρχουν αρκετά παραδείγματα χρήσης αυτών των μεθόδων για την επίλυση προβλημάτων παλινδρόμησης [70] [71] [72]. Στο FNN χρησιμοποιήθηκαν 6 κρυφά στρώματα με κάθε στρώμα να αποτελείται από 40 νευρώνες εκτός από το τελευταίο που αποτελείται από έναν νευρώνα. Ως συνάρτηση ενεργοποίησης χρησιμοποιήθηκε

η σιγμοϊδής (sigmoid). Η διάρκεια της εκπαίδευσης ήταν 500 εποχές. Το RNN κατασκευάστηκε με 15 αναδρομικές μονάδες και συνάρτηση ενεργοποίησης τη σιγμοϊδή. Η εκπαίδευσή του έγινε σε 150 εποχές. Στο LSTM χρησιμοποιήθηκαν 15 αναδρομικές LSTM μονάδες, ως συνάρτηση ενεργοποίησης η tanh και η εκπαίδευση διήρκεσε 100 εποχές. Στο Bidirectional LSTM χρησιμοποιήθηκαν 15 αναδρομικές LSTM μονάδες και ως συνάρτηση ενεργοποίησης η tanh, εκπαιδεύτηκε σε 100 εποχές. Στην εκπαίδευση κάθε νευρωνικού δικτύου χρησιμοποιήθηκε ως συνάρτηση υπολογισμού σφάλματος το Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error). Επιπλέον, σε κάθε νευρωνικό δίκτυο χρησιμοποιήθηκε για την αρχικοποίηση των βαρών, ο αλγόριθμος Glorot.

4.6 Παράμετροι νευρωνικών δικτύων

Στην κατασκευή ενός νευρωνικού δικτύου έχει μεγάλη σημασία η επιλογή των παραμέτρων που το καθορίζουν. Η επιλογή τους εξαρτάται από το είδος του προβλήματος που καλείται να λύσει, το πλήθος των δεδομένων εκπαίδευσης, το εύρος των δεδομένων κ.α. Πολλές φορές, η εύρεση των καταλλήλων παραμέτρων είναι ένα αρκετά πολύπλοκο πρόβλημα και οι ερευνητές καταλήγουν στη λύση των δοκιμαστικών εκτελέσεων μέχρι να πετύχουν επιθυμητό αποτέλεσμα. Μερικές από τις παραμέτρους είναι: η επιλογή συνάρτησης ενεργοποίησης, το πλήθος των κρυφών στρωμάτων, η επιλογή συνάρτησης σφάλματος, το πλήθος εποχών στην εκπαίδευση. Στη συγκεκριμένη εργασία ορισμένες από τις παραμέτρους όπως το πλήθος εποχών και κρυφών στρωμάτων επιλέχθηκαν από δοκιμαστικές εκτελέσεις. Μια ιδιαίτερα σημαντική παράμετρος είναι αυτή που αφορά την αρχικοποίηση των βαρών. Η αρχικοποίηση βαρών είναι η διαδικασία καθορισμού των βαρών σε μικρές τυχαίες τιμές που ορίζουν το σημείο εκκίνησης για τη μάθηση του μοντέλου νευρωνικού δικτύου. Σε κάθε εκτέλεση το νευρωνικό δίκτυο αρχικοποιείται με διαφορετικό σύνολο βαρών, που οδηγεί σε διαφορετική έξοδο του δικτύου. Παλιότερα χρησιμοποιούνταν τυχαίες τιμές συγκεκριμένου εύρους. Τώρα υπάρχουν διάφοροι αλγόριθμοι που βοηθούν στην αρχικοποίηση βαρών. Επιλέχθηκε ο αλγόριθμος Glorot [73] ο οποίος αρχικοποιεί τα βάρη, με ομοιόμορφη κατανομή πιθανότητας U , σαν τυχαίες τιμές εύρους: $U[-\frac{1}{\sqrt{n}}, \frac{1}{\sqrt{n}}]$, όπου n το πλήθος εισόδων σε κάθε κόμβο. Η συνάρτηση σφάλματος συνήθως είναι το Μέσο Τετραγωνικό Σφάλμα [74].

4.7 Πειράματα

Στο πειραματικό μέρος τις παρούσας εργασίας κατασκευάστηκαν βαθιά νευρωνικά δίκτυα τα οποία λαμβάνουν ως είσοδο τα δεδομένα που αναφέρονται στην ενότητα 4.4 και προβλέπουν την τιμή του θερμικού βαθμού απόδοσης του κτηρίου αναφοράς. Το εύρος τιμών της απόδοσης είναι 0-1. Οι τιμές της απόδοσης είναι γνωστές εκ των προτέρων (μάθηση με επίβλεψη). Σημειώνεται ότι η είσοδος αποτελείται από πέντε μεταβλητές. Δεδομένου ότι ένα νευρωνικό δίκτυο αν εκπαιδευτεί με ίδια δεδομένα μπορεί να παράξει διαφορετικά αποτελέσματα κάθε φορά, για κάθε πείραμα η διαδικασία εκπαίδευσης και δοκιμής πραγματοποιήθηκε δέκα φορές ώστε να εξασφαλιστεί η αξιοπιστία των αποτελεσμάτων. Έτσι, τα αποτελέσματα που παρουσιάζονται αποτελούν το μέσο όρο των αποτελεσμάτων από τα δέκα τρεξίματα.

Η πρώτη σειρά πειραμάτων έγινε με χρήση αποκλειστικά του πρώτου συνόλου δεδομένων. Το 80% των δεδομένων του αξιοποιήθηκε για την εκπαίδευση του νευρωνικού δικτύου και το 20% για τη δοκιμή. Για αυτά τα πειράματα κατασκευάστηκαν νευρωνικά δίκτυα των κατηγοριών: FNN, Simple RNN, LSTM, Bidirectional LSTM.

Η δεύτερη σειρά πειραμάτων έγινε με χρήση του δεύτερου συνόλου δεδομένων. Πιο συγκεκριμένα, στην εκπαίδευση χρησιμοποιήθηκαν 4,000 εγγραφές, ενώ για τη δοκιμή χρησιμοποιήθηκαν 500 εγγραφές. Για αυτά τα πειράματα κατασκευάστηκαν νευρωνικά δίκτυα των κατηγοριών: FNN, Simple RNN, LSTM, Bidirectional LSTM.

Η τρίτη σειρά πειραμάτων έγινε με χρήση και των δυο συνόλων δεδομένων. Πιο συγκεκριμένα, στην εκπαίδευση χρησιμοποιήθηκαν 200 εγγραφές από το πρώτο σύνολο και 7,000 από το δεύτερο, ενώ για τη δοκιμή χρησιμοποιήθηκαν 200 εγγραφές από το πρώτο και 1,500 από το δεύτερο. Αξίζει να σημειωθεί ότι για τις ανάγκες αυτού του πειράματος το δεύτερο σύνολο δεδομένων πέρασε από ένα επιπλέον στάδιο προεπεξεργασίας. Τα δεδομένα που επιλέχθηκαν λήφθηκαν με τυχαία σειρά, δεν ήταν δηλαδή ταξινομημένα βάση της ημερομηνίας και ώρας. Για αυτά τα πειράματα κατασκευάστηκαν νευρωνικά δίκτυα των κατηγοριών: FNN, Simple RNN, LSTM, Bidirectional LSTM.

Τα επόμενα πειράματα πραγματοποιήθηκαν χρησιμοποιώντας ως είσοδο τέσσε-

ρις ανεξάρτητες μεταβλητές έναντι πέντε που χρησιμοποιήθηκαν στα προηγούμενα. Συγκεκριμένα, δεν χρησιμοποιείται η θερμοκρασία εξόδου του δευτερεύοντος αγωγού T_4 . Αυτά τα πειράματα έγιναν δυο φορές. Την πρώτη χρησιμοποιήθηκε μόνο το πρώτο σύνολο δεδομένων και τη δεύτερη συνδυασμός των δυο συνόλων. Στο πείραμα με συνδυασμό των συνόλων πραγματοποιήθηκε η ίδια προεπεξεργασία με την τρίτη σειρά πειραμάτων. Κατασκευάστηκαν νευρωνικά δίκτυα των κατηγοριών: FNN, Simple RNN, LSTM, Bidirectional LSTM.

4.8 Περιγραφή κώδικα

4.8.1 Εισαγωγή

Ο κώδικας για την πραγματοποίηση των πειραμάτων γράφτηκε σε γλώσσα Python. Δημιουργήθηκαν συνολικά πέντε αρχεία της μορφής .py. Τα τέσσερα αρχεία περιέχουν τις υλοποιήσεις των νευρωνικών δικτύων και την πραγματοποίηση των πειραμάτων που αναφέρθηκαν στην ενότητα 4.7 και ένα περιλαμβάνει βοηθητικές συναρτήσεις. Πιο αναλυτικά, στο αρχείο FNN.py γίνεται η κατασκευή του Feedforward νευρωνικού δικτύου, στο RNN.py γίνεται κατασκευή του Recurrent νευρωνικού δικτύου, στο LSTM.py γίνεται η κατασκευή του LSTM νευρωνικού δικτύου και στο LSTM_Bidirectional.py γίνεται η κατασκευή του Bidirectional LSTM νευρωνικού δικτύου.

4.8.2 Κύριο μέρος

Κάθε ένα από τα κύρια αρχεία ξεκινά με προτροπή στον χρήστη να επιλέξει μια από τις έξι λειτουργίες του προγράμματος οι οποίες αντιπροσωπεύουν τα διάφορα πειράματα που αναφέρονται στην ενότητα 4.7. Στην πρώτη λειτουργία γίνεται χρήση μόνο του πρώτου συνόλου δεδομένων και το νευρωνικό δίκτυο δέχεται ως είσοδο πέντε μεταβλητές: T_1, T_2, T_3, T_4, V_1 . Στη δεύτερη λειτουργία γίνεται και πάλι χρήση μόνο του πρώτου συνόλου δεδομένων αλλά το νευρωνικό δίκτυο δέχεται ως είσοδο τέσσερις μεταβλητές: T_1, T_2, T_3, V_1 . Στην τρίτη λειτουργία γίνεται χρήση και των δυο συνόλων δεδομένων και το νευρωνικό δίκτυο δέχεται ως είσοδο πέντε μεταβλητές: T_1, T_2, T_3, T_4, V_1 . Στην τέταρτη λειτουργία γίνεται και πάλι χρήση και των δυο συνόλων δεδομένων αλλά το νευρωνικό δίκτυο δέχεται ως είσοδο τέσσερις με-

ταβλητές: T_1, T_2, T_3, V_1 . Στην πέμπτη λειτουργία χρησιμοποιείται το δεύτερο σύνολο δεδομένων και το νευρωνικό δίκτυο δέχεται ως είσοδο πέντε μεταβλητές: T_1, T_2, T_3, T_4, V_1 . Τέλος, στην έκτη λειτουργία χρησιμοποιείται το δεύτερο σύνολο δεδομένων και το νευρωνικό δίκτυο δέχεται ως είσοδο τέσσερις μεταβλητές: T_1, T_2, T_3, V_1 .

Το επόμενο βήμα είναι ο καθορισμός των παραμέτρων του προγράμματος ανάλογα με τη λειτουργία που επέλεξε ο χρήστης. Οι περισσότερες παράμετροι αφορούν τη δομή και την εκπαίδευση του νευρωνικού δικτύου. Οι κυριότερες είναι: η συνάρτηση ενεργοποίησης, ο αλγόριθμος αρχικοποίησης βαρών που θα χρησιμοποιηθεί, η συνάρτηση σφάλματος, το πλήθος των εποχών στην εκπαίδευση του νευρωνικού δικτύου, το πλήθος των κρυφών στρωμάτων (αφορά αποκλειστικά το FNN), το πλήθος των μονάδων RNN (αφορά αποκλειστικά το RNN), το πλήθος των μονάδων LSTM (αφορά αποκλειστικά το LSTM).

Στη συνέχεια με τη χρήση των κατάλληλων βιβλιοθηκών γίνεται άνοιγμα και ανάγνωση των αρχείων που περιέχουν τις συλλογές δεδομένων. Όταν το πρόγραμμα βρίσκεται στην πρώτη ή τη δεύτερη λειτουργία, διαβάζει την πρώτη σειρά δεδομένων και ορίζει ότι το 80% αυτής θα αποθηκευτεί στις λίστες X_{train} και y_{train} ώστε να αξιοποιηθεί στην εκπαίδευση και το 20% αυτής θα αποθηκευτεί στις λίστες X_{test} και y_{test} ώστε να αξιοποιηθεί στη δοκιμή. Στην περίπτωση που το πρόγραμμα βρίσκεται στην τρίτη ή τέταρτη λειτουργία, ανοίγονται και τα δυο αρχεία συλλογών δεδομένων και οι λίστες X_{test} και y_{test} γεμίζουν με τη βοήθεια της συνάρτησης `concatenate_shuffled_datasets` η οποία θα περιγραφεί αναλυτικά παρακάτω. Σημειώνεται ότι οι λίστες X_{train} και X_{test} περιλαμβάνουν τις τιμές των μεταβλητών T_1, T_2, T_3, T_4 και V_1 ενώ οι λίστες y_{train} και y_{test} αποθηκεύουν τις τιμές της θερμικής απόδοσης.

Αφού έγινε η εισαγωγή των κατάλληλων δεδομένων ανά περίπτωση, πραγματοποιείται η κατασκευή του νευρωνικού δικτύου με τη συνδρομή συναρτήσεων από τη βιβλιοθήκη `tensorflow.keras`. Ακολουθώς, το νευρωνικό δίκτυο που δημιουργήθηκε, εκπαιδεύεται με τα δεδομένα των λιστών X_{train} και y_{train} . Με την ολοκλήρωση της εκπαίδευσης, γίνεται η δοκιμή. Το εκπαιδευμένο μοντέλο παίρνει ως είσοδο τη λίστα X_{test} , προβλέπει τις τιμές της θερμικής απόδοσης και τις αποθηκεύει στο `y_prediction_array`. Έπειτα συγκρίνονται οι τιμές του `y_prediction_array` με αυτές του y_{test} (που περιέχει τις σωστές τιμές θερμικής απόδοσης) και υπολογίζονται οι

τιμές των μετρικών αξιολόγησης. Οι μετρικές αποθηκεύονται σε ένα αρχείο κειμένου. Τέλος, δημιουργείται και αποθηκεύεται το διάγραμμα ισοτιμίας. Στον Αλγόριθμο 1 παρουσιάζεται ο ψευδοκώδικας του αλγορίθμου.

4.8.3 Βοηθητικές συναρτήσεις

Οι σημαντικότερες από τις βοηθητικές συναρτήσεις είναι: η `concatenate_shuffled_datasets`, η `store_results` και η `create_plot`.

Η `concatenate_shuffled_datasets` χρησιμοποιείται στην τρίτη και τέταρτη λειτουργία του προγράμματος (4.8.2). Οι παράμετροι που απαιτεί είναι μια boolean μεταβλητή (`shuffle`), το πρώτο και το δεύτερο αρχείο συλλογής δεδομένων (`dataset_file1 - dataset_file2`), το πλήθος των εγγραφών από την πρώτη και τη δεύτερη συλλογή δεδομένων που θα χρησιμοποιηθεί στην εκπαίδευση (`num_of_records_training1 - num_of_records_training2`), το πλήθος των εγγραφών από την πρώτη και τη δεύτερη συλλογή δεδομένων που θα χρησιμοποιηθεί στις δοκιμές (`num_of_records_testing1 - num_of_records_testing2`). Καλεί μια άλλη συνάρτηση η οποία ανοίγει τα δυο αρχεία, κρατά το πλήθος των εγγραφών που ζητά ο χρήστης και τις αποθηκεύει με τυχαία σειρά. Στη συνέχεια, η συνάρτηση ενώνει τα δεδομένα που λήφθηκαν από τα δυο αρχεία και τα ανακατεύει, τα τοποθετεί δηλαδή με τυχαία σειρά. Επιστέφει τέσσερις λίστες: `X_training`, `y_training`, `X_test`, `y_test`.

Η συνάρτηση `store_results` χρησιμοποιείται για την επεξεργασία και αποθήκευση σε αρχείο κειμένου των μετρικών αξιολόγησης.

Η `create_plot` χρησιμοποιεί τη βιβλιοθήκη `matplotlib.pyplot` για να δημιουργήσει το διάγραμμα ισοτιμίας.

4.9 Μετρικές αξιολόγησης

Για την αξιολόγηση της απόδοσης των νευρωνικών δικτύων που κατασκευάστηκαν χρησιμοποιήθηκαν διάφορες μετρικές.

Η πρώτη μετρική είναι το Μέσο Απόλυτο Σφάλμα (Mean Absolute Error-MAE). Ο υπολογισμός του γίνεται ως εξής:

$$MAE = \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{n}$$

```

mode = choose_program_mode();
if mode == 1 then
| set_parameters(1);
else if mode == 2 then
| set_parameters(2);
else if mode == 3 then
| set_parameters(3);
else if mode == 4 then
| set_parameters(4);
else if mode == 5 then
| set_parameters(5);
else if mode == 6 then
| set_parameters(6);
else
| exit();
end
if mode == 1 or mode == 2 then
| X_train, X_test, y_train, y_test = read_dataset(dataset_1);
else if mode == 3 or mode == 4 then
| X_train, X_test, y_train, y_test = concatenate_shuffled_datasets(dataset_1,
| dataset_2)
else if mode == 5 or mode == 6 then
| X_train, X_test, y_train, y_test = read_dataset(dataset_2);
if mode == 2 or mode == 4 then
| X_train, X_test = delete_T4();
for n = 1, 2, ..., 10 do
| create_neural_network();
| compile_neural_network();
| train_neural_network();
| test_neural_network();
| calculate_metrics();
end
end

```

Αλγόριθμος 1: Κύριος αλγόριθμος

όπου n το πλήθος των εγγραφών που αξιοποιήθηκαν στη δοκιμή του νευρωνικού δικτύου, y_i οι προβλεπόμενες τιμές και \hat{y}_i οι πραγματικές τιμές. Στην ιδανική περίπτωση (δηλαδή στην περίπτωση που όλες οι προβλέψεις του νευρωνικού δικτύου ταυτίζονται με τις πραγματικές τιμές) η τιμή του Μέσου Απολύτου Σφάλματος είναι μηδέν.

Η επόμενη μετρική είναι το Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error-MSE). Ο υπολογισμός του γίνεται ως εξής:

$$MSE = \sum_{i=1}^n \frac{|y_i - \hat{y}_i|^2}{n}$$

όπου n το πλήθος των εγγραφών που αξιοποιήθηκαν στη δοκιμή του νευρωνικού δικτύου, y_i οι προβλεπόμενες τιμές και \hat{y}_i οι πραγματικές τιμές. Στην ιδανική περίπτωση η τιμή του Μέσου Τετραγωνικού Σφάλματος είναι μηδέν.

Μια ακόμα μετρική είναι το Σφάλμα Αθροισμένων Τετραγώνων (Sum of Squares Error-SSE). Για τον υπολογισμό του γίνονται οι παρακάτω πράξεις:

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

όπου n το πλήθος των εγγραφών που αξιοποιήθηκαν στη δοκιμή του νευρωνικού δικτύου, y_i οι προβλεπόμενες τιμές και \hat{y}_i οι πραγματικές τιμές. Στην ιδανική περίπτωση η τιμή του Σφάλματος Αθροισμένων Τετραγώνων είναι μηδέν.

Άλλη μετρική είναι το R^2 . Το R^2 είναι ίσως η σημαντικότερη μετρική σε προβλήματα παλινδρόμησης. Πριν την επεξήγηση του R^2 καλό είναι να κατανοηθεί η έννοια της διακύμανσης. Η διακύμανση είναι το μέτρο που εκφράζει πόσο διαφέρουν ορισμένες τιμές από τη μέση τιμή αυτών. Το R^2 εκφράζεται με ποσοστό (0-100%) και δείχνει πόσο καλά προσεγγίζει η γραμμή παλινδρόμησης τα πραγματικά δεδομένα. Υπολογίζεται έτσι [75]:

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

όπου n το πλήθος των εγγραφών που αξιοποιήθηκαν στη δοκιμή του νευρωνικού δικτύου, y_i οι προβλεπόμενες τιμές, \hat{y}_i οι πραγματικές τιμές και \bar{y} η διακύμανση των προβλεπόμενων τιμών. Στην ιδανική περίπτωση η τιμή του R^2 είναι 100%.

4.10 Αποτελέσματα


Σε αυτήν την παράγραφο γίνεται παρουσίαση των αποτελεσμάτων. Η αξιολόγηση έγινε με βάση τις μετρικές που παρουσιάστηκαν στην ενότητα 4.9 και των διαγραμμάτων ισοτιμίας.

Τα πρώτα πειράματα έγιναν με χρήση του πρώτου συνόλου δεδομένων και πέτυχε μεταβλητές ως είσοδο. Τα αποτελέσματα φαίνονται στον Πίνακα 4.2. Από τα νευρωνικά δίκτυα που χρησιμοποιήθηκαν καλύτερη απόδοση ως προς το R^2 είχε το FNN με 99.51%, ακολουθεί το Bidirectional LSTM με 98.95%, στην τρίτη θέση βρίσκεται το RNN με 98.59% και τέταρτο το LSTM με 98.22%. Αν η σύγκριση γίνει ως προς το Μέσο Απόλυτο Σφάλμα (MAE) το FNN έχει και πάλι την καλύτερη από-


δοση, ακολουθεί το Bidirectional LSTM, έπειτα το LSTM, ακολουθεί το LSTM και στην τέταρτη θέση το RNN. Στο Σχήμα 4.4 φαίνονται τα διαγράμματα ισοτιμίας.

Πίνακας 4.2: Χρήση πρώτου συνόλου δεδομένων - Πέντε μεταβλητές εισόδου


	FNN	RNN	LSTM	Bidirectional LSTM
MAE	0.004337	0.007419	0.006990	0.006710
MSE	0.000030	0.000084	0.000089	0.000063
R^2	99.51%	98.59%	98.22%	98.95%
SSE	0.000020	0.007367	0.006249	0.007363




(α') FNN



(β') RNN



(γ') LSTM



(δ') LSTM Bidirectional

Σχήμα 4.4: Fitting accuracy - Πρώτο πείραμα

Τα επόμενα πειράματα έγιναν με χρήση του δεύτερου συνόλου δεδομένων και πέντε μεταβλητές ως είσοδο. Τα αποτελέσματα φαίνονται στον Πίνακα 4.3. Από τα

νευρωνικά δίκτυα που χρησιμοποιήθηκαν καλύτερη απόδοση ως προς το R^2 είχε το FNN με 99.18%, ακολουθεί το Bidirectional LSTM με 97.57%, στην τρίτη θέση με μικρή διαφορά βρίσκεται το LSTM με 96.16% και τέταρτο το RNN με 83.64%. Αν η σύγκριση γίνει ως προς το Μέσο Απόλυτο Σφάλμα (MAE) το FNN έχει και πάλι την καλύτερη απόδοση, ακολουθεί το Bidirectional LSTM, έπειτα το LSTM, και στην τέταρτη θέση το RNN. Στο Σχήμα 4.5 φαίνονται τα διαγράμματα ισοτιμίας. Ενώ στο Σχήμα 4.10, οι τιμές του MAE για κάθε τρέξιμο των αλγορίθμων.

Πίνακας 4.3: Χρήση δευτέρου συνόλου δεδομένων - Πέντε μεταβλητές εισόδου


	FNN	RNN	LSTM	Bidirectional LSTM
MAE	0.006375	0.021230	0.014032	0.010266
MSE	0.000070	0.001394	0.000327	0.000207
R^2	99.18%	83.64%	96.16%	97.57%
SSE	0.000051	0.010608	0.011224	0.010939

Τα αποτελέσματα των πειραμάτων που χρησιμοποιήθηκαν δυο σύνολα δεδομένων και πέντε μεταβλητές εισόδου φαίνονται στον Πίνακα 4.4. Ως προς το R^2 το καλύτερο αποτέλεσμα έχει το FNN με ποσοστό 99.90%, ακολουθεί το Bidirectional LSTM με 98.61%, έπειτα το LSTM με 96.70% και τέλος το RNN με 90.85%. Για σύγκριση ως προς ο Μέσο Απόλυτο Σφάλμα (MAE) το FNN βρίσκεται στην πρώτη θέση ακολουθούν τα Bidirectional LSTM και LSTM και έπειτα το RNN με διαφορά μιας μονάδας από τα υπόλοιπα. Στο Σχήμα 4.6 φαίνονται τα διαγράμματα ισοτιμίας. Ενώ στο Σχήμα 4.10 παρουσιάζονται συγκριτικά οι τιμές του MAE για κάθε τρέξιμο των πειραμάτων όλων των νευρωνικών δικτύων που χρησιμοποιήθηκαν. Τέλος, στο Σχήμα 4.10 διακρίνονται οι τιμές του MAE για κάθε μια από τις δέκα φορές που εκπαιδεύτηκαν τα μοντέλα.


Πίνακας 4.4: Χρήση δυο συνόλων δεδομένων - Πέντε μεταβλητές εισόδου

	FNN	RNN	LSTM	Bidirectional LSTM
MAE	0.002915	0.026756	0.015592	0.010399
MSE	0.000014	0.001359	0.000501	0.000212
R^2	99.90%	90.85%	96.70%	98.61%
SSE	0.000009	0.018226	0.018635	0.019019


Για τα επόμενα πειράματα αξιοποιήθηκε το πρώτο σύνολο δεδομένων και τέσσερις μεταβλητές ως είσοδος. Τα αποτελέσματα φαίνονται στον Πίνακα 4.5. Από τα νευρωνικά δίκτυα που χρησιμοποιήθηκαν καλύτερη απόδοση ως προς το R^2 είχε




(α) FNN



(β) RNN



(γ) LSTM




(δ) LSTM Bidirectional

Σχήμα 4.5: Fitting accuracy - Δεύτερο πείραμα


το FNN με 99.38%, ακολουθεί το LSTM με 94.19%, στην τρίτη θέση βρίσκεται το Bidirectional LSTM με 93.98% και τέταρτο το RNN με 93.16%. Αν η σύγκριση γίνει ως προς το Μέσο Απόλυτο Σφάλμα (MAE) το FNN έχει και πάλι την καλύτερη απόδοση, ακολουθεί το LSTM, έπειτα το Bidirectional LSTM με μικρή διαφορά και στην τέταρτη θέση το RNN. Στο Σχήμα 4.7 φαίνονται τα διαγράμματα ισοτιμίας.

Πίνακας 4.5: Χρήση πρώτου συνόλου δεδομένων - Τέσσερις μεταβλητές εισόδου


	FNN	RNN	LSTM	Bidirectional LSTM
MAE	0.004803	0.015503	0.013630	0.013870
MSE	0.000037	0.000410	0.000348	0.000361
R^2	99.38%	93.16%	94.19%	93.98%
SSE	0.000025	0.007177	0.007023	0.006965




(α) FNN



(β) RNN



(γ) LSTM




(δ) LSTM Bidirectional


Σχήμα 4.6: Fitting accuracy - Τρίτο πείραμα

Στα ακόλουθα πειράματα αξιοποιήθηκε το δεύτερο σύνολο δεδομένων και τέσσερις μεταβλητές ως είσοδος. Τα αποτελέσματα φαίνονται στον Πίνακα 4.6. Από τα νευρωνικά δίκτυα που χρησιμοποιήθηκαν καλύτερη απόδοση ως προς το R^2 είχε το FNN με 93.70%, ακολουθεί το LSTM με 89.80%, στην τρίτη θέση βρίσκεται το Bidirectional LSTM με 86.83% και τέταρτο το RNN με 81.79%. Αν η σύγκριση γίνει ως προς το Μέσο Απόλυτο Σφάλμα (MAE) το FNN έχει και πάλι την καλύτερη απόδοση, ακολουθεί το LSTM, έπειτα το Bidirectional LSTM και στην τέταρτη θέση το RNN Στο Σχήμα 4.8 φαίνονται τα διαγράμματα ισοτιμίας. Στο Σχήμα 4.11 παρουσιάζονται οι τιμές του MAE για κάθε τρέξιμο του πειράματος.


Τα τελευταία πειράματα πραγματοποιήθηκαν και με τα δυο σύνολα δεδομένων




(α) FNN



(β) RNN



(γ) LSTM




(δ) LSTM Bidirectional

Σχήμα 4.7: Fitting accuracy - Τέταρτο πείραμα


και τέσσερις μεταβλητές εισόδου. Τα αποτελέσματα αποτυπώνονται στον Πίνακα 4.7. Αν λάβουμε το R^2 ως μέτρο σύγκρισης στην πρώτη θέση είναι το FNN με 95.41%, μετά το Bidirectional LSTM με 90.13%, ακολουθεί το LSTM με 87.80% και το RNN με 85.18%. Ως προς το Μέσο Απόλυτο Σφάλμα (MAE) το FNN έχει και πάλι την καλύτερη απόδοση, δεύτερο είναι το Bidirectional LSTM και ακολουθούν τα LSTM και RNN. Στο Σχήμα 4.9 παρουσιάζονται τα διαγράμματα ισοτιμίας. Στο Σχήμα 4.14 παρουσιάζεται η χρονική διάρκεια της εκπαίδευσης των νευρωνικών δικτύων που χρησιμοποιήθηκαν σε αυτό το πείραμα. Επιπλέον, στο Σχήμα 4.13 φαίνονται οι τιμές του MAE για κάθε τρέξιμο του κώδικα.

Πίνακας 4.6: Χρήση δεύτερου συνόλου δεδομένων - Τέσσερις μεταβλητές εισόδου


	FNN	RNN	LSTM	Bidirectional LSTM
MAE	0.015390	0.027943	0.020907	0.024474
MSE	0.000537	0.001552	0.000869	0.001122
R^2	93.70%	81.79%	89.80%	86.83%
SSE	0.000244	0.010261	0.010312	0.011368




(α) FNN



(β) RNN



(γ) LSTM




(δ) LSTM_Bidirectional


Σχήμα 4.8: Fitting accuracy - Πέμπτο πείραμα

Πίνακας 4.7: Χρήση δυο συνόλων δεδομένων - Τέσσερις μεταβλητές εισόδου


	FNN	RNN	LSTM	Bidirectional LSTM
MAE	0.017582	0.035712	0.030760	0.026516
MSE	0.000680	0.002195	0.001788	0.001435
R^2	95.41%	85.18%	87.80%	90.13%
SSE	0.000312	0.018100	0.017710	0.017460




(α) FNN



(β) RNN




(γ) LSTM




(δ) LSTM Bidirectional

Σχήμα 4.9: Fitting accuracy - Έκτο πείραμα


Σχήμα 4.10: Τιμές μέσου απολύτου σφάλματος για 10 εκτελέσεις - Χρήση δευτέρου συνόλου δεδομένων και πέντε μεταβλητών εισόδου




Σχήμα 4.11: Τιμές μέσου απολύτου σφάλματος για 10 εκτελέσεις - Χρήση δευτέρου συνόλου δεδομένων και τεσσάρων μεταβλητών εισόδου




Σχήμα 4.12: Τιμές μέσου απολύτου σφάλματος για 10 εκτελέσεις - Χρήση δυο συνόλων δεδομένων και πέντε μεταβλητών εισόδου



Σχήμα 4.13: Τιμές μέσου απολύτου σφάλματος για 10 εκτελέσεις - Χρήση δυο συνόλων δεδομένων και τεσσάρων μεταβλητών εισόδου



Σχήμα 4.14: Χρόνος εκπαίδευσης σε δευτερόλεπτα - Δυο σύνολα δεδομένων, τέσσερις μεταβλητές



Κεφάλαιο 5

Σχολιασμός - Συμπεράσματα

5.1 Σχολιασμός αποτελεσμάτων

Τα πειράματα που πραγματοποιήθηκαν έδειξαν ότι με τη χρήση βαθιών νευρωνικών δικτύων μπορεί να προσδιοριστεί η τιμή της θερμικής απόδοσης κτηρίων με μεγάλη ακρίβεια. Συγκεκριμένα στο πείραμα που χρησιμοποιήθηκε ένα σύνολο δεδομένων που περιείχε 436 εγγραφές όλοι οι τύποι νευρωνικών δικτύων που χρησιμοποιήθηκαν έδωσαν πολύ καλά αποτελέσματα. Το R^2 σε όλες τις περιπτώσεις ήταν μεγαλύτερο από 98%. Το Μέσο απόλυτο σφάλμα (MAE) που εκφράζει τη μέση απόσταση της προβλεπόμενης τιμής από τη σωστή είναι πολύ χαμηλό. Για παράδειγμα, με το FNN η τιμή του MAE ήταν 0.004337. Αν θεωρήσουμε τη θερμική απόδοση ποσοστό, αυτό σημαίνει ότι το σφάλμα στην πρόβλεψη της απόδοσης είναι κατά μέσο όρο 0.4337%. Σε αυτά τα πρώτα πειράματα, όλοι οι τύποι νευρωνικών δικτύων που χρησιμοποιήθηκαν πέτυχαν σχεδόν ταύτιση των τιμών που προέβλεψαν με τις σωστές. Στην επόμενη εκτέλεση, αξιοποιήθηκαν δεδομένα από τη δεύτερη συλλογή. Συγκεκριμένα, 4000 εγγραφές χρησιμοποιήθηκαν στην εκπαίδευση και 500 στις δοκιμές. Το FNN και σε αυτή την περίπτωση έφτασε πολύ κοντά στις πραγματικές τιμές. Από την άλλη το RNN είχε αρκετά χειρότερη απόδοση με την απόκλιση από τα σωστά που φανερώνεται από το MAE να είναι περίπου 2.1. Η εξελιγμένη μορφή του RNN, το LSTM είχε αισθητά καλύτερο αποτέλεσμα από αυτό με την απόδοση ως προς το R^2 να είναι αρκετά κοντά σε αυτή του FNN. Το Bidirectional LSTM, είχε ελαφρώς καλύτερα αποτελέσματα από το LSTM. Το πείραμα που χρησιμοποιήθηκε συνδυασμός συνόλων δεδομένων είναι πιο πολύπλοκο καθώς χρησιμοποιήθηκαν δεδομένα από δυο διαφορετικά κτήρια. Για την εκπαί-

δευση χρησιμοποιήθηκαν 200 εγγραφές από το πρώτο σύνολο δεδομένων και 7000 από το δεύτερο. Υπήρχαν μεγάλες αποκλίσεις στις τιμές θερμοκρασιών των δυο κτηρίων και αυτό δυσκολεύει αρκετά τη διαδικασία της εκπαίδευσης. Αλλά και πάλι ο προσδιορισμός του θερμικού βαθμού απόδοσης έγινε με μεγάλη ακρίβεια ειδικά από το FNN του οποίου η ποσοστιαία απόκλιση από τις πραγματικές τιμές απόδοσης ήταν κατά μέσο όρο 0.2. Αξίζει να σημειωθεί ότι οι τιμές των μετρικών σε αυτό το πείραμα είναι γενικά καλύτερες από ότι στο πείραμα που χρησιμοποιήθηκε μόνο το δεύτερο σύνολο δεδομένων. Πρέπει να τονιστεί ότι στο προηγούμενο πείραμα χρησιμοποιήθηκαν λιγότερες εγγραφές και οι εποχές εκπαίδευσης ήταν λιγότερες. Στη συνέχεια έγινε προσπάθεια εύρεσης της θερμικής απόδοσης χρησιμοποιώντας μια μεταβλητή εισόδου λιγότερη. Η εκπαίδευση, αρχικά πραγματοποιήθηκε με το πρώτο σύνολο δεδομένων. Σε αυτό το πείραμα το FNN απέδωσε εξίσου καλά με το αντίστοιχο πείραμα με όλες τις μεταβλητές διαθέσιμες. Τα RNN, LSTM, και Bidirectional LSTM είχαν λίγο μικρότερη ακρίβεια στις προβλέψεις τους αλλά η απόκλιση που δείχνει το MAE ήταν κοντά στο 1.4. Κρατώντας την ίδια είσοδο, χρησιμοποιήθηκε η δεύτερη συλλογή δεδομένων. Αυτή η περίπτωση ήταν δυσκολότερη για τα νευρωνικά δίκτυα καθώς τα δεδομένα που χρησιμοποιήθηκαν ήταν από ημέρες με διαφορετικές συνθήκες. Όμως οι προβλεπόμενες τιμές από το FNN δεν απείχαν από τις πραγματικές πάνω από 1.5. Τα άλλα νευρωνικά δίκτυα με εξαίρεση το LSTM, δεν απέδωσαν εξίσου καλά. Τέλος, το παραπάνω πείραμα επαναλήφθηκε με την εκπαίδευση να αξιοποιεί εγγραφές και από τα δυο σύνολα δεδομένων. Την καλύτερη απόδοση είχαν το FNN και το Bidirectional LSTM με αρκετά υψηλό R^2 και απόκλιση που δείχνει το MAE κοντά στο 1.7 για το FNN. Οι άλλοι δυο τύποι νευρωνικών δικτύων είχαν λίγο μικρότερη ακρίβεια στον προσδιορισμό της θερμικής απόδοσης. Όμως, λαμβάνοντας υπόψη την πολυπλοκότητα του προβλήματος και την ανομοιομορφία των δεδομένων, τα αποτελέσματα είναι ικανοποιητικά. Τα τελευταία πειράματα είναι ιδιαίτερα σημαντικά καθώς αποδεικνύεται ότι ακόμα και όταν τα δεδομένα θερμοκρασίας και παροχής είναι πολλά και ανομοιομορφα και δεν υπάρχουν διαθέσιμες όλες οι απαραίτητες τιμές μετρήσεων για τον υπολογισμό του θερμικού βαθμού απόδοσης, τα νευρωνικά δίκτυα μπορούν να τον προσεγγίσουν.

Αξίζει να σημειωθεί ότι κάθε ένα από τα πείραμα που εκτελέστηκαν, έτρεξε

δέκα φορές ώστε τα αποτελέσματα να είναι πιο αντιπροσωπευτικά. Στα Σχήματα 4.10, 4.11, 4.12 και 4.13 παρουσιάζονται οι τιμές του MAE για κάθε τρέξιμο. Τα συγκεκριμένα διαγράμματα παρουσιάστηκαν μόνο για τα πειράματα με πολλά δεδομένα καθώς στα άλλα, οι διαφορές ήταν πολύ μικρές. Το FNN φαίνεται ότι σε όλες τις περιπτώσεις έχει μικρή διακύμανση στις τιμές του MAE και επιδεικνύει μια σταθερότητα. Αντίθετα το απλό RNN έχει αρκετά μεγαλύτερη διακύμανση ως προς τις τιμές του MAE, γεγονός που το καθιστά λιγότερο αξιόπιστο. Όσον αφορά τα LSTM και Bidirectional LSTM, κυμαίνονται περίπου στο ίδιο επίπεδο με το FNN, με το LSTM να έχει ελαφρώς μεγαλύτερη διακύμανση.

Ιδιαίτερο ενδιαφέρον παρουσιάζει η σύγκριση των νευρωνικών δικτύων ως προς τον χρόνο εκπαίδευσης (Σχήμα 4.14). Η σύγκριση έγινε με χρήση δεδομένων από το πιο χρονοβόρο πείραμα: αυτό στο οποίο χρησιμοποιήθηκαν δυο σύνολα δεδομένων και τέσσερις μεταβλητές. Το FNN έχει αισθητά λιγότερο χρόνο εκπαίδευσης εξαιτίας της απλότητας της δομής του. Τα αναδρομικά (Recurrent) δίκτυα απαιτούν πολύ περισσότερο χρόνο καθώς η επεξεργασία στα αναδρομικά στρώματα είναι μια πολύπλοκη διαδικασία.

5.2 Συμπεράσματα

Στην παρούσα εργασία, πραγματοποιήθηκε ο προσδιορισμός τιμών θερμικής απόδοσης ενεργειακών συστημάτων κτηρίων με χρήση βαθιών νευρωνικών δικτύων. Στα πειράματα που υλοποιήθηκαν, χρησιμοποιήθηκαν δεδομένα θερμοκρασίας και παροχής νερού συστημάτων θέρμανσης δυο κτηρίων για διάφορες χρονικές στιγμές. Κατασκευάστηκαν τέσσερα νευρωνικά δίκτυα και συγκρίθηκαν ως προς την απόδοσή τους στο συγκεκριμένο πρόβλημα παλινδρόμησης.

Αρχικά όλα τα νευρωνικά δίκτυα εκπαιδεύτηκαν και εν συνεχεία δοκιμάστηκαν μόνο με το σύνολο δεδομένων του πρώτου κτηρίου που περιέχει λίγες εγγραφές. Έπειτα, χρησιμοποιήθηκαν τα δεδομένα του δεύτερου κτηρίου. Ακολούθως, σε επόμενο πείραμα αξιοποιήθηκε συνδυασμός των δεδομένων των δυο κτηρίων. Στις τρεις αυτές περιπτώσεις όλα τα νευρωνικά δίκτυα που υλοποιήθηκαν, προσδιόρισαν με την απαιτούμενη ακρίβεια τον βαθμό θερμικής απόδοσης. Έπειτα, τα νευρωνικά δίκτυα εκπαιδεύτηκαν και δοκιμάστηκαν σε ένα δυσκολότερο πρόβλημα. Αξιοποίησαν τα δεδομένα των ίδιων κτηρίων, αλλά αυτή τη φορά τους δόθηκε μια μεταβλητή λι-

γότερη στην είσοδο (τέσσερις έναντι πέντε). Ο προσδιορισμός του βαθμού απόδοσης με λιγότερα δεδομένα είναι ιδιαίτερα σημαντικός καθώς σε τέτοιες περιπτώσεις ο μαθηματικός του υπολογισμός είναι αδύνατος. Στα προαναφερθέντα πειράματα τα νευρωνικά δίκτυα ανταποκρίθηκαν ικανοποιητικά και έφτασαν αρκετά κοντά στις πραγματικές τιμές της απόδοσης.

5.3 Μελλοντικές προεκτάσεις

Μελλοντικά, θα μπορούσαν να χρησιμοποιηθούν δεδομένα από περισσότερα κτήρια και μεγαλύτερα χρονικά διαστήματα. Έτσι, τα νευρωνικά δίκτυα θα είναι σε θέση να υπολογίζουν το θερμικό βαθμό απόδοσης κτηρίων πάνω στα οποία δεν έχουν εκπαιδευτεί. Επιπλέον, με δεδομένα από μεγάλα χρονικά διαστήματα, μπορεί να κατασκευαστεί νευρωνικό δίκτυο που θα δέχεται ως είσοδο τιμές θερμικής απόδοσης και θα προβλέπει τις αντίστοιχες τιμές σε μελλοντικές ημερομηνίες. Τέλος, υπάρχει δυνατότητα δοκιμής των νευρωνικών δικτύων με λήψη τριών μεταβλητών έναντι τεσσάρων που χρησιμοποιήθηκαν στην τελευταία σειρά πειραμάτων.

Βιβλιογραφία

- [1] javapoint.com, “Javapoint..” <https://www.javatpoint.com/>.
- [2] L. Zouloumis, G. Stergianakos, N. Ploskas, and G. Panaras, “Dynamic simulation-based surrogate model for the dimensioning of building energy systems,” *Energies*, vol. 14, no. 21, p. 7141, 2021.
- [3] g2.com, “g2..” <https://www.g2.com/articles/supervised-vs-unsupervised-learning>.
- [4] learndatasci.com, “learndatasci..” <https://www.learndatasci.com/tutorials/reinforcement-q-learning-scratch-python-openai-gym/>.
- [5] Y. Guo, X. Cao, B. Liu, and M. Gao, “Solving partial differential equations using deep learning and physical constraints,” *Applied Sciences*, vol. 10, no. 17, p. 5917, 2020.
- [6] towardsdatascience.com, “towardsdatascience..” <https://towardsdatascience.com/3-neural-network-architectures-you-need-to-know-for-nlp-5660f11281be>.
- [7] colah’s blog, “colah.github.io..” <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- [8] S. A. Kalogirou and M. Bojic, “Artificial neural networks for the prediction of the energy consumption of a passive solar building,” *Energy*, vol. 25, no. 5, pp. 479–491, 2000.
- [9] C. Turhan, T. Kazanasmaz, I. E. Uygun, K. E. Ekmen, and G. G. Akkurt, “Comparative study of a building energy performance software (kep-iyte-ess) and ann-based building heat load estimation,” *Energy and Buildings*, vol. 85, pp. 115–125, 2014.
- [10] C. Zhou, Z. Fang, X. Xu, X. Zhang, Y. Ding, X. Jiang, *et al.*, “Using long short-term memory networks to predict energy consumption of air-conditioning systems,” *Sustainable Cities and Society*, vol. 55, p. 102000, 2020.
- [11] F. Mtibaa, K.-K. Nguyen, M. Azam, A. Papachristou, J.-S. Venne, and M. Cheriet, “Lstm-based indoor air temperature prediction framework for hvac systems in smart buildings,” *Neural Computing and Applications*, vol. 32, no. 23, pp. 17569–17585, 2020.
- [12] H. Cheng, Z. Xie, Y. Shi, and N. Xiong, “Multi-step data prediction in wireless sensor networks based on one-dimensional cnn and bidirectional lstm,” *IEEE Access*, vol. 7, pp. 117883–117896, 2019.
- [13] E. Union, “Eurostat energy statistics—an overview..” https://ec.europa.eu/eurostat/statistics-explained/index.php/Energy_statistics_-_an_overview#Primary_energy_production.

-
- [14] X. Zhang, W. Shi, X. Li, B. Yan, A. Malkawi, and N. Li, "Decentralized temperature control via hvac systems in energy efficient buildings: An approximate solution procedure," in *2016 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, pp. 936–940, IEEE, 2016.
- [15] W. Thuiller, "Climate change and the ecologist," *Nature*, vol. 448, no. 7153, pp. 550–552, 2007.
- [16] Y. Geng, W. Ji, Z. Wang, B. Lin, and Y. Zhu, "A review of operating performance in green buildings: Energy use, indoor environmental quality and occupant satisfaction," *Energy and Buildings*, vol. 183, pp. 500–514, 2019.
- [17] A. Schieweck, E. Uhde, T. Salthammer, L. C. Salthammer, L. Morawska, M. Mazaheri, and P. Kumar, "Smart homes and the control of indoor air quality," *Renewable and Sustainable Energy Reviews*, vol. 94, pp. 705–718, 2018.
- [18] M. Arif, M. Katafygiotou, A. Mazroei, A. Kaushik, E. Elsarrag, *et al.*, "Impact of indoor environmental quality on occupant well-being and comfort: A review of the literature," *International Journal of Sustainable Built Environment*, vol. 5, no. 1, pp. 1–11, 2016.
- [19] T. N. Quang, C. He, L. D. Knibbs, R. De Dear, and L. Morawska, "Co-optimisation of indoor environmental quality and energy consumption within urban office buildings," *Energy and Buildings*, vol. 85, pp. 225–234, 2014.
- [20] M. Katafygiotou and D. K. Serghides, "Bioclimatic chart analysis in three climate zones in cyprus," *Indoor and Built Environment*, vol. 24, no. 6, pp. 746–760, 2015.
- [21] A. Ashrae, "Standard 55-2013: Thermal environmental conditions for human occupancy," *American Society of Heating, Refrigerating, and Air-Conditioning Engineers, Inc. Atlanta*, 2013.
- [22] J. A. Wright, H. A. Loosemore, and R. Farmani, "Optimization of building thermal design and control by multi-criterion genetic algorithm," *Energy and buildings*, vol. 34, no. 9, pp. 959–972, 2002.
- [23] M. Hamdy, A. Hasan, and K. Siren, "Applying a multi-objective optimization approach for design of low-emission cost-effective dwellings," *Building and environment*, vol. 46, no. 1, pp. 109–123, 2011.
- [24] F. B. Fitch, "Warren s. mcculloch and walter pitts. a logical calculus of the ideas immanent in nervous activity. bulletin of mathematical biophysics, vol. 5 (1943), pp. 115–133.," *The Journal of Symbolic Logic*, vol. 9, no. 2, pp. 49–50, 1944.
- [25] S. Haggemüller, R. C. Maron, A. Hekler, J. S. Utikal, C. Barata, R. L. Barnhill, H. Beltraminelli, C. Berking, B. Betz-Stablein, A. Blum, *et al.*, "Skin cancer classification via convolutional neural networks: systematic review of studies involving human experts," *European Journal of Cancer*, vol. 156, pp. 202–216, 2021.
- [26] S. S. Yadav and S. M. Jadhav, "Deep convolutional neural network based medical image classification for disease diagnosis," *Journal of Big Data*, vol. 6, no. 1, pp. 1–18, 2019.

-
- [27] R. Wang, Z. Li, J. Cao, T. Chen, and L. Wang, "Convolutional recurrent neural networks for text classification," in *2019 International Joint Conference on Neural Networks (IJCNN)*, pp. 1–6, IEEE, 2019.
- [28] Z. Wang, Y. He, and M. Jiang, "A comparison among three neural networks for text classification," in *2006 8th international Conference on Signal Processing*, vol. 3, IEEE, 2006.
- [29] J. Clark, I. Koprinska, and J. Poon, "A neural network based approach to automated e-mail classification," in *Proceedings IEEE/WIC international conference on web intelligence (WI 2003)*, pp. 702–705, IEEE, 2003.
- [30] M. Litvak, "Deep dive into authorship verification of email messages with convolutional neural network," in *Annual International Symposium on Information Management and Big Data*, pp. 129–136, Springer, 2018.
- [31] H. Chu, J. Bian, Q. Lang, X. Sun, and Z. Wang, "Daily groundwater level prediction and uncertainty using lstm coupled with pmi and bootstrap incorporating teleconnection patterns information," *Sustainability*, vol. 14, no. 18, p. 11598, 2022.
- [32] C. Giri, S. Thomassey, J. Balkow, and X. Zeng, "Forecasting new apparel sales using deep learning and nonlinear neural network regression," in *2019 International Conference on Engineering, Science, and Industrial Applications (ICESI)*, pp. 1–6, IEEE, 2019.
- [33] W. Cao, V. Mirjalili, and S. Raschka, "Rank consistent ordinal regression for neural networks with application to age estimation," *Pattern Recognition Letters*, vol. 140, pp. 325–331, 2020.
- [34] C. F. Sabottke, M. A. Breaux, and B. M. Spieler, "Estimation of age in unidentified patients via chest radiography using convolutional neural network regression," *Emergency radiology*, vol. 27, no. 5, pp. 463–468, 2020.
- [35] A. Varma, A. Sarma, S. Doshi, and R. Nair, "House price prediction using machine learning and neural networks," in *2018 second international conference on inventive communication and computational technologies (ICICCT)*, pp. 1936–1939, IEEE, 2018.
- [36] I. D. Wilson, S. D. Paris, J. A. Ware, and D. H. Jenkins, "Residential property price time series forecasting with neural networks," in *Applications and Innovations in Intelligent Systems IX*, pp. 17–28, Springer, 2002.
- [37] P. Cunningham, M. Cord, and S. J. Delany, "Supervised learning," in *Machine learning techniques for multimedia*, pp. 21–49, Springer, 2008.
- [38] Q. V. Le, "Building high-level features using large scale unsupervised learning," in *2013 IEEE international conference on acoustics, speech and signal processing*, pp. 8595–8598, IEEE, 2013.
- [39] L. P. Kaelbling, M. L. Littman, and A. W. Moore, "Reinforcement learning: A survey," *Journal of artificial intelligence research*, vol. 4, pp. 237–285, 1996.

-
- [40] A. Delarue, R. Anderson, and C. Tjandraatmadja, "Reinforcement learning with combinatorial actions: An application to vehicle routing," *Advances in Neural Information Processing Systems*, vol. 33, pp. 609–620, 2020.
- [41] J. James, W. Yu, and J. Gu, "Online vehicle routing with neural combinatorial optimization and deep reinforcement learning," *IEEE Transactions on Intelligent Transportation Systems*, vol. 20, no. 10, pp. 3806–3817, 2019.
- [42] A. S. Polydoros and L. Nalpantidis, "Survey of model-based reinforcement learning: Applications on robotics," *Journal of Intelligent & Robotic Systems*, vol. 86, no. 2, pp. 153–173, 2017.
- [43] D. Svozil, V. Kvasnicka, and J. Pospichal, "Introduction to multi-layer feed-forward neural networks," *Chemometrics and intelligent laboratory systems*, vol. 39, no. 1, pp. 43–62, 1997.
- [44] G. Bebis and M. Georgiopoulos, "Feed-forward neural networks," *IEEE Potentials*, vol. 13, no. 4, pp. 27–31, 1994.
- [45] V. K. Ojha, A. Abraham, and V. Snášel, "Metaheuristic design of feedforward neural networks: A review of two decades of research," *Engineering Applications of Artificial Intelligence*, vol. 60, pp. 97–116, 2017.
- [46] M. Lukoševičius and H. Jaeger, "Reservoir computing approaches to recurrent neural network training," *Computer Science Review*, vol. 3, no. 3, pp. 127–149, 2009.
- [47] A. M. Schäfer and H.-G. Zimmermann, "Recurrent neural networks are universal approximators," *International journal of neural systems*, vol. 17, no. 04, pp. 253–263, 2007.
- [48] N. J. Johannesen, "Machine learning applications for load predictions in electrical energy network," 2022.
- [49] T. Mikolov, S. Kombrink, L. Burget, J. Černocký, and S. Khudanpur, "Extensions of recurrent neural network language model," in *2011 IEEE international conference on acoustics, speech and signal processing (ICASSP)*, pp. 5528–5531, IEEE, 2011.
- [50] J. L. Elman, "Finding structure in time," *Cognitive science*, vol. 14, no. 2, pp. 179–211, 1990.
- [51] Y. Yu, X. Si, C. Hu, and J. Zhang, "A review of recurrent neural networks: Lstm cells and network architectures," *Neural computation*, vol. 31, no. 7, pp. 1235–1270, 2019.
- [52] A. Graves and J. Schmidhuber, "Framewise phoneme classification with bidirectional lstm and other neural network architectures," *Neural networks*, vol. 18, no. 5-6, pp. 602–610, 2005.
- [53] Y. Bin, Y. Yang, F. Shen, N. Xie, H. T. Shen, and X. Li, "Describing video with attention-based bidirectional lstm," *IEEE transactions on cybernetics*, vol. 49, no. 7, pp. 2631–2641, 2018.
- [54] L. Gao, Z. Guo, H. Zhang, X. Xu, and H. T. Shen, "Video captioning with attention-based lstm and semantic consistency," *IEEE Transactions on Multimedia*, vol. 19, no. 9, pp. 2045–2055, 2017.

-
- [55] Q. Wang, C. Feng, Y. Xu, H. Zhong, and V. S. Sheng, “A novel privacy-preserving speech recognition framework using bidirectional lstm,” *Journal of Cloud Computing*, vol. 9, no. 1, pp. 1–13, 2020.
- [56] A. Graves, N. Jaitly, and A.-r. Mohamed, “Hybrid speech recognition with deep bidirectional lstm,” in *2013 IEEE workshop on automatic speech recognition and understanding*, pp. 273–278, IEEE, 2013.
- [57] M. Bojić and N. Lukić, “Numerical evaluation of solar-energy use through passive heating of weekend houses in yugoslavia,” *Renewable Energy*, vol. 20, no. 2, pp. 207–222, 2000.
- [58] Y. Liang, K. Ouyang, L. Jing, S. Ruan, Y. Liu, J. Zhang, D. S. Rosenblum, and Y. Zheng, “Urbanfm: Inferring fine-grained urban flows,” in *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining*, pp. 3132–3142, 2019.
- [59] B. Delcroix, J. L. Ny, M. Bernier, M. Azam, B. Qu, and J.-S. Venne, “Autoregressive neural networks with exogenous variables for indoor temperature prediction in buildings,” in *Building Simulation*, vol. 14, pp. 165–178, Springer, 2021.
- [60] S. Singaravel, J. Suykens, and P. Geyer, “Deep-learning neural-network architectures and methods: Using component-based models in building-design energy prediction,” *Advanced Engineering Informatics*, vol. 38, pp. 81–90, 2018.
- [61] D. B. Crawley, L. K. Lawrie, F. C. Winkelmann, W. F. Buhl, Y. J. Huang, C. O. Pedersen, R. K. Strand, R. J. Liesen, D. E. Fisher, M. J. Witte, *et al.*, “Energyplus: creating a new-generation building energy simulation program,” *Energy and buildings*, vol. 33, no. 4, pp. 319–331, 2001.
- [62] S. J. Pan and Q. Yang, “A survey on transfer learning,” *IEEE Transactions on knowledge and data engineering*, vol. 22, no. 10, pp. 1345–1359, 2009.
- [63] E. Liu, Y. Wang, and Y. Huang, “Short-term forecast of multi-load of electrical heating and cooling in regional integrated energy system based on deep lstm rnn,” in *2020 IEEE 4th Conference on Energy Internet and Energy System Integration (EI2)*, pp. 2994–2998, IEEE, 2020.
- [64] H. Drucker, C. J. Burges, L. Kaufman, A. Smola, and V. Vapnik, “Support vector regression machines,” *Advances in neural information processing systems*, vol. 9, 1996.
- [65] Y. I. Alamin, J. D. Álvarez, M. del Mar Castilla, and A. Ruano, “An artificial neural network (ann) model to predict the electric load profile for an hvac system,” *IFAC-PapersOnLine*, vol. 51, no. 10, pp. 26–31, 2018.
- [66] tiobe.com, “Tiobe – the software quality company..” <https://www.tiobe.com/tiobe-index/>.
- [67] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. Corrado, A. Davis, J. Dean, M. Devin, *et al.*, “Tensorflow: Large-scale machine learning on heterogeneous distributed systems,” 2015.
- [68] tensorflow.org, “Tensorflow..” <https://www.tensorflow.org/>.

-
- [69] keras.io, “Keras..” <https://keras.io/>.
- [70] H. Niu, E. Reeves, and P. Gerstoft, “Source localization in an ocean waveguide using supervised machine learning,” *The Journal of the Acoustical Society of America*, vol. 142, no. 3, pp. 1176–1188, 2017.
- [71] Y. Chen, Y. Shi, and B. Zhang, “Modeling and optimization of complex building energy systems with deep neural networks,” in *2017 51st Asilomar Conference on Signals, Systems, and Computers*, pp. 1368–1373, IEEE, 2017.
- [72] M. Kaselimi, N. Doulamis, A. Doulamis, A. Voulodimos, and E. Protopapadakis, “Bayesian-optimized bidirectional lstm regression model for non-intrusive load monitoring,” in *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 2747–2751, IEEE, 2019.
- [73] X. Glorot and Y. Bengio, “Understanding the difficulty of training deep feedforward neural networks,” in *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, pp. 249–256, JMLR Workshop and Conference Proceedings, 2010.
- [74] J. Qi, J. Du, S. M. Siniscalchi, X. Ma, and C.-H. Lee, “On mean absolute error for deep neural network based vector-to-vector regression,” *IEEE Signal Processing Letters*, vol. 27, pp. 1485–1489, 2020.
- [75] P. Yin and X. Fan, “Estimating r^2 shrinkage in multiple regression: A comparison of different analytical methods,” *The Journal of Experimental Education*, vol. 69, no. 2, pp. 203–224, 2001.