



ΕΘΝΙΚΟ ΜΕΤΣΟΒΕΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ ΚΑΙ

ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

Βελτίωση πρόβλεψης ενεργειακής κατανάλωσης κτιρίων με χρήση τεχνικών μεταφοράς μάθησης και temporal fusion transformers

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

ΑΝΤΩΝΙΟΥ ΖΑΚΥΝΘΙΝΟΥ

Επιβλέπων : Ευάγγελος Μαρινάκης
Επίκουρος Καθηγητής ΕΜΠ

Αθήνα, Φεβρουάριος 2024



ΕΘΝΙΚΟ ΜΕΤΣΟΒΕΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ ΚΑΙ

ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

Βελτίωση πρόβλεψης ενεργειακής κατανάλωσης κτιρίων με χρήση τεχνικών μεταφοράς μάθησης και temporal fusion transformers

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
ΤΟΥ
ΑΝΤΩΝΙΟΥ ΖΑΚΥΝΘΙΝΟΥ

Επιβλέπων : Ευάγγελος Μαρινάκης
Επίκουρος Καθηγητής ΕΜΠ

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 24η Φεβρουαρίου 2024.

.....
Ευάγγελος Μαρινάκης
Επίκουρος Καθηγητής ΕΜΠ

.....
Δημήτριος Ασκούνης
Καθηγητής ΕΜΠ

.....
Ευάγγελος Σπιλιώτης
Επίκουρος Καθηγητής ΕΜΠ

Αθήνα, Φεβρουάριος 2024



ΕΘΝΙΚΟ ΜΕΤΣΟΒΕΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ ΚΑΙ

ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

.....

Ζακυνθινός Αντώνιος

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.

Copyright © Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Αντώνιος Ζακυνθινός, 2024

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 δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Η ακριβής πρόβλεψη του ηλεκτρικού φορτίου είναι ζωτικής σημασίας για τη βελτιστοποίηση της διαχείρισης ενέργειας και τη διασφάλιση της σταθερότητας του δικτύου, ιδιαίτερα με τη διαρκώς αυξανόμενη ενσωμάτωση της τεχνητής νοημοσύνης σε αυτόν τον τομέα. Ωστόσο, η ακρίβεια της πρόβλεψης συχνά επηρεάζεται από τον περιορισμένο όγκο ιστορικών δεδομένων, καθιστώντας δύσκολη την αποτελεσματική εκπαίδευση μοντέλων βαθιάς μάθησης. Η παρούσα διατριβή εξερευνά τη χρήση τεχνικών μεταφοράς μάθησης (transfer learning) για τη βελτίωση της ακρίβειας της πρόβλεψης, μεταφέροντας γνώση από ένα καλά εδραιωμένο σύνολο δεδομένων πηγής σε στοχευμένα σύνολα δεδομένων με διαφορετικούς βαθμούς έλλειψης δεδομένων. Αυτές οι μέθοδοι εφαρμόστηκαν σε ένα εύρος υλοποιημένων αρχιτεκτονικών βαθιάς μάθησης, συμπεριλαμβανομένων των LSTM, RNN, CNN, του υβριδικού CNN-LSTM, καθώς και το μοντέλο μετασχηματιστή συγχώνευσης χρόνου (TFT). Το μοντέλο TFT εξετάζεται ιδιαίτερα ως μέσο βελτίωσης των προβλέψεων, αξιοποιώντας την αρχιτεκτονική προσοχής (attention-based) και τις προηγμένες δυνατότητες επιλογής χαρακτηριστικών. Επιπλέον, ενσωματώθηκαν μετεωρολογικά δεδομένα στη διαδικασία εκπαίδευσης, προκειμένου να διευκολυνθεί η ακριβής προσαρμογή του μοντέλου και να αυξηθεί η ακρίβεια των προβλέψεων του, παρέχοντας πολύτιμες πληροφορίες. Τέλος αυτή η έρευνα στοχεύει να αποδείξει τα πλεονεκτήματα του συνδυασμού της μεταφοράς μάθησης με το TFT, αναπτύσσοντας μια πιο προσαρμοστική, επεκτάσιμη και αποδοτική ως προς τα δεδομένα προσέγγιση στην πρόβλεψη ηλεκτρικού φορτίου, συμβάλλοντας σε πιο έξυπνες λύσεις διαχείρισης ενέργειας.

Λέξεις Κλειδιά

Πρόβλεψη ενεργειακής κατανάλωσης, μηχανική μάθηση, βαθιά μάθηση, μεταφορά μάθησης, έλλειψη δεδομένων, ηλεκτρική κατανάλωση κτιρίου, σύνολο δεδομένων κτιρίων Genome-2, μετασχηματιστής συγχώνευσης χρόνου

Abstract

Accurate electrical load forecasting is crucial for optimizing energy management and ensuring grid stability, especially with the growing integration of artificial intelligence in this field. However, forecasting performance is often hindered by limited historical data, making it challenging to train deep learning models effectively. This thesis explores the use of transfer learning techniques to enhance forecasting accuracy by transferring knowledge from a well-established source dataset to target datasets with different degrees of data scarcity. Those methods were applied to a range of implemented deep learning architectures, including LSTMs, RNNs, CNNs, CNN-LSTM hybrids, and the Temporal Fusion Transformer (TFT). The TFT model is particularly investigated as a means to improve predictions by leveraging its attention-based architecture and advanced feature selection capabilities. Additionally weather-related data were integrated into the training process in order to facilitate accurate training and increase prediction accuracy by offering valuable insights. Finally, this research aims to demonstrate the advantages of combining transfer learning with TFT to develop a more adaptive, scalable, and data-efficient approach to load forecasting, contributing to smarter energy management solutions.

Keywords

Electrical load forecasting, machine learning, deep learning, transfer learning, data scarcity, building electrical consumption, Genome-2 building dataset, Temporal Fusion Transformer

Ευχαριστίες

Αρχικά θα ήθελα να ευχαριστήσω τον καθηγητή κ. Ευάγγελο Μαρινάκη για την ευκαιρία που μου έδωσε να ασχοληθώ με το αντικείμενο των προβλέψεων σε ένα τόσο ανερχόμενο τομέα όπως η ενέργεια. Επίσης, θα ήθελα να ευχαριστήσω το διδακτορικό φοιτητή Βασίλη Μιχαλακόπουλο για τις πολύτιμες συμβουλές και διορθώσεις του, την αδιάκοπη καθοδήγηση του και το συνολικότερο ενδιαφέρον που έδειξε για την εξέλιξη και εν τέλει περάτωση της διπλωματικής μου εργασίας. Τέλος θα ήθελα να ευχαριστήσω θερμά την οικογένεια και τους φίλους μου που βρίσκονταν δίπλα μου και με στήριζαν καθ' όλη τη διάρκεια της παρούσας μελέτης.

Αντώνιος Ζακυνθινός
Αθήνα, Φεβρουάριος 2024

Περιεχόμενα

<i>Περίληψη</i>	7
<i>Abstract</i>	9
<i>Ευχαριστίες</i>	11
<i>Περιεχόμενα</i>	13
<i>Κατάλογος Σχημάτων</i>	17
<i>Πρόλογος</i>	22
1. Εισαγωγή	24
1.1 Η ανάγκη για ακριβείς προβλέψεις ενεργειακής κατανάλωσης...	24
1.1.1 Η έννοια της πρόβλεψης	25
1.1.2 Αντίκτυπος στην διαχείριση ενέργειας	26
1.1.3 Εφαρμογές στη διαχείριση κτιρίων και στα έξυπνα δίκτυα	28
1.1.4 Προκλήσεις εκτέλεσης προβλέψεων	32
1.2 Στόχοι της παρούσας μελέτης	35
1.2.1 Αξιολόγηση βασικών νευρωνικών δικτύων.....	36
1.2.2 Εφαρμογές τεχνικών μεταφοράς μάθησης	37
1.2.3 Εξέταση απόδοσης του μοντέλου μετασχηματιστή συγχώνευσης χρόνου (Temporal Fusion Transformer)	37
1.2.4 Δομή της διπλωματικής εργασίας.....	38
2. Θεωρητικό υπόβαθρο και βιβλιογραφική ανασκόπηση	40
2.1 Η ιστορική εξέλιξη και θεωρητική ανασκόπηση των μοντέλων πρόβλεψης	40
2.1.1 Βασικά στατιστικά μοντέλα πρόβλεψης	40
2.1.2 Ενσωμάτωση της μηχανικής μάθησης στην διαδικασία της πρόβλεψης.....	47
2.1.3 Βαθιά Μάθηση : Εξέλιξη της διαδικασίας πρόβλεψης μέσω νευρωνικών δικτύων.....	53

2.1.4	Σχετικές έρευνες στην πρόβλεψη ενεργειακού φορτίου.....	71
2.2	Μεταφορά Μάθησης : Μια λύση στο πρόβλημα της έλλειψης δεδομένων.....	74
2.2.1	Εισαγωγή στη μεταφορά μάθησης.....	74
2.2.2	Τεχνικές μεταφοράς μάθησης.....	79
2.2.3	Σχετικές έρευνες στην εφαρμογή τεχνικών μεταφοράς μάθησης για πρόβλεψη ενεργειακού φορτίου	87
2.3	Μετρικές για την αξιολόγηση της απόδοσης μιας πρόβλεψης.....	91
2.3.1	Το μέσο απόλυτο σφάλμα (MAE).....	92
2.3.2	Το μέσο απόλυτο ποσοστό σφάλματος (MAPE)	92
2.3.3	Η ρίζα μέσου τετραγωνικού σφάλματος (RMSE).....	93
2.3.4	Το σκορ R^2 (R^2 Score).....	94
2.3.5	Συγκριτική Ανάλυση Μετρικών.....	95
3.	Μεθοδολογία πειραμάτων πρόβλεψης.....	96
3.1	Προεπισκόπηση της μεθοδολογίας προβλέψεων	96
3.2	Σχηματισμός των συνόλων δεδομένων εκπαίδευσης.....	98
3.2.1	Το σύνολο δεδομένων Genome-2.....	99
3.2.2	Διαδικασία επιλογής κτιρίων και χαρακτηριστικών	104
3.2.3	Προεπεξεργασία δεδομένων	109
3.3	Περιγραφή και ανάλυση της αρχιτεκτονικών των νευρωνικών δικτύων.....	115
3.3.1	Η ομάδα των ακολουθιακών μοντέλων.....	115
3.3.2	Το δίκτυο μετασχηματιστή συγχώνευσης χρόνου (Temporal Fusion Transformer).....	123
3.4	Μεθοδολογία εκπαίδευσης και πρόβλεψης.....	132
3.4.1	Διαδικασία εκπαίδευσης	132
3.4.2	Χρονικοί ορίζοντες προβλέψεων	138

3.5 Μεθοδολογία μεταφοράς μάθησης.....	140
3.5.1 Τεχνικές μεταφοράς μάθησης ακολουθιακών μοντέλων.....	141
3.5.2 Τεχνικές μεταφοράς μάθησης του μοντέλου TFT	144
4. Σύγκριση και αξιολόγηση αποτελεσμάτων.....	148
4.1 Ανάλυση αποτελεσμάτων των δικτύων.....	148
4.1.1 Επιδόσεις του μοντέλου στοιβαγμένων RNN.....	149
4.1.2 Επιδόσεις του μοντέλου στοιβαγμένων LSTM.....	155
4.1.3 Επιδόσεις του μοντέλου στοιβαγμένων CNN.....	161
4.1.4 Επιδόσεις του υβριδικού δικτύου	168
4.1.5 Επιδόσεις δικτύου TFT.....	176
4.2 Συγκριτικά αποτελέσματα.....	184
5. Επίλογος.....	202
Βιβλιογραφία.....	207

Κατάλογος Σχημάτων

Εικόνα 2.1 : Αρχιτεκτονική Perceptron [55].....	53
Εικόνα 2.2 : Παράδειγμα αρχιτεκτονικής MLP ενός κρυφού επιπέδου [55].....	55
Εικόνα 2.3 : Αρχιτεκτονική βασικού συνελκτικού δικτύου (CNN) [60]	57
Εικόνα 2.4 : Αρχιτεκτονική ενός RNN με 2 επαναληπτικά κρυφά επίπεδα (Πηγή : Understanding the Mechanism and Types of Recurrent Neural Networks).....	58
Εικόνα 2.5 : Αριστερά - Διάγραμμα ενός απλού νευρώνα RNN με είσοδο x που ενσωματώνεται στην κρυφή μνήμη h με επαναληπτική σύνδεση και έξοδο o . Δεξιά - Ο ίδιος νευρώνας ως ένα ξεδιπλωμένο υπολογιστικό γράφημα με είσοδο για κάθε χρονικό βήμα. [63].....	59
Εικόνα 2.6 : Αρχιτεκτονική ενός επιπέδου LSTM (Πηγή : MathWorks - Long Short-Term Memory Neural Networks)	61
Εικόνα 2.7 : Διάγραμμα ροής δεδομένων μέσα σε ένα νευρώνα ενός επιπέδου LSTM (Πηγή : MathWorks - Long Short-Term Memory Neural Networks).....	61
Εικόνα 2.8 : Αρχιτεκτονική ενός Μετασχηματιστή (Πηγή : Wikipedia - Transformer (deep learning architecture)).....	65
Εικόνα 2.9 : Αριστερά - Μηχανισμός Αυτοπροσοχής. Δεξιά - Προσοχή πολλαπλών κεφαλών [71].....	67
Εικόνα 2.10 : Αριστερά - Παραδοσιακές μέθοδοι μηχανικής μάθησης. Δεξιά - Μέθοδος μηχανικής μάθησης [78].....	76
Εικόνα 2.11 : Κατηγορίες μεταφοράς μάθησης [83]	80
Εικόνα 2.12 : Απεικόνιση προσεγγίσεων μεταφοράς μάθησης [83].....	81
Εικόνα 3.1: Διάγραμμα μεθοδολογίας πειραμάτων πρόβλεψης	97
Εικόνα 3.2: Προεπισκόπηση λεπτομερειών για τις τοποθεσίες από τις οποίες συλλέχθηκαν τα ενεργειακά δεδομένα [96] ..	99
Εικόνα 3.3: Κανονικοποιημένη ημερήσια κατανάλωση ηλεκτρικής ενέργειας ανά μονάδα επιφάνειας (Αριστερά). Γράφημα ποιότητας δεδομένων κατανάλωσης ηλεκτρικής ενέργειας (Δεξιά) [96].....	101
Εικόνα 3.4: Κατανομές μετεωρολογικών δεδομένων [96].....	102
Εικόνα 3.5: Κατανομές των μεταδεδομένων [96].....	102
Εικόνα 3.6: Γραφικές παραστάσεις της θερμοκρασίας αέρα και δρόσου στις τοποθεσίες των επιλεγμένων κτιρίων.....	108
Εικόνα 3.7: Γραφική παράσταση της κατανάλωσης ενέργειας των επιλεγμένων κτιρίων..	109
Εικόνα 3.8: Γραφική παράσταση ενεργειακής κατανάλωσης του πηγαίου κτιρίου πριν και μετά το στάδιο προεπεξεργασίας.....	111
Εικόνα 3.9: Γραφική παράσταση ενεργειακής κατανάλωσης του πρώτου στοχευμένου κτιρίου πριν και μετά το στάδιο προεπεξεργασίας.....	111
Εικόνα 3.10: Γραφική παράσταση ενεργειακής κατανάλωσης του δεύτερου στοχευμένου κτιρίου πριν και μετά το στάδιο προεπεξεργασίας.....	112
Εικόνα 3.11: Η αρχιτεκτονική του μοντέλου στοιβαγμένων επιπέδων RNN.	117
Εικόνα 3.12: Αρχιτεκτονική του μοντέλου στοιβαγμένων LSTM.....	119
Εικόνα 3.13: Αρχιτεκτονική του μοντέλου στοιβαγμένων CNN.....	120
Εικόνα 3.14: Αρχιτεκτονική του υβριδικού μοντέλου	122
Εικόνα 3.15: Διάγραμμα αρχιτεκτονικής του μοντέλου TFT [97].....	123
Εικόνα 3.16: Αρχιτεκτονική δικτύου υπολειμματικών πυλών (Αριστερά) - Αρχιτεκτονική δικτύου επιλογής μεταβλητών (Δεξιά) [97].....	124
Εικόνα 4.1 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του μοντέλου στοιβαγμένων RNN στο πηγαίο κτίριο	149
Εικόνα 4.2: Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα στο πρώτο στοχευμένο κτίριο του μοντέλου στοιβαγμένων RNN (διάρκειας 12 μηνών)	151

Εικόνα 4.26 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του υβριδικού μοντέλου στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών).....	172
Εικόνα 4.27 : Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του υβριδικού μοντέλου στο δεύτερο στοχευμένο κτίριο	174
Εικόνα 4.28 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του υβριδικού μοντέλου στο δεύτερο στοχευμένο κτίριο.....	175
Εικόνα 4.29 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του μοντέλου TFT στο πηγαίο κτίριο	176
Εικόνα 4.30 : Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του μοντέλου TFT στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών).....	178
Εικόνα 4.31 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου TFT στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών).....	178
Εικόνα 4.32 : Εύρη σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του μοντέλου TFT στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών).....	180
Εικόνα 4.33 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου TFT στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών).....	180
Εικόνα 4.34 : Εύρη σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του μοντέλου TFT στο δεύτερο στοχευμένο κτίριο.....	182
Εικόνα 4.35 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου TFT στο δεύτερο στοχευμένο κτίριο	182
Εικόνα 4.36 : Γραφικές παραστάσεις καλύτερων ημερησίων προβλέψεων στο σύνολο δεδομένων του πηγαίου κτιρίου	185
Εικόνα 4.37 : Γραφικές παραστάσεις καλύτερων εβδομαδιαίων προβλέψεων στο σύνολο δεδομένων του πηγαίου κτιρίου.....	186
Εικόνα 4.38 : Γραφικές παραστάσεις καλύτερων μηνιαίων προβλέψεων στο σύνολο δεδομένων του πηγαίου κτιρίου	187
Εικόνα 4.39 : Κατανομές σφαλμάτων ημερησίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)	188
Εικόνα 4.40 : Γραφική παράσταση ημερησίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)	188
Εικόνα 4.41 : Κατανομές σφαλμάτων εβδομαδιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)	189
Εικόνα 4.42 : Γραφική παράσταση εβδομαδιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)	190
Εικόνα 4.43 : Κατανομές σφαλμάτων μηνιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)	191
Εικόνα 4.44 : Γραφική παράσταση μηνιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)	191
Εικόνα 4.45 : Κατανομές σφαλμάτων ημερησίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)	192
Εικόνα 4.46 : Γραφικές παραστάσεις ημερησίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών).	192
Εικόνα 4.47 : Κατανομές σφαλμάτων εβδομαδιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)	194
Εικόνα 4.48 : Γραφικές παραστάσεις εβδομαδιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)	194
Εικόνα 4.49 : Κατανομές σφαλμάτων μηνιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)	196

Εικόνα 4.50 : Γραφικές παραστάσεις μηνιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)	196
Εικόνα 4.51 : Κατανομές σφαλμάτων ημερησίων προβλέψεων των καλύτερων μοντέλων στο δεύτερο στοχευμένο κτίριο	197
Εικόνα 4.52 : Γραφικές παραστάσεις ημερησίων προβλέψεων των καλύτερων μοντέλων στο δεύτερο στοχευμένο κτίριο .	197
Εικόνα 4.53 : Κατανομές σφαλμάτων εβδομαδιαίων προβλέψεων των καλύτερων μοντέλων στο δεύτερο στοχευμένο κτίριο	199
Εικόνα 4.54 : Γραφικές παραστάσεις εβδομαδιαίων προβλέψεων των καλύτερων μοντέλων στο δεύτερο στοχευμένο κτίριο	199
Εικόνα 4.55 : Κατανομές σφαλμάτων μηνιαίων προβλέψεων των καλύτερων μοντέλων στο δεύτερο στοχευμένο κτίριο ..	200
Εικόνα 4.56 : Γραφικές παραστάσεις μηνιαίων προβλέψεων των καλύτερων μοντέλων στο δεύτερο στοχευμένο κτίριο	201

Πρόλογος

Η παρούσα διπλωματική εργασία εκπονήθηκε στα πλαίσια ολοκλήρωσης των προπτυχιακών σπουδών μου στη Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Η/Υ υπό την επίβλεψη του εργαστηρίου Συστημάτων Αποφάσεων και Διοίκησης του τομέα Ηλεκτρονικών Βιομηχανικών Διατάξεων και Συστημάτων Αποφάσεων.

Εισαγωγή

1.1 Η ανάγκη για ακριβείς προβλέψεις ενεργειακής κατανάλωσης

Τα τελευταία 50 χρόνια η κατανάλωση ηλεκτρικής ενέργειας έχει αυξηθεί εκθετικά με τα συστήματα ηλεκτρικής ενέργειας να καθιερωθούν αναγκαία για την αδιάκοπη διανομή ενέργειας σε ολόένα και αυξανόμενο φάσμα συσκευών, από ηλεκτρονικές συσκευές καταναλωτών όπως ηλεκτρονικούς υπολογιστές έως και βιομηχανικά μηχανήματα. Παράλληλα η αυξανόμενη τάση εξηλεκτρισμού της βιομηχανίας και η υιοθέτηση νέων τεχνολογιών, όπως ηλεκτρικά αυτοκίνητα, αναμένεται να αυξήσει τις απαιτήσεις κατανάλωσης ενώ η επίτευξη υψηλότερης ενεργειακής απόδοσης σε συσκευές τελικής χρήσης καταναλωτή να τις μειώσει [1]. Έτσι γίνεται αντιληπτή μια αστάθεια στη χρήση ηλεκτρικής ενέργειας η οποία αποτελεί εμπόδιο για την εύρυθμη και αξιόπιστη λειτουργία του ενεργειακού δικτύου.

Για να μπορέσει να καλυφθεί αυτή η κατανάλωση θα πρέπει να υπάρχει και αντίστοιχη παραγωγή. Παρόλο που ακόμα παρατηρείται εξάρτηση σε μεγάλο βαθμό στις μη ανανεώσιμες πηγές ενέργειας για την κάλυψη των ενεργειακών απαιτήσεων, η ανάγκη για ένα καθαρό και βιώσιμο ενεργειακό τομέα έχει οδηγήσει σε σημαντικές αλλαγές στο σύγχρονο ενεργειακό δίκτυο, συμπεριλαμβανομένης της αυξημένης ενσωμάτωσης ανανεώσιμων πηγών ενέργειας και της χρήσης εξελιγμένων έξυπνων αισθητήρων και συσκευών παρακολούθησης του δικτύου [2]. Επομένως πλέον γίνεται αντιληπτή η σύγχρονη πολυπλοκότητα τέτοιων δικτύων και η αποτελεσματική διαχείριση τους απαιτεί πληροφορίες που προκύπτουν από τη διαρκή παρακολούθηση και ανάλυση τους. Αυτό επιτρέπει και την αξιοποίηση των δεδομένων αυτών για

προβλέψεις προσφέροντας πολύτιμες γνώσεις για την αδιάκοπη λειτουργία ενός δικτύου.

1.1.1 Η έννοια της πρόβλεψης

Η θεμελιώδης αρχή της πρόβλεψης βασίζεται στην υπόθεση ότι τα μοτίβα που παρατηρούνται στα δεδομένα του παρελθόντος ή ακόμα και η κατανομή τους θα εμφανιστούν κατά ίδιο ή παρόμοιο τρόπο στο μέλλον [3]. Η ανακάλυψη αυτών των προτύπων αλλά και η σωστή ερμηνεία τους είναι από τους σημαντικότερους παράγοντες για να θεωρηθεί μια πρόβλεψη ακριβής. Πέρα όμως της θεωρίας, στη πράξη, οι προβλέψεις εκτελούνται ώστε τα άτομα που λαμβάνουν αποφάσεις να επωφεληθούν από τα συμπεράσματα τους και να βελτιστοποιήσουν τις πιθανές μελλοντικές εκβάσεις [3]. Για παράδειγμα η κατανάλωση ενέργειας ενός μεγάλου βιομηχανικού φορτίου μπορεί να μειωθεί αισθητά αναμένοντας τις προβλεπόμενες αυξημένες τιμές ρεύματος στο κοντινό μέλλον ή μια εγκατάσταση αποθήκευσης ενέργειας μπαταριών ενδεχομένως να αποφασίσει να επαναφορτίσει γνωρίζοντας τις προβλεπόμενες χαμηλές τιμές ενέργειας λόγω της υψηλής παραγωγής αιολικής ενέργειας τη νύχτα και ηλιακής ενέργειας τη μέρα. Επομένως φαίνεται πως οι προβλέψεις είναι ικανές να εξοπλίσουν τους υπεύθυνους λήψης αποφάσεων με την ικανότητα αποφυγής πιθανών κινδύνων και επίτευξης ευνοϊκότερων αποτελεσμάτων [4].

Παράλληλα αναγκαία συνιστώσα για την πραγματοποίηση τους είναι τα ιστορικά δεδομένα τα οποία θα πρέπει να βρίσκονται σε μορφή χρονοσειρών. Τα δεδομένα χρονοσειρών είναι το αποτέλεσμα παρακολούθησης μιας συγκεκριμένης διαδικασίας σε βάθος μιας χρονικής περιόδου κατά την οποία λαμβάνονται δείγματα παρατήρησης με συγκεκριμένο δειγματοληπτικό ρυθμό δημιουργώντας μια ακολουθία τιμών που αντιστοιχούν σε διαδοχικά ισαπέχουσες χρονικές στιγμές [4]. Με την ανάπτυξη της εποχής των δεδομένων είναι προφανές ότι και τα δεδομένα χρονοσειρών έχουν σημειώσει σημαντική αύξηση και στην ποικιλία τους αλλά και στον ρυθμό παραγωγής τους. Στη καθημερινότητα, η παραγωγή τους έχει εξαπλωθεί σε διάφορους τομείς όπως γεωργία, οικονομία, μετεωρολογία, στρατό αλλά και στην ενέργεια [4].

Η διαδικασία της πρόβλεψης όμως διαφέρει ανάλογα το χρονικό ορίζοντα πρόβλεψης, δηλαδή το μελλοντικό διάστημα για το οποίο προετοιμάζεται μια πρόβλεψη και παράγει αποτελέσματα [3]. Ειδικότερα μπορεί να ταξινομηθεί σε βραχυπρόθεσμη, μεσοπρόθεσμη και μακροπρόθεσμη. Η βραχυπρόθεσμη πρόβλεψη αφορά το διάστημα της επόμενης ώρας έως και της επόμενης εβδομάδας και είναι σημαντική για διάφορους λειτουργικούς σκοπούς αλλά και ως δεδομένα για προβλέψεις μεγαλύτερων χρονικών οριζόντων. Η μεσοπρόθεσμη πρόβλεψη κυμαίνεται στον 1 μήνα έως και τα 5 χρόνια ενώ η μακροπρόθεσμη πρόβλεψη καλύπτει το διάστημα των 5 έως 20 επόμενων χρόνων και η σημασία τους έγκειται στην πολύτιμη γνώση που προσφέρουν σε μελλοντικό προγραμματισμό για την εκάστοτε χρονική περίοδο αντίστοιχα ενώ οι πληροφορίες που προκύπτουν από τις βραχυπρόθεσμες μπορούν να τις επηρεάσουν σημαντικά [5]. Ωστόσο αυτός ο ορισμός οριζόντων αλλάζει ανάλογα τη βιβλιογραφία. Συνολικά οι προβλέψεις οποιουδήποτε χρονικού ορίζοντα έχουν ολοένα και αυξανόμενες εφαρμογές σε διάφορους τομείς ένας εκ των οποίων είναι η ενέργεια και η ανάλυση τους παρακάτω θα αναδείξει την σημασία και την αναγκαιότητα τους.

1.1.2 Αντίκτυπος στην διαχείριση ενέργειας

Οι εταιρίες παροχής ηλεκτρικής ενέργειας έχοντας ως διαρκή στόχο την αξιόπιστη διανομή ηλεκτρικής ενέργειας στους καταναλωτές σε ανταγωνιστικό κόστος αντιμετωπίζουν ποικιλία προκλήσεων στην προσπάθεια διαχείρισης των δικτύων τους και οι προβλέψεις είναι ικανές να δώσουν λύση σε πολλές από αυτές.

Κύριο ζήτημα αποτελεί ο χρονοπρογραμματισμός κατανάλωσης, παραγωγής και διανομής ενέργειας που είναι ιδιαίτερης σημασίας για την αποφυγή ελλείψεων και πλεονασμάτων ενέργειας τα οποία αντιστοιχούν σε αναξιοπιστία δικτύου και αυξημένα κόστη αντίστοιχα. Η αυξανόμενη ενσωμάτωση ανανεώσιμων πηγών ενέργειας όπως αιολική και ηλιακή στα σύγχρονα δίκτυα ενέργειας εισάγει τυχαιές διακυμάνσεις στην παραγωγή οι οποίες συνδυαστικά με την αστάθεια που χαρακτηρίζει την καθημερινή

κατανάλωση καθιστούν τις ακριβείς βραχυπρόθεσμες προβλέψεις ανεκτίμητες καθώς οποιαδήποτε προσεγγιστική εκτίμηση της σύντομης μελλοντικής ροής ενός δικτύου μπορεί να αξιοποιηθεί για την σωστή ευθυγράμμιση της προσφοράς και της ζήτησης [6] [7].

Παράλληλα η ανάλυση ροής φορτίου είναι εξίσου σημαντική για την διαπίστωση της καλύτερης λειτουργίας των υπάρχοντων συστημάτων και περιλαμβάνει τον υπολογισμό της ροής της ηλεκτρικής ενέργειας καθ' όλο το δίκτυο. Μια βραχυπρόθεσμη ή μεσοπρόθεσμη πρόβλεψη μελλοντικής κατανάλωσης ή παραγωγής αντιστοιχεί σε ανάλογο φορτίο σε συγκεκριμένα σημεία του δικτύου διευκολύνοντας έτσι τους χειριστές του να καθορίσουν τις διαδρομές βέλτιστης ροής και τα επίπεδα τάσης σε διάφορα σημεία ώστε να αποφευχθούν υπερφορτίσεις, αστάθειες τάσης και διακοπές ρεύματος [6].

Εφόσον έχει διαπιστωθεί ότι οι υπάρχουσες υποδομές είναι επαρκείς για τη διαχείριση των προβλεπόμενων φορτίων επόμενη πρόκληση για την εξασφάλιση της αδιάκοπης και αξιόπιστης λειτουργίας τους είναι η συντήρηση τους. Σε αυτή τη περίπτωση φαίνεται ιδιαίτερα η σημασία και η συνεισφορά των μεσοπρόθεσμων προβλέψεων καθώς έχουν τη δυνατότητα να αναγνωρίσουν τάσεις ενεργειακής κατανάλωσης σε βάθος χρόνων με βάση οικονομικούς, δημογραφικούς και εποχικούς παράγοντες [7]. Κατά τη διάρκεια του φθινοπώρου ή της άνοιξης, που η κατανάλωση τείνει να είναι χαμηλότερη, εκμεταλλεύονται τα αποτελέσματα τους για να προγραμματίσουν διακοπές λειτουργίας για συντήρηση και οι σταθμοί ηλεκτροπαραγωγής που βασίζονται σε ορυκτά καύσιμα να εξασφαλίσουν τη προμήθεια και αποθήκευση τους διασφαλίζοντας έτσι ετοιμότητα για τις καλοκαιρινές και χειμερινές περιόδους που η κατανάλωση μεγιστοποιείται [5].

Η εξασφάλιση της σωστής και αποδοτικής λειτουργίας ενός δικτύου είναι αναγκαία για την κάλυψη των ποικίλων και αυξανόμενων απαιτήσεων του όσον αφορά το παρόν και το σύντομο μέλλον αλλά δεν διασφαλίζει τη θωράκιση του από παράγοντες όπως η αύξηση του πληθυσμού, η αστικοποίηση, η απανθρακοποίηση της ενέργειας και η επέκταση της βιομηχανίας. Αναδύεται έτσι η ανάγκη για μεθοδικό προγραμματισμό κυρίως επενδυτικού χαρακτήρα, όπως για παράδειγμα επέκταση δικτύων μεταφοράς και διανομής ενέργειας, μετάβαση σε ανανεώσιμες πηγές ενέργειας και δρομολόγηση αναβάθμισης συστημάτων αποθήκευσης ενέργειας, ώστε να καλυφθούν μελλοντικές

απαιτήσεις, η οποία εισάγει μεγάλο ρίσκο καθώς η οποιαδήποτε υποεπένδυση θα μπορούσε να οδηγήσει σε διακοπές ρεύματος και αστάθεια ενώ η υπερεπένδυση σε περιττό κόστος και αχρησιμοποίητους πόρους [3] [5]. Όπως οι μεσοπρόθεσμες έτσι και οι μακροπρόθεσμες προβλέψεις μπορούν να εξαλείψουν τις επιπτώσεις των τυχαίων διακυμάνσεων που προκύπτουν βραχυπρόθεσμα και να αναγνωρίσουν τάσεις ζήτησης και παραγωγής μεγάλης διάρκειας μειώνοντας τις μελλοντικές αβεβαιότητες και ενισχύοντας τις στρατηγικές για τη διαχείριση οικονομικών, περιβαλλοντικών και τεχνολογικών αλλαγών [7].

1.1.3 Εφαρμογές στη διαχείριση κτιρίων και στα έξυπνα δίκτυα

Λίγο πριν τη δεκαετία του 2000 το παραδοσιακό μέχρι τότε ενεργειακό δίκτυο αντιμετώπιζε σοβαρά προβλήματα. Οι ενεργειακές απαιτήσεις αυξάνονταν ολοένα και περισσότερο και η παραγωγή βασιζόμενη τότε κατά κύριο λόγο σε ορυκτά καύσιμα συνέβαλλε ιδιαιτέρως στις εκπομπές αερίων του θερμοκηπίου, ένα φαινόμενο το οποίο σε συνδυασμό με ακραία καιρικά συμβάντα φανέρωσαν τρωτά σημεία στο δίκτυο. Ταυτόχρονα η προσπάθεια ενσωμάτωσης ανανεώσιμων πηγών ενέργειας εισήγαγε μεταβλητότητα και αστάθεια στη παραγωγή και σε συνδυασμό με την ανικανότητα βελτιστοποίησης της ροής ενέργειας του δικτύου μετάδοσης και διανομής σε πραγματικό χρόνο οδήγησε σε διακοπές ενέργειας και γενική αναξιοπιστία [7] [8]. Επίσης η συνολική αρχιτεκτονική του δικτύου ήταν μονόδρομη με αφετηρία τα εργοστάσια παραγωγής ενέργειας και προορισμό τους καταναλωτές προσφέροντας τους μειωμένες ευκαιρίες να συμμετάσχουν στην διαχείριση ενέργειας [7]. Αυτά τα προβλήματα προετοίμασαν τις συνθήκες για τη διαμόρφωση της έννοιας του έξυπνου δικτύου το οποίο αποτελεί το μελλοντικό όραμα των συστημάτων ενέργειας. Η υλοποίηση του περιλαμβάνει τη χρήση της τεχνητής νοημοσύνης, των μεγάλων δεδομένων και του διαδικτύου των πραγμάτων και έχει ως σκοπό τη δημιουργία μιας σουίτας εφαρμογών που βασίζονται σε πληροφορίες προερχόμενες από τον αυτοματισμό του δικτύου η

οποία ενσωματώνει τη συμπεριφορά και τις δράσεις όλων των συνδεδεμένων προφίλ (σύνολο χαρακτηριστικών) παραγωγής και κατανάλωσης μέσω δυνατοτήτων αμφίδρομης επικοινωνίας για την βιώσιμη, οικονομική και ασφαλή τροφοδοσία ενέργειας [9] [10].

Τα έξυπνα δίκτυα αποτελούνται από 2 μέρη, τη πλευρά της παραγωγής και τη πλευρά της κατανάλωσης και η ροή ενέργειας που τις ενώνει πλέον είναι αμφίδρομη. Τα οικιακά κτίρια αντιστοιχούν περίπου στο 40% της συνολικής κατανάλωσης ενέργειας και οι καταναλωτές που είναι κομμάτι του δικτύου χωρίζονται σε 2 κατηγορίες: τους παραδοσιακούς καταναλωτές και τους παραγωγούς-καταναλωτές με τη δεύτερη κατηγορία να μεγαλώνει διαρκώς [8]. Έτσι λοιπόν η παρακολούθηση και η συνολική διαχείριση ενέργειας ενός κτιρίου είναι απαραίτητη και μπορεί να πραγματοποιηθεί μόνο στα έξυπνα κτίρια με ενσωματωμένους έξυπνους αισθητήρες καθιστώντας τα αναγκαία για τη πλευρά της κατανάλωσης. Αυτό ισχύει καθώς ακόμα και αν η παραγωγή είναι βελτιστοποιημένη η συνολική αποτελεσματικότητα του δικτύου θα μειωθεί αν δεν υπάρχει επαρκής παρακολούθηση της κατανάλωσης με τη σημασία της να πολλαπλασιάζεται όταν πρόκειται και για κτίριο που παράγει και καταναλώνει ενέργεια [7] [8] [10].

Ο καταναλωτής και ειδικότερα ο παραγωγός-καταναλωτής είναι πλέον το ενδιαφερόμενο μέλος για τον οποίο όλο το δίκτυο δημιουργήθηκε για να υποστηρίξει [11]. Λαμβάνοντας αυτό το δικό ρόλο όσο οι τιμές της ενέργειας αλλάζουν διαρκώς και οι βιώσιμες ενεργειακές πρακτικές πληθαίνουν είναι αναμενόμενο να χρειάζονται εργαλεία για την βελτιστοποίηση της ενεργειακής χρήσης του κτιρίου, τη μείωση των εξόδων και την μεγιστοποίηση του οφέλους από ανανεώσιμες πηγές, όπως ηλιακά πάνελ, οι οποίες προκαλούν δυσκολίες στον συγχρονισμό παραγωγής και κατανάλωσης [10] [11] [12]. Αυτά τα εργαλεία δεν θα μπορούσαν να προσφέρουν αυτές τις λειτουργίες αν δεν είχαν δεδομένα βραχυπρόθεσμων προβλέψεων ώστε να διαθέτουν γνώσεις για μελλοντικές περιόδους πιθανού ενεργειακού πλεονάσματος και ελλείματος [10] [13]. Επίσης αυτού του είδους προβλέψεις έχουν τη δυνατότητα να λάβουν υπόψη παράγοντες όπως ο καιρός και τα μοτίβα διαβίωσης (πόσα άτομα ζουν σε ένα σπίτι και πόσο χρόνο διαμένουν σε αυτό ανά μέρα) ρυθμίζοντας έτσι τη χρήση ενεργειακά αναποτελεσματικών συστημάτων όπως θέρμανση, εξαέρωση και κλιματισμό ελαχιστοποιώντας περαιτέρω τα λειτουργικά κόστη [10] [11].

Ταυτόχρονα η άνοδος των αποκεντροποιημένων ενεργειακών δικτύων και η διαρκής γνώση των τιμών της ενέργειας και του διαθέσιμου ενεργειακού πλεονάσματος μέσω προβλέψεων ωθεί τους παραγωγούς-καταναλωτές στην ανταλλαγή του τις κατάλληλες στιγμές στα πλαίσια τοπικών δικτύων με άλλους παραγωγούς-καταναλωτές δημιουργώντας ένα συνεργατικό ενεργειακό οικοσύστημα που προσφέρει οικονομικά οφέλη στους συμμετέχοντες και καλύτερη συνολική ισορροπία δικτύου [10] [13] [14].

Μια ισορροπία η οποία μπορεί εύκολα να χαθεί εάν δεν πραγματοποιηθεί επαρκής προγραμματισμός και προετοιμασία για τις αλλαγές στα μοτίβα κατανάλωσης εκτεταμένων χρονικών περιόδων. Η αποθήκευση της ενέργειας από τις ανανεώσιμες πηγές αποτελεί ένα τέτοιο ζήτημα και η χρονοδρομολόγηση της χρήσης μπαταριών για αυτό το σκοπό αντιδρώντας στις περιόδους αυξημένης κατανάλωσης και μειωμένης παραγωγής είναι απαραίτητη [10] [15]. Οι βραχυπρόθεσμες αλλά κυρίως οι μεσοπρόθεσμες προβλέψεις προσφέρουν άμεση λύση φανερώνοντας τις τάσεις της ενεργειακής συμπεριφοράς των ανανεώσιμων πηγών αλλά και του δικτύου γενικότερα ενημερώνοντας εγκαίρως τους διαχειριστές των κτιρίων για επικείμενες περιόδους υψηλής ζήτησης ενέργειας. Έτσι διασφαλίζεται ετοιμότητα και αποτελεσματικός προγραμματισμός αναγκαίας συντήρησης αλλά και στοχευμένης φόρτισης και εκφόρτισης με βάση τις ανάγκες του δικτύου, μειώνοντας και την εξάρτηση από την παραγωγή ενέργειας προερχόμενη από ορυκτά καύσιμα [11] [13]. Επίσης ένας παραγωγός-καταναλωτής πρέπει να είναι ενημερωμένος για τις μελλοντικές οικονομικές, περιβαλλοντικές και τεχνολογικές εξελίξεις ενώ πρέπει να προσαρμόζεται στις εξελισσόμενες ενεργειακές πολιτικές, στη δυναμική της αγοράς και στους στόχους βιωσιμότητας και απανθρακοποίησης ώστε να μεγιστοποιήσει τα οικονομικά και λειτουργικά οφέλη του. Αυτές οι γνώσεις πηγάζουν από πληροφορίες που δεν θα ήταν διαθέσιμες εάν δεν εφαρμόζονταν μακροπρόθεσμες προβλέψεις καθώς προσφέρουν μια στρατηγική οπτική των μελλοντικών εκτεταμένων τάσεων στην ενεργειακή κατανάλωση, παραγωγή αλλά και τιμή [10] [11] [13]. Για παράδειγμα με αυτό το τρόπο είναι εφικτά τα εξής: ο προγραμματισμός αναβάθμισης της ενεργειακής αποθήκευσης, η βελτιστοποίηση οικονομικού οφέλους από ενεργειακές συναλλαγές, η ασφαλέστερη επένδυση στην επέκταση της ανανεώσιμης ενεργειακής παραγωγής και η συνολικότερη ενίσχυση της

ανθεκτικότητας ενός έξυπνου κτιρίου σε αβεβαιότητες.

Ωστόσο τα οφέλη τους συνεχίζουν πέρα από την αποκεντρωμένη διαχείριση ενέργειας και μπορούν να γενικευτούν και στη πιο ολοκληρωμένη μορφή ενός έξυπνου δικτύου στο οποίο κύριο χαρακτηριστικό είναι η δυναμική προσαρμογή της κατανάλωσης και παραγωγής σε πραγματικό χρόνο [13]. Κύριος παράγοντας αυτής της σταθερότητας αποτελούν τα προγράμματα ανταπόκρισης στη ζήτηση (Demand Response Programs) που προσφέρουν στους συμμετέχοντες στο δίκτυο πληροφορίες για να ανιχνεύουν περιόδους μέγιστης κατανάλωσης και να ρυθμίζουν την ενεργειακή συμπεριφορά τους μέσω βραχυπρόθεσμων προβλέψεων για τη σταθεροποίηση του δικτύου σε πραγματικό χρόνο [13] [14] [16] [17]. Ταυτόχρονα χρησιμοποιούνται συστήματα βελτιστοποίησης τάσης επωφελούμενα από ίδιου είδους προβλέψεις με βάση τις οποίες πραγματοποιείται δυναμική προσαρμογή επιπέδων τάσης και μετριασμός ανισορροπιών συχνοτήτων σε περιόδους υψηλής δραστηριότητας [12] [16]. Επίσης τα δεδομένα προβλέψεων όλων των ειδών επιτρέπουν την ομαδοποίηση των ενεργειακών φορτίων του δικτύου ανάλογα την καταναλωτική συμπεριφορά τους, επιτρέποντας την εφαρμογή στοχευμένων στρατηγικών για εξισορρόπηση φορτίου και βελτίωση της απόδοσης [15]. Η ικανότητα ομαδοποίησης ενεργειακών φορτίων πέρα από τα προαναφερθέντα οφέλη θέτει και τις βάσεις για την αντιμετώπιση αναδυόμενων προκλήσεων, όπως η ενσωμάτωση των ηλεκτρικών οχημάτων στο δίκτυο που αναπόφευκτα θα το πιέσουν εάν δεν διαχειριστεί σωστά. Χρησιμοποιώντας δεδομένα βραχυπρόθεσμων και μεσοπρόθεσμων προβλέψεων είναι εφικτή η ανάλυση και ενσωμάτωση τους ως ξεχωριστές ενεργειακές ομάδες στις τοπικές στρατηγικές διαχείρισης ενέργειας βελτιστοποιώντας τη χρονοδρομολόγηση φορτίσεων και μετριάζοντας τη ενεργειακή συμφόρηση του δικτύου [12] [17].

Όμως η διατήρηση της διαθεσιμότητας τόσο σημαντικών υποδομών όπως τα έξυπνα δίκτυα και η ενσωμάτωση εξελιγμένων τεχνολογιών και επικοινωνιακών συστημάτων στη λειτουργία τους έχει αυξήσει την συνολική πολυπλοκότητα τους και έχει εισάγει ένα νέο εύρος πιθανών κινδύνων ασφαλείας στη μορφή σημείων ευάλωτων σε κυβερνοεπιθέσεις [16]. Αυτές οι αναδυόμενες απειλές στο κυβερνοχώρο μπορούν να παραποιήσουν δεδομένα αισθητήρων, να διακόψουν εξ' αποστάσεως τη λειτουργία βιομηχανικού εξοπλισμού και να τροποποιήσουν τις ρυθμίσεις των συστημάτων ελέγχου

φέροντας καταστροφικές συνέπειες όπως διακοπές λειτουργίας, μη διαθεσιμότητα υπηρεσιών και μείωση ακεραιότητας δεδομένων ελέγχου και επικοινωνίας [18]. Αναγκαία λοιπόν έχουν καταστεί τα προβλεπτικά μοντέλα και κυρίως αυτά που λειτουργούν αξιοποιώντας τη τεχνητή νοημοσύνη καθώς προσφέρουν μηχανισμούς πρόληψης και αντιμετώπισης τέτοιων επιθέσεων αλλά και θωράκισης ενάντια τους. Αναλύοντας ιστορικά δεδομένα από κυβερνοεπιθέσεις και ανωμαλίες δικτύου μπορούν να προβλέψουν τη πιθανότητα εμφάνισης τέτοιων φαινομένων σε πραγματικό χρόνο ενημερώνοντας τους διαχειριστές να αναλάβουν προληπτικά μέτρα όπως απομόνωση ευάλωτων συστημάτων από το συνολικό δίκτυο πριν προκύψει κάποια επίθεση [16] [17]. Αν τα προληπτικά τους μέτρα αποτύχουν τότε, βασιζόμενα σε προβλεπόμενες τάσεις κυβερνοεπιθέσεων, προετοιμάζουν σχέδια αντιμετώπισης συμβάντων (Incident Response) προσαρμοσμένα στα τρωτά σημεία του δικτύου [12] [17]. Παράλληλα ενισχύουν τους αδύναμους κρίκους του όπως οι συσκευές IoT (Internet of Things) προβλέποντας τα κενά ασφαλείας τους και αντιμετωπίζοντας τα εγκαίρως [14]. Έτσι εξασφαλίζεται η σταθερότητα και η αξιοπιστία του δικτύου αλλά αυξάνεται και η ασφάλεια και ανθεκτικότητα του ενάντια σε κακόβουλες δραστηριότητες.

Συνολικά, οι εφαρμογές των προβλέψεων στα έξυπνα δίκτυα είναι ποικίλες και επεκτείνονται, πέρα από τη διαχείριση φορτίου και την ενσωμάτωση των ανανεώσιμων πηγών ενέργειας, σε ανεπτυγμένους τομείς όπως η προγνωστική συντήρηση και ενημέρωση, η αποκεντροποιημένη ενεργειακή αγορά και η κυβερνοασφάλεια προσφέροντας καθοριστικές γνώσεις για τη διαρκή αποδοτικότητα, αξιοπιστία και προσαρμοστικότητα σε όλο και πιο πολύπλοκα ενεργειακά δίκτυα.

1.1.4 Προκλήσεις εκτέλεσης προβλέψεων

Ωστόσο, παρά τις διάφορες εξελίξεις, η ίδια η πρόβλεψη από μόνη της αντιμετωπίζει πλήθος προκλήσεων που εμποδίζουν την ακρίβεια και την χρησιμότητα της και πρέπει να αντιμετωπιστούν για την πλήρη αξιοποίηση της.

Ένα προβλεπτικό μοντέλο, είτε είναι στατιστικό είτε υποβοηθούμενο από τεχνητή νοημοσύνη, βασίζεται σε δεδομένα χρονοσειρών οπότε είναι λογικό οι προκλήσεις που συνοδεύουν τις προβλέψεις του να πηγάζουν από αυτά καθώς διαθέτουν τις πληροφορίες που απαιτούνται για να πραγματοποιηθούν σωστά. Αρχικά είναι απαραίτητο το πλήθος των δεδομένων να είναι επαρκές και ειδικά για αρκετά προβλεπτικά μοντέλα βαθιάς μάθησης η επάρκεια πληρείται όταν η ποσότητα διαθέσιμων δεδομένων είναι πολύ μεγάλη ώστε η χρονοσειρά να καλύπτει αρκετό χρόνο για να εμφανιστούν και να ανιχνευτούν πιθανά μοτίβα στο ιστορικό παρελθόν [19] [20]. Αυτό στα περισσότερα έξυπνα δίκτυα δεν αποτελεί πρόβλημα καθώς έχουν συλλεχθεί δεδομένα από την παρελθοντική λειτουργία τους, κάτι το οποίο όμως δεν ισχύει για τα καινούργια για τα οποία πρέπει να χρησιμοποιηθούν προβλέψεις για την ορθή λειτουργία τους. Ωστόσο τα δεδομένα ακόμα και αν είναι πολλά σε πλήθος αν δεν αντιπροσωπεύουν σωστά την ιστορική συμπεριφορά που πρέπει να αναγνωρίσει ένα μοντέλο δεν θα συνεισφέρουν σε μια σωστή πρόβλεψη [4] [19]. Η ποιότητα τους, επομένως, πρέπει να είναι υψηλή, πράγμα που είναι εξαιρετικά δύσκολο στα πραγματικά δεδομένα καθώς παράγονται από έξυπνους αισθητήρες, συστήματα αυτόματης απόκτησης δεδομένων και πειραματικές μεθόδους [4]. Επίσης διάφοροι παράγοντες, όπως η σταθερότητα και οι συνθήκες του εξοπλισμού που πραγματοποιεί τη συλλογή των δεδομένων, συχνά προκαλούν εσωτερικές ανωμαλίες στα δεδομένα, όπως θόρυβο, τιμές που λείπουν και ακραίες τιμές, οι οποίες επηρεάζουν σοβαρά την ακρίβεια της πρόβλεψης [21] [22]. Ακόμα και αν πληρούνται όμως αυτές οι προϋποθέσεις και τα ιστορικά δεδομένα χαρακτηρίζονται από επάρκεια και καλή ποιότητα υπάρχουν περιπτώσεις προβλέψεων που χρειάζονται επιπρόσθετες πληροφορίες που οφείλονται σε εξωγενείς παράγοντες [23]. Τέτοια παραδείγματα αποτελούν η συμβολή του καιρού και των περιβαλλοντικών συνθηκών στις προβλέψεις παραγωγής ενέργειας από ανανεώσιμες πηγές όπως αιολική και ηλιακή αλλά και των χαρακτηριστικών ενός κτιρίου και των ενεργειακών συνηθειών των κατοίκων του στην πρόβλεψη της ενεργειακής κατανάλωσης του [21] [23]. Παράλληλα σε πρακτικά σενάρια πρόβλεψης παρατηρείται ότι η ακρίβεια και η απόδοση του μοντέλου πρόβλεψης μειώνεται σταδιακά με τη πάροδο του χρόνου και ο κύριος λόγος είναι το χάσμα μεταξύ ιστορικών δεδομένων και δεδομένων σε πραγματικό χρόνο ενώ τα νέα δεδομένα δεν μαθαίνονται σταδιακά από το

προβλεπτικό μοντέλο ώστε να εφαρμοστούν στις μελλοντικές προβλέψεις του [4] [23].

Τα έξυπνα δίκτυα όμως συνέχεια εξελίσσονται και η επίτευξη ακριβών προβλέψεων σε ένα δίκτυο μικρής κλίμακας, από το οποίο προήλθαν τα ιστορικά δεδομένα, δεν αποτελεί μοναδικό στόχο ενός προβλεπτικού μοντέλου καθώς ενδεχομένως να μην έχει την δυνατότητα να αποδώσει το ίδιο σε ένα μεγαλύτερο και πιο σύνθετο δίκτυο [4] [24]. Ιδιαίτερη πρόκληση λοιπόν αποτελεί και η παραγωγή γενικευμένων και επεκτάσιμων προβλέψεων και ιδιαίτερα κατά την ενσωμάτωση μεγάλου αριθμού κατανεμημένων ενεργειακών πόρων ή τη διαχείριση πολλών μικρότερων δικτύων διασφαλίζοντας την γενικότερη και διευρυμένη αξιοποίηση των προβλεπτικών συστημάτων χωρίς να υφίσταται οποιαδήποτε αισθητή πτώση ακρίβειας και απόδοσης [4]. Επιπλέον η ανάγκη αξιοποίησης μεγάλων δεδομένων εισάγει νέες δυσκολίες. Ο ενεργειακός τομέας παράγει διαρκώς δεδομένα μεγάλου όγκου, ποικιλίας και μεταβλητότητας, τα οποία ενώ αφενός έχουν την δυνατότητα να εμπλουτίσουν την ακρίβεια προβλέψεων, απαιτούν αφετέρου ανεπτυγμένες υποδομές για την αποθήκευση, το διαμοιρασμό και την επεξεργασία σε πραγματικό χρόνο, κάτι που οι συμβατικές τεχνολογίες συχνά δεν μπορούν να διαχειριστούν αποτελεσματικά [24]. Τέτοια δεδομένα μεγάλου όγκου λόγω της δυναμικής και στοχαστικής φύσης τους παρουσιάζουν ξεχωριστή πολυπλοκότητα. Τα μοτίβα ενεργειακής κατανάλωσης επηρεάζονται από κοινωνικές και οικονομικές εξελίξεις, όπως η ένταξη ηλεκτρικών αυτοκινήτων και η ενσωμάτωση ανανεώσιμων πηγών στο δίκτυο, με αποτέλεσμα τα μοντέλα να μην έχουν τη δυνατότητα να τα ανιχνεύουν ενώ αλλάζουν τόσο δυναμικά [25]. Άλλη ένα σημαντικό ζήτημα αποτελεί και η χρονική περίοδο ανάμεσα σε διαδοχικά δείγματα δεδομένων μιας χρονοσειράς. Για παράδειγμα οι χρονοσειρές που έχουν μετρηθεί σε χρονικά διαστήματα 10 λεπτών ή 1 ώρας μπορούν ενδεχομένως να αυξήσουν την ακρίβεια βραχυπρόθεσμων προβλέψεων αλλά αυξάνουν τις υπολογιστικές απαιτήσεις για την επεξεργασία τους και τον κίνδυνο ένα μοντέλο να ανιχνεύσει το θόρυβο που προκαλούν λόγω της πυκνότητας τους παρά τις γνήσιες τάσεις και εποχικότητες που εμπεριέχουν [4]. Τέλος αξίζει να αναφερθεί πως η ποικιλία προβλεπτικών μοντέλων είναι μεγάλη και η επιλογή τους αποτελεί πρόκληση από μόνη της και πρέπει να γίνεται με γνώμονα το είδος επιθυμητής πρόβλεψης [20]. Για

παράδειγμα για μια βραχυπρόθεσμη πρόβλεψη είναι απαραίτητο το μοντέλο να μπορεί να ανιχνεύσει τις απότομες και συχνές διακυμάνσεις σε μια χρονοσειρά ενώ για μια μακροπρόθεσμη πρέπει να είναι ανθεκτικό έναντι του παραγόμενου θορύβου και να μην προσαρμοστεί υπερβολικά σε αυτό.

Συμπερασματικά λοιπόν, οι προβλέψεις και ιδιαίτερα η πρόβλεψη ενεργειακού φορτίου είναι κρίσιμο συστατικό της σύγχρονης διαχείρισης ενέργειας του οποίου η υλοποίηση είναι φυσικό και επακόλουθο να συνοδεύεται από διάφορες δυσκολίες. Όσο όμως τα έξυπνα δίκτυα εξελίσσονται εξαρτώμενα από ανανεώσιμες πηγές ενέργειας και η ενεργειακή δομή μεταβαίνει σε ολόένα και πιο αποκεντρωμένα πρότυπα, η ικανότητα πρόβλεψης με ακρίβεια και ευελιξία θα παραμείνει καθοριστική για τη διασφάλιση της σταθερότητας του δικτύου, της λειτουργικής απόδοσης και της βιώσιμης χρήσης ενέργειας.

1.2 Στόχοι της παρούσας μελέτης

Στη μελέτη που πραγματοποιήθηκε για την διεκπεραίωση της διπλωματικής εργασίας αναλύθηκε ο τομέας των προβλέψεων ενεργειακής κατανάλωσης καθώς αποτελεί αναπόσπαστο κομμάτι των σύγχρονων ενεργειακών συστημάτων και επηρεάζει την διαδικασία λήψης αποφάσεων στη συνολική διαχείριση ενός δικτύου [5]. Σε αυτόν τον τομέα σημαντική εξέλιξη έχουν σημειώσει τα μοντέλα βαθιάς μάθησης τα οποία έχουν αποδειχθεί χρήσιμα στην ανίχνευση χρονικών εξαρτήσεων ανάμεσα στα δεδομένα μιας χρονοσειράς και τα υβριδικά μοντέλα που προσφέρουν βελτιωμένες δυνατότητες εξαγωγής χαρακτηριστικών [26]. Επιπλέον αναλύονται διάφορες τεχνικές μεταφοράς μάθησης για την αντιμετώπιση προκλήσεων όπως η έλλειψη δεδομένων επιτρέποντας τη μεταφορά γνώσης και προβλεπτικής ικανότητας ενός μοντέλου ήδη εκπαιδευμένου σε κάποιο σχετικό σύνολο με επαρκή δεδομένα [27] [28]. Έτσι λοιπόν εδώ αξιολογείται η προβλεπτική απόδοση βασικών νευρωνικών δικτύων σε 3 σύνολα δεδομένων με αισθητή διαφορά εύρους τιμών, διακύμανσης και μεγέθους μεταξύ του και επιχειρείται η βελτίωση της μέσω

τεχνικών μεταφοράς μάθησης στα σύνολα που έχουν τα λιγότερα ενώ δίνεται ιδιαίτερη έμφαση στις δυνατότητες του σύνθετου μοντέλου Μετασχηματιστή Συγχώνευσης Χρόνου (Temporal Fusion Transformer – TFT) το οποίο έχει αποδειχθεί ότι έχει τη δυνατότητα να διαχειριστεί περίπλοκα χρονικά μοτίβα [29].

1.2.1 Αξιολόγηση βασικών νευρωνικών δικτύων

Αρχικά η διπλωματική ξεκινάει με την εκπαίδευση και αξιολόγηση της προβλεπτικής απόδοσης παραδοσιακών αρχιτεκτονικών βαθιάς μάθησης όπως το επαναλαμβανόμενο νευρωνικό δίκτυο (stacked RNN), το δίκτυο μακράς βραχύχρονης μνήμης (stacked LSTM), το συνελκτικό νευρωνικό δίκτυο (stacked CNN) και μια υβριδική αρχιτεκτονική που αποτελεί ένα στρατηγικό συνδυασμό των 2 τελευταίων (LSTM-CNN-Hybrid). Αυτά τα μοντέλα θεωρούνται θεμελιώδη στην ανάλυση χρονοσειρών κυρίως για την ικανότητα τους να ανιχνεύουν τις χρονικές εξαρτήσεις σε ακολουθίες και τις αλληλεπιδράσεις μεταξύ μεταβλητών. Για παράδειγμα τα μοντέλα LSTM και RNN διαπρέπουν στην αναγνώριση χρονικών μοτίβων ενώ τα CNN προσφέρουν αποτελεσματική εξαγωγή χαρακτηριστικών από δεδομένα με πολλές μεταβλητές [26].

Αναλύθηκε το σύνολο δεδομένων Genome-2 και επιλέχθηκαν 3 κτίρια από τα οποία σχηματίστηκαν 3 σύνολα δεδομένων που περιέχουν την ενεργειακή κατανάλωση του κτιρίου, διάφορα μεταδεδομένα του και μετεωρολογικά δεδομένα από την τοποθεσία του. Για την αποτελεσματική πρόβλεψη σε κάθε ένα από αυτά έγινε ξεχωριστή προσαρμογή των υπερπαραμέτρων των μοντέλων για να επιτευχθεί η καλύτερη απόδοση ενώ αξιολογήθηκαν σε προβλέψεις επόμενης μέρας, επόμενης εβδομάδας και επόμενου μήνα [26]. Τα αποτελέσματα εξυπηρετούν ως απόδειξη ενδεχομένων περιορισμών τους στην ανίχνευση σύνθετων αλληλεπιδράσεων των μεταβλητών σε μεγάλα χρονικά διαστήματα και ως βάση για την εξέταση πιο εξελιγμένων πρακτικών όπως η εφαρμογή τεχνικών μεταφοράς μάθησης και η αρχιτεκτονική του TFT.

1.2.2 Εφαρμογές τεχνικών μεταφοράς μάθησης

Τα 3 σύνολα δεδομένων αντιπροσωπεύουν κτίρια διαφορετικού μεγέθους που βρίσκονται σε διαφορετικές τοποθεσίες και παρουσιάζουν διαφορετική ενεργειακή συμπεριφορά ώστε τα δεδομένα μεταξύ τους να διαφέρουν αρκετά. Από αυτά επιλέχθηκαν τα δύο που παρουσιάζουν το περισσότερο θόρυβο και μειώθηκε ο συνολικός αριθμός δεδομένων τους για να προσομοιωθούν περιβάλλοντα με έλλειψη δεδομένων. Έτσι για κάθε μοντέλο υλοποιήθηκαν και εφαρμόστηκαν κάποιες βασικές τεχνικές μεταφοράς μάθησης για να αντιμετωπίσουν αυτό το πρόβλημα με σκοπό να εξεταστεί αν είναι εφικτή η αξιοποίηση της γνώσης που προέρχεται από το σύνολο με επαρκή δεδομένα για τις προβλέψεις στα άλλα δύο [27] [30]. Αυτές οι προσεγγίσεις είναι εξαιρετικά σημαντικές καθώς στοχεύουν στην γεφύρωση του χάσματος μεταξύ συνόλων δεδομένων με ελάχιστη ομοιότητα και στην ανίχνευση της δυνατότητας προσαρμογής της προβλεπτικής ικανότητας ενός μοντέλου στα διαφορετικά χαρακτηριστικά άλλων συνόλων δεδομένων με ελάχιστη έως μηδενική προκατάληψη (zero bias).

1.2.3 Εξέταση απόδοσης του μοντέλου μετασχηματιστή συγχώνευσης χρόνου (Temporal Fusion Transformer)

Το μοντέλο Μετασχηματιστή Συγχώνευσης Χρόνου (TFT) αποτελεί μια σύγχρονη αρχιτεκτονική αιχμής στην πρόβλεψη χρονοσειρών, ειδικά σχεδιασμένη ώστε να διαχειρίζεται δεδομένα με πολλές μεταβλητές και να ρυθμίζει δυναμικά μέσω μηχανισμών προσοχής την σημασία των χαρακτηριστικών των δεδομένων εισόδου του [29]. Σε αυτήν την εργασία υλοποιήθηκε το μοντέλο TFT και διερευνήθηκε η απόδοση του στους ίδιους ορίζοντες πρόβλεψης με τα παραδοσιακά μοντέλα ενώ εφαρμόστηκαν και ορισμένες, προσαρμοσμένες σε αυτό, τεχνικές μεταφοράς μάθησης για επιπλέον βελτίωση των προβλέψεων του.

1.2.4 Δομή της διπλωματικής εργασίας

Η παρούσα διπλωματική εργασία ακολουθεί την εξής δομή:

Κεφάλαιο 1 : Εισαγωγή

Το κεφάλαιο αυτό ανέλυσε την ανάγκη ακρίβειας στις προβλέψεις ενεργειακού φορτίου αναδεικνύοντας τη σημασία τους για τους διαχειριστές ενεργειακών δικτύων αλλά και τους καταναλωτές. Επίσης επεξήγησε τις εφαρμογές τους στην εύρυθμη λειτουργία έξυπνων κτιρίων, ανέφερε συχνές προκλήσεις που συνοδεύουν τη διεξαγωγή τους και έθεσε τους στόχους της εργασίας αυτής.

Κεφάλαιο 2 : Θεωρητικό υπόβαθρο και βιβλιογραφική ανασκόπηση

Το κεφάλαιο 2 παρέχει μια ιστορική ανασκόπηση των μεθόδων διεξαγωγής προβλέψεων από τις παραδοσιακές στατιστικές μεθόδους έως και την ενσωμάτωση προσεγγίσεων τεχνητής νοημοσύνης (AI), μηχανικής μάθησης (ML) και της βαθιάς μάθησης (DL). Αναλύει την σύσταση διάφορων νευρωνικών δικτύων, συμπεριλαμβάνοντας αναλυτικά τις αρχιτεκτονικές τους, ενώ επεξηγεί τις μετρικές αξιολόγησής που χρησιμοποιήθηκαν. Επίσης περιγράφει την γενικότερη ανάπτυξη των τεχνικών μεταφοράς μάθησης ως μέσο αντιμετώπισης των προκλήσεων που προκύπτουν από την έλλειψη δεδομένων. Συνολικά παρέχει τα θεμέλια για την σωστή κατανόηση των πλεονεκτημάτων και περιορισμών των διαφόρων δικτύων αλλά και προσεγγίσεων μεταφοράς γνώσης πριν περιγραφεί η διεξαγωγή των πειραμάτων που τα εμπεριέχουν.

Κεφάλαιο 3 : Μεθοδολογία πειραμάτων πρόβλεψης

Το κεφάλαιο 3 αναλύει το πείραμα που διεξάχθηκε από την αρχική επιλογή των δεδομένων για όλους τους τομείς έως και την τελική συλλογή των αποτελεσμάτων των προβλέψεων. Περιλαμβάνει την συλλογιστική πορεία που

ακολουθήθηκε για την επιλογή των δεδομένων και των χαρακτηριστικών εισόδου τους όπως και τη σχετική προεπεξεργασία τους πριν την αξιοποίηση τους για τις προβλέψεις. Επίσης περιγράφεται ο τρόπος υλοποίησης των μοντέλων που αξιοποιήθηκαν και των υπερπαραμέτρων που περιέχουν ενώ επεξηγείται η διαδικασία επιλογής και εφαρμογής των τεχνικών μεταφοράς μάθησης για τη βελτίωση των προβλέψεων. Τέλος αναλύεται και το συνολικό πλαίσιο εκπαίδευσης και συλλογής αποτελεσμάτων στις προβλέψεις.

Κεφάλαιο 4 : Σύγκριση και αξιολόγηση αποτελεσμάτων

Το κεφάλαιο 4 αναπαριστά τα αποτελέσματα της απόδοσης των προβλέψεων ξεχωριστά για κάθε μοντέλο αλλά και συγκριτικά μεταξύ τους. Συνολικά περιλαμβάνει διεξοδική ανάλυση της ακρίβειας του κάθε μοντέλου, η οποία συνοδεύεται από σχετικές μετρικές και οπτικοποιήσεις αποτελεσμάτων, ενώ παρουσιάζεται το μοντέλο με τη καλύτερη απόδοση στην πρόβλεψη ενεργειακού φορτίου κάθε κτιρίου ανά κάθε χρονικό ορίζοντα.

Κεφάλαιο 2

Θεωρητικό υπόβαθρο και βιβλιογραφική ανασκόπηση

2.1 Η ιστορική εξέλιξη και θεωρητική ανασκόπηση των μοντέλων πρόβλεψης

Η ανάλυση χρονοσειρών έχει πολύ σημαντικό ρόλο στον ενεργειακό τομέα καθώς περιλαμβάνει την κατανόηση μοτίβων και τάσεων στα ιστορικά δεδομένα με σκοπό να επηρεαστούν θετικά οι μελλοντικές αποφάσεις. Αποτελεί αντικείμενο έρευνας πολλά χρόνια με αποτέλεσμα να έχει εξελιχθεί από τη χρήση θεμελιωδών στατιστικών μοντέλων, που αξιοποιούσαν τις γραμμικές σχέσεις ανάμεσα στα ιστορικά δεδομένα, στην υιοθέτηση μοντέλων μηχανικής μάθησης τα οποία μπορούν να διαχειριστούν και μη γραμμικές σχέσεις και τέλος στην ενσωμάτωση και των νευρωνικών δικτύων που αποδείχθηκαν ιδιαίτερα αποτελεσματικά στην διαχείριση πολύ σύνθετων συνόλων δεδομένων και εξωγενών παραγόντων. Αυτή η ενότητα θα περιγράψει την ιστορική εξέλιξη των μοντέλων αυτών και θα αναλύσει το θεωρητικό υπόβαθρο τους, τους περιορισμούς τους αλλά και τις εφαρμογές τους στην πρόβλεψη φορτίου.

2.1.1 Βασικά στατιστικά μοντέλα πρόβλεψης

Όπως προαναφέρθηκε οι θεμελιώδεις μέθοδοι για την πρόβλεψη μιας χρονοσειράς είναι βασισμένοι στη στατιστική και έχουν επιφέρει καλά αποτελέσματα σε διάφορους τομείς όπως η μετεωρολογία και η οικονομία [4]. Η χρήση τους όμως εξαρτάται από ένα κύριο χαρακτηριστικό σε μια

χρονοσειρά, τη στασιμότητα. Μια χρονοσειρά θεωρείται μια στοχαστική διαδικασία και αυτή η διαδικασία ονομάζεται στάσιμη όταν η άνευ όρων κοινή κατανομή πιθανοτήτων ενός αριθμού παρατηρήσεων που λήφθηκαν σε ορισμένες χρονικές στιγμές δεν αλλάζει όταν μετατοπίζεται χρονικά [31].

Μαθηματικά εκφράζεται ως :

$$F_X(x_{t_1+\tau}, \dots, x_{t_n+\tau}) = F_X(x_{t_1}, \dots, x_{t_n}) \text{ για όλα τα } \tau, t_1, \dots, t_n \in \mathbb{R} \text{ και } n \in \mathbb{N}_{>0}$$

όπου :

- X_t : Η στοχαστική διαδικασία (χρονοσειρά)
- $F_X(x_{t_1+\tau}, \dots, x_{t_n+\tau})$: Η αθροιστική συνάρτηση κατανομής της άνευ όρων (δηλαδή, χωρίς αναφορά σε κάποια συγκεκριμένη αρχική τιμή) κοινής κατανομής της $\{X_t\}$ τις στιγμές $t_1 + \tau, \dots, t_n + \tau$.

Κατά συνέπεια, μια στάσιμη χρονοσειρά δεν έχει τάση καθώς παράμετροι όπως ο μέσος όρος, η διακύμανση και τα χαρακτηριστικά αυτοσυσχέτισης δεν αλλάζουν με την πάροδο του χρόνου.

Πρόβλεψη σε στάσιμα δεδομένα

Για τη πρόβλεψη λοιπόν στάσιμων χρονοσειρών, πρώτος ο Yule εισήγαγε την έννοια της τυχειότητας σε μια χρονοσειρά και θεώρησε κάθε χρονοσειρά ως μια τυχαία διαδικασία προτείνοντας το αυτοπαλίνδρομο μοντέλο {Autoregressive model (AR)} [32]. Αυτό το μοντέλο βασίζεται στην ιδέα ότι η τρέχουσα τιμή μιας χρονοσειράς $\{X_t\}$, μπορεί να υπολογιστεί ως ένας γραμμικός συνδυασμός των p προηγούμενων τιμών, $x_{t-1}, \dots, x_{t-p}$, μαζί με ένα σφάλμα [31] [33]. Το μοντέλο AR τάξης p έχει τη μορφή :

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + w_t = \sum_{i=1}^p \varphi_i X_{t-i} + w_t$$

Όπου :

- X_t : Η παρατηρούμενη τιμή της στάσιμης χρονοσειράς τη στιγμή t
- w_t : Το σφάλμα (λευκός θόρυβος) τη στιγμή t

- φ_i : Ο συντελεστής αυτοπαλινδρόμησης για τη καθυστερημένη τιμή της χρονοσειράς (X_{t-i})

Ενώ τα AR μοντέλα εστίαζαν στη χρήση παρελθοντικών τιμών για την εύρεση της τρέχουσας τιμής, την ίδια περίπου περίοδο ο Slutsky πρότεινε το μοντέλο κινούμενου μέσου (MA) δίνοντας έμφαση περισσότερο στα σφάλματα παρελθοντικών προβλέψεων [34]. Συγκεκριμένα το μοντέλο MA προβλέπει μελλοντικές τιμές χρησιμοποιώντας παρελθοντικά λάθη προβλέψεων [31] [34]. Η μαθηματική έκφραση του μοντέλου MA τάξης q είναι η ακόλουθη :

$$X_t = \mu + w_t + \theta_1 w_{t-1} + \theta_2 w_{t-2} + \dots + \theta_n w_{t-q} = \sum_{i=1}^q \theta_i w_{t-i} + \mu + w_t$$

όπου:

- X_t : Η παρατηρούμενη τιμή της στάσιμης χρονοσειράς τη στιγμή t
- μ : Η μέση τιμή της χρονοσειράς
- w_t : Το σφάλμα (λευκός θόρυβος) τη στιγμή t
- θ_i : Ο συντελεστής κινούμενου μέσου για το καθυστερημένο σφάλμα πρόβλεψης (w_{t-i})

Έπειτα ο Wold παρουσίασε το διάσημο του θεώρημα «Wold Decomposition Theorem» που αναφέρει ότι μια στάσιμη χρονοσειρά μπορεί να εκφραστεί ως το άθροισμα 2 συνιστωσών [35]:

- Μια καθαρά ντετερμινιστική συνιστώσα (για παράδειγμα ένα γραμμικό μοτίβο)
- Μια στοχαστική συνιστώσα αναπαριστάμενη ως μια διαδικασία κινούμενου μέσου όρου άπειρης τάξης

Έτσι οι απόψεις του υποστήριζαν την σημασία των γραμμικών σχέσεων μεταξύ δεδομένων, στις οποίες εστιάζει το μοντέλο AR, και την ικανότητα του μοντέλου MA να καταγράψει τις εξαρτήσεις μιας χρονοσειράς αξιοποιώντας τα προηγούμενα σφάλματα πρόβλεψης καθιστώντας τα θεμελιώδη εργαλεία για την ανάλυση και πρόβλεψη στάσιμων χρονοσειρών. Ταυτόχρονα έθεσαν τις

βάσεις για την έρευνα στις προβλέψεις χρονοσειρών καθώς οι Box και Jenkins βασίστηκαν σε αυτά και πρότειναν το ευρέως διαδεδομένο αυτοπαλίνδρομο μοντέλο κινητού μέσου (ARMA) [36]. Αυτό ενσωματώνει τα 2 προηγούμενα μοντέλα και έπειτα από προ-επεξεργασία της χρονοσειράς, αφαιρώντας τη σταθερή μέση τιμή της από όλες τις τιμές της ($X'_t = X_t - \mu$), περιγράφεται ως εξής:

$$X_t = \sum_{i=1}^p \varphi_i X_{t-i} + \sum_{j=1}^q \theta_j w_{t-j} + w_t$$

όπου:

- p : Η τάξη των αυτοπαλίνδρομων όρων
- q : Η τάξη των όρων κινητού μέσου

Το ARMA έχει σημειώσει μεγάλα επιτεύγματα στην πρόβλεψη των στάσιμων χρονοσειρών. Όμως τα δεδομένα χρονοσειρών πραγματικού χρόνου δεν είναι σχεδόν ποτέ αμιγώς στάσιμα με αποτέλεσμα να διαθέτει χαμηλή ευελιξία και η εφαρμογή του να περιορίζεται από τα χαρακτηριστικά των δεδομένων [4] [31].

Πρόβλεψη σε μη στάσιμα δεδομένα

Στον πραγματικό κόσμο τα δεδομένα εμφανίζουν τάση, εποχικότητα ή περιοδικότητα σε κάποιο βαθμό και κατ' επέκταση θεωρούνται μη στάσιμα. Ωστόσο παρατηρήθηκε ότι αν αφαιρεθεί το τοπικό επίπεδο (μέσος όρος χρονοσειράς σε μια δεδομένη χρονική στιγμή) ή η τάση από μια μη στάσιμη χρονοσειρά τότε παρουσιάζει ομοιογένεια και στάσιμη συμπεριφορά [4]. Η μετάβαση αυτή από μη στασιμότητα σε στασιμότητα είναι εφικτή μέσω διαφοροποίησης ($X'_t = X_t - X_{t-1}$). Έτσι οι Box και Jenkins, εκτός από το μοντέλο ARMA, πρότειναν και μια εκδοχή του που ενσωματώνει ένα στοιχείο διαφοροποίησης για να μπορεί να διαχειριστεί και μη στάσιμες χρονοσειρές, το αυτοπαλίνδρομο ολοκληρωμένο μοντέλου κινητού μέσου (ARIMA) [36]. Η έκφραση του μοντέλου ARIMA(p,d,q) είναι η εξής:

$$\Delta^d X_t = \sum_{i=1}^p \varphi_i \Delta^d X_{t-i} + \sum_{j=1}^q \theta_j w_{t-j} + w_t$$

όπου:

- $\Delta^d X_t = X_t - X_{t-d}$: Η χρονοσειρά έπεται από d διαφοροποιήσεις
- p : Η τάξη των αυτοπαλινδρομων όρων
- q : Η τάξη των όρων κινητού μέσου
- d : Η τάξη διαφοροποίησης ώστε να γίνει η χρονοσειρά στάσιμη

Αν $d=0$ τότε το μοντέλο είναι ισοδύναμο με το μοντέλο ARMA και η χρονοσειρά είναι στάσιμη ενώ αν $d>0$ τότε εκτελούνται d βήματα διαφοροποίησης μέχρι η χρονοσειρά να γίνει στάσιμη και η πρόβλεψη εκτελείται με τη συνδυαστική χρήση των μοντέλων AR και MA. Το μοντέλο ARIMA όμως έχει επιτύχει καλά αποτελέσματα μόνο στις προβλέψεις χρονοσειρών σχετικά απλών δεδομένων [4]. Για δεδομένα τα οποία όμως εμφανίζουν εποχικότητα προτάθηκε μια επέκταση του μοντέλου ARIMA, το εποχικό αυτοπαλινδρομο ολοκληρωμένο μοντέλο κινούμενου μέσου (SARIMA), που προσθέτει εποχική διαφοροποίηση, εποχικούς αυτοπαλινδρομους συντελεστές και εποχικούς συντελεστές κινητού μέσου [37]. Ένα μοντέλο SARIMA(p,d,q)(P,D,Q,s) έχει τη μορφή :

$$\Delta^d \Delta_s^D X_t = \sum_{i=1}^p \varphi_i \Delta^d \Delta_s^D X_{t-i} + \sum_{j=1}^q \theta_j w_{t-j} + \sum_{k=1}^P \Phi_k \Delta^d \Delta_s^D X_{t-ks} + \sum_{m=1}^Q \theta_m w_{t-ms} + w_t$$

όπου:

- $\Delta^d \Delta_s^D X_t = \Delta^d (1 - L^s)^D X_t$: Η χρονοσειρά έπεται από D εποχικές διαφοροποιήσεις με s εποχική περίοδο και d απλές διαφοροποιήσεις.
- L^k : Ο τελεστής καθυστέρησης για μετατόπιση k χρονικών βημάτων προς τα πίσω
- Φ_k : Εποχικοί συντελεστές αυτοπαλινδρόμησης για τη καθυστερημένη διαφοροποιημένη (εποχικά και μη) τιμή της χρονοσειράς ($\Delta^d \Delta_s^D X_{t-ks}$)
- θ_m : Εποχικοί συντελεστές κινητού μέσου για το εποχικό καθυστερημένο σφάλμα πρόβλεψης (w_{t-ms})
- P : Η τάξη των εποχικών αυτοπαλινδρομων όρων
- Q : Η τάξη των εποχικών όρων κινητού μέσου

Οι μη εποχικοί όροι μένουν ίδιοι με το μοντέλο ARIMA. Συνδυάζοντας λοιπόν όλα τα προηγούμενα μοντέλα και προσθέτοντας κάποια επιπλέον χαρακτηριστικά το μοντέλο SARIMA αποδείχθηκε ένα ευέλικτο και οικονομικό μοντέλο πρόβλεψης που είναι ικανό να διαχειριστεί μη στάσιμες χρονοσειρές με εποχικότητα.

Πρόβλεψη με συνυπολογισμό εξωγενών παραγόντων

Ωστόσο στον πραγματικό κόσμο πολλές φορές υπάρχουν αρκετές εξωτερικές μεταβλητές που επηρεάζουν μια πρόβλεψη και οφείλονται σε εξωγενείς παράγοντες όπως ο καιρός και η ώρα. Για την μαθηματική απεικόνιση αυτών των σχέσεων εφαρμόζεται παλινδρομη ανάλυση (Regression Analysis) η οποία επιτρέπει την πρόβλεψη των αλλαγών μιας εξαρτημένης μεταβλητής μέσω άλλων ανεξάρτητων και καθορίζει την συμβολή κάθε μιας ανεξάρτητης μεταβλητής στην εξήγηση της εξαρτημένης [38]. Συγκεκριμένα ένας αλγόριθμος γραμμικής παλινδρόμησης αναζητά σχέσεις μεταξύ εξαρτημένων και ανεξάρτητων μεταβλητών ώστε να τις εκμεταλλευτεί και να προβλέψει τις μελλοντικές τιμές της εξαρτημένης βάση αυτών και χωρίζεται σε μονομεταβλητή και πολυμεταβλητή. Στην απλή γραμμική παλινδρόμηση (SLR) υπάρχει μόνο μια σταθερή μεταβλητή και εκφράζεται ως εξής:

$$y = a + bx + \varepsilon$$

όπου :

- y : Η εξαρτημένη μεταβλητή
- a : Ο σταθερός όρος
- b : Ο συντελεστής της ανεξάρτητης μεταβλητής
- x : Η ανεξάρτητη μεταβλητή
- ε : Ο όρος του σφάλματος

Όσο αυξάνονται οι ανεξάρτητες μεταβλητές το μοντέλο της πολλαπλής γραμμικής παλινδρόμησης (MLR) είναι αυτό που εκφράζει τη σχέση τους με την εξαρτημένη μεταβλητή ως εξής :

$$y = a + b_1x_1 + b_2x_2 + \dots + b_nx_n + \varepsilon$$

όπου:

- y : Η εξαρτημένη μεταβλητή
- a : Ο σταθερός όρος
- b_i : Ο συντελεστής της ανεξάρτητης μεταβλητής i
- x_i : Η ανεξάρτητη μεταβλητή i
- ε : Ο όρος τους σφάλματος

Ωστόσο παρά της χρησιμότητας που παρουσιάζει λόγω της απλότητας του σαν μοντέλο είναι και η αιτία για διάφορους περιορισμούς που ετοίμασαν το έδαφος για την πρόταση μεταγενέστερων μοντέλων βασιζόμενων σε αυτό. Για παράδειγμα η πολυσυγγραμικότητα, δηλαδή η υψηλή συσχέτιση μεταξύ 2 ή περισσότερων ανεξάρτητων μεταβλητών που είχε ως αποτέλεσμα την ακανόνιστη μεταβολή των συντελεστών τους όταν συνέβαιναν μικρές αλλαγές στο μοντέλο ή τα δεδομένα, ήταν η αιτία για την ενσωμάτωση των κανονικοποιήσεων L^1 (απόσταση Μανχάταν) και L^2 (ευκλείδεια κανονικοποίηση) στο μοντέλο MLR δημιουργώντας το παλίνδρομο μοντέλο τελεστή ελάχιστης απόλυτης συρρίκνωσης και επιλογής (LASSO Regressor model) και το παλίνδρομο μοντέλο κορυφογραμμής (Ridge Regressor model) αντίστοιχα [38] [39]. Παράλληλα στοχεύοντας στην επίτευξη της στοιχειώδους απεικόνισης μη γραμμικών σχέσεων μεταξύ των ανεξάρτητων μεταβλητών και της εξαρτημένης προτάθηκε το μοντέλο πολυωνυμικής παλινδρόμησης (Polynomial Regression) που αντικαθιστά τις ανεξάρτητες μεταβλητές με πολυωνυμικούς όρους [40].

Αυτά τα στατιστικά μοντέλα αποτέλεσαν θεμελιώδη εργαλεία για την ανάλυση χρονοσειρών προσφέροντας μεθόδους για την ανίχνευση τάσεων, εποχικότητας αλλά και σχέσεων με εξωγενείς παράγοντες στα δεδομένα. Ωστόσο η ολοένα αυξανόμενη πολυπλοκότητα και μη γραμμικότητα στα δεδομένα σε συνδυασμό με την ανακάλυψη εξαρτήσεων υψηλότερης τάξης σε αυτά φανερώνουν ορισμένους περιορισμούς που χαρακτηρίζουν αυτά τα μοντέλα με αποτέλεσμα η ανάγκη για χρήση νέων μεθόδων να γίνεται πιο εμφανής.

2.1.2 Ενσωμάτωση της μηχανικής μάθησης στην διαδικασία της πρόβλεψης

Η μετάβαση από τα παραδοσιακά στατιστικά μοντέλα σε μοντέλα που βασίζονται στην τεχνητή νοημοσύνη δεν συνέβη άμεσα. Η χρήση τους περιοριζόταν σε βραχυπρόθεσμες προβλέψεις χρονοσειρών με κυρίως στάσιμα και γραμμικά δεδομένα και όσο αυξανόταν η πολυπλοκότητα τους τα μοντέλα άρχισαν να έχουν μειωμένη απόδοση. Έτσι λοιπόν η έρευνα στράφηκε στην εξερεύνηση προσεγγίσεων τεχνητής νοημοσύνης και μηχανικής μάθησης που σηματοδότησε την αρχή μιας νέας εποχής στην πρόβλεψη χρονοσειρών [41] [42].

Η ανάπτυξη της τεχνητής νοημοσύνης

Ο όρος της τεχνητής νοημοσύνης δεν είχε ποτέ ξεκάθαρη ερμηνεία, καθώς μεταβαλλόταν από εποχή σε εποχή. Η κεντρική ιδέα, όμως, έχει παραμείνει ίδια και μπορεί να εντοπιστεί πίσω στο 1950 όπου ο Alan Turing έθεσε την ερώτηση «Μπορούν να σκεφτούν οι μηχανές ;». Τότε πρότεινε και το πασίγνωστο παιχνίδι της μίμησης (Imitation Game) σύμφωνα με το οποίο υποστήριξε ότι εάν μια μηχανή μπορεί να μιμηθεί αρκετά πειστικά ανθρώπινες αντιδράσεις τότε μπορεί να θεωρηθεί ότι είναι ικανή να σκέφτεται [43]. Αυτό έθεσε τα φιλοσοφικά θεμέλια ώστε να θεωρηθεί η ικανότητα υπολογισμού ως μέσο μίμησης ανθρώπινων νοητικών διαδικασιών. Στη συνέχεια το 1956 η θεωρία αυτομάτων (Automata Theory) και η θεωρία σύνθετης επεξεργασίας της πληροφορίας (Complex information processing Theory) ανέπτυξαν περαιτέρω συλλογιστικές που αφορούν «μηχανές που σκέφτονται» [44]. Συγκεκριμένα η θεωρία των αυτομάτων δομήθηκε μέσω συλλογής διαφόρων σχετικών ερευνών στον τομέα από τους Shannon and McCarthy και περιέγραψε με μαθηματικό τρόπο το σχεδιασμό συστημάτων ικανών να επεξεργαστούν πληροφορίες συνδέοντας τη θεωρία με τη πράξη [45]. Παράλληλα η θεωρία επεξεργασίας της πληροφορίας παρουσιάστηκε από τον Newel και Simon το 1956 και αφορά μια απλοποιημένη επιστημονική έκφραση που συγκρίνει τις λειτουργίες του ανθρώπινου μυαλού με αυτές ενός υπολογιστή παρομοιάζοντας την ανθρώπινη επεξεργασία πληροφορίας με μια ακολουθία σταδίων που μπορούν να μοντελοποιηθούν σε

ένα υπολογιστικό σύστημα [46]. Αυτές λοιπόν έθεσαν τα θεμέλια για τη δημιουργία ευφύων συστημάτων ικανών να επεξεργάζονται αυτόνομα πληροφορίες και να λαμβάνουν αποφάσεις, πράγμα το οποίο τυπικά απαιτεί ανθρώπινη νοημοσύνη.

Τα πρώτα συστήματα τεχνητής νοημοσύνης ενσωμάτωσαν συμβολικό συλλογισμό και μεθοδολογίες που βασιζόνταν σε κανόνες για την αντιμετώπιση προβλημάτων που ήταν σαφώς ορισμένα [44] [47]. Ονομάζονται συστήματα συμβολικής τεχνητής νοημοσύνης (Symbolic AI systems) και η ουσία τους βασίζεται στη λογική και στη προσομοίωση δομημένης νοημοσύνης αντλώντας πληροφορίες από προκαθορισμένες βάσεις γνώσεων [44]. Ωστόσο οι περιορισμοί αυτών των συστημάτων έγιναν εμφανείς, ιδιαίτερα όταν βρίσκονται αντιμέτωπα με μη ντετερμινιστικά προβλήματα για τα οποία οι προκαθορισμένοι κανόνες δεν είναι επαρκώς ευέλικτοι για να τα διαχειριστούν. Με τη πάροδο του χρόνου η εξέλιξη αυτών των συστημάτων σε συνδυασμό με την ενσωμάτωση των στατιστικών μεθόδων σήμαναν μια σημαντική στροφή προς την εξερεύνηση προσεγγίσεων που βασιζονται ενεργά στα δεδομένα οδηγώντας στον σχηματισμό της έννοιας της μηχανικής μάθησης (Machine Learning) [44] [48].

Μηχανική Μάθηση (ML) : Ανακάλυψη μοτίβων μέσα από δεδομένα

Η μηχανική μάθηση αποτελεί μια πρακτική που επιτρέπει στα συστήματα να μαθαίνουν και να βελτιώνονται από τα δεδομένα που επεξεργάζονται χωρίς να επεμβαίνει κάποιος άνθρωπος [44]. Σε αντίθεση με τη συμβολική τεχνητή νοημοσύνη, τα συστήματα μηχανικής μάθησης εκμεταλλεύονται ιστορικά δεδομένα μαζί με οποιαδήποτε μοτίβα εμπεριέχουν και αντί για κανόνες βασίζονται σε αλγορίθμους για να τα ανακαλύψουν, καθιστώντας τα αποτελεσματικά για να λύσουν μη-ντετερμινιστικά σύνθετα προβλήματα όπως η πρόβλεψη χρονοσειρών [47].

Τα πρώτα μοντέλα μηχανικής μάθησης βασίστηκαν σε τεχνικές όπως η γραμμική παλινδρόμηση και τα δέντρα αποφάσεων. Η γραμμική παλινδρόμηση όπως έχει αναφερθεί ήδη ήταν αποτελεσματική όσον αφορά απλά προβλήματα πρόβλεψης χρονοσειρών αλλά είχε αρκετούς περιορισμούς στην διαχείριση μη γραμμικών σχέσεων στα δεδομένα και οι δυσκολίες

αυξάνονταν όσο τα σύνολα γινόντουσαν πιο σύνθετα. Ταυτόχρονα τα δέντρα αποφάσεων αποτέλεσαν το 1960 άλλη μια θεμελιώδη μέθοδο μηχανικής μάθησης που αναπτύχθηκε λόγω της ανάγκης ερμηνεύσιμων μοντέλων για προβλήματα ταξινόμησης και βελτιστοποίησης. Αξιοποιεί τη δομή δέντρου για να αναπαραστήσει συγκεκριμένες αποφάσεις μαζί με ότι αποτελέσματα προκύψουν. Για τη πρόβλεψη χρονοσειρών που αποτελεί ένα πρόβλημα βελτιστοποίησης αξιοποιήθηκε το δέντρο παλινδρόμησης σύμφωνα με το οποίο πραγματοποιείται αναδρομική κατάτμηση των δεδομένων με βάση τις μεταβλητές χαρακτηριστικών της χρονοσειράς ώστε να ελαχιστοποιηθεί η διακύμανση σε κάθε υποσύνολο που προκύπτει [47] [49]. Προσφέρουν ερμηνευσιμότητα και μέσω των εφαρμογών τους παρουσίασαν ιδιαίτερη ικανότητα στη διαχείριση της μη-γραμμικότητας και στην επιλογή σχετικών χαρακτηριστικών ανάλογα με το πρόβλημα αλλά χαρακτηρίζονται επίσης από αστάθεια καθώς είναι ευαίσθητα σε μικρές αλλαγές στα δεδομένα και στην υπερπροσαρμογή αν δεν επιβλέπονται στενά μειώνοντας την ικανότητα γενίκευσης τους [20] [50].

Μεταγενέστερα παρουσιάστηκε η μέθοδος του τυχαίου δάσους (Random Forest) η οποία αντιμετωπίζει το πρόβλημα της υπερπροσαρμογής στα δέντρα αποφάσεων εισάγοντας μια προσέγγιση συνόλου [4] [49] [51]. Συγκεκριμένα εφαρμόζει πολλαπλά δέντρα αποφάσεων σε τυχαία υποσύνολα δεδομένων διασφαλίζοντας ποικιλομορφία στις επιμέρους προβλέψεις, τις οποίες συνδυάζει με μεθόδους υπολογισμού μέσου όρου και παράγει μια τελική πρόβλεψη. Έχουν τη δυνατότητα παραγωγής γενικευμένων αποτελεσμάτων, διαχείρισης συνόλων δεδομένων μεγάλων διαστάσεων και ενσωμάτωσης εξωγενών παραγόντων όπως οικονομικοί και μετεωρολογικοί [20] [48]. Ωστόσο παρόλο που τα δέντρα αποφάσεων είναι ερμηνεύσιμα στο σύνολο τους έπειτα από εύρεση της μέσης πρόβλεψης αποτελεί πρόκληση η ερμηνεύση των αιτιών που οδήγησαν σε αυτήν ενώ η εκπαίδευση τους μπορεί να είναι υπολογιστικά ακριβή και ιδιαίτερα σε μεγάλα σύνολα δεδομένων, πράγμα που είναι ολοένα και πιο σύνθετες [49].

Παράλληλα σημαντική εξέλιξη στον τομέα της μηχανικής μάθησης αποτέλεσαν και οι μηχανές διανυσμάτων στήριξης (Support Vector Machines) που ακολούθησαν μια εντελώς διαφορετική προσέγγιση αξιοποιώντας συναρτήσεις πυρήνα [4] [20]. Αυτές οι συναρτήσεις λαμβάνουν ως είσοδο

δεδομένα που ανήκουν σε χώρο χαμηλών διαστάσεων τα οποία συνήθως δεν είναι εύκολα διαχωρίσιμα και τα μετατρέπουν σε δεδομένα χώρου υψηλότερων διαστάσεων στον οποίο είναι διαχωρίσιμα. Έτσι λοιπόν το SVM όντας μοντέλο που επιλύει προβλήματα ταξινόμησης προβάλλει το σύνολο εκπαίδευσης σε έναν χώρο περισσότερων διαστάσεων και βρίσκει το υπερεπίπεδο το οποίο διαχωρίζει βέλτιστα τα σημεία [49]. Μαθηματικά εκφράζεται ως εξής :

$$\text{Ελαχιστοποίηση } \frac{1}{2} ||w||^2 \text{ με την προϋπόθεση ότι } y_i(w^T x_i + b) \geq 1, \forall i$$

όπου:

- w : Το διάνυσμα βαρών
- b : ο όρος μεροληψίας
- y_i : η ετικέτα της κλάσης
- x_i : το διάνυσμα χαρακτηριστικών της παρατήρησης i

Το μοντέλο παλινδρόμης διανυσματικής υποστήριξης (SVR) αποτελεί την επέκταση του SVM για προβλήματα βελτιστοποίησης όπως η πρόβλεψη χρονοσειρών και χρησιμοποιεί μια συνάρτηση απώλειας ευαίσθητη στο ϵ ως εξής [52]:

$$L_{\epsilon}(y, \hat{y}) = \begin{cases} |y - \hat{y}| - \epsilon & \text{αν } |y - \hat{y}| < \epsilon \\ 0 & \text{αλλιώς} \end{cases}$$

Έχουν αποδειχθεί ιδιαίτερα αποδοτικά σε βραχυπρόθεσμες και μεσοπρόθεσμες προβλέψεις με μη στάσιμα δεδομένα ενώ είναι ανθεκτικά στην υπερπροσαρμογή στα δεδομένα [9] [49]. Ωστόσο η απόδοση του βασίζεται πολύ στην επιλογή των παραμέτρων του ενώ όπως και στη μέθοδο τυχαίου δάσους είναι υπολογιστικά ακριβό [4].

Τέλος αξίζουν να αναφερθούν και ορισμένες μέθοδοι ενίσχυσης (boosting) που αξιοποιούν μοντέλα ασθενής μάθησης (απλά μοντέλα όπως δέντρα αποφάσεων που συμμετέχουν σε προβλέψεις με μεθόδους συνόλου) όπως ο αλγόριθμος AdaBoost και οι μηχανές Gradient Boosting (GBMs) των οποίων η

προβλεπτική απόδοση σημείωσε σημαντική βελτίωση σε σχέση με άλλα μοντέλα και ειδικά σε μεγάλα σύνολα δεδομένων. Συγκεκριμένα ο αλγόριθμος AdaBoost.R2, μια ειδική μορφή για προβλήματα βελτιστοποίησης, συνδυάζει επαναληπτικά τις προβλέψεις πολλαπλών μοντέλων ασθενής μάθησης βελτιώνοντας την απόδοση της συνολικής πρόβλεψης. Το κάθε μοντέλο ασθενής μάθησης διαθέτει το δικό του σταθμισμένο σφάλμα πρόβλεψης και εκπαιδεύεται με σκοπό τη μείωση του ενώ η τελική πρόβλεψη είναι το άθροισμα των σταθμισμένων συνεισφορών των επιμέρους προβλέψεων μετά το πέρας της εκπαίδευσης των αντίστοιχων μοντέλων. Εκφράζεται ως εξής:

$$F(x) = \sum_{m=1}^M a_m h_m(x)$$

όπου:

- $h_m(x)$: Το m-οστό ασθενές μοντέλο μάθησης
- a_m : Το βάρος (συμμετοχή) της πρόβλεψης του m-οστού ασθενή μοντέλου μάθησης που υπολογίζεται με βάση το σφάλμα e_m :

$$e_m = \frac{\sum_{i=1}^N |y_i - h_m(x_i)|}{\sum_{i=1}^N |y_i - \bar{y}|} \quad \text{όπου} \quad \bar{y} = \frac{1}{N} \sum_{i=1}^N y_i$$

- M : Ο συνολικός αριθμός μοντέλων

Αποτελεί μια απλή ευέλικτη μέθοδο που μπορεί να ανταπεξέλθει σε απαιτητικά προβλήματα καθώς εστιάζει επαναληπτικά στα μεγάλα σφάλματα, πράγμα που το καθιστά ιδιαίτερα ευαίσθητο σε θορυβώδη δεδομένα και ακραίες τιμές [4] [50]. Από την άλλη οι GBMs ελαχιστοποιούν μια επιλεγμένη συνάρτηση απώλειας προσθέτοντας διαδοχικά προβλέψεις μοντέλων ασθενής μάθησης που διορθώνουν τα υπολειπόμενα σφάλματα των προηγούμενων προβλέψεων. Έχει τη μορφή :

$$F_m(x) = F_{m-1}(x) + \gamma h_m(x)$$

όπου:

- $F_m(x)$: Το ενισχυμένο μοντέλο μετά από m επαναλήψεις
- γ : Ο ρυθμός εκμάθησης
- $h_m(x)$: Το μοντέλο ασθενής μάθησης στο m -οστό βήμα

Σε αντίθεση με τον αλγόριθμο AdaBoost βελτιστοποιεί άμεσα την συνάρτηση απώλειας χρησιμοποιώντας τη μέθοδο της βαθμωτής καθόδου (gradient descent), που στοχεύει στην συνεχή ενημέρωση των παραμέτρων του μοντέλου προς τη κατεύθυνση της μεγαλύτερης καθόδου στην κλίση της συνάρτησης απώλειας μέχρι αυτή να συγκλίνει σε ένα ελάχιστο και εκφράζεται ως εξής [9] [47]:

$$\theta = \theta - \gamma \nabla L(\theta)$$

όπου :

- θ : Οι παράμετροι του μοντέλου
- γ : Ο ρυθμός εκμάθησης
- $\nabla L(\theta)$: Η κλίση της συνάρτησης απώλειας ως προς θ .

Αυτή η μέθοδος σε συνδυασμό με τη δυνατότητα επιλογής της συνάρτησης απώλειας καθιστά τα GBMs αρκετά ευέλικτα και ικανά να διαχειριστούν σύνθετα σύνολα δεδομένων που τα διέπουν μη γραμμικές σχέσεις [4] [48]. Ωστόσο έχουν υψηλό υπολογιστικό κόστος και αν δεν ρυθμιστούν προσεκτικά οι υπερπαραμέτροι του, όπως ο ρυθμός εκμάθησης, τότε είναι εύκολο να υπερπροσαρμοστούν στο σύνολο δεδομένων που εκπαιδεύτηκαν μειώνοντας αισθητά την ικανότητα γενίκευσης τους [48].


Αυτές οι μέθοδοι αποδείχθηκαν πολύ χρήσιμα εργαλεία για προβλήματα βελτιστοποίησης και συγκεκριμένα στην πρόβλεψη χρονοσειρών. Όσο όμως τα σύνολα δεδομένων γίνοντουσαν όλο και πιο ογκώδη και περίπλοκα, τα παραδοσιακά μοντέλα μηχανικής μάθησης άρχισαν να εμφανίζουν περιορισμούς ενώ αυξανόταν και η ανάγκη για μοντελοποίηση ιδιαίτερων χρονικών εξαρτήσεων. Έτσι αναπτύχθηκε η έννοια της βαθιάς μάθησης (Deep Learning) η οποία με την πρακτική υλοποίηση νευρωνικών δικτύων πρόσφερε απaráμιλλες δυνατότητες εκμάθησης αναπαραστάσεων από δεδομένα.

2.1.3 Βαθιά Μάθηση : Εξέλιξη της διαδικασίας πρόβλεψης μέσω νευρωνικών δικτύων

Η βαθιά μάθηση (DL) αποτελεί ένα υποσύνολο του εύρους που καταλαμβάνει γενικότερα η μηχανική μάθηση και αντιπροσωπεύει το σύνολο των μοντέλων που αξιοποιούν τεχνητούς νευρώνες σχηματίζοντας έτσι πολλά επίπεδα, τα οποία απαρτίζονται από αυτούς, με σκοπό την εκμάθηση σύνθετων αναπαραστάσεων από τα δεδομένα εισόδου τους.

Τεχνητά Νευρωνικά Δίκτυα (ANNs)

Η πρώτη θεωρητική περιγραφή τους μπορεί να εντοπιστεί πίσω στο 1943 από τους McCulloch και Pitts ενώ η πρώτη πρακτική υλοποίηση ενός μονοεπίπεδου τεχνητού νευρωνικού δικτύου (ANN), που μπορεί να εκπαιδευτεί, ονομαζόμενη Perceptron αναπτύχθηκε το 1958 από τον Rosenblatt [53] [54]. Συγκεκριμένα το μοντέλο Perceptron σχεδιάστηκε για προβλήματα ταξινόμησης. Προσομοιώνει ένα βιολογικό νευρώνα και μαθαίνει αλλάζοντας



Εικόνα 2.1 : Αρχιτεκτονική Perceptron [55]

τις παραμέτρους του ενώ επεξεργάζεται δεδομένα, πράγμα που διαφοροποιεί αρκετά τη γενική φύση των νευρωνικών δικτύων με άλλα μοντέλα στα οποία οι παράμετροι θα έπρεπε να έχουν οριστεί εξ αρχής. Ουσιαστικά λαμβάνει το

σταθμισμένο άθροισμα του διανύσματος εισόδου και εφαρμόζει μια συνάρτηση βήματος για να παράξει τη κλάση. Όπως φαίνεται στην Εικόνα 2.1, το μοντέλο μπορεί να περιγραφεί ως εξής :

$$a = \text{sign} \left(\sum_{i=1}^n w_i p_i + b \right)$$

όπου :

- w_i : Ο σταθμισμένος όρος του i-οστού χαρακτηριστικού εισόδου
- p_i : Η τιμή του i-οστού χαρακτηριστικού εισόδου
- b : σταθερά μεροληψίας


Επίσης ακολουθεί έναν απλό κανόνα για την ανανέωση των σταθμισμένων όρων :

$$w_i = w_i + \Delta w_i \quad \text{όπου} \quad \Delta w_i = \eta (a_{true} - a) x_i$$

Όπου η είναι ο ρυθμός μάθησης. Πρακτικά επιβραβεύει αυξάνοντας τους σταθμισμένους όρους των χαρακτηριστικών εισόδου που η συνεισφορά τους οδηγεί στο σωστό αποτέλεσμα και τιμωρεί μειώνοντας αυτούς που οδηγούν στο λάθος. Αξίζει να σημειωθεί επίσης πως η συνάρτηση βήματος είναι αυτή που παράγει το αποτέλεσμα σε δυαδική μορφή (0 ή 1) και ανήκει στην ομάδα των συναρτήσεων ενεργοποίησης. Με την κατάλληλη επιλογή συνάρτησης ενεργοποίησης το μοντέλο μπορεί να προσφέρει λύσεις και σε προβλήματα βελτιστοποίησης όπως πρόβλεψη της επόμενης τιμής σε μια χρονοσειρά λαμβάνοντας μια ακολουθία παρελθοντικών τιμών της σαν είσοδο αλλά περιορίζεται σε γραμμικά διαχωρίσιμα προβλήματα.

Μοντέλα με περισσότερους τεχνητούς νευρώνες από το Perceptron δεν μπορούσαν να αξιοποιηθούν πρακτικά καθώς δεν υπήρχε τρόπος αποτελεσματικής εκπαίδευσης μέχρι το 1986 που οι Rumelhart, Hinton και Williams καθιέρωσαν επίσημα τον αλγόριθμο της αντίστροφης διάδοσης σφάλματος (backpropagation) ως μια αποτελεσματική μέθοδο εκπαίδευσης πολυεπίπεδων νευρωνικών δικτύων [44] [56]. Έτσι παρουσιάστηκε και η πρώτη αρχιτεκτονική πολυεπίπεδου νευρωνικού δικτύου, το πολυεπίπεδο Perceptron (Multi-Layer Perceptron). Βασίζεται στην αρχιτεκτονική του Perceptron και την

επεκτείνει με την μορφή επιπέδων. Ένα μοντέλο MLP είναι πλήρως ορισμένο όταν έχει ένα επίπεδο εισόδου, ένα ή περισσότερα κρυφά επίπεδα και ένα επίπεδο εξόδου. Κάθε επίπεδο διαθέτει τουλάχιστον ένα νευρώνα (Perceptron) που συνδέεται με όλους τους νευρώνες του προηγούμενου επιπέδου αλλά και



Εικόνα 4.2 : Παράδειγμα αρχιτεκτονικής MLP ενός κρυφού επιπέδου [55]

του επόμενου. Όλοι οι νευρώνες ενός επιπέδου διαθέτουν την ίδια συνάρτηση ενεργοποίησης η οποία επιλέγεται ανάλογα τον τύπο του προβλήματος. Έτσι λοιπόν για προβλέψεις χρονοσειρών το διάνυσμα εισόδου διέρχεται από όλα τα επίπεδα του MLP μέχρι να φτάσει στο επίπεδο εξόδου που παράγεται το αποτέλεσμα της πρόβλεψης και το σφάλμα σε σχέση με την πραγματική τιμή. Έπειτα εφαρμόζεται ο αλγόριθμος αντίστροφης διάδοσης σφάλματος ώστε να πραγματοποιηθεί η εκπαίδευση του μοντέλου αλλάζοντας τις παραμέτρους του. Συγκεκριμένα κάθε σταθμισμένος όρος εκπαιδεύεται ως εξής:

$$w = w + \Delta w \quad \mu\epsilon \quad \Delta w = -\eta \frac{\partial w}{\partial L}$$

όπου :

- Δw : Η μεταβολή του σταθμισμένου όρου
- η : Ο ρυθμός μάθησης
- L : Η συνάρτηση σφάλματος
- w : Ο σταθμισμένος όρος προς μεταβολή


Αποτελεί έναν απλό και αποδοτικό τρόπο ανανέωσης των παραμέτρων ενός νευρωνικού δικτύου που χρησιμοποιείται μέχρι και σήμερα για την εκπαίδευση τους. Το μοντέλο MLP έχει εφαρμοστεί για προβλέψεις χρονοσειρών και έχει παρουσιάσει εξαιρετικές ικανότητες στην διαχείριση μη γραμμικών σχέσεων στα δεδομένα και στον συνυπολογισμό εξωγενών μεταβλητών σε σχέση με άλλες γνωστές στατιστικές μεθόδους [57] [58]. Ωστόσο αντιμετωπίζει τα δεδομένα ως ανεξάρτητα διανύσματα εισόδου μειώνοντας την ικανότητα του να αναγνωρίζει χρονικές εξαρτήσεις.

Παρά αυτές τις εξελίξεις τα πρώτα νευρωνικά δίκτυα περιοριζόντουσαν έντονα από την έλλειψη υπολογιστικής δύναμης και δεδομένων, πράγμα που εμπόδιζε την ευρεία υιοθέτηση τους μέχρι την αναβίωση τους το 2010 με τις καινοτομίες στα υπολογιστικά συστήματα όπως η χρήση μονάδων γραφικής επεξεργασίας (GPU) οι οποίες επίσπευσαν έντονα τους χρόνους εκπαίδευσης των μοντέλων και βοήθησαν στην ανάπτυξη νέων αρχιτεκτονικών [44] [59].

Συνελικτικά Νευρωνικά Δίκτυα (CNNs)

Τέτοιες ανεπτυγμένες αρχιτεκτονικές αποτελούν και τα Συνελικτικά νευρωνικά δίκτυα τα οποία ανήκουν στην ομάδα δικτύων βαθιάς μάθησης. Χρησιμοποιήθηκαν κυρίως για την επεξεργασία εικόνας αλλά έχουν εξελιχθεί και είναι πλέον ένα ευέλικτο εργαλείο επεξεργασίας δεδομένων σε μορφή ακολουθίας, συμπεριλαμβανομένων και των χρονοσειρών [60]. Έχουν σχεδιαστεί κατά κύριο λόγο για την εξαγωγή χαρακτηριστικών από δομημένα δεδομένα μέσω συνελικτικών επιπέδων που ανιχνεύουν μοτίβα όπως φαίνεται και στην Εικόνα 2.3. Συγκεκριμένα αντιμετωπίζει τα δεδομένα εισόδου σαν μονοδιάστατο σήμα ενώ κάθε χρονικό βήμα (η ομάδα μεταβλητών-χαρακτηριστικών εισόδου μια συγκεκριμένη χρονική στιγμή) αντιστοιχεί σε μια διάσταση χαρακτηριστικού. Τα δεδομένα αυτά διαδίδονται στο συνελικτικό επίπεδο (convolutional layer) τα οποίο αποτελείται από ένα φίλτρο (kernel) που ολισθαίνει πάνω τους πραγματοποιώντας πολλαπλασιασμούς μεταξύ των στοιχείων που επικαλύπτει και τις τιμές της αντίστοιχης θέσεις του φίλτρου, εξάγοντας έτσι χάρτες χαρακτηριστικών (feature maps). Αυτοί μετά το πέρας της συνέλιξης διαδίδονται σε ένα επίπεδο υποδειγματοληψίας (pooling layer) που μειώνει τις χωρικές διαστάσεις τους διατηρώντας τις σημαντικές

πληροφορίες. Τέλος η έξοδος μετατρέπεται σε ένα μονοδιάστατο διάνυσμα (flattening) το οποίο εισάγεται σε ένα MLP για να παράξει την πρόβλεψη.



Εικόνα 2.3 : Αρχιτεκτονική βασικού συνελκτικού δικτύου (CNN) [60]

Μαθηματικά η συνέλιξη εκφράζεται ως εξής :

$$y(t) = \sum_{k=1}^K x(t+k)w(k) + b$$

όπου :


- $y(t)$: Χάρτης χαρακτηριστικών χρονικής στιγμής t
- $x(t+k)$: Τιμή εισόδου τη χρονική στιγμή $t+k$
- $w(k)$: Σταθμισμένη τιμή του φίλτρου στη θέση k
- b : Όρος μεροληψίας (bias)
- K : Μέγεθος του φίλτρου

Ουσιαστικά το μοντέλο CNN είναι ένα εξαιρετικό εργαλείο για αυτόματη εκμάθηση χαρακτηριστικών από τα δεδομένα [61]. Ωστόσο όπως και άλλα μοντέλα πριν από αυτό βασίζεται πολύ στην σωστή ρύθμιση των υπερπαραμέτρων του, όπως το μέγεθος του φίλτρου, πράγμα που ενδεχομένως να το καταστήσει υπολογιστικά ακριβό ενώ δεν διαθέτει την ικανότητα να

ανιχνεύσει εξαρτήσεις μεγάλης εμβέλειας σε δεδομένα χρονοσειρών και κατ' επέκταση δεν είναι κατάλληλο για μακροπρόθεσμες προβλέψεις [61] [62].

Επαναληπτικά Νευρωνικά Δίκτυα (RNNs)


Τα CNNs έχουν τη δυνατότητα να μοντελοποιήσουν χωρικά τα δεδομένα και προσαρμόστηκαν για την επεξεργασία διαδοχικών δεδομένων (sequential data). Τα επαναληπτικά νευρωνικά δίκτυα (RNNs) ωστόσο σχεδιάστηκαν για να διαχειρίζονται διαδοχικά δεδομένα και να πραγματοποιούν χρονική μοντελοποίηση, πράγμα που τα καθιστά ιδανικά για προβλήματα όπως τη πρόβλεψη χρονοσειρών [4] [60] [63]. Έχει χρησιμοποιηθεί ευρέως για βραχυπρόθεσμες προβλέψεις και έχει σημειώσει σημαντική βελτίωση απόδοσης στη μοντελοποίηση μη γραμμικών και δυναμικών συμπεριφορών συγκριτικά



Εικόνα 2.4 : Αρχιτεκτονική ενός RNN με 2 επαναληπτικά κρυφά επίπεδα (Πηγή : [Understanding the Mechanism and Types of Recurrent Neural Networks](#))

με προηγούμενα στατιστικά μοντέλα ενώ συνεχίζει να χρησιμοποιείται συνδυαστικά με συνελκτικά δίκτυα σε υβριδικές αρχιτεκτονικές για ταυτόχρονη χωρική και χρονική μοντελοποίηση δεδομένων [44] [60] [62]. Αποτελεί ένα προωθητικό δίκτυο όπως και το συνελκτικό και όπως φαίνεται

και στην Εικόνα 2.4 έχει παρόμοια μορφή με ένα MLP με κύρια διαφορά στους νευρώνες των κρυφών επιπέδων του. Συγκεκριμένα παρουσιάζουν μια



Εικόνα 2.5 : Αριστερά - Διάγραμμα ενός απλού νευρώνα RNN με είσοδο x που ενσωματώνεται στην κρυφή μνήμη h με επαναληπτική σύνδεση και έξοδο o . Δεξιά - Ο ίδιος νευρώνας ως ένα ξεδιπλωμένο υπολογιστικό γράφημα με είσοδο για κάθε χρονικό βήμα. [63]

επιπλέον σύνδεση που επιστρέφει την έξοδο του νευρώνα στον εαυτό του ως άλλη μια είσοδο σε συνδυασμό με την επόμενη. Αυτό επιτρέπει στο μοντέλο να θυμάται παρελθοντικά δεδομένα όταν επεξεργάζεται τα νέα και αυτή η διαδικασία ονομάζεται επαναληπτική. Για την καλύτερη κατανόηση του θεωρούμε ότι οι είσοδοι για κάθε χρονική στιγμή t είναι ανεξάρτητοι μεταξύ τους όπως και στην Εικόνα 2.5. Έτσι αντιστοιχεί ένας νευρώνας για κάθε στιγμή που δέχεται ως είσοδο την έξοδο του νευρώνα της προηγούμενης στιγμής και προσφέρει την δική του έξοδο ως είσοδο στον νευρώνα της επόμενης στιγμής ξεδιπλώνοντας έτσι το μοντέλο. Μαθηματικά μπορεί να εκφραστεί ως :

$$\begin{aligned} a^{(t)} &= Wh^{(t-1)} + Ux^{(t)} + b \\ h^{(t)} &= F(a^{(t)}) \\ o^{(t)} &= c + Vh^{(t)} \\ \hat{y}^{(t)} &= L(o^{(t)}) \end{aligned}$$

όπου :

- U : Σταθμισμένος όρος σύνδεσης από είσοδο σε κρυφή μνήμη
- W : Σταθμισμένος όρος σύνδεσης από κρυφή μνήμη σε κρυφή μνήμη
- $x^{(t)}$: Είσοδος τη χρονική στιγμή t
- $a^{(t)}$: Συνδυαστική είσοδος τη χρονική στιγμή t


- F : Συνάρτηση ενεργοποίησης
- $h^{(t)}$: Όρος κρυφής κατάστασης (hidden state) τη χρονική στιγμή t
- V : Σταθμισμένος όρος σύνδεσης από κρυφή μνήμη σε έξοδο
- b, c : Όροι μεροληψίας (biases)
- L : Συνάρτηση απώλειας

Η συνολική απώλεια του μοντέλου υπολογίζεται ως το άθροισμα των απωλειών όλων των χρονικών στιγμών και για την ελαχιστοποίηση της υπολογίζεται η κλίση της συνάρτησης απώλειας ως προς τις παραμέτρους που σχετίζονται με αυτή με σκοπό την ανανέωση τους. Κατά την διάρκεια αντίστροφης διάδοσης σφάλματος η κλίση της συνάρτησης ως προς ένα νευρώνα υπολογίζεται αναδρομικά ξεκινώντας με τους νευρώνες πριν το τελικό αποτέλεσμα και στη συνέχεια διαδίδεται πίσω στο χρόνο. Ωστόσο εδώ τα παραδοσιακά επαναληπτικά νευρωνικά δίκτυα αντιμετωπίζουν το πρόβλημα απειρισμού ή εξαφάνισης της κλίσης (exploding/vanishing gradient problem), όπου οι κλίσεις των πρώτων επιπέδων μεγαλώνουν ή μικραίνουν κατά τη διάρκεια της αντίστροφης διάδοσης με αποτέλεσμα στα τελευταία επίπεδα η κλίση να απειρίζεται ή να γίνεται μηδενική, πράγμα που εμποδίζει τα μοντέλα αυτά να μάθουν εξαρτήσεις μεγάλης εμβέλειας [4] [44] [60] [62]. Παρόλα αυτά, έχουν προταθεί αρκετές βελτιώσεις της αρχιτεκτονικής των RNNs όπως τα αμφίδρομα επαναληπτικά δίκτυα (Bidirectional-RNNs), που βελτιώνουν την απόδοση του επεξεργάζοντας δεδομένα και στις δυο κατευθύνσεις αξιοποιώντας παρελθοντικό και μελλοντικό περιεχόμενο, αλλά και άλλες προσεγγίσεις που αντιμετωπίζουν το πρόβλημα εξαφάνισης της κλίσης [4] [60] [62].

Δίκτυα Μακράς Βραχυπρόθεσμης Μνήμης (LSTMs)


Μια τέτοια αρχιτεκτονική που σχεδιάστηκε για την επίλυση του προβλήματος εξαφάνισης της κλίσης και αποτέλεσε κομβική καινοτομία στον τομέα της πρόβλεψης χρονοσειρών είναι το δίκτυο μακράς βραχυπρόθεσμης μνήμης (LSTM) [60]. Αποτελεί μια μορφή επαναληπτικού νευρωνικού δικτύου με πύλες (gated RNN) που διαφέρει στο σχεδιασμό του νευρώνα καθώς εκτός από την εξωτερική επανάληψη, ανάμεσα σε νευρώνες διαφορετικών χρονικών στιγμών, που προσφέρει ένα RNN διαθέτει και έναν εσωτερικό βρόχο στον

οποίο ελέγχεται η ροή της πληροφορίας. Στην Εικόνα 2.6 παρουσιάζεται η αρχιτεκτονική ενός επιπέδου LSTM σύμφωνα με την οποία η είσοδος και η έξοδος είναι ίδια όπως και σε ένα RNN αλλά κάθε 2 νευρώνες διαδοχικών



Εικόνα 2.6 : Αρχιτεκτονική ενός επιπέδου LSTM (Πηγή : [MathWorks - Long Short-Term Memory Neural Networks](#))

χρονικών στιγμών συμμετέχουν σε 2 συνδέσεις που μεταφέρουν εκτός από τη κρυφή κατάσταση ($h^{(t)}$) και τη κατάσταση κελιού ($c^{(t)}$). Η κατάσταση κελιού περιέχει τη μακροπρόθεσμη μνήμη του δικτύου και μεταφέρει τη σχετική πληροφορία σε όλα τα χρονικά βήματα ενώ η κρυφή κατάσταση διαθέτει τη βραχυπρόθεσμη μνήμη του δικτύου και λειτουργεί και σαν έξοδος του για το αντίστοιχο χρονικό βήμα. Συγκεκριμένα ο νευρώνας της χρονικής στιγμής t λαμβάνει την αντίστοιχη είσοδο $x^{(t)}$, τη κατάσταση κελιού $c^{(t-1)}$ και τη κρυφή



Εικόνα 2.7 : Διάγραμμα ροής δεδομένων μέσα σε ένα νευρώνα ενός επιπέδου LSTM (Πηγή : [MathWorks - Long Short-Term Memory Neural Networks](#))

κατάσταση $h^{(t-1)}$ της προηγούμενης χρονικής στιγμής $t-1$ και με τη βοήθεια διάφορων πυλών υπολογίζονται οι επόμενες καταστάσεις $c^{(t)}$ και $h^{(t)}$ που

προωθούνται στον επόμενο νευρώνα. Σύμφωνα με την Εικόνα 2.7 η λειτουργία ενός LSTM εκφράζεται ως εξής :

- Πύλη Λήθης (Forget Gate - f) :

$$f^{(t)} = \sigma_g(W_f x^{(t)} + R_f h^{(t-1)} + b_f)$$

Αποφασίζει τι πληροφορίες από τη προηγούμενη κατάσταση κελιού $c^{(t-1)}$ να ξεχάσει και έχει ως έξοδο τη τιμή 0 (λήθη) ή 1 (διατήρηση) για κάθε πληροφορία στην $c^{(t-1)}$

- Πύλη Εισόδου (Input Gate - i) :

$$i^{(t)} = \sigma_g(W_i x^{(t)} + R_i h^{(t-1)} + b_i)$$

Αποφασίζει ποια νέα πληροφορία να προσθέσει στη κατάσταση κελιού $c^{(t)}$ και παράγει μια τιμή μεταξύ 0 και 1 για να ρυθμίσει τη σημασία κάθε νέας εισόδου.

- Υποψήφια κατάσταση κελιού (Candidate Cell State - g) :

$$g^{(t)} = \sigma_c(W_g x^{(t)} + R_g h^{(t-1)} + b_g)$$

Παράγει υποψήφιες τιμές για να ανανεώσουν τη προηγούμενη κατάσταση κελιού των οποίων η σημασία ρυθμίζεται από την πύλη εισόδου.

- Ανανέωση κατάστασης κελιού (Cell State - $c^{(t)}$) :

$$c^{(t)} = f^{(t)} \odot c^{(t-1)} + i^{(t)} \odot g^{(t)}$$

Συνδυάζει τη διατηρημένη πληροφορία (μέσω της πύλης λήθης) με τη νέα πληροφορία (μέσω της πύλης εισόδου και της υποψήφιας κατάστασης κελιού) και δημιουργεί την νέα κατάσταση κελιού (μακροπρόθεσμη μνήμη)

- Πύλη Εξόδου (Output Gate - o) :

$$o^{(t)} = \sigma_g(W_o x^{(t)} + R_o h^{(t-1)} + b_o)$$

Αποφασίζει ποιο μέρος της κατάστασης κελιού $c^{(t)}$ θα αποτελέσει την έξοδο και παράγει μια τιμή μεταξύ 0 και 1 που θα λειτουργήσει σαν φίλτρο στη συνέχεια.

- Ανανέωση κρυφής κατάστασης (Hidden State - $h^{(t)}$) :

$$h^{(t)} = o^{(t)} \odot \sigma_c(c^{(t)})$$

Φιλτράρεται η ανανεωμένη κατάσταση κελιού με αποτέλεσμα να παραχθεί η ανανεωμένη κρυφή κατάσταση που αποτελεί και την έξοδο του νευρώνα LSTM για τη χρονική στιγμή t .

όπου :

- $W = \begin{bmatrix} W_i \\ W_f \\ W_g \\ W_o \end{bmatrix}$: Σταθμισμένοι όροι εισόδου
- $R = \begin{bmatrix} R_i \\ R_f \\ R_g \\ R_o \end{bmatrix}$: Σταθμισμένοι όροι επανάληψης
- $b = \begin{bmatrix} b_i \\ b_f \\ b_g \\ b_o \end{bmatrix}$: Όροι μεροληψίας (biases)
- $\odot$: Πολλαπλασιασμός διανυσμάτων κατά στοιχείο
- σ_c : Η συνάρτηση ενεργοποίησης κατάστασης. Χρησιμοποιείται συνήθως η συνάρτηση υπερβολικής εφαπτομένης (tanh)
- σ_g : Η συνάρτηση ενεργοποίησης της πύλης. Χρησιμοποιείται συνήθως η σιγμοειδής συνάρτηση ($\sigma(x) = (1 + e^{-1})^{-1}$)


Το δίκτυο μακράς βραχυπρόθεσμης μνήμης διαχειρίζεται αποδοτικά εξαρτήσεις μεγάλης εμβέλειας στα δεδομένα, αντιμετωπίζει επιτυχώς το

πρόβλημα εξαφάνισης των κλίσεων και για αυτό έχει εφαρμοστεί επιτυχώς στην πραγματοποίηση προβλέψεων χρονοσειρών όπου και έχει σημειώσει καλύτερα αποτελέσματα από παραδοσιακά στατιστικά μοντέλα όπως το ARIMA [9] [15] [60] [62]. Ωστόσο αποτελούν μια ιδιαίτερα σύνθετη αρχιτεκτονική με αρκετές υπερπαραμέτρους που τα καθιστά υπολογιστικά ακριβά στην εκπαίδευση τους ενώ είναι ευαίσθητα στην ρύθμιση τους ώστε να παράξουν σωστές προβλέψεις και να αποφύγουν την υπερπροσαρμογή, ιδιαίτερα σε μικρά σύνολα δεδομένων [15] [60] [62].

Για την αντιμετώπιση κάποιων προκλήσεων που συναντά το δίκτυο LSTM έχουν προταθεί ορισμένες βελτιώσεις του όπως το αμφίδρομο δίκτυο μακράς βραχυπρόθεσμης μνήμης (Bidirectional LSTM – Bi-LSTM), το δίκτυο της επαναλαμβανόμενης μονάδας μέσω πυλών (Gated Recurrent Unit – GRU) και η αμφίδρομη εξέλιξη του (Bidirectional GRU – Bi-GRU). Το Bi-LSTM εκμεταλλεύεται εκτός από παρελθοντικές καταστάσεις και τις μελλοντικές με αποτέλεσμα να αυξάνεται η απόδοση τους και να υπερτερούν των τυπικών LSTMs σε περιπτώσεις με σύνθετα δεδομένα με πολλές διακυμάνσεις [15] [60]. Παρόμοια τα GRUs έχουν παρόμοιες προβλεπτικές ικανότητες με τα LSTMs αλλά προσφέρουν μια πολύ πιο απλή αρχιτεκτονική που περιλαμβάνει 2 πύλες αντί για 3, μια ενιαία κατάσταση που περιέχει τη κρυφή κατάσταση και τη κατάσταση κελιού και αποκάλυψη του πλήρες περιεχομένου της μνήμης χωρίς πρόσθετη ρύθμιση από κάποια πύλη [9] [62]. Έτσι αποτελεί μια υπολογιστικά πιο φθηνή εκδοχή του LSTM που διατηρεί την ικανότητα του να διαχειρίζεται εξαρτήσεις μεγάλης εμβέλειας στα δεδομένα ενώ μπορεί να εκπαιδευτεί αισθητά πιο γρήγορα [9] [60] [62]. Τέλος το Bi-GRU ακολουθεί την λογική του σχεδιασμού ενός GRU αλλά επεξεργάζεται ακολουθίες δεδομένων και προς τις 2 κατευθύνσεις βελτιώνοντας την κατανόηση των δεδομένων καθώς συνδυάζει παρελθοντικές με μελλοντικές γνώσεις σχηματίζοντας εξαρτήσεις [60]. Τέλος αξίζει να αναφερθεί ότι όλα τα είδη επαναληπτικών δικτύων που αναφέρθηκαν έχουν χρησιμοποιηθεί εκτενώς σε υβριδικές αρχιτεκτονικές μαζί με συνελκτικά δίκτυα ώστε να εκμεταλλευτούν το συνδυασμό χωρικής και χρονικής μοντελοποίησης των δεδομένων για ενισχυμένη εκμάθηση χαρακτηριστικών και ακρίβεια [60].

Το Μοντέλο Μετασχηματιστή (Transformer Model)

Το μοντέλο μετασχηματιστή αποτελεί μια αρχιτεκτονική που έχει φέρει επανάσταση στον τομέα της επεξεργασίας φυσικής γλώσσας (NLP) και έχει υιοθετηθεί ευρέως για διάφορες εργασίες όπως και η ανάλυση χρονοσειρών. Σε αντίθεση με τα επαναληπτικά νευρωνικά δίκτυα, που επεξεργάζονται δεδομένα ακολουθιακά, αυτό το μοντέλο επιχειρεί να αξιοποιήσει ένα μηχανισμό γνωστό ως αυτοπροσοχή (Self-Attention Mechanism) ώστε να επεξεργαστεί παράλληλα



Εικόνα 2.8 : Αρχιτεκτονική ενός Μετασχηματιστή (Πηγή : [Wikipedia - Transformer \(deep learning architecture\)](#))

τα δεδομένα εισόδου και να αποκτήσει πληροφορίες που τα αντικατοπτρίζουν στο σύνολο τους, βελτιώνοντας σημαντικά την απόδοση του σε μεγάλα σύνολα δεδομένων [4]. Όπως φαίνεται στην εικόνα 2.8 το μοντέλο του Μετασχηματιστή αποτελείται από έναν κωδικοποιητή και έναν αποκωδικοποιητή, που το καθένα έχει πολλαπλά επίπεδα. Συγκεκριμένα μπορεί να αναλυθεί ως εξής:

- Ενσωματώσεις Εισόδου (Input Embeddings) :

$$E = W_{emb} \cdot X$$

1. E : Πίνακας ενσωματώσεων εισόδου
2. W_{emb} : Εκπαιδευσιμος Πίνακας σταθμισμένων όρων επιπέδου
3. X : Διάνυσμα διακριτής εισόδου

Αναθέτει σε κάθε διακριτό σύμβολο εισόδου ένα μοναδικό δείκτη από ένα προκαθορισμένο χώρο χαρακτηριστικών (*feature space*) ο οποίος χρησιμοποιείται μετά για να αντιστοιχίσει το σύμβολο σε ένα πυκνό συνεχές διάνυσμα αναπαράστασης. Τυπικά είναι σταθερού μεγέθους (d_{model}) για να διασφαλιστεί συμβατότητα με όλα τα επόμενα επίπεδα.

- Κωδικοποίηση Θέσης (Positional Encoding) :

$$PE_{(pos, 2i)} = \sin\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right)$$

$$PE_{(pos, 2i+1)} = \cos\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right)$$


1. pos : Θέση του συμβόλου στην ακολουθία
2. $2i$: Άρτιοι δείκτες στο διάνυσμα ενσωματωμένων αναπαραστάσεων
3. $2i + 1$: Περιττοί δείκτες στο διάνυσμα ενσωματωμένων αναπαραστάσεων
4. d_{model} : Διαστατικότητα του χώρου ενσωμάτωσης (*embedding space*)

Παράγει ένα μοναδικό διάνυσμα διάστασης d_{model} για κάθε θέση στην ακολουθία διαφοροποιώντας το από άλλες θέσεις. Έτσι επιτρέπεται στο μοντέλο να μάθει τόσο τη σχετική όσο και την απόλυτη πληροφορία μιας θέσης. Τέλος προωθείται στο επόμενο επίπεδο (κωδικοποιητής ή αποκωδικοποιητής) το άθροισμα του

διανύσματος της κωδικοποίησης θέσης με το διάνυσμα ενσωμάτωσης εισόδου ως εξής :

$$Z = E + PE$$

- Μηχανισμός Προσοχής (Attention Mechanism) :



Εικόνα 2.9 : Αριστερά – Μηχανισμός Αυτοπροσοχής. Δεξιά – Προσοχή πολλαπλών κεφαλών [71]

Αυτός ο μηχανισμός εφαρμόζεται τόσο στον κωδικοποιητή όσο και στον αποκωδικοποιητή του μετασχηματιστή και είναι υπεύθυνος για τη σωστή εκτίμηση της σημασίας των διαφόρων συμβόλων εισόδου σε μια αλληλουχία, λαμβάνοντας υπόψη τις μεταξύ τους σχέσεις, διευκολύνοντας την αποτίπωση εξαρτήσεων μεγάλης εμβέλειας. Υπολογίζει ένα σύνολο από βαθμολογίες προσοχής για κάθε ζεύγος συμβόλων εισόδου οι οποίες καθορίζουν την εστίαση που πρέπει να δοθεί σε άλλα σύμβολα εισόδου κατά την επεξεργασία ενός συγκεκριμένου. Αυτό επιτυγχάνεται με τους πίνακες Query (Q), Key (K) και

Value (V) οι οποίοι μαθαίνονται κατά τη διάρκεια της εκπαίδευσης. Συγκεκριμένα από την Εικόνα 2.9 η αυτοπροσοχή μπορεί να εκφραστεί ως :

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V$$

1. $Q = Z \cdot W^Q$: Πίνακας Q με διάσταση $(n \times d_q)$
2. $K = Z \cdot W^K$: Πίνακας K με διάσταση $(n \times d_k)$
3. $V = Z \cdot W^V$: Πίνακας V με διάσταση $(n \times d_v)$
4. W^Q, W^K, W^V : Οι πίνακες σταθμισμένων όρων με διαστάσεις $(d_{model} \times d_q)$, $(d_{model} \times d_k)$ και $(d_{model} \times d_v)$ αντίστοιχα.

Μέσω πολλαπλασιασμού των πινάκων Q, K υπολογίζεται ο πίνακας που περιέχει τη βαθμολογία εστίασης για κάθε σύμβολο εισόδου ο οποίος κλιμακώνεται για να αποφευχθούν πολύ μεγάλες τιμές. Στη συνέχεια προαιρετικά εφαρμόζεται μια μάσκα για να αποτρέψει τη προσοχή σε μελλοντικές τιμές (κυρίως κατά την αποκωδικοποίηση) και θέτει τις τιμές αυτών των θέσεων σε $-\infty$. Έπειτα προωθείται στη συνάρτηση SoftMax από την οποία κανονικοποιούνται οι βαθμολογίες σε πιθανότητες σε όλα τα κλειδιά και τέλος πολλαπλασιάζονται ο πίνακας βαθμολογιών εστίασης με το πίνακα V και προκύπτει η τελική σταθμισμένη αναπαράσταση της εστίασης.

Προσοχή πολλαπλών κεφαλιών

Στην Εικόνα 2.8 όμως το μοντέλο Μετασχηματιστή χρησιμοποιεί επίπεδα προσοχής πολλαπλών κεφαλών οι οποίες όπως φαίνονται και δεξιά στην Εικόνα 2.9 αποτελούνται από πολλές κεφαλές που εκτελούν αυτοπροσοχή. Συγκεκριμένα μπορεί να εκφραστεί ως εξής :

$$Q_i = Z \cdot W_i^Q, K_i = Z \cdot W_i^K, V_i = Z \cdot W_i^V$$

$$Head_i = Attention(Q_i, K_i, V_i)$$

$$Concat_Heads = Concat(Head_1, Head_2, \dots, Head_h)$$

$$Multi - Head_Attention_Output = Concat_Heads \cdot W^O$$

1. W_i^Q, W_i^K, W_i^V : Οι πίνακες σταθμισμένων όρων της κεφαλής i

2. W^O : Ο πίνακας σταθμισμένων όρων εξόδου που συνδυάζει της βαθμολογίες εστίασης όλων των κεφαλών σε ένα τελικό πίνακα εξόδου και ευθυγραμμίζει τις διαστάσεις του με τις απαιτούμενες από τα επόμενα επίπεδα.

Εκτελούνται πολλαπλές λειτουργίες αυτοπροσοχής παράλληλα, η καθεμία με το δικό της σύνολο πινάκων Q, K και V . Οι έξοδοι αυτών στη συνέχεια ενώνονται και μετασχηματίζονται γραμμικά για να πραχθεί η τελική έξοδος. Έτσι το μοντέλο εστιάζει σε διαφορετικά μέρη μιας ακολουθίας ταυτόχρονα με αποτέλεσμα να μπορεί να κατανοήσει πολύπλοκα μοτίβα.

- Κωδικοποιητής (Encoder) :

Σε ένα μπλοκ κωδικοποιητή λαμβάνεται σαν είσοδος το συνολικό διάνυσμα αναπαράστασης και αρχικά υπολογίζεται η σχετική σημασία μεταξύ των συμβόλων εισόδου. Στη συνέχεια λαμβάνεται το άθροισμα του διανύσματος εισόδου με την έξοδο του επιπέδου προσοχής πολλαπλών κεφαλών και κανονικοποιούνται για να σταθεροποιηθεί και επιταχυνθεί η εκπαίδευση. Στη συνέχεια αυτή η έξοδος εισέρχεται σε ένα μη γραμμικό πλήρες συνδεδεμένο προωθητικό επίπεδο (*Fully connected feed-forward layer – FC*) και έπειτα λαμβάνεται ξανά το άθροισμα της με την έξοδο του FC επιπέδου και κανονικοποιούνται. Η συνολική έξοδος του κωδικοποιητή αποτελεί ένα διάνυσμα αναπαράστασης εισόδου με ενσωματωμένη τη εστίαση και σχηματίζει τους πίνακες K και V του δεύτερου επιπέδου προσοχής πολλαπλών κεφαλών. Τέλος αξίζει να αναφερθεί πως η συνολική αρχιτεκτονική του κωδικοποιητή αποτελείται από πολλαπλά τέτοια πανομοιότυπα μπλοκ στοιβαγμένα μαζί, που η έξοδος του ενός είναι η είσοδος του άλλου, ώστε να αυξηθεί η εκφραστική ισχύς του.

- Αποκωδικοποιητής (Decoder) :

Σε ένα μπλοκ αποκωδικοποιητή η λογική είναι παρόμοια με τον κωδικοποιητή όπου λαμβάνει το διάνυσμα αναπαράστασης εισόδου, το προωθεί σε ένα επίπεδο προσοχής πολλαπλών κεφαλών με μάσκα και πραγματοποιεί πρόσθεση μεταξύ αυτού και της εξόδου του επιπέδου προσοχής και κανονικοποίηση του αθροίσματος. Εδώ η μάσκα χρησιμοποιείται για να μην εισάγεται προσοχή στις

μελλοντικές τιμές και υπάρχει διαρροή δεδομένων από το μέλλον κατά τη διάρκεια της εκπαίδευσης. Στη συνέχεια η διαδικασία αυτή επαναλαμβάνεται αλλά με ένα επίπεδο προσοχής πολλαπλών επιπέδων στο οποίο δεν υπάρχει μάσκα και οι πίνακες K και V προκύπτουν από την έξοδο του κωδικοποιητή. Τέλος έξοδος του αποκωδικοποιητή προκύπτει όπως και στον κωδικοποιητή με τη χρήση ενός μη γραμμικού FC επιπέδου από το οποίο λαμβάνεται το κανονικοποιημένο άθροισμα της εισόδου και της εξόδου του. Όπως και ο κωδικοποιητής η συνολική αρχιτεκτονική περιλαμβάνει πολλαπλά πανομοιότυπα μπλοκ στοιβαγμένα μαζί.

- Έξοδος Μετασχηματιστή (Transformer Output) :

$$Z_{linear} = Z_{decoder} \cdot W_{linear} + b_{linear}$$

1. W_{linear} : Πίνακας σταθμισμένων όρων γραμμικού FC επιπέδου με διάσταση (d_{model}, d_{out})
2. b_{linear} : Πίνακας όρων μεροληψίας με διάσταση (d_{out})
3. d_{out} : Η διαστατικότητα της εξόδου (Ορίζοντας πρόβλεψη)
4. Z_{linear} : Οι προβλεπόμενες τιμές

Η έξοδος του αποκωδικοποιητή εισάγεται σε ένα γραμμικό FC επίπεδο και από αυτό παράγεται η συνεχής έξοδος του αν είναι συνεχόμενη πρόβλεψη ή εφαρμόζεται η συνάρτηση SoftMax αν πρόκειται για πιθανοτική πρόβλεψη.

Όπως προαναφέρθηκε τα μοντέλα Μετασχηματιστών μέσω των μηχανισμών προσοχής επεξεργάζονται παράλληλα τα δεδομένα το οποίο είναι ιδιαίτερα αποτελεσματικό για μεγάλες χρονοσειρές και έχουν τη δυνατότητα να αντιλαμβάνονται εξαρτήσεις μεγάλης εμβέλειας [4] [41]. Επίσης διαχειρίζονται εξαιρετικά πολλαπλές μεταβλητές εισόδου που τα καθιστά πολύτιμα σε προβλήματα που επηρεάζονται από ποικίλους παράγοντες όπως η πρόβλεψη κατανάλωσης ενώ έχουν μεγάλη προσαρμοστικότητα αφού μπορούν να εφαρμοστούν σε πολλά και διαφορετικά προβλήματα αλλά και συνδυαστικά με άλλα μοντέλα ως κομμάτι υβριδικής αρχιτεκτονικής [63] [64]. Ωστόσο έχουν υπολογιστικά ακριβή εκπαίδευση, ιδιαίτερα για μεγάλες ακολουθίες

δεδομένων, είναι ευαίσθητα στην ρύθμιση των υπερπαραμέτρων τους και λόγω της ικανότητας τους να επεξεργάζονται όλα τα δεδομένα παράλληλα ενδεχομένως να παραβλέψουν κοντινές χρονικές εξαρτήσεις που είναι χρήσιμες για βραχυπρόθεσμες προβλέψεις [63] [64]. Σε αυτή τη διπλωματική εργασία θα χρησιμοποιηθεί ένα μοντέλο μετασχηματιστή που ονομάζεται Μετασχηματιστής Συγχώνευσης Χρόνου (Temporal Fusion Transformer – TFT).

2.1.4 Σχετικές έρευνες στην πρόβλεψη ενεργειακού φορτίου

Τα μοντέλα που παρουσιάστηκαν ως τώρα έχουν αρκετές εφαρμογές στον τομέα των προβλέψεων αλλά αυτή που μας απασχολεί ιδιαίτερα είναι η πρόβλεψη ηλεκτρικού φορτίου σε κτίρια.

Πίνακας 2.1: Σχετικές έρευνες στην πρόβλεψη ενεργειακού φορτίου

Συγγραφείς	Έτος	Αρχιτεκτονική Μοντέλου	Διάστημα Πρόβλεψης	Ορίζοντας Πρόβλεψης
(Wang) [65]	2012	MLR	1 Χρόνος	1 Χρόνος
(Chujai et al.) [66]	2013	ARMA, ARIMA	1 Ημέρα, 1 Εβδομάδα, 1 μήνα, 4 μήνες	42 Μέρες, 30 Εβδομάδες, 10 Μήνες, 4 Τετράμηνα
(Twanabasu et al.) [67]	2013	SARIMA, SVR, MLP	1 Ώρα	1 Ώρα
(Massana et al.) [68]	2015	MLR, SVR, MLP	1 Ώρα	1 Ώρα
(Moon et al.) [69]	2018	MLP, RF (ensemble)	1 Ημέρα	1 Εβδομάδα
(Silva et al.) [70]	2019	RF, GBRT, AdaboostR2	1 Ώρα	1 Ώρα
(Cai et al.) [71]	2019	SARIMAX, RNN, CNN	1 Ώρα	1 Ώρα, 24 Ώρες
(Kong et al.) [72]	2019	LSTM	30 Λεπτά	30 Λεπτά
(Zhang et al.) [73]	2020	LSTM-GBM hybrid	15 Λεπτά	1 Ώρα
(Alhussein et al.) [74]	2020	CNN-LSTM hybrid	30 Λεπτά	30 Λεπτά, 1 Ώρα, 3 Ώρες
(Kim et al.) [75]	2021	Attention-LSTM	1 Ώρα	24 Ώρες
(Wang et al.) [76]	2022	Transformer	1 Ώρα	24 Ώρες

Με τη πάροδο του χρόνου έχουν διεξαχθεί πολλές έρευνες που πειραματίστηκαν με διάφορες αρχιτεκτονικές μοντέλων με σκοπό τις

προβλέψεις ενεργειακού φορτίου κτηρίων ώστε να ελεγχθεί η αποτελεσματικότητά τους και στον πίνακα 2.1 έχουν συλλεχθεί ορισμένες από αυτές. Συγκεκριμένα ο Wang χρησιμοποίησε το 2012 δύο μοντέλα MLR με τα οποία, συνυπολογίζοντας εξωγενείς παράγοντες, εκτέλεσε προβλέψεις για την μέση ετήσια ενεργειακή κατανάλωση ενός ξενοδοχείου στο Ταϊβάν [65]. Ένα χρόνο μετά οι (Chujai et al.) έδειξαν ότι στην πρόβλεψη κατανάλωσης ατομικού νοικοκυριού το μοντέλο ARMA ήταν αποτελεσματικότερο από το ARIMA όταν ο προβλεπτικός ορίζοντας είναι στα πλαίσια ημέρας ή εβδομάδας και το ARIMA το είναι πιο αποτελεσματικό σε μηνιαίες και 4μηνιαίες προβλέψεις [66]. Παράλληλα οι (Twanabasu et al.) σύγκριναν την απόδοση των μοντέλων SVR και MLP με του SARIMA σε πρόβλεψη κατανάλωσης της επόμενης ώρας ενός πανεπιστημιακού κτηρίου στην Νορβηγία αναδεικνύοντας το MLP ως το καλύτερο εκ των τριών [67]. Δύο χρόνια αργότερα σε αντίστοιχο πανεπιστημιακό κτήριο στην Ισπανία οι (Massana et al.) σύγκριναν τις δυνατότητες των ίδιων μοντέλων με αυτές του MLR στον ίδιο προβλεπτικό ορίζοντα, λαμβάνοντας όμως υπόψη και εξωτερικούς παράγοντες όπως θερμοκρασία και περιόδους διακοπών, επαληθεύοντας την ισχυρή προβλεπτική ικανότητα της νευρωνικής αρχιτεκτονικής του MLP [68]. Συνεχίζοντας το 2018 σε έναν πανεπιστημιακό χώρο στη Κορέα οι (Moon et al.) συλλέξαν ωριαία δεδομένα ενεργειακής κατανάλωσης, καιρικών χαρακτηριστικών και ιδιαίτερων συμβάντων από σύνολο διαφορετικών κτηρίων όπως βιβλιοθήκες, εργαστήρια και φοιτητικές εστίες με σκοπό τη σύγκριση των προβλέψεων ενός απλού MLP με αυτές ενός υβριδικού μοντέλου RF-MLP, που αξιοποιεί τη μέθοδο των τυχαίων δέντρων για την επιλογή χαρακτηριστικών και το MLP για τη πρόβλεψη, παρουσιάζοντας 7% βελτίωση μέσω της υβριδικής προσέγγισης [69]. Αργότερα εκμεταλλευόμενοι την λογική προσεγγίσεων συνόλου και ενίσχυσης οι (Silva et al.) αξιοποίησαν τα μοντέλα RF, AdaBoost και Gradient-Boost Random Trees για να εκτελέσουν προβλέψεις επόμενης ώρας σε κτήριο γραφείων πανεπιστημίου στη Πορτογαλία οι οποίες αποτύπωσαν την υπεροχή του μοντέλου AdaBoost κατά 11,3% και 6.5% έναντι των RF και GBRT αντίστοιχα [70]. Από την άλλη οι (Cai et al.) πειραματίστηκαν με τις αρχιτεκτονικές των RNN και CNN και τις τροποποίησαν μέσω μηχανισμών πυλών (Gated-RNN και Gated-CNN) για να εκτελέσουν ωριαίες προβλέψεις ενεργειακής κατανάλωσης επόμενης μέρας σε εμπορικά κτήρια στις ΗΠΑ.

Θεωρώντας την απόδοση του στατιστικού μοντέλου SARIMAX ως σημείο αναφοράς τα GCNN και GRNN σημείωσαν σημαντική βελτίωση ενώ αποδοτικότερη αποδείχτηκε η συνελικτική λύση κατά 15% [71]. Παράλληλα στην έρευνα των (Kong et al.) το LSTM αποδείχτηκε εμφανώς αποδοτικότερο από άλλα εμπειρικά μοντέλα και συμβατικά ANNs στην πρόβλεψη ενεργειακού φορτίου μεμονωμένων κτηρίων και ομάδων κτιρίων στην Αυστραλία παρουσιάζοντας 7.4%-17.2% και 19.2%-33.7% πτώση σφάλματος αντίστοιχα [72]. Ένα χρόνο αργότερα οι (Zhang et al.) και οι (Alhussein et al.) υλοποίησαν τα υβριδικά μοντέλα LSTM-GBM και LSTM-CNN και απέδειξαν τις δυνατότητες που κρύβονται στην αξιοποίηση πολλαπλών μοντέλων στην ίδια αρχιτεκτονική σε σύγκριση με τη μεμονωμένη απόδοση τους σε βραχυπρόθεσμες προβλέψεις ενεργειακού φορτίου [73] [74]. Άλλη μια υβριδική αρχιτεκτονική που αξίζει αναφορά είναι στην έρευνα των (Kim et al.) οι οποίοι εισήγαγαν ένα μοντέλο κωδικοποιητή-αποκωδικοποιητή στο οποίο ενσωμάτωσαν μηχανισμούς προσοχής και επίπεδα LSTM, με σκοπό την ωριαία πρόβλεψη ενεργειακής κατανάλωσης επόμενης μέρας σε προσομοιωμένα και πραγματικά δεδομένα ενός εταιρικού κτηρίου στη Νότια Κορέα, επιβεβαιώνοντας την εξαιρετική του ικανότητα να εστιάζει στα σημαντικά χαρακτηριστικά και να ανιχνεύει εξαρτήσεις μεγάλης εμβέλειας [75]. Τέλος το 2022 οι (Wang et al.) εφάρμοσαν την αρχιτεκτονική του Μετασχηματιστή στην προσπάθεια ωριαίων προβλέψεων ενεργειακού φορτίου επόμενης μέρας συνυπολογίζοντας εξωγενείς παράγοντες σε κτήρια ενός πανεπιστημιακού χώρου στην Αριζόνα και πέτυχαν μια εξαιρετική πτώση σφάλματος 70% σε σχέση με άλλα μοντέλα όπως LSTM, RF, SVR.

Οι μελέτες που αναλύθηκαν παρουσίασαν μια ευρεία γκάμα μοντέλων προς εφαρμογή στην πρόβλεψη ενεργειακού φορτίου κτηρίων, με το κάθε ένα να αναδεικνύει τις ικανότητες του σε συγκεκριμένες περιπτώσεις χρήσης. Ωστόσο παρά τις εξελίξεις στον σχεδιασμό των αρχιτεκτονικών υπάρχει ακόμα μια κρίσιμη πρόκληση που παραμένει και εμποδίζει σε ένα βαθμό όλες τις προσεγγίσεις της μηχανικής και ιδιαίτερα βαθιάς μάθησης: η περιορισμένη διαθεσιμότητα λεπτομερών δεδομένων υψηλής ποιότητας και ιδιαίτερα σε ποικιλία τύπων κτιρίων και περιοχών.

2.2 Μεταφορά Μάθησης : Μια λύση στο πρόβλημα της έλλειψης δεδομένων

Αποτελεί γεγονός η εξαιρετική επιτυχία που έχουν σημειώσει οι τεχνολογίες μηχανικής και βαθιάς μάθησης στο να προσφέρουν αποδοτικές λύσεις σε μια ευρεία ποικιλία σύγχρονων προβλημάτων, ένα εκ των οποίων είναι και η ανάλυση χρονοσειρών. Όμως οι ικανότητες τους πηγάζουν από την εκπαίδευση τους η οποία πραγματοποιείται πάνω σε επισημασμένα δείγματα ενός ήδη συλλεγμένου και επεξεργασμένου συνόλου δεδομένων εκπαίδευσης (training data). Έπειτα τα εκπαιδευμένα μοντέλα διατηρώντας τη γνώση που αποκόμισαν από αυτό το σύνολο εξετάζονται σε ένα άλλο με προηγουμένως άγνωστα δεδομένα, το σύνολο δεδομένων δοκιμής (test data), με σκοπό να δοκιμαστούν οι προβλεπτικές ικανότητες τους. Η επιτυχία τους λοιπόν είναι λογικό να εξαρτάται σε μεγάλο βαθμό από την διάρκεια και ποιότητα της εκπαίδευσης, κάτι που οφείλεται αμιγώς στη ποσότητα και ποιότητα των δεδομένων εκπαίδευσης, αλλά ταυτόχρονα περιορίζεται από την υπόθεση ότι ο χώρος χαρακτηριστικών (feature domain) και η στατιστική κατανομή των δεδομένων (data distribution) στο σύνολο εκπαίδευσης και δοκιμής είναι πανομοιότυπα [77]. Ωστόσο σε πραγματικές συνθήκες αυτή η υπόθεση παραβιάζεται συχνά καθώς μπορεί να διαφέρουν αρκετά στοιχεία μεταξύ εκπαίδευσης και δοκιμής δημιουργώντας προβλήματα στην εκπαίδευση μοντέλων σε αυτές τις περιπτώσεις αυξάνοντας την ανάγκη για την εύρεση μιας λύσης.

2.2.1 Εισαγωγή στη μεταφορά μάθησης

Αυτή η λύση προέκυψε από τη παρατήρηση ότι η γνώση που απαιτείται για να επιλυθεί ένα πρόβλημα στο οποίο δεν υπάρχει διαθέσιμο εκπαιδευμένο μοντέλο ενδεχομένως να υπάρχει σε μια τροποποιημένη μορφή της μέσω πιθανών εκπαιδευμένων μοντέλων που επιλύουν παρόμοια προβλήματα. Για παράδειγμα μπορεί να μην υπάρχει διαθέσιμη η γνώση για την ταξινόμηση

φωτογραφιών που περιέχουν αφέψημα αλλά να υπάρχει ένα εκπαιδευμένο συνελκτικό δίκτυο που διαθέτει την γνώση για την ταξινόμηση φωτογραφιών που περιέχουν φαγητά. Αυτό το είδος γνώσης αν και όχι αυτό που απαιτείται αποτελεί αρκετά συγγενική γνώση στο σημείο που μπορεί να αξιοποιηθεί για το τρέχον ζήτημα. Έτσι λοιπόν προέκυψε ο όρος της Μεταφοράς Μάθησης (Transfer Learning) που στοχεύει στη βελτίωση της πρόβλεψης ενός μοντέλου μηχανικής μάθησης σε ένα στοχευμένο πρόβλημα αξιοποιώντας τη γνώση ενός διαφορετικού εκπαιδευμένου μοντέλου το οποίο πραγματοποιεί αποδοτικές προβλέψεις σε ένα άλλο συγγενικό πρόβλημα [77] [78].


Η προέλευση της έννοιας της μεταφοράς μάθησης

Η διαδικασία αυτή έχει εμπνευστεί αντλώντας πληροφορίες από θεμελιώδεις αρχές της γνωσιακής επιστήμης σύμφωνα με τις οποίες οι άνθρωποι γενικεύουν γνώσεις που απέκτησαν στο παρελθόν για να αντιμετωπίσουν νέα προβλήματα καθώς αυτό αποτελεί πιο άμεση και αποδοτική αντιμετώπιση συγκριτικά με την προσπάθεια εκμάθησης νέων πληροφοριών από το μηδέν [77]. Οι πρώτες έρευνες στη μεταφορά μάθησης επικεντρώθηκαν στη βελτίωση της απόδοσης μέσω επαναχρησιμοποιούμενης γνώσης βασιζόμενες σε μελέτες για την επαγωγική μεταφορά (inductive transfer) και την διατομεακή προσαρμογή (cross-domain adaptation) [77] [79]. Ωστόσο μέσω τεχνικών ενισχυτικής μάθησης ορίστηκαν τα θεμέλια για την ανάπτυξη και περαιτέρω εξέλιξη του όρου. Σε αυτόν το τομέα μάθησης ένα σύστημα προσπαθεί να μάθει μέσα από την άμεση αλληλεπίδραση με το περιβάλλον ενώ ορίζονται πολιτικές μάθησης (learning policies) που απεικονίζουν συγκεκριμένες καταστάσεις του περιβάλλοντος σε αντίστοιχες ενέργειες. Έτσι λοιπόν για την αντιμετώπιση συγκεκριμένων προβλημάτων επιχειρήθηκε επιτυχώς η αξιοποίηση πολιτικών μάθησης που εφαρμόστηκαν σε συγγενικά προβλήματα αποδεικνύοντας την ευρηματικότητα και αποτελεσματικότητα μιας τέτοιας μεθοδολογίας [77]. Μεταγενέστερα η άνοδος της βαθιάς μάθησης εισήγαγε την εκπαίδευση μοντέλων σε μεγάλα σύνολα δεδομένων η οποία απαιτούσε ιδιαίτερα μεγάλο υπολογιστικό κόστος αν πραγματοποιούνταν από την αρχή. Έτσι η ιδέα της μεταφοράς μάθησης αποτέλεσε μια εξέχουσα εναλλακτική μέθοδο με ελάχιστο κόστος, ιδιαίτερα σε εφαρμογές όπως ταξινόμηση εικόνας και επεξεργασία

φυσικής γλώσσας [77] [79] [80]. Με την άνοδο αυτών των υπολογιστικών προκλήσεων, οι ερευνητές αναζήτησαν τρόπους για την αξιοποίηση προεκπαιδευμένων μοντέλων οδηγώντας στη διαμόρφωση των αρχών της μεταφοράς μάθησης.

Πώς ορίζεται η μεταφορά μάθησης

Η μεταφορά μάθησης έχει επίσημα οριστεί ως μια μέθοδος μηχανικής μάθησης, όπου η γνώση που αποκτήθηκε από ένα πηγαίο τομέα (source domain) ή εργασία (source task) επαναχρησιμοποιείται για τη βελτίωση της εκμάθησης σε ένα άλλο σχετικό στοχευμένο τομέα (target domain) ή καθήκον (target task). Όπως φαίνεται και στην Εικόνα 2.10 αυτό επιτυγχάνεται μέσω της



Εικόνα 2.10 : Αριστερά – Παραδοσιακές μέθοδοι μηχανικής μάθησης. Δεξιά – Μέθοδος μηχανικής μάθησης [78]

αξιοποίησης κοινών δομών, όπως χαρακτηριστικά, μοτίβα ή αναπαραστάσεις μεταξύ των τομέων. Η διαδικασία όπως αναφέρθηκε βασίζεται σε δυο στοιχεία, τον τομέα και το καθήκον, τα οποία πρέπει να οριστούν με σαφήνεια. Ένας τομέας (Domain) εκφράζεται ως εξής:

$$D = \{X, P(x)\}$$

όπου:

- X : Χώρος χαρακτηριστικών
- $x = \{x_1, x_2, \dots, x_n\} \in X$: Σύνολο χαρακτηριστικών ενός δείγματος
- $P(x)$: Οριακή κατανομή πιθανότητας των δεδομένων

Ταυτόχρονα μια εργασία (task) αποτυπώνεται ως :

$$T = \{Y, f(.)\}$$

όπου :

- Y : Χώρος ετικετών
- $f(.)$: Μια προβλεπτική συνάρτηση για ένα συγκεκριμένο στόχο

Έτσι λοιπόν δεδομένου ενός τομέα $D = \{X, P(x)\}$ και μιας εργασίας $T = \{Y, f(.)\}$ τότε τα δειγματικά δεδομένα αποτελούνται από ζεύγη $\{x_i, y_i\}$ όπου $x_i \in X$ και $y_i \in Y$ και η προβλεπτική συνάρτηση στοχεύει να μάθει τις ετικέτες που αντιστοιχούν σε αυτά τα δεδομένα με σκοπό να προβλέψει τις ετικέτες σε νέα και προηγουμένως άγνωστα. Επομένως η f θεωρείται η υπό όρους κατανομή των δειγμάτων και γράφεται ως $f(x) = P(y|x)$. Έτσι λοιπόν δεδομένου ενός πηγαίου τομέα D_S με την αντίστοιχη συνοδευόμενη εργασία T_S και προβλεπτική συνάρτηση $f_S(.)$ και ενός διαφορετικού στοχευμένου τομέα D_T με εργασία T_T και συνάρτηση $f_T(.)$ τότε η μεταφορά μάθησης στοχεύει στην μεταβίβαση της σχετικής γνώσης που εμπεριέχεται στα $D_S, T_S, f_S(.)$ ώστε να αυξηθεί η απόδοση της στοχευμένης προβλεπτικής συνάρτησης $f_T(.)$ στα D_T, T_T [77]. Ωστόσο η διαφορά μεταξύ πηγαίου και στοχευμένου περιβάλλοντος μπορεί να ποικίλει σε είδος και ποσότητα ενώ ο βαθμός ομοιότητας τομέων και εργασιών είναι ο κύριος παράγοντας επιτυχίας της μεθόδου μεταφοράς μάθησης [77] [78].

Τα οφέλη της μεταφοράς μάθησης

Η εφαρμογή της σε διάφορα προβλήματα έχει επιτρέψει στα μοντέλα να γενικεύουν αποτελεσματικά τις προβλέψεις τους μεταξύ τομέων με διαφορετικές κατανομές δεδομένων ή εργασίες και τα οφέλη της είναι πολλά [77]. Υπάρχουν πολλές περιπτώσεις στις οποίες η συλλογή μεγάλων επισημασμένων συνόλων δεδομένων είναι δύσκολη ή ανέφικτη. Αξιοποιώντας γνώση από προεκπαιδευμένα μοντέλα, μέσω μεταφοράς μάθησης επιτυγχάνονται αποδοτικές και εύστοχες προβλέψεις ακόμα και με ελάχιστα επισημασμένα δεδομένα στο στοχευμένο τομέα [78] [81]. Ταυτόχρονα όταν τα

διαθέσιμα δεδομένα είναι λίγα και θορυβώδη αυξάνεται η πιθανότητα υπερπροσαρμογής ενός μοντέλου προς εκπαίδευση, κάτι που αποφεύγεται όταν παρέχεται μια ισχυρή αρχικοποίηση των παραμέτρων του μέσω μεταφερόμενης γνώσης [77] [82]. Από την άλλη όταν τα δεδομένα είναι διαθέσιμα η διαδικασία εκπαίδευσης ενός μοντέλου εκ νέου είναι χρονοβόρα και επιφέρει υπολογιστικό κόστος, πράγμα που αποφεύγεται σε μεγάλο βαθμό μεταφέροντας ήδη υπάρχουσα γνώση [78][80]. Τέλος αξιοσημείωτη είναι και η ικανότητα αυτής της μέθοδου να κλιμακώνεται αποδοτικά σε εργασίες που απαιτούν περίπλοκη εξαγωγή χαρακτηριστικών όπως η ταξινόμηση εικόνας ή η ανάλυση συναισθήματος [79].

Η μεταφορά μάθησης στην ανάλυση χρονοσειρών

Όσο το ενδιαφέρον για την βαθιά μάθηση ολοένα και αυξάνεται έχουν αναλυθεί περιπτώσεις χρήσης μεθόδων μεταφοράς μάθησης κυρίως σε τομείς όπως όραση υπολογιστών και επεξεργασία φυσικής γλώσσας με την ανάλυση χρονοσειρών να αποτελεί ένα νέο μέτωπο έρευνας [83]. Αποτελεί ένα χώρο εργασιών κύριου ενδιαφέροντος και θέτει ιδιαίτερες προκλήσεις κυρίως λόγω της ακολουθιακής φύσης των δεδομένων και των μεταβαλλόμενων στατιστικών χαρακτηριστικών τους μεταξύ τομέων. Τα δεδομένα δυο ξεχωριστών τομέων σε αυτή τη περίπτωση διαθέτουν διαφορετικές χρονικές εξαρτήσεις και μοτίβα που οφείλονται στα διαφορετικά χαρακτηριστικά και στις διαφορετικές κατανομές των δεδομένων. Η μεταφορά μάθησης στοχεύει να ευθυγραμμίσει αυτές τις χρονικές εξαρτήσεις και τα μοτίβα μεταξύ τομέων. Έτσι οι διαθέσιμες γνωστές χρονικές αναπαραστάσεις ενός τομέα μπορούν να αξιοποιηθούν για την πρόβλεψη σε νέες εργασίες ή τομείς που είτε έχουν έλλειψη δεδομένων είτε το υπολογιστικό κόστος εκ νέου εκπαίδευσης μοντέλου είναι υψηλό [77] [82] [83]. Για παράδειγμα στην πρόβλεψη φορτίου η γνώση που προκύπτει από κτίρια με εκτεταμένη ποιοτική παρακολούθηση μπορεί να «μεταφερθεί» για τη βελτίωση των προβλέψεων σε κτίρια που χαρακτηρίζονται από έλλειψη δεδομένων [82]. Συνολικά η διαθεσιμότητα μοντέλων που έχουν προεκπαιδευτεί σε γενικευμένα ακολουθιακά μοτίβα μπορεί με ελάχιστη εκπαίδευση και περαιτέρω προσαρμογή να είναι πλήρως ικανά και εξαιρετικά αποδοτικά στο να εκτελέσουν στοχευμένες εργασίες που απαιτούν διαχείριση μη στάσιμων

δεδομένων με χρονικές εξαρτήσεις μακράς εμβέλειας [81] [82].

2.2.2 Τεχνικές μεταφοράς μάθησης

Στη μεταφορά μάθησης έχουν προταθεί αρκετές τεχνικές για την επιτυχή αξιοποίηση διαθέσιμης γνώσης σε πολλά διαφορετικά προβλήματα και έχουν σχεδιαστεί προσπαθώντας να απαντήσουν σε τρία κύρια επιστημονικά ερωτήματα: τι, πώς και πότε να μεταφέρω τη γνώση [78];

Συγκεκριμένα η ερώτηση «τι να μεταφέρω» αφορά ποια χαρακτηριστικά της γνώσης θα μεταφερθούν ανάμεσα σε τομείς ή εργασίες καθώς σε αρκετές περιπτώσεις μέρος της πληροφορίας ενός τομέα αφορά συγκεκριμένα αυτόν ενώ άλλα πρέπει να μεταφερθούν καθώς είναι ικανά να αυξήσουν την απόδοση μεταφοράς. Ωστόσο ακόμα και αν είναι γνωστά ποια κομμάτια της γνώσης θα μεταφερθούν πρέπει να υλοποιηθούν και μέθοδοι με τους οποίους θα γίνει η μεταφορά σωστά και χωρίς να χαθεί πληροφορία, πράγμα που συσχετίζεται με την ερώτηση «πώς να το μεταφέρω». Τέλος η ερώτηση «πότε να το μεταφέρω» είναι εξίσου σημαντική καθώς υπάρχουν περιπτώσεις στις οποίες οι τομείς σχετίζονται ελάχιστα ή και καθόλου και όποια προσπάθεια μεταφορά μάθησης θα οδηγήσει σε αποτυχία. Σε ορισμένες περιπτώσεις μπορεί να οδηγήσει σε βλάβη στην εκπαίδευση ενός μοντέλου στο στοχευμένο τομέα, ένα φαινόμενο που ονομάζεται «αρνητική μεταφορά» (negative transfer) [78].

Κύριες κατηγορίες μεταφοράς μάθησης

Για να υφίσταται η ανάγκη μεταφοράς γνώσης μεταξύ εργασιών ή τομέων θα πρέπει να είναι διαφορετικοί οι τομείς ή οι εργασίες. Ταυτόχρονα ανάλογα τη περίπτωση μπορεί να διαφέρει η διαθεσιμότητα ετικετών στα σύνολα δεδομένων του πηγαίου και στοχευμένου τομέα διακρίνοντας τρεις κύριες κατηγορίες μεταφοράς μάθησης: την επαγωγική, διαγωγική και μη επιβλεπόμενη [77] [78] [83]. Όπως φαίνεται και στην Εικόνα 2.11 διακρίνονται οι κύριες κατηγορίες ενώ η διαθεσιμότητα ετικετών στο στοχευμένο τομέα καθιστά την μεταφορά μάθησης ενημερωμένη (informed) ή μη (uninformed).

Information	Labeled Source Domain	Labeled Target Domain	Problem Setting	Data Mining Tasks
Informed	✓	✓	Inductive TL	Classification, Regression
	x	✓		
Uninformed	✓	x	Transductive TL	Clustering, Dimensionality Reduction
	x	x	Unsupervised TL	

Εικόνα 2.11 : Κατηγορίες μεταφοράς μάθησης [83]


Η επαγωγική (inductive) μεταφορά μάθησης υφίσταται όταν υπάρχουν επισημασμένα δεδομένα στο στοχευμένο τομέα τα οποία αξιοποιούνται για την εκμάθηση συγκεκριμένων εργασιών. Σε αυτή τη κατηγορία η στοχευμένη εργασία διαφέρει με τη πηγαία ενώ οι τομείς μπορούν να είναι ίδιοι ή διαφορετικοί. Είναι χρήσιμη σε περιπτώσεις που οι εργασίες χαρακτηρίζονται από ορισμένες δομικές ή και σημασιολογικές ομοιότητες αλλά υπάρχει ο κίνδυνος υπερπροσαρμογής ιδιαίτερα όταν τα επισημασμένα δεδομένα στον στοχευμένο τομέα είναι λίγα. Οι τεχνικές που ανήκουν σε αυτή τη κατηγορία εφαρμόζονται πολύ συχνά σε προβλήματα βελτιστοποίησης και ταξινόμησης [77] [83].

Από την άλλη η διαγωγική (transductive) μεταφορά μάθησης είναι μια κατηγορία που αντιμετωπίζει τις περιπτώσεις στις οποίες οι εργασίες είναι ίδιες και οι τομείς διαφέρουν μεταξύ τους με τη διαθεσιμότητα επισημασμένων δεδομένων να περιορίζεται στον πηγαίο τομέα. Στόχος σε αυτό το είδος μεταφοράς μάθησης είναι η ευθυγράμμιση των διαφορετικών τομέων με συγκεκριμένες μεθόδους ώστε να δημιουργηθούν μοντέλα με γενικευμένη εκπαίδευση που προσαρμόζονται σε νέες κατανομές δεδομένων [78] [83]. Ωστόσο αν οι 2 τομείς είναι πολύ διαφορετικοί και δεν ευθυγραμμιστούν σωστά υπάρχει ο κίνδυνος αρνητικής μεταφοράς ενώ όπως και στην επαγωγική μεταφορά μάθησης οι συνήθεις εφαρμογές αφορούν εργασίες βελτιστοποίησης και ταξινόμησης.

Τέλος η μη επιβλεπόμενη (unsupervised) μεταφορά μάθησης εμπεριέχει, σε αντίθεση με τις προηγούμενες δυο κατηγορίες, περιπτώσεις στις οποίες δεν υπάρχουν επισημασμένα δεδομένα σε κανένα τομέα συμπεριλαμβανομένων

σεναρίων όπως διαφορετικοί τομείς με ίδιες εργασίες και το αντίστροφο. Αυτές εστιάζουν περισσότερο στη μεταφορά μοτίβων, δομών ή αναπαραστάσεων για την υποβοήθηση μη επιβλεπόμενων εργασιών στο στοχευμένο τομέα, η οποία διασφαλίζεται με ευθυγράμμιση των κατανομών των χαρακτηριστικών ανάμεσα στους δυο τομείς [77]. Συνήθεις εργασίες της κατηγορίας αποτελούν η συσταδοποίηση και η μείωση διαστατικότητας.

Εκτός από την ύπαρξη ετικετών στους τομείς ενδιαφέροντος άλλο ένα χαρακτηριστικό που ομαδοποιεί τις τεχνικές μεταφοράς μάθησης είναι η ομοιότητα του χώρου χαρακτηριστικών (X_S, X_T) και ετικετών (Y_S, Y_T). Αν πρόκειται για όμοιους χώρους τότε πραγματοποιείται ομογενής μεταφορά μάθησης (Homogeneous) ενώ αν είναι διαφορετικοί τότε είναι ετερογενής (Heterogeneous) [83]. Επίσης η προσέγγιση με την οποία πραγματοποιείται η



Εικόνα 2.12 : Απεικόνιση προσεγγίσεων μεταφοράς μάθησης [83]

μεταφορά γνώσης είναι ενδεικτικός παράγοντας ομαδοποίησης όπως φαίνεται και στην εικόνα 2.12. Η κύρια διαφορά αποτελεί το «σημείο» στο οποίο θα αναζητήσει κάποιος τη γνώση. Η εστίαση μπορεί να πραγματοποιηθεί κατευθείαν στην αρχιτεκτονική και στον τρόπο που έχει εκπαιδευτεί ένα μοντέλο (Model-based), στους χώρους χαρακτηριστικών και των κατανομών τους (Feature-based), σε δείγματα εισόδου των δυο τομέων (Instance-based) και σε γενικές γνώσεις που συνδέουν τους δυο τομείς ή εργασίες (Relational-Knowledge-based).

Τεχνικές μεταφοράς μάθησης βασιζόμενες σε μοντέλα (Model-based)

Συγκεκριμένα από τις πιο διαδεδομένες είναι οι προσεγγίσεις που εστιάζουν στο ίδιο το μοντέλο οι οποίες μάλιστα ομαδοποιούνται εκ νέου για μεγαλύτερη κατανόηση.

Αναλυτικότερα ένα είδος μεθόδων επιχειρούν τη μεταφορά της γνώσης που βρίσκεται στις εκπαιδευμένες παραμέτρους (Parameter-based) ενός μοντέλου από ένα πηγαίο τομέα σε ένα στοχευμένο. Συνήθως περιλαμβάνει προσεκτική επιλογή των μεταφερόμενων παραμέτρων από διάφορα επίπεδα ενός μοντέλου «παγώνοντας» (Layer Freezing) τα κατά τη διάρκεια της εκ νέου σύντομης εκπαίδευσης και προσαρμογής του στο στοχευμένο τομέα (Fine-tuning) [77] [83]. Είναι μια πολύ αποδοτική μέθοδος ιδιαίτερα σε περιπτώσεις που το στοχευμένο σύνολο δεδομένων είναι μικρό ενώ μειώνουν αισθητά το υπολογιστικό κόστος και το χρόνο εκπαίδευσης. Ωστόσο απαιτείται προσεκτική επιλογή των παραμέτρων και του χρόνου επανεκπαίδευσης για να αποφευχθεί η υπερπροσαρμογή.

Αντίστοιχα η ανταγωνιστική μάθηση (Adversarial Network) αποτελεί μια τεχνική που επιχειρεί να ελαττώσει την διαφορά μεταξύ των κατανομών δεδομένων στους τομείς κατά τη διάρκεια της εξαγωγής χαρακτηριστικών από αυτά. Συγκεκριμένα μέσω ανταγωνιστικών νευρωνικών δικτύων πραγματοποιείται από κοινού εκπαίδευση ενός εξαγωγέα χαρακτηριστικών (Feature Extractor) με ένα ταξινομητή τομέα (Domain Classifier) σε ένα ανταγωνιστικό πλαίσιο όπου ο εξαγωγέας χαρακτηριστικών προσπαθεί να μάθει χαρακτηριστικά αλληλένδετα με τον τομέα στον οποίο ανήκουν ενώ ο ταξινομητής να τα ταξινομήσει στον αντίστοιχο τομέα [79]. Η ανταγωνιστική μάθηση λειτουργεί με τέτοιο τρόπο ώστε η μάθηση του ενός να μπερδεύει τη μάθηση του άλλου με αποτέλεσμα να μαθαίνονται χαρακτηριστικά τα οποία είναι ανεξάρτητα από τους 2 τομείς διατηρώντας βεβαίως σαν στόχο την πραγματοποίηση της ίδιας εργασίας. Έχει την ικανότητα να μειώσει αποτελεσματικά το κόστος αλλαγής τομέα και είναι ιδιαίτερα ανθεκτική με σύνθετα και μη στάσιμα δεδομένα όπως τα δεδομένα χρονοσειρών [83]. Η ανταγωνιστική εκπαίδευση όμως απαιτεί περίπλοκες αρχιτεκτονικές δικτύων και υψηλούς υπολογιστικούς πόρους ενώ είναι ευαίσθητη στην βελτιστοποίηση των υπερπαραμέτρων καθιστώντας αυτή τη μέθοδο μια σοφή επιλογή όταν

υπάρχει έλλειψη δεδομένων σε ένα στοχευμένο τομέα.

Από την άλλη η μάθηση συνόλου (Ensemble Learning) συνδυάζει τις προβλέψεις από διάφορα, προ-εκπαιδευμένα στο πηγαιό τομέα, μοντέλα για να εκτελέσει προβλέψεις στο στοχευμένο. Τα μοντέλα αυτά μπορούν να αξιοποιηθούν αυτούσια ή έπειτα από μερική προσαρμογή στο στοχευμένο τομέα και οι προβλέψεις τους συνδυάζονται με τεχνικές όπως ο σταθμισμένος μέσος όρος για να διασφαλιστεί μια ισορροπημένη συνεισφορά του κάθε μοντέλου στο τελικό αποτέλεσμα. Η λογική αυτή είναι ευέλικτη και ανθεκτική στην υπερπροσαρμογή καθώς εκμεταλλεύεται διαφορετικές αρχιτεκτονικές μαζί ενώ έχει υψηλή απόδοση λόγω της μεγάλης ικανότητας γενίκευσης των τελικών προβλέψεων [78] [81] [83]. Ταυτόχρονα τα μοντέλα μπορούν να έχουν εκπαιδευτεί σε παραπάνω από ένα πηγαιό τομέα στην οποία υποπερίπτωση πραγματοποιείται μεταφορά μάθησης από πολλαπλές πηγές (Multi-source Ensemble Learning). Βέβαια η εφαρμογή αυτής της μεθόδου προϋποθέτει την διαθεσιμότητα των προεκπαιδευμένων μοντέλων, πράγμα που είναι υπολογιστικά ακριβό, σε συνδυασμό με μια στοιχειώδη ποικιλομορφία και συμπληρωματικότητα των αρχιτεκτονικών τους καθώς παρόμοια μοντέλα μπορεί να αποδειχθούν αχρείαστα προσφέροντας μηδαμινή βελτίωση της απόδοσης [81] [83]. Επίσης προσοχή απαιτείται στον τρόπο που θα καθορίζεται η συνεισφορά της κάθε επιμέρους πρόβλεψης καθώς κάθε μοντέλο μπορεί να έχει διαφορετική μεμονωμένη απόδοση [78]. Αξίζει να αναφερθεί

Τέλος οι μέθοδοι ελέγχου μοντέλου (Model Control Strategies) αποτελούν ειδικές προσεγγίσεις που επεξεργάζονται δυναμικά την αρχιτεκτονική ενός μοντέλου κατά τη διάρκεια της εκπαίδευσης ή της μεταφοράς της γνώσης του ώστε να βελτιστοποιήσουν την απόδοση προβλέψεων στο στοχευμένο τομέα. Αυτές οι προσαρμογές συχνά περιλαμβάνουν αλλαγές στη συνάρτηση απώλειας, το ρυθμό μάθησης ενός μοντέλου ή στην αρχιτεκτονική του δικτύου ώστε να πραγματοποιηθεί επιτυχώς η μεταφορά γνώσης. Ανάλογα τη μέθοδο ελέγχου μπορεί να επιτευχθεί υψηλή προσαρμογή στο στοχευμένο τομέα και να μειωθούν οι πιθανότητες αρνητικής μεταφοράς γνώσης εφόσον δεν μεταφέρονται άσχετα ή παραπλανητικά μοτίβα από το πηγαιό τομέα [83]. Ωστόσο αρκετές τέτοιες μέθοδοι είναι υπολογιστικά ακριβές στην υλοποίηση τους και εμφανίζονται προκλήσεις την βελτιστοποίηση των υπερπαραμέτρων τους ενώ προϋποθέτουν σε βάθος γνώση τόσο του πηγαιού όσο και του

στοχευμένου τομέα, πράγμα που δεν είναι πάντα εφικτό [77] [78] [81].

Τεχνικές μεταφοράς μάθησης βασιζόμενες στα χαρακτηριστικά (Feature-based)

Οι προσεγγίσεις μεταφοράς μάθησης που βασίζονται στα χαρακτηριστικά εισόδου εστιάζουν στους χώρους χαρακτηριστικών μεταξύ πηγαίου και στοχευμένου τομέα με σκοπό την ευθυγράμμιση τους και μπορεί εν μέρει να κατηγοριοποιηθεί περαιτέρω.

Αναλυτικότερα ο συμμετρικός μετασχηματισμός χαρακτηριστικών (Symmetric Feature Transformation) αποτελεί ένα κύριο είδος τέτοιων προσεγγίσεων που στοχεύουν στον μετασχηματισμό των χαρακτηριστικών και των δυο τομέων σε ένα κοινό λανθάνοντα χώρο (latent space) χαμηλών διαστάσεων όπου οι κατανομές τους είναι ευθυγραμμισμένες [77]. Αποτελεί κυρίως προσέγγιση ομογενής μεταφοράς μάθησης και διασφαλίζει την εκπαίδευση σε χαρακτηριστικά που δεν σχετίζονται με κάποιο τομέα αλλά και τη διατήρηση γνώσης σχετικής με τη ζητούμενη εργασία. Απλοποιεί αρκετά την εκπαίδευση μειώνοντας την «απόσταση» των δυο τομέων αλλά η απόδοση του βασίζεται ενεργά στην ποιότητα του λανθάνοντα χώρου [77] [83]. Αξίζει να αναφερθεί πως για αυτό το σκοπό έχουν αξιοποιηθεί μέχρι και ολόκληρα βαθιά νευρωνικά δίκτυα για βαθιά μάθηση χαρακτηριστικών (Deep Feature Learning) τα οποία έχουν τη δυνατότητα να παράξουν χαρακτηριστικά που δεν σχετίζονται με τομέα διατηρώντας την αρχική πληροφορία τους [77]. Ωστόσο προϋποθέτουν την ύπαρξη μεγάλων συνόλων δεδομένων για να εκπαιδευτούν και απαιτούν υψηλό υπολογιστικό κόστος.

Από την άλλη ο ασύμμετρος μετασχηματισμός χαρακτηριστικών (Asymmetric Feature Transformation) στοχεύει στον μετασχηματισμό μόνο των χαρακτηριστικών του πηγαίου τομέα ώστε να «ταιριάζουν» με το χώρο χαρακτηριστικών του στοχευμένου. Αποτελεί κυρίως μέθοδο ετερογενής μεταφοράς μάθησης και επιχειρεί την εκπαίδευση ολοκλήρωσης μιας εργασίας με μετασχηματισμένα πηγαία χαρακτηριστικά που ευθυγραμμίζονται με τα στοχευμένα ώστε να προσομοιωθεί η εκπαίδευση σε αυτόν τον τομέα ακόμα και αν δεν προέρχονται τα δεδομένα από εκεί. Είναι σχεδιασμένη να εστιάζει μόνο στα στοχευμένα χαρακτηριστικά τα οποία μένουν अपαράλλαχτα ενώ

αποφεύγεται η πολύ περίπλοκη επεξεργασία των δεδομένων [83]. Η απόδοση της όμως βασίζεται ενεργά στην υψηλή ποιότητα της συνάρτησης μετασχηματισμού χαρακτηριστικών ενώ μέσω της διαδικασίας προσαρμογής των πηγαίων χαρακτηριστικών στα στοχευμένα είναι πιθανή και η απώλεια πληροφορίας σχετικής με τον πηγαίο τομέα η οποία θα μπορούσε να είναι χρήσιμη για τις προβλέψεις στο στοχευμένο τομέα [77].

Τέλος είναι σχετικά συχνή η χρήση υβριδικών προσεγγίσεων που συνδυάζουν συμμετρικές και ασύμμετρες τεχνικές μετασχηματισμού χαρακτηριστικών αξιοποιώντας τα πλεονεκτήματα και των δυο και περιορίζοντας τους επιμέρους περιορισμούς τους. Έτσι μπορούν να αντιμετωπιστούν διαφορετικοί τύποι ασυμφωνιών μεταξύ των τομέων ταυτόχρονα και να επιτευχθεί καλύτερη γεφύρωση μεταξύ τους [78]. Όμως η πληθώρα μετασχηματισμών επιφέρει υπολογιστικό κόστος και η αρμονική συμπληρωματική εφαρμογή τους απαιτεί ιδιαίτερη προσοχή ώστε οι προσφορές του κάθε μετασχηματισμού να μην αλληλοαναιρούνται [77].

Αξίζει να σημειωθεί πως η μεταφορά γνώσης με τέτοιου είδους τεχνικές από πολλαπλούς πηγαίους τομείς είναι εφικτή και πολλές φορές μπορεί να αποδειχθεί εξαιρετικά αποδοτική.

Τεχνικές μεταφοράς μάθησης βασιζόμενες σε δείγματα εισόδου (Instance-based)

Οι προσεγγίσεις μεταφοράς μάθησης που βασίζονται στα δείγματα εισόδου των τομέων αξιοποιούν την υπόθεση ότι κάποια δείγματα πηγαίας εισόδου είναι πιο σχετικά με τα δείγματα της στοχευμένης εισόδου από άλλα.

Ένα συχνά εφαρμοζόμενο είδος τέτοιων προσεγγίσεων είναι αυτές που βασίζονται στην επαναστάθμιση της πηγαίας εισόδου (Reweighting-Based Approaches). Συγκεκριμένα αναθέτουν σταθμισμένους όρους στα δείγματα της πηγαίας εισόδου ανάλογα τη σχετικότητα τους με το στοχευμένο τομέα. Αυτή η σχετικότητα καθορίζεται μέσω μετρικών ομοιότητας ή συγκεκριμένων τεχνικών ευθυγράμμισης τομέων. Έτσι διασφαλίζουν ότι τα πιο σχετικά δείγματα της πηγαίας εισόδου έχουν τη μεγαλύτερη επιρροή στην εκπαίδευση. Επίσης διατηρούν την ποικιλομορφία των δεδομένων του πηγαίου τομέα ενώ προτιμώνται αρκετά λόγω της απλής υλοποίησής τους [77]. Ωστόσο αν η

διαφορά μεταξύ τομέων είναι μεγάλη τότε είναι αρκετά αναποτελεσματικές ενώ όσο μεγαλύτερο είναι το σύνολο των πηγαίων δεδομένων τόσο πιο υπολογιστικά ακριβές είναι [83].

Παράλληλα σημαντικές είναι και οι προσεγγίσεις που βασίζονται στην επιλογή δειγμάτων εισόδου (Instance Selection-based). Αυτές εστιάζουν στην επιλογή, σχετικών με το στοχευμένο τομέα, δειγμάτων πηγαίας εισόδου. Έπειτα εκπαιδεύεται το εκάστοτε μοντέλο στο σύνολο αυτών και των στοχευμένων δειγμάτων εισόδου αγνοώντας εντελώς τα άσχετα πηγαία δείγματα και βελτιώνοντας έτσι τα αποτελέσματα του λόγω της εστίασης στις σχετικές πληροφορίες. Αυτές οι μέθοδοι είναι ιδιαίτερα εύχρηστες καθώς επιταχύνουν την εκπαίδευση μειώνοντας το μέγεθος του συνόλου δεδομένων και μειώνουν το θόρυβο που θα προερχόταν από τα άσχετα δεδομένα [78]. Παρόλα αυτά όμως περιλαμβάνουν το ρίσκο αποβολής σημαντικής πληροφορίας λόγω πιθανών αυστηρών κριτηρίων επιλογής [77].

Τέλος μεγάλη εφαρμογή συναντάμε και σε προσεγγίσεις που βασίζονται στο μετασχηματισμό των δειγμάτων πηγαίας εισόδου (Instance Transformation-based). Αυτές περιλαμβάνουν μετασχηματισμούς όπως κλιμάκωση, εμπλουτισμό ή προβολή σε νέο λανθάνοντα χώρο των δειγμάτων πηγαίας εισόδου ώστε να ευθυγραμμίζονται με τα δείγματα στοχευμένης εισόδου. Γεφυρώνουν σε ένα βαθμό το κενό μεταξύ τομέων με ελάχιστη απώλεια δεδομένων και μπορούν να φανούν ιδιαίτερα χρήσιμες όταν η επαναστάθμιση ή η επιλογή δειγμάτων εισόδου αποδειχθούν αναποτελεσματικές [77]. Ωστόσο προϋποθέτουν μια σαφώς ορισμένη και εύστοχη συνάρτηση μετασχηματισμού καθώς αν δεν σχεδιαστεί σωστά μπορεί να αλλοιώσει τα μοτίβα πηγαίας εισόδου και να μειώσει την ακρίβεια των προβλέψεων [83]. Όπως και στις άλλες κατηγορίες μεθόδων η αξιοποίηση πολλαπλών πηγαίων τομέων ταυτόχρονα είναι εφικτή.

Τεχνικές μεταφοράς μάθησης βασιζόμενες σε σχεσιακή γνώση (Relational-knowledge-based Transfer Learning Approaches)

Εξίσου σημαντικές είναι και οι προσεγγίσεις που βασίζονται σε σχεσιακές γνώσεις μεταξύ δύο τομέων. Έχουν εφαρμογή σε σχεσιακούς τομείς που περιλαμβάνουν διασυνδεδεμένα ή δομημένα δεδομένα [77]. Αξιοποιούν

σχέσεις μεταξύ των δεδομένων αντί να εστιάζουν σε ανεξάρτητα χαρακτηριστικά ή παραμέτρους, πράγμα που είναι ιδανικό για δεδομένα που δεν είναι ανεξάρτητα και ομοιόμορφα κατανεμημένα [78] [84]. Είναι ιδανικά για εργασίες σε κοινωνικά δίκτυα και διασυνδεδεμένα συστήματα ενώ συναντάμε και εφαρμογές τους παράλληλα με άλλες μεθόδους όταν συγκεκριμένες σχέσεις μεταξύ τομέων είναι γνωστές και αξιοποιήσιμες [77]. Παρόλα αυτά όμως οι σχεσιακοί τομείς συνήθως περιλαμβάνουν περίπλοκες διασυνδέσεις που καθιστούν την εξαγωγή σχέσεων δύσκολη ενώ η λανθασμένη επιλογή σχέσεων προς αξιοποίηση μπορεί να οδηγήσει σε μεταφορά αδιάφορης ή παραπλανητικής γνώσης [83] [84]. Επίσης μια σχετική ομοιότητα μεταξύ τομέων πρέπει να είναι παρούσα για να πετύχει η μεταφορά γνώσης ενώ το υπολογιστικό κόστος που σχετίζεται με τη σχεσιακή μάθηση (Relational Learning) είναι αρκετά υψηλό, ιδιαίτερα για σύνολα δεδομένων μεγάλης κλίμακας [85].

2.2.3 Σχετικές έρευνες στην εφαρμογή τεχνικών μεταφοράς μάθησης για πρόβλεψη ενεργειακού φορτίου

Επιστρέφοντας στο ζήτημα της πρόβλεψης ενεργειακού φορτίου σε κτίρια, η μεταφορά μάθησης έχει αποδειχθεί ως ένα αποδοτικό εργαλείο για την αντιμετώπιση προκλήσεων σχετικά με την έλλειψη επισημασμένων δεδομένων σε νέα κτίρια αλλά και τις διαφορές μεταξύ κτιρίων. Στον πίνακα 2.1 φαίνονται μερικές από τις σχετικές έρευνες όσον αφορά την μεταφορά μάθησης μεταξύ κτιρίων για τη βελτίωση της πρόβλεψης ενεργειακού φορτίου.

Συγκεκριμένα οι (Gao et al.) πρότειναν το 2020 ένα μοντέλο αρχιτεκτονικής κωδικοποιητή-αποκωδικοποιητή με χρήση δυο LSTM επιπέδων για επεξεργασία δεδομένων χρονοσειρών και ένα μοντέλο CNN δυο διαστάσεων με μηχανισμό προσοχής τα οποία εκπαιδεύτηκαν σε κτίρια γραφείων με ιστορικά δεδομένα κατανάλωσης. Έπειτα τα επανεκπαίδευσαν στα ελάχιστα δεδομένα των στοχευμένων κτιρίων αλλά διατήρησαν τις παραμέτρους που ευθύνονται για την εξαγωγή χαρακτηριστικών με αποτέλεσμα να βελτιωθεί το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE) βραχυπρόθεσμης πρόβλεψης επόμενης

μέρας και στα δυο μοντέλα κατά 19.69% και 20.54% αντίστοιχα [81]. Παράλληλα οι (Fan et al.) εξέτασαν την αποδοτικότητα τεχνικών μεταφοράς μάθησης σε προβλέψεις επόμενης μέρας για 507 μη κατοικήσιμα κτίρια. Οι τεχνικές περιλάμβαναν επαναστάθμιση των πηγαίων δειγμάτων εισόδου με βάση κριτηρίων ομοιότητας όπως η Δυναμική Ευθυγράμμιση Χρόνου τα οποία έπειτα χρησιμοποιήθηκαν για προσαρμογή των προεκπαιδευμένων μοντέλων στο στοχευμένο τομέα. Η έρευνα τους σημείωσε πτώση του σφάλματος πρόβλεψης από 15% έως και 78% με βάση την ομοιότητα μεταξύ τομέων [84].

Πίνακας 2.1: Σχετικές έρευνες στην πρόβλεψη ενεργειακού φορτίου

Συγγραφείς	Έτος	Αρχιτεκτονική Μοντέλου	Τεχνικές Μεταφοράς Μάθησης
(Gao et al.) [81]	2020	CNN-Attention, LSTM, Seq2seq	Parameter-based
(Fan et al.) [84]	2020	-	Reweighting-based, Parameter-based
(Ahn & Kim) [80]	2022	LSTM	Parameter-based
(Li et al.) [79]	2022	LSTM	Parameter-based ,Adversarial Learning, Symmetric Feature-based
(Peng et al.) [86]	2022	Ensemble-LSTM	Multi-source Ensemble Learning
(López Santos et al.) [82]	2023	TFT	Parameter-based, Symmetric Feature-based
(Lu et al.) [87]	2023	LSTM	Symmetric Feature-based, Multi-source Ensemble Learning
(Xiao et al.) [85]	2024	LSTM, GRU	Model Control Strategy, Parameter-based, Multi-Source Ensemble Learning,
(Singh & Bedi) [88]	2024	Transformer, LSTM, sequence-to-sequence	Hybrid Feature-based, Parameter-based
(Qian et al.) [89]	2024	LSTM	Instance Selection & Transformation, Symmetric Feature-based Parameter-based
(Xing et al.) [90]	2024	LSTM	Hybrid Feature-Based Parameter-based

Το 2022 οι (Ahn & Kim) εκπαιδευσαν ένα μοντέλο LSTM σε προσομοιωμένο σύνολο δεδομένων ενεργειακής κατανάλωσης κτιρίων με γραφεία και το επανεκπαίδευσαν στους στοχευμένους τομείς με ελάχιστα δεδομένα διατηρώντας τις παραμέτρους των πρώτων επιπέδων του, που είναι υπεύθυνα για την εξαγωγή χαρακτηριστικών, σταθερές. Έτσι σημείωσαν συντελεστή μεταβλητότητας μέσου τετραγωνικού σφάλματος (CV-RMSE) 4.25% και μέσο σφάλμα μεροληψίας (MBE) 1.7% το οποίο αποτελεί σημαντική βελτίωση σε

σχέση με τις προβλέψεις μοντέλων που εκπαιδεύτηκαν κατευθείαν στους στοχευμένους τομείς [80]. Οι (Li et al.) χρησιμοποίησαν το ίδιο μοντέλο το οποίο εκπαιδευσαν σε 47 εμπορικά κτίρια και επιχείρησαν προσαρμογή μέσω περαιτέρω εκπαίδευσης (fine-tuning), δημιουργία κοινών χαρακτηριστικών μέσω επιπλέον ανταγωνιστικού επιπέδου (DANN) και εισαγωγή επιπέδου για προσαρμογή του πηγαίου χώρου χαρακτηριστικών. Κατά μέσω όρο σημείωσαν βελτίωση κατά 75% σε βραχυπρόθεσμες προβλέψεις ενεργειακού φορτίου κτιρίων με ελλιπή δεδομένα σε σχέση με το παραδοσιακό LSTM. Παράλληλα οι (Peng et al.) ακολουθώντας μια διαφορετική προσέγγιση επέλεξαν ορισμένα κτίρια πλούσια σε δεδομένα κατανάλωσης και εκπαιδευσαν ένα διαφορετικό LSTM για κάθε ένα ενώ υπολόγισαν, με χρήση ορισμένων μετρικών, το δείκτη ομοιότητας με ένα στοχευμένο, ελλιπή σε δεδομένα, κτίριο. Έπειτα με βάση αυτό δημιούργησαν σταθμισμένους όρους για κάθε πηγαίο τομέα και με λογική συνόλου συνδύασαν όλες τις επιμέρους βραχυπρόθεσμες προβλέψεις προσφέροντας σημαντική βελτίωση και σταθερότητα σε συγκριτικά με προβλέψεις που προέρχονται από ένα μόνο πηγαίο τομέα [86].

Ένα χρόνο αργότερα οι (López Santos et al.) αξιοποίησαν το μοντέλο TFT το οποίο εκπαιδευσαν σε κατοικήσιμα και μικρά εμπορικά κτίρια με πληθώρα δεδομένων κατανάλωσης με σκοπό την πρόβλεψη σε κτίρια με περιορισμένα. Επιχείρησαν αρχικά να μετασχηματίσουν τα χαρακτηριστικά του πηγαίου και στοχευμένου τομέα σε κοινό λανθάνοντα χώρο πριν τη προεκπαίδευση του και έπειτα το προσάρμοσαν μέσω περαιτέρω εκπαίδευσης στα ελάχιστα στοχευμένα δεδομένα. Οι προβλέψεις χαρακτηρίστηκαν από μειωμένη ρίζα μέσου τετραγωνικού σφάλματος (RMSE) κατά 11% σε σχέση με προβλέψεις χωρίς μεταφορά μάθησης [82]. Με παρόμοιο τρόπο οι (Lu et al.) μετασχημάτισαν τα χαρακτηριστικά μεταξύ πολλών πηγαίων μικτών κτιρίων με το στοχευμένο σε κοινό χώρο και εκπαιδευσαν ένα LSTM για κάθε κτίριο. Έπειτα στάθμισαν το κάθε πηγαίο τομέα ανάλογα την ομοιότητα με το στοχευμένο και συνδύασαν τις προβλέψεις πετυχαίνοντας βελτίωση στο μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE) από 6.88% έως 15.37% συγκριτικά με κάθε επιμέρους πρόβλεψη ανάλογα την ομοιότητα [87].

Το 2024 οι (Xiao et al.) αξιοποίησαν πολλά μοντέλα όπως LSTM και GRU προεκπαιδευμένα σε πολλά πηγαία κτίρια τα οποία επανεκπαίδευσαν μεταγενέστερα στο στοχευμένο. Όμως εφαρμόστηκε ένα σύστημα ενισχυτικής

μάθησης το οποίο ανάλογα την ομοιότητα των χαρακτηριστικών του κάθε πηγαίου τομέα με το στοχευμένο επέλεξε ποιες παραμέτρους θα προσαρμόσει στην επανεκπαίδευση και συνδύασε δυναμικά τις προβλέψεις για το τελικό αποτέλεσμα σημειώνοντας σημαντική βελτίωση [85]. Από την άλλη οι (Singh & Bedi) πρότειναν ένα μοντέλο αρχιτεκτονικής κωδικοποιητή-αποκωδικοποιητή που ενσωματώνει επίπεδα Μετασχηματιστή και LSTM σε κάθε σκέλος του το οποίο εκπαιδεύσαν στο υποσύνολο διαθέσιμων πηγαίων τομέων που εμφάνισε τη μεγαλύτερη ομοιότητα με το στοχευμένο. Στην εκπαίδευση συμπεριέλαβαν τα πιο όμοια πηγαία χαρακτηριστικά σε σχέση με τα στοχευμένα τα οποία μετασχημάτισαν σε κοινό λανθάνοντα χώρο και μετά το τέλος της πραγματοποίησαν προσαρμογή με περαιτέρω εκπαίδευση στο στοχευμένο τομέα. Οι προβλέψεις επόμενου χρόνου που πραγματοποιήθηκαν παρουσίασαν πτώση στο CV-RMSE κατά 4.53% [88]. Παράλληλα οι (Qian et al.) πειραματίστηκαν με δύο προσεγγίσεις μεταφοράς μάθησης που αξιοποίησαν τα πιο όμοια επιλεγμένα διαθέσιμα πηγαία κτίρια μέσω κριτηρίων ομοιότητας. Η πρώτη μέθοδος περιλαμβάνει ένα μοντέλο GBR το οποίο εκπαιδεύτηκε σε επιλεγμένα και εναπασταθμισμένα δείγματα εισόδου με βάση την ομοιότητα και έπειτα προσαρμόστηκε περαιτέρω στο στοχευμένο τομέα ενώ η δεύτερη μέθοδος περιλάμβανε προεκπαιδευμένα μοντέλα LSTM στα πηγαία κτίρια με βάση χαρακτηριστικά που ήταν μετασχηματισμένα σε κοινό χώρο και έπειτα προσαρμόστηκαν και αυτά στο στοχευμένο χώρο με την τελική πρόβλεψη να πρόκυπτε από κοινή συνάρτηση σφάλματος. Η δεύτερη μέθοδος αποδείχθηκε αποδοτικότερη με το σφάλμα βραχυπρόθεσμης πρόβλεψης να μειώνεται κατά 7.23% [89]. Τέλος οι (Xing et al.) μετασχημάτισαν τα κοινά χαρακτηριστικά μεταξύ πηγαίου και στοχευμένου τομέα σε κοινό χώρο και πρόσθεσαν τα χαρακτηριστικά που ήταν μοναδικά σε κάθε τομέα ξεχωριστά για να αξιοποιήσουν την πιθανή πληροφορία του. Έπειτα εκπαιδεύσαν ένα μοντέλο LSTM σε αυτό το σύνολο και το προσάρμοσαν με περαιτέρω εκπαίδευση στο στοχευμένο τομέα σημειώνοντας αυξημένο σκορ R2 και μειωμένο μέσο απόλυτο σφάλμα (MAE) για βραχυπρόθεσμες προβλέψεις [90].

Η μεταφορά μάθησης έχει αποδειχθεί εξαιρετικά αποδοτική στη πρόβλεψη ενεργειακού φορτίου κτιρίων αντιμετωπίζοντας το πρόβλημα λειψών δεδομένων ειδικά σε νέα κτίρια. Διάφορες τεχνικές δίνουν λύση σε διαφορετικές προκύπτουσες προκλήσεις βελτιώνοντας την ακρίβεια και ανθεκτικότητα των

προβλέψεων ολοένα και περισσότερο σε νέα σύνολα δεδομένων κατανάλωσης ενώ δείχνουν να έχουν προοπτικές για την προώθηση μελλοντικών εξελίξεων στα συστήματα διαχείρισης ενέργειας.

2.3 Μετρικές για την αξιολόγηση της απόδοσης μιας πρόβλεψης

Κατά την πραγματοποίηση προβλέψεων είναι απαραίτητο να υπάρχουν τρόποι αξιολόγησης τους για διάφορους λόγους. Αρχικά αποτελούν τα εργαλεία σύγκρισης της αποτελεσματικότητας των προβλεπόμενων τιμών σε σχέση με ιστορικά δεδομένα. Επιπλέον προσφέρουν πληροφορίες για την ανάλυση της φύσης του σφάλματος πρόβλεψης επιτρέποντας τη διάγνωση αδυναμιών και τη στοχευμένη βελτίωση. Έτσι μπορεί να ενισχυθεί η απόδοση και αξιοπιστία των προβλεπτικών μοντέλων με τη πάροδο του χρόνου. Εκτός από ατομική αξιολόγηση έχουν την δυνατότητα να αποτυπώσουν την απόδοση πολλών μοντέλων στην ίδια κλίμακα επιτρέποντας την άμεση σύγκριση μεταξύ τους και τη δημιουργία δεικτών αναφοράς και στόχων απόδοσης. Έτσι γίνονται ξεκάθαροι οι παράγοντες που ορίζουν μια καλή πρόβλεψη και καθορίζονται ποιοτικά πρότυπα για τα μοντέλα. Στη συνέχεια μια καλή πρόβλεψη είναι το θεμέλιο της ενημερωμένης λήψης αποφάσεων με εταιρίες και οργανισμούς να βασίζονται ενεργά σε αυτές για την επιλογή στρατηγικής, την κατανομή πόρων και την αποτελεσματική ανταπόκριση σε μεταβαλλόμενες συνθήκες. Σε αυτή την ενότητα θα εξεταστούν βασικές μετρικές που αξιοποιήθηκαν για την αξιολόγηση των προβλέψεων αυτής της διπλωματικής εργασίας

2.3.1 Το μέσο απόλυτο σφάλμα (MAE)

Το μέσο απόλυτο σφάλμα (Mean Absolute Error) αποτελεί μια από τις κυριότερες και πιο απλές στατιστικές μετρικές σφάλματος που εφαρμόζονται και εκφράζει την μέση τιμή της διαφοράς μεταξύ προβλεπόμενων και πραγματικών τιμών σε απόλυτη τιμή [91] [92]. Μαθηματικά εκφράζεται ως εξής:

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

όπου :

- y_i : Πραγματική τιμή για τη χρονική στιγμή i
- f_i : Πραγματική τιμή για τη χρονική στιγμή i

Σαν μετρική προτιμάται καθώς αντιμετωπίζει όλα τα σφάλματα με τον ίδιο τρόπο χωρίς να συνεισφέρουν δυσανάλογα οι μεγαλύτερες αποκλίσεις στην τελική τιμή της [93] [94]. Ωστόσο υπάρχουν περιπτώσεις που τα μεγάλα σφάλματα είναι σημαντικό να ανιχνεύονται ενώ ταυτόχρονα δεν προσφέρει κάποια πληροφορία για την γενική κατεύθυνση των σφαλμάτων, δηλαδή αν υπάρχει υπερεκτίμηση ή υποτίμηση [93]. Τέλος είναι μια μέθοδος που εξαρτάται από τη κλίμακα των τιμών μιας χρονοσειράς, πράγμα που καθιστά δύσκολη την σύγκριση της απόδοσης μεταξύ συνόλων δεδομένων με διαφορετικές κλίμακες [94].

2.3.2 Το μέσο απόλυτο ποσοστό σφάλματος (MAPE)

Το μέσο απόλυτο ποσοστό σφάλματος (Mean Absolute Percentage Error) είναι μια μετρική που αποτυπώνει την ευστοχία προβλεπόμενων τιμών ως ποσοστό των πραγματικών τιμών. Ποσοτικοποιεί το μέσο ποσοστό της διαφοράς μεταξύ προβλεπόμενων και πραγματικών τιμών. Η μαθηματική έκφραση υπολογισμού της MAPE είναι η εξής :

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|y_i - f_i|}{|y_i|}$$

όπου:

- y_i : Πραγματική τιμή για τη χρονική στιγμή i
- f_i : Πραγματική τιμή για τη χρονική στιγμή i

Σε αντίθεση με τη MAE δεν εξαρτάται από τη κλίμακα των τιμών μιας χρονοσειράς και είναι εύκολα ερμηνεύσιμη [94]. Είναι ιδιαίτερα αποδοτική σε σύνολα δεδομένων με μικρό αριθμό ακραίων τιμών ωστόσο έχει ένα σοβαρό ελάττωμα όταν μια πραγματική τιμή μιας χρονοσειράς μηδενίζεται ή τείνει προς το μηδέν καθώς κατά τον υπολογισμό της προκύπτει απειρισμός ή ακραίες τιμές αντίστοιχα. [91] [92] [93] [94]. Επίσης οι μετρικές που βασίζονται σε ποσοστιαία σφάλματα έχουν το μειονέκτημα της επιβολής διαφορετικής βαρύτητας σε θετικά σφάλματα συγκριτικά με τα αρνητικά, καθιστώντας τις ασύμμετρες [94].

2.3.3 Η ρίζα μέσου τετραγωνικού σφάλματος (RMSE)

Η ρίζα μέσου τετραγωνικού σφάλματος (Root Mean Squared Error) αποτελεί μια ακόμα ευρέως διαδεδομένη μετρική που αποτυπώνει την ακρίβεια των προβλέψεων ποσοτικοποιώντας το μέσο μέγεθος σφαλμάτων μεταξύ προβλεπόμενων και πραγματικών τιμών. Εκφράζεται ως εξής :

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

όπου:

- y_i : Πραγματική τιμή για τη χρονική στιγμή i
- f_i : Πραγματική τιμή για τη χρονική στιγμή i

Δίνει έμφαση σε μεγαλύτερα σφάλματα λόγω της τετραγωνικής φύσης της, καθιστώντας την χρήσιμη σε περιπτώσεις που οι μεγάλες αποκλίσεις μεταξύ πρόβλεψης και πραγματικής τιμής πρέπει να αποφεύγονται [91] [92]. Είναι ιδιαίτερα ευαίσθητη στην διακύμανση των σφαλμάτων αποτυπώνοντας την συνέπεια τους ενώ είναι καλό να προτιμάται όταν αυτά ακολουθούν κατανομή Gauss [93] [94]. Παρόμοια με τη μετρική MAE είναι εξαρτώμενη από τη κλίμακα των τιμών της χρονοσειράς περιορίζοντας την σαν μέτρο σύγκρισης απόδοσης μεταξύ συνόλων δεδομένων ενώ μπορεί να επηρεαστεί αρνητικά από ακραίες τιμές λαμβάνοντας μεγάλες τιμές σε σύνολα δεδομένων με πολλές ακραίες τιμές [94].

2.3.4 Το σκορ R^2 (R^2 Score)

Το σκορ R^2 , γνωστό και ως συντελεστής προσδιορισμού, αποτελεί τη σύγκριση της διακύμανσης των σφαλμάτων με των πραγματικών δεδομένων. Ποσοτικοποιεί την ικανότητα μιας πρόβλεψης να αναπαράγει τα παρατηρούμενα αποτελέσματα σε σύγκριση με ένα αφελές (Naive) μοντέλο μέσου όρου. Αν έχει τιμή 1 ή 100% τότε σημαίνει ότι οι προβλεπόμενες τιμές ταυτίζονται με τις πραγματικές ενώ 0 ή 0% σημαίνει ότι το μοντέλο δεν προσφέρει καλύτερες προβλέψεις από τη χρήση του μέσου όρου των παρατηρήσεων ως πρόβλεψη [91]. Η μαθηματική του έκφραση είναι η εξής :

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

όπου:

- y_i : Πραγματική τιμή για τη χρονική στιγμή i
- f_i : Πραγματική τιμή για τη χρονική στιγμή i
- $\bar{y}$: Μέση τιμή των πραγματικών τιμών

Αποτελεί μια ευρέως αναγνωρισμένη μετρική καθώς προσφέρει μια ξεκάθαρη αναπαράσταση της καταλληλότητας ενός μοντέλου για μια εργασία καθώς

εκφράζει το ποσοστό της διακύμανσης των πραγματικών τιμών που μπορεί να ανιχνευτεί. Επίσης δεν εξαρτάται από τη κλίμακα των τιμών της χρονοσειράς επιτρέποντας την σύγκριση μοντέλων μεταξύ διαφορετικών συνόλων δεδομένων. Ωστόσο είναι ευαίσθητο σε δεδομένα με υψηλή διακύμανση ή θόρυβο με αποτέλεσμα να υπερεκτιμά ή υποτιμά λανθασμένα τις προβλεπτικές ικανότητες ενός μοντέλου [92].

2.3.5 Συγκριτική Ανάλυση Μετρικών

Σε αυτή τη διπλωματική εργασία, η επιλογή αυτών των μετρικών προσφέρει ένα ολοκληρωμένο πλαίσιο αξιολόγησης της απόδοσης επιλεγμένων μοντέλων σε προβλέψεις ενεργειακού φορτίου κτιρίων. Κάθε μια αποτυπώνει διαφορετικές πτυχές της αξιολόγησης ενός μοντέλου και εξυπηρετεί διαφορετικά στην κατανόηση της απόδοσης του. Το μέσο απόλυτο σφάλμα παρέχει μια απλή ερμηνεία του μέσου σφάλματος πρόβλεψης ενεργειακού φορτίου και εύκολη σύγκριση μεταξύ διαφορετικών προβλέψεων στο ίδιο κτίριο. Επεκτείνοντας αυτή τη χρησιμότητα το μέσο ποσοστιαίο απόλυτο σφάλμα κανονικοποιεί τα σφάλματα σε ποσοστά επιτρέποντας την άμεση σύγκριση προβλέψεων ίδιου μοντέλου μεταξύ κτιρίων με διαφορετική κλίμακα κατανάλωσης. Ταυτόχρονα η τετραγωνική ρίζα μέσου σφάλματος όντας ευαίσθητη σε μεγάλα σφάλματα, δίνει έμφαση στην επίδραση των ακραίων αποκλίσεων και αποτυπώνει την ύπαρξη τους εφόσον οι ακραίες τιμές κατανάλωσης είναι κρίσιμες στην πρόβλεψη ενεργειακού φορτίου. Τέλος ο συντελεστής προσδιορισμού R^2 θεωρείται η κύρια μετρική αξιολόγησης καθώς προσφέρει μια καλή εικόνα της καταλληλότητας ενός μοντέλου σε μια εργασία παρουσιάζοντας το ποσοστό διακύμανσης πραγματικών τιμών που είναι ικανό να αποτυπώσει. Ωστόσο μόνος του θα μπορούσε να οδηγήσει σε παραπλανητικά αποτελέσματα. Για αυτό η συνολική χρήση όλων αυτών των μετρικών διασφαλίζει ότι οι προβλέψεις των επιλεγμένων μοντέλων θα αξιολογηθούν ως προς την ακρίβεια, ανθεκτικότητα στη μεταβλητότητα της ενεργειακής κατανάλωσης και συνολική ικανότητα αποτύπωσης της δυναμικής των δεδομένων ενεργειακού φορτίου.

Κεφάλαιο 3


Μεθοδολογία πειραμάτων πρόβλεψης

3.1 Προεπισκόπηση της μεθοδολογίας προβλέψεων

Για τα πειράματα προβλέψεων που πραγματοποιήθηκαν για αυτή τη διπλωματική εργασία εφαρμόστηκε μια μεθοδολογία που βασίζεται στη μεταφορά της γνώσης ήδη εκπαιδευμένων μοντέλων για τη βελτίωση της ακρίβειας προβλέψεων σε κτίρια με έλλειψη δεδομένων. Όπως φαίνεται και στο διάγραμμα της Εικόνας 3.1 πρόκειται για μια πολυεπίπεδη διαδικασία η οποία περιλαμβάνει τη συλλογή και επεξεργασία δεδομένων κτιρίων, την εκπαίδευση νευρωνικών δικτύων σε αυτά, τη μεταφορά γνώσης και επανεκπαίδευση των ίδιων δικτύων με δεδομένα άλλων κτιρίων και εν τέλει την πραγματοποίηση προβλέψεων σε τρεις διαφορετικούς ορίζοντες πρόβλεψης.

Συγκεκριμένα τα δεδομένα αντλούνται από το σύνολο ανοικτών δεδομένων Genome 2 και επιλέγονται τρία διαφορετικά κτίρια εκ των οποίων το ένα κατέχει το ρόλο του πηγαίου τομέα και τα άλλα δύο αποτελούν το πρώτο και το δεύτερο στοχευμένο τομέα αντίστοιχα. Για τη προσομοίωση κτιρίων με έλλειψη δεδομένων περιορίζονται τα δεδομένα των στοχευμένων τομέων. Έτσι δημιουργείται το πρώτο σενάριο έλλειψης, στο οποίο διαθέτουν τα μισά δεδομένα σε σχέση με το πηγαίο. Επιπλέον μόνο για το πρώτο στοχευμένο κτίριο δημιουργείται άλλο ένα σενάριο ακραίας έλλειψης, σύμφωνα με το οποίο διαθέτει το ένα τέταρτο του όγκου δεδομένων του πηγαίου τομέα. Στη συνέχεια τα δεδομένα υπόκεινται σε προεπεξεργασία ώστε να έχουν μια μορφή κατάλληλη για την εκπαίδευση των νευρωνικών δικτύων.

Στη συνέχεια κάθε νευρωνικό δίκτυο εκπαιδεύεται ξεχωριστά σε κάθε στοχευμένο κτίριο σχηματίζοντας για κάθε ένα μια βασική εκδοχή του που



Εικόνα 3.1: Διάγραμμα μεθοδολογίας πειραμάτων πρόβλεψης

εμπεριέχει εκπαίδευση χωρίς κάποιο είδος μεταφοράς μάθησης. Κατόπιν τα δίκτυα εκπαιδεύονται και στο πηγαίο κτίριο και μέσω διάφορων τεχνικών

μεταφοράς μάθησης προσαρμόζονται (finetuning) στα στοχευμένα κτίρια μέσω ήπιας επανεκπαίδευσης. Έτσι για κάθε τεχνική μεταφοράς μάθησης που αντιστοιχεί σε ένα δίκτυο δημιουργείται μια εκδοχή του για κάθε στοχευμένο κτίριο, που διαθέτει τη γνώση που αποκόμισε από τη προεκπαίδευση τους και την συνεισφορά της προσαρμογής του στο εκάστοτε κτίριο. Έτσι πλέον για κάθε σενάριο έλλειψης δεδομένων και κάθε στοχευμένο κτίριο διαθέτουμε μια βασική εκδοχή του κάθε δικτύου και μια εκδοχή μεταφοράς μάθησης για κάθε αντίστοιχη τεχνική.

Τέλος εκτελούμε για κάθε εκδοχή κάθε μοντέλου τις αντίστοιχες προβλέψεις επόμενης μέρας, επόμενης εβδομάδας και επόμενου μήνα και πραγματοποιούμε την απαιτούμενη ανάλυση αποτελεσμάτων.

3.2 Σχηματισμός των συνόλων δεδομένων εκπαίδευσης

Για την σωστή διεξαγωγή πειραμάτων πρόβλεψης είναι απαραίτητο τα σύνολα δεδομένων να είναι σαφώς ορισμένα και στην κατάλληλη μορφή που χρειάζεται για την διευκόλυνση της εκπαίδευσης των μοντέλων. Συγκεκριμένα τα δεδομένα που αξιοποιήθηκαν για τη παρούσα μελέτη αντλήθηκαν από το σύνολο ανοιχτών δεδομένων κτιρίων Genome-2 και για την διασφάλιση της κατάλληλης μορφής τους για το στάδιο της εκπαίδευσης των νευρωνικών δικτύων υπεβλήθησαν σε μια διεξοδική φάση προεπεξεργασίας. Αυτή η υποενότητα περιγράφει την συνολική διαδικασία που πραγματοποιήθηκε από τη αρχική συλλογή αυτών των δεδομένων μέχρι και την τελική μορφή τους, η οποία αξιοποιήθηκε από τα μοντέλα για την εκπαίδευση τους.

3.2.1 Το σύνολο δεδομένων Genome-2

Το Genome-2 είναι το πιο εκτενές και δημόσια διαθέσιμο σύνολο δεδομένων το οποίο μεταξύ άλλων παρέχει και δεδομένα μετρητών ενέργειας σε κτίρια [95]. Αποτελεί μέρος του έργου “Building Data Genome Project”, μια διεθνή κοινοπραξία ακαδημαϊκών και επαγγελματιών στο τομέα της ενέργειας των κτιρίων με σκοπό τη δημιουργία μεγάλων, ανοικτών συνόλων δεδομένων που ενισχύουν την κατανόηση των βασικών παραμέτρων που διέπουν τη λειτουργία των κτιρίων και την κατανάλωση ενέργειας τους [95]. Η πρώτη φάση του προαναφερόμενου έργου ολοκληρώθηκε δημοσιεύοντας το 2017 το σύνολο δεδομένων Genome που περιλάμβανε ωριαία ενεργειακά δεδομένα ενός έτους από περισσότερα από 500 κτίρια.

Προεπισκόπηση του συνόλου Genome-2

Αυτό λοιπόν αποτελεί τη νέα έκδοση του συνόλου με ενεργειακά δεδομένα συλλεγμένα από 1,636 διαφορετικά μη οικιστικά κτίρια σε 19 τοποθεσίες στη


Site	UID	Kaggle	Actual Site Name	Location	Climate	Buildings	Meters
Panther	1P4YFG	0	Univ. of Central Florida (UCF)	Orlando, FL	2 A	136	299
Robin	1TKL5P	1	Univ. College London (UCL)	London, UK	4 A	52	67
Fox	4QFLSM	2	Arizona State Univ. (ASU)	Tempe, AZ	2B	137	306
Rat	72SGIQ	3	Washington DC - City Buildings	Washington DC	4 A	305	305
Bear	7E44IQ	4	Univ. of California - Berkeley	Berkeley, CA	3 C	92	92
Lamb	9T5ZA2	5	Cardiff - City Buildings	Cardiff, UK	4 A	147	265
Eagle	EQDHIP	6	Anonymous	N/A	4 A	47	106
Moose	H7PNXU	7	Ottawa - City Buildings	Ottawa, Ontario	6 A	15	43
Gator	I9U4WZ	8	Anonymous	N/A	2 A	74	74
Bull	JG98YH	9	Univ. of Texas - Austin	Austin, TX	2 A	124	308
Bobcat	JP4TNW	10	Anonymous	N/A	5B	36	116
Crow	JTM0LY	11	Carleton Univ.	Ottawa, Ontario	6 A	5	15
Wolf	RFO3TV	12	Univ. College Dublin (UCD)	Dublin, Ireland	5 A	36	66
Hog	SREOJG	13	Anonymous	Anonymous	6 A	163	336
Peacock	WI83D6	14	Princeton University	Princeton, NJ	5 A	106	298
Cockatoo	YYAFES	15	Cornell University	Cornell, NY	6 A	124	282
Shrew	L2HJLD	—	UK Parliament	London, UK	4 A	9	13
Swan	N950XM	—	Anonymous	N/A	3 C	21	55
Mouse	ZVJUMW	—	Ormand Street Hospital	London, UK	4 A	7	7

Εικόνα 3.4: Προεπισκόπηση λεπτομερειών για τις τοποθεσίες από τις οποίες συλλέχθηκαν τα ενεργειακά δεδομένα [96]

Βόρεια Αμερική και την Ευρώπη μέρος του οποίου είχε χρησιμοποιηθεί και στο διαγωνισμό Great Energy Predictor III (GEP3) που διοργανώθηκε το 2019 από τον αμερικανικό σύλλογο μηχανικών θέρμανσης, ψύξης και κλιματισμού (ASHRAE) [96]. Όπως φαίνεται και στην Εικόνα 3.2 κάθε τοποθεσία έχει ένα μοναδικό αναγνωριστικό κωδικό που αντιπροσωπεύεται από ονόματα ζώων για να διασφαλιστεί ανωνυμία σε ορισμένες περιπτώσεις. Στις υπόλοιπες όμως φαίνονται τα πραγματικά ονόματα των ινστιτούτων ή τοποθεσιών μαζί με τη γεωγραφική τους θέση. Όλα διαθέτουν συγκεκριμένους αναγνωριστικούς κωδικούς για λόγους παρακολούθησης αλλά και αναφορικά ως προς τη χρήση τους στον προαναφερόμενο διαγωνισμό. Επίσης για κάθε τοποθεσία αναφέρεται ο αριθμός κτιρίων από τα οποία συλλέχθηκαν δεδομένα, ο αριθμός ενεργειακών μετρητών που είναι τοποθετημένοι στα κτίρια της τοποθεσίας αλλά και η ταξινομημένη κλιματική ζώνη της με βάση τις ζώνες που χρησιμοποιήθηκαν στο διαγωνισμό, οι οποίες στοχεύουν στη κατηγοριοποίηση των περιβαλλοντικών συνθηκών που επηρεάζουν τις μετρήσεις. Τα συλλεγμένα δεδομένα περιλαμβάνουν ωριαίες μετρήσεις που αντιπροσωπεύουν συμπεριφορά ολόκληρου κτιρίου από την αρχή του 2016 έως και το τέλος του 2017. Η συχνότητα αυτή που παρατηρείται στις μετρήσεις επιλέχθηκε καθώς παρέχει την απαραίτητη λεπτομέρεια για την εφαρμογή αναλυτικών τεχνικών σε διάφορες χρονικές κλίμακες όπως ημερήσιες, εβδομαδιαίες, μηνιαίες, εποχιακές και ετήσιες.

Περιγραφή και ανάλυση των συλλεγόμενων μεταβλητών


Ο κύριος στόχος αυτού του συνόλου δεδομένων είναι η συλλογή ενεργειακών δεδομένων καλής ποιότητας με την απαραίτητη συχνότητα. Εκτός από μετρήσεις κατανάλωσης ηλεκτρικής ενέργειας, έχουν τοποθετηθεί και μετρητές ζεστού νερού, κρύου νερού, ατμού, φυσικού αερίου, άρδευσης και ηλιακής ενέργειας αποτυπώνοντας συνολικά τη συμπεριφορά ενός κτιρίου [95]. Για την παρούσα μελέτη από τα ενεργειακά δεδομένα αξιοποιήθηκαν μόνο οι μετρήσεις κατανάλωσης ηλεκτρικής ενέργειας οι οποίες σύμφωνα με την Εικόνα 3.3 αριστερά μπορεί να παρατηρηθεί ο χάρτης συσχέτισης της κανονικοποιημένης μορφής της με τη πάροδο του χρόνου. Η κατανάλωση είναι ταξινομημένη σε αύξουσα σειρά μετρητών από κάτω προς τα πάνω



Εικόνα 3.3: Κανονικοποιημένη ημερήσια κατανάλωση ηλεκτρική ενέργειας ανά μονάδα επιφάνειας (Αριστερά). Γράφημα ποιότητας δεδομένων κατανάλωσης ηλεκτρικής ενέργειας (Δεξιά) [96]


παρουσιάζοντας τη διαφορά στην κατανάλωση μεταξύ κτιρίων. Είναι εμφανές ότι υπάρχουν εποχικές διακυμάνσεις στα περισσότερα κτίρια αλλά και ακραίες μετρήσεις κατανάλωσης στα σημεία έντονης στιγμιαίας εναλλαγής χρωμάτων. Επίσης η ύπαρξη ελλιπών τιμών παρουσιάζεται ως συνεχόμενες μαύρες ζώνες. Παράλληλα δεξιά είναι το γράφημα ποιότητας των δεδομένων αυτών ταξινομημένων σε αύξουσα σειρά με τον ίδιο τρόπο. Οι ελλιπείς τιμές αποτυπώνονται με λευκό χρώμα, ενώ οι μηδενικές τιμές και οι ακραίες τιμές με ελαφρύ κόκκινο και κόκκινο αντίστοιχα. Είναι προφανές κυρίως στο κάτω μέρος τους γραφήματος ότι υπάρχουν αρκετές ασυνήθιστες μετρήσεις αλλά και ακραίες ενώ δεν μπορεί να αγνοηθεί και το γεγονός ότι παρατηρείται και έλλειψη δεδομένων σε κάποιους μετρητές σε ορισμένες χρονικές περιόδους. Ωστόσο η πλειοψηφία των μετρητών προσφέρει δεδομένα υψηλής ποιότητας.

Στη συνέχεια κάθε τοποθεσία αντιστοιχείται σε ένα μετεωρολογικό σταθμό “Integrated Surface Data” (ISD) από τον οποίο συλλέγονται διάφορα μετεωρολογικά δεδομένα. Συγκεκριμένα είναι διαθέσιμες μετρήσεις για νεφοκάλυψη, θερμοκρασία αέρα, θερμοκρασία δρόσου, ύψος νετού σε 1 και 6



Εικόνα 7.4: Κατανομές μετεωρολογικών δεδομένων [96]

ώρες, πίεση, ταχύτητα ανέμου και κατεύθυνση ανέμου [95]. Στην Εικόνα 3.4 παρατηρούνται διάφορες γραφικές που παρουσιάζουν τις κατανομές των τιμών αυτών των δεδομένων σε όλη την έκταση των μετρητών. Παρατηρούμε κατά κύριο λόγο έλλειψη σύννεφων με τη θερμοκρασία να ακολουθεί κανονική κατανομή με κέντρο τους 10-20°C . Παράλληλα οι βροχοπτώσεις είναι σπάνιες, οι άνεμοι είναι κυρίως χαμηλής ταχύτητας 5 m/s αλλά παρουσιάζουν και κάποιες σπάνιες μέγιστες μετρήσεις από 15 m/s έως 25 m/s ενώ είναι εμφανές



Εικόνα 3.5: Κατανομές των μεταδεδομένων [96]

πως ο άνεμος ρέει προς όλες τις κατευθύνσεις με κυρίαρχες να είναι οι διευθύνσεις γύρω στις 0° (Βόρεια) και 270° (Δυτικά). Τέλος εκτός από τα μετεωρολογικά δεδομένα ανά τοποθεσία προσφέρονται και εκτενή μεταδεδομένα για κάθε κτίριο που παρέχουν βασικές πληροφορίες σχετικά με αυτό και συμβάλλουν στη κατανόηση των λειτουργικών χαρακτηριστικών και δομικών ιδιοτήτων που επηρεάζουν τα πρότυπα ενεργειακής χρήσης. Συγκεκριμένα προσφέρονται πληροφορίες όπως πρωτεύουσα και δευτερεύουσα χρήση, έκταση δαπέδου, γεωγραφικό μήκος και πλάτος, έτος κατασκευής, αριθμός ορόφων, σκορ Energy Star, ένταση ενεργειακής χρήσης, είδος θερμότητας, βιομηχανία στην οποία ανήκει, αριθμός κατοίκων, επίπεδο LEED (Leadership in Energy and Environmental Design) και ζώνη ώρας [95]. Αναλυτικότερα στην Εικόνα 3.5 φαίνονται οι κατανομές ορισμένων από αυτά και παρατηρείται πως τα περισσότερα κτίρια ανήκουν σε εκπαιδευτικά ινστιτούτα και περίπου τα μισά βρίσκονται στο ανατολικό μέρος των ΗΠΑ. Η έκταση τους κυμαίνεται κυρίως μέχρι τα 20000 m²/s ενώ είναι κτισμένα κατά κύριο λόγο στις χρονικές περιόδους ανάμεσα στο 1960 έως 1980 και από το 1990 έως το 2018 και χρησιμοποιούν κυρίως λιγότερα από 500 άτομα κάθε κτίριο. Ωστόσο είναι εμφανές πως υπάρχει μεγάλη έλλειψη δεδομένων για τις δύο τελευταίες μετρήσεις με αποτέλεσμα αυτά τα δεδομένα να μην αντιπροσωπεύουν όλα τα κτίρια του συνόλου δεδομένων.

Καθαρισμός και επεξεργασία των δεδομένων

Τα δεδομένα κατά τη συλλογή τους από τους μετρητές στις διάφορες τοποθεσίες και μετεωρολογικούς σταθμούς είναι ακατέργαστα και για να διασφαλιστεί η συνοχή και ομοιομορφία του τελικού συνόλου δεδομένων μετασχηματίστηκαν με διάφορους τρόπους [95].

Αρχικά οι μετρήσεις από όλους τους μετρητές κάθε ενεργειακού τύπου σε ένα κτίριο συγκεντρώθηκαν και μετατράπηκαν σε τυποποιημένες μονάδες μέτρησης για να διασφαλιστεί η συνέπεια. Στη συνέχεια ορισμένες μέθοδοι ακολουθήθηκαν για τον αύξηση της ποιότητας των δεδομένων και τον περιορισμό των ανωμαλιών. Συγκεκριμένα κάθε μετρητής που αποτύπωνε μια μοναδική τιμή σε όλη τη διαδικασία παρατήρησης, παρουσίαζε παραπάνω από τις μισές μετρήσεις ως αρνητικές ή σημείωνε παραπάνω από 100 μέρες χωρίς να

αποδώσει κάποια μέτρηση, αναγνωρίστηκε και αφαιρέθηκε καθώς δεν συνείσφερε ουσιαδώς στην ανάλυση. Παράλληλα περιπτώσεις διπλότυπων μετρήσεων διαγράφηκαν και όποιες εναπομείναντες αρνητικές μετρήσεις αντικαταστάθηκαν με την ειδική αριθμητική τιμή κινητής υποδιαστολής “Not a Number” (NaN). Στη συνέχεια με χρήση λογαριθμικού μετασχηματισμού ανιχνεύθηκαν οι ακραίες τιμές και αντικαταστάθηκαν με την τιμή NaN ενώ για να διασφαλιστεί η συνέπεια της αριθμητικής ακρίβειας των τιμών όλες οι μετρήσεις στρογγυλοποιήθηκαν στα τέσσερα δεκαδικά ψηφία.

Τα δεδομένα από τους μετεωρολογικούς σταθμούς δέχτηκαν επίσης κάποια προεπεξεργασία και καθαρισμό. Ακολούθησαν παρόμοια τυποποίηση και πιθανές προσαρμογές κλιμάκωσης για να ευθυγραμμιστούν με τα άλλα δεδομένα ενώ οι ελλιπείς τιμές αντικαταστάθηκαν με την τιμή NaN.

Συμπληρωματικά με τον καθαρισμό των ενεργειακών μετρήσεων, πραγματοποιήθηκαν και ενέργειες για την τυποποίηση και των μεταδεδομένων κάθε κτιρίου. Οι τιμές έκτασης δαπέδου μετασχηματίστηκαν σε τετραγωνικά μέτρα και τετραγωνικά πόδια ενώ το γεωγραφικό πλάτος και μήκος ρυθμίστηκαν ώστε να αποτυπώνουν την κεντρική τοποθεσία του χώρου ή της πόλης στην οποία ανήκει ένα κτίριο διασφαλίζοντας την συνέπεια σε όλο το σύνολο δεδομένων. Επιπλέον πραγματοποιήθηκε επαλήθευση των τιμών του έτους κατασκευής κτιρίων με αποτέλεσμα όσες δεν ανήκαν στο εύρος ετών από το 1900 έως το 2018 τότε αντικαταστάθηκαν με την τιμή NaN.

Τέλος για να συγχρονιστούν τα ενεργειακά δεδομένα με τα μεταδεδομένα εφαρμόστηκε μια σύγκριση. Κάθε κτίριο με ενεργειακά δεδομένα που δεν διαθέτει μεταδεδομένα αλλά και αντίστροφα διαγράφηκαν δημιουργώντας ένα ολοκληρωμένο και συνεπές σύνολο δεδομένων.

3.2.2 Διαδικασία επιλογής κτιρίων και χαρακτηριστικών

Όπως αναφέρθηκε το σύνολο δεδομένων Genome-2 διαθέτει δεδομένα από 1,636 κτίρια τα οποία βρίσκονται σε διαφορετικές τοποθεσίες. Είναι προφανές πως δεν μπορούν να αξιοποιηθούν όλα για την περεταίρω εκπαίδευση των νευρωνικών δικτύων καθώς αυτό απαιτεί πολύ χρόνο, ιδιαίτερα για την εύρεση

των βέλτιστων υπερπαραμέτρων. Επίσης οι μεταβλητές χαρακτηριστικών που προσέφερε το σύνολο δεδομένων ήταν πολλές και αρκετές ήταν αχρείαστες. Επομένως πραγματοποιήθηκε μια διαδικασία επιλογής κτιρίων αλλά και των χαρακτηριστικών που αξιοποιήθηκαν για την διαδικασία της εκπαίδευσης.

Επιλογή του χώρου χαρακτηριστικών

Η επιλογή των χαρακτηριστικών που αξιοποιήθηκαν στην εκπαίδευση των νευρωνικών δικτύων απαιτούσε προσοχή καθώς έχουν διαφορετική επίδραση στην ακρίβεια των τελικών προβλέψεων [21]. Από τις ενεργειακές μετρήσεις είναι προφανές πως αξιοποιήθηκαν μόνο οι μετρήσεις της κατανάλωσης ηλεκτρικής ενέργειας ολόκληρου του κτιρίου αγνοώντας τις υπόλοιπες. Από τα μετεωρολογικά δεδομένα οι μετρήσεις που επιλέχθηκαν είναι οι ακόλουθες:

Θερμοκρασία Αέρα (air temperature): Η θερμοκρασία του αέρα αποτελεί κύριο παράγοντα κατανάλωσης ενέργειας σε ένα κτίριο καθώς επηρεάζει άμεσα τα συστήματα θέρμανσης και κλιματισμού τα οποία καταναλώνουν ηλεκτρική ενέργεια. Έχει άμεση σχέση με τις καθημερινές διακυμάνσεις αλλά και με τα εποχικά μοτίβα της ενεργειακής κατανάλωσης.

Θερμοκρασία Δρόσου (dew temperature): Η θερμοκρασία δρόσου αποτελεί μια μέτρηση της ατμοσφαιρικής υγρασίας και επηρεάζει τις υγραντικές και αφυγραντικές διαδικασίες των συστημάτων κλιματισμού. Για παράδειγμα τα κτίρια που διαθέτουν συστήματα ελέγχου κλιματικών συνθηκών ρυθμίζουν την θέρμανση και ψύξη με βάση τα επίπεδα υγρασίας επηρεάζοντας το ηλεκτρικό φορτίο κατανάλωση.

Νεφοκάλυψη (cloud coverage): Η νεφοκάλυψη αφορά την διαθεσιμότητα του φυσικού ηλιακού φωτός, η έλλειψη του οποίου οδηγεί στην αυξημένη ανάγκη τεχνητού φωτός το οποίο κατ' επέκταση οδηγεί στην αυξημένη κατανάλωση ενέργειας.

Ταχύτητα Ανέμου (Wind speed): Η ταχύτητα του ανέμου αν αποκτήσει υψηλές τιμές μπορεί να οδηγήσει σε απώλεια θερμότητας, ιδιαίτερα όταν ένα κτίριο έχει ανεπαρκή μόνωση, οδηγώντας σε αυξημένη ανάγκη θέρμανσης.

Κατεύθυνση Ανέμου (wind direction): Η κατεύθυνση ανέμου μπορεί να επηρεάσει τα φορτία θέρμανσης και ψύξης ενός κτιρίου ανάλογα με τον

προσανατολισμό του σε σχέση με αυτόν. Επίσης ο φυσικός αερισμός ενός κτιρίου επηρεάζεται από την κατεύθυνση και τη ταχύτητα του ανέμου μειώνοντας το φορτίο ψύξης υπό ευνοϊκές συνθήκες ανέμου.

Αξίζει να αναφερθεί ότι το φορτίο θέρμανσης και ψύξης έχει άμεση σχέση με το ηλεκτρικό φορτίο καθώς πολλές πηγές θέρμανσης και ψύξης αξιοποιούν ηλεκτρική ενέργεια για τη χρήση τους όπως για παράδειγμα ένα κλιματιστικό ή ένα αερόθερμο σώμα. Στη συνέχεια τα μεταδεδομένα κάθε κτιρίου αναλύθηκαν και αξιολογήθηκαν ώστε να επιλεγθούν αυτά που κρίνονται απαραίτητα. Συγκεκριμένα επιλέχθηκαν τα παρακάτω χαρακτηριστικά:

Έκταση κτιρίου σε τετραγωνικά μέτρα (sqm): Η έκταση κτιρίου επιλέχθηκε καθώς συνδέεται άμεσα με το επίπεδο ενεργειακής κατανάλωσης ενός κτιρίου. Μεγαλύτερης έκτασης κτίρια απαιτούν συνήθως μεγαλύτερη κατανάλωση ενεργειακού φορτίου σε σχέση με αυτά μικρότερης έκτασης.

Γεωγραφικό μήκος και πλάτος (lat,lng): Το γεωγραφικό μήκος και πλάτος προσφέρουν πληροφορίες για την τοποθεσία του κτιρίου που είναι άμεσα συνδεδεμένη με τα μετεωρολογικά χαρακτηριστικά που επηρεάζουν τη κατανάλωση του.


Έτος κατασκευής κτιρίου (yearbuilt): Το έτος κατασκευής αποτελεί κύριο παράγοντα κατανάλωσης ενεργειακού φορτίου καθώς παλαιότερα κτίρια ενδέχεται να έχουν απαρχαιωμένη μόνωση, συστήματα θέρμανσης και ψύξης και ηλεκτρικές συσκευές με αποτέλεσμα να σημειώνει υψηλότερη ενεργειακή κατανάλωση σε σύγκριση με νεότερα ενεργειακά αποδοτικά κτίρια.

Τα μεταδεδομένα αυτά επιτρέπουν τη δημιουργία επιπρόσθετων χαρακτηριστικών που προκύπτουν από αυτά ενώ λειτουργούν και ως κατηγορικές μεταβλητές. Επομένως ο συνδυασμός των επιλεγμένων χαρακτηριστικών στοχεύει στην βέλτιστη εκπαίδευση των νευρωνικών δικτύων προς εξέταση. Στη συνέχεια με βάση αυτά θα επιλεγθούν τρία κατάλληλα κτίρια για να προσομοιωθούν κατάλληλα τα επιθυμητά σενάρια

Επιλογή κατάλληλων κτιρίων προς εκπαίδευση


Η διαδικασία της επιλογής των κτιρίων αποτέλεσε μια περίπλοκη διαδικασία καθώς οι επιλογές ήταν πολλές. Ο στόχος του πειράματος είναι να εκπαιδεύσουμε κάποια νευρωνικά δίκτυα στα δεδομένα ενός πηγαίου κτιρίου με συνεπή δεδομένα καλής ποιότητας και να εκτελέσουμε ετερογενή μεταφορά μάθησης σε δύο ξεχωριστά κτίρια τα οποία διαφέρουν στο εύρος τιμών των μεταβλητών τους, στη διακύμανση τους, στο βαθμό θορύβου που παρουσιάζουν αλλά και στη ποσότητα τους. Αρχικά δεν είναι εφικτή η διαφορά εύρους τιμών σε όλη την έκταση του χώρου χαρακτηριστικών καθώς υπάρχουν ορισμένες μεταβλητές όπως η νεφοκάλυψη, η ταχύτητα και η κατεύθυνση του ανέμου που αναπόφευκτα θα έχουν παρόμοιο εύρος τιμών. Ωστόσο μπορεί να πραγματοποιηθεί επιλογή κατάλληλου συνδυασμού κτιρίων που ικανοποιεί διαφορετικά εύρη τιμών στα υπόλοιπα χαρακτηριστικά. Όσον αφορά τα μετεωρολογικά δεδομένα αλλά και τα μεταδεδομένα γεωγραφικού μήκους και πλάτους αρκεί τα επιλεγμένα κτίρια να βρίσκονται σε διαφορετικές τοποθεσίες ώστε να αλλάξει και το κλίμα αντίστοιχα. Επομένως επιλέχθηκαν οι τοποθεσίες Panther, Peacock και Robin που όπως προαναφέρθηκε είναι συνθηματικές ονομασίες ζώων που αντιστοιχούν στο Πανεπιστήμιο της Κεντρικής Φλόριντας (UCF), στο Πανεπιστημιακό Κολέγιο του Λονδίνου (UCL) και στο Πανεπιστήμιο του Πρίνστον στο Νιου Τζέρσεϊ αντίστοιχα [96]. Όπως φαίνεται στην Εικόνα 3.6 η θερμοκρασία σε κάθε τοποθεσία ακολουθεί παρόμοια εποχικότητα ενώ παρατηρούμε τις διαφορές στα εύρη τιμών της. Η πηγαία τοποθεσία έχει τις χαμηλότερες θερμοκρασίες ενώ η δεύτερη στοχευμένη έχει πιο ζεστό κλίμα σε αντίθεση με τη πρώτη με εξαίρεση τους χειμερινούς και ανοιξιάτικους μήνες που υπάρχει κάποια αλληλοεπικάλυψη. Όσον αφορά τη δρόσο η πρώτη στοχευμένη τοποθεσία σημειώνει τις μεγαλύτερες τιμές ενώ τις πιο χαμηλές η δεύτερη στοχευμένη ενώ η πηγαία βρίσκεται στη μέση. Παρατηρείται ξανά αλληλοεπικάλυψη μεταξύ των υψηλών τιμών της δεύτερης στοχευμένης και της πηγαίας.

Στη συνέχεια τα κτίρια επιλέχθηκαν από τη κατηγορία καταλύματος και λειτουργούν ως φοιτητικές εστίες στα αντίστοιχα πανεπιστήμια που ανήκουν. Συγκεκριμένα το πηγαίο κτίριο έχει έκταση 2272 τετραγωνικά μέτρα (τ.μ.) και είναι χτισμένο το 1968, το πρώτο στοχευμένο κτίριο διαθέτει 11895 τ.μ. χώρου



Εικόνα 3.6: Γραφικές παραστάσεις της θερμοκρασίας αέρα και δρόσου στις τοποθεσίες των επιλεγμένων κτιρίων

και κατασκευάστηκε το 2000 ενώ το δεύτερο καταλαμβάνει χώρο 5842 τ.μ. και ολοκληρώθηκε η κατασκευή του το 1960. Επομένως υπάρχει αισθητή διαφορά σε όλα τα μεταδεδομένα των κτιρίων. Αυτά μπορούν να φανούν και στην Εικόνα 3.7 που φαίνεται η γραφική παράσταση της κατανάλωσης ενεργειακού φορτίου των τριών συνόλων δεδομένων. Παρατηρείται πως το πηγαίο κτίριο όντας το πιο μικρό σημειώνει ημερήσια κατανάλωση περίπου από 15 έως 65 kWh, το πρώτο στοχευμένο κτίριο όντας το μεγαλύτερο καταναλώνει περίπου από 55 έως 130 kWh ενώ το δεύτερο που βρίσκεται κάπου στο ενδιάμεσο σημειώνει κατανάλωση από 30 έως 85 kWh. Ταυτόχρονα το πηγαίο κτίριο παρουσιάζει σταθερή διακύμανση ενώ τα στοχευμένα κτίρια εκδηλώνουν αυξημένη διακύμανση και θόρυβο, ιδιαίτερα το δεύτερο. Επίσης αξίζει να αναφερθεί πως παρουσιάζεται μεγάλη πτώση στο εύρος αλλά και στη μεταβλητότητα της κατανάλωσης των κτιρίων το καλοκαίρι ενώ στο πρώτο



Εικόνα 3.7: Γραφική παράσταση της κατανάλωσης ενέργειας των επιλεγμένων κτιρίων..

στοχευμένο και στη περίοδο των χριστουγεννιάτικων διακοπών καθώς οι φοιτητές ενδεχομένως να λείπουν κατά τη διάρκεια αυτή από τις εστίες. Ωστόσο δεν παρατηρείται μεγάλη μείωση στο πηγαίο κτίριο και σε συνδυασμό με τη σταθερότητα που χαρακτηρίζει τα δεδομένα του είναι ο λόγος που επιλέγεται για το ρόλο αυτό. Τέλος διακρίνονται και ορισμένες ακραίες και ελλιπείς τιμές οι οποίες θα διαχειριστούν στον στάδιο προεπεξεργασίας που ακολουθεί πριν την είσοδο τους στα νευρωνικά δίκτυα προς εκπαίδευση.

3.2.3 Προεπεξεργασία δεδομένων

Εφόσον τα δεδομένα συλλέχθηκαν σχηματίζεται η τελική μορφή του χώρου χαρακτηριστικών συνδυάζοντας τη μεταβλητή στόχου (ηλεκτρική κατανάλωση ενέργειας), τη μεταβλητή χρόνου, τις μετεωρολογικές μεταβλητές και τα μεταδεδομένα. Έτσι κάθε δείγμα εισόδου από οποιοδήποτε σύνολο δεδομένων εκ των τριών αποτελείται από 11 χαρακτηριστικά. Στη συνέχεια ακολουθείται μια αρχική διαδικασία προεπεξεργασίας που απαιτείται για την εκπαίδευση όλων των νευρωνικών δικτύων. Συγκεκριμένα περιλαμβάνει την συμπλήρωση

των ελλειπουσών τιμών και τον χειρισμό των ακραίων τιμών. Για τους σκοπούς αυτούς δημιουργήθηκαν δύο συναρτήσεις εκ των οποίων η πρώτη εφαρμόστηκε στα μετεωρολογικά χαρακτηριστικά και η δεύτερη στα δεδομένα κατανάλωσης.

Συγκεκριμένα η πρώτη ονομάζεται «fix_nans» και ελέγχει κάθε δειγματική τιμή ενός χαρακτηριστικού και αν λείπει τότε τη συμπληρώνει με την ίδια τιμή ενός δείγματος από κάποια άλλη χρονική στιγμή στο σύνολο και πραγματοποιεί ξανά έλεγχο για την επιβεβαίωση της σωστής αντικατάστασης με αριθμό. Αν δεν συμπληρώθηκε τότε επαναλαμβάνει για άλλη χρονική στιγμή μέχρι αντικατασταθεί σωστά. Οι χρονικές στιγμές που ελέγχει είναι σειριακά, ανάλογα τη θέση του δείγματος, οι εξής:

± 1 χρόνος, ± 1 μέρα, ± 2 μέρες, ± 3 μέρες, ± 4 μέρες, ± 5 μέρες

Η δεύτερη συνάρτηση ονομάζεται «tweak_outliers» και λαμβάνει σειριακά τα δείγματα ενός χαρακτηριστικού ανά μήνα ελέγχοντας για τυχόν ακραίες τιμές και τις διορθώνει. Συγκεκριμένα λαμβάνει τη μέση τιμή και τη σταθερή απόκλιση των μηνιαίων δειγμάτων του χαρακτηριστικού προς εξέταση και υπολογίζει ένα ανώτατο και κατώτατο όριο ως εξής :

$$lower_{bound} = mean - 2 * std_{dev} \quad higher_{bound} = mean + 2 * std_{dev}$$


Στη συνέχεια ελέγχει αν οι εξεταζόμενες τιμές ξεπερνάνε αυτά τα όρια, ρυθμίζοντας, σε αυτή τη περίπτωση, τη τιμή τους ώστε να έρθει πλησιέστερα στη μέση τιμή του αντίστοιχου μήνα.

Ο λόγος που η συνάρτηση «fix_nans» εφαρμόστηκε μόνο στα μετεωρολογικά χαρακτηριστικά είναι επειδή τα δεδομένα κατανάλωσης απαιτούσαν πιο εξατομικευμένο χειρισμό.

Προεπεξεργασία πηγαίου κτιρίου

Το πηγαίο σύνολο δεδομένων είναι το πιο κατάλληλο για εκπαίδευση, καθώς παρουσιάζει ελάχιστες διακυμάνσεις, σχεδόν καθόλου ελλειπείς τιμές και μικρό αριθμό ακραίων τιμών. Ειδικότερα στην αριστερή γραφική παράσταση της Εικόνας 3.8 φαίνεται πως διαθέτει ορισμένες ακραίες τιμές μεγαλύτερες των


65 kWh και μικρότερες των 13 kWh. Οι χαμηλές ακραίες τιμές αντικαταστάθηκαν με αυτές ενός χρόνου πριν ενώ οι υψηλές τιμές αντικαταστάθηκαν με τη μέση τιμή των τιμών μια μέρα πριν και μια μέρα μετά. Στη συνέχεια εφαρμόστηκε η συνάρτηση «tweak_outliers» και το αποτέλεσμα φαίνεται στη δεξιά γραφική παράσταση της ίδιας εικόνας.



Εικόνα 3.8: Γραφική παράσταση ενεργειακής κατανάλωσης του πηγαιού κτιρίου πριν και μετά το στάδιο προεπεξεργασίας.

Προεπεξεργασία πρώτου στοχευμένου κτιρίου

Το πρώτο στοχευμένο κτίριο όπως φαίνεται από την αριστερή γραφική παράσταση στην Εικόνα 3.9 διαθέτει ελάχιστες ελλιπείς τιμές αλλά αρκετές ακραίες τιμές μεγαλύτερες των 130 kWh αλλά και ορισμένες μικρές ακραίες τιμές καθ' όλη τη διάρκεια των δύο χρόνων. Για το χειρισμό αυτών ορισμένες τιμές αντικαταστάθηκαν με αυτές ενός χρόνου πριν ή ενός χρόνου μετά ενώ




Εικόνα 3.9: Γραφική παράσταση ενεργειακής κατανάλωσης του πρώτου στοχευμένου κτιρίου πριν και μετά το στάδιο προεπεξεργασίας.

άλλες έλαβαν τη μέση τιμή του συνόλου των τιμών δύο μερών πριν και δύο μερών μετά. Στη συνέχεια εφαρμόστηκε και εδώ η συνάρτηση «tweak_outliers» τα τελικά δεδομένα φαίνονται στη γραφική παράσταση δεξιά.

Προεπεξεργασία δευτέρου στοχευμένου κτιρίου

Το δεύτερο στοχευμένο κτίριο σε αντίθεση με το πρώτο διαθέτει λιγότερες ακραίες τιμές αλλά πολλές ελλειπίες οι οποίες πρέπει να χειριστούν ανάλογα. Παρατηρώντας την Εικόνα 3.10 είναι εμφανές πως λείπουν οι τιμές από την αρχή του Ιανουαρίου έως και τα μέσα του Μαΐου του έτους 2016. Αυτές οι τιμές αντικαταστάθηκαν με αυτές στις αντίστοιχες χρονικές στιγμές του επόμενου χρόνου για να εξασφαλιστούν τα μοτίβα εποχικότητας και η συνοχή με τις ιστορικές τάσεις των δεδομένων. Παράλληλα οι ακραίες τιμές χειρίστηκαν με παρόμοιο τρόπο ενώ στο τέλος εφαρμόστηκε και σε αυτό το σύνολο η συνάρτηση «tweak_outliers» παράγοντας τη τελική χρονοσειρά δεδομένων κατανάλωσης όπως φαίνεται στη δεξιά γραφική παράσταση.



Εικόνα 3.10: Γραφική παράσταση ενεργειακής κατανάλωσης του δεύτερου στοχευμένου κτιρίου πριν και μετά το στάδιο προεπεξεργασίας.

Τελικό στάδιο προεπεξεργασίας

Με τον κατάλληλο χειρισμό των ελλειπών και ακραίων τιμών, το σύνολο δεδομένων είναι πλέον καθαρό και σωστά προετοιμασμένο για το τελικό στάδιο προεπεξεργασίας.

Αυτό αρχικά περιλαμβάνει τη διαίρεση κάθε μέτρησης ενεργειακής κατανάλωσης με τα τετραγωνικά μέτρα του κτιρίου μετατρέποντας την μεταβλητή στόχου σε μια που αντιπροσωπεύει την κατανάλωση ανά τετραγωνικό μέτρο. Έτσι τα δίκτυα θα εκπαιδευτούν στην πρόβλεψη κατανάλωσης ενεργειακού φορτίου που δεν εξαρτάται από την έκταση του κτιρίου. Επίσης η χρονική μεταβλητή βρίσκεται σε μορφή ημερομηνίας η οποία δεν είναι κατάλληλη για την εκπαίδευση των μοντέλων. Επομένως διασπάται

σε 2 μεταβλητές που αντιπροσωπεύουν την ώρα και τον μήνα καθώς αυτά συνδέονται άμεσα με την ενεργειακή συμπεριφορά ενός κτιρίου.

Στη συνέχεια τα σύνολα δεδομένων κλιμακώνονται μεταξύ των τιμών 0 και 1 καθώς οι μονάδες μέτρησης μεταξύ των μεταβλητών των χρονοσειρών ενός συνόλου δεδομένων διαφέρουν με αποτέλεσμα χαρακτηριστικά με μεγάλες αριθμητικές τιμές να επηρεάζουν περισσότερο την εκπαίδευση ενός μοντέλου. Επίσης κατά τη διαδικασία ανανέωσης των παραμέτρων ενός μοντέλου οι υψηλές τιμές κυριαρχούν και προκαλούν μεγαλύτερες διακυμάνσεις στις μεταβολές των σταθμισμένων όρων οδηγώντας σε πιο αργή εκπαίδευση.

Έπειτα από την κλιμάκωση τα δεδομένα των στοχευμένων κτιρίων περιορίζονται δημιουργώντας 2 υποσύνολα. Το πρώτο διαθέτει δεδομένα ενός χρόνου ξεκινώντας από το Μάϊο του 2016 και λαμβάνεται και από τα δύο σύνολα δεδομένων. Το δεύτερο περιλαμβάνει δεδομένα 6 μηνών ξεκινώντας από τον Απρίλιο του 2016 και λαμβάνεται μόνο από τα δεδομένα του πρώτου στοχευμένου κτιρίου. Τέλος χωρίστηκαν τα σύνολα δεδομένων σε σύνολα εκπαίδευσης (train sets) και σύνολα δοκιμής (test sets) με τα πρώτα να περιλαμβάνουν το ποσοστό 80% των συνόλων και τα δεύτερα το υπόλοιπο 20%, μια αναλογία ευρέως γνωστή και αποδοτική.

Οι συγκεκριμένες χρονικές περίοδοι υποσυνόλων επιλέχθηκαν με τέτοιο τρόπο ώστε το χρονικό διάστημα στο τέλος του κάθε υποσυνόλου που αντιστοιχεί στο ανάλογο σύνολο δοκιμής να μην περιλαμβάνει τις χρονικές περιόδους που σημειώνεται μειωμένη ενεργειακή κατανάλωση. Αυτό είναι σημαντικό καθώς οποιαδήποτε εκπαίδευση πραγματοποιηθεί στα δεδομένα των στοχευμένων κτιρίων θα περιλαμβάνει γνώση σχετικά με την ενεργειακή συμπεριφορά του κτιρίου που επικρατεί στο μεγαλύτερο χρονικό διάστημα του συνόλου εκπαίδευσης. Αν τα δεδομένα δοκιμής διαφέρουν αρκετά σε σχέση με αυτό τότε οι προβλέψεις δεν θα είναι ακριβείς.

Η υπόλοιπη προεπεξεργασία των συνόλων εξαρτάται από το μοντέλο το οποίο θα εκπαιδευτεί σε αυτά. Ειδικότερα ακολουθείται μια διαδικασία για την εκπαίδευση ακολουθιακών μοντέλων και μια διαφορετική για την εκπαίδευση του μοντέλου TFT.

Τα ακολουθιακά μοντέλα είναι μια ομάδα δικτύων, που σύμφωνα με την Εικόνα 3.1 περιλαμβάνει το μοντέλο στοιβαγμένων LSTM, το μοντέλο στοιβαγμένων RNN, το μοντέλο στοιβαγμένων CNN και το υβριδικό μοντέλο

CNN-LSTM, τα οποία απαιτούν τα δεδομένα εισόδου να βρίσκονται σε μορφή ακολουθιών. Μια ακολουθία εισόδου αποτελείται από δείγματα πολλαπλών χρονικών βημάτων, όπου κάθε βήμα περιλαμβάνει ένα ή περισσότερα χαρακτηριστικά, συνοδευόμενα από την τιμή της μεταβλητής στόχου του επόμενου χρονικού βήματος. Στα πλαίσια της εργασίας επιλέχθηκε το μήκος των ακολουθιών εισόδου να είναι οι 48 προηγούμενες μετρήσεις, που αντιστοιχούν στις μετρήσεις των δύο προηγούμενων ημερών, καθώς τα μοντέλα θα μπορούν να ανιχνεύσουν τις βραχυπρόθεσμες και μεσοπρόθεσμες χρονικές εξαρτήσεις καλύτερα. Επομένως αναδιαμορφώνονται τα δεδομένα ώστε να διαθέτουν αυτή τη μορφή και να είναι συμβατά προς εκπαίδευση. Παράλληλα μετατρέπονται σε δυαδική μορφή τα δεδομένα που αντιπροσωπεύουν το μήνα που λήφθηκε μια μέτρηση, ώστε να μπορούν να αξιοποιηθούν από αλγόριθμους μηχανικής μάθησης. Συγκεκριμένα κάθε μήνας πλέον αποτελεί ένα νέο ξεχωριστό χαρακτηριστικό, το οποίο για τα δείγματα τα οποία αντιστοιχούν στον αντιπροσωπευόμενο μήνα λαμβάνει τιμή 1 ενώ για τα άλλα τιμή 0. Επομένως πλέον τα σύνολα δεδομένων βρίσκονται στη κατάλληλη μορφή για την εκπαίδευση των ακολουθιακών μοντέλων που αναφέρθηκαν.

Το μοντέλο TFT είναι επίσης σχεδιασμένο να διαχειρίζεται ακολουθίες εισόδου. Ωστόσο στη παρούσα εργασία υλοποιήθηκε με τη βοήθεια της βιβλιοθήκης «pytorch-forecasting», η οποία περιλαμβάνει μια ιδιαίτερη υλοποίηση του μοντέλου που λαμβάνει ως είσοδο ένα αντικείμενο της κλάσης «TimeSeriesDataSet» και για αυτό απαιτείται ξεχωριστή προεπεξεργασία. Αυτή η κλάση ανήκει σε αυτή τη βιβλιοθήκη και αντιπροσωπεύει αντικείμενα συνόλων δεδομένων που δρομολογούνται προς εκπαίδευση των μοντέλων της ενώ αυτοματοποιεί κάποιες διεργασίες όπως η αποδοτική διαχείριση κατηγορικών αλλά και στατικών και χρονικά μεταβαλλόμενων μεταβλητών. Επομένως ορίζεται το χρονικό χαρακτηριστικό του μήνα μέτρησης ως κατηγορικό χαρακτηριστικό για να μπορεί να επωφεληθεί η εκπαίδευση του μοντέλου από αυτό. Επίσης η συγκεκριμένη κλάση απαιτεί από το σύνολο δεδομένων να διαθέτει ένα χαρακτηριστικό που περιέχει το χρονικό δείκτη του δείγματος (time index) και ζητάει να οριστεί με βάση ποιο χαρακτηριστικό προσδιορίζεται ένα κτίριο σε περίπτωση που στο σύνολο εκπαίδευσης συμμετέχουν παραπάνω από ένα. Για την επίλυση αυτών των ζητημάτων δημιουργούμε το χαρακτηριστικό «time_index» στο οποίο αριθμούμε από την

αρχή όλα τα δείγματα και το χαρακτηριστικό «group_id» του οποίου του δίνουμε την τιμή 0 για όλα τα δείγματα ώστε να μην υπάρξει κάποια ομαδοποίηση καθώς κάθε σύνολο δεδομένων αντιπροσωπεύει ένα μόνο κτίριο. Έτσι τα σύνολα δεδομένων των κτιρίων είναι έτοιμα για να ξεκινήσει η εκπαίδευση του μοντέλου TFT.

3.3 Περιγραφή και ανάλυση της αρχιτεκτονικών των νευρωνικών δικτύων

Τα δεδομένα πλέον βρίσκονται στην κατάλληλη μορφή ώστε να διεξαχθεί η εκπαίδευση των επιλεγμένων μοντέλων που θα πραγματοποιήσουν τις προβλέψεις. Όπως προαναφέρθηκε υπάρχει μια διάκριση ανάμεσα στα μοντέλα με βάση τα βήματα προεπεξεργασίας που ακολουθήθηκαν ξεχωρίζοντας όλα τα μοντέλα εκτός του TFT ως μια ομάδα ακολουθιακών μοντέλων η οποία εξυπηρετεί μόνο ονομαστικούς σκοπούς χωρίς να σημαίνει πως το μοντέλο TFT δεν έχει τη δυνατότητα να επεξεργαστεί ακολουθιακά δεδομένα. Σε αυτήν την υποενότητα θα πραγματοποιηθεί μια ανάλυση των επιλεγμένων αρχιτεκτονικών αλλά και των πλεονεκτημάτων τους όσον αφορά τον τομέα της πρόβλεψης ενεργειακής κατανάλωσης.

3.3.1 Η ομάδα των ακολουθιακών μοντέλων

Η ομάδα ακολουθιακών μοντέλων δεν έχει μοναδικό κοινό το στάδιο προεπεξεργασίας των δεδομένων εκπαίδευσης τους αλλά και τη συνολική δομή τους καθώς ακολουθούν παρόμοια σχεδιαστικά πρότυπα. Συγκεκριμένα υλοποιήθηκαν όλα μέσω της βιβλιοθήκης «Tensorflow» η οποία αναπτύχθηκε από τη Google και εστιάζει στο πλαίσιο βαθιάς μάθησης παρέχοντας ένα


ολοκληρωμένο σύστημα για τη δημιουργία, εκπαίδευση και ανάπτυξη μοντέλων μηχανικής μάθησης.

Η αρχική δημιουργία κάθε μοντέλου έγινε μέσω της εντολής «model = tf.keras.layers.Sequential()» και κάθε μεταγενέστερο επίπεδο προστίθεται με την εντολή «model.add()». Στη συνέχεια εφαρμόζεται η εντολή «tf.keras.layers.Input()» η οποία ορίζει το μέγεθος της εισόδου που θα δεχτεί ενώ η υπόλοιπη αρχιτεκτονική τους μπορεί να αναλυθεί σε δύο μέρη. Το πρώτο αποσκοπεί στην εξαγωγή χαρακτηριστικών από τα δεδομένα και το δεύτερο στην εκμάθηση σχέσεων μεταξύ αυτών των χαρακτηριστικών για την τελική πρόβλεψη. Το δεύτερο μέρος σχεδιαστικά παραμένει ίδιο σε όλα αυτά τα μοντέλα και αποτελείται από δύο πλήρως συνδεδεμένα επίπεδα (Dense layers), τα οποία προστίθενται με την εντολή «model.add(tf.keras.layers.Dense())», ακολουθούμενα το κάθε ένα από ένα επίπεδο «Dropout», το οποίο αντιστοιχεί στην εντολή «model.add(tf.keras.layers.Dropout())», ενώ η πρόβλεψη προκύπτει από ένα τελικό επίπεδο dense με ένα νευρώνα εξόδου. Αυτή η σχεδιαστική επιλογή είναι ευρέως διαδεδομένη καθώς τα πλήρως συνδεδεμένα επίπεδα είναι ικανά για αποδοτικές προβλέψεις ενώ τα επίπεδα «Dropout» επιτρέπουν τυχαία σε ένα ποσοστό της εξόδου του προηγούμενου επιπέδου τους να προωθηθεί στο επόμενο μειώνοντας έτσι τις πιθανότητες το μοντέλο να υπερπροσαρμοστεί σε ένα σύνολο δεδομένων (overfitting) [74] [96]. Ωστόσο αν και αυτό το κομμάτι της αρχιτεκτονικής των μοντέλων είναι σχεδιαστικά ίδιο, οι υπερπαραμέτροι των επιπέδων του διαφέρουν μεταξύ των μοντέλων και αυτό οφείλεται στα αποτελέσματα της απόδοσης διάφορων συνδυασμών τους μέσω πειραματισμού.

Αρχιτεκτονική του μοντέλου στοιβαγμένων RNN (stacked RNN)

Τα δεδομένα εισόδου όπως προαναφέρθηκε βρίσκονται σε ακολουθιακή μορφή με αποτέλεσμα η πρώτη επιλογή μοντέλου να περιλαμβάνει επίπεδα RNN, τα οποία προστίθενται στο μοντέλο μέσω της εντολής «model.add(tf.keras.layers.SimpleRNN())». Αυτά τα επίπεδα επιλέχθηκαν διότι είναι σχεδιασμένα να διαχειρίζονται ακολουθιακά δεδομένα διατηρώντας στη μνήμη τους προηγούμενες εισόδους ενώ είναι ιδιαιτέρως χρήσιμα στην ανίχνευση βραχυπρόθεσμων εξαρτήσεων μεταξύ των δεδομένων [60]. Όπως

φαίνεται και στην Εικόνα 3.11 το πρώτο μέρος της αρχιτεκτονικής αποτελείται από 3 επίπεδα RNN στη σειρά. Η επιλογή τριών επιπέδων αποσκοπεί στην προσθήκη επιπλέον βάθους στην ανάλυση και εξαγωγή χαρακτηριστικών από



Εικόνα 3.11: Αρχιτεκτονική του μοντέλου στοιβαγμένων επιπέδων RNN.

τα δεδομένα. Συγκεκριμένα η διαδικασία είναι ιεραρχική με τα πρώτα επίπεδα να μοντελοποιούν τις βραχυπρόθεσμες εξαρτήσεις προωθώντας τις κρυφές καταστάσεις τους στα επόμενα επίπεδα τα οποία μοντελοποιούν τις μακροπρόθεσμες. Έτσι λοιπόν αυξάνεται η ικανότητα του μοντέλου να αναπαριστά και να μαθαίνει πιο σύνθετες σχέσεις από τα δεδομένα εισόδου. Ωστόσο η πολλαπλή προσθήκη επιπέδων RNN μπορεί να προκαλέσει το πρόβλημα απειρισμού ή εξαφάνισης της κλίσης (exploding or vanishing gradient problem) ενώ αυξάνει και τη πολυπλοκότητα του μοντέλου και κατ' επέκταση και το χρόνο εκπαίδευσης του. Μέσω πειραματισμών αποφάνθηκε πως τα τρία επίπεδα RNN είναι αρκετά ώστε να θεωρούνται μια ασφαλής επιλογή που αυξάνει την απόδοση του μοντέλου σε προβλέψεις ενεργειακού φορτίου.

Οι υπερπαραμέτροι αυτού του μοντέλου βρέθηκαν μέσω διαδικασίας

βελτιστοποίησης υπερπαραμέτρων με τη βοήθεια της βιβλιοθήκης «optuna» για κάθε σύνολο δεδομένων ξεχωριστά. Τα εύρη τιμών που ελέγχθηκαν για κάθε υπερπάρμετρο είναι τα εξής :


- Νευρώνες επιπέδων RNN : [32, 64, 128, 256]
- Νευρώνες επιπέδων Dense : [64, 128, 256]
- Ποσοστό Dropout : [0.2, 0.25, 0.3, 0.35, 0.4, 0.45, 0.5]

Ο λόγος που δεν ελέγχθηκαν τιμές μικρότερες των 32 και μεγαλύτερες των 256 νευρώνων για κάθε επίπεδο είναι διότι το σύνολο δεδομένων δεν είναι αρκετά μικρό για να χρειάζεται λιγότερους ή πολύ μεγάλο για να απαιτεί περισσότερους για τη σωστή μοντελοποίηση του. Παρόμοια λογική εφαρμόστηκε και στην επιλογή νευρώνων των πλήρως συνδεδεμένων δικτύων ενώ το εύρος ελέγχου ποσοστών των νευρώνων που θα απενεργοποιηθούν στα επίπεδα «Dropout» είναι τέτοιο ώστε να παραμένει αρκετός αριθμός για να μεταδοθεί σωστά η πληροφορία και ταυτόχρονα να ελαττώνεται αρκετά η πιθανότητα υπερπροσαρμογής. Επίσης η επιλογή τιμών που είναι δυνάμεις του δύο αποτελεί σχεδιαστική επιλογή που βελτιστοποιεί την πρόσβαση στη μνήμη κατά τη διάρκεια εκπαίδευσης.

Αρχιτεκτονική του μοντέλου στοιβαγμένων LSTM (stacked LSTM)

Η επόμενη επιλογή αρχιτεκτονικής για την αποδοτική εξαγωγή χαρακτηριστικών αποτελούν τα επίπεδα LSTM τα οποία όπως έχει αναφερθεί είναι μια παραλλαγή των RNNs. Συγκεκριμένα επιλέχθηκαν καθώς χρησιμοποιούνται ευρέως λόγω της ικανότητας τους να διατηρούν μακροχρόνιες εξαρτήσεις και να ελαττώνουν τις πιθανότητες εμφάνισης του προβλήματος απειρισμού ή εξαφάνισης της κλίσης [60]. Για αυτό το λόγο θεωρούνται ιδανικά για τη διαχείριση της εποχικότητας και των χρονικών τάσεων στα ενεργειακά δεδομένα [72]. Όπως φαίνεται στην Εικόνα 3.12 ο σχεδιασμός του πρώτου μέρους είναι παρόμοιος με του προηγούμενου μοντέλου με τη μόνη διαφορά να είναι η αντικατάσταση των επιπέδων RNN με επίπεδα LSTM μέσω της εντολής «model.add(tf.keras.layers.LSTM())». Όπως και πριν με κάθε επίπεδο μοντελοποιούνται όλο και πιο μακροπρόθεσμες

εξαρτήσεις ενώ οι νευρώνες των επιπέδων LSTM μπορούν να διαχωρίσουν καλύτερα τις βραχυπρόθεσμες διακυμάνσεις με τις μακροχρόνιες τάσεις. Ωστόσο θα μπορούσαν να έχουν επιλεχθεί παραπάνω επίπεδα LSTM με σκοπό




Εικόνα 3.12: Αρχιτεκτονική του μοντέλου στοιβαγμένων LSTM

την καλύτερη εξαγωγή χαρακτηριστικών, εφόσον είναι πιο ανθεκτικά στο πρόβλημα του απειρισμού ή εξαφάνισης της κλίσης. Η επιλογή αυτή όμως συνέβη γιατί η εκπαίδευση επιπέδων LSTM είναι υπολογιστικά αρκετά πιο ακριβή και αργή από ότι των επιπέδων RNN ενώ ο ίδιος αριθμός επιπέδων διασφαλίζει ισοδύναμο βάθος εξαγωγής χαρακτηριστικών, επιτρέποντας συγκριτική αξιολόγηση της προβλεπτικής τους απόδοσης.

Οι υπερπαράμετροι όπως και στο προηγούμενο μοντέλο βρέθηκαν μέσω διαδικασίας βελτιστοποίησης υπερπαραμέτρων ενώ τα εύρη τιμών που ελέγχθηκαν για κάθε υπερπαράμετρο είναι τα ίδια σε αντιστοιχία με αυτά του μοντέλου με τα επίπεδα RNN.

Αρχιτεκτονική του μοντέλου στοιβαγμένων CNN (stacked CNN)

Στη συνέχεια απομακρυνόμενοι από τύπους επαναληπτικών νευρωνικών δικτύων επιλέχθηκε να εξεταστεί η ικανότητα ενός μοντέλου που ενσωματώνει συνελκτικά επίπεδα για την εξαγωγή χαρακτηριστικών [60]. Αναλυτικότερα παρόλο που σχεδιάστηκαν για επεξεργασία εικόνας, τα CNNs έχουν αξιοποιηθεί ευρέως στην πρόβλεψη χρονοσειρών γιατί έχουν τη δυνατότητα να ανιχνεύσουν χωρικές και χρονικές συσχετίσεις στα ενεργειακά δεδομένα [71]. Στην Εικόνα 3.13 φαίνεται με λεπτομέρεια ο σχεδιασμός του πρώτου μέρους αυτού του μοντέλου. Όπως και στα προηγούμενα μοντέλα στοιβάζονται τρία επίπεδα απλά στη προκειμένη περίπτωση είναι συνελκτικά και προστίθενται με την εντολή «`model.add(tf.keras.layers.Conv1D())`», εκ των οποίων το καθένα



Εικόνα 3.13: Αρχιτεκτονική του μοντέλου στοιβαγμένων CNN

ακολουθείται από ένα επίπεδο μέγιστης υποδειγματοληψίας (MaxPooling Layer) μέσω της εντολής «`model.add(tf.keras.layers.MaxPooling1D())`», . Το


πρώτο επίπεδο εκτελεί μονοδιάστατη συνέλιξη με μονοδιάστατο φίλτρο μήκους 5 και βήμα 1, δηλαδή ανιχνεύει χωρικές συσχετίσεις μεταξύ των χαρακτηριστικών εισόδου και χρονικές συσχετίσεις μεταξύ 5 συνεχόμενων χρονικών βημάτων. Τα επόμενα επίπεδα εκτελούν παρόμοιες συνέλιξεις απλά με φίλτρο μήκους 3, ώστε να εστιάσουν περισσότερο σε αναλυτικότερες βραχυπρόθεσμες συσχετίσεις. Τα επίπεδα MaxPooling πραγματοποιούν υποδειγματοληψία στο σύνολο εξαγόμενων χαρακτηριστικών λαμβάνοντας τη μέγιστη τιμή μεταξύ δυο διαδοχικών χρονικών βημάτων. Αυτά τα επίπεδα αποσκοπούν στην ελάττωση του μήκους της ακολουθίας διατηρώντας τις πιο σημαντικές πληροφορίες. Τέλος έπειτα από τις διαδοχικές συνέλιξεις και υποδειγματοληψίες, ο πολυδιάστατος χάρτης εξαγόμενων χαρακτηριστικών εισάγεται στο επίπεδο Flatten με τη βοήθεια της εντολής «model.add(tf.keras.layers.Flatten())», και μετατρέπεται σε μονοδιάστατο ώστε να μπορεί να επεξεργαστεί από τα επόμενα πλήρως συνδεδεμένα επίπεδα.

Οι υπερπαραμέτροι βρίσκονται ξανά με τον ίδιο τρόπο ενώ τα εύρη τιμών που ελέγχθηκαν είναι κατά αντιστοιχία τα ίδια με των προηγούμενων μοντέλων ακολουθώντας παρόμοια λογική.

Αρχιτεκτονική του υβριδικού μοντέλου (CNN-LSTM-hybrid)

Τελευταίο μοντέλο της ομάδας αποτελεί μια υβριδική προσέγγιση που συνδυάζει τα επίπεδα LSTM με τα επίπεδα CNN. Αποτελεί ένα συχνό υβριδικό σχεδιασμό σε προβλήματα πρόβλεψης χρονοσειρών καθώς συνδυάζει τις εξαιρετικές ικανότητες μοντελοποίησης χωρικών εξαρτήσεων που διαθέτουν τα συνελκτικά επίπεδα με τις ικανότητες μοντελοποίησης βραχυπρόθεσμων και μακροπρόθεσμων χρονικών εξαρτήσεων [60] [74]. Ειδικότερα στην εικόνα 3.14 φαίνεται η συνολική υβριδική αρχιτεκτονική. Τα πρώτα δύο επίπεδα είναι συνελκτικά τα οποία εξάγουν χαρακτηριστικά μεταξύ των δεδομένων με βάση τη χωρική διάταξη τους και μειώνουν τη διαστατικότητα τους πριν εισαχθούν στα επόμενα δύο επίπεδα LSTM τα οποία θα τα επεξεργαστούν περαιτέρω και θα διατηρήσουν τις σημαντικές χρονικές εξαρτήσεις διασφαλίζοντας την αποδοτική εκμάθηση εποχικών μοτίβων και τάσεων. Τα συνελκτικά επίπεδα μειώνουν το υπολογιστικό κόστος πριν την επεξεργασία των δεδομένων από τα επίπεδα LSTM γιατί τα εξαγόμενα χαρακτηριστικά που λειτουργούν ως είσοδο

σε αυτά είναι μικρότερα σε μέγεθος από ότι η πραγματική είσοδος, καθιστώντας αυτή τη προσέγγιση γρηγορότερη και ενδεχομένως πιο αποδοτική από την




Εικόνα 3.14: Αρχιτεκτονική του υβριδικού μοντέλου

απλή χρήση επιπέδων LSTM.

Οι υπερπαραμέτροι αυτού του μοντέλου ρυθμίστηκαν με τον ίδιο τρόπο ενώ τα εύρη τιμών που ελέγχθηκαν είναι αντίστοιχα με αυτά των προηγούμενων μοντέλων για να διασφαλιστεί δίκαιη σύγκριση των αποτελεσμάτων τους.

3.3.2 Το δίκτυο μετασχηματιστή συγχώνευσης χρόνου (Temporal Fusion Transformer)


Το μοντέλο μετασχηματιστή συγχώνευσης χρόνου (Temporal Fusion Transformer) στον τομέα της πρόβλεψης δεδομένων χρονοσειράς ξεχωρίζει ως μια καινοτόμα αρχιτεκτονική που προσφέρει ερμηνευσιμότητα και εξαιρετική προβλεπτική ακρίβεια. Ωστόσο η επιλογή εξέτασης των επιδόσεων αυτού του μοντέλου σε αυτήν την εργασία βασίστηκε στην ικανότητα του να μοντελοποιεί ταυτόχρονα τις βραχυπρόθεσμες και μακροπρόθεσμες χρονικές εξαρτήσεις ενώ η πιθανή ερμηνευσιμότητα που προσφέρει δεν εμπίπτει στο πλαίσιο της παρούσας διπλωματικής εργασίας. Σε αντίθεση με την ομάδα ακολουθιακών μοντέλων τα οποία εστιάζουν κυρίως σε ακολουθιακή εξαγωγή χαρακτηριστικών, το μοντέλο TFT ενσωματώνει πολλαπλά εξειδικευμένα δίκτυα για την πιο αποτελεσματική ανίχνευση των χρονικών σχέσεων που διέπουν τα δεδομένα [97].



Εικόνα 3.15: Διάγραμμα αρχιτεκτονικής του μοντέλου TFT [97]

Η υλοποίηση του μοντέλου πραγματοποιήθηκε με τη βοήθεια της βιβλιοθήκης «PyTorch Forecasting» η οποία βασίζεται στις γενικότερες βιβλιοθήκες «PyTorch» και «PyTorch Lightning». Το συγκεκριμένο πλαίσιο διευκολύνει αρκετά την υλοποίηση αυτού του σύνθετου μοντέλου αλλά και την αποδοτική εκπαίδευση του διαχειρίζοντας τη δημιουργία παρτίδων (batches) δεδομένων και τον κατανομημένο υπολογισμό τους.

Το μοντέλο TFT έχει σχεδιαστεί με βάση σημαντικές αρχιτεκτονικές καινοτομίες που του επιτρέπουν να διαθέτει υψηλή προβλεπτική ικανότητα όπως φαίνεται από το επίσημο διάγραμμα της αρχιτεκτονικής του στην Εικόνα 3.15. Αρχικά σε αντίθεση με τα άλλα μοντέλα διαχειρίζεται τα δεδομένα εισόδου ανάλογα την εξάρτησή τους με το χρόνο. Δηλαδή ξεχωρίζει τις στατικές μεταβλητές όπως η έκταση ενός κτιρίου με τις παρελθοντικές χρονικά εξαρτώμενες μεταβλητές όπως η κατανάλωση ή καιρικά χαρακτηριστικά και πιθανές γνωστές μελλοντικές εξωγενείς χρονικά εξαρτώμενες μεταβλητές όπως προβλεπόμενα μετεωρολογικά δεδομένα ή το μήνα πρόβλεψη. Στη προκειμένη περίπτωση σε αυτό το στάδιο επιλέγονται τα 48 προηγούμενα χρονικά βήματα, ενσωματώνονται (embeddings) οι μεταβλητές εισόδου ώστε να έχουν την ίδια διαστατικότητα και εισέρχονται στο δίκτυο επιλογής μεταβλητών.



Εικόνα 3.16: Αρχιτεκτονική δικτύου υπολειμματικών πύλων (Αριστερά) - Αρχιτεκτονική δικτύου επιλογής μεταβλητών (Δεξιά) [97]

Το δίκτυο υπολειμματικών πυλών (GRN)

Η λειτουργία όμως του δικτύου TFT βασίζεται ενεργά στην εκτεταμένη χρήση του δικτύου GRN το οποίο πρέπει να αναλυθεί πριν περιγραφεί η υπόλοιπη αρχιτεκτονική του. Η δομή του φαίνεται αριστερά στην Εικόνα 3.16 και πρόκειται για ένα δίκτυο το οποίο έχει κομβικό ρόλο στη συνολική απόδοση του μοντέλου ενώ προσφέρει ευελιξία καθώς εκτελεί μη γραμμική επεξεργασία πληροφοριών μόνο όταν είναι απαραίτητη. Συγκεκριμένα χρησιμοποιείται στην επεξεργασία και βελτίωση επιλεγμένων χαρακτηριστικών εισόδου, στην ενσωμάτωση των στατικών χαρακτηριστικών και στον εμπλουτισμό των αναπαραστάσεων των δεδομένων πριν και μετά την εφαρμογή του μηχανισμού προσοχής. Λαμβάνει μια αρχική είσοδο η οποία σε συνδυασμό με πιθανές στατικές μεταβλητές εισέρχεται σε ένα πλήρως συνδεδεμένο επίπεδο που ακολουθείται από μια εκθετική γραμμική συνάρτηση ενεργοποίησης (Exponential Linear Unit - ELU). Η συνάρτηση ELU χρησιμοποιείται γιατί επιτρέπει μικρές αρνητικές εξόδους, πράγμα που αποτρέπει πιθανούς νεκρούς νευρώνες και βελτιώνει τη ροή της κλίσης στα βαθιά νευρωνικά δίκτυα. Έτσι λοιπόν η έξοδος αποτελεί ένα μη γραμμικό μετασχηματισμό της εισόδου που εξαρτάται από ενδεχόμενες στατικές μεταβλητές εισόδου. Αυτή εισέρχεται σε ένα επιπλέον πλήρως συνδεδεμένο επίπεδο για περαιτέρω βελτίωση της αναπαράστασης η οποία ακολουθείται από ένα επίπεδο dropout για αποφυγή υπερπροσαρμογής. Τέλος για να προσφέρει την προαναφερθείσα ευελιξία και να αποκλείει μη απαραίτητα στοιχεία, το δίκτυο αξιοποιεί μονάδες γραμμικών πυλών (Gated Linear Units - GLUs). Αναλυτικότερα όλο το δίκτυο μπορεί να εκφραστεί ως εξής :

$$\begin{aligned} GRN_{\omega}(a, c) &= LayerNorm(a + GLU_{\omega}(\eta_2)) , \\ \eta_2 &= W_{2,\omega}\eta_1 + b_{2,\omega} , \\ \eta_1 &= ELU(W_{1,\omega}a + W_{2,\omega}c + b_{1,\omega}) , \\ GLU_{\omega}(\gamma) &= \sigma(W_{4,\omega}\gamma + b_{4,\omega}) \odot (W_{5,\omega}\gamma + b_{5,\omega}) \end{aligned}$$

όπου:

- a : Κύρια είσοδος του δικτύου
- c : Διάνυσμα πλαισίου στατικών μεταβλητών (Context vector)

- $\eta_i \in \mathbb{R}^{d_{model}}$: Οι έξοδοι των ενδιάμεσων δικτύων
- $W_{(.)} \in \mathbb{R}^{d_{model} \times d_{model}}$: Οι αντίστοιχοι πίνακες σταθμισμένων όρων
- $b_{(.)} \in \mathbb{R}^{d_{model}}$: Οι αντίστοιχοι όροι μεροληψίας
- $\sigma(.)$: Η σιγμοειδή συνάρτηση ενεργοποίησης
- $\odot$: Το γινόμενο Hadamard
- d_{model} : Το μέγεθος κρυφής κατάστασης του μοντέλου (hidden state size)

Το δίκτυο επιλογής παραμέτρων (VSN)

Το δίκτυο επιλογής μεταβλητών (Variable Selection Network) φαίνεται δεξιά στην Εικόνα 3.16 και όπως προαναφέρθηκε διαχειρίζεται διαφορετικά τους τύπους μεταβλητών. Κάθε ενσωματωμένη μεταβλητή εισόδου $\xi_t^{(i)}$ ενός χρονικού βήματος t εισέρχεται σε ένα δίκτυο υπολειμματικών πυλών (Gated Recurrent Unit) το οποίο εξάγει υψηλού επιπέδου αναπαραστάσεις. Οι έξοδοι από αυτά τα δίκτυα για κάθε μεταβλητή συνδυάζονται σε μια συνολική είσοδο E_t η οποία συνδυαστικά με κάποιο ενδεχόμενο διάνυσμα στατικών πληροφοριών c_s (context vector) εισέρχονται σε ένα ξεχωριστό δίκτυο GRN το οποίο συνοδεύεται από μια συνάρτηση ενεργοποίησης SoftMax με σκοπό την δημιουργία ενός σταθμισμένου όρου για κάθε μεταβλητή που αντιπροσωπεύει το πόσο σχετική είναι. Τέλος η κάθε μεταβλητή πολλαπλασιάζεται με τον σταθμισμένο όρο της διασφαλίζοντας ότι οι πιο σχετικές και σημαντικές μεταβλητές θα συνεισφέρουν περισσότερο στην τελική αναπαράσταση των δεδομένων εισόδου. Με αυτό το τρόπο μειώνεται ο θόρυβος και η πιθανότητα υπερπροσαρμογής εφόσον διατηρούνται τα πιο σημαντικά χαρακτηριστικά ενώ αυξάνεται η αποτελεσματικότητα του μοντέλου. Μαθηματικά μπορεί να εκφραστεί ως εξής :

$$v_{\chi t} = \text{Softmax} \left(GRN_{v_{\chi}} \left(E_t, c_s, c \right) \right),$$

$$\tilde{\xi}_t^{(i)} = GRN_{\tilde{\xi}_t^{(i)}}(\xi_t^{(i)}),$$

$$\tilde{\xi}_t = \sum_{i=1}^{m_{\chi}} v_{\chi t}^{(i)} \tilde{\xi}_t^{(i)}$$

όπου:

- $u_{\chi t} \in R^{d_{m\chi}}$: Το διάνυσμα σταθμισμένων όρων
- $\xi_t^{(i)}$: Το επεξεργασμένο διάνυσμα μιας μεταβλητής i τη χρονική στιγμή t
- $\tilde{\xi}_t$: Ο συνδυασμός σταθμισμένων διανυσμάτων κάθε μεταβλητής μια χρονική στιγμή t

Κωδικοποιητές στατικών μεταβλητών

Η αρχιτεκτονική του μοντέλου TFT περιλαμβάνει διάφορα σημεία στα οποία πραγματοποιείται ενσωμάτωση πληροφορίας από τα στατικά δεδομένα μέσω της χρήσης διανύσματος πληροφοριών (context vector). Για το σκοπό αυτό δημιουργούνται τέσσερα τέτοια διανύσματα c_s, c_e, c_c και c_h τα οποία χρησιμοποιούν ξεχωριστά δίκτυα GRN για τη κωδικοποίηση τους. Συγκεκριμένα το διάνυσμα c_s χρησιμοποιείται στην επιλογή μεταβλητών, τα διανύσματα c_c, c_h χρησιμοποιούνται στα επίπεδα LSTM και το διάνυσμα c_e στον εμπλουτισμό τους μετά την επεξεργασία τους από τα επίπεδα LSTM.

Το δίκτυο κωδικοποιητή-αποκωδικοποιητή με χρήση επιπέδων LSTM

Η συνολική αρχιτεκτονική αποτελεί σχεδιαστικά ένα σύστημα κωδικοποιητή-αποκωδικοποιητή. Έπειτα από την εξαγωγή των αναπαραστάσεων των δεδομένων εισόδου, αυτά εισέρχονται σε ένα ή περισσότερα επίπεδα LSTM για τη μοντελοποίηση βραχυπρόθεσμων χρονικών εξαρτήσεων. Στο στάδιο κωδικοποίησης λαμβάνονται τα διανύσματα c_c, c_h τα οποία αρχικοποιούν την κρυφή κατάσταση (hidden state) και την κατάσταση κελιού (cell state) του πρώτου νευρώνα LSTM του επιπέδου και οι αναπαραστάσεις παρελθοντικών χρονοεξαρτώμενων μεταβλητών τις ανανεώνουν για κάθε χρονικό βήμα ενώ η τελευταία κρυφή κατάσταση που περιέχει τις βραχυπρόθεσμες χρονικές εξαρτήσεις προωθείται για την αρχικοποίηση του σταδίου αποκωδικοποίησης. Σε αυτό το στάδιο λαμβάνονται οι αναπαραστάσεις των πιθανών γνωστών μελλοντικών χρονοεξαρτώμενων δεδομένων εισόδου ανά χρονικό βήμα και επεξεργάζονται παράλληλα όταν πραγματοποιείται η πρόβλεψη. Ανεξάρτητα του σταδίου κωδικοποίησης ή αποκωδικοποίησης η έξοδος από τα επίπεδα LSTM αποτελεί ένα διάνυσμα

αναπαράστασης συμφραζόμενων πληροφοριών το οποίο εισέρχεται σε ένα μηχανισμό πύλης για να αποφασιστεί αν η επεξεργασία είναι απαραίτητη ή όχι και προωθείται στο στάδιο στατικού εμπλουτισμού.

Επίπεδο στατικού εμπλουτισμού

Σε αυτό το στάδιο βελτιώνονται οι αναπαραστάσεις των σχετικών μεταβλητών περεταίρω με βάση και το διάνυσμα στατικής πληροφορίας c_e με σκοπό την κατάλληλη προετοιμασία τους για το επίπεδο χρονικής προσοχής (temporal attention). Αυτή η διαδικασία πραγματοποιείται μέσω του δικτύου GRN του οποίου οι παράμετροι μοιράζονται σε όλο το επίπεδο. Στη συνέχεια η έξοδος αυτού του επιπέδου εισέρχεται στο στάδιο προσοχής.

Ο μηχανισμός προσοχής του μοντέλου TFT

Η προσοχή που εφαρμόζεται από το μοντέλο TFT έχει σημαντικό ρόλο στην ανίχνευση μακροπρόθεσμων χρονικών εξαρτήσεων τις οποίες ενδεχομένως να μην μπορούν να μοντελοποιήσουν τα επίπεδα LSTM. Η είσοδος της είναι το εμπλουτισμένο διάνυσμα αναπαράστασης χαρακτηριστικών το οποίο διασφαλίζει ότι το δίκτυο προσοχής θα λειτουργεί με υψηλού επιπέδου αναπαραστάσεις. Συγκεκριμένα βασίζεται στο μηχανισμό προσοχής των μετασχηματιστών αλλά είναι σχεδιασμένο ειδικά για προβλέψεις σε δεδομένα χρονοσειρών καθώς διαθέτει μάσκα (masked attention), ώστε να μην διαρρέονται πληροφορίες από μελλοντικά χρονικά βήματα στη διαδικασία υπολογισμού της προσοχής, ενώ είναι και ερμηνεύσιμος (interpretable attention) καθώς όλα τα κεφάλια προσοχής μοιράζονται τον ίδιο πίνακα τιμών V (Values). Σε κάθε χρονικό βήμα ο μηχανισμός «προσέχει» όλα τα προηγούμενα χρονικά βήματα και μαθαίνει ένα σύνολο σταθμισμένων όρων προσοχής που καθορίζουν την σημασία του κάθε ενός για τη πρόβλεψη σε αυτό το βήμα. Κάθε χρονικό βήμα προθέτονται αντί να ενώνονται οι παρελθοντικές πληροφορίες των παράλληλων πολλαπλών κεφαλών προσοχής και λαμβάνονται έτσι τα ερμηνεύσιμα σκορ προσοχής (interpretable attention scores). Η συνολική διαδικασία μπορεί να περιγραφεί ως εξής :

$$\begin{aligned}
\text{InterpretableMultiHead}(Q, K, V) &= \tilde{H}W_H, \\
\tilde{H} &= \tilde{A}(Q, K)VW_V, \\
\tilde{H} &= \left\{ \frac{1}{m_H} \sum_{h=1}^{m_H} \text{Attention}(QW_Q^{(h)}, KW_K^{(h)}, VW_V) \right\}
\end{aligned}$$

όπου:

- $(W_K^{(h)}, W_Q^{(h)}) \in R^{d_{model} \times d_{attn}}$: Οι πίνακες K (Keys), V (Values) μιας κεφαλής προσοχής h
- $W_V \in R^{d_{model} \times d_V}$: Ο πίνακας V (Values)
- $W_H \in R^{d_{model} \times d_{model}}$: Πίνακας που χρησιμοποιείται για την τελική γραμμική αντιστοίχιση
- m_H : Ο αριθμός των κεφαλών προσοχής

Κατά τη διάρκεια της αποκωδικοποίησης μετά το στάδιο προσοχής οι αναπαραστάσεις εισάγονται σε ένα μηχανισμό πύλης για να εξεταστεί η χρησιμότητα της επεξεργασίας μέσω προσοχής και έπειτα σε ένα τελευταίο επίπεδο μη γραμμικής επεξεργασίας μέσω δικτύου GRN, του οποίου τα βάρη μοιράζονται σε όλο το επίπεδο. Στη συνέχεια η έξοδος εισέρχεται σε ένα τελευταίο μηχανισμό πύλης που εξετάζει αν είναι απαραίτητη η συνολική επεξεργασία των αναπαραστάσεων που συνέβη σε σχέση με την μορφή που βρίσκονταν μετά το επίπεδο των LSTM.

Πρόβλεψη μέσω βελτιστοποίησης ποσοστημορίων

Σε αντίθεση με τα άλλα μοντέλα που πραγματοποιούν ντετερμινιστική πρόβλεψη μιας τιμής, η πρόβλεψη που πραγματοποιεί το TFT είναι στη μορφή ποσοστημορίων ώστε να προσφέρει μια εκτίμηση αβεβαιότητας. Συγκεκριμένα η τελική αναπαράσταση εισέρχεται σε ένα πλήρως συνδεδεμένο επίπεδο του οποίου η έξοδος την αντιστοιχεί σε τιμές ποσοστημορίων. Αυτή η διαδικασία μπορεί να περιγραφεί ως εξής:

$$\hat{y}(q, t, \tau) = W_q \tilde{\Psi}(t, \tau) + b_q$$

όπου:

- $W_q \in R^{1 \times d}$: Ο πίνακας σταθμισμένων όρων
- $b_q \in R$: Οι όροι προκατάληψης
- $\tau \in \{1, \dots, \tau_{max}\}$: Ο χρονικός ορίζοντας πρόβλεψης
- q : Το ποσοστημόριο πρόβλεψης

Συγκεκριμένα πραγματοποιούνται προβλέψεις του 10^{ου}, 50^{ου} και 90^{ου} ποσοστημορίου ενώ η συνάρτηση απώλειας που χρησιμοποιείται αποτελεί το σύνολο της απώλειας pinball για όλες τις εξόδους η οποία εκφράζεται ως εξής:

$$\mathcal{L}(\Omega, W) = \sum_{y_t \in \Omega} \sum_{q \in Q} \sum_{\tau=1}^{\tau_{max}} \frac{QL(y_t, \hat{y}(q, t - \tau, \tau), q)}{M\tau_{max}}$$

$$QL(y, \hat{y}, q) = \begin{cases} q(y - \hat{y}) & \text{αν } y \geq \hat{y} \\ (1 - q)(\hat{y} - y) & \text{αν } y < \hat{y} \end{cases}$$

όπου:

- $L_q(y, \hat{y}, q)$: Η συνάρτηση απώλειας pinball
- Ω : Ο τομέας εκπαίδευσης που περιέχει M δείγματα
- W : Το σύνολο όλων των σταθμισμένων όρων του μοντέλου TFT
- Q : Το σύνολο ποσοστημορίων [0.1, 0.5, 0.9]
- y : Η πραγματική τιμή
- $\hat{y}$: Η προβλεπόμενη τιμή
- q : Το ποσοστημόριο

Στην ουσία η εκτίμηση ενός ποσοστημορίου διασφαλίζει ότι το αντίστοιχο ποσοστό των πραγματικών τιμών είναι μικρότερες από αυτήν. Έτσι διασφαλίζονται προβλέψεις πιθανοτικής φύσεως οι οποίες είναι αρκετά ανθεκτικές σε ακραίες τιμές. Ωστόσο για την άμεση σύγκριση με την απόδοση των άλλων ακολουθιακών μοντέλων λαμβάνουμε το 50^ο ποσοστημόριο.

Επιλογή εύρους υπερπαραμέτρων

Η εύρεση των βέλτιστων υπερπαραμέτρων για κάθε σύνολο δεδομένων πραγματοποιήθηκε και σε αυτό το μοντέλο μέσω αυτοματοποιημένης διαδικασίας χρησιμοποιώντας τη βιβλιοθήκη «ortuna». Η επιλογή ωστόσο του εύρους των τιμών για κάθε υπερπαραμέτρο που ελέγχθηκαν είναι οι εξής:

- Μέγεθος κρυφής κατάστασης: [32, 64, 128]
- Μέγεθος συνεχούς ενσωμάτωσης : [8, 16, 32]
- Αριθμός κεφαλών προσοχής: Από 2 έως 8 με βήμα 1
- Επίπεδα LSTM: 2
- Ποσοστό Dropout : [0.2, 0.25, 0.3, 0.35, 0.4, 0.45, 0.5]

Το μέγεθος κρυφών επιπέδων καθορίζει τον αριθμό νευρώνων σε κάθε επίπεδο του μοντέλου και δεδομένου του μεγέθους των συνόλων δεδομένων που θα αξιοποιηθούν αυτό το εύρος αποδείχθηκε κατάλληλος συμβιβασμός μεταξύ επαρκούς μοντελοποίησης και αποφυγής υπερπροσαρμογής. Ο λόγος που δεν εξετάστηκε το μοντέλο με 256 νευρώνες σε κάθε επίπεδο είναι διότι θα γινόταν πολύ περίπλοκο για τα δεδομένα που διαθέτουμε ενώ ο χρόνος εκπαίδευσης του θα αυξανόταν πολύ περισσότερο σχετικά με τα άλλα μεγέθη. Ταυτόχρονα το μέγεθος συνεχούς ενσωμάτωσης αφορά το μέγεθος ανάλυσης των συνεχών μεταβλητών πριν την επεξεργασία τους και βάση πειραματισμού αυτές οι τιμές αποτελούν ικανοποιητικό εύρος για τον έλεγχο αποδοτικών και περιγραφικών σεναρίων ενσωμάτωσης. Επιπλέον το στάδιο προσοχής αποτελεί ένα από τα πιο σημαντικά σημεία επεξεργασίας με αποτέλεσμα να ελεγχθεί ένα αρκετά μεγάλο εύρος αριθμών κεφαλών. Από την άλλη τα επίπεδα LSTM επιλέχθηκαν να είναι δύο καθώς αποτελεί μια ισορροπία μεταξύ εξαγωγής δεδομένων και υπολογιστικής αποδοτικότητας, ιδιαίτερα δεδομένου του επόμενου σταδίου επεξεργασίας μέσω προσοχής που ακολουθεί. Τέλος το εύρος τιμών του ποσοστού dropout παραμένει παρόμοιο με τα προηγούμενα μοντέλα για τους ίδιους λόγους.

3.4 Μεθοδολογία εκπαίδευσης και πρόβλεψης

Τα δεδομένα έχουν πλέον διαμορφωθεί στην κατάλληλη μορφή για εκπαίδευση ενώ τα μοντέλα που θα χρησιμοποιηθούν για την πρόβλεψη έχουν σχεδιαστεί πλήρως, λαμβάνοντας υπόψη τόσο τις αρχιτεκτονικές απαιτήσεις όσο και τις ιδιαιτερότητες των δεδομένων. Επομένως το επόμενο βήμα περιλαμβάνει το λεπτομερή σχεδιασμό της διαδικασίας εκπαίδευσης αλλά και πρόβλεψης ο οποίος θα αναλυθεί διεξοδικά στην παρούσα υποενότητα.

3.4.1 Διαδικασία εκπαίδευσης

Για την πραγματοποίηση των πειραμάτων που θέλουμε να εκτελέσουμε πρέπει αρχικά να εκπαιδεύσουμε τα διαθέσιμα μοντέλα στο σύνολο δεδομένων του πηγαίου κτιρίου το οποίο διαθέτει δεδομένα δύο χρόνων. Έπειτα η ίδια διαδικασία θα επαναληφθεί για ανεκπαιδευτες μορφές των μοντέλων στα σύνολα δεδομένων διάρκειας 12 μηνών του πρώτου και του δεύτερου στοχευμένου κτιρίου αλλά και στο εξειδικευμένο σύνολο διάρκειας 6 μηνών που λήφθηκε από το πρώτο. Έτσι θα υπάρχει διαθέσιμη η σύγκριση της απόδοσης προβλέψεων στα δεδομένα ενός στοχευμένου κτιρίου μεταξύ ενός μοντέλου που έχει εκπαιδευτεί αμιγώς σε αυτό και του ίδιου μοντέλου που διαθέτει γνώση από εκπαίδευση στα δεδομένα του πηγαίου.

Πλαίσιο βασικής εκπαίδευσης

Για τη διασφάλιση της καλύτερης πιθανής εκπαίδευσης κάθε μοντέλου δημιουργούμε ένα χώρο αναζήτησης υπερπαραμέτρων που περιλαμβάνει ένα εύρος τιμών για κάθε υπερπαραμέτρο δημιουργώντας συνδυασμούς με τους οποίους πραγματοποιούνται δοκιμές εκπαίδευσης με σκοπό την εύρεση αυτού που ελαχιστοποιηθεί την επιλεγμένη συνάρτηση σφάλματος. Η αυτοματοποίηση και βελτιστοποίηση αυτής της διαδικασίας πραγματοποιείται

μέσω της βιβλιοθήκης «optuna» η οποία αξιοποιεί μια προσέγγιση μπεϋζιανής βελτιστοποίησης η οποία επιλέγει κατάλληλους συνδυασμούς τιμών υπερπαραμέτρων για την μείωση της συνάρτησης σφάλματος πιο αποδοτικά από ότι μια τυχαία επιλογή ανά δοκιμή εκπαίδευσης. Συγκεκριμένα χρησιμοποιεί Δενδροειδείς Εκτιμητές Parzen (Tree-structured Parzen Estimators - TPE) για την αξιολόγηση των πιο υποσχόμενων περιοχών του χώρου αναζήτησης ενώ εκμεταλλεύεται αξιολογήσεις συνδυασμών υπερπαραμέτρων από προηγούμενες δοκιμές εκπαίδευσης, ανανεώνοντας έτσι το εσωτερικό μοντέλο του ώστε να βελτιώσει την επιλογή του συνδυασμού υπερπαραμέτρων της επόμενης δοκιμής [98].

Για την διαδικασία βελτιστοποίησης υπερπαραμέτρων, εκτός από αυτές που εξαρτώνται από το μοντέλο οι οποίες αναλύθηκαν προηγουμένως, επιλέχθηκε και το ακόλουθο εύρος τιμών για τις υπερπαραμέτρους εκπαίδευσης ως εξής:

- Ρυθμός μάθησης : 0.0001 έως 0.01 μέσω λογαριθμικής δειγματοληψίας
- Μέγεθος παρτίδας : [32,64,128,256] (πηγαίο), [32,64,128] (στοχευμένα)

Συγκεκριμένα ο ρυθμός μάθησης επιλέχθηκε με τέτοιο τρόπο ώστε να μην είναι πολύ υψηλός καθώς υπάρχει ο κίνδυνος υπερπροσαρμογής και ταυτόχρονα να μην είναι πολύ χαμηλός ώστε να υπάρχει ουσιώδη εκμάθηση ανά εποχή εκπαίδευσης. Ταυτόχρονα το μέγεθος παρτίδας δεδομένων παραμένει από 32 έως 256 δείγματα για την εκπαίδευση στο σύνολο δεδομένων του πηγαίου κτιρίου και από 32 έως 128 δείγματα για την εκπαίδευση στα στοχευμένα. Η επιλογή 256 δειγμάτων ανά παρτίδα δεν επιλέχθηκε για τα στοχευμένα κτίρια καθώς υπάρχει μεγάλη μείωση στο σύνολο των δεδομένων με αποτέλεσμα να υφίστανται ανανέωση των σταθμισμένων όρων του κάθε μοντέλου λιγότερες φορές ανά εποχή εκπαίδευσης. Επίσης μειώνονται οι ικανότητες γενίκευσης του μοντέλου και αυξάνονται οι πιθανότητες υπερπροσαρμογής. Αντίθετα τιμές μικρότερες των 32 θα ανανεώσουν πολύ συχνά το μοντέλο ανά μια εποχή εισάγοντας θόρυβο και καθιστώντας την εκπαίδευση πιο ασταθή. Για το στάδιο βελτιστοποίησης των υπερπαραμέτρων επιλέχθηκε ο αριθμός 40 δοκιμών εκπαίδευσης ώστε να εξεταστεί επαρκής αριθμός συνδυασμών.

Στη συνέχεια κατά τη διάρκεια της εκπαίδευσης για την ανανέωση παραμέτρων του μοντέλου έπειτα από την επεξεργασία κάθε παρτίδας

δεδομένων επιλέχθηκε να χρησιμοποιηθεί ο αλγόριθμος βελτιστοποίησης ADAM, ο οποίος αποτελεί μια ευρέως διαδεδομένη μέθοδο στοχαστικής βελτιστοποίησης [99]. Συγκεκριμένα σε αντίθεση με τη μέθοδο της στοχαστικής καθόδου κλίσης (Stochastic Gradient Descent) που χρησιμοποιεί σταθερό ρυθμό μάθησης, ο αλγόριθμος ADAM προσαρμόζει τον προκαθορισμένο ρυθμό ανάλογα τον όρο προς ανανέωση. Αυτό το χαρακτηριστικό προσφέρει σταθερή εκπαίδευση ενώ ταυτόχρονα συλλέγει προηγούμενες κλίσεις για να την επιταχύνει. Ο αλγόριθμος ADAM υλοποιείται με την βοήθεια της εντολής «tf.keras.optimizers.Adam()» και ενσωματώνεται στο εκάστοτε ακολουθιακό μοντέλο ως όρισμα εισόδου στην εντολή «model.compile()» ενώ για το μοντέλο TFT ορίζεται κατευθείαν σαν τιμή της υπερπαραμέτρου του «optimizer = “Adam”».

Η διάρκεια της βασικής εκπαίδευσης σε κάθε σύνολο δεδομένων για όλα τα ακολουθιακά μοντέλα που εκπαιδεύτηκαν ορίστηκε στις 40 εποχές στοχεύοντας σε μια ισορροπία μεταξύ γρήγορης και αναλυτικής εκπαίδευσης ενώ από το σύνολο εκπαίδευσης επιλέχθηκε το ποσοστό 20% ως σύνολο επαλήθευσης το οποίο αποτελεί μια ευρέως διαδεδομένη αναλογία για αυτό το σκοπό. Σε αυτό το σύνολο επιχειρεί να προβλέψει το μοντέλο στο τέλος μιας εποχής ώστε να υπολογιστεί το σφάλμα επαλήθευσης. Αυτό αποτελεί σημαντικό δείκτη αξιολόγησης της εκπαίδευσης και θα χρησιμεύσει στην εφαρμογή της μεθόδου πρώιμης διακοπής (Early Stopping), η οποία δέχεται σαν παράμετρο έναν δείκτη υπομονής που υποδεικνύει πόσες εποχές εκπαίδευσης θα επιτρέψει σε ένα μοντέλο να εκτελέσει χωρίς να παρουσιάσει μείωση στο σφάλμα επαλήθευσης. Ταυτόχρονα διατηρεί στη μνήμη τις τιμές των παραμέτρων της εποχής με το ελάχιστο σφάλμα ώστε όταν σταματήσει η εκπαίδευση να επαναφέρει τις παραμέτρους του μοντέλου στις βέλτιστες τιμές τους. Αποτελεί έναν αποδοτικό τρόπο για να επιταχυνθεί η εκπαίδευση και να αποφευχθεί η υπερπροσαρμογή στο εκάστοτε σύνολο εκπαίδευσης ενώ υλοποιείται μέσω της εντολής «es = tf.keras.callbacks.EarlyStopping()» με δείκτη υπομονής ίσο με 10 για τις βασικές εκπαιδεύσεις. Παράλληλα επιλέγεται να ενεργοποιηθεί η τυχαία αναδιάταξη των δεδομένων κατά τη διαδικασία εκπαίδευσης, με σκοπό τη βελτίωση της γενίκευσης του μοντέλου και την αποφυγή πιθανής μεροληψίας που ενδεχομένως να προκύψει από τη σειρά των δειγμάτων. Τέλος η εκπαίδευση ενός ακολουθιακού μοντέλου πραγματοποιείται με την εντολή «model.fit()»

στην οποία εισάγουμε ως ορίσματα το σύνολο εκπαίδευσης χωρισμένο στις ακολουθίες εισόδου 48 ωρών και στις τιμές-στόχους που αντιστοιχούν σε αυτές, τον αριθμό εποχών, την αναλογία συνόλου επαλήθευσης, το μέγεθος παρτίδας, την ενεργοποίηση ή μη της αναδιάταξης και την εισαγωγή της μεθόδου πρώιμης διακοπής.

Όσον αφορά το μοντέλο TFT η υλοποίηση του γίνεται μέσω της βιβλιοθήκης «Pytorch Forecasting» ενώ η εκπαίδευση τους μέσω της βιβλιοθήκης «Pytorch Lightning». Αρχικά το σύνολο δεδομένων έχει οριστεί ως αντικείμενο της κλάσης «pytorch_forecasting.TimeSeriesDataSet» που είναι συμβατή με το μοντέλο, το οποίο δημιουργείται μέσω της εντολής:

```
Model = pytorch_forecasting.models.TemporalFusionTransformer.fromDataset()
```

όπου ορίζεται εκτός των υπερπαραμέτρων του που έχουν αναλυθεί προηγουμένως και το σύνολο δεδομένων στο οποίο θα εκπαιδευτεί καθώς έτσι λαμβάνει τις απαραίτητες πληροφορίες για τον τύπο κάθε μεταβλητής της. Επίσης για να πραγματοποιηθεί η εκπαίδευση χρειάστηκε να δημιουργηθεί ένας εκπαιδευτής (trainer) μέσω της εντολής `lightning.pytorch.Trainer()` στον οποίο ορίζεται το ίδιο πλαίσιο εκπαίδευσης με τα ακολουθιακά μοντέλα. Για λόγους συμβατότητας η εντολή «`lightning.pytorch.callbacks.EarlyStopping()`» χρησιμοποιήθηκε στην συγκεκριμένη περίπτωση για τον ορισμό της πρώιμης διακοπής. Ωστόσο για την ροή των παρτίδων χρειάστηκε να μετατρέψουμε το σύνολο δεδομένων `TimeSeriesDataSet` σε μια δομή που θα διαχειρίζεται αποδοτικά την επεξεργασία των παρτίδων και την φόρτωση των δεδομένων (dataloader) μέσω της εντολής «`TimeSeriesDataSet.to_dataloader()`». Έτσι το μοντέλο και η μετασχηματισμένη μορφή των συνόλων δεδομένων εκπαίδευσης και επαλήθευσης εισέρχονται σαν ορίσματα στην εντολή «`trainer.fit()`» ώστε να ξεκινήσει η εκπαίδευση.

Βασική εκπαίδευση στο πηγαίο σύνολο δεδομένων

Παρακάτω αποδίδονται οι τιμές των υπερπαραμέτρων κάθε μοντέλου έπειτα από τη διαδικασία βελτιστοποίησης υπερπαραμέτρων στο πηγαίο σύνολο δεδομένων.

Ακολουθιακά μοντέλα

Model	Feature Extraction Units	Dense Units	Dropout rates	Batch Size	Learning Rate
Stacked RNN	1 st RNN layer: 256 2 nd RNN layer: 256 3 rd RNN layer: 32	1 st layer: 256 2 nd layer: 64	1 st layer: 0.45 2 nd layer: 0.5	32	0.000722
Stacked CNN	1 st CNN layer: 64 2 nd CNN layer: 32 3 rd CNN layer: 128	1 st layer: 256 2 nd layer: 256	1 st layer: 0.35 2 nd layer: 0.25	128	0.000296
Stacked LSTM	1 st LSTM layer: 256 2 nd LSTM layer: 128 3 rd LSTM layer: 128	1 st layer: 256 2 nd layer: 256	1 st layer: 0.2 2 nd layer: 0.5	32	0.002446
CNN-LSTM-Hybrid	1 st CNN layer: 128 2 nd CNN layer: 256 1 st LSTM layer: 128 2 nd LSTM layer: 64	1 st layer: 128 2 nd layer: 128	1 st layer: 0.2 2 nd layer: 0.35	32	0.000423

Μοντέλο TFT

Model	Hidden Size	Hidden Continuous Size	Attention Heads	Dropout Rate	Batch Size	Learning Rate
TFT	32	32	5	0.35	256	0.000654

Βασική εκπαίδευση στο πρώτο στοχευμένο σύνολο δεδομένων

Παρακάτω αποδίδονται οι τιμές των υπερπαραμέτρων κάθε μοντέλου έπειτα από τη διαδικασία βελτιστοποίησης υπερπαραμέτρων στο πρώτο στοχευμένο σύνολο δεδομένων διάρκειας 12 μηνών.

Ακολουθιακά μοντέλα

Model	Feature Extraction Units	Dense Units	Dropout rates	Batch Size	Learning Rate
Stacked RNN	1 st RNN layer: 256 2 nd RNN layer: 256 3 rd RNN layer: 32	1 st layer: 256 2 nd layer: 64	1 st layer: 0.5 2 nd layer: 0.2	64	0.000973
Stacked CNN	1 st CNN layer: 256 2 nd CNN layer: 32 3 rd CNN layer: 256	1 st layer: 256 2 nd layer: 256	1 st layer: 0.35 2 nd layer: 0.5	64	0.000296

Stacked LSTM	1 st LSTM layer: 64 2 nd LSTM layer: 32 3 rd LSTM layer: 64	1 st layer: 128 2 nd layer: 64	1 st layer: 0.45 2 nd layer: 0.5	32	0.001310
CNN-LSTM-Hybrid	1 st CNN layer: 256 2 nd CNN layer: 256 1 st LSTM layer: 64 2 nd LSTM layer: 128	1 st layer: 256 2 nd layer: 64	1 st layer: 0.25 2 nd layer: 0.25	32	0.004526

Μοντέλο TFT

Model	Hidden Size	Hidden Continuous Size	Attention Heads	Dropout Rate	Batch Size	Learning Rate
TFT	128	8	6	0.25	32	0.000990

Στη συνέχεια αποδίδονται οι τιμές για το ίδιο σύνολο διάρκειας 6 μηνών.

Ακολουθιακά μοντέλα

Model	Feature Extraction Units	Dense Units	Dropout rates	Batch Size	Learning Rate
Stacked RNN	1 st RNN layer: 256 2 nd RNN layer: 64 3 rd RNN layer: 32	1 st layer: 256 2 nd layer: 64	1 st layer: 0.4 2 nd layer: 0.2	64	0.000676
Stacked CNN	1 st CNN layer: 256 2 nd CNN layer: 32 3 rd CNN layer: 64	1 st layer: 256 2 nd layer: 64	1 st layer: 0.3 2 nd layer: 0.3	32	0.002476
Stacked LSTM	1 st LSTM layer: 256 2 nd LSTM layer: 64 3 rd LSTM layer: 64	1 st layer: 128 2 nd layer: 64	1 st layer: 0.2 2 nd layer: 0.45	32	0.002779
CNN-LSTM-Hybrid	1 st CNN layer: 64 2 nd CNN layer: 32 1 st LSTM layer: 128 2 nd LSTM layer: 128	1 st layer: 128 2 nd layer: 128	1 st layer: 0.3 2 nd layer: 0.3	32	0.008879

Μοντέλο TFT

Model	Hidden Size	Hidden Continuous Size	Attention Heads	Dropout Rate	Batch Size	Learning Rate
TFT	64	8	7	0.35	32	0.000366

Βασική εκπαίδευση στο δεύτερο στοχευμένο σύνολο δεδομένων

Παρακάτω αποδίδονται οι τιμές των υπερπαραμέτρων κάθε μοντέλου έπειτα από τη διαδικασία βελτιστοποίησης υπερπαραμέτρων στο δεύτερο στοχευμένο σύνολο δεδομένων διάρκειας 12 μηνών.

Ακολουθιακά μοντέλα

Model	Feature Extraction Units	Dense Units	Dropout rates	Batch Size	Learning Rate
Stacked RNN	1 st RNN layer: 256 2 nd RNN layer: 128 3 rd RNN layer: 128	1 st layer: 128 2 nd layer: 256	1 st layer: 0.2 2 nd layer: 0.35	32	0.000743
Stacked CNN	1 st CNN layer: 256 2 nd CNN layer: 128 3 rd CNN layer: 128	1 st layer: 256 2 nd layer: 64	1 st layer: 0.3 2 nd layer: 0.35	64	0.005045
Stacked LSTM	1 st LSTM layer: 128 2 nd LSTM layer: 64 3 rd LSTM layer: 64	1 st layer: 128 2 nd layer: 256	1 st layer: 0.3 2 nd layer: 0.4	32	0.005150
CNN-LSTM-Hybrid	1 st CNN layer: 64 2 nd CNN layer: 128 1 st LSTM layer: 32 2 nd LSTM layer: 32	1 st layer: 256 2 nd layer: 128	1 st layer: 0.35 2 nd layer: 0.45	32	0.000606

Μοντέλο TFT

Model	Hidden Size	Hidden Continuous Size	Attention Heads	Dropout Rate	Batch Size	Learning Rate
TFT	32	8	2	0.25	32	0.000870

3.4.2 Χρονικοί ορίζοντες προβλέψεων

Αν είναι διαθέσιμα τα εκπαιδευμένα μοντέλα τότε μπορεί να πραγματοποιηθεί πρόβλεψη στα σύνολα δεδομένων δοκιμής (test sets) τα οποία αποσπώνται ως το ποσοστό 20% του συνολικού συνόλου από το τέλος. Με αυτό το τρόπο μπορούν να παραχθούν προβλέψεις κατανάλωσης φορτίου για όλη αυτή τη διάρκεια και να συγκριθούν με τις πραγματικές τιμές ώστε να αξιολογηθούν με βάση τους επιθυμητούς χρονικούς ορίζοντες πρόβλεψης. Η

πρόβλεψη πραγματοποιείται σε όλες τις περιπτώσεις μέσω της εντολής «model.predict()» η οποία δέχεται σαν όρισμα το σύνολο δεδομένων δοκιμής. Από το τελικό σύνολο προβλέψεων πραγματοποιήθηκαν συγκρίσεις με τις πραγματικές τιμές για τις χρονικές περιόδους που αντιστοιχούν στην επόμενη μέρα, επόμενη εβδομάδα και επόμενο μήνα και παράχθηκαν τα αντίστοιχα αποτελέσματα και μετρικές αξιολόγησης που θα αναλυθούν στο κεφάλαιο 4.

Πρόβλεψη επόμενης μέρας

Η πρόβλεψη κατανάλωσης φορτίου ενός κτιρίου για την επόμενη μέρα αποτελεί αναγκαία πληροφορία για την βραχυπρόθεσμη διαχείριση ενέργειας, διασφαλίζοντας την αποδοτική καθημερινή χρήση της και βελτιστοποιώντας το κόστος. Είναι ιδιαίτερα χρήσιμη για προγράμματα απόκρισης στη ζήτηση (demand response programs), όπου τα κτίρια μπορούν να μειώσουν το φορτίο κατά τις ώρες αιχμής, ανταποκρινόμενα σε δυναμικές μεταβολές στις τιμές της ηλεκτρικής ενέργειας ή στις συνθήκες του δικτύου. Επιπλέον, οι ημερήσιες προβλέψεις επιτρέπουν τη βέλτιστη αξιοποίηση των συστημάτων αποθήκευσης ενέργειας και των κατανεμημένων ενεργειακών πόρων όπως τα φωτοβολταϊκά συστήματα καθώς η αποθηκευμένη ενέργεια τους χρησιμοποιείται τις πιο αποδοτικές χρονικές στιγμές.

Πρόβλεψη επόμενης εβδομάδας

Η γνώση του ηλεκτρικού ενεργειακού φορτίου για την επόμενη εβδομάδα χρησιμεύει στον μεσοπρόθεσμο ενεργειακό προγραμματισμό επιτρέποντας την αποτελεσματικότερη διαχείριση της προμηθευόμενης ενέργειας και της συντήρησης των συστημάτων. Προβλέποντας τις διακυμάνσεις της ζήτησης ηλεκτρικής ενέργειας κατά τη διάρκεια της εβδομάδας επιτρέπει στους διαχειριστές εγκαταστάσεων να βελτιστοποιήσουν τη χρήση ενέργειας μεταξύ περιόδων αιχμής και εκτός αιχμής. Είναι ιδιαίτερα πολύτιμες γνώσεις για μεγάλα εμπορικά κτίρια, βιομηχανικές εγκαταστάσεις ή έξυπνες πανεπιστημιούπολεις καθώς οι εβδομαδιαίες τάσεις κατανάλωσης παρουσιάζουν την ενεργειακή συμπεριφορά που καθορίζει την απαραίτητη αγορά ενέργειας και τις στρατηγικές τιμολόγησης με βάση το χρόνο χρήσης

(time-of-use tariff strategies). Επιπλέον, η προληπτική συντήρηση των ηλεκτρικών υποδομών μπορεί να προγραμματιστεί με βάση την αναμενόμενη μεταβολή φορτίου, μειώνοντας τον κίνδυνο αιφνίδιων βλαβών και διακοπών λειτουργίας.

Πρόβλεψη επόμενου μήνα

Από την άλλη οι προβλεπόμενες εκτιμήσεις μηνιαίας ηλεκτρικής κατανάλωσης είναι απαραίτητες για τον μακροπρόθεσμο ενεργειακό προγραμματισμό, τη διαχείριση προϋπολογισμού και τις διαπραγματεύσεις συμβολαίων με τους παρόχους ενέργειας. Κατά τη διάρκεια αυτού του χρονικού ορίζοντα αναγνωρίζεται η εποχικότητα στην χρήση ηλεκτρικής ενέργειας επιτρέποντας έτσι τη κατάλληλη προετοιμασία για πιθανές περιόδους υψηλής κατανάλωσης. Ταυτόχρονα οι διαχειριστές εγκαταστάσεων μπορούν να αξιοποιήσουν τις μηνιαίες προβλέψεις για τη διαπραγμάτευση ευνοϊκότερης τιμολόγησης ηλεκτρικής ενέργειας και τη βελτιστοποίηση της συμμετοχής σε προγράμματα απόκρισης στη ζήτηση (demand response programs).

3.5 Μεθοδολογία μεταφοράς μάθησης

Η βασική εκπαίδευση όλων των μοντέλων σε όλα τα σύνολα δεδομένων έχει πλέον ολοκληρωθεί και τα εκπαιδευμένα μοντέλα έχουν αποθηκευτεί. Στη συνέχεια θα εφαρμοστούν ορισμένες τεχνικές μεταφοράς μάθησης βασιζόμενες στις παραμέτρους (Parameter-based) των προεκπαιδευμένων πλέον μοντέλων του συνόλου δεδομένων του πηγαίου κτιρίου με σκοπό τις προβλέψεις στα στοχευμένα κτίρια. Σε αυτή την υποενότητα θα αναλυθούν όλες οι τεχνικές που επιλέχθηκαν για κάθε μοντέλο αλλά και ο λόγος που επιλέχθηκαν.

3.5.1 Τεχνικές μεταφοράς μάθησης ακολουθιακών μοντέλων

Τα ακολουθιακά μοντέλα όπως αναφέρθηκε ήδη αποτελούν μια ομάδα μοντέλων των οποίων η αρχιτεκτονική τους είναι σχεδιαστικά παρόμοια αποτελούμενη από το πρώτο μέρος που είναι υπεύθυνο για την εξαγωγή χαρακτηριστικών και το δεύτερο που αποσκοπεί στην επεξεργασία των εξαγόμενων χαρακτηριστικών για την πρόβλεψη. Για αυτό τον λόγο εφαρμόστηκαν οι ίδιες τρεις τεχνικές μεταφοράς μάθησης για όλα τα μοντέλα με εξαίρεση το υβριδικό για το οποίο υλοποιήθηκαν επιπλέον δύο λόγω της δομής του. Ο λόγος που επιλέχθηκε η επαναπροσαρμογή (finetuning) σαν είδος μεταφοράς μάθησης είναι διότι ένα προεκπαιδευμένο μοντέλο διαθέτει χρήσιμη γνώση όπως επαναλαμβανόμενα μοτίβα κατανάλωσης φορτίου ή εποχικές διακυμάνσεις οι οποίες με επανεκπαίδευση προσαρμόζονται στο στοχευμένο. Επίσης είναι ιδανικό είδος μεταφοράς μάθησης δεδομένης της ομοιότητας των χώρων χαρακτηριστικών αλλά και του είδους της πρόβλεψης μεταξύ των συνόλων δεδομένων .

Πλήρη επαναπροσαρμογή μοντέλου

Η πρώτη τεχνική μεταφοράς μάθησης που εφαρμόστηκε είναι μια πλήρη επαναπροσαρμογή στο εκάστοτε στοχευμένο σύνολο δεδομένων. Αναλυτικότερα λαμβάνεται το εξεταζόμενο, προεκπαιδευμένο στο πηγαίο σύνολο δεδομένων, μοντέλο και επανεκπαιδεύεται στο στοχευμένο. Πριν την επανεκπαίδευση το πρώτο μέρος του μοντέλου έχει ήδη μάθει χρήσιμα χαρακτηριστικά από το πηγαίο σύνολο ενώ το δεύτερο μέρος έχει μάθει να αντιστοιχεί αυτά τα χαρακτηριστικά στην προβλεπόμενη τιμή κατανάλωσης ηλεκτρικής ενέργειας του πηγαίου κτιρίου. Προσαρμόζοντας και τα δύο μέρη του μοντέλου σε ένα στοχευμένο σύνολο δεδομένων έχει ως αποτέλεσμα να ρυθμιστεί όλη η λειτουργία του μοντέλου ανάλογα το στοχευμένο σύνολο. Έτσι διατηρεί ένα μέρος της ήδη υπάρχουσας γνώσης του ενώ ταυτόχρονα την εμπλουτίζει με πληροφορίες σχετικά με τον στοχευμένο τομέα. Για την εκτέλεση αυτής της τεχνικής φορτώνουμε το αποθηκευμένο προεκπαιδευμένο μοντέλο

μέσω της εντολής «tf.keras.models.load_model()» και έπειτα εκτελούμε το ίδιο πλαίσιο εκπαίδευσης στο επιθυμητό σύνολο δεδομένων με τις ίδιες υπερπαραμέτρους μοντέλου.

Επαναπροσαρμογή μονάδας εξαγωγής χαρακτηριστικών

Στη δεύτερη τεχνική μεταφοράς μάθησης, τα πλήρως συνδεδεμένα επίπεδα επιλέχθηκαν να μην επανεκπαιδευτούν με αποτέλεσμα μόνο η διαδικασία εξαγωγής χαρακτηριστικών να ρυθμιστεί με βάση το στοχευμένο τομέα. Αυτό επιτρέπει στο μοντέλο να διατηρήσει τη χρήσιμη γνωστική πληροφορία που βρίσκεται στα πλήρως συνδεδεμένα επίπεδα σχετικά με τον εκάστοτε στόχο, ο οποίος παραμένει ίδιος σε όλα τα σύνολα δεδομένων που εξετάζονται. Συγκεκριμένα αποτελεί την διεξαγωγή πρόβλεψης της ίδιας στοχευμένης μεταβλητής που είναι η κατανάλωση ηλεκτρικού φορτίου. Αυτά τα επίπεδα έχουν ήδη μάθει να εκτελούν μια δομημένη διαδικασία εκτέλεσης πρόβλεψης από το πηγαίο τομέα και «παγώνοντας» την περαιτέρω εκπαίδευση τους (layer freezing) επιχειρείται να εξεταστεί αν η ήδη υπάρχουσα γνώση είναι γενικευμένη αρκετά ώστε να αποδώσει με παρόμοιο τρόπο και σε ένα στοχευμένο τομέα. Ταυτόχρονα το μέρος του μοντέλου που είναι υπεύθυνο για την εξαγωγή των χαρακτηριστικών από τα δεδομένα θα προσαρμοστεί μέσω επανεκπαίδευσης στο στοχευμένο σύνολο καθώς διαφορετικά κτίρια ενδεχομένως να διαθέτουν και διαφορετική ενεργειακή συμπεριφορά. Για αυτό χρειάζεται μια προσαρμογή στις διακυμάνσεις του στοχευμένου τομέα όσο το μοντέλο επωφελείται από τη γνώση που αποκτήθηκε από την προεκπαίδευση του. Για την εκτέλεση αυτής της τεχνικής πραγματοποιείται ξανά φόρτωση του προεκπαιδευμένου μοντέλου και έπειτα επιλέγονται τα επίπεδα που δεν θα επιδεχθούν περαιτέρω εκπαίδευση μέσω της εντολής «model.layers[i].trainable = False» όπου i είναι το επίπεδο του οποίου οι παράμετροι θα «παγώσουν». Η υπόλοιπη επαναπροσαρμογή στο στοχευμένο σύνολο δεδομένων παραμένει η ίδια.

Εξειδικευμένη επαναπροσαρμογή

Η τρίτη τεχνική μεταφοράς μάθησης αποτελείται από δύο ξεχωριστές επανεκπαιδεύσεις. Η πρώτη μοιάζει αρκετά με την δεύτερη προσέγγιση μεταφοράς μάθησης ακολουθώντας τη λογική της διατήρησης της γνώσης που εμπεριέχεται στα πλήρως συνδεδεμένα επίπεδα. Ωστόσο αντί να προσαρμοστούν στο στοχευμένο τομέα τα ήδη εκπαιδευμένα επίπεδα υπεύθυνα για την εξαγωγή των χαρακτηριστικών, αυτά απορρίπτονται και αντικαθίστανται με ίδιου τύπου ανεκπαίδευτα επίπεδα και επιχειρείται η εκπαίδευση αυτών. Στη συνέχεια πραγματοποιείται η δεύτερη επανεκπαίδευση στο στοχευμένο τομέα στην οποία όμως τα πλήρως συνδεδεμένα επίπεδα έχουν ρυθμιστεί ώστε να δέχονται πλέον περαιτέρω εκπαίδευση. Με αυτό το τρόπο μπορεί να εξεταστεί αν η γνώση που προϋπάρχει από το πηγαίο τομέα στα επίπεδα εξαγωγής χαρακτηριστικών δεν είναι εν τέλει αναγκαία και η εκ νέου εκπαίδευση προσφέρει καλύτερη απόδοση. Η επανεκπαιδεύσεις πραγματοποιούνται με το ίδιο πλαίσιο εκπαίδευσης και υπερπαραμέτρους μοντέλου με εξαίρεση τη δεύτερη στην οποία μειώνεται κατά 30% ο ρυθμός μάθησης και οι εποχές μειώνονται στις 20 με σκοπό να αποφευχθεί η υπερπροσαρμογή.

Επιπλέον τεχνικές μεταφοράς μάθησης στο υβριδικό μοντέλο

Το υβριδικό μοντέλο, λόγω της συγκεκριμένης αρχιτεκτονικής του, επιτρέπει τον διαχωρισμό των επιπέδων εξαγωγής χαρακτηριστικών σε επίπεδα CNN και επίπεδα LSTM. Αυτή η δομή καθιστά δυνατή την περαιτέρω ανάλυση της σημασίας της προϋπάρχουσας γνώσης σε κάθε μία από αυτές τις ομάδες ξεχωριστά. Συγκεκριμένα ακολουθώντας τη λογική της τρίτης τεχνικής μεταφοράς μάθησης εξετάζουμε δύο επιπλέον σενάρια μεταφοράς στα οποία πραγματοποιείται εκ νέου ανακατασκευή των επιπέδων CNN, διατηρώντας τα επίπεδα LSTM ανέπαφα και το αντίστροφο. Σε κάθε ένα από αυτά τα σενάρια, τα ανακατασκευασμένα επίπεδα εκπαιδεύονται εξ αρχής χωρίς προεκπαίδευση από το πηγαίο σύνολο δεδομένων, ενώ η υπόλοιπη εκπαίδευση του μοντέλου ακολουθεί την ίδια διαδικασία που είχε εφαρμοστεί προηγουμένως. Με τη σύγκριση των επιδόσεων των μοντέλων εφαρμόζουν αυτές τις τεχνικές

μεταφοράς μάθησης, μπορούμε να αξιολογήσουμε την επίδραση της προεκπαίδευσης των επιπέδων εξαγωγής χαρακτηριστικών στην ικανότητα του μοντέλου να γενικεύει όταν εφαρμόζεται σε διαφορετικά σύνολα δεδομένων. Έτσι αν παρατηρηθούν σημαντικές διαφορές στις επιδόσεις, αυτό θα υποδηλώνει ότι η γνώση που αποκτάται από τα CNN ή τα LSTM κατά την εκπαίδευση στο πηγαίο σύνολο δεδομένων παίζει καθοριστικό ρόλο στη μεταφορά της γνώσης στο στοχευμένο.

3.5.2 Τεχνικές μεταφοράς μάθησης του μοντέλου TFT

Για την αποδοτική προσαρμογή του μοντέλου TFT από το πηγαίο σύνολο δεδομένων στα στοχευμένα, υλοποιήθηκαν τέσσερις τεχνικές μεταφοράς μάθησης οι οποίες επιλέχθηκαν με γνώμονα την αρχιτεκτονική και συνολική δομή του μοντέλου. Κάθε σενάριο μεταφοράς μάθησης εστιάζει στην επαναπροσαρμογή (fine-tuning) συγκεκριμένων επιπέδων του μοντέλου, επιτρέποντας μια δομημένη σύγκριση της επιρροής που έχουν τα διαφορετικά προεκπαιδευμένα μέρη του μοντέλου σε προβλέψεις σε στοχευμένο τομέα.

Πλήρη επαναπροσαρμογή μοντέλου

Όπως και στα ακολουθιακά μοντέλα έτσι και στο μοντέλο TFT η πρώτη μέθοδος που εξετάζεται είναι η πλήρη επαναπροσαρμογή του μοντέλου σε ένα στοχευμένο τομέα. Αναλυτικότερα επανεκπαιδεύονται με το ίδιο πλαίσιο εκπαίδευσης και τις ίδιες υπερπαραμέτρους όλα τα επίπεδα του μοντέλου στο εκάστοτε στοχευμένο σύνολο δεδομένων ρυθμίζοντας έτσι τη διαδικασία της επιλογής μεταβλητών, της εξαγωγής αναπαραστάσεων μέσω ανίχνευσης βραχυπρόθεσμων και μακροπρόθεσμων χρονικών εξαρτήσεων και της τελικής πρόβλεψης. Έτσι μπορεί να εξεταστεί πόσο καλά γενικεύονται οι προβλέψεις τους μέσω πλήρους επαναπροσαρμογής σε σχέση με μερική επαναπροσαρμογή που θα εξεταστεί στη συνέχεια. Για την εκτέλεση της τεχνικής χρησιμοποιείται η εντολή «`model = TemporalFusionTransformer.load_from_checkpoint()`» για να

φορτωθεί το μοντέλο και πραγματοποιείται ξανά η εκπαίδευση όπως έχει περιγραφεί.

Επαναπροσαρμογή επιλογής μεταβλητών και μηχανισμών πυλών

Η δεύτερη τεχνική μεταφοράς μάθησης εστιάζει στην επανεκπαίδευση του δικτύου επιλογής μεταβλητών και στους μηχανισμούς πυλών που βρίσκονται σε όλη την έκταση της αρχιτεκτονικής του μοντέλου. Το δίκτυο επιλογής μεταβλητών καθορίζει τις πιο σχετικές μεταβλητές ανά χρονικό βήμα καθιστώντας τη σχετική γνώση που μπορεί να υπάρχει σε ένα στοχευμένο τομέα σημαντική για τη πρόβλεψη. Αυτό ισχύει καθώς διαφορετικά κτίρια ενδεχομένως να έχουν διαφορετικούς παράγοντες που επηρεάζουν την κατανάλωση τους με αποτέλεσμα μέσω της επαναπροσαρμογής το μοντέλο να μαθαίνει τη διαφορετική προτεραιότητα μεταβλητών του νέου τομέα. Επίσης οι μηχανισμοί πύλης ρυθμίζουν την ροή της πληροφορίας εκτελώντας μη γραμμικούς μετασχηματισμούς μόνο όταν είναι απαραίτητοι. Αποτελούν μέρος της αρχιτεκτονικής του δικτύου επιλογής μεταβλητών και είναι υπεύθυνα για τον εμπλουτισμό των αναπαραστάσεων με πληροφορίες από τις στατικές μεταβλητές. Επομένως η επανεκπαίδευση τους προσφέρει μια εστιασμένη μέθοδο προσαρμογής αποφεύγοντας την υπερπροσαρμογή και διατηρώντας την συνολική σταθερότητα του μοντέλου. Για την εκτέλεση αυτού του πλαισίου μεταφοράς μάθησης φορτώνεται το αποθηκευμένο μοντέλο, αναζητούνται όλα τα επίπεδα μέσω της εντολής «for name, param in model.named_parameters():» και επιλέγονται τα επίπεδα:

- static_variable_selection
- encoder_variable_selection
- decoder_variable_selection
- static_enrichment
- post_attn_gate_norm
- post_lstm_gate_norm

για τα οποία εφαρμόζεται η εντολή «param.requires_grad = True» ενώ για τα άλλα επίπεδα εφαρμόζεται η εντολή «param.requires_grad = False»

Επαναπροσαρμογή επιπέδων LSTM

Η επόμενη μέθοδος μεταφοράς μάθησης επικεντρώνεται στην επανεκπαίδευση μόνο των επιπέδων LSTM στα στάδια κωδικοποίησης και αποκωδικοποίησης. Αυτά είναι υπεύθυνα για την ανίχνευση των βραχυπρόθεσμων χρονικών εξαρτήσεων στα δεδομένα. Επομένως διαφορετικά κτίρια ενδεχομένως να διαθέτουν διαφορετικές βραχυπρόθεσμες τάσεις κατανάλωσης καθιστώντας την επαναπροσαρμογή τους σε ένα νέο στοχευμένο τομέα αναγκαία. Επίσης παγώνοντας τα υπόλοιπα επίπεδα μπορεί να εξεταστεί η επίδραση της αποκλειστικής προσαρμογής αυτού του μηχανισμού στην τελική πρόβλεψη διατηρώντας τη γενικότερη γνώση του μοντέλου άθικτη. Η επαναπροσαρμογή μόνο των επιπέδων αυτών γίνεται με τον ίδιο τρόπο όπως και η δεύτερη προσέγγιση απλά επιλέγονται μόνο τα ακόλουθα επίπεδα:

- lstm_encoder
- lstm_decoder

Επαναπροσαρμογή επιπέδων προσοχής και εμπλουτισμού

Η τέταρτη τεχνική μεταφοράς μάθησης έχει παρόμοια λογική με την τρίτη με κύρια διαφορά ότι στη προκειμένη περίπτωση επαναπροσαρμόζονται μόνο ο μηχανισμός προσοχής πολλών κεφαλών και οι μηχανισμοί πυλών που προηγούνται και έπονται αυτού. Δηλαδή όλη η διαδικασία από τον στατικό εμπλουτισμό έως και την κανονικοποίηση των εξαγόμενων αναπαραστάσεων από το μηχανισμό προσοχής. Ο μηχανισμός προσοχής ανιχνεύει τις μακροπρόθεσμες χρονικές εξαρτήσεις οι οποίες είναι εξίσου σημαντικές με τις βραχυπρόθεσμες καθώς η κατανάλωση συνήθως εμφανίζει περιοδικές διακυμάνσεις και εποχικά μοτίβα. Έτσι η επαναπροσαρμογή του επιτρέπει στην ήδη μαθημένη αποδιδόμενη προτεραιότητα σε παρελθοντικές πληροφορίες που διαθέτει το μοντέλο να ρυθμιστεί στις ιδιαιτερότητες ενός στοχευμένο συνόλου δεδομένων. Ταυτόχρονα ο στατικός εμπλουτισμός τροποποιεί τα δεδομένα εισάγοντας στατική πληροφορία ανάλογη με το κτίριο διασφαλίζοντας ότι ο μηχανισμός προσοχής θα εστιάσει σε σχετικά χρονικά μοτίβα βασισμένα και σε

στατικούς παράγοντες. Τέλος ο μηχανισμός πυλών μετά τη διαδικασία προσοχής αποφασίζει πόση πληροφορία από τις εξαγόμενες χρονικές αναπαραστάσεις θα προωθηθεί στα επόμενα επίπεδα. Η επαναπροσαρμογή τους αποσκοπεί στην αποφυγή απόδοσης προτεραιότητας σε μέρη των πληροφοριών, εξαγόμενων από το μηχανισμό προσοχής, που εξαρτάται αποκλειστικά από τα μοτίβα και τις διακυμάνσεις του πηγαίου συνόλου δεδομένων. Η υλοποίηση της πραγματοποιήθηκε όπως και προηγουμένως με τη διαφορά ότι για αυτή τη προσέγγιση επιλέχθηκαν τα εξής επίπεδα:

- `multihead_attn`
- `static_enrichment`
- `post_attn_gate_norm`

Σύγκριση και αξιολόγηση αποτελεσμάτων

4.1 Ανάλυση αποτελεσμάτων των δικτύων

Όλα τα μοντέλα πλέον έχουν εκπαιδευτεί σε όλα τα σύνολα δεδομένων και για όλα τα σενάρια έλλειψης δεδομένων που επιθυμούμε να εξετάσουμε. Επομένως σε αυτήν την ενότητα θα αναλυθούν μεμονωμένα οι επιδόσεις του κάθε μοντέλου εστιάζοντας στα πλεονεκτήματα του κάθε ενός. Θα παρουσιαστούν αποτελέσματα των μετρικών MAE, RMSE, MAPE και σκορ R2 αλλά και γραφικές παραστάσεις του εύρους σφαλμάτων και των προβλεπόμενων τιμών σε σχέση με τις πραγματικές. Για την διευκόλυνση της συνδυαστικής οπτικοποίησης των αποτελεσμάτων των διάφορων τεχνικών μεταφοράς μάθησης ανά μοντέλο ακολουθείται η εξής αντιστοιχία χρώματος με τεχνική:

- Απουσία τεχνικής : Μαύρο χρώμα
- Πρώτη τεχνική (TL1) : Κόκκινο χρώμα
- Δεύτερη τεχνική (TL2) : Πράσινο χρώμα
- Τρίτη τεχνική (TL3) : Μπλε χρώμα
- Τέταρτη τεχνική (TL4) : Μωβ χρώμα
- Πέμπτη τεχνική (TL5) : Ροζ χρώμα
- Πραγματικές τιμές (True) : Πορτοκαλί χρώμα

Επίσης οι γραφικές παραστάσεις συνδυαστικής οπτικοποίησης αποτελεσμάτων των τεχνικών μεταφοράς μάθησης για το χρονικό ορίζοντα του ενός μήνα έχουν παραληφθεί καθώς είναι αρκετά περίπλοκές και δεν διακρίνονται ιδιαίτερα χρήσιμες πληροφορίες. Η αποτύπωση των


πραγματικών τιμών στις χρονικές περιόδους κάθε γραφικής παράστασης αποτυπώνεται με κίτρινες διακεκομμένες γραμμές ενώ για την υλοποίηση όλων των γραφικών παραστάσεων και οπτικοποιήσεων σε όλη την έκταση αυτής της διπλωματικής εργασίας χρησιμοποιήθηκε η βιβλιοθήκη «matplotlib».

4.1.1 Επιδόσεις του μοντέλου στοιβαγμένων RNN

Πηγαίο σύνολο δεδομένων

Μετρικές προβλέψεων

Οριζοντας πρόβλεψης	RMSE	MAE	MAPE	R^2 score
1 μέρα	3.171	2.361	0.099	82.958
1 εβδομάδα	1.993	2.414	0.102	82.814
1 μήνα	3.212	2.312	0.098	79.571



Εικόνα 10.1 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του μοντέλου στοιβαγμένων RNN στο πηγαίο κτίριο


Το μοντέλο στοιβαγμένων RNN παρουσιάζει ισχυρή προβλεπτική ικανότητα στο πηγαίο σύνολο δεδομένων και ιδιαίτερα για χρονικούς ορίζοντες της επόμενης μέρας και εβδομάδας. Συγκεκριμένα σημειώνει υψηλά σκορ R^2 με σχετικά χαμηλές τιμές RMSE και MAE ανιχνεύοντας σωστά βραχυπρόθεσμα μοτίβα κατανάλωσης όπως φαίνεται από τον παραπάνω πίνακα. Ωστόσο για τον ορίζοντα του ενός μήνα παρουσιάζεται μικρή πτώση στο σκορ R^2 το οποίο φανερώνει την ενδεχόμενη αδυναμία του στην διαχείριση μακροπρόθεσμων διακυμάνσεων. Οι γραφικές παραστάσεις της Εικόνας 4.1 το επιβεβαιώνουν αυτό δείχνοντας κατά κύριο λόγο κοντινή ευθυγράμμιση με τις πραγματικές τιμές για μικρούς χρονικούς ορίζοντες ενώ για μεγαλύτερους παρουσιάζεται υπερβολική εξομάλυνση η οποία οδηγεί σε αποκλίσεις κατά τις περιόδους μέγιστης κατανάλωσης. Ταυτόχρονα παρουσιάζεται και μια αλλόκοτη ενεργειακή συμπεριφορά τη 16^η μέρα την οποία δεν φαίνεται να έχει τη δυνατότητα να μοντελοποιήσει χρονικά.

Πρώτο στοχευμένο σύνολο δεδομένων (Διάρκειας 12 μηνών)


Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Ορίζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
Χωρίς	1 ημέρα	9.736	8.33	0.087	44.42
	1 εβδομάδα	8.661	7.263	0.075	41.33
	1 μήνα	8.867	6.961	0.074	37.62
Πρώτη	1 ημέρα	8.042	6.416	0.071	62.06
	1 εβδομάδα	8.536	7.084	0.078	42.98
	1 μήνα	9.385	7.993	0.093	30.12
Δεύτερη	1 ημέρα	9.207	7.659	0.085	50.27
	1 εβδομάδα	9.357	8.021	0.089	31.48
	1 μήνα	9.739	8.421	0.099	24.75
Τρίτη	1 ημέρα	7.482	5.666	0.055	67.16
	1 εβδομάδα	7.186	5.582	0.056	59.59
	1 μήνα	8.215	6.902	0.071	46.46

Κατά την διάρκεια προβλέψεων του μοντέλου στο πρώτο στοχευμένο κτίριο παρατηρούμε ότι με απλή εκπαίδευση εκ νέου η απόδοση είναι κακή σημειώνοντας χαμηλά σκορ R^2 και υψηλές τιμές RMSE τα οποία χειροτερεύουν



Εικόνα 4.2: Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα στο πρώτο στοχευμένο κτίριο του μοντέλου στοιβαγμένων RNN (διάρκειας 12 μηνών)



Εικόνα 4.3 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου στοιβαγμένων RNN στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)


όσο αυξάνεται ο ορίζοντας πρόβλεψης. Με τη χρήση της πρώτης προσέγγισης μεταφοράς μάθησης παρουσιάζονται αξιοσημείωτη αύξηση στην απόδοση κυρίως για μικρούς χρονικούς ορίζοντες αλλά αυτή η βελτίωση χάνεται όταν μεγαλώνουν οι ορίζοντες, πράγμα που μπορεί να οφείλεται σε υπερπροσαρμογή στις βραχυπρόθεσμες χρονικές εξαρτήσεις. Η δεύτερη τεχνική βελτιώνει ελάχιστα τις βραχυπρόθεσμες προβλέψεις αλλά αποδεικνύεται αναποτελεσματική για τους άλλους χρονικούς ορίζοντες καθώς το «πάγωμα» των προβλεπτικών επιπέδων περιορίζει την προσαρμογή. Τέλος η τρίτη μέθοδος παρουσιάζει τα καλύτερα αποτελέσματα σημειώνοντας βελτίωση σε όλους τους ορίζοντες πρόβλεψης αυξάνοντας το σκορ R^2 και μειώνοντας το μέσο σφάλμα.

Ταυτόχρονα οι κατανομές σφαλμάτων που παρουσιάζονται στην Εικόνα 4.2 επιβεβαιώνουν την υπεροχή της τρίτης μεθόδου ως αυτής με τη μεγαλύτερη μείωση σφάλματος και την υστέρηση της δεύτερης καθώς φαίνεται πως αυξάνει το σφάλμα σε όλους τους ορίζοντες. Τέλος οι οπτικοποιήσεις των προβλέψεων για την επόμενη μέρα και εβδομάδα στην Εικόνα 4.3 παρουσιάζουν καλύτερη ευθυγράμμιση με τις πραγματικές τιμές μέσω της τρίτης προσέγγισης η οποία φαίνεται πως είναι ικανή να ανιχνεύει τις μεγάλες μειώσεις στην κατανάλωση αλλά δεν παρουσιάζει την ίδια ικανότητα και για την μεγάλες αυξήσεις σε σύγκριση με τις άλλες δυο μεθόδους.


Πρώτο στοχευμένο σύνολο δεδομένων (Διάρκειας 6 μηνών)

Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Οριζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
Χωρίς	1 ημέρα	4.908	3,932	0.04	70.92
	1 εβδομάδα	6.081	4.911	0.052	54.62
	1 μήνα	7.107	5.832	0.064	34.87
Πρώτη	1 ημέρα	7.978	6.636	0.071	23.11
	1 εβδομάδα	7.144	5.569	0.061	37.36
	1 μήνα	7.172	5.497	0.057	33.67
Δεύτερη	1 ημέρα	7.649	6.396	0.072	29.31
	1 εβδομάδα	7.162	5.789	0.063	37.03
	1 μήνα	7.334	5.783	0.061	30.64
Τρίτη	1 ημέρα	7.529	6.062	0.065	31.51
	1 εβδομάδα	7.299	5.789	0.063	34.61
	1 μήνα	7.381	6.007	0.066	29.75



Εικόνα 4.4 : Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα στο πρώτο στοχευμένο κτίριο του μοντέλου στοιβαγμένων RNN (διάρκειας 6 μηνών)



Εικόνα 4.5 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου στοιβαγμένων RNN στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)

Όταν υφίσταται μεγαλύτερη έλλειψη δεδομένων (6 μήνες) το μοντέλο παραδόξως παρουσιάζει καλύτερη απόδοση πρόβλεψης σε σχέση με όταν το σύνολο δεδομένων είχε έκταση 12 μηνών η οποία βέβαια μειώνεται όσο

αυξάνεται ο χρονικός ορίζοντας πρόβλεψης με την απόδοση να είναι χειρότερη όταν προβλέπει για τον επόμενο μήνα σε σχέση με πριν. Αυτό βέβαια σημαίνει ότι το μοντέλο έχει υπερπροσαρμοστεί σε ένα βαθμό στο θόρυβο του συνόλου καθώς η μεγαλύτερη έλλειψη δεδομένων αντιστοιχεί σε μικρότερο σύνολο διαφορετικών μοτίβων προς εκμάθηση με αποτέλεσμα να μαθευτούν μόνο οι βραχυπρόθεσμες διακυμάνσεις. Επιπλέον αυτή η έλλειψη παρουσιάζει ιδιαίτερη πρόκληση στην προσαρμογή ενός προεκπαιδευμένου μοντέλου σε αυτά τα ελάχιστα δείγματα, πράγμα που φαίνεται και από την απόδοση των μεθόδων μεταφοράς μάθησης καθώς καμία δεν κατάφερε να βελτιώσει τα αποτελέσματα.


Παρατηρώντας τις κατανομές σφαλμάτων στην Εικόνα 4.4 παρατηρούμε πως για προβλέψεις της επόμενης μέρας η καλύτερη μέθοδος είναι η δεύτερη καθώς η επαναπροσαρμογή των επιπέδων RNN οδήγησε σε καλύτερη ανίχνευση βραχυπρόθεσμων χρονικών εξαρτήσεων. Για προβλέψεις επόμενης εβδομάδας η τρίτη μέθοδος, συγκριτικά με τις άλλες, έχει τη μεγαλύτερη μείωση σφάλματος ενώ η πρώτη μέθοδος δείχνει πως η συνολική πληροφορία από το πηγείο σύνολο δεν συνδυάζεται σωστά με κάποια ενδεχόμενη υπερπροσαρμογή σε αυτό. Τέλος οι οπτικοποιήσεις της Εικόνας 4.5 παρουσιάζουν συνολικά μεγάλες αποκλίσεις στα μοντέλα που έχουν ενσωματώσει μεθόδους μεταφοράς μάθησης, ωστόσο η τρίτη προσέγγιση φαίνεται να ανιχνεύει περισσότερα σημεία μέγιστης και ελάχιστης κατανάλωσης από τις άλλες μεθόδους.

Δεύτερο στοχευμένο σύνολο δεδομένων


Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Ορίζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
Χωρίς	1 ημέρα	6.515	5.549	0.091	-18.37
	1 εβδομάδα	6.318	5.244	0.085	23.96
	1 μήνα	6.696	5.451	0.104	40.58
Πρώτη	1 ημέρα	6.935	5.742	0.099	-34.11
	1 εβδομάδα	7.508	6.151	0.105	-7.41
	1 μήνα	8.004	6.568	0.129	15.09
	1 ημέρα	7.981	6.662	0.116	-77.56

Δεύτερη	1 εβδομάδα	8.456	6.962	0.121	-36.23
	1 μήνα	9.063	7.581	0.149	-8.86
Τρίτη	1 ημέρα	6.312	4.862	0.078	-11.08
	1 εβδομάδα	6.512	5.352	0.085	19.22
	1 μήνα	6.852	5.529	0.102	37.78



Εικόνα 4.6 : Κατανομές σφαλμάτων στο πρώτο στοχευμένο κτίριο για κάθε ορίζοντα πρόβλεψης του μοντέλου στοιβαγμένων RNN



Εικόνα 4.7 : Γραφικές παραστάσεις προβλέψεων του μοντέλου στοιβαγμένων RNN στο πρώτο στοχευμένο κτίριο για την επόμενη μέρα/εβδομάδα/μήνα

Τα αποτελέσματα του μοντέλου αυτού για τις προβλέψεις στο δεύτερο στοχευμένο κτίριο αποκαλύπτουν τις σημαντικές δυσκολίες που συναντά στην ανίχνευση των μοτίβων αυτού του συνόλου με τη καλύτερη επίδοση να συναντάται στις προβλέψεις επόμενου μήνα, πράγμα που υποδυκνύει την ανικανότητα του μοντέλου να μάθει τις βραχυπρόθεσμες χρονικές εξαρτήσεις. Οι τεχνικές μεταφοράς μάθησης που εφαρμόζονται δεν προσφέρουν κάποια βελτίωση και στις περισσότερες περιπτώσεις επιφέρουν χειρότερα αποτελέσματα όπως για παράδειγμα η πρώτη και η δεύτερη οι οποίες παρουσιάζουν εξαιρετικά κακά σκορ R^2 (-34.11%, -7.41% και -77.56%, -36.23% αντίστοιχα), πράγμα που σημαίνει πως τα χρονικά μοτίβα που έχουν μαθευτεί από το πηγαίο κτίριο δεν μεταφέρονται σωστά. Από την άλλη η τρίτη μέθοδος σημειώνει θετικά σκορ R^2 παρουσιάζοντας μια στοιχειώδη επιτυχής μεταφορά γνώσης.

Οι κατανομές σφαλμάτων στην Εικόνα 4.6 παρουσιάζουν τα αυξημένα σφάλματα που επιφέρουν οι μέθοδοι μεταφοράς μάθησης με τη τρίτη μέθοδο να αποδίδει παρόμοια με το βασικό μοντέλο για προβλέψεις επόμενου μήνα.


Παράλληλα οι οπτικοποιήσεις της Εικόνας 4.7 δείχνουν μεγάλες αποκλίσεις στις μεθόδους 1 και 2 ενώ επιβεβαιώνει τη καλύτερη συγκριτικά απόδοση της τρίτης μεθόδου και του βασικού μοντέλου.

4.1.2 Επιδόσεις του μοντέλου στοιβαγμένων LSTM

Πηγαίο σύνολο δεδομένων

Μετρικές προβλέψεων

Οριζοντας πρόβλεψης	RMSE	MAE	MAPE	R2 score
1 μέρα	2.874	2.274	0.093	85.99
1 εβδομάδα	2.692	2.215	0.092	86.09
1 μήνα	3.171	2.226	0.091	80.09



Εικόνα 4.8 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του μοντέλου στοιβαγμένων LSTM στο πηγαίο κτίριο


Το μοντέλο στοιβαγμένων επιπέδων LSTM αποδεικνύεται ιδιαίτερα ακριβές στις προβλέψεις του στο σύνολο δεδομένων του πηγαίου κτιρίου με ιδιαίτερα υψηλά σκορ R^2 με τη καλύτερη απόδοση να εμφανίζεται στις βραχυπρόθεσμες προβλέψεις και έπειτα στις μακροπρόθεσμες με την απόδοση στις προβλέψεις επόμενης εβδομάδας είναι οι υψηλότερες με το χαμηλότερο μέσο σφάλμα. Οι τιμές RMSE και MAE συνολικά παραμένουν σταθερά χαμηλές υποδηλώνοντας ότι το μοντέλο προσφέρει γενικευμένες προβλέψεις σε όλο το σύνολο. Τέλος οι γραφικές παραστάσεις της Εικόνας 4.8 επιβεβαιώνουν την καλή ευθυγράμμιση των προβλεπόμενων τιμών με τις πραγματικές. Ωστόσο διακρίνονται μερικές ακραίες μέγιστες και ελάχιστες τιμές οι οποίες δεν ανιχνεύονται από το μοντέλο ενώ όπως είναι αναμενόμενο δεν μπορεί να ανιχνεύσει τη ασυνήθιστη ενεργειακή συμπεριφορά που εμφανίζεται τη 16^η μέρα.

Πρώτο στοχευμένο σύνολο δεδομένων (Διάρκειας 12 μηνών)


Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Ορίζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
Χωρίς	1 ημέρα	7.177	6.141	0.062	69.79
	1 εβδομάδα	6.074	4.835	0.051	71.13
	1 μήνα	6.888	5.486	0.062	62.36
Πρώτη	1 ημέρα	6.818	5.675	0.057	72.73
	1 εβδομάδα	5.794	4.562	0.047	73.72
	1 μήνα	5.945	4.708	0.052	71.96
Δεύτερη	1 ημέρα	7.003	5.955	0.061	71.23
	1 εβδομάδα	5.803	4.766	0.052	73.64
	1 μήνα	6.214	5.029	0.057	69.37
Τρίτη	1 ημέρα	7.158	6.168	0.062	69.95
	1 εβδομάδα	6.097	4.793	0.048	70.91
	1 μήνα	6.794	5.487	0.105	38.82

Όταν επιχειρεί προβλέψεις στο πρώτο στοχευμένο κτίριο οι επιδόσεις του πέφτουν σε σχέση με το πηγαίο λόγω της μείωσης του όγκου δεδομένων αλλά παρατηρείται το ίδιο μοτίβο με τις επιδόσεις να διατηρούνται υψηλές στους



Εικόνα 4.9 : Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα στο πρώτο στοχευμένο κτίριο του μοντέλου στοιβαγμένων LSTM (διάρκειας 12 μηνών)



Εικόνα 4.10 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου στοιβαγμένων LSTM στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)


μικρούς χρονικούς ορίζοντες και να πέφτουν σταδιακά όσο αυξάνονται. Στη προκειμένη περίπτωση παρατηρούμε και μεγαλύτερη πτώση στο μέσο σφάλμα στις προβλέψεις της επόμενης εβδομάδας σε σχέση με το πηγαίο. Η πλήρη επαναπροσαρμογή του μοντέλου του επιτρέπει να διατηρήσει με το καλύτερο τρόπο την υπάρχουσα γνώση και να την συνδυάσει με τις ιδιοτροπίες του στοχευμένου συνόλου εφόσον παρουσιάζει τα καλύτερα αποτελέσματα σημειώνοντας το συνδυασμό υψηλότερου σκορ R^2 και χαμηλότερου μέσου σφάλματος για όλους τους χρονικούς ορίζοντες. Η δεύτερη μέθοδος έχει ελάχιστα χειρότερα αποτελέσματα επιβεβαιώνοντας τη χρησιμότητα της πληροφορίας που θα μπορούσαν να εκμεταλλευτούν τα πλήρως συνδεδεμένα επίπεδα εάν συμμετείχαν στην επαναπροσαρμογή. Από την άλλη η απόδοση της τρίτης προσέγγισης απέχει ακόμα περισσότερο από τη πρώτη ενώ στις προβλέψεις επόμενου μήνα οι επιδόσεις μειώνονται δραματικά ($R^2 = 38.82\%$), πράγμα που δείχνει πως η εκ νέου εκπαίδευση επιπέδων LSTM οδηγεί σε απώλεια χρήσιμης πληροφορίας.

Οι κατανομές σφαλμάτων της Εικόνας 4.9 αποκαλύπτουν μια ξεκάθαρη μείωση στο μέσο σφάλμα με τη πρώτη και δεύτερη τεχνική μεταφοράς μάθησης ενώ οι οπτικοποιήσεις της Εικόνας 4.10 δείχνουν την αποδοτική μοντελοποίηση της τάσης και της περιοδικής συμπεριφοράς της ενεργειακής κατανάλωσης χωρίς όμως να μπορούν να ανιχνεύσουν ακραίες μέγιστες και ελάχιστες τιμές.


Πρώτο στοχευμένο σύνολο δεδομένων (Διάρκειας 6 μηνών)

Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Οριζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
Χωρίς	1 ημέρα	5.995	4.692	0.049	56.58
	1 εβδομάδα	6.102	4.746	0.051	51.32
	1 μήνα	6.516	5.126	0.055	45.24
Πρώτη	1 ημέρα	4.622	3.735	0.041	74.19
	1 εβδομάδα	6.001	4.543	0.047	55.81
	1 μήνα	6.621	5.012	0.051	43.47
Δεύτερη	1 ημέρα	4.526	3.467	0.037	75.25
	1 εβδομάδα	5.382	4.136	0.043	64.47
	1 μήνα	6.143	3.634	0.048	51.34
Τρίτη	1 ημέρα	6.763	5.209	0.056	44.74
	1 εβδομάδα	6.585	4.868	0.053	46.77
	1 μήνα	6.396	4.986	0.054	47.25



Εικόνα 4.11 : Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα στο πρώτο στοχευμένο κτίριο του μοντέλου στοιβαγμένων LSTM (διάρκειας 6 μηνών)



Εικόνα 4.12 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου στοιβαγμένων LSTM στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)

Το προσωμοιομένο περιβάλλον υψηλής έλλειψης δεδομένων είναι αναμενόμενο να καθιστά το μοντέλο ανίκανο να σημειώσει παρόμοιες επιδόσεις με αυτές στο σύνολο δεδομένων διάρκειας 12 μηνών οδηγώντας σε μείωση περίπου 20-27% στο σκορ R^2 . Η πρώτη μέθοδος μεταφοράς μάθησης

όπως και πριν προσφέρει καλύτερα αποτελέσματα ειδικά για βραχυπρόθεσμες προβλέψεις ενώ αποδυναμώνεται χειρότερη για μακροπρόθεσμες κυρίως γιατί η προσαρμογή των προβλεπτικών επιπέδων της αντικατέστησε σημαντική προϋπάρχουσα γνώση που διευκολύνει προβλέψεις σε πιο εκτενείς χρονικούς ορίζοντες. Αυτό επιβεβαιώνεται και από τη δεύτερη μέθοδο μεταφοράς μάθησης η οποία βελτιώνει κατά 14% και 17% το σκορ R^2 στις προβλέψεις επόμενης εβδομάδας και μήνα σε σχέση με τη πρώτη ενώ βελτιώνει ελάχιστα και την απόδοση στις βραχυπρόθεσμες προβλέψεις. Η εκ νέου εκπαίδευση των επιπέδων LSTM στο στοχευμένο σύνολο αποδεικνύει ότι υπάρχει σημαντική πληροφορία στα επίπεδα αυτά από το πηγαίο σύνολο, η απουσία της οποίας σε συνδυασμό την διατήρηση των προεκπαιδευμένων προβλεπτικών επιπέδων οδηγεί σε ακόμη χειρότερα αποτελέσματα. Ωστόσο στις μακροπρόθεσμες προβλέψεις έχει μικρότερο σφάλμα από τη πρώτη μέθοδο, πράγμα που επιβεβαιώνει ότι δεν αλλοιώθηκαν εντελώς οι γνώσεις του πηγαίου κτιρίου στα προβλεπτικά επίπεδα του.


Οι κατανομές στην Εικόνα 4.11 επιβεβαιώνουν ότι το μοντέλο που αξιοποιεί εξειδικευμένη προσαρμογή των επιπέδων LSTM παρουσιάζει τη μεγαλύτερη μείωση μέσου σφάλματος σημειώνοντας τα πιο συνεπή αποτελέσματα ενώ αμέσως επόμενο είναι το μοντέλο που αξιοποιεί πλήρη επαναπροσαρμογή. Τέλος παρατηρούμε πως οι οπτικοποιήσεις των αποτελεσμάτων της Εικόνας 4.12 φανερώνουν ότι τα μοντέλα που εφαρμόζουν τη πρώτη και δεύτερη μέθοδο ευθυγραμμίζονται στενά με τις πραγματικές τιμές και φαίνεται να ανιχνεύουν σωστά τις ακραίες ελάχιστες τιμές αλλά όχι τις μέγιστες. Ωστόσο το μοντέλο που ενσωματώνει την τρίτη μέθοδο αποδεικνύεται ότι μπορεί να τις ανιχνεύσει παρουσιάζοντας βέβαια μεγαλύτερες αποκλίσεις στις υπόλοιπες τιμές.

Δεύτερο στοχευμένο σύνολο δεδομένων


Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Ορίζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
Χωρίς	1 ημέρα	5.776	4.687	0.074	6.98
	1 εβδομάδα	6.419	5.271	0.083	21.51
	1 μήνα	6.611	5.45	0.104	42.08
	1 ημέρα	5.561	4.825	0.081	14.76

Πρώτη	1 εβδομάδα	6.414	5.262	0.086	21.66
	1 μήνα	6.724	5.494	0.106	40.08
Δεύτερη	1 ημέρα	6.146	5.103	0.087	-5.32
	1 εβδομάδα	6.951	5.591	0.095	7.95
	1 μήνα	7.298	5.971	0.116	29.40
Τρίτη	1 ημέρα	5.444	4.566	0.076	17.36
	1 εβδομάδα	5.999	4.948	0.081	31.44
	1 μήνα	6.794	5.487	0.105	38.89



Εικόνα 4.13 : Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα στο δεύτερο στοχευμένο κτίριο του μοντέλου στοιβαγμένων LSTM



Εικόνα 4.14 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου στοιβαγμένων LSTM στο δεύτερο στοχευμένο κτίριο

Το δεύτερο στοχευμένο κτίριο παρουσιάζει ιδιαίτερες προκλήσεις στη διαδικασία προβλέψεων του μοντέλου. Οι υψηλές απότομες διακυμάνσεις και τα συνολικότερα ιδιαίτερα μοτίβα κατανάλωσης του συγκεκριμένου κτιρίου καθιστούν την προσαρμογή ενός μοντέλου πιο δύσκολη σε αυτό. Συγκεκριμένα η βασική εκπαίδευση πετυχαίνει ιδιαίτερα χαμηλό σκορ R^2 για βραχυπρόθεσμες προβλέψεις (6.98) ενώ αυξάνεται μαζί με το χρονικό ορίζοντα πρόβλεψης. Ωστόσο για τις προβλέψεις επόμενης μέρας παρουσιάζει το μικρότερο μέσο σφάλμα σε σχέση με όλα τα άλλα μοντέλα υποδεικνύοντας υψηλή βραχυπρόθεσμη ακρίβεια σε όρους απόλυτου σφάλματος. Ωστόσο παρόλο που το σφάλμα είναι μικρό δεν φαίνεται να μπορεί να ανιχνεύσει αποδοτικά τη συνολική κατανομή των πραγματικών τιμών. Για μεγαλύτερους χρονικούς ορίζοντες μπορεί να αυξάνεται το σκορ R^2 αλλά αυξάνονται και οι

άλλες μετρικές παρουσιάζοντας συνολικά κακή απόδοση. Η πρώτη τεχνική μεταφοράς μάθησης προσφέρει ελάχιστη μείωση της RMSE και αύξηση του σκορ R^2 αλλά αυξάνονται και τα σφάλματα στις βραχυπρόθεσμες προβλέψεις. Όσον αφορά μεγαλύτερους ορίζοντες έχει παρόμοια επίδοση με το βασικό μοντέλο. Η δεύτερη μέθοδος έχει τα χειρότερα αποτελέσματα επιβεβαιώνοντας την αξία της γνώσης που μπορούν να αποκομίσουν τα προβλεπτικά επίπεδα από αυτό το σύνολο δεδομένων. Η τελευταία προσέγγιση αποδίδει καλύτερα από τις άλλες δύο και το βασικό μοντέλο αλλά εξακολουθεί να θεωρείται κακή απόδοση πρόβλεψης σε όλους τους χρονικούς ορίζοντες.

Οι κατανομές σφαλμάτων της Εικόνας 4.13 επιβεβαιώνουν το χαμηλό σφάλμα του βασικού μοντέλου στις βραχυπρόθεσμες προβλέψεις και τη βελτίωση του μέσω της πρώτης και τρίτης τεχνικής για μεγαλύτερους χρονικούς ορίζοντες αλλά φανερώνει και τα συνολικά υψηλά σφάλματα που επικρατούν στις προβλέψεις αυτού του συνόλου δεδομένων. Οι οπτικοποιήσεις της Εικόνας 4.14 παρουσιάζουν την ανικανότητα των μοντέλων να ανιχνεύσουν την ιδιαίτερη διακύμανση των πραγματικών τιμών του στις προβλέψεις επόμενης μέρας. Ταυτόχρονα φαίνεται πως μοντελοποιούν σε ένα βαθμό το μοτίβο κατανάλωσης σε εβδομαδιαία βάση αλλά δεν έχουν τη δυνατότητα να καλύψουν τις ακραίες μέγιστες τιμές και κάποιες ελάχιστες.


4.1.3 Επίδοσεις του μοντέλου στοιβαγμένων CNN

Πηγαίο σύνολο δεδομένων

Μετρικές προβλέψεων

Ορίζοντας πρόβλεψης	RMSE	MAE	MAPE	R^2 score
1 μέρα	4.461	3.313	0.132	66.25
1 εβδομάδα	3.984	3.091	0.122	69.55
1 μήνα	4.059	2.796	0.117	67.37

Το μοντέλο στοιβαγμένων CNN αποδίδει καλά και στους τρεις ορίζοντες πρόβλεψης παρουσιάζοντας μικρότερα σφάλματα στους μακρύτερους. Το σκορ




Εικόνα 4.15 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του μοντέλου στοιβαγμένων CNN στο πηγαίο κτίριο

R^2 παραμένει σχετικά υψηλό ανάμεσα στο 66% και 70% ενώ ανιχνεύει χειρότερα τις ακραίες τιμές στις προβλέψεις επόμενης μέρας παρουσιάζοντας αυξημένη τιμή στη μετρική RMSE. Από τις οπτικοποιήσεις της Εικόνας 4.15 παρατηρούμε ότι στις προβλέψεις επόμενης μέρας υπάρχει στενή ευθυγράμμιση με τις πραγματικές τιμές αλλά δεν καταφέρνει να απεικονίσει την διακύμανση τους στις τελευταίες ώρες. Για τον ορίζοντα επόμενης εβδομάδας και μήνα παρατηρούμε σωστή μοντελοποίηση της περιοδικής συμπεριφοράς της κατανάλωσης του κτιρίου αλλά δεν καταφέρνει να ευθυγραμμιστεί με αρκετές τοπικές ελάχιστες αλλά και κάποιες ολικές μέγιστες και ελάχιστες τιμές. Τέλος όπως και τα προηγούμενα μοντέλα δεν είναι ικανό να ανιχνεύσει την ιδιαίτερη συμπεριφορά της 16^{ης} μέρας καθώς έχει πολύ μεγάλη απόκλιση την συνηθισμένη ενεργειακή συμπεριφορά.


Πρώτο στοχευμένο σύνολο δεδομένων (Διάρκειας 12 μηνών)

Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Οριζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
Χωρίς	1 ημέρα	8.892	7.462	0.074	53.62
	1 εβδομάδα	7.994	5.951	0.059	49.99
	1 μήνα	8.023	6.329	0.071	48.93
Πρώτη	1 ημέρα	7.401	6.366	0.063	67.88
	1 εβδομάδα	7.046	5.529	0.056	61.15
	1 μήνα	7.491	5.959	0.065	55.49
Δεύτερη	1 ημέρα	6.452	5.367	0.054	75.58
	1 εβδομάδα	6.242	4.836	0.052	69.51
	1 μήνα	6.529	5.285	0.058	66.18
Τρίτη	1 ημέρα	7.192	5.794	0.059	69.66
	1 εβδομάδα	7.612	5.812	0.058	54.65
	1 μήνα	8.686	6.989	0.079	40.14



Εικόνα 4.16 : Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα στο πρώτο στοχευμένο κτίριο του μοντέλου στοιβαγμένων CNN (διάρκειας 12 μηνών)



Εικόνα 4.17 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου στοιβαγμένων CNN στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)

Η επίδοση του μοντέλου στην έκδοση του συνόλου δεδομένων διάρκειας 12 μηνών του πρώτου στοχευμένου κτίριού είναι ικανοποιητική και ειδικά όταν μεταφέρεται γνώση από το πηγαίο τομέα. Συγκεκριμένα το βασικό μοντέλο


εκδηλώνει σχετικά υψηλές τιμές RMSE και MAE για όλους τους ορίζοντες πρόβλεψης καθώς δυσκολεύεται να απεικονίσει σωστά τις διακυμάνσεις του συνόλου. Η μεταφορά μάθησης βελτιώνει την απόδοση, ειδικά για τις δυο πρώτες μεθόδους. Η πλήρη επαναπροσαρμογή του μοντέλου παρουσιάζει σημαντική μείωση στις τιμές RMSE, MAPE και MAE για τους πρώτους δύο ορίζοντες αυξάνοντας ταυτόχρονα το σκορ R^2 . Αυτό σημαίνει πως η πληροφορία του πηγαίου κτιρίου συνδυάζεται σωστά με αυτήν του στοχευμένου προσφέροντας καλύτερες και πιο συνεπείς προβλέψεις. Η δεύτερη μέθοδος, σύμφωνα με την οποία δεν επανεκπαιδεύονται τα προβλεπτικά επίπεδα, επιφέρει τα καλύτερα αποτελέσματα σημειώνοντας αύξηση περίπου 25% στο σκορ R^2 και μείωση 20-25% στις μετρικές RMSE, MAPE και MAE. Αυτό σημαίνει πως αλλοιώνεται σημαντική πληροφορία στα πλήρως συνδεδεμένα επίπεδα από το πηγαίο κτίριο αν πραγματοποιείται επανεκπαίδευση τους με αποτέλεσμα να μειώνονται οι συνολικές επιδόσεις. Η τρίτη μέθοδος προσφέρει κάποια βελτίωση ιδιαίτερα στις βραχυπρόθεσμες προβλέψεις λόγω της εκ νέου εκπαίδευσης των επιπέδων CNN αλλά αυτή η βελτίωση μειώνεται έντονα όσο αυξάνεται ο ορίζοντας πρόβλεψης. Επίσης παρατηρείται ότι η τιμή των μετρικών RMSE, MAPE και MAE είναι μικρότερη στις προβλέψεις επόμενης εβδομάδας καθώς το μοντέλο φαίνεται να μπορεί να προβλέψει καλύτερα σε αυτόν τον ορίζοντα, πράγμα που εντοπίζεται και στις προβλέψεις στο πηγαίο κτίριο.

Οι κατανομές σφαλμάτων της Εικόνας 4.16 επιβεβαιώνουν την έντονη μείωση που προσφέρει η δεύτερη τεχνική σε όλους τους ορίζοντες αλλά και η πρώτη η οποία φαίνεται να αποδίδει καλύτερα στις προβλέψεις επόμενης μέρας. Στις οπτικοποιήσεις της Εικόνας 4.17 φαίνεται ότι τα μοντέλα που αξιοποιούν τη πρώτη και τη δεύτερη μεταφορά μάθησης ακολουθούν στενότερα τις πραγματικές τιμές αλλά δεν καλύπτουν ακριβώς τη διακύμανση σε βραχυπρόθεσμους ορίζοντες ενώ για προβλέψεις επόμενης εβδομάδας ακολουθούν στενότερα το περιοδικό μοτίβο χωρίς όμως να ανιχνεύουν τις ακραίες μέγιστες τιμές σωστά.


Πρώτο στοχευμένο σύνολο δεδομένων (Διάρκειας 6 μηνών)

Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Οριζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
Χωρίς	1 ημέρα	5.666	3.991	0.043	61.21
	1 εβδομάδα	6.239	4.794	0.051	52.21
	1 μήνα	6.474	4.937	0.053	45.95
Πρώτη	1 ημέρα	7.344	6.642	0.071	34.84
	1 εβδομάδα	6.809	5.539	0.058	43.08
	1 μήνα	6.261	5.046	0.053	49.45
Δεύτερη	1 ημέρα	6.351	5.432	0.057	51.27
	1 εβδομάδα	6.326	5.099	0.054	50.87
	1 μήνα	6.163	4.781	0.051	51.01
Τρίτη	1 ημέρα	6.431	4.996	0.052	50.05
	1 εβδομάδα	7.256	5.481	0.056	35.36
	1 μήνα	6.045	4.696	0.052	52.88



Εικόνα 4.18: Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα στο πρώτο στοχευμένο κτίριο του μοντέλου στοιβαγμένων CNN (διάρκειας 6 μηνών)



Εικόνα 4.19 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου στοιβαγμένων CNN στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)

Όταν τα διαθέσιμα δεδομένα στο στοχευμένο τομέα υποδιπλασιάζονται είναι λογικό να μειώνονται και οι αποδόσεις των μοντέλων διότι δεν πραγματοποιείται παρόμοιας ποιότητας εκπαίδευση. Ωστόσο το βασικό μοντέλο παρουσιάζει σχετικά χαμηλές τιμές MAE, RMSE και MAPE για την πρόβλεψη

επόμενης μέρας ενώ η απόδοση του μειώνεται σταδιακά όσο αυξάνεται ο χρονικός ορίζοντας πρόβλεψης. Ωστόσο συγκριτικά με την προηγούμενη εκπαίδευση του σε δεδομένα 12 μηνών, τα αποτελέσματα είναι καλύτερα και ειδικά όσον αφορά το μέσο σφάλμα. Αυτό συμβαίνει διότι το υποσύνολο των προηγούμενων δεδομένων που συμμετείχε σε αυτή τη πρόβλεψη περιλάμβανε μοτίβα κατανάλωσης που ταιριάζουν με το διάστημα στο οποίο πραγματοποιήσε προβλέψεις και το μοντέλο μπόρεσε να τα ανιχνεύσει και να υπερπροσαρμοστεί σε αυτά. Εφαρμόζοντας τη πρώτη μέθοδο μεταφοράς μάθησης τα αποτελέσματα είναι αισθητά χειρότερα παρουσιάζοντας μεγαλύτερα και περισσότερα σφάλματα σε όλους τους χρονικούς ορίζοντες. Εμποδίζοντας την επανεκπαίδευση των προβλεπτικών επιπέδων φαίνεται να βελτιώνει αρκετά την απόδοση του μοντέλου σε σχέση με πριν αλλά και πάλι δεν υπερτερεί του βασικού μοντέλου παρά μόνο ελάχιστα στις μακροπρόθεσμες προβλέψεις. Η τρίτη μέθοδος παρουσιάζει παρόμοια συμπεριφορά με τη δεύτερη με ελάχιστες διαφορές, πράγμα που σημαίνει πως η γνώση του πηγαίου κτιρίου στα συνελκτικά επίπεδα του μοντέλου δεν προσφέρει στη προκειμένη περίπτωση περισσότερα οφέλη από ότι η εκ νέου εκπαίδευση τους.


Οι κατανομές σφαλμάτων της Εικόνας 4.18 επιβεβαιώνουν τα πορίσματα που αναφέρθηκαν παραπάνω δείχνοντας μεγάλα σφάλματα σε όλους τους χρονικούς ορίζοντες ενώ οι τεχνικές μεταφοράς μάθησης μειώνουν ελάχιστα το σφάλμα μόνο στις προβλέψεις επόμενης εβδομάδας. Οι οπτικοποιήσεις στην Εικόνα 4.19 φανερώνουν την ανικανότητα των μοντέλων να ανιχνεύσουν αποδοτικά τις διακυμάνσεις του μοντέλου ακολουθώντας βέβαια το περιοδικό μοτίβο κατανάλωσης σχετικά πιστά. Ταυτόχρονα μόνο το βασικό μοντέλο φαίνεται να πλησιάζει κοντά στις ακραίες μέγιστες τιμές κατανάλωσης που σημειώνονται.

Δεύτερο στοχευμένο σύνολο δεδομένων


Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Ορίζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
	1 ημέρα	5.496	4.412	0.071	15.76
Χωρίς	1 εβδομάδα	6.661	5.418	0.086	15.48

	1 μήνα	8.011	6.581	0.131	14.93
Πρώτη	1 ημέρα	7.223	6.434	0.108	-45.48
	1 εβδομάδα	7.357	5.915	0.102	-3.12
	1 μήνα	8.551	6.962	0.137	3.10
Δεύτερη	1 ημέρα	6.854	6.175	0.103	-31.02
	1 εβδομάδα	6.709	5.467	0.091	14.27
	1 μήνα	7.812	6.313	0.124	19.12
Τρίτη	1 ημέρα	5.909	5.259	0.88	2.64
	1 εβδομάδα	7.086	5.816	0.094	4.35
	1 μήνα	8.041	6.459	0.122	14.31



Εικόνα 4.20 : Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα στο δεύτερο στοχευμένο κτίριο του μοντέλου στοιβαγμένων CNN



Εικόνα 4.21 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου στοιβαγμένων CNN στο δεύτερο στοχευμένο κτίριο

Το δεύτερο σύνολο δεδομένων παρουσιάζει ιδιαίτερες διακυμάνσεις σε σχέση με τα άλλα και το μοντέλο αντιμετωπίζει προκλήσεις στην σωστή πρόβλεψη ανεξάρτητα του χρονικού ορίζοντα πρόβλεψης. Το βασικό μοντέλο παρουσιάζει σχετικά χαμηλές τιμές MAE, MAPE και RMSE για προβλέψεις μιας μέρας, οι οποίες αυξάνονται όσο μεγαλώνει ο ορίζοντας, πράγμα που υποδεικνύει ότι δεν μπορεί να διαχειριστεί μακροπρόθεσμες χρονικές εξαρτήσεις. Ταυτόχρονα το σκορ R^2 παραμένει πολύ μικρό σε όλες τις προβλέψεις του δείχνοντας ανικανότητα να ανιχνεύσει τη διακύμανση του συνόλου. Η εφαρμογή τεχνικών μεταφοράς μάθησης από την άλλη δεν βοηθάει ιδιαίτερα τα αποτελέσματα. Η πρώτη παρουσιάζει σημαντικά μεγαλύτερες τιμές στις μετρικές MAPE, MAE και RMSE σε όλους τους ορίζοντες ενώ το σκορ R^2

λαμβάνει μεγάλες αρνητικές τιμές που υποδεικνύει αρνητική συσχέτιση προβλεπόμενων και πραγματικών τιμών. Η δεύτερη παρουσιάζει καλύτερα αποτελέσματα από τη πρώτη αλλά και πάλι η πρόβλεψη είναι πολύ κακής ποιότητας. Η τρίτη παρουσιάζει τη καλύτερη ισορροπία τιμών μεταξύ μετρικών και οριζόντων πρόβλεψης συγκριτικά με τις άλλες προσεγγίσεις και δεν περιλαμβάνει αρνητικά σκορ R^2 αλλά και πάλι δεν μπορεί να μοντελοποιήσει ιδιαίτερα τη διακύμανση των δεδομένων.

Οι κατανομές των σφαλμάτων τους στην Εικόνα 4.20 δείχνει τα ιδιαίτερα υψηλά σφάλματα που χαρακτηρίζουν τις προβλέψεις του μοντέλου στοιβαγμένων CNN σε αυτό το σύνολο δεδομένων. Παρομοίως οι οπτικοποιήσεις της Εικόνας 4.21 δείχνουν μια ελαφριά μοντελοποίηση της συνολικής τάσης κατανάλωσης αλλά σε καμία περίπτωση δεν περιγράφουν τη διακύμανση ούτε ανιχνεύουν ιδιαίτερα υψηλές και χαμηλές τιμές κατανάλωσης.


4.1.4 Επιδόσεις του υβριδικού δικτύου

Πηγαίο σύνολο δεδομένων

Μετρικές προβλέψεων

Οριζοντας πρόβλεψης	RMSE	MAE	MAPE	R^2 score
1 μέρα	4.627	3.765	0.164	63.69
1 εβδομάδα	4.245	3.486	0.154	65.43
1 μήνα	4.197	3.061	0.137	65.11

Το υβριδικό μοντέλο επιχειρεί να συνδυάσει τις προβλεπτικές ικανότητες των συνελκτικών επιπέδων και των επιπέδων LSTM. Στο πηγαίο σύνολο δεδομένων παρουσιάζει ανταγωνιστικές τιμές MAE, RMSE και σκορ R^2 αλλά δεν καταφέρνει να απεικονίσει τα μοτίβα του πηγαίου συνόλου όπως άλλα μοντέλα. Όπως και πριν κατά κύριο λόγο τα αποτελέσματα των μετρικών μειώνονται όσο αυξάνεται ο οριζοντας πρόβλεψης. Οι οπτικοποιήσεις της



Εικόνα 4.22 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του υβριδικού μοντέλου στο πηγαίο κτίριο


Εικόνας 4.22 παρουσιάζουν την ικανότητα του μοντέλου να μοντελοποιήσει γενικότερες τάσεις και περιοδικές διακυμάνσεις. Ωστόσο στις προβλέψεις επόμενης μέρας παρατηρούμε λανθασμένη εξομάλυνση προς τις τελευταίες ώρες. Στην εβδομαδιαία πρόβλεψη όπως και στην μηνιαία είναι εμφανής η αδυναμία του να ανιχνεύσει ολικές ελάχιστες και μέγιστες τιμές αλλά και κάποιες τοπικές ενώ όπως και όλα τα προηγούμενα μοντέλα δεν μπορεί να διαχειριστεί την ασυνήθιστη συμπεριφορά της 16^{ης} μέρας.

Πρώτο στοχευμένο σύνολο δεδομένων (Διάρκειας 12 μηνών)


Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Οριζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
Χωρίς	1 ημέρα	7.902	6.546	0.064	63.37
	1 εβδομάδα	7.169	5.607	0.056	59.78
	1 μήνα	7.179	5.612	0.062	59.11
Πρώτη	1 ημέρα	6.392	5.286	0.052	76.03
	1 εβδομάδα	5.901	4.751	0.049	72.75

	1 μήνα	5.896	4.713	0.051	72.42
Δεύτερη	1 ημέρα	6.548	5.437	0.054	74.85
	1 εβδομάδα	6.041	4.805	0.049	71.44
	1 μήνα	5.929	4.712	0.051	72.11
Τρίτη	1 ημέρα	11.387	9.345	0.091	23.94
	1 εβδομάδα	9.555	7.763	0.078	28.55
	1 μήνα	8.106	6.438	0.069	47.87
Τέταρτη	1 ημέρα	9.011	7.023	0.068	52.38
	1 εβδομάδα	7.439	6.001	0.061	56.71
	1 μήνα	7.965	6.353	0.071	49.672
Πέμπτη	1 ημέρα	9.998	8.413	0.083	41.363
	1 εβδομάδα	7.726	5.974	0.059	53.29
	1 μήνα	7.048	5.502	0.059	60.593



Εικόνα 4.23 : Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του υβριδικού μοντέλου στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)



Εικόνα 4.24 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του υβριδικού μοντέλου στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)

Στο πρώτο στοχευμένο κτίριο το υβριδικό μοντέλο διαθέτει λιγότερα δεδομένα για να προσαρμοστεί. Αποτέλεσμα αυτού είναι οι επιδόσεις της βασικής εκπαίδευσης να υστερούν με σχετικά υψηλές τιμές RMSE και MAE οι οποίες όμως μειώνονται ελάχιστα όσο αυξάνεται ο ορίζοντας με την εβδομαδιαία πρόβλεψη να παρουσιάζει τη καλύτερη ισορροπία τιμών μεταξύ των μετρικών. Το σκορ R^2 παραμένει περίπου 60% για όλες τις μετρικές δείχνοντας πως ακόμα και αν μειώνεται ελάχιστα το μέσο σφάλμα η απεικόνιση των τάσεων και της συνολικής διακύμανσης παραμένει ίδια. Εφαρμόζοντας


πλήρη επαναπροσαρμογή του μοντέλου φαίνεται να έχει τα καλύτερα αποτελέσματα σημειώνοντας τις μικρότερες τιμές των μετρικών RMSE, MAE και MAPE ενώ ταυτόχρονα το σκορ R^2 είναι μεγαλύτερο του 70% για όλους τους χρονικούς ορίζοντες. Επιλέγοντας να μην επανεκπαιδευτούν τα πλήρως συνδεδεμένα επίπεδα του οδηγεί σε ελάχιστα χειρότερα αποτελέσματα υποδεικνύοντας ότι η προϋπάρχουσα γνώση τους από το πηγαίο κτίριο είναι σημαντική για τις προβλέψεις και αλλοιώνεται ελάχιστα μέσω της εκπαίδευσης στο στοχευμένο. Η εκ νέου εκπαίδευση των συνελκτικών επιπέδων και των επιπέδων LSTM φαίνεται να αποδίδει χειρότερα από όλες τις άλλες μεθόδους σημειώνοντας το μεγαλύτερο μέσο σφάλμα και το μικρότερο σκορ R^2 καθώς απορρίπτει τέσσερα επίπεδα με πολύ πλούσια πληροφορία σχετικά με την εξαγωγή χαρακτηριστικών που αποδείχθηκε πως βοηθάει ενεργά τις προβλέψεις ενώ σε αυτή τη περίπτωση δεν αξιοποιείται. Επιλέγοντας μόνο τα συνελκτικά επίπεδα ή τα επίπεδα LSTM προς εκ νέου εκπαίδευση βελτιώνει τα αποτελέσματα ωστόσο επιλέγοντας τα πρώτα προσφέρει καλύτερες βραχυπρόθεσμες προβλέψεις ενώ επιλέγοντας τα δεύτερα σημειώνεται καλύτερη μακροπρόθεσμη επίδοση, πράγμα που οφείλεται στις επιμέρους αρχιτεκτονικές τους.

Οι κατανομές των σφαλμάτων τους στην Εικόνα 4.23 επιβεβαιώνουν τη μείωση του μέσου σφάλματος μέσω της πρώτης και δεύτερης τεχνικής στις εβδομαδιαία και μηνιαία πρόβλεψη ενώ μόνο η πρώτη προσφέρει ελάχιστη μείωση στην ημερήσια. Ωστόσο τα ανώτατα όρια των σφαλμάτων μειώνονται αισθητά από αυτές ενώ είναι ξεκάθαρο ότι δεν βελτιώνονται τα αποτελέσματα από τις άλλες τρεις μεθόδους. Οι οπτικοποιήσεις της Εικόνας 4.24 δείχνουν ότι τα μοντέλα που αξιοποιούν τις δύο πρώτες μεθόδους ευθυγραμμίζονται περισσότερο με την γενική περιοδική τάση κατανάλωσης και στις εβδομαδιαίες προβλέψεις φαίνονται να μπορούν να ανιχνεύσουν καλύτερα τις μέγιστες ακραίες τιμές σε σχέση με τα άλλα μοντέλα. Όμως κανένα μοντέλο δεν μπορεί να περιγράψει επαρκώς τις διακυμάνσεις της παρουσιάζοντας υπερβολική εξομάλυνση.


Πρώτο στοχευμένο σύνολο δεδομένων (Διάρκειας 6 μηνών)

Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Οριζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
Χωρίς	1 ημέρα	9.397	7.665	0.079	-6.694
	1 εβδομάδα	8.901	7.233	0.075	2.766
	1 μήνα	7.938	6.294	0.066	18.75
Πρώτη	1 ημέρα	4.879	4.041	0.042	71.24
	1 εβδομάδα	6.085	5.026	0.052	54.54
	1 μήνα	6.576	5.361	0.056	44.23
Δεύτερη	1 ημέρα	4.742	3.721	0.038	72.83
	1 εβδομάδα	5.807	4.599	0.048	58.61
	1 μήνα	6.753	5.353	0.055	41.21
Τρίτη	1 ημέρα	9.148	6.671	0.66	-1.11
	1 εβδομάδα	9.822	7.585	0.076	-18.42
	1 μήνα	9.492	7.393	0.075	-16.18
Τέταρτη	1 ημέρα	7.648	5.263	0.056	29.33
	1 εβδομάδα	7.849	5.942	0.064	24.37
	1 μήνα	7.588	5.871	0.064	25.74
Πέμπτη	1 ημέρα	7.497	5.863	0.061	32.09
	1 εβδομάδα	7.157	5.761	0.059	37.12
	1 μήνα	6.903	5.445	0.057	38.554



Εικόνα 4.25 : Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του υβριδικού μοντέλου στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)



Εικόνα 4.26 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του υβριδικού μοντέλου στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)

Η βασική εκπαίδευση του μοντέλου στο ιδιαίτερα ελλιπές σύνολο δεδομένων 6 μηνών του πρώτου στοχευμένου κτιρίου αποδεικνύεται ιδιαίτερα αναποτελεσματική καθώς οι υψηλές τιμές RMSE και MAE υποδεικνύουν υψηλές αποκλίσεις στις προβλέψεις ενώ σύμφωνα με το αρνητικό σκορ R^2 το μοντέλο δεν είναι ικανό να μοντελοποιήσει τις διακυμάνσεις του συνόλου δεδομένων. Όσο αυξάνεται ο ορίζοντας πρόβλεψης φαίνεται πως οι επιδόσεις βελτιώνονται αλλά εξακολουθούν να μην μπορούν να ανιχνεύσουν σημαντικά μοτίβα κατανάλωσης εφόσον διαθέτουν θετικό αλλά πολύ μικρό σκορ R^2 . Με την πλήρη επανεκπαίδευση του πηγαίου προεκπαιδευμένου μοντέλου σε αυτό το σύνολο παρατηρείται εξαιρετική βελτίωση των αποτελεσμάτων σημειώνοντας 58%, 30% και 15% μείωση του μέσου σφάλματος για κάθε χρονικό ορίζοντα πρόβλεψης αντίστοιχα ενώ παράλληλα το σκορ R^2 είναι αρκετά υψηλό (71%) για ημερήσιες προβλέψεις ενώ μειώνεται στις εβδομαδιαίες και μηνιαίες οι οποίες είναι καλύτερες από του βασικού μοντέλου αλλά δεν παρουσιάζουν ιδιαίτερη απόδοση. Η εξαίρεση των προεκπαιδευμένων πλήρως συνδεδεμένων επιπέδων από την επανεκπαίδευση οδηγεί σε ελάχιστα καλύτερα αποτελέσματα σε όλους τους ορίζοντες, κάτι που υποδεικνύει την ύπαρξη χρήσιμης γνώσης για αυτά στο εξεταζόμενο σύνολο. Επανεκπαιδεύοντας εκ νέου τα επίπεδα εξαγωγής επιπέδων παρουσιάζει χειρότερα αποτελέσματα με μεγάλη αύξηση των αποκλίσεων. Η επιλογή είτε των συνελκτικών επιπέδων είτε των επιπέδων LSTM για εκ νέου εκπαίδευση αποδίδει καλύτερα σε σχέση με τη προηγούμενη μέθοδο χωρίς όμως να αποδίδει ιδιαίτερα καλά ενώ η επιλογή των επιπέδων LSTM αποδίδει καλύτερα εκ των δυο.


Οι κατανομές των σφαλμάτων της Εικόνας 4.25 επιβεβαιώνουν το μειωμένο μέσο σφάλμα που προσφέρουν οι τεχνικές μεταφοράς μάθησης σε σχέση με τη βασική εκπαίδευση ενώ διακρίνεται εύκολα η συνολικότερη συνέπεια και υπεροχή της πρώτης και δεύτερης προσέγγισης. Οι μεγαλύτεροι χρονικοί ορίζοντες πρόβλεψης φαίνεται πως αντιστοιχούν σε μεγαλύτερα σφάλματα, πράγμα που συνάδει με την αναμενόμενη συσσώρευση αβεβαιότητας με τη πάροδο του χρόνου. Στην Εικόνα 4.26 παρατηρούνται οι οπτικοποιήσεις των προβλέψεων των μοντέλων και μπορούμε να διακρίνουμε ότι η πρώτη και η δεύτερη μέθοδος ευθυγραμμίζονται καλύτερα με τις πραγματικές τιμές και μοντελοποιούν καλύτερα τις διακυμάνσεις του συνόλου. Ωστόσο η πέμπτη

προσέγγιση φαίνεται να μπορεί να ανιχνεύσει καλύτερα τις μέγιστες τιμές κατανάλωσης αλλά η απόδοση τους περιορίζεται σε αυτό το χαρακτηριστικό.

Δεύτερο στοχευμένο σύνολο δεδομένων


Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Οριζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
Χωρίς	1 ημέρα	7.126	6.334	0.107	-41.58
	1 εβδομάδα	6.853	5.583	0.093	10.54
	1 μήνα	7.618	6.238	0.123	23.09
Πρώτη	1 ημέρα	6.057	4.669	0.075	-2.29
	1 εβδομάδα	6.209	4.986	0.079	26.57
	1 μήνα	6.412	5.176	0.097	45.51
Δεύτερη	1 ημέρα	5.787	4.738	0.076	6.62
	1 εβδομάδα	6.154	4.998	0.081	27.85
	1 μήνα	6.501	5.303	0.101	43.99
Τρίτη	1 ημέρα	6.782	5.621	0.093	-28.25
	1 εβδομάδα	7.402	5.875	0.096	-4.36
	1 μήνα	8.101	6.259	0.121	13.02
Τέταρτη	1 ημέρα	6.424	5.101	0.081	-15.05
	1 εβδομάδα	7.951	6.468	0.103	-20.41
	1 μήνα	8.310	6.751	0.131	8.27
Πέμπτη	1 ημέρα	7.736	5.904	0.092	-66.85
	1 εβδομάδα	8.497	6.528	0.101	-37.54
	1 μήνα	8.021	6.313	0.114	14.76



Εικόνα 4.27 : Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του υβριδικού μοντέλου στο δεύτερο στοχευμένο κτίριο

Η εκπαίδευση του υβριδικού μοντέλου στο δεύτερο στοχευμένο επίπεδο παρουσιάζει παρόμοια σφάλματα με την επίδοση στο εξάμηνο σύνολο δεδομένων του πρώτου στοχευμένου κτιρίου αλλά και αισθητά χαμηλότερα



Εικόνα 4.28 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του υβριδικού μοντέλου στο δεύτερο στοχευμένο κτίριο

σκορ R^2 . Συγκεκριμένα το βασικό μοντέλο φαίνεται να μην μπορεί να προσαρμοστεί καθόλου στα δεδομένα εκδηλώνοντας μεγάλες αποκλίσεις από τις πραγματικές τιμές και κατ' επέκταση αδυναμία ευθυγράμμισης με την τάση κατανάλωσης που υπάρχει σημειώνοντας αρνητικό σκορ R^2 στις ημερίσιες προβλέψεις του. Εφαρμόζοντας ολική επαναπροσαρμογή του πηγαιού προεκπαιδευμένου μοντέλου στο τρέχων σύνολο δεδομένων προσφέρει σημαντική βελτίωση των αποτελεσμάτων αλλά εξακολουθεί να μην αποτυπώνει σωστά τις ιδιαιτερότητες του συνόλου δεδομένων. Εξαιρώντας από τη προηγούμενη διαδικασία τα προβλεπτικά επίπεδα επιφέρει ελάχιστα καλύτερη επίδοση στις ημερήσιες προβλέψεις σε σχέση με πριν όντας σαφώς καλύτερη από την επίδοση του βασικού μοντέλου ενώ αυτή είναι παρόμοια στις εβδομαδιαίες και χειρότερη στις μηνιαίες προβλέψεις. Οποιαδήποτε προσπάθεια εκ νέου εκπαίδευσης επιπέδων εξαγωγής χαρακτηριστικών οδηγεί σε αισθητά χειρότερα αποτελέσματα σε σχέση με το βασικό μοντέλο.


Οι κατανομές σφαλμάτων της Εικόνας 4.27 επιβεβαιώνουν την ικανότητα της πρώτης και δεύτερης μεθόδου να μειώνει το αισθητά το εύρος αλλά και τη μέση τιμή του σφάλματος σε σχέση με το βασικό μοντέλο και τις άλλες μεθόδους ενώ παρατηρούνται συνολικά αυξημένα σφάλματα για μηνιαίες προβλέψεις υποδεικνύοντας την αυξημένη αβεβαιότητα που συνοδεύει τους πιο μεγάλους χρονικούς ορίζοντες. Οι οπτικοποιήσεις στην Εικόνα 2.28 παρουσιάζουν την ανικανότητα όλων των μεθόδων να αποτυπώσουν τη διακύμανση των πραγματικών τιμών αλλά η πρώτη και δεύτερη μέθοδος μεταφοράς μάθησης φαίνεται να αποτυπώνουν καλύτερα τη γενικότερη τάση των δεδομένων ενώ δεν ανιχνεύουν αρκετές μέγιστες τιμές κατανάλωσης.

4.1.5 Επιδόσεις δικτύου TFT

Πηγαίο σύνολο δεδομένων

Μετρικές προβλέψεων

Ορίζοντας πρόβλεψης	RMSE	MAE	MAPE	R^2 score
1 μέρα	3.326	2.398	0.092	81.24
1 εβδομάδα	3.035	2.37	0.091	82.32
1 μήνα	3.671	2.553	0.105	73.33



Εικόνα 4.29 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του μοντέλου TFT στο πηγαίο κτίριο


Το μοντέλο TFT πραγματοποιώντας εκπαίδευση στο σύνολο δεδομένων του πηγαίου κτιρίου σημειώνει ιδιαίτερα καλά αποτελέσματα δεδομένων του διαθέσιμου όγκου δεδομένων. Συγκεκριμένα για ημερήσιες προβλέψεις παρουσιάζει αρκετά χαμηλές τιμές RMSE, MAE και MAPE ενώ το σκορ R^2 θεωρείται αρκετά καλό. Στις εβδομαδιαίες προβλέψεις επιτυγχάνει καλύτερες τιμές σε όλες τις μετρικές, πράγμα που σημαίνει πως εκμεταλλεύεται σωστά τα

χρονικά μοτίβα και το μήκος των ακολουθιών εισόδου (μήκος ίσο με 48 ώρες). Στις μηνιαίες προβλέψεις παρατηρείται ελάχιστα χειρότερη απόδοση, η οποία είναι αναμενόμενη δεδομένης της αυξημένης αβεβαιότητας που συνοδεύει τέτοιους ορίζοντες πρόβλεψης. Από τις οπτικοποιήσεις της Εικόνας 4.29 παρατηρείται αρκετά στενή ευθυγράμμιση με τις πραγματικές τιμές με κάποιες υπερεκτιμήσεις να είναι ορατές προς τις τελευταίες ώρες της πρόβλεψης. Η απόδοση στις εβδομαδιαίες προβλέψεις είναι παρόμοια καλή αποτυπώνοντας καλά την τάση των δεδομένων και τα συνολικότερα μοτίβα ενώ πραγματοποιεί ελάχιστες υποτιμήσεις των μέγιστων τιμών κατανάλωσης του πηγαίου κτιρίου. Στη μηνιαία πρόβλεψη παρατηρούμε παρόμοια επίδοση με της εβδομαδιαίας αλλά όπως και τα προηγούμενα μοντέλα αδυνατεί να απεικονίσει την συμπεριφορά της 16^{ης} μέρας κυρίως γιατί αποτελεί εξαίρεση στην ενεργειακή συμπεριφορά του κτιρίου.


Πρώτο στοχευμένο σύνολο δεδομένων (Διάρκειας 12 μηνών)

Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Ορίζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
Χωρίς	1 ημέρα	6.935	6.126	0.062	71.79
	1 εβδομάδα	5.884	4.571	0.047	71.91
	1 μήνα	5.909	4.499	0.049	72.31
Πρώτη	1 ημέρα	6.458	5.352	0.055	75.54
	1 εβδομάδα	6.225	4.881	0.051	69.68
	1 μήνα	6.171	4.706	0.051	69.81
Δεύτερη	1 ημέρα	7.017	5.999	0.061	71.12
	1 εβδομάδα	6.169	4.804	0.049	70.22
	1 μήνα	6.211	4.765	0.052	69.41
Τρίτη	1 ημέρα	5.888	5.009	0.053	79.67
	1 εβδομάδα	5.627	4.445	0.046	75.22
	1 μήνα	5.545	4.134	0.045	75.61
Τέταρτη	1 ημέρα	6.366	5.559	0.057	76.24
	1 εβδομάδα	5.564	4.373	0.045	75.78
	1 μήνα	5.834	4.491	0.049	73.01



Εικόνα 4.30 : Κατανομές σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του μοντέλου TFT στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)



Εικόνα 4.31 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου TFT στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)

Η μείωση του όγκου των δεδομένων είναι εμφανές πως μειώνει την απόδοση του μοντέλου αισθητά σχετικά με το πηγαίο μοντέλο παρατηρώντας μια μείωση περίπου 10% στο σκορ R^2 , το οποίο ωστόσο παραμένει μεγαλύτερο του 70% υποδεικνύοντας ότι μπορεί και ανιχνεύει τη διακύμανση του συνόλου σχετικά καλά. Επίσης παρατηρείται ελάχιστα καλύτερη απόδοση στις μηνιαίες προβλέψεις σε σχέση με τους άλλους ορίζοντες ενώ οι ημερήσιες σημειώνουν υψηλότερες τιμές στις μετρικές RMSE, MAPE και MAE παρόλο που διατηρούν παρόμοιο σκορ R^2 . Εφαρμόζοντας πλήρη επαναπροσαρμογή του πηγαίου μοντέλου στο τρέχον σύνολο δεδομένων αυξάνει την απόδοση στις ημερήσιες προβλέψεις αισθητά σημειώνοντας χαμηλότερες τιμές RMSE και MAE και υψηλότερο σκορ R^2 ενώ οι εβδομαδιαίες και μηνιαίες προβλέψεις είναι ελάχιστα χειρότερες από το βασικό μοντέλο, πράγμα που σημαίνει πως η χρήσιμη πληροφορία για μακροπρόθεσμες προβλέψεις από το πηγαίο τομέα αλλοιώνεται με την ολική επαναπροσαρμογή. Εστιάζοντας αυτή στα επίπεδα επιλογής μεταβλητών παρουσιάζει χειρότερα αποτελέσματα με πριν στις ημερήσιες και μηνιαίες προβλέψεις ενώ σημειώνει ελάχιστη βελτίωση στις εβδομαδιαίες. Από την άλλη αν επανεκπαιδευτούν τα επίπεδα LSTM η απόδοση είναι σημαντικά μεγαλύτερη με το σκορ στις ημερήσιες προβλέψεις να φτάνει το 80% και στις υπόλοιπες περίπου 75%, πράγμα που επιβεβαιώνει την σημασία προσαρμογής τους στον στοχευμένο τομέα διατηρώντας τη χρήσιμη γνώση που κατείχαν από το πηγαίο. Τέλος προσαρμόζοντας μόνο το μηχανισμό της


προσοχής και το στατικό εμπλουτισμό επιφέρει τα καλύτερα αποτελέσματα μετά τη τρίτη μέθοδο ενώ παρουσιάζει τη βέλτιστη απόδοση στις εβδομαδιαίες προβλέψεις σημειώνοντας καλύτερο σκορ R^2 από αυτή.

Οι κατανομές σφαλμάτων της Εικόνας 4.30 επιβεβαιώνουν την υπεροχή της εφαρμογής της τρίτης και της τέταρτης μεθόδου καθώς μειώνουν αισθητά το μέσο σφάλμα αλλά και το εύρος του σε σχέση με το βασικό μοντέλο, ιδιαίτερα η τρίτη, ενώ η πρώτη και η δεύτερη σε αρκετές περιπτώσεις έχουν παρόμοιο ή ελάχιστα μικρότερο εύρος σφαλμάτων αυτό. Παράλληλα στην Εικόνα 4.31 φαίνονται οι οπτικοποιήσεις όλων των μοντέλων και παρουσιάζεται η συνολική ικανότητα τους να ευθυγραμμίζονται με τη γενικότερη τάση και να ανιχνεύουν τα περιοδικά μοτίβα της κατανάλωσης με τη τρίτη να αποδίδει καλύτερα. Ωστόσο είναι αισθητές αρκετές υπερεκτιμήσεις και υποτιμήσεις, πιο έντονα στις ημερήσιες προβλέψεις, αλλά και αρκετές μέγιστες τιμές κατανάλωσης που δεν ανιχνεύονται καθόλου από κανένα μοντέλο.


Πρώτο στοχευμένο σύνολο δεδομένων (Διάρκειας 6 μηνών)

Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Ορίζοντας Πρόβλεψης	RMSE	MAE	MAPE	R2 score
Χωρίς	1 ημέρα	6.557	5.019	0.052	48.06
	1 εβδομάδα	6.746	5.158	0.054	44.13
	1 μήνα	6.659	5.193	0.055	42.82
Πρώτη	1 ημέρα	5.337	4.131	0.043	65.59
	1 εβδομάδα	6.038	4.649	0.048	55.25
	1 μήνα	5.604	4.417	0.047	59.51
Δεύτερη	1 ημέρα	5.26	4.004	0.041	66.57
	1 εβδομάδα	5.856	4.456	0.046	57.91
	1 μήνα	5.414	4.221	0.045	62.21
Τρίτη	1 ημέρα	4.253	3.313	0.035	78.15
	1 εβδομάδα	5.096	3.954	0.042	68.12
	1 μήνα	4.878	3.864	0.041	69.31
Τέταρτη	1 ημέρα	4.716	3.67	0.039	73.13
	1 εβδομάδα	5.175	3.984	0.042	67.12
	1 μήνα	5.015	3.925	0.042	67.57



Εικόνα 4.32 : Εύρη σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του μοντέλου TFT στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)



Εικόνα 4.33 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου TFT στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)

Η εκπαίδευση του μοντέλου TFT χρησιμοποιώντας δεδομένα διάρκειας 6 μηνών είναι σαφώς δυσκολότερη καθώς διαθέτει αρκετές παραμέτρους όντας ένα ιδιαίτερα σύνθετο μοντέλο. Ωστόσο καταφέρνει να σημειώσει σκορ R^2 μεγαλύτερο του 40% για όλους τους ορίζοντες με το μέσο σφάλμα να παραμένει σταθερό αλλά σχετικά υψηλό. Εφαρμόζοντας πλήρη επανεκπαίδευση του πηγαιού μοντέλου στο εξεταζόμενο σύνολο δεδομένων προσφέρει αισθητή βελτίωση σε όλες τις μετρικές σε σχέση με το βασικό μοντέλο, ιδιαίτερα στις ημερήσιες και μηνιαίες προβλέψεις όπου σημειώνει 25-30% βελτίωση στο σκορ R^2 . Ωστόσο θα ήταν αναμενόμενο να είχε τα καλύτερα αποτελέσματα από όλες τις μεθόδους αλλά λόγω του μικρού μεγέθους του συνόλου υπάρχει η πιθανότητα υπερπροσαρμογής. Εστιάζοντας την υπερπροσαρμογή στα επίπεδα επιλογής μεταβλητών και στο στατικό εμπλουτισμό το μοντέλο μπορεί να διατηρήσει το μεγαλύτερο μέρος της προϋπάρχουσας γνώσης από το πηγαιό σύνολο ενώ ταυτόχρονα βελτιώνει τον τρόπο ενσωμάτωσης των στατικών και δυναμικών μεταβλητών του νέου συνόλου δεδομένων. Έτσι επιτυγχάνεται μια σχετικά μικρή αλλά αισθητή συνολική βελτίωση όλων των μετρικών σε σχέση με τη πρώτη μέθοδο. Από την άλλη εστιάζοντας την επαναπροσαρμογή αποκλειστικά στον κωδικοποιητή-αποκωδικοποιητή LSTM το μοντέλο μπορεί και ανανεώνει τον τρόπο που μοντελοποιεί χρονικές εξαρτήσεις με γνώση από το στοχευμένο τομέα με

αποτέλεσμα να αποδίδει εξαιρετικά σε σχέση με όλες τις υπόλοιπες μεθόδους σημειώνοντας σκορ R^2 περίπου 80% για ημερήσιες προβλέψεις και 70% για εβδομαδιαίες και μηνιαίες ενώ το μέσο σφάλμα μειώνεται ανάλογα. Τέλος επανεκπαιδεύοντας μόνο τα επίπεδα σχετικά με τη προσοχή και το στατικό εμπλουτισμό πριν από αυτήν, το μοντέλο μπορεί να εστιάσει περισσότερο στις μακροπρόθεσμες εξαρτήσεις αλλά λόγω του μικρού όγκου δεδομένων εκπαίδευσης δεν μπορεί να προσφέρει καλύτερες μακροπρόθεσμες προβλέψεις σε σχέση με την τρίτη μέθοδο καθώς η προϋπάρχουσα γνώση από το πηγαίο τομέα αλλοιώνεται και δεν μπορεί να εφαρμοστεί σωστά όπως σε αυτήν.


Οι κατανομές σφαλμάτων της Εικόνας 4.32 παρουσιάζουν την γενικότερη βελτίωση που προσφέρουν οι τεχνικές μεταφοράς μάθησης στην απόδοση του μοντέλου σε σχέση με απλή εκπαίδευση ενώ επιβεβαιώνεται η υπεροχή της τρίτης μεθόδου ως τη πιο αποτελεσματική. Ταυτόχρονα οι οπτικοποιήσεις στην Εικόνα 4.33 παρουσιάζουν την ικανότητα των μοντέλων που εφαρμόζουν τη δεύτερη και τρίτη προσέγγιση μεταφοράς μάθησης να ευθυγραμμίζονται με τις πραγματικές τιμές ωστόσο υπάρχουν σημεία που παρατηρούνται υποεκτιμήσεις και υπερεκτιμήσεις. Στις εβδομαδιαίες προβλέψεις φαίνεται πως οι ίδιες μέθοδοι επιτρέπουν την ανίχνευση του μοτίβου κατανάλωσης του συνόλου δεδομένων και τη καλύτερη μοντελοποίηση των μέγιστων τιμών κατανάλωσης σε σχέση με τα άλλα μοντέλα.

Δεύτερο στοχευμένο σύνολο δεδομένων


Μετρικές προβλέψεων

Τεχνική Μεταφοράς Μάθησης	Ορίζοντας Πρόβλεψης	RMSE	MAE	MAPE	R^2 score
Χωρίς	1 ημέρα	6.824	5.736	0.099	-29.84
	1 εβδομάδα	5.949	4.912	0.082	32.58
	1 μήνα	6.166	4.973	0.095	49.61
Πρώτη	1 ημέρα	5.391	4.495	0.077	19.01
	1 εβδομάδα	6.388	5.283	0.089	22.26
	1 μήνα	6.002	4.803	0.091	52.26
Δεύτερη	1 ημέρα	5.451	4.352	0.072	17.16
	1 εβδομάδα	7.521	5.836	0.093	-7.72
	1 μήνα	7.119	5.641	0.106	32.82

Τρίτη	1 ημέρα	4.246	3.571	0.059	49.74
	1 εβδομάδα	4.697	3.771	0.062	57.97
	1 μήνα	4.966	4.029	0.077	67.32
Τέταρτη	1 ημέρα	6.694	5.397	0.087	-24.96
	1 εβδομάδα	7.057	5.652	0.091	5.13
	1 μήνα	7.282	5.841	0.109	29.79



Εικόνα 4.34 : Εύρη σφαλμάτων των προβλέψεων επόμενης μέρας/εβδομάδας/μήνα του μοντέλου TFT στο δεύτερο στοχευμένο κτίριο



Εικόνα 4.35 : Γραφικές παραστάσεις προβλέψεων επόμενης μέρας/εβδομάδας του μοντέλου TFT στο δεύτερο στοχευμένο κτίριο

Το δεύτερο στοχευμένο κτίριο περιλαμβάνει δεδομένα με μεγάλη διακύμανση τα οποία είναι δύσκολο να μοντελοποιηθούν χωρίς επαρκή εκπαίδευση. Το βασικό μοντέλο εδώ συναντά αρκετές προκλήσεις και η απόδοση του είναι αρκετά κακή, ιδιαίτερα στις ημερήσιες προβλέψεις στις οποίες έχει αρνητικό σκορ R^2 αν και βελτιώνεται αρκετά όσο αυξάνεται ο χρονικός ορίζοντας. Εκτελώντας πλήρη επαναπροσαρμογή του πηγαίου μοντέλου παρουσιάζει μεικτή απόδοση βελτιώνοντας ιδιαίτερος τις ημερήσιες προβλέψεις και αρκετά λιγότερο τις μηνιαίες ενώ στις εβδομαδιαίες το αποτέλεσμα είναι χειρότερο, πράγμα που υποδεικνύει κάποιο βαθμό υπερπροσαρμογής στο μικρό όγκο δεδομένων. Προσαρμόζοντας μόνο τα επίπεδα επιλογής στατικών και δυναμικών μεταβλητών τα αποτελέσματα είναι κατά κύριο λόγο χειρότερα, πράγμα που σημαίνει πως υπάρχουν και άλλα επίπεδα που έχουν να αποκομίσουν σημαντική γνώση από το εξεταζόμενο σύνολο ή η προϋπάρχουσα γνώση του πηγαίου τομέα σε αυτά τα επίπεδα αλλοιώνεται και δεν μπορεί να προσφέρει τη κατάλληλη επιλογή σχετικών

μεταβλητών. Από την άλλη προσαρμόζοντας τα επίπεδα LSTM που είναι υπεύθυνα για την εξαγωγή ακολουθιακών μοτίβων το μοντέλο παρουσιάζει εξαιρετική βελτίωση σε όλες τις μετρικές. Οι τιμές των μετρικών RMSE και MAE είναι αρκετά μειωμένες στις ημερήσιες και εβδομαδιαίες προβλέψεις με το σκορ R^2 να βρίσκεται στο 50% και 57% αντίστοιχα ενώ για τις μηνιαίες προβλέψεις εντοπίζεται αυξημένο σφάλμα, πράγμα που είναι λογικό λόγω της αβεβαιότητας, αλλά παρουσιάζει σκορ R^2 ίσο με 67.32% υποδηλώνοντας ότι μοντελοποιεί πολύ καλύτερα τη διακύμανση του συνόλου. Η τελευταία μέθοδος εστιάζει στην επανεκπαίδευση του μηχανισμού προσοχής, ο οποίος βασίζεται και στις αναπαραστάσεις των επιπέδων LSTM τα οποία όπως φαίνεται και από τη δεύτερη μέθοδο δεν αποδίδουν καλά χωρίς επαναπροσαρμογή, με αποτέλεσμα οι αναπαραστάσεις τους να μην αντιπροσωπεύουν καλά τα δεδομένα και κατ' επέκταση δεν θα εκπαιδευτεί στα σωστά μοτίβα ο μηχανισμός προσοχής. Έτσι τα αποτελέσματα είναι αρκετά κακά σε σχέση με το βασικό μοντέλο.

Οι κατανομές των σφαλμάτων της εικόνας 4.34 επιβεβαιώνουν την υπεροχή της τέταρτης μεθόδου σε σχέση με όλες τις άλλες προσφέροντας συνολικά μικρότερα μέσα σφάλματα σε όλους τους χρονικούς ορίζοντες ενώ σχετική βελτίωση παρατηρείται και μέσω της πρώτης και δεύτερης στις ημερήσιες προβλέψεις. Παράλληλα στην εικόνα 4.35 παρατηρείται η έντονη διαφορά των προβλέψεων του μοντέλου που αξιοποιεί τη πρώτη μέθοδο σε σχέση με τα άλλα όσον αφορά την απεικόνιση της συνολικής τάσης και διακύμανσης αλλά εξακολουθούν να υπάρχουν μέγιστες και ελάχιστες τιμές κατανάλωσης που δεν περιγράφονται επαρκώς.

4.2 Συγκριτικά αποτελέσματα


Στην παρούσα υποενότητα θα αναλυθούν τα αποτελέσματα των προβλέψεων επόμενης ημέρας, εβδομάδας και μήνα των καλύτερων εκδοχών κάθε μοντέλου σε όλα τα σύνολα δεδομένων. Η ταξινόμηση έγινε μέσω σύγκρισης της απόδοσης στη μετρική RMSE καθώς επηρεάζεται έντονα από τα μεγάλα σφάλματα και στην πρόβλεψη ενεργειακού φορτίου είναι ιδιαίτερα σημαντική η μείωση των μεγάλων αποκλίσεων από τις πραγματικές τιμές κατανάλωσης για να μην προκληθεί αστάθεια στο ενεργειακό δίκτυο, ειδικά όταν δεν ανιχνεύεται η πολύ υψηλή κατανάλωση. Επίσης για την οπτικοποίηση των αποτελεσμάτων παρουσιάζονται μόνο τα τρία καλύτερα μοντέλα με χρήση του κόκκινου, πράσινου και μπλε για το πρώτο, δεύτερο και τρίτο καλύτερο αντίστοιχα. Τέλος για απλούστευση της έκφρασης τα ακολουθιακά μοντέλα θα αναφέρονται απλά με το όνομα των επιπέδων εξαγωγής δεδομένων τους καθώς αυτό τα διαφοροποιεί αρχιτεκτονικά μεταξύ τους. Για παράδειγμα το μοντέλο στοιβαγμένων LSTM θα αναφέρεται ως απλά LSTM.

Πηγαίο σύνολο δεδομένων

Μετρικές καλύτερων ημερήσιων προβλέψεων

Μοντέλο	RMSE	MAE	MAPE	R^2 score
Stacked LSTM	2.874	2.274	0.093	85.99
Stacked RNN	3.171	2.361	0.099	82.96
TFT	3.326	2.398	0.092	81.24
Stacked CNN	4.461	3.313	0.132	66.25
CNN-LSTM-Hybrid	4.467	3.765	0.164	63.69

Για τις ημερήσιες προβλέψεις στο πηγαίο σύνολο δεδομένων το LSTM αποδίδει καλύτερα από τα άλλα προσφέροντας τις καλύτερες τιμές σε όλες τις μετρικές δείχνοντας την ισχυρή ικανότητα του να μοντελοποιεί ακολουθιακά δεδομένα. Ελάχιστα χειρότερο είναι το RNN το οποίο είναι λογικό καθώς εξακολουθεί να είναι ακολουθιακό μοντέλο αλλά με λιγότερες δυνατότητες από




Εικόνα 4.36 : Γραφικές παραστάσεις καλύτερων ημερήσιων προβλέψεων στο σύνολο δεδομένων του πηγαίου κτιρίου

το LSTM. Παρόμοια επίδοση έχει και το TFT το οποίο λόγω της έκτασης του συνόλου δεδομένων θα μπορούσε να μην έχει πραγματοποιήσει σωστή επιλογή μεταβλητών ή ακόμα και να έχει υπερπροσαρμοστεί. Ωστόσο οι διαφορές των τριών μοντέλων είναι ουσιαστικά μικρές αλλά αισθητά καλύτερες από το CNN και το υβριδικό μοντέλο τα οποία δεν φαίνεται να ανιχνεύουν τόσο καλά τις χρονικές εξαρτήσεις. Η Εικόνα 4.36 παρέχει μια οπτικοποίηση των τριών καλύτερων αποτελεσμάτων και επιβεβαιώνει την παρόμοια καλή ευθυγράμμιση τους με τις πραγματικές τιμές ενώ αναδεικνύει την ικανότητα του LSTM να απεικονίζει καλύτερα τις μέγιστες και ελάχιστες τιμές.

Μετρικές καλύτερων εβδομαδιαίων προβλέψεων

Μοντέλο	RMSE	MAE	MAPE	R^2 score
Stacked LSTM	2.692	2.215	0.091	86.094
Stacked RNN	2.993	2.414	0.102	82.814
TFT	3.035	2.37	0.091	82.324
Stacked CNN	3.984	3.091	0.122	69.548
CNN-LSTM-Hybrid	4.245	3.486	0.154	65.429

Στις εβδομαδιαίες προβλέψεις η κατάταξη είναι ίδια, με το LSTM να βρίσκεται πάλι πρώτο προσφέροντας ακόμη χαμηλότερο σφάλμα και υψηλότερο σκορ R^2 και τα μοντέλα RNN και TFT προσφέρουν ακόμη πιο παρόμοια απόδοση με εξαίρεση το δείκτη MAE και MAPE οι οποίο είναι μικρότεροι στο μοντέλο TFT το οποίο σημαίνει ότι διαθέτει καλύτερο μέσο




Εικόνα 4.37 : Γραφικές παραστάσεις καλύτερων εβδομαδιαίων προβλέψεων στο σύνολο δεδομένων του πηγαίου κτιρίου

σφάλμα σε σχέση με το RNN αλλά παρουσιάζει κάποιες πιο έντονες μεγάλες αποκλίσεις. Το υβριδικό μοντέλο και το CNN εξακολουθούν να είναι τα χειρότερα καθώς δεν ανιχνεύουν τόσο καλά τα χρονικά μοτίβα. Οι οπτικοποιήσεις της Εικόνας 4.37 παρουσιάζουν την στενή ευθυγράμμιση του μοντέλου LSTM με το χρονικό μοτίβο κατανάλωσης ενώ αναδεικνύουν την υπερεκτίμηση αρκετών μέγιστων τιμών κατανάλωσης από το μοντέλο TFT αλλά και την ύπαρξη ορισμένων που δεν αποτυπώνονται από κανένα.

Μετρικές καλύτερων μηνιαίων προβλέψεων

Μοντέλο	RMSE	MAE	MAPE	R^2 score
Stacked LSTM	3.17	2.226	0.092	80.11
Stacked RNN	3.212	2.311	0.098	79.57
TFT	3.671	2.553	0.105	73.33
Stacked CNN	4.059	2.796	0.117	67.37
CNN-LSTM-Hybrid	4.197	3.061	0.137	65.11

Τα μοντέλα ακολουθούν επίσης την ίδια κατάταξη όταν πρόκειται για μηνιαίες προβλέψεις στις οποίες παρατηρούμε μια συνολική αύξηση στις μετρικές RMSE λόγω της αβεβαιότητας αλλά και μια μείωση του μέσου σφάλματος στο υβριδικό μοντέλο και το CNN δείχνοντας καλύτερη ευθυγράμμιση στο μηνιαίο χρονικό ορίζοντα. Το LSTM είναι πρώτο αλλά το RNN βρίσκεται πολύ κοντά στην απόδοση ενώ το TFT βρίσκεται πλέον πιο κοντά στην απόδοση του CNN παρά στου RNN όπως στους προηγούμενους 2



Εικόνα 4.38 : Γραφικές παραστάσεις καλύτερων μηνιαίων προβλέψεων στο σύνολο δεδομένων του πηγαίου κτιρίου


ορίζοντες. Αυτό οφείλεται πιθανότατα στην περιπλοκότητα του μοντέλου TFT και στην αδυναμία που παρουσιάζει στο παρόν σύνολο δεδομένων ο μηχανισμός προσοχής στο να εξάγει ουσιώδεις αναπαραστάσεις από την έξοδο των επιπέδων LSTM που διαθέτει. Επίσης η επιλογή μεταβλητών μπορεί να μην αποτυπώνει καλά τη σχέση τους με τη μεταβλητή στόχου ώστε να γίνει σωστή εστίαση στις προβλέψεις. Στην Εικόνα 4.38 παρατηρούνται οι οπτικοποιήσεις των προβλέψεων και ξανά φαίνεται ότι αρκετές μέγιστες τιμές δεν ανιχνεύονται ακριβώς ενώ το TFT παρουσιάζει κάποιες έντονες αποκλίσεις στις ακραίες τιμές το οποίο σε ορισμένες περιπτώσεις τις αποτυπώνει καλύτερα από τα άλλα μοντέλα ενώ σε άλλες αποτελεί χειρότερη πρόβλεψη. Τέλος αξίζει να αναφερθεί πως η ιδιότροπη ενεργειακή συμπεριφορά της 16^{ης} μέρας αποτυπώνεται καλύτερα από το μοντέλο RNN λόγω της ικανότητας του να κρατάει στη μνήμη του σχετικά βραχυπρόθεσμες χρονικές εξαρτήσεις με αποτέλεσμα να μην μπερδεύεται όσο τα άλλα μοντέλα παρατηρώντας το συνολικό μοτίβο κατανάλωσης των προηγούμενων 15 ημερών.

Πρώτο στοχευμένο σύνολο δεδομένων (Διάρκειας 12 μηνών)


Μετρικές καλύτερων ημερήσιων προβλέψεων

Μοντέλο	RMSE	MAE	MAPE	R^2 score
TFT-TL3	5.888	5.009	0.053	79.67
CNN-LSTM-Hybrid-TL1	6.392	5.286	0.052	76.03
CNN-TL2	6.452	5.367	0.054	75.58

LSTM-TL1	6.818	5.675	0.057	72.73
RNN-TL3	7.482	5.666	0.055	67.16



Εικόνα 4.39 : Κατανομές σφαλμάτων ημερησίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)



Εικόνα 4.40 : Γραφική παράσταση ημερησίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)


Όσον αφορά τα μοντέλα με τη καλύτερη απόδοση στο πρώτο στοχευμένο κτίριο, το πηγαίο μοντέλο TFT με χρήση της τρίτης μεθόδου μεταφοράς μάθησης προσφέρει τη καλύτερη απόδοση με το σκορ R^2 να φτάνει στο 80% που αποτελεί παρόμοια απόδοση με του πηγαίου τομέα έχοντας διαθέσιμα τα μισά δεδομένα. Στη συνέχεια τα επόμενα καλύτερα μοντέλα έχοντας αρκετά παρόμοια απόδοση είναι το πηγαίο υβριδικό μοντέλο και το πηγαίο CNN μέσω της πρώτης και της δεύτερης μεθόδου αντίστοιχα προσφέροντας σκορ R^2 περίπου 4% μικρότερο αλλά αυξάνοντας τιμή της μέτρησης RMSE και MAE κατά 10%

και 5% αντίστοιχα δείχνοντας σημαντική βελτίωση σε σχέση ακόμα και με το πηγαίο τομέα, πράγμα που σημαίνει πως τα επίπεδα CNN όντας συστατικό και των δύο μοντέλων μπορεί να ανιχνεύσει καλύτερα τοπικά μοτίβα από αυτό το σύνολο δεδομένων σε σχέση με το πηγαίο. Τα μοντέλα LSTM και RNN πετυχαίνουν την καλύτερη απόδοση στο τομέα μέσω της πρώτης και τρίτης προσέγγισης μεταφοράς μάθησης από το πηγαίο τομέα αλλά είναι χειρότερα από τα προηγούμενα τρία.


Στην Εικόνα 4.39 παρουσιάζεται αρχικά η έντονη διαφορά στο μέσο σφάλμα που προσφέρει η μεταφορά μάθησης ακόμα και στο μοντέλο με τη χειρότερη απόδοση δείχνοντας την σημασία της σε περιπτώσεις έλλειψης δεδομένων. Επίσης φαίνεται και η συνολικότερη μείωση που προσφέρει το μοντέλο TFT ακόμα και με βασική εκπαίδευση μόνο. Τέλος η οπτικοποίηση των αποτελεσμάτων δείχνει μια υπερτίμηση των χαμηλών τιμών κατανάλωσης από το μοντέλο TFT σε σχέση με τα άλλα μοντέλα στο πρώτο μισό της μέρας ενώ απεικονίζει καλύτερα τις μέγιστες τιμές στο τέλος της μέρας.

Μετρικές καλύτερων εβδομαδιαίων προβλέψεων

Μοντέλο	RMSE	MAE	MAPE	R^2 score
TFT-TL4	5.564	4.373	0.045	75.78
LSTM-TL1	5.794	4.561	0.047	73.72
CNN-LSTM-Hybrid-TL1	5.901	4.751	0.049	72.75
CNN-TL2	6.242	4.836	0.051	69.51
RNN-TL3	7.186	5.581	0.056	59.59



Εικόνα 4.41 : Κατανομές σφαλμάτων εβδομαδιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)




Εικόνα 4.42 : Γραφική παράσταση εβδομαδιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)

Για τις εβδομαδιαίες προβλέψεις υφίσταται η ίδια κατάταξη με εξαίρεση το μοντέλο LSTM, το οποίο σημειώνει αρκετά καλύτερη απόδοση σε σχέση με τον ημερήσιο ορίζοντα πρόβλεψης και ανέρχεται από τη τέταρτη θέση στη δεύτερη. Για τις εβδομαδιαίες προβλέψεις υφίσταται η ίδια κατάταξη με εξαίρεση το μοντέλο LSTM, το οποίο σημειώνει αρκετά καλύτερη απόδοση σε σχέση με τον ημερήσιο ορίζοντα πρόβλεψης και ανέρχεται από τη τέταρτη θέση στη δεύτερη. Ταυτόχρονα η καλύτερη απόδοση παρέχεται από το μοντέλο TFT αλλά μέσω επανεκπαίδευσης του μηχανισμού προσοχής και του στατικού εμπλουτισμού σε αντίθεση με τα επίπεδα LSTM στις ημερήσιες προβλέψεις. Παρατηρείται συνολική μείωση στις τιμές RMSE και MAE σε σχέση με τις ημερήσιες προβλέψεις λόγω αύξησης του πλήθους συγκρίσιμων τιμών αλλά και ελάχιστη μείωση στο σκορ R^2 το οποίο μπορεί να αιτιολογηθεί λόγω του αυξημένου ορίζοντα αλλά και της μεγαλύτερης διακύμανσης που προσφέρει το στοχευμένο σύνολο σε σχέση με το πηγαίο.


Οι κατανομές σφαλμάτων στην εικόνα 4.41 δείχνουν ξανά την έντονη διαφορά απόδοσης σε σχέση με το καλύτερο βασικό μοντέλο και την υπεροχή του μοντέλου TFT. Στην εικόνα 4.42 φαίνεται η μεγαλύτερη διακύμανση του συνόλου και η ευθυγράμμιση των μοντέλων με την γενική περιοδική τάση της πραγματικής κατανάλωσης. Ωστόσο παραμένουν ολικές μέγιστες τιμές ανά περίοδο που περιγράφονται καλύτερα από το TFT και ορισμένες τοπικές ελάχιστες τιμές που περιγράφονται από το LSTM και το υβριδικό μοντέλο.

Μετρικές καλύτερων μηνιαίων προβλέψεων

Μοντέλο	RMSE	MAE	MAPE	R^2 score
TFT-TL3	5.545	4.134	0.045	75.61
CNN-LSTM-Hybrid-TL1	5.896	4.713	0.051	72.42
LSTM-TL1	5.945	4.708	0.052	71.96
CNN-TL2	6.529	5.285	0.058	66.18
RNN-TL3	8.215	6.902	0.078	46.46



Εικόνα 4.43 : Κατανομές σφαλμάτων μηνιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)



Εικόνα 4.44 : Γραφική παράσταση μηνιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 12 μηνών)

Στις μηνιαίες προβλέψεις το μοντέλο TFT εξακολουθεί να είναι το πιο αποδοτικό αλλά μέσω της τρίτης προσέγγισης μεταφοράς μάθησης προσφέροντας παρόμοια αποτελέσματα με τις εβδομαδιαίες προβλέψεις ενώ το υβριδικό προσφέρει ελάχιστα πιο ακριβείς προβλέψεις από το LSTM, τα οποία


αποδίδουν ελάχιστα χειρότερα σε σχέση με τον αμέσως μικρότερο ορίζοντα. Το μοντέλο CNN και RNN δεν βελτιώνονται ωστόσο και συνεχίζουν να προσφέρουν συγκριτικά τη χειρότερη απόδοση.

Οι κατανομές σφαλμάτων της Εικόνας 4.43 επιβεβαιώνουν την προαναφερθείσα κατάταξη παρουσιάζοντας ξανά την μεγάλη βελτίωση που προσφέρει η μεταφορά μάθησης. Οι οπτικοποιήσεις της Εικόνας 4.44 δείχνουν την καλύτερη απεικόνιση ακραίων τιμών από το μοντέλο TFT αλλά και αρκετές υποεκτιμήσεις και υπερεκτιμήσεις των ελάχιστων και μέγιστων τιμών κατανάλωσης αντίστοιχα από το υβριδικό μοντέλο. Το LSTM δεν επίσης σημειώνει παρόμοια συμπεριφορά αλλά ανάστροφη υπερεκτιμώντας τις ελάχιστες τιμές και υποεκτιμώντας τις μέγιστες ενώ όλα φαίνεται να ανιχνεύουν την γενικότερη περιοδική διακύμανση του συνόλου.

Πρώτο στοχευμένο σύνολο δεδομένων (Διάρκειας 6 μηνών)

Μετρικές καλύτερων ημερησίων προβλέψεων

Μοντέλο	RMSE	MAE	MAPE	R^2 score
TFT-TL3	4.253	3.313	0.035	78.15
LSTM-TL2	4.526	3.467	0.037	75.25
CNN-LSTM-Hybrid-TL2	4.742	3.721	0.038	72.83
RNN-base	4.908	3.931	0.041	70.91
CNN-base	5.666	3.991	0.043	61.21




Εικόνα 4.45 : Κατανομές σφαλμάτων ημερησίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)

Μειώνοντας περαιτέρω το σύνολο των δεδομένων οδηγεί σε ορισμένα διαφορετικά αποτελέσματα σε σχέση με πριν όμως για τις ημερήσιες προβλέψεις το πηγαίο TFT εφαρμόζοντας ξανά τη τρίτη μέθοδο αποδίδει καλύτερα από όλα τα υπόλοιπα σημειώνοντας σκορ R^2 περίπου ίσο με 80% αναδεικνύοντας την σημασία της επανεκπαίδευσης των επιπέδων LSTM που περιέχονται στην αρχιτεκτονική του. Εκ των υπόλοιπων μοντέλων, το LSTM βρίσκεται δεύτερο και το υβριδικό τρίτο αξιοποιώντας την δεύτερη προσέγγιση ενώ οι πιο απλές αρχιτεκτονικές των μοντέλων CNN και RNN δεν επωφεληθήκαν από τη μεταφορά μάθησης και βρίσκονται στη τέταρτη και πέμπτη θέση αντίστοιχα. Κάθε μοντέλο διαφέρει περίπου το ίδιο από το προηγούμενο και το επόμενο όσον αφορά την απόδοση ενώ η μεγαλύτερη διαφορά βρίσκεται ανάμεσα στα δύο τελευταία.


Οι κατανομές των σφαλμάτων της Εικόνας 4.45 παρουσιάζουν τη μεγαλύτερη δυσκολία μεταφοράς γνώσης σε στοχευμένο τομέα με τέτοια έλλειψη δεδομένων εφόσον μόνο το TFT, το LSTM και το υβριδικό προσφέρουν καλύτερη απόδοση μέσω μεταφοράς μάθησης από το καλύτερο βασικό μοντέλο του τομέα με το TFT να παρουσιάζει τη μεγαλύτερη σταθερότητα και συνέπεια στις προβλέψεις του. Ταυτόχρονα η οπτικοποίηση των αποτελεσμάτων στην Εικόνα 4.46 δείχνει την ευθυγράμμιση των προβλέψεων με το μοτίβο κατανάλωσης αλλά υπάρχει αισθητή υποεκτίμηση των υψηλών τιμών της, ιδιαίτερα από το υβριδικό μοντέλο.

Μετρικές καλύτερων εβδομαδιαίων προβλέψεων

Μοντέλο	RMSE	MAE	MAPE	R^2 score
TFT-TL3	5.096	3.954	0.042	68.12
LSTM-TL2	5.381	4.136	0.043	64.47
CNN-LSTM-Hybrid-TL2	5.807	4.599	0.048	58.61
RNN-base	6.081	4.911	0.052	54.62
CNN-base	6.239	4.794	0.051	52.21



Εικόνα 4.47 : Κατανομές σφαλμάτων εβδομαδιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)



Εικόνα 4.48 : Γραφικές παραστάσεις εβδομαδιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)

Στις προβλέψεις επόμενης εβδομάδας, η κατάταξη των μοντέλων παραμένει ίδια με το TFT να εξακολουθεί να υπερέχει των άλλων μοντέλων με αισθητά


χαμηλότερο μέσο σφάλμα και υψηλότερο σκορ R^2 ενώ όλες οι αποδόσεις χειροτερεύουν περίπου κατά 15% πιθανότατα λόγω της αύξησης του χρονικού ορίζοντα διατηρώντας τα ελάχιστα δεδομένα εκπαίδευσης ίδια.

Στην Εικόνα 4.47 φαίνονται οι κατανομές σφαλμάτων οι οποίες επιβεβαιώνουν την υπάρχουσα κατάταξη με το TFT και το LSTM να προσφέρουν τα χαμηλότερα μέσα σφάλματα προσφέροντας πιο σταθερή και αξιόπιστη απόδοση σε σχέση με τα άλλα ενώ τα CNN και RNN εξακολουθούν να μην βελτιώνουν την καλύτερη βασική πρόβλεψη. Οι οπτικοποιήσεις της Εικόνας 4.48 επίσης επαληθεύουν την απόδοση του TFT παρουσιάζοντας έντονη ευθυγράμμιση καθώς ακολουθεί την πραγματική τάση κατανάλωσης έχοντας βέβαια κάποιες αποκλίσεις κυρίως στις έντονες διακυμάνσεις στις υψηλές τιμές κάθε περιόδου. Το LSTM είναι παρόμοιο με το TFT αλλά δεν ανιχνεύει τόσο καλά τις μέγιστες τιμές ενώ το υβριδικό μοντέλο αποκλίνει περισσότερο με περεταίρω εξομάλυνση.


Μετρικές καλύτερων μηνιαίων προβλέψεων

Μοντέλο	RMSE	MAE	MAPE	R^2 score
TFT-TL3	4.878	3.864	0.041	69.31
CNN-TL3	6.045	4.696	0.051	52.88
LSTM-TL2	6.143	4.634	0.048	51.34
CNN-LSTM-Hybrid-TL1	6.576	5.361	0.056	44.23
RNN-base	7.107	5.832	0.064	34.87

Στις μηνιαίες προβλέψεις αυτού του συνόλου υπήρχαν ορισμένες διαφορές στην απόδοση των μοντέλων. Αρχικά εκτός της διατηρούμενης υπεροχής του μοντέλου TFT, η απόδοση του αυξήθηκε κατά 2-3% σε όλες τις μετρικές σε αντίθεση με τις εβδομαδιαίες προβλέψεις, πράγμα που αναδεικνύει τις δυνατότητες μοντελοποίησης μακροπρόθεσμων εξαρτήσεων. Ταυτόχρονα το LSTM διατηρώντας την ίδια τεχνική μεταφοράς μάθησης σημειώνει αύξηση 11% στις μετρικές RMSE και MAE λαμβάνοντας τη τρίτη θέση και αποδίδοντας χειρότερα από το CNN, το οποίο εφαρμόζοντας εκ νέου εκπαίδευση των συνελκτικών επιπέδων του αυξάνει την απόδοση του κατά περίπου 4% σε σχέση



Εικόνα 4.49 : Κατανομές σφαλμάτων μηνιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)



Εικόνα 4.50 : Γραφικές παραστάσεις μηνιαίων προβλέψεων των καλύτερων μοντέλων στο πρώτο στοχευμένο κτίριο (διάρκειας 6 μηνών)

με τις εβδομαδιαίες προβλέψεις σημειώνοντας έτσι τη δεύτερη καλύτερη απόδοση. Το υβριδικό μοντέλο και το μοντέλο RNN παρουσιάζουν επίσης χειρότερα αποτελέσματα και καταλαμβάνουν τη τέταρτη και πέμπτη θέση αντίστοιχα.


Η Εικόνα 4.49 περιλαμβάνει τις κατανομές των σφαλμάτων που δείχνουν τη ξεκάθαρη μείωση που προσφέρει το πηγαιό μοντέλο TFT μέσω της τρίτης τεχνικής μεταφοράς μάθησης. Οι οπτικοποιήσεις της Εικόνας 4.50 δείχνουν ισχυρή υπερεκτίμηση των πραγματικών τιμών από το μοντέλο CNN ενώ το

LSTM φαίνεται να υποεκτιμά αρκετά τις μέγιστες τιμές κατανάλωσης καθιστώντας την απόδοση του TFT με διαφορά τη πιο συνεπή και αξιόπιστη.


Δεύτερο στοχευμένο σύνολο δεδομένων

Μετρικές καλύτερων ημερησίων προβλέψεων

Μοντέλο	RMSE	MAE	MAPE	R^2 score
TFT-TL3	4.246	3.571	0.059	49.74
LSTM-TL3	5.444	4.566	0.076	17.36
CNN-base	5.496	4.412	0.071	15.77
CNN-LSTM-Hybrid-TL2	5.787	4.738	0.076	6.62
RNN-TL3	6.312	4.862	0.078	-11.08



Εικόνα 4.51 : Κατανομές σφαλμάτων ημερησίων προβλέψεων των καλύτερων μοντέλων στο δεύτερο στοχευμένο κτίριο




Εικόνα 4.52 : Γραφικές παραστάσεις ημερησίων προβλέψεων των καλύτερων μοντέλων στο δεύτερο στοχευμένο κτίριο

Το δεύτερο στοχευμένο κτίριο παρουσιάζει αυξημένη διακύμανση σε σχέση με τα υπόλοιπα με αποτέλεσμα να αποτελεί δυσκολότερο σενάριο μεταφοράς γνώσης. Από τα αποτελέσματα των μετρικών, όπως και πριν το πηγαίο μοντέλο TFT επωφελομένο από τη τρίτη μέθοδο μεταφοράς γνώσης καταφέρνει και προσφέρει την καλύτερη απόδοση η οποία δεν είναι ιδιαίτερα καλή αλλά δεδομένων των συγκριτικών αποδόσεων των υπόλοιπων μοντέλων είναι αισθητά καλύτερη προσφέροντας σκορ R^2 περίπου 50%. Το LSTM μέσω εκ νέου εκπαίδευσης των επιπέδων του προσφέρει την αμέσως καλύτερη απόδοση παρουσιάζοντας αύξηση του μέσου σφάλματος κατά 20% και μείωση του σκορ R^2 κατά 75% κάτι που σημαίνει πως μοντελοποιεί την διακύμανση αισθητά χειρότερα από το TFT. Ταυτόχρονα σημειώνει σχεδόν ίδια αποτελέσματα με το βασικό μοντέλο CNN το οποίο βρίσκεται στην τρίτη θέση και προσφέρει ελάχιστα χειρότερη τιμή RMSE και 5% καλύτερη τιμή MAE. Το υβριδικό μοντέλο μέσω της τρίτης μεθόδου και το βασικό RNN βρίσκονται στις τελευταίες θέσεις παρουσιάζοντας ιδιαίτερα κακή απόδοση.

Οι κατανομές σφαλμάτων της Εικόνας 4.51 δείχνουν την ιδιαίτερη μείωση των σφαλμάτων μέσω του TFT κυρίως μόνο μέσω μεταφοράς μάθησης σχετικά με το καλύτερο βασικό μοντέλο. Στην Εικόνα 4.52 παρατηρούμε τις γραφικές παραστάσεις των προβλέψεων αυτών των μοντέλων και είναι εμφανές πως το βασικό μοντέλο CNN και το LSTM με χρήση της τρίτης μεθόδου παρουσιάζουν μια καθυστέρηση στις προβλέψεις τους σχετικά με τις πραγματικές τιμές η οποία οδηγεί σε σημαντικές αποκλίσεις. Το TFT από την άλλη καταφέρνει να ακολουθήσει πιο πιστά τις πραγματικές τιμές κατανάλωσης αλλά και αυτό παρουσιάζει ιδιαίτερη εξομάλυνση αγνοώντας εν μέρη την έντονη διακύμανση του συνόλου.

Μετρικές καλύτερων εβδομαδιαίων προβλέψεων

Μοντέλο	RMSE	MAE	MAPE	R^2 score
TFT-TL3	4.697	3.771	0.062	57.97
LSTM-TL3	5.999	4.948	0.081	31.44
CNN-LSTM-Hybrid-TL2	6.154	4.998	0.08	27.85
RNN-base	6.318	5.244	0.085	23.96
CNN-base	6.661	5.418	0.086	15.48



Εικόνα 4.53 : Κατανομές σφαλμάτων εβδομαδιαίων προβλέψεων των καλύτερων μοντέλων στο δεύτερο στοχευμένο κτίριο



Εικόνα 4.54 : Γραφικές παραστάσεις εβδομαδιαίων προβλέψεων των καλύτερων μοντέλων στο δεύτερο στοχευμένο κτίριο


Στις εβδομαδιαίες προβλέψεις παρατηρείται συνολική αύξηση στις τιμές των μετρικών RMSE, MAE και MAPE αλλά και αύξηση του σκορ R^2 , πράγμα που δικαιολογείται εν μέρει λόγω των αυξημένων δειγμάτων στα οποία γίνεται η σύγκριση για να παραχθούν τα αποτελέσματα των μετρικών. Ταυτόχρονα το υβριδικό μοντέλο μέσω της δεύτερης προσέγγισης μεταφοράς μάθησης καταφέρνει να προσφέρει καλύτερα αποτελέσματα ενώ το βασικό μοντέλο RNN παρουσιάζει ελάχιστα πιο βελτιωμένα αποτελέσματα από το βασικό CNN το οποίο στις συγκεκριμένες προβλέψεις έχει τα χειρότερα αποτελέσματα.

Οι κατανομές σφαλμάτων στην Εικόνα 4.53 επαληθεύουν για άλλη μια φορά την αξιοπιστία και χρησιμότητα της μεταφοράς μάθησης σε προβλέψεις σε νέους τομείς που εκφράζουν ιδιαίτερη διακύμανση και θόρυβο ενώ το

μοντέλο TFT εξακολουθεί να έχει το μικρότερο εύρος σφαλμάτων αλλά και μέσο σφάλμα από όλα τα άλλα μοντέλα με διαφορά, ακόμα και μέσω βασικής εκπαίδευσης. Τέλος η Εικόνα 4.54 παρουσιάζει την επίδοση των καλύτερων μοντέλων αναδεικνύοντας τις ιδιαίτερες αποκλίσεις του μοντέλου LSTM και του υβριδικού μοντέλου τα οποία όπως και στις ημερήσιες παρουσιάζουν καθυστέρηση ενώ το TFT ευθυγραμμίζεται περισσότερο με τη συνολική διακύμανση του συνόλου. Ωστόσο καμία πρόβλεψη δεν αποτυπώνει επαρκώς τις ακραίες μέγιστες και ελάχιστες τιμές πραγματικής κατανάλωσης.


Μετρικές καλύτερων μηνιαίων προβλέψεων

Μοντέλο	RMSE	MAE	MAPE	R^2 score
TFT-TL3	4.966	4.029	0.077	67.32
CNN-LSTM-Hybrid-TL1	6.412	5.176	0.097	45.51
LSTM-base	6.611	5.45	0.104	42.08
RNN-base	6.696	5.451	0.104	40.58
CNN-TL2	7.812	6.313	0.124	19.12



Εικόνα 4.55 : Κατανομές σφαλμάτων μηνιαίων προβλέψεων των καλύτερων μοντέλων στο δεύτερο στοχευμένο κτίριο

Οι μηνιαίες προβλέψεις παρουσιάζουν ιδιαίτερες αλλαγές στα αποτελέσματα των μοντέλων. Αρχικά συνολικά οι τιμές των μετρικών RMSE, MAE και MAPE αυξάνονται ξανά κατά 4-5% ενώ ταυτόχρονα αυξάνεται και το σκορ R^2 κατά 15-35% για τους ίδιους λόγους με πριν ενώ το TFT εξακολουθεί να βρίσκεται στη πρώτη θέση σημειώνοντας την καλύτερη απόδοση. Το υβριδικό μοντέλο εκμεταλλευόμενο τη πρώτη μέθοδο μεταφοράς μάθησης πετυχαίνει καλύτερες προβλέψεις συγκριτικά με τα άλλα μοντέλα και καταλήγει στη



Εικόνα 4.56 : Γραφικές παραστάσεις μηνιαίων προβλέψεων των καλύτερων μοντέλων στο δεύτερο στοχευμένο κτίριο

δεύτερη θέση ενώ οι βασικές εκδόσεις των μοντέλων LSTM και το RNN βρίσκονται στην τρίτη και τέταρτη θέση της κατάταξης χωρίς να υποβοηθούνται ιδιαίτερα από κάποια μέθοδο μεταφοράς μάθησης. Το CNN προσφέροντας πλέον τη καλύτερη απόδοση μέσω της τρίτης μεθόδου βρίσκεται στην τελευταία θέση με ιδιαίτερα αυξημένο σφάλμα.

Οι κατανομές σφαλμάτων της Εικόνας 4.55 υποδεικνύουν τη συνολική βελτίωση που προσφέρουν οι τεχνικές μεταφοράς μάθησης όσον αφορά τη μείωση του εύρους των σφαλμάτων χωρίς βέβαια να απεικονίζει την συχνότητα τους, ενώ το TFT παρουσιάζει το μικρότερο εύρος και μέσω βασικής εκπαίδευσης αλλά και με μεταφορά μάθησης, το οποίο υποδεικνύει συνέπεια και αξιοπιστία . Ταυτόχρονα στην Εικόνα 4.56 οι οπτικοποιήσεις των μηνιαίων προβλέψεων και πραγματικών τιμών αρχικά παρουσιάζουν την πολύ έντονη διακύμανση του συνόλου. Επίσης το βασικό LSTM και το υβριδικό μοντέλο παρουσιάζουν αρκετή εξομάλυνση αγνοώντας πολλές τοπικές και ολικές μέγιστες και ελάχιστες τιμές, ενώ το TFT παρουσιάζει μεγαλύτερη διακύμανση προσπαθώντας να ευθυγραμμιστεί με τις πραγματικές τιμές κατανάλωσης. Συνολικά παρατηρείται πως δεν υπάρχει σταθερή περίοδος και η τάση είναι αρκετά απρόβλεπτη και για αυτό τα μοντέλα δεν μπορούν να ανιχνεύσουν κάποιο επαναλαμβανόμενο μοτίβο.

Κεφάλαιο 5

Επίλογος

Ο γενικότερος σκοπός αυτής της διπλωματικής εργασίας ήταν να αξιολογηθούν διάφορα μοντέλα βαθιάς μάθησης, από απλά έως και πολύ σύνθετα, για την πρόβλεψη ενεργειακού φορτίου κτιρίου υπό την ύπαρξη έλλειψης δεδομένων. Η έρευνα πραγματοποιήθηκε μέσω του συνόλου δεδομένων Genome-2 το οποίο περιλαμβάνει δεδομένα από κτίρια με διαφορετικές καταναλωτικές συμπεριφορές και επίπεδα θορύβου. Ο κύριος στόχος ήταν η διερεύνηση του επιπέδου βελτίωσης της απόδοσης απλών αρχιτεκτονικών βαθιάς μάθησης στη πρόβλεψη ενεργειακής κατανάλωσης κτιρίων με διαβαθμισμένη έλλειψη δεδομένων και επίπεδα θορύβου, μέσω εφαρμογής μεθόδων μεταφοράς μάθησης και του μοντέλου μετασχηματιστή χρονικής συγχώνευσης. Η έρευνα εξέτασε τα πλεονεκτήματα και τους περιορισμούς του κάθε μοντέλου όπως και το χρονικό ορίζοντα πρόβλεψης που αποδίδουν καλύτερα. Η λεπτομερής αξιολόγηση της απόδοσης τους παρουσιάστηκε μέσω μετρικών όπως η RMSE, MAE, MAPE και το σκορ R^2 , οι οποίες μας επιτρέπουν να κατανοήσουμε την αξία που προσφέρουν στον ενεργειακό τομέα και τη συνολικότερη διαχείριση του.

Συμπεράσματα

Το μοντέλο στοιβαγμένων RNN λόγω της επαναληπτικής φύσης του είχε τη δυνατότητα να αντιληφθεί βραχυπρόθεσμες χρονικές εξαρτήσεις αλλά μπορεί να υπερπροσαρμοστεί εύκολα. Στο πηγαίο κτίριο η απόδοση του ήταν ικανοποιητική σε όλους τους χρονικούς ορίζοντες αλλά στην μετάβαση του στο πρώτο στοχευμένο κτίριο μειώνοντας τα δεδομένα εκπαίδευσης κατά το ήμισυ η απόδοση του πέφτει πολύ και η μεταφορά μάθησης προσφέρει σημαντική βελτίωση κατά 20-25%. Ωστόσο η κακή απόδοση του δεν οφείλεται τόσο στην έλλειψη δεδομένων αποκλειστικά αλλά και στην αυξημένη διακύμανση του

τομέα καθώς μειώνοντας κατά 75% το σύνολο εκπαίδευσης του επιτρέπει να εστιάσει σε λιγότερα δείγματα και να προσφέρει καλύτερες ημερήσιες και εβδομαδιαίες προβλέψεις χωρίς όμως να βελτιώνεται η απόδοση του μέσω της μεταφοράς μάθησης. Το σύνολο του δεύτερου στοχευμένου κτιρίου διαφέρει αρκετά από το πηγαίο παρουσιάζοντας την πιο έντονη διακύμανση με αποτέλεσμα να μην αποδίδει καλά χωρίς να βελτιώνεται η πρόβλεψη με χρήση γνώσης από το πηγαίο.

Το μοντέλο στοιβαγμένων LSTM αποτελεί εξέλιξη του RNN που αντιμετωπίζει τα γνωστά προβλήματα του μέσω της κρυφής μνήμης. Στο πηγαίο τομέα η απόδοση του είναι εξαιρετική ενώ παρόλο που μειώνεται στο πρώτο στοχευμένο σύνολο η απόδοση του θεωρείται σχετικά καλή δεδομένου του μικρότερου όγκου δεδομένων ενώ σημειώνει μια μικρή βελτίωση μέσω μεταφοράς μάθησης. Μειώνοντας περεταίρω το σύνολο δεδομένων οδηγεί σε πτώση 20-25% της απόδοσης του ενώ η μεταφορά πηγαίας γνώσης σημειώνει αισθητά μεγαλύτερη βελτίωση. Το δεύτερο στοχευμένο κτίριο λόγω της ιδιαίτερης ενεργειακής συμπεριφοράς του αποτελεί πρόκληση για το μοντέλο το οποίο εμφανίζει περεταίρω πτώση 30% της απόδοσης του με σχετικά καλή βελτίωση μέσω μεταφοράς μάθησης.

Το μοντέλο στοιβαγμένων CNN αποτελεί μια αρχιτεκτονική που είναι ικανή να εντοπίζει τις βραχυπρόθεσμες χρονικές εξαρτήσεις ενώ είναι ιδιαίτερα γρήγορο στην εκπαίδευση του. Στο πηγαίο τομέα ωστόσο δεν αποδίδει όσο καλά απέδωσαν τα ακολουθιακά μοντέλα αλλά οι προβλέψεις θεωρούνται σχετικά καλές. Μειώνοντας τα δεδομένα κατά 50% στο πρώτο στοχευμένο σύνολο δεδομένων προκαλεί πτώση 25-30% στην απόδοση του, η οποία βελτιώνεται μέσω μεταφοράς μάθησης σε σημείο που να σημειώνει παρόμοια αποτελέσματα με το πηγαίο. Η επιπλέον μείωση των δεδομένων ωστόσο προσφέρει καλύτερα αποτελέσματα στις βραχυπρόθεσμες σε αντίθεση με τις μακροπρόθεσμες προβλέψεις ενώ η μεταφορά πηγαίας γνώσης βελτιώνει ελάχιστα μόνο τις τελευταίες κυρίως λόγω των ξεκάθαρων μοτίβων που είναι διαθέσιμα στα λίγα δεδομένα τα οποία δεν αλλοιώνονται από περεταίρω θόρυβο όπως στο προηγούμενο σενάριο έλλειψης δεδομένων. Τέλος το δεύτερο στοχευμένο σύνολο δεδομένων αποτελεί εξαιρετικά μεγάλη πρόκληση για το μοντέλο καθώς δεν μπορεί να αντιληφθεί το μοτίβο και παρουσιάζει καθυστέρηση στις προβλέψεις του σχετικά με τις πραγματικές τιμές ενώ η

μεταφορά μάθησης βελτιώνει ελάχιστα τις μακροπρόθεσμες προβλέψεις.

Το υβριδικό μοντέλο επιχειρεί τον συνδυασμό των χαρακτηριστικών των δικτύων LSTM και CNN προσπαθώντας να απεικονίζει και βραχυπρόθεσμες και μακροπρόθεσμες προβλέψεις. Ωστόσο η απόδοση του στο πηγαίο κτίριο είναι περισσότερο παρόμοια με αυτή του μοντέλου στοιβαγμένων CNN παρά με τα LSTM, πράγμα το οποίο σημαίνει πως η εξαγωγή χαρακτηριστικών πρώτα από τα CNN να μην επέτρεψε στα επίπεδα LSTM να αποδώσουν το καλύτερο δυνατό αποτέλεσμα. Στο πρώτο στοχευμένο κτίριο χρησιμοποιώντας τα μισά δεδομένα, η απόδοση μειώνεται ελάχιστα ενώ οι τεχνικές μεταφοράς μάθησης βελτιώνουν τα αποτελέσματα προσφέροντας απόδοση συγκρίσιμη με το πηγαίο και σε κάποιες περιπτώσεις και καλύτερη. Μειώνοντας περαιτέρω τα διαθέσιμα δεδομένα αποδεικνύεται εξαιρετικά δύσκολη η μοντελοποίηση τους από το μοντέλο, το οποίο σημειώνει ιδιαίτερα μεγάλη αύξηση στην απόδοση του κατά 35-45% μέσω μεταφοράς πηγαίας γνώσης. Το δεύτερο στοχευμένο κτίριο παρουσιάζει ακόμη μεγαλύτερη πρόκληση ενώ η μεταφορά μάθησης προσφέρει βελτίωση αλλά μικρότερη συγκριτικά με πριν.

Το μοντέλο μετασχηματιστή συγχώνευσης χρόνου επιδιώκει να συνδυάσει επιλογή σχετικών μεταβλητών εισόδου και εξαγωγή βραχυπρόθεσμων και μακροπρόθεσμων χρονικών εξαρτήσεων από αυτά με ανάμειξη επιπέδων LSTM και ενός μηχανισμού προσοχής. Στο πηγαίο κτίριο οι αποδόσεις του είναι ιδιαίτερα καλές κατατάσσοντας το παρόμοια με τα ακολουθιακά μοντέλα. Όταν βρίσκεται αντιμέτωπο με τα μισά δεδομένα εκπαίδευσης στο πρώτο στοχευμένο κτίριο οι αποδόσεις του πέφτουν αλλά με εφαρμογή τεχνικών μεταφοράς μάθησης καταφέρνει να αποδώσει περίπου όπως και στον πηγαίο τομέα. Μειώνοντας περαιτέρω τα δεδομένα προκαλεί επιπλέον πτώση στην απόδοση αλλά σημειώνει ξανά σημαντική βελτίωση 25-35% σε αυτήν μεταφέροντας πηγαία γνώση. Στο δεύτερο στοχευμένο κτίριο η βασική απόδοση είναι επίσης χαμηλότερη ωστόσο το πλεονέκτημα που έχει αξιοποιήσει ως τώρα χρησιμοποιώντας πηγαία πληροφορία δεν μειώνεται σημειώνοντας ανταγωνιστικά αποτελέσματα.

Συνολικά στο πηγαίο τομέα το μοντέλο με τη καλύτερη απόδοση αποδεικνύεται το μοντέλο στοιβαγμένων LSTM ενώ το μοντέλο στοιβαγμένων RNN και το TFT είναι δεύτερο και τρίτο, το οποίο είναι λογικό καθώς το RNN υστερεί όσον αφορά τις μακροχρόνιες εξαρτήσεις σε σχέση με το LSTM και το

TFT είναι αρκετά σύνθετο μοντέλο για τον μικρό όγκο των δεδομένων ενώ είναι πιθανό και ο μηχανισμός προσοχής να μην μπόρεσε να αξιοποιηθεί σωστά σε αυτό το σύνολο. Όμως στο πρώτο στοχευμένο σύνολο δεδομένων διατηρώντας τα μισά δεδομένα το TFT και το υβριδικό μοντέλο προσφέρουν μέσω μεταφοράς μάθησης τις καλύτερες προβλέψεις σε όλους τους χρονικούς ορίζοντες. Μειώνοντας ξανά τα δεδομένα κατά το ήμισυ η καλύτερη απόδοση προσφέρεται από το TFT ακολουθούμενο από το LSTM ενώ για το δεύτερο στοχευμένο κτίριο ισχύει ξανά παρόμοια κατάταξη. Επομένως αποδεικνύεται ότι η χρήση πιο σύνθετων αρχιτεκτονικών σε συνδυασμό με μεθόδους μεταφοράς μάθησης έχει τη δυνατότητα να αντιμετωπίζει αποδοτικά το πρόβλημα έλλειψης δεδομένων.

Μελλοντικά βήματα

Ο ενεργειακός τομέας αντιμετωπίζει συνεχώς προκλήσεις που σχετίζονται με τις διακυμάνσεις της ζήτησης και προσφοράς αλλά και τη βιωσιμότητα και βελτιστοποίηση του δικτύου ενώ ανεπτυγμένα μοντέλα όπως αυτά που αξιολογήθηκαν σε αυτή τη διπλωματική εργασία μπορούν να έχουν καθοριστικό ρόλο στο σχεδιασμό σωστών και αξιόπιστων διαχειριστικών στρατηγικών. Αυτή η έρευνα αναδεικνύει τις δυνατότητες προσαρμογής προεκπαιδευμένων μοντέλων για αξιόπιστες προβλέψεις ενεργειακής κατανάλωσης σε κτίρια που δεν διαθέτουν αρκετά δεδομένα ώστε να έχει νόημα η εκ νέου εκπαίδευση κάποιου μοντέλου για καλύτερη απόδοση. Ωστόσο υπάρχουν αρκετά σημεία κατά τη διάρκεια της διεξαγωγής αυτών των πειραμάτων τα οποία μπορούν να βελτιωθούν.

Αρχικά το σύνολο δεδομένων που χρησιμοποιήσαμε διαθέτει ένα μεγάλο αριθμό από κτίρια, τα οποία θα μπορούσαν με ορισμένη επεξεργασία να διαμορφώσουν ένα μεγάλο σύνολο δεδομένων προς εκπαίδευση και να αξιοποιηθεί μια συνολική γνώση διατηρώντας τις ιδιαιτερότητες του κάθε κτιρίου. Το μοντέλο TFT έχει τη δυνατότητα να ταξινομεί τις χρονοσειρές εισόδου με βάση επιλεγμένες κατηγορικές μεταβλητές, πράγμα που σημαίνει πως η απόδοση της προπαιδευμένης εκδοχής του θα μπορούσε να είναι αρκετά καλύτερη, μεταφέροντας εννοείται αυτή τη γνώση και στα κτίρια που δεν διαθέτουν αρκετά ενεργειακά δεδομένα. Ταυτόχρονα πιθανό θα ήταν να

συμπεριληφθούν και άλλες στατικές μεταβλητές για βελτιωμένο εμπλουτισμό των αναπαραστάσεων εισόδου.

Στη συνέχεια η εύρεση των καλύτερων υπερπαραμέτρων του κάθε μοντέλου έγινε μέσω της βιβλιοθήκης «optuna» η οποία εκτός από επιλεγμένο χώρο αναζήτησης για τις υπερπαραμέτρους δέχεται και αριθμό δοκιμών, η αύξηση των οποίων μπορεί να οδηγήσει σε εύρεση καλύτερων συνδυασμών υπερπαραμέτρων αλλά έχει και αυξημένο υπολογιστικό κόστος. Αν ωστόσο υπήρχε διάθεση περισσότερων πόρων μια τέτοια αναζήτηση θα ήταν εφικτή με αποτέλεσμα την βελτίωση της απόδοσης κάθε μοντέλου.

Τέλος οι τεχνικές μεταφοράς μάθησης που επιλέχθηκαν για αυτή τη διπλωματική είναι ένα υποσύνολο αυτών που βασίζονται στις αρχιτεκτονικές των μοντέλων. Εφικτή είναι η εξέταση άλλων παρόμοιων μεθόδων της ίδιας κατηγορίας όπως η μάθηση συνόλου ενώ χρήσιμες θα μπορούσαν να αποδειχθούν και οι μέθοδοι που βασίζονται στα χαρακτηριστικά ή στα δείγματα εισόδου.

Βιβλιογραφία

- [1] Zhou, Ella and Trieu Mai, "Electrification Futures Study: Operational Analysis of U.S. Power Systems with Increased Electrification and Demand-Side Flexibility.," Golden,CO: National Renewable Energy Laboratory. NREL/TP-6A20-79094., [Online]. Available: <https://www.nrel.gov/docs/fy21osti/79094.pdf>.
- [2] IEA (2023), "Tracking Clean Energy Progress 2023," IEA, Paris, Licence: CC BY 4.0, [Online]. Available: <https://www.iea.org/reports/tracking-clean-energy-progress-2023>.
- [3] T. Hong, P. Pinson, Y. Wang, R. Weron, D. Yang and H. Zareipour, "Energy Forecasting: A Review and Outlook," *IEEE Open Access Journal of Power and Energy*, pp. 376-388, 09 October 2020.
- [4] Z. Liu, Z. Zhu, J. Gao and C. Xu, "Forecast Methods for Time Series Data: A Survey," *IEEE Access* vol 9, pp. 91896-91912, 01 June 2021.
- [5] Abdelhai A. Sallam and Om P. Malik, *Electric Distribution Systems*, Wiley-IEEE Press , 2011.
- [6] Dewangan, Fanidhar & Biswal and Monalisa, "A Comparative Analysis of Deep Learning Based Load Forecasting Techniques," in *3rd International conference on Power Electronics and IoT Applications in Renewable Energy and its Control (PARC)*, Bharthia, 2024.
- [7] K. Devinder, I. N. Shama , M. Apel, H. Enamul and Y. D. Zhao , "Energy forecasting in smart grid systems: recent advancements in probabilistic deep learning," *IET Generation, Transmission & Distribution*, vol. 16, no. 22, pp. 4461-4479, 2022.
- [8] G. Pinto, Z. Wang, A. Roy, T. Hong and A. Capozzoli, "Transfer learning for smart buildings: A critical review of algorithms, applications, and future perspectives," *Advances in Applied Energy*, vol. 5, 2022.
- [9] L. Rabelo, L. Rabelo, E. Gutierrez-Franco and N. Clavijo Buritica, "Machine Learning for Short-Term Load Forecasting in Smart Grids," *Energies*, no. 10.3390/en15218079, 2022.
- [10] F. Khosrojerdi, S. Gagnon and R. Valverde, "Applications of Artificial Intelligence in Smart Grids: Present and Future Research Domains," in *IEEE 9th International Conference on Smart Energy Grid Engineering (SEGE)*, Oshawa, Canada, 2021.
- [11] Dileep. G, "A survey on smart grid technologies and applications," *Renewable Energy*, vol. 146, pp. 2589-2625, 2020.
- [12] A. Malik and J. Ravishankar, "A review of demand response techniques in smart grids," in *2016 IEEE Electrical Power and Energy Conference (EPEC)*, Ottawa, ON, Canada, 2016.
- [13] S. M. Abu Adnan Abir, Adnan Anwar, Jinho Choi and A. S. M. Kayes, "IoT-Enabled Smart Energy Grid: Applications and Challenges," *IEEE Access*, vol. 9, pp. 50961-50981, 2021.
- [14] D. Ruilong , Y. Zaiyue , C. Mo-Yuen and C. Jiming, "A Survey on Demand Response in Smart Grids: Mathematical Models and Approaches," *IEEE Transactions on Industrial Informatics*, vol. 11, no. 3, pp. 570-582, 2015.
- [15] H. Jahangir, H. Tayarani, S. . S. Gougheri, M. A. Golkar, A. Ahmadian and A. Elkamel, "Deep Learning-Based Forecasting Approach in Smart Grids With Microclustering and Bidirectional LSTM Network," *IEEE Transactions on Industrial Electronics*, vol. 68, no. 9, pp. 8298-8309, 2020.
- [16] H. Kechang and L. Jingjiao, "Short-term Load Forecasting Considering Demand Response," in *Sustainable Power and Energy Conference (iSPEC)*, Nanjing, China , 2021.
- [17] J. S. Vardakas, N. Zorba and C. V. Verikoukis, "A Survey on Demand Response Programs in Smart Grids: Pricing Methods and Optimization Algorithms," *IEEE Communications Surveys & Tutorials*, vol. 17, no. 1, pp. 152-178, 2014.
- [18] T. Choi, R. K. L. Ko, T. Saha, J. Scarsbrook, A. M. Koay and S. Wang, "Plan2Defend: AI Planning for Cybersecurity in Smart Grids," in *2021 IEEE PES Innovative Smart Grid Technologies - Asia (ISGT Asia)*, Brisbane, Australia, 2022.
- [19] S. Akhtar, S. Shahzad, A. Zaheer, H. Ullah, H. Kilic, R. Gono, M. Jasiński and Z. Leonowicz, "Short-Term Load Forecasting Models: A Review of Challenges, Progress, and the Road Ahead.," *Energies*, vol. 16, p. 4060, 2023.
- [20] X. Wang, H. Wang, B. Bhandari and L. Cheng, "AI-Empowered Methods for Smart Energy Consumption: A Review of Load Forecasting, Anomaly Detection and Demand Response," *International Journal of Precision Engineering and Manufacturing-Green Technology*, vol. 11, pp. 1-31, 2023.

- [21] Zhongjun Ni, Chi Zhang, Magnus Karlsson and Shaofang Gong, "A study of deep learning-based multi-horizon building energy forecasting," *Energy and Buildings*, vol. 303, 2024.
- [22] N. Ahmad, Y. Ghadi, M. Adnan and M. Ali, "Load Forecasting Techniques for Power System: Research Challenges and Survey," *IEEE Access*, vol. 10, pp. 71054-71090, 2022.
- [23] A. Rani, A. Srinivasan, S. Shiney, B. Kalpana, Subramaniam, Sangar, Velusamy and S. Pandi, "Artificial Intelligence - Enabled Smart Grids: Enhancing Efficiency and Sustainability," in *7th International Conference on Electronics, Communication and Aerospace Technology (ICECA)*, Coimbatore, India., 2023.
- [24] J. Hu and A. V. Vasilakos, "Energy Big Data Analytics and Security: Challenges and Opportunities," *IEEE Transactions on Smart Grid*, vol. 7, no. 5, pp. 2423-2436, 2016.
- [25] K.B. Lindberg, P. Seljom , H. Madsen, D. Fischer and M. Korpås, "Long-term electricity load forecasting: Current and future trends," *Utilities Policy*, vol. 58, pp. 102-119, 2019.
- [26] J. Shyam Prasath, B. Natarajan , K. Venkatraman, M. Nallusamy, M. Revathi and T. Muruganantham, "A Novel Approach for Electricity Load Forecasting using Hybrid Deep Learning Models," in *2024 IEEE International Conference for Women in Innovation, Technology & Entrepreneurship (ICWITE)*, Bangalore, India, 2024.
- [27] 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, 2010.
- [28] R. Mauro , G. Katarina , E. Hany F. , H. Wilson A. and C. Miriam A.M. , "Transfer learning with seasonal and trend adjustment for cross-building energy forecasting," *Energy and Buildings*, vol. 165, pp. 352-363, 2018.
- [29] Giacomazzi, Elena & Haag, Felix & Hopf and Konstantin, "Short-Term Electricity Load Forecasting Using the Temporal Fusion Transformer: Effect of Grid Hierarchies and Data Sources.," in *e-Energy '23: The 14th ACM International Conference on Future Energy Systems*, Orlando, Florida, 2023.
- [30] J. Schreiber and B. Sick, "Model selection, adaptation, and combination for transfer learning in wind and photovoltaic power forecasts," *Energy and AI*, vol. 14, 2023.
- [31] W. Granville, Tunnicliffe, George E. P. Box, Gregory C. Reinsel and Greta M and Gregory C. Reinsel and Greta M. Ljung, *Time Series Analysis: Forecasting and Control*, 5th Edition, New Jersey: John Wiley and Sons Inc., 2016.
- [32] G. U. Yule, , "On a method of investigating periodicities disturbed series, with special reference to Wolfer's sunspot numbers," *Philosophical Transactions of the Royal Society*, vol. 226, no. 636-646, 1927.
- [33] Mingda Zhang, "Time Series: Autoregressive models - AR, MA, ARMA, ARIMA," University of Pittsburgh, Pittsburgh, Oct 23, 2018.
- [34] E. Slutsky, "The Summation of Random Causes as the Source of Cyclic Processes," *The Econometric Society*, vol. 5, pp. 105-146, 1937.
- [35] Herman O. A. Wold, "On Prediction in Stationary Time Series.," *The Annals of Mathematical Statistics*, vol. 19, pp. 558-567, Dec, 1948.
- [36] Box, G.E.P. and Jenkins, G.M. , "Time Series Analysis: Forecasting and Control. Revised Edition," *Journal of Mathematical Finance*, vol. 7, 1976.
- [37] Josef Arlt and Peter Trcka, "Automatic SARIMA modeling and forecast accuracy," *Communications in Statistics-Simulation and Computation*, vol. 47, 2019.
- [38] Sam Ansari and Ali Bou Nassif, "A Comprehensive Study of Regression Analysis and the Existing Techniques," in *Advances in Science and Engineering Technology International Conferences (ASET)*, Dubai, United Arab Emirates, 2022.
- [39] Sun, Yiming and Wang, Xinyuan and Zhang, Chi and Zuo and Mingkai, "Multiple Regression: Methodology and Applications," *Highlights in Science, Engineering and Technology*, vol. 49, pp. 542-548, 2023.
- [40] West, M., & Harrison, J., "Polynomial Trend Models," *Bayesian Forecasting and Dynamic Models*, p. 201-228, 1989.
- [41] W. Li and K. L. E. Law, "Deep Learning Models for Time Series Forecasting: A Review," *IEEE Access*, vol. 12, pp. 92306-92327, 2024.
- [42] G.Peter Zhang, "Time series forecasting using a hybrid ARIMA and neural network model," *Neurocomputing*, vol. 50, pp. 159-175, 2003.
- [43] A. M. TURING, I., "COMPUTING MACHINERY AND INTELLIGENCE," *Mind*, vol. LIX, no. 236, p. 433-460, 1950.

- [44] Groumpos, Peter, "A Critical Historic Overview of Artificial Intelligence: Issues, Challenges, Opportunities and Threats," *Artificial Intelligence and Applications*, 2023.
- [45] Mccarthy, John & Shannon, Claude, "Automata Studies," *Annals of Mathematics Studies*, vol. 36, pp. 157-165, 1956.
- [46] A. Newell and H. Simon, "The logic theory machine--A complex information processing system," *IRE Transactions on Information Theory*, vol. 2, no. 3, pp. 61-79, 1956.
- [47] A. Entezari, A. Aslani, R. Zahedi and Y. Noorollahi, "Artificial intelligence and machine learning in energy systems: A bibliographic perspective," *Energy Strategy Reviews*, vol. 45, 2023.
- [48] Butt, Faisal & Hussain, Lal & Mahmood and Anzar & Lon, "Artificial Intelligence based accurately load forecasting system to forecast short and medium-term load demands.," *Mathematical Biosciences and Engineering.*, vol. 18, pp. 400-425, 2021.
- [49] Pavlos S. Georgilakis, "Classification and Forecasting," in *Spotlight on Modern Transformer Design*, London, Springer London, 2009, pp. 157--217.
- [50] Cortez Paulo, "Artificial Intelligence in Knowledge Management for Time Series Forecasting," 1997.
- [51] J. & K. R. & A. N. & M. I. Ali, "Random Forests and Decision Trees.," *International Journal of Computer Science Issues(IJCSI).*, vol. 9, 2012.
- [52] Carmela Comito and Clara Pizzuti, "Artificial intelligence for forecasting and diagnosing COVID-19 pandemic: A focused review," *Artificial Intelligence in Medicine*, vol. 128, 2022.
- [53] Warren S. McCulloch and Walter Pitts , "A logical calculus of the ideas immanent in nervous activity," *The bulletin of mathematical biophysics*, vol. 5, pp. 115-133, 1943.
- [54] R. F., "The perceptron: a probabilistic model for information storage and organization in the brain.," *Psychol Rev.*, pp. 386-408, 1958.
- [55] David E. Rumelhart, Geoffrey E. Hinton and Ronald J. Williams , "Learning representations by back-propagating errors," *Nature*, vol. 323, pp. 533-536, 1986.
- [56] G. Dudek, "Multilayer perceptron for short-term load forecasting: from global to local approach," *Neural Computing and Applications*, vol. 32, pp. 3695-3707, 2020.
- [57] O. E. Dragomir, F. Dragomir, I. Brezeanu and E. Minca, "MLP neural network as load forecasting tool on short-term horizon," in *19th Mediterranean Conference on Control & Automation (MED)*, Corfu, Greece, 2011.
- [58] A. Almalaq and G. Edwards, "A Review of Deep Learning Methods Applied on Load Forecasting," in *16th IEEE International Conference on Machine Learning and Applications (ICMLA)*, Cancun, Mexico, 2017.
- [59] Huifeng Xu, Feihu Hu, Xinhao Liang, Guoqing Zhao, "A framework for electricity load forecasting based on attention mechanism time series depthwise separable convolutional neural network," *Energy*, vol. 299, pp. 131-258, 2024.
- [60] H. Eskandari, M. Imani and M. P. Moghaddam, "Convolutional and recurrent neural network based model for short-term load forecasting," *Electric Power Systems Research*, vol. 195, pp. 107-173, 2021.
- [61] Ying-Yi Hong, Gerard Francesco DG. Apolinario and Yung-Han Cheng, "Week-ahead Daily Peak Load Forecasting Using Hybrid Convolutional Neural Network," *IFAC-PapersOnLine*, vol. 56, pp. 372-377, 2023.
- [62] Das, S., Tariq, A., Santos, T., Kantareddy, S.S. and Banerjee, I. , "Recurrent Neural Networks (RNNs): Architectures, Training Tricks, and Introduction to Influential Research.," in *Machine Learning for Brain Disorders. Neuromethods*, New York, Humana, 2023, pp. 117-138.
- [63] G.H. Harish Nayak, Md Wasi Alam, G. Avinash, Rajeev Ranjan Kumar, Mrinmoy Ray, Samir Barman, K.N. Singh, B. Samuel Naik, Nurnabi Meherul Alam, Prasenjit Pal, Santosha Rathod and Jaiprakash Bisen, "Transformer-based deep learning architecture for time series forecasting," *Software Impacts*, vol. 22, pp. 100-716, 2024.
- [64] Ailing Zeng, Muxi Chen, Lei Zhang and Qiang Xu, "Are Transformers Effective for Time Series Forecasting?," in *The Thirty-Seventh AAAI Conference on Artificial Intelligence (AAAI-23)*, Washington, 2023.
- [65] Jen Chun Wang, "A study on the energy performance of hotel buildings in Taiwan," *Energy and Buildings*, vol. 49, pp. 268-275, 2012.
- [66] Pasapitch Chujai, Nittaya Kerdprasop and Kittisak Kerdprasop, "Time Series Analysis of Household Electric Consumption with ARIMA and ARMA Models," in *International MultiConference of Engineers and Computer*

Scientists, Hong Kong, 2013.

- [67] S.R. Twanabasu and B.A. Bremdal, "Load forecasting in a smart grid oriented building," in *22nd International Conference and Exhibition on Electricity Distribution*, Stockholm, 2013.
- [68] Joaquim Massana, Carles Pous, Llorenç Burgas, Joaquim Melendez and Joan Colomer, "Short-term load forecasting in a non-residential building contrasting models and attributes," *Energy and Buildings*, vol. 92, pp. 322-330, 2015.
- [69] Jihoon Moon, Yongsung Kim, Mingjae Son and Eunjun Hwang, "Hybrid Short-Term Load Forecasting Scheme Using Random Forest and Multilayer Perceptron," *Energies*, vol. 11, 2018.
- [70] Jose Silva, Isabel Praça, Tiago Pinto and Zita Vale , "Energy Consumption Forecasting Using Ensemble Learning Algorithms," in *Distributed Computing and Artificial Intelligence, 16th International Conference, Special Sessions, Ávila*, 2019.
- [71] Mengmeng Cai, Manisa Pipattanasomporn and Saifur Rahman, "Day-ahead building-level load forecasts using deep learning vs. traditional time-series techniques," *Applied Energy*, vol. 236, pp. 1078-1088, 2019.
- [72] Weicong Kong, Zhao Yang Dong, Youwei Jia, David J. Hill, Yan Xu and Yuan Zhang, "Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network," *IEEE Transactions on Smart Grid*, vol. 10, no. 1, pp. 841-851, 2019.
- [73] Chaobo Zhang , Junyang Li, Yang Zhao , Tingting Li, Qi Chen and Xuejun Zhang, "A hybrid deep learning-based method for short-term building energy load prediction combined with an interpretation process," *Energy and Buildings*, vol. 225, 2020.
- [74] Musaed Alhussein, Khursheed Aurangzeb and Syed Irtaza Haider, "Hybrid CNN-LSTM Model for Short-Term Individual Household Load Forecasting," *IEEE Access*, vol. 8, pp. 180544-180557, 2020.
- [75] Chul Ho Kim , Marie Kim and Yu Jin Song , "Sequence-to-sequence deep learning model for building energy consumption prediction with dynamic simulation modeling," *Journal of Building Engineering*, vol. 43, 2021.
- [76] Chen Wang, Ying Wang, Zhetong Ding, Tao Zheng, Jiangyi Hu and Kaifeng Zhang, "A Transformer-Based Method of Multienergy Load Forecasting in Integrated Energy System," *IEEE Transactions on Smart Grid*, vol. 13, no. 4, pp. 2703-2714, 2022.
- [77] Abolfazl Farahani, Behrouz Pourshojae, Khaled Rasheed and Hamid R. Arabnia, "A Concise Review of Transfer Learning," in *2020 International Conference on Computational Science and Computational Intelligence (CSCI)*, Las Vegas, NV, USA, 2020.
- [78] Asmaul Hosna, Ethel Merry, Jigme Gyalmo, Zulfikar Alom, Zeyar Aung and Mohammad Abdul Azim, "Transfer learning: a friendly introduction," *Journal of Big Data*, vol. 9, 2022.
- [79] Guannan Li, Yubei Wu, Jiangyan Liu, Xi Fang and Zixi Wang, "Performance evaluation of short-term cross-building energy predictions using deep transfer learning strategies," *Energy and Buildings*, vol. 275, 2022.
- [80] Yusun Ahn and Byungseon Sean Kim, "Prediction of building power consumption using transfer learning-based reference building and simulation dataset," *Energy and Buildings*, vol. 258, 2022.
- [81] Yuan Gao, Yingjun Ruan, Chengkuan Fang and Shuai Yin, "Deep learning and transfer learning models of energy consumption forecasting for a building with poor information data," *Energy and Buildings*, vol. 223, pp. 110-156, 2020.
- [82] Miquel López Santos, Saúl Díaz García, Xela García Santiago, Ana Ogando-Martínez, Fernando Echevarría Camarero, Gonzalo Blázquez Gil and Pablo Carrasco Ortega, "Deep learning and transfer learning techniques applied to short-term load forecasting of data-poor buildings in local energy communities," *Energy and Buildings*, vol. 292, pp. 113-164, 2023.
- [83] Manuel Weber, Maximilian Auch, Christoph Doblander, Peter Mandl and Hans-Arno Jacobsen, "Transfer Learning With Time Series Data: A Systematic Mapping Study," *IEEE Access*, vol. 9, pp. 165409-165432, 2021.
- [84] Cheng Fan, Yongjun Sun, Fu Xiao, Jie Ma, Dasheng Lee, Jiayuan Wang and Yen Chieh Tseng, "Statistical investigations of transfer learning-based methodology for short-term building energy predictions," *Applied Energy*, vol. 262, 2020.
- [85] Ling Xiao, Qinyi Bai and Binglin Wang, "A dynamic multi-model transfer based short-term load forecasting," *Applied Soft Computing*, vol. 2024, 2024.

- [86] Chao Peng, Yifan Tao, Zhipeng Chen, Yong Zhang and Xiaoyan Sun, "Multi-source transfer learning guided ensemble LSTM for building multi-load forecasting," *Expert Systems with Applications*, vol. 202, 2022.
- [87] Huiming Lu, Jiazheng Wu, Yingjun Ruan, Fanyue Qian, Hua Meng, Yuan Gao and Tingting Xu, "A multi-source transfer learning model based on LSTM and domain adaptation for building energy prediction," *International Journal of Electrical Power & Energy Systems*, vol. 149, 2023.
- [88] Gurjot Singh and Jatin Bedi, "A federated and transfer learning based approach for households load forecasting," *Knowledge-Based Systems*, vol. 299, 2024.
- [89] Fanyue Qian, Yingjun Ruan, Huiming Lu, Hua Meng and Tingting Xu, "Enhancing source domain availability through data and feature transfer learning for building power load forecasting," *Building Simulator*, vol. 17, pp. 625-638, 2024.
- [90] Zhuoqun Xing, Yiqun Pan, Yiting Yang, Xiaolei Yuan, Yumin Liang and Zhizhong Huang, "Transfer learning integrating similarity analysis for short-term and long-term building energy consumption prediction," *Applied Energy*, vol. 365, 2024.
- [91] A. Mystakidis, P. Koukaras, N. Tsalikidis, D. Ioannidis and C. Tjortjis, "Energy Forecasting: A Comprehensive Review of Techniques and Technologies," *Energies*, vol. 17, 2024.
- [92] Wenxiang Li and K. L. Eddie Law, "Deep Learning Models for Time Series Forecasting: A Review," *IEEE Access*, vol. 12, pp. 92306 - 92327, 2024.
- [93] J.M. González-Sopeña, V. Pakrashi and B. Ghosh, "An overview of performance evaluation metrics for short-term statistical wind power forecasting," *Renewable and Sustainable Energy Reviews*, vol. 138, 2021.
- [94] D. Koutsandreas, F. Petropoulos, E. Spiliotis and V. Assimakopoulos, "On the selection of forecasting accuracy measures," *Journal of the Operational Research Society*, vol. 73, pp. 1-18, 2021.
- [95] M. Clayton, K. Anjuman, P. Bianca, A. Pandarasamy, P. June Young, N. Zoltan, R. Paul, H. Brodie W., S. Zixiao and M. Forrest, "The Building Data Genome Project 2, energy meter data from the ASHRAE Great Energy Predictor III competition," *Scientific Data*, vol. 7, no. 1, 2020.
- [96] Nivethitha Somu, Gauthama Raman M R and Krithi Ramamritham, "A deep learning framework for building energy consumption forecast," *Renewable and Sustainable Energy Reviews*, vol. 137, 2021.
- [97] B. Lim, S. Ö. Arık, N. Loeff and T. Pfister, "Temporal Fusion Transformers for interpretable multi-horizon time series forecasting," *International Journal of Forecasting*, vol. 37, no. 4, pp. 1748-1764, 2021.
- [98] T. Akiba, S. Sano, T. Yanase and S. Sano, "Optuna: A Next-generation Hyperparameter Optimization Framework," in *The 25th ACM SIGKDD International Conference*, New York, USA, 2019.
- [99] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," in *3rd International Conference for Learning Representations*, San Diego, USA, 2014.