



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
Διατμηματικό Πρόγραμμα Μεταπτυχιακών Σπουδών
«Παραγωγή και Διαχείριση Ενέργειας»

Ηρώων Πολυτεχνείου 9, 157 73, Ζωγράφου – 210-7723655 – epminfo@power.ece.ntua.gr

ΜΕΤΑΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

**«ΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ
ΗΛΕΚΤΡΙΚΗΣ ΖΗΤΗΣΗΣ ΟΙΚΙΑΚΩΝ
ΦΟΡΤΙΩΝ ΜΕ ΧΡΗΣΗ ΑΝΑΔΡΟΜΙΚΩΝ
ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ»**

Του Μεταπτυχιακού Φοιτητή

Παπαλουκά Γιώργου

Επιβλέπων

Παύλος Σ. Γεωργιλιάκης, Καθηγητής ΕΜΠ, ΗΜΜΥ

Αθήνα, Ιούλιος 2023

ΕΥΧΑΡΙΣΤΙΕΣ

Η παρούσα διπλωματική εργασία εκπονήθηκε κατά το ακαδημαϊκό έτος 2022–2023 υπό την επίβλεψη του κ. Παύλου Γεωργιλάκη, καθηγητή της σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Ε.Μ.Π. στον οποίο οφείλω ιδιαίτερες ευχαριστίες για την ανάθεσή της, δίνοντάς μου την ευκαιρία να ασχοληθώ με ένα ενδιαφέρον και δημιουργικό θέμα. Επίσης, θα ήθελα να ευχαριστήσω τον υποψήφιο διδάκτορα Χριστόφορο Μένο - Αικατερινιάδη για την πολύτιμη βοήθεια και καθοδήγηση που μου παρείχε σε όλη τη διάρκεια εκπόνησης της εργασίας, καθώς και για τον πολύτιμο χρόνο που μου αφιέρωσε.

Ακόμα, θα ήθελα να ευχαριστήσω την Αναστασία για την υπομονή, την στήριξη και την βοήθεια της σε όλη αυτή την διαδρομή. Τέλος, την οικογένεια μου και ιδιαίτερα την αδερφή μου, Σταυρούλα, για την πολύτιμη στήριξη της και τον φίλο μου Μιχάλη για την βοήθεια του.

Περιεχόμενα

Σύνοψη	1
Περίληψη	1
Abstract.....	3
Summary.....	3
ΚΕΦΑΛΑΙΟ 1ο	5
ΕΙΣΑΓΩΓΗ	5
1.1 Αντικείμενο εργασίας	5
1.2 Δομή της εργασίας.....	5
ΚΕΦΑΛΑΙΟ 2ο	7
ΠΡΟΒΛΕΨΗ ΗΛΕΚΤΡΙΚΗΣ ΖΗΤΗΣΗΣ.....	7
2.1 Σύγχρονα ηλεκτρικά δίκτυα	7
2.2 Προκλήσεις και σύγχρονες απαιτήσεις οικιακών φορτίων	9
2.3 Σημασία πρόβλεψης ηλεκτρικού φορτίου	12
2.4 Χρησιμότητα των νευρωνικών δικτύων στην πρόβλεψη φορτίου	14
ΚΕΦΑΛΑΙΟ 3ο	19
ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ.....	19
3.1 Γενικά	19
3.2 Νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης	20
3.3 Αναδρομικά νευρωνικά δίκτυα (RNN).....	21
3.4 Δίκτυα μακράς βραχυπρόθεσμης μνήμης.....	23
3.5 Βασικές υπερπαραμέτροι	24
ΚΕΦΑΛΑΙΟ 4ο	27
ΔΕΔΟΜΕΝΑ.....	27
4.1 Επιλογή δεδομένων	27
4.2 Ανάλυση δεδομένων	29
4.3 Επεξεργασία δεδομένων.....	30
ΚΕΦΑΛΑΙΟ 5ο	33
ΜΟΝΤΕΛΟ	33
5.1 Εισαγωγή.....	33
5.2 Περιγραφή μοντέλου	33
5.3 Δομή μοντέλου	35
5.4 Κριτήρια ακριβείας μοντέλου	40

ΚΕΦΑΛΑΙΟ 6^ο	43
ΕΦΑΡΜΟΓΕΣ	43
6.1 Γενικά	43
6.2 Τέξας.....	44
6.3 Καλιφόρνια.....	49
6.4 Νέα Υόρκη.....	53
6.5 Ανάλυση ευαισθησίας.....	59
ΚΕΦΑΛΑΙΟ 7^ο	65
ΣΥΜΠΕΡΑΣΜΑΤΑ - ΕΠΕΚΤΑΣΕΙΣ	65
7.1 Συμπεράσματα.....	65
7.2 Επεκτάσεις.....	66
ΒΙΒΛΙΟΓΡΑΦΙΑ	67
ΠΗΓΕΣ ΣΧΗΜΑΤΩΝ	70

ΜΕΤΑΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ:	«Βραχυπρόθεσμη πρόβλεψη ηλεκτρικής ζήτησης οικιακών φορτίων με χρήση αναδρομικών νευρωνικών δικτύων»
ΦΟΙΤΗΤΗΣ:	Παπαλουκάς Γιώργος
ΕΠΙΒΛΕΠΩΝ:	Παύλος Σ. Γεωργιλάκης, Καθηγητής ΕΜΠ, ΗΜΜΥ
ΑΚΑΔΗΜΑΪΚΟ ΕΤΟΣ:	2022-2023

Σύνοψη

Σκοπός της παρούσας διπλωματικής εργασίας είναι η υλοποίηση ενός μοντέλου για την πρόβλεψη του βραχυπρόθεσμου ηλεκτρικού φορτίου οικιακών συσκευών, μια κρίσιμη πτυχή της διαχείρισης του ενεργειακού συστήματος. Το μοντέλο θα υλοποιηθεί με τη χρήση ενός αναδρομικού νευρωνικού δικτύου (Recurrent Neural Network - RNN) σε περιβάλλον python, το οποίο θα είναι σε θέση να εντοπίζει μοτίβα και τάσεις και να προβλέπει τη μελλοντική ζήτηση.

Σε πρώτη φάση θα πραγματοποιηθεί η εκπαίδευση, με πραγματικά δεδομένα, ενός αναδρομικού δικτύου έτσι ώστε να μπορεί να προβλεφθεί η βραχυπρόθεσμη αθροιστική ηλεκτρική κατανάλωση όμοιων οικιακών συσκευών της ίδιας περιοχής. Θα καταβληθούν προσπάθειες για τη βελτιστοποίηση των επιδόσεων του μοντέλου μέσω της ρύθμισης των υπερπαραμέτρων, της προσαρμογής της αρχιτεκτονικής και της βελτίωσης της διαδικασίας εκμάθησης. Αφού βελτιστοποιηθεί, το μοντέλο θα υποβληθεί σε επικύρωση με τη χρήση πραγματικών δεδομένων οικιακού ηλεκτρικού φορτίου από το σύνολο των διαθέσιμων δεδομένων. Αυτό θα επιτρέψει τη λεπτομερή αξιολόγηση της ακρίβειας πρόβλεψης και της συνολικής αξιοπιστίας του.

Τέλος, η εργασία ολοκληρώνεται με τη σύνοψη των βασικών ευρημάτων και των συνεισφορών της παρούσας έρευνας, ενώ παράλληλα περιγράφονται πιθανές κατευθύνσεις για μελλοντικές εργασίες στον τομέα αυτό. Αυτή η ολοκληρωμένη μελέτη αναμένεται να συμβάλει στον τομέα της βραχυπρόθεσμης πρόβλεψης φορτίου, παρέχοντας ένα εξελιγμένο και αξιόπιστο εργαλείο για τη διαχείριση της ενέργειας των κατοικιών και την προώθηση της βιώσιμης χρήσης της ενέργειας.

Περίληψη

Στα πλαίσια της προσπάθειας απανθρακοποίησης της οικονομίας, τα τελευταία χρόνια, πραγματοποιείται μια μεγάλη προσπάθεια για τον ενεργειακό μετασχηματισμό των δικτύων ηλεκτρικής ενέργειας. Ειδικότερα, δίνεται έμφαση στον εκσυγχρονισμό συνολικά του συστήματος ηλεκτρικής ενέργειας, το οποίο γίνεται πιο "έξυπνο" για να φιλοξενήσει την αυξανόμενη διείσδυση ανανεώσιμων πηγών ενέργειας καθώς και τις διαρκώς μεταβαλλόμενες καταναλωτικές συνήθειες των χρηστών. Τα οικιακά φορτία αποτελούν κρίσιμη συνιστώσα του συστήματος ηλεκτρικής ενέργειας, αντιπροσωπεύοντας σημαντικό μερίδιο της κατανάλωσης ηλεκτρικής ενέργειας παγκοσμίως και θα πρέπει και αυτά να εξελιχθούν ώστε να ανταποκρίνονται στις σύγχρονες απαιτήσεις. Για τον λόγο αυτό, η ανάπτυξη μεθόδων και μοντέλων πρόβλεψης για τον υπολογισμό της κατανάλωσης ηλεκτρικού οικιακού φορτίου είναι πλέον ζωτικής σημασίας.

Την ίδια στιγμή, η χρήση μοντέλων μηχανικής μάθησης για τη βραχυπρόθεσμη πρόβλεψη της οικιακής ζήτησης ηλεκτρικής ενέργειας έχει γίνει όλο και πιο δημοφιλής. Τα νευρωνικά δίκτυα αποτελούν έναν τύπο αλγορίθμου μηχανικής μάθησης που έχει σχεδιαστεί για να επεξεργάζεται πληροφορίες με τρόπο παρόμοιο με εκείνο που επεξεργάζεται πληροφορίες ο ανθρώπινος εγκέφαλος. Έχουν την δυνατότητα να χρησιμοποιηθούν για ποικίλες εργασίες, όπως η αναγνώριση εικόνων και ομιλίας, η επεξεργασία φυσικής γλώσσας και η πρόβλεψη χρονοσειρών. Στην παρούσα εργασία, θα αναπτυχθεί ένα μοντέλο βραχυπρόθεσμης πρόβλεψης φορτίου οικιακών συσκευών βασισμένο στα νευρωνικά δίκτυα.

Το μοντέλο υλοποιήθηκε με τη χρήση ενός αναδρομικού νευρωνικού δικτύου (Recurrent Neural Network - RNN) και επικεντρώνει στη βραχυπρόθεσμη πρόβλεψη φορτίου, η οποία αποσκοπεί στην βραχυπρόθεσμη εκτίμηση της

ηλεκτρικής κατανάλωσης διάφορων οικιακών συσκευών. Το διαφορετικό που προσδίδει το συγκεκριμένο μοντέλο, έγκειται στο ότι επικεντρώνει στην κατανάλωση κρίσιμων ηλεκτρικών συσκευών και όχι γενικά στην οικιακή κατανάλωση σε επίπεδο κατοικίας ή κοινότητας. Η ανάλυση αυτή είναι ιδιαίτερα σημαντική καθώς βοηθάει στην δημιουργία ενός μοτίβου κατανάλωσης με αναφορά την οικιακή ηλεκτρική συσκευή.

Τα δεδομένα που χρησιμοποιήθηκαν για την εκπαίδευση του μοντέλου προέρχονται από ένα δημοσίως διαθέσιμο σύνολων δεδομένων, που έχει σχεδιαστεί ειδικά για την πρόβλεψη της ζήτησης ηλεκτρικής ενέργειας. Αυτά τα δεδομένα προέρχονται από την Pecan Street, έναν ερευνητικό οργανισμό που συλλέγει, από έξυπνους μετρητές και άλλες πηγές, δεδομένα χρήσης ενέργειας από κατοικίες στις Ηνωμένες Πολιτείες. Κατά την επιλογή των δεδομένων έπρεπε να ληφθούν υπόψη διάφοροι παράγοντες, όπως η ποιότητά τους, η διαθεσιμότητα και η αντιπροσωπευτικότητά τους. Οι μελέτες (case studies) που εξέτασε η εργασία αφορούν τρεις διαφορετικές περιοχές των Ηνωμένων Πολιτειών: το Τέξας, την Καλιφόρνια και τη Νέα Υόρκη.

Το ενισχυμένο μοντέλο LSTM (Long Short Term Memory), που δημιουργήθηκε, εκπαιδεύεται με δεδομένα ιστορικών καταναλώσεων διάρκειας τριών μηνών με στόχο να προβλέψει τις καταναλώσεις 5 ημερών, οι οποίες συγκρίνονται με τις πραγματικές τιμές. Ταυτόχρονα, υλοποιείται ένα ενισχυμένο μοντέλο ANN (Artificial Neural Network) για τη διόρθωση των προβλέψεων που παράγονται από το μοντέλο LSTM. Αυτό γίνεται με σκοπό τη βελτίωση της ακρίβειας των προβλέψεων. Το πρόσθετο μοντέλο ANN έχει δικά του επίπεδα νευρώνων, τις αντίστοιχες συναρτήσεις ενεργοποίησης και τη συγκεκριμένη αρχιτεκτονική που ορίζεται στον κώδικα. Τα αποτελέσματα, των προβλέψεων παρουσιάζονται αναλυτικά.

Το βασικό κριτήριο ακρίβειας του μοντέλου είναι το Μέσο Απόλυτο Ποσοστιαίο Σφάλμα το οποίο συγκρίνεται με τα αντίστοιχα σφάλματα δημοσιευμένης εργασίας. Παράλληλα, υπολογίζονται και άλλοι δείκτες ακριβείας προκειμένου να εξεταστεί συνολικά η ακρίβεια των προβλέψεων του δικτύου. Επιπλέον, συγκρίνεται η ακρίβεια των προβλέψεων του ενισχυμένου δικτύου LSTM που υλοποιήθηκε, με αυτό του απλού LSTM δικτύου. Σημειώνεται ακόμα, ότι οι διαφορετικές συσκευές παρουσιάζουν διαφορετικά μοτίβα χρήσης, ανάλογα με τη συχνότητα, την εποχικότητα ή και άλλους παράγοντες οι οποίες λήφθηκαν υπόψη για να γίνουν και οι κατάλληλες προσαρμογές στις υπερπαραμέτρους του δικτύου. Επιπρόσθετα, πραγματοποιήθηκε ανάλυση ευαισθησίας κρίσιμων για το μοντέλο υπερπαραμέτρων και παρουσιάστηκαν τα αντίστοιχα συμπεράσματα.

Λέξεις κλειδιά: Βραχυπρόθεσμη πρόβλεψη φορτίου, εκσυγχρονισμός ηλεκτρικών συστημάτων, έξυπνα δίκτυα, μηχανική μάθηση, νευρωνικά δίκτυα, αναδρομικά νευρωνικά δίκτυα

POST-GRADUATE THESIS: **«Short term residential load forecasting with the use of Recurrent Neural Networks»**

STUDENT: **Papaloukas Georgios**

SUPERVISOR: **Pavlos S. Georgilakis, Professor NTUA, ECE**

ACADEMIC YEAR: **2022-2023**

Abstract

The scope of this thesis is the implementation of a model for the forecasting of the short-term electricity load at the residential level, a critical aspect of energy system management. The model will be implemented using a Recurrent Neural Network (RNN), which will be able to identify patterns and trends and predict future demand.

Firstly, a recurrent LSTM (Long Short Term Memory) network will be trained with real-world data so that the short-term cumulative electricity consumption of similar household appliances in residences in the same area can be predicted. Efforts will be made to optimize the performance of the model by tuning the hyperparameters, adapting the architecture and improving the learning process. Once optimized, the model will be subjected to validation using actual residential electric load data from the dataset. This will allow a detailed evaluation of its prediction accuracy and overall reliability.

Finally, this thesis concludes with a summary of the key findings and contributions of this research, while outlining possible directions for future work in this area. This comprehensive study is expected to contribute to the field of short-term load forecasting, providing a sophisticated and reliable tool for managing residential energy and promoting sustainable energy use.

Summary

In the process of decarbonizing the economy, a major effort has been made the recent years to transform the electricity networks. In particular, emphasis has been placed on modernizing the electricity system as a whole, making it “smarter” to accommodate the increasing use of renewable energy sources, as well as the constantly changing demand habits of users. Residential loads, as a critical component of the power system, representing a significant share of global electricity consumption, will also need to evolve to meet modern demands. For this reason, the development of forecasting methods and models for calculating residential electricity load demand is now of vital importance.

At the same time, the use of machine learning models for short-term residential electric load forecasting has become increasingly popular. Neural networks are a type of machine learning algorithm designed to process information in a way similar to the way the human brain processes information. They have the potential to be used for a variety of tasks such as image and speech recognition, natural language processing and time series prediction. In this thesis, a model for short-term load forecast of home appliances based on neural networks will be developed.

The model is implemented using a Recurrent Neural Network (RNN) and focuses on short-term load forecasting, which aims to estimate the short-term electrical consumption of various home appliances. What makes this model different is that it focuses on the consumption of critical electrical appliances and not on the general household consumption at the level of a household or community. This analysis is particularly important as it helps establish a consumption pattern with reference to the household electrical appliance.

The data used to train the model was obtained from an open source dataset, specifically designed for electricity load forecasting. This data comes from Pecan Street, a research organization that collects, from smart meters and other sources, energy use data from residences in the United States. Several factors had to be taken into account in the selection of the data, such as their quality, availability and representativeness. The case studies implemented in this thesis concern three different regions of the United States: Texas, California and New York.

The augmented LSTM model, which was created, is trained with three months of historical consumption data to predict 5 days of consumption, which are compared against the actual values. At the same time, an augmented ANN (Artificial Neural Network) model is implemented to correct the forecasts generated by the LSTM model. This is done

to improve the accuracy of the forecasts. The augmented ANN model has its own neuron layers, the corresponding activation functions and the specific architecture defined in the code. The results of the predictions are presented in detail.

The main accuracy criterion of the model is the Mean Absolute Percentage Error which is compared with the corresponding errors of a reference paper. At the same time, other precision factors are calculated in order to examine the overall accuracy of the network predictions. In addition, the accuracy of the predictions of the implemented augmented LSTM network is compared with that of the simple LSTM network. It is also noted that different devices exhibit different usage patterns depending on frequency, seasonality or other factors that were taken into account in order to make appropriate adjustments to the network hyperparameters. In addition, a sensitivity analysis of critical hyperparameters for the model was performed and the corresponding conclusions were presented.

Key words: short term load forecasting, modernization of electric systems, smart grids, machine learning, neural networks, recurrent neural networks

ΚΕΦΑΛΑΙΟ 1ο

ΕΙΣΑΓΩΓΗ

1.1 Αντικείμενο εργασίας

Η ηλεκτρική ενέργεια αποτελεί στις σύγχρονες κοινωνίες στοιχείο ζωτικής σημασίας, ενώ η ολοένα και αποδοτικότερη εξασφάλιση της αποτελεί πάγια επιδίωξη. Έννοιες όπως η εξοικονόμηση ενέργειας και η προστασία του περιβάλλοντος αποκτούν στις μέρες μας τεράστια σημασία, καθοδηγώντας ουσιαστικά τον επανασχεδιασμό των ηλεκτρικών δικτύων που βρίσκεται σε εξέλιξη. Σε αυτό το πλαίσιο, η πρόβλεψη της ηλεκτρικής ζήτησης οικιακών φορτίων αποκτά ιδιαίτερη σημασία για τα σύγχρονα δίκτυα ενέργειας. Σκοπός της παρούσας εργασίας είναι η υλοποίηση ενός μοντέλου με χρήση αναδρομικών νευρωνικών δικτύων που να προβλέπει την βραχυπρόθεσμη ηλεκτρική κατανάλωση διάφορων οικιακών φορτίων. Τα νευρωνικά δίκτυα μπορούν να χρησιμοποιηθούν για την πρόβλεψη της ζήτησης οικιακών φορτίων, χρησιμοποιώντας ιστορικά δεδομένα κατανάλωσης ηλεκτρικής ενέργειας από καταναλωτές σε διάφορες περιοχές. Με τη χρήση αυτών των δεδομένων, το νευρωνικό δίκτυο μπορεί να αναγνωρίσει μοτίβα και τάσεις και να προβλέψει τη μελλοντική ζήτηση. Πιο συγκεκριμένα, θα πραγματοποιηθεί η εκπαίδευση ενός αναδρομικού LSTM δικτύου έτσι ώστε να μπορεί να προβλεφθεί η βραχυπρόθεσμη αθροιστική ηλεκτρική κατανάλωση όμοιων οικιακών συσκευών σε κατοικίες της ίδιας περιοχής. Στην συνέχεια, αναπτύσσεται το δίκτυο από την εκπαίδευση μέχρι και την ανάλυση των υπερπαραμέτρων, χρησιμοποιώντας πραγματικά δεδομένα καταναλώσεων. Τέλος, πραγματοποιείται σύγκριση με άλλες μεθόδους πρόβλεψης, αναφέρονται πιθανές μελλοντικές βελτιώσεις και στόχοι για περαιτέρω έρευνα.

1.2 Δομή της εργασίας

Η παρούσα εργασία οργανώνεται σε οκτώ κεφάλαια:

- Στο Κεφάλαιο 2 παρουσιάζονται οι σύγχρονες προκλήσεις των συστημάτων ηλεκτρικής ενέργειας και η σημασία της πρόβλεψης ζήτησης ηλεκτρικού φορτίου, σε μια πορεία απανθρακοποίησης της ενέργειας.
- Στο Κεφάλαιο 3 παρουσιάζεται μια γενική περιγραφή των νευρωνικών δικτύων αλλά και μια επισκόπηση των νευρωνικών δικτύων εμπρόσθιας τροφοδότησης (FFNN), των αναδρομικών νευρωνικών δικτύων (RNN) και των δικτύων μακράς βραχυπρόθεσμης μνήμης (LSTM), καθώς τα παραπάνω χρησιμοποιήθηκαν στο μοντέλο.
- Στο Κεφάλαιο 4 αναλύεται ο τρόπος επιλογής, ανάλυσης και επεξεργασίας των δεδομένων που χρησιμοποιήθηκαν για την εκπαίδευση και την επαλήθευση του μοντέλου.
- Στο Κεφάλαιο 5 περιγράφεται το πρόβλημα πρόβλεψης φορτίου και παρουσιάζεται το μοντέλο που υλοποιήθηκε. Γίνεται μια λεπτομερής επισκόπηση του επαυξημένου LSTM δικτύου και αναλύονται τα κριτήρια ακρίβειας του μοντέλου.

- Στο Κεφάλαιο 6 παρουσιάζονται τα διάφορα case studies με βάση τα οποία εκπαιδεύτηκε και επαληθεύθηκε το υλοποιημένο μοντέλο.
- Στο Κεφάλαιο 7 παρουσιάζονται τα συμπεράσματα της εργασίας και προτείνονται τρόποι βελτίωσης και επέκτασής της.
- Τέλος, παρουσιάζεται η βιβλιογραφία που χρησιμοποιήθηκε σε όλη την έκταση της εργασίας.

ΚΕΦΑΛΑΙΟ 2^ο

ΠΡΟΒΛΕΨΗ ΗΛΕΚΤΡΙΚΗΣ ΖΗΤΗΣΗΣ

2.1 Σύγχρονα ηλεκτρικά δίκτυα

Στο παρόν κεφάλαιο θα συζητηθεί ο ενεργειακός μετασχηματισμός των δικτύων ηλεκτρικής ενέργειας λόγω της προσπάθειας απανθρακοποίησης της οικονομίας. Ειδικότερα, έμφαση θα δοθεί στον εκσυγχρονισμό συνολικά του συστήματος ηλεκτρικής ενέργειας, το οποίο γίνεται πιο "έξυπνο" για να φιλοξενήσει την αυξανόμενη διείσδυση ανανεώσιμων πηγών ενέργειας καθώς και τις διαρκώς μεταβαλλόμενες καταναλωτικές συνήθειες των χρηστών.

Ιστορικά, το δίκτυο ηλεκτρικής ενέργειας είχε σχεδιαστεί για να μεταφέρει και να διανέμει την ενέργεια από μεγάλες, κεντρικές μονάδες παραγωγής ηλεκτρικής ενέργειας στους καταναλωτές. Η προσέγγιση αυτή λειτούργησε για την παραγωγή ενέργειας με βάση τα ορυκτά καύσιμα, όπου οι σταθμοί παραγωγής ηλεκτρικής ενέργειας βρίσκονταν κοντά σε πηγές ορυκτών καυσίμων και μπορούσαν να παράγουν ενέργεια με ελεγχόμενο ρυθμό. Ωστόσο, η ανάγκη για μετάβαση προς μια οικονομία χαμηλών εκπομπών διοξειδίου του άνθρακα απαιτεί θεμελιώδη μετασχηματισμό των ενεργειακών συστημάτων καθιστώντας την μια από τις μεγαλύτερες προκλήσεις της εποχής μας [1].

Ο τομέας της ηλεκτρικής ενέργειας διαδραματίζει κρίσιμο ρόλο σε αυτή τη μετάβαση, δεδομένου ότι η παραγωγή της είναι υπεύθυνη για σημαντικό μερίδιο των παγκόσμιων εκπομπών αερίων διοξειδίου του άνθρακα. Είναι κεντρικής σημασίας για πολλές πτυχές της καθημερινής ζωής και γίνεται όλο και περισσότερο καθώς η ηλεκτρική ενέργεια διαδίδεται σε νέες τελικές χρήσεις, όπως τα ηλεκτρικά οχήματα και οι αντλίες θερμότητας. Το 2021, από το σύνολο του άνθρακα που χρησιμοποιήθηκε παγκοσμίως, το 59% προοριζόταν για τον τομέα της ηλεκτροπαραγωγής. Αντίστοιχα την ίδια χρονιά για την ηλεκτροπαραγωγή χρησιμοποιήθηκε το 34% της παγκόσμιας κατανάλωσης του φυσικού αερίου, το 4% του πετρελαίου. Αποτέλεσμα των παραπάνω ήταν ο τομέας παραγωγής ηλεκτρικής ενέργειας να είναι υπεύθυνος για πάνω από το ένα τρίτο των συνολικών εκπομπών CO₂ [2],[3].

Ο εξηλεκτρισμός διαφόρων τομέων, όπως οι μεταφορές και η θέρμανση, είναι απαραίτητος για τη αποφυγή χρήσης ορυκτών καυσίμων και ως εκ τούτου για τη μείωση εκπομπών αερίων του θερμοκηπίου. Κύρια προϋπόθεση για τη μείωση ατμοσφαιρικών ρύπων μέσω εξηλεκτρισμού αποτελεί η ηλεκτρική ενέργεια να παράγεται από διάφορες πηγές χαμηλών εκπομπών άνθρακα ή από ανανεώσιμες πηγές, όπως η ηλιακή, η αιολική και η υδροηλεκτρική. Με τη μετάβαση στην «καθαρή» παραγωγή ηλεκτρικής ενέργειας μπορεί να μειωθεί η ενεργειακή εξάρτησή από τα ορυκτά καύσιμα μειώνοντας ταυτόχρονα και τις εκπομπές CO₂. Σύμφωνα με πρόσφατη έκθεση του διεθνούς ενεργειακού οργανισμού IEA (International Energy Agency), οι ανανεώσιμες πηγές ενέργειας θα κυριαρχήσουν μεταξύ άλλων τεχνολογιών ηλεκτροπαραγωγής, αντιπροσωπεύοντας το 75-80% του συνολικού μείγματος ηλεκτροπαραγωγής έως το 2050 με αιχμή τα φωτοβολταϊκά και τα αιολικά [2]. Επιπρόσθετα, η διαθεσιμότητα των ανανεώσιμων πηγών ενέργειας συγκεκριμένες ώρες της μέρας μπορεί να οδηγήσει σε ενεργειακό πλεόνασμα τις ώρες αυτές, σε

περίπτωση που η παραγωγή υπερβαίνει τη ζήτηση. Επωφελές είναι το πλεόνασμα αυτό να χρησιμοποιηθεί για την παραγωγή «καθαρών» καυσίμων, όπως το υδρογόνο που μπορεί να συνεισφέρει αργότερα σε βιομηχανικές διαδικασίες καύσης αλλά και σε επίπεδο θέρμανσης, αντικαθιστώντας το φυσικό αέριο. Η διαθεσιμότητα τέτοιων «πράσινων» καυσίμων παρέχει μια πολλά υποσχόμενη εναλλακτική οδό για την απαλλαγή διάφορων τομέων από τον άνθρακα [4].

Παράλληλα, η παραγωγή ηλεκτρικής ενέργειας από ανανεώσιμες πηγές χαρακτηρίζεται από στοχαστικότητα, πράγμα που σημαίνει ότι η παραγωγή ποικίλλει ανάλογα με τις καιρικές συνθήκες και άλλους παράγοντες. Αυτή η στοχαστικότητα καθιστά δύσκολη την ενσωμάτωση των ανανεώσιμων πηγών ενέργειας στο δίκτυο ηλεκτρικής ενέργειας, καθώς το δίκτυο πρέπει να είναι σε θέση να εξισορροπεί την προσφορά και τη ζήτηση σε πραγματικό χρόνο. Επομένως, παρατηρείται μια ανάγκη για αλλαγή στη δυναμική του συστήματος, απαιτώντας ένα πιο ευέλικτο και προσαρμοστικό δίκτυο. Ο εκσυγχρονισμός και η αυτοματοποίηση του συστήματος ηλεκτρικής ενέργειας είναι απαραίτητα στοιχεία για να γίνει πιο ευέλικτο, προσαρμόσιμο και "έξυπνο". Ως έξυπνο δίκτυο ορίζεται ένα δίκτυο ηλεκτρικής ενέργειας που χρησιμοποιεί προηγμένες τεχνολογίες και συστήματα επικοινωνίας για τη βελτιστοποίηση της παραγωγής, της διανομής και της κατανάλωσης ηλεκτρικής ενέργειας [5], [6]. Το έξυπνο δίκτυο περιλαμβάνει διάφορα στοιχεία, όπως προηγμένους αισθητήρες, δίκτυα επικοινωνίας και συστήματα ανάλυσης δεδομένων. Οι προηγμένοι αισθητήρες, όπως οι μονάδες μέτρησης φάσης (PMU), παρέχουν δεδομένα σε πραγματικό χρόνο σχετικά με την κατάσταση του δικτύου, επιτρέποντας την συνεχή παρακολούθηση και τον καλύτερο έλεγχο του δικτύου. Τα δίκτυα επικοινωνίας επιτρέπουν στις συσκευές του δικτύου να επικοινωνούν μεταξύ τους, παρακολουθώντας την ενσωμάτωση ανανεώσιμων πηγών ενέργειας, συστημάτων αποθήκευσης ενέργειας και ηλεκτρικών οχημάτων. Τα συστήματα ανάλυσης των δεδομένων, που συλλέγονται από τους αισθητήρες και τα δίκτυα επικοινωνίας, παρέχουν πληροφορίες σχετικά με τη λειτουργία του δικτύου και βελτιστοποιούν την απόδοσή του. Οι τεχνικές ανάλυσης δεδομένων που χρησιμοποιούνται ποικίλλουν με κυριότερες τις παρακάτω: ανάλυση χρονοσειρών, στατιστική ανάλυση και μηχανική μάθηση.

Ταυτόχρονα, ο εκσυγχρονισμός του συστήματος ηλεκτρικής ενέργειας περιλαμβάνει την ανάπτυξη προηγμένων τεχνολογιών, όπως οι έξυπνοι μετρητές, τα ηλεκτρικά οχήματα και τα συστήματα αποθήκευσης ενέργειας. Οι έξυπνοι μετρητές είναι προηγμένοι μετρητές που επιτρέπουν την αμφίδρομη επικοινωνία μεταξύ των καταναλωτών και των διάφορων εμπλεκόμενων στην παραγωγή και διανομή ηλεκτρικής ενέργειας, όπως οι εταιρείες προμήθειας, οι επιχειρήσεις κοινής ωφέλειας, οι φορείς σωρευτικής εκπροσώπησης αλλά και οι εταιρείες που παρέχουν διάφορες υπηρεσίες στον τομέα της ενέργειας, όπως ενεργειακές συμβουλευτικές υπηρεσίες ή εταιρείες παροχής ηλεκτρικής ενέργειας. Οι μετρητές αυτοί, παρέχουν δεδομένα σχετικά με την κατανάλωση ηλεκτρικής ενέργειας, επιτρέποντας στους καταναλωτές να παρακολουθούν τη χρήση ηλεκτρικής ενέργειας και στις επιχειρήσεις κοινής ωφέλειας να βελτιστοποιούν τη διανομή της ηλεκτρικής ενέργειας. Οι έξυπνοι μετρητές έχουν την δυνατότητα επίσης, να διευκολύνουν τα προγράμματα απόκρισης στη ζήτηση, όπου οι καταναλωτές μπορούν να μειώσουν τη χρήση ηλεκτρικής ενέργειας κατά τις περιόδους αιχμής της ζήτησης. Ιστορικές μετρήσεις μπορούν να οδηγήσουν σε αξιολόγηση και καλύτερη αξιοποίηση της ευελιξίας των χρηστών έτσι ώστε να προσαρμόζεται καλύτερα η ζήτηση στην προσφορά ηλεκτρικής ενέργειας

και να γίνεται όσο το δυνατόν καλύτερη αξιοποίηση των ανανεώσιμων πηγών ενέργειας, μειώνοντας την ανάγκη για παραγωγή ενέργειας με βάση τα ορυκτά καύσιμα.

Τα ηλεκτρικά οχήματα, ως βασικό συστατικό του εκσυγχρονισμένου συστήματος ηλεκτρικής ενέργειας, μπορούν να παρέχουν αποθηκευτική ικανότητα στο δίκτυο, επιτρέποντας την ενσωμάτωση ανανεώσιμων πηγών ενέργειας και βελτιώνοντας την ευελιξία του δικτύου. Τα ηλεκτρικά οχήματα μπορούν ταυτόχρονα, να χρησιμοποιηθούν ως εργαλείο απόκρισης στη ζήτηση, καθώς έχουν την δυνατότητα να φορτίζονται σε περιόδους χαμηλής ζήτησης, και συνήθως χαμηλότερου κόστους κατανάλωσης, και να εκφορτίζονται σε περιόδους υψηλής ζήτησης, συμβάλλοντας στην εξισορρόπηση της προσφοράς και της ζήτησης.

Τα συστήματα αποθήκευσης ενέργειας αποκτούν, ολοένα και μεγαλύτερη σημασία στο εκσυγχρονισμένο σύστημα ηλεκτρικής ενέργειας. Μπορούν να χρησιμοποιηθούν για την αποθήκευση πλεονάζουσας ενέργειας από ανανεώσιμες πηγές κατά τη διάρκεια περιόδων χαμηλής ζήτησης και την παροχή της ενέργειας αυτής κατά τη διάρκεια περιόδων υψηλής ζήτησης, βελτιώνοντας την ευελιξία του δικτύου. Επιπλέον, τα συστήματα αποθήκευσης ενέργειας έχουν την δυνατότητα να χρησιμοποιηθούν για την παροχή εφεδρικής ενέργειας κατά τη διάρκεια διακοπών του δικτύου, μειώνοντας την ανάγκη για εφεδρικές γεννήτριες που βασίζονται σε ορυκτά καύσιμα.

Επιπλέον, ο εκσυγχρονισμός του συστήματος ηλεκτρικής ενέργειας απαιτεί σημαντικές επενδύσεις σε υποδομές και προηγμένες τεχνολογίες. Οι κυβερνήσεις, οι επιχειρήσεις κοινής ωφέλειας και οι διάφορες εταιρείες παροχής ηλεκτρικής ενέργειας σε όλο τον κόσμο επενδύουν στον εκσυγχρονισμό των συστημάτων ηλεκτρικής ενέργειας για να βελτιώσουν την αποδοτικότητα, την αξιοπιστία και τη βιωσιμότητα των δικτύων ηλεκτρικής ενέργειας. Ρυθμιστικά εμπόδια και περιορισμοί χρηματοδότησης οδηγούν σε καθυστερήσεις που πρέπει να ξεπεραστούν για επίτευξη ταχύτερης ενεργειακής μετάβασης.

Συμπερασματικά, ο μετασχηματισμός των δικτύων ηλεκτρικής ενέργειας αποτελεί κρίσιμο στοιχείο της προσπάθειας για την απανθρακοποίηση της ενέργειας. Η ανάπτυξη ανανεώσιμων πηγών ενέργειας, ο εκσυγχρονισμός και η αυτοματοποίηση του συστήματος ηλεκτρικής ενέργειας αποτελούν βασικές συνιστώσες του μετασχηματισμού των δικτύων ηλεκτρικής ενέργειας. Ο εκσυγχρονισμός του συστήματος ηλεκτρικής ενέργειας θα οδηγήσει στην καλύτερη ενσωμάτωση των ανανεώσιμων πηγών ενέργειας στο δίκτυο, μειώνοντας την ανάγκη για παραγωγή ενέργειας με βάση τα ορυκτά καύσιμα και βελτιώνοντας τη βιωσιμότητα του συστήματος ηλεκτρικής ενέργειας.

2.2 Προκλήσεις και σύγχρονες απαιτήσεις οικιακών φορτίων

Τα οικιακά φορτία αποτελούν κρίσιμη συνιστώσα του συστήματος ηλεκτρικής ενέργειας, αντιπροσωπεύοντας σημαντικό μερίδιο της κατανάλωσης ηλεκτρικής ενέργειας παγκοσμίως. Πιο συγκεκριμένα, το 2020, ο οικιακός τομέας αντιπροσώπευε το 27,4% της τελικής κατανάλωσης

ενέργειας ή το 18,7% της ακαθάριστης εσωτερικής κατανάλωσης ενέργειας στην ΕΕ, σύμφωνα με τα επίσημα στατιστικά της Eurostat για την κατανάλωση ενέργειας στα νοικοκυριά. Υπάρχει σταθερή αύξηση της ετήσιας κατανάλωσης ενέργειας των νοικοκυριών ως αποτέλεσμα της αύξησης του πληθυσμού, της αύξησης της οικονομικής δραστηριότητας και της αυξημένης χρήσης οικιακών συσκευών [7]. Καθώς το σύστημα ηλεκτρικής ενέργειας υφίσταται μετασχηματισμό προς μια οικονομία χαμηλών εκπομπών διοξειδίου του άνθρακα, τα οικιακά φορτία πρέπει επίσης να εξελιχθούν ώστε να ανταποκρίνονται στις σύγχρονες απαιτήσεις.

Μία από τις προκλήσεις των οικιακών φορτίων είναι τα πρότυπα ενεργειακής κατανάλωσής τους. Τα οικιακά φορτία χαρακτηρίζονται από συνεχείς μεταβολές δημιουργώντας κάποιες περιόδους αιχμής και συμφόρησης μέσα στη μέρα ή και μέσα στο χρόνο. Η ζήτηση σε αυτές τις περιόδους μπορεί να επιβαρύνει το σύστημα ηλεκτρικής ενέργειας και να οδηγήσει στην ανάγκη για πρόσθετη παραγωγή ηλεκτρικής ενέργειας. Η ζήτηση αιχμής για τα οικιακά φορτία συνδέεται συχνά με τα καθημερινά πρότυπα κατανάλωσης ενέργειας, με χαρακτηριστική την χρήση των συστημάτων θέρμανσης και ψύξης κατά τις ώρες αιχμής. Μπορεί επίσης, να επηρεάζεται και από εποχιακούς παράγοντες, όπως η χρήση κλιματισμού κατά τη διάρκεια του καλοκαιριού ή η φόρτιση ενός ηλεκτρικού αυτοκινήτου μετά τις τυπικές ώρες εργασίας (9π.μ. – 5μ.μ.). Επομένως, παρατηρείται ότι εδραιώνονται αυτές οι χρονικές περίοδοι υψηλής ζήτησης και συνεπώς υπάρχει η δυνατότητα να προβλεφθούν. Επιπροσθέτως, μελετάται αν η προσθήκη νέων φορτίων στην οικιακή κατανάλωση, όπως οι αντλίες θερμότητας ή τα ηλεκτρικά αυτοκίνητα, θα αυξήσουν το επίπεδο των αιχμών ή θα δημιουργήσουν νέες μέσα στη μέρα ή μέσα στο χρόνο.

Οι σύγχρονες απαιτήσεις των οικιακών φορτίων σχετίζονται κυρίως με την ενεργειακή τους απόδοση, στα πλαίσια βελτιστοποίησης της χρήσης ενέργειας, η οποία αποτελεί ζωτικής σημασίας έννοια για την παροχή λύσεων σε πολλές από τις ενεργειακές προκλήσεις που αντιμετωπίζει ο κόσμος σήμερα. Οι κατασκευαστές οικιακών συσκευών διεξάγουν έρευνα για την ανάπτυξη ενεργειακά αποδοτικών προϊόντων με τελικό στόχο να καταστήσουν τις οικιακές συσκευές πιο ενεργειακά αποδοτικές. Επιπρόσθετα, ένα ακόμα σημαντικό βήμα προς την κατεύθυνση της ενεργειακής αποδοτικότητας και της εξοικονόμησης ενέργειας στο οικιακό περιβάλλον είναι η εισαγωγή οικιακών συστημάτων διαχείρισης ενέργειας (Home Energy Management Systems - HEMS), τα οποία μπορούν να βελτιστοποιήσουν τη χρήση της ενέργειας στο σπίτι και να μειώσουν τις ενεργειακές απώλειες. Αυτά τα συστήματα κατά κύριο λόγο αποτελούνται από τα παρακάτω [8]:

- Συσκευές μέτρησης: οι συσκευές μέτρησης είναι ζωτικής σημασίας για το έξυπνο σπίτι. Τις περισσότερες φορές, αυτό που μπορεί να μετρηθεί μπορεί και να ελεγχθεί. Οι μετρητές αερίου, νερού και ηλεκτρικής ενέργειας είναι οι κύριες συσκευές μέτρησης για νοικοκυριά.
- Συσκευές ανίχνευσης: Οι οικιακοί αισθητήρες, που σχετίζονται με την ανίχνευση ρεύματος, τάσης, θερμοκρασίας, κίνησης και φωτός. Ανιχνεύουν τις επιθυμητές παραμέτρους σε διάφορες τοποθεσίες και στέλνουν τα σήματα σε ένα κεντρικό σύστημα. Χρησιμοποιώντας αυτές τις παραμέτρους, οι έξυπνες συσκευές μπορούν να

παρακολουθούνται, να ελέγχονται ή να προγραμματίζονται για να λειτουργούν σε επιθυμητές περιόδους.

- Ενεργοποίηση υποδομής τεχνολογίας πληροφοριών και επικοινωνίας (ICT infrastructure): Τέτοιες υποδομές αποτελούν συνδυασμό κρίκο ανάμεσα σε αισθητήρες, μετρητές και τις ηλεκτρικές συσκευές με τη μονάδα παρακολούθησης ή ελέγχου. Τόσο οι ασύρματες όσο και οι ενσύρματες τεχνολογίες επικοινωνίας αναπτύσσονται για την ενσωμάτωση διαφόρων οικιακών συσκευών. Το Wi-Fi είναι η κορυφαία τεχνολογία που διευκολύνει τα οικιακά δίκτυα.
- Έξυπνες συσκευές: Οι έξυπνες συσκευές παρέχουν στους οικιακούς πελάτες πληροφόρηση σχετικά με τη χρήση ενέργειας και επιτρέπουν την ανάπτυξη συμπεριφοράς η οποία είναι ενεργειακά αποδοτική και φιλική προς το περιβάλλον. Είναι οικιακές συσκευές με ενσωματωμένα συστήματα νοημοσύνης και επικοινωνίας που επιτρέπουν στις συσκευές να παρακολουθούνται και να ελέγχονται απομακρυσμένα. Τα πλυντήρια ρούχων, τα ψυγεία και τα πλυντήρια πιάτων είναι μερικές από τις οικιακές συσκευές που έχουν γίνει έξυπνες. Εάν η κατασκευή και η υιοθέτηση έξυπνων συσκευών διαδοθούν ευρέως, υπάρχει δυνατότητα μείωσης της ζήτησης σε μεγάλη κλίμακα [8], [9].

Όπως έχει παρατηρηθεί όμως στην ερευνητική βιβλιογραφία, η κατανάλωση ενέργειας στις κατοικίες συχνά δεν είναι τόσο αποδοτική όσο θα μπορούσε να είναι. Πιο συγκεκριμένα, οι άνθρωποι τείνουν να υποτιμούν την βελτιστοποίηση της ενεργειακής αποδοτικότητας των κατοικιών τους, όπως για παράδειγμα η τοποθέτηση κατάλληλης μόνωσης ή η αντικατάσταση ενεργειακά μη αποδοτικών συσκευών. Η προσθήκη των συστημάτων διαχείρισης ενέργειας στο σπίτι (Home Energy Management Systems) μπορεί να βοηθήσει σε αυτή τη διαδικασία σε συνδυασμό με την ενίσχυση της ενεργής συμμετοχής των χρηστών μέσω των συστημάτων διαχείρισης ενέργειας. Αυτό μπορεί να οδηγήσει σε μείωση της κατανάλωσης ενέργειας μέσω της προσαρμογής των ρυθμίσεων θερμοκρασίας, της αποθήκευσης ενέργειας και την υποστήριξη της διακοπής περιττών φορτίων κατά τις αιχμές ζήτησης. Η ευαισθητοποίηση, η εκπαίδευση και η διάθεση των απαραίτητων εργαλείων στους χρήστες μπορούν να διευκολύνουν την αλλαγή των συνηθειών τους και να δώσουν τη δυνατότητα για καλύτερο έλεγχο της κατανάλωσής τους.

Ταυτόχρονα, υπάρχουν ποικίλες προκλήσεις που σχετίζονται με την ενσωμάτωση των ανανεώσιμων πηγών ενέργειας στο δίκτυο, την εγκατάσταση ηλιακών συλλεκτών και ανεμογεννητριών και την υιοθέτηση συστημάτων διαχείρισης ενέργειας. Σημαντικό ζήτημα είναι οι δυσκολίες που αντιμετωπίζονται στην ευρεία χρήση των έξυπνων μετρητών και της υποδομής τεχνολογίας πληροφοριών και επικοινωνίας καθώς απαιτούν σημαντικές επενδύσεις από τους παρόχους ενέργειας και τους καταναλωτές. Η αναγνώριση και η αποζημίωση του οικονομικού κόστους αποτελεί σημαντικό παράγοντα για την ευρεία υιοθέτηση αυτών των τεχνολογιών. Επιπλέον, υπάρχουν προβλήματα αποδοχής και εμπιστοσύνης από τους καταναλωτές. Οι πολίτες μπορεί να ανησυχούν για την ιδιωτικότητα και την ασφάλεια των προσωπικών τους δεδομένων. Ακόμα, υπάρχουν πολιτικές και κοινωνικές προκλήσεις. Οι πολιτικές αποφάσεις και οι προτεραιότητες διαφέρουν από χώρα σε χώρα και μεταξύ παρόχων ενέργειας. Η απαιτούμενη συνεργασία και ο συντονισμός μεταξύ ενδιαφερομένων φορέων και πολιτικών παραγόντων είναι

αναγκαία για την επιτυχή ευρεία υιοθέτηση των έξυπνων μετρητών και την ανάπτυξη της απαιτούμενης ICT υποδομής [10].

2.3 Σημασία πρόβλεψης ηλεκτρικού φορτίου

Η πρόβλεψη του ηλεκτρικού φορτίου είναι ζωτικής σημασίας για την αποτελεσματική λειτουργία του συστήματος ηλεκτρικής ενέργειας. Μέχρι στιγμής, δεν υπάρχει ακριβές πρότυπο για την ταξινόμηση του εύρους των προβλέψεων φορτίου. Ωστόσο, ορισμένοι συγγραφείς έχουν χωρίσει την πρόβλεψη φορτίου όσον αφορά τη διάρκεια της πρόβλεψης σε τρεις κατηγορίες [11]: βραχυπρόθεσμες προβλέψεις (short-term), μεσοπρόθεσμες προβλέψεις (medium-term) και μακροπρόθεσμες προβλέψεις (long-term). Άλλοι ερευνητές προχωρούν στην ταξινόμηση της πρόβλεψης φορτίου σε τέσσερις ομάδες [12]: μακροπρόθεσμες προβλέψεις, μεσοπρόθεσμες προβλέψεις, βραχυπρόθεσμες προβλέψεις και πολύ βραχυπρόθεσμες προβλέψεις, ως εξής:

- Μακροπρόθεσμη πρόβλεψη φορτίου (Long-term load forecasting - LTLF): είναι η πρόβλεψη για περισσότερο από ένα έτος έως 20 χρόνια μπροστά. Αυτός ο τύπος πρόβλεψης είναι θεμελιώδης για τον στρατηγικό ενεργειακό σχεδιασμό, την γενική ανάπτυξη του συστήματος ηλεκτρικής ενέργειας (μονάδες παραγωγής, σύστημα μεταφοράς και σύστημα διανομής).
- Μεσοπρόθεσμη πρόβλεψη φορτίου (Medium-term load forecasting - MTLF): είναι συνήθως η πρόβλεψη για μια εβδομάδα έως ένα έτος, η οποία χρησιμοποιείται για τον μεσοπρόθεσμο προγραμματισμό κάλυψης φορτίου.
- Βραχυπρόθεσμη πρόβλεψη φορτίου (Short-term load forecasting - STLF): είναι η πρόβλεψη για διαστήματα που κυμαίνονται από μία ώρα έως μία εβδομάδα και είναι ιδιαίτερα σημαντική για άμεσο προγραμματισμό παραγωγής, μεταφοράς και διανομής.
- Εξαιρετικά/πολύ βραχυπρόθεσμη πρόβλεψη φορτίου (Ultra/very short-term load forecasting - VSTLF): κυμαίνεται από μερικά λεπτά έως μία ώρα μπροστά και χρησιμοποιείται για τον έλεγχο σε πραγματικό χρόνο [12].

Παρόλο που αναπτύχθηκαν πολυάριθμες μέθοδοι και μοντέλα πρόβλεψης για τον υπολογισμό μιας ακριβούς πρόβλεψης φορτίου, η εύρεση ενός κατάλληλου μοντέλου πρόβλεψης για ένα συγκεκριμένο δίκτυο ηλεκτρικής ενέργειας δεν είναι εύκολη υπόθεση και κανένα από αυτά δεν μπορεί να γενικευτεί για όλα τα πρότυπα ζήτησης. Τα μοντέλα πρόβλεψης ηλεκτρικού φορτίου μπορούν να χωριστούν σε δύο κατηγορίες:

- Μέθοδοι πρόβλεψης πολλαπλών παραγόντων (multi-factor forecasting methods)
- Μέθοδοι πρόβλεψης χρονοσειρών (time series forecasting methods)

Με την διαρκή ανάπτυξη των μεθόδων αυτών επιτυγχάνεται η ολοένα και ακριβέστερη πρόβλεψη φορτίου που είναι απαραίτητη για διάφορους λόγους:

- Επιτρέπει στις επιχειρήσεις κοινής ωφέλειας να σχεδιάζουν αποτελεσματικά τα συστήματα ηλεκτρικής ενέργειας, διασφαλίζοντας ότι παράγεται αρκετή ηλεκτρική ενέργεια για την κάλυψη της ζήτησης. Η πρόβλεψη φορτίου μπορεί να βοηθήσει τους ενδιαφερόμενους να προγραμματίσουν μελλοντικές επενδύσεις σε υποδομές παραγωγής, μεταφοράς και διανομής ηλεκτρικής ενέργειας.
- Δίνει την δυνατότητα βελτιστοποίησης της λειτουργίας των συστημάτων ηλεκτρικής ενέργειας, μειώνοντας τις ενεργειακές απώλειες μεταφοράς και διανομής του συστήματος καθώς και βελτιώνοντας την ενεργειακή απόδοση των τελικών καταναλωτών. Με την ακριβή πρόβλεψη της ζήτησης, οι επιχειρήσεις κοινής ωφέλειας μπορούν να προσαρμόζουν τα συστήματα παραγωγής και διανομής τους, ώστε να αποφεύγεται η υπερπαραγωγή καθώς και η υπερκατανάλωση ενέργειας. Την ίδια στιγμή, η πρόβλεψη φορτίου βοηθά στην κατανόηση των μοτίβων κατανάλωσης ενέργειας και την πρόβλεψη της ζήτησης σε διάφορες περιόδους. Αυτό επιτρέπει την ορθή προσαρμογή των τιμών σε πραγματικό χρόνο, λαμβάνοντας υπόψη την προβλεπόμενη ζήτηση και τη διαθεσιμότητα ενέργειας. Αποτέλεσμα είναι η δίκαιη και αποδοτική τιμολόγηση, όπου οι καταναλωτές ανταμείβονται για την ευελιξία που προσφέρουν στην κατανάλωσή τους.
- Μπορεί να βοηθήσει στην ευστάθεια του δικτύου, διασφαλίζοντας ότι το σύστημα ηλεκτρικής ενέργειας είναι ισορροπημένο και λειτουργεί εντός ασφαλών ορίων, προκειμένου να ανταποκρίνεται ασφαλέστερα η παραγωγή στις διακυμάνσεις της ζήτησης που προκαλούνται από τη χρήση οικιακών φορτίων, όπως τα συστήματα θέρμανσης και ψύξης.
- Μπορεί να συνεισφέρει στη μείωση του λειτουργικού κόστους, αποφεύγοντας την υπερπαραγωγή και την υπερβολική κατανάλωση ενέργειας. Με την ακριβή πρόβλεψη της ζήτησης, οι επιχειρήσεις κοινής ωφέλειας μπορούν να βελτιστοποιήσουν τα συστήματα παραγωγής και διανομής τους, μειώνοντας την ανάγκη για δαπανηρή εφεδρική παραγωγή και υποδομές μεταφοράς [13].

Παράλληλα, η πρόβλεψη του φορτίου των νοικοκυριών μπορεί να προσφέρει διάφορα οφέλη σε διάφορους ενδιαφερόμενους, μεταξύ των οποίων [13]:

- Υπηρεσίες κοινής ωφέλειας: Οι επιχειρήσεις κοινής ωφέλειας είναι οι πρωταρχικοί δικαιούχοι της πρόβλεψης του φορτίου των νοικοκυριών, καθώς τους επιτρέπει να σχεδιάζουν και να λειτουργούν αποτελεσματικά τα ηλεκτρικά τους συστήματα. Η πρόβλεψη του φορτίου των νοικοκυριών μπορεί να βοηθήσει τις επιχειρήσεις κοινής ωφέλειας να βελτιστοποιήσουν τα συστήματα παραγωγής και διανομής τους, μειώνοντας τη χρήση ενέργειας και βελτιώνοντας την ενεργειακή απόδοση του συστήματος.
- Καταναλωτές: Η πρόβλεψη φορτίου διαδραματίζει κρίσιμο ρόλο στην αύξηση της δέσμευσης των τελικών χρηστών για εξοικονόμηση ενέργειας, παρέχοντας πολύτιμες πληροφορίες και γνώσεις που μπορούν να επηρεάσουν τη συμπεριφορά τους και να ενθαρρύνουν την αποδοτικότερη χρήση ενέργειας. Με την κατανόηση των μοτίβων χρήσης ενέργειας και τη λήψη ανατροφοδότησης σχετικά με την κατανάλωσή τους, οι τελικοί χρήστες αποκτούν μεγαλύτερη επίγνωση των ενεργειακών τους συνηθειών και μπορούν να εντοπίσουν ευκαιρίες για δράσεις εξοικονόμησης ενέργειας.[14]

- **Ρυθμιστικές αρχές:** Οι ρυθμιστικές αρχές μπορούν επίσης να επωφεληθούν από την πρόβλεψη του φορτίου των νοικοκυριών, καθώς μπορεί να τις βοηθήσει να παρακολουθούν και να ρυθμίζουν αποτελεσματικά το σύστημα ηλεκτρικής ενέργειας. Με την κατανόηση των προτύπων κατανάλωσης ηλεκτρικής ενέργειας των μεμονωμένων νοικοκυριών, οι ρυθμιστικές αρχές μπορούν να αναπτύξουν πολιτικές και κανονισμούς που υποστηρίζουν την αποτελεσματική λειτουργία του συστήματος ηλεκτρικής ενέργειας.
- **Φορείς σωρευτικής εκπροσώπησης (ΦοΣΕ):** Οι ΦοΣΕ αποτελούν ένα νέο συμμετέχοντα στην αγορά ηλεκτρικής ενέργειας που λειτουργεί ως εικονικός σταθμός παραγωγής ενέργειας, ο οποίος είναι ένας συσσωρευτής διασκορπισμένων καταναλωμένων ενεργειακών πόρων με στόχο να δώσει τη δυνατότητα σε αυτές τις μικρές πηγές ενέργειας να παρέχουν υπηρεσίες στο δίκτυο. Η πρόβλεψη φορτίου μπορεί να παρέχει πληροφορίες για τη μελλοντική ζήτηση ενέργειας, επιτρέποντας στους φορείς σωρευτικής εκπροσώπησης να προγραμματίσουν την παραγωγή τους ανάλογα και να ενσωματώσουν αυξημένη ποσότητα ανανεώσιμης ενέργειας στο δίκτυο. επίσης, βοηθάει στο να αναπτύξουν ευέλικτα δίκτυα παροχής ενέργειας. Αυτό σημαίνει ότι μπορούν να διαχειριστούν και να ισορροπήσουν τη ζήτηση και την παραγωγή ενέργειας με ακρίβεια, αποφεύγοντας την υπερπαραγωγή και την υπερφόρτωση του δικτύου. Αυτό μπορεί να επιτευχθεί και μέσω της αποθήκευσης ενέργειας και της αυξημένης χρήσης έξυπνων συσκευών και συστημάτων διαχείρισης [15].
- **Κοινωνία:** Η κοινωνία στο σύνολό της μπορεί να επωφεληθεί από την πρόβλεψη του φορτίου των νοικοκυριών. Βελτιστοποιώντας τη λειτουργία του συστήματος ηλεκτρικής ενέργειας, η πρόβλεψη του φορτίου των νοικοκυριών μπορεί να μειώσει την ανάγκη για ηλεκτροπαραγωγή με βάση τα ορυκτά καύσιμα, μειώνοντας τις εκπομπές αερίων του θερμοκηπίου και βελτιώνοντας τη βιωσιμότητα του συστήματος ηλεκτρικής ενέργειας. Η κοινωνία μπορεί να επωφεληθεί επίσης, γιατί μειώνεται το συνολικό κόστος συστήματος.

Εν κατακλείδι, η πρόβλεψη του ηλεκτρικού φορτίου αποτελεί κρίσιμο στοιχείο του συστήματος ηλεκτρικής ενέργειας, επιτρέποντας να σχεδιάζεται και να λειτουργεί πιο αποτελεσματικά το δίκτυο. Η πρόβλεψη του φορτίου των νοικοκυριών είναι μια ειδική εφαρμογή της πρόβλεψης ηλεκτρικού φορτίου που παρέχει διάφορα οφέλη σε διάφορους ενδιαφερόμενους, συμπεριλαμβανομένων των επιχειρήσεων κοινής ωφέλειας, των καταναλωτών, των ρυθμιστικών αρχών και της κοινωνίας στο σύνολό της. Με την ακριβή πρόβλεψη των προτύπων κατανάλωσης ηλεκτρικής ενέργειας, η πρόβλεψη του φορτίου των νοικοκυριών μπορεί να βελτιώσει την αποδοτικότητα και τη βιωσιμότητα του συστήματος ηλεκτρικής ενέργειας, υποστηρίζοντας τη μετάβαση προς μια οικονομία χαμηλών εκπομπών άνθρακα.

2.4 Χρησιμότητα των νευρωνικών δικτύων στην πρόβλεψη φορτίου

Η πρόβλεψη φορτίου, όπως αναφέρεται παραπάνω, είναι μια κρίσιμη διαδικασία στη λειτουργία και στον προγραμματισμό των ηλεκτρικών συστημάτων. Υπάρχουν διάφορες μέθοδοι για την πρόβλεψη ηλεκτρικού φορτίου, συμπεριλαμβανομένων γραμμικών και μη γραμμικών μεθόδων πρόβλεψης καθώς και προσεγγίσεων που βασίζονται στη μηχανική μάθηση. Οι γραμμικές μέθοδοι

πρόβλεψης βασίζονται στην υπόθεση ότι η σχέση μεταξύ των μεταβλητών εισόδου και εξόδου είναι γραμμική. Περιλαμβάνουν την απλή παλινδρόμηση, την πολλαπλή παλινδρόμηση και την παλινδρόμηση χρονοσειρών. Συγκεκριμένα:

- Η απλή παλινδρόμηση είναι μια στατιστική μέθοδος πρόβλεψης της τιμής μιας εξαρτημένης μεταβλητής με βάση την τιμή μιας μόνο ανεξάρτητης μεταβλητής. Προϋποθέτει γραμμική σχέση μεταξύ της εξαρτημένης μεταβλητής και της ανεξάρτητης μεταβλητής.
- Η πολλαπλή παλινδρόμηση είναι μια στατιστική μέθοδος για την πρόβλεψη της τιμής μιας εξαρτημένης μεταβλητής με βάση τις τιμές πολλών ανεξάρτητων μεταβλητών. Η πολλαπλή παλινδρόμηση προϋποθέτει γραμμική σχέση μεταξύ της εξαρτημένης μεταβλητής και των ανεξάρτητων μεταβλητών.
- Η παλινδρόμηση χρονοσειρών είναι μια στατιστική μέθοδος για την πρόβλεψη της τιμής μιας εξαρτημένης μεταβλητής με βάση τις τιμές των παρελθουσών παρατηρήσεων της εξαρτημένης μεταβλητής. Υποθέτει κι αυτή γραμμική σχέση μεταξύ της εξαρτημένης μεταβλητής και των παρελθουσών παρατηρήσεων.

Οι παραδοσιακές γραμμικές μέθοδοι για την πρόβλεψη φορτίου, αποτυγχάνουν να αποτυπώσουν τις μη γραμμικές εξαρτήσεις και τις περίπλοκες αλληλεπιδράσεις ανάμεσα σε αυτούς τους παράγοντες. Κατά τη διάρκεια των τελευταίων δεκαετιών, τα τεχνητά νευρωνικά δίκτυα (Artificial Neural Networks - ANNs) έχουν εμφανιστεί ως μια υποσχόμενη εναλλακτική λύση λόγω της ικανότητάς τους να απεικονίζουν περίπλοκες μη γραμμικές σχέσεις, και της ανθεκτικότητάς τους στον θόρυβο και στις παρεκκλίσεις στα δεδομένα. Τα ANNs είναι σχεδιασμένα για να μιμούνται τη λειτουργία του ανθρώπινου εγκεφάλου, που αποτελείται από αλληλεπιδραστικούς νευρώνες, όπου κάθε νευρώνας επεξεργάζεται πληροφορίες που λαμβάνει και τις μεταφέρει σε άλλους. Ένα νευρωνικό δίκτυο μπορεί να μάθει από παλαιότερα δεδομένα, να αναγνωρίζει κρυφά μοτίβα και να χρησιμοποιεί αυτή τη γνώση για να κάνει προβλέψεις. Η διαδικασία μάθησης περιλαμβάνει την προσαρμογή των βαρών σύνδεσης μεταξύ των νευρώνων, με βάση το σφάλμα στην έξοδο, βελτιώνοντας έτσι την ακρίβεια της πρόβλεψης με τον χρόνο.

Τα νευρωνικά δίκτυα έχουν αποτελέσει μια επανάσταση στον τομέα της τεχνητής νοημοσύνης και έχουν αναδειχθεί ως ισχυρό εργαλείο για την πρόβλεψη του ηλεκτρικού φορτίου. Οι ηλεκτρικές εταιρείες και οι πάροχοι ενέργειας χρησιμοποιούν όλο και περισσότερο αυτήν την τεχνολογία για να βελτιστοποιήσουν την παραγωγή, τη διανομή και την κατανάλωση ηλεκτρικής ενέργειας. Επιπλέον, τα νευρωνικά δίκτυα μπορούν να ενσωματωθούν σε συστήματα αυτοματισμού και διαχείρισης της ενέργειας. Με τη χρήση τους, μπορούν να αναπτυχθούν προηγμένα συστήματα πρόβλεψης και αυτόματου ελέγχου του ηλεκτρικού φορτίου, που μπορούν να ανταποκριθούν σε αλλαγές και αναταράξεις στο δίκτυο. Αυτό οδηγεί σε μεγαλύτερη αξιοπιστία, αποδοτικότητα και οικονομία στην παραγωγή και διανομή ηλεκτρικής ενέργειας. Επιπλέον, παρέχουν τη δυνατότητα ανάλυσης και πρόβλεψης μεγάλου όγκου δεδομένων σε πραγματικό χρόνο. Αυτό σημαίνει, ότι μπορούν να παράγουν γρήγορες και ακριβείς προβλέψεις για το ηλεκτρικό φορτίο, επιτρέποντας τη λήψη άμεσων μέτρων και τη λήψη αποφάσεων σε πραγματικό χρόνο. Αυτό είναι κρίσιμο για τη διαχείριση των ενεργειακών πόρων, την πρόληψη προβλημάτων στο δίκτυο και την αποφυγή

διακοπών ηλεκτροδότησης. Τέλος, επιτρέπει την εκτίμηση των δυνατοτήτων ευελιξίας και της δυναμικότητας για αλλαγές στην κατανάλωση. Με βάση αυτήν την εκτίμηση, οι πάροχοι ενέργειας μπορούν να σχεδιάσουν ευέλικτα πακέτα τιμολόγησης που ενθαρρύνουν τους καταναλωτές να προσαρμόσουν την κατανάλωσή τους σε περιόδους με χαμηλότερη ζήτηση. Αυτό μπορεί να περιλαμβάνει χαμηλότερες τιμολογήσεις κατά τις ώρες χαμηλής ζήτησης ή προνομιακές τιμολογήσεις για καταναλωτές που συμβάλλουν στην εξομάλυνση του φορτίου. Η πρόβλεψη φορτίου παρέχει, επομένως, την απαραίτητη πληροφορία για τον σχεδιασμό ευέλικτων πακέτων τιμολόγησης που ενθαρρύνουν τη συμμετοχή των καταναλωτών σε ενεργειακές πρακτικές που είναι φιλικές προς το περιβάλλον και οικονομικά επωφελείς.

Τα νευρωνικά δίκτυα παρέχουν επίσης τη δυνατότητα συνεχούς βελτίωσης και ανάπτυξης. Με τη συλλογή συνεχούς πληροφορίας και την εκπαίδευση τους με νέα δεδομένα, τα νευρωνικά δίκτυα μπορούν να εξελίσσονται και να προσαρμόζονται στις αλλαγές που συμβαίνουν στο ηλεκτρικό σύστημα. Αυτό εξασφαλίζει ότι οι προβλέψεις του φορτίου θα είναι συνεχώς ακριβείς και ενημερωμένες. Η εφαρμογή των ANNs στην πρόβλεψη φορτίου περιλαμβάνει την εκπαίδευση του δικτύου με ιστορικά δεδομένα φορτίου και συνδεδεμένους παράγοντες, όπως οι καιρικές συνθήκες και ο τύπος της ημέρας (καθημερινή, σαββατοκύριακο, αργία), επιτρέποντας στο δίκτυο να μάθει τυχόν μοτίβα και εξαρτήσεις. Αφού εκπαιδευτεί, το δίκτυο μπορεί να χρησιμοποιηθεί για την πρόβλεψη του μελλοντικού φορτίου με βάση τις παρεχόμενες εισόδους.

Παρά την επιτυχία τους, τα ANNs έχουν επίσης κάποιες προκλήσεις. Η επιλογή της κατάλληλης αρχιτεκτονικής δικτύου, της μεθόδου εκπαίδευσης και των παραμέτρων μπορεί να είναι δύσκολη και να επηρεάσει σημαντικά την απόδοση του δικτύου. Επιπλέον, τα ANNs απαιτούν μεγάλη ποσότητα δεδομένων για την εκπαίδευση και μπορεί να υποφέρουν από υπερπροσαρμογή (overfitting), όπου το δίκτυο γίνεται πολύ καλό στην προσαρμογή στα δεδομένα εκπαίδευσης αλλά δεν είναι σε θέση να γενικεύσει καλά σε νέα δεδομένα. Εντούτοις, με τη σωστή εφαρμογή και την ακριβή ρύθμιση, τα ANNs παραμένουν μια δυνατή εργαλειοθήκη για την πρόβλεψη φορτίου [16], [17], [18], [19].

Συνοψίζοντας, η χρησιμότητα των νευρωνικών δικτύων στην πρόβλεψη του ηλεκτρικού φορτίου είναι αναμφισβήτητη. Με την ικανότητά τους να αναγνωρίζουν μη γραμμικές σχέσεις, να αναλύουν μεγάλα σε όγκο και πολύπλοκα δεδομένα, να προσαρμόζονται σε αλλαγές και να προβλέπουν σε πραγματικό χρόνο, συμβάλλουν στην αποδοτική διαχείριση της ενέργειας, την εξοικονόμηση ενέργειας και την προαγωγή της έξυπνης ενεργειακής διανομής. Η χρησιμότητα των νευρωνικών δικτύων στην πρόβλεψη του ηλεκτρικού φορτίου απλώνεται και σε άλλους τομείς. Οι Φορείς Σωρευτικής Εκπροσώπησης μπορούν να εξισορροπήσουν την προσφορά και τη ζήτηση ενέργειας με ακρίβεια και αποτελεσματικότητα. Μπορούν να προβλέπουν τις αλλαγές στη ζήτηση, να προσδιορίζουν τις περιόδους υψηλής ζήτησης και να λαμβάνουν αποφάσεις βάσει αυτών των προβλέψεων. Αυτό οδηγεί σε βελτιωμένη διαχείριση των πόρων ενέργειας, μείωση των κινδύνων υπερφόρτωσης του δικτύου και αυξημένη αξιοποίηση των ανανεώσιμων πηγών ενέργειας. Επιπλέον, η ακριβής πρόβλεψη φορτίου επιτρέπει την εκτίμηση της ευελιξίας των οικιακών καταναλωτών, προσφέροντας τη δυνατότητα προώθησης ενεργειακών πρακτικών που

βασίζονται στη ζήτηση και την εκμετάλλευση της διαθέσιμης ευελιξίας για τη βελτιστοποίηση του δικτύου και τη μείωση των λειτουργικών εξόδων [20].

ΚΕΦΑΛΑΙΟ 3^ο

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

3.1 Γενικά

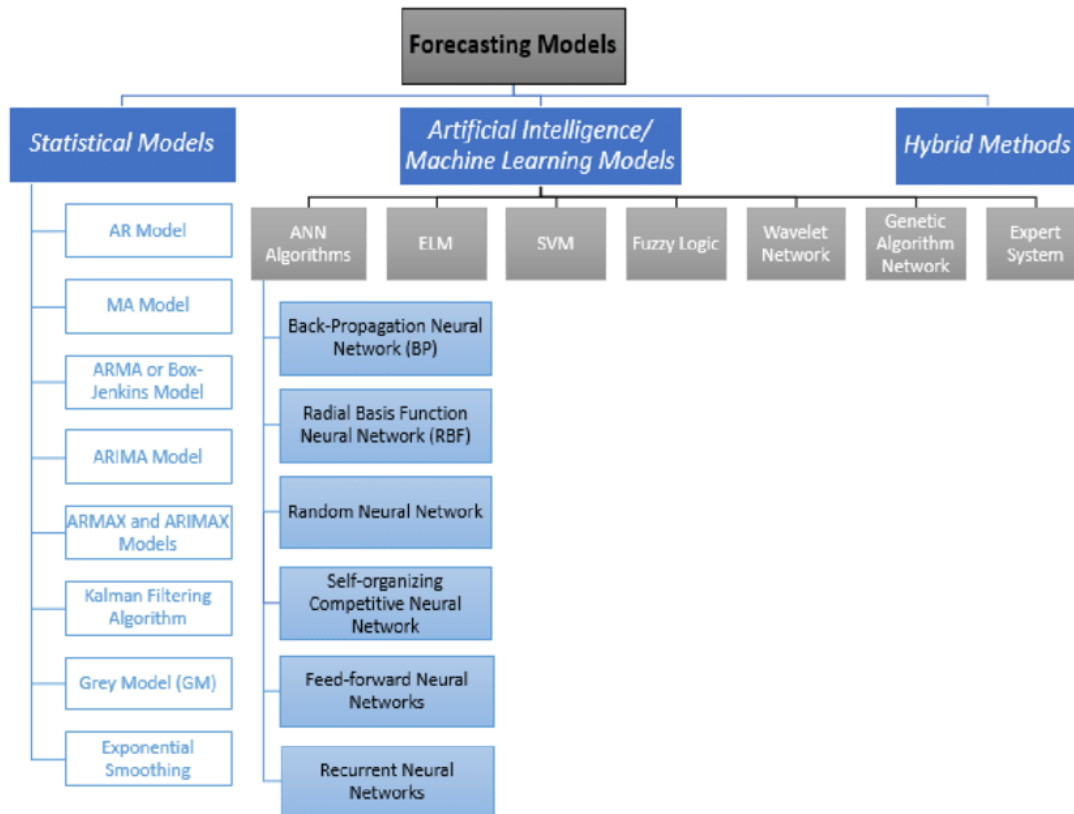
Τα νευρωνικά δίκτυα έχουν μακρά ιστορία, η οποία χρονολογείται από τη δεκαετία του 1940, αλλά μόλις τη δεκαετία του 1980 άρχισαν να χρησιμοποιούνται ευρέως. Στη δεκαετία του 1990, οι περιορισμοί των νευρωνικών δικτύων έγιναν εμφανείς, αλλά στη δεκαετία του 2010, η ανάπτυξη αλγορίθμων βαθιάς μάθησης οδήγησε σε αναζωπύρωση του ενδιαφέροντος [21]. Τα νευρωνικά δίκτυα είναι ένας τύπος αλγορίθμου μηχανικής μάθησης που έχει σχεδιαστεί για να επεξεργάζεται πληροφορίες με τρόπο παρόμοιο με εκείνο που επεξεργάζεται πληροφορίες ο ανθρώπινος εγκέφαλος. Έχουν την δυνατότητα να χρησιμοποιηθούν για ποικίλες εργασίες, όπως η αναγνώριση εικόνων και ομιλίας, η επεξεργασία φυσικής γλώσσας και η πρόβλεψη χρονοσειρών. Στην ενότητα αυτή, θα γίνει μια γενική περιγραφή των νευρωνικών δικτύων, της ιστορίας τους και των εφαρμογών τους.

Τα νευρωνικά δίκτυα αποτελούνται από έναν μεγάλο αριθμό διασυνδεδεμένων κόμβων που είναι οργανωμένοι σε επίπεδα. Κάθε κόμβος λαμβάνει είσοδο από άλλους κόμβους και εφαρμόζει μια μαθηματική συνάρτηση σε αυτή την είσοδο για να παράγει μια έξοδο. Παράλληλα, οι εξοδοί των κόμβων ενός επιπέδου χρησιμεύουν ως είσοδοι στους κόμβους του επόμενου επιπέδου και η διαδικασία συνεχίζεται μέχρι το επίπεδο εξόδου. Η διαδικασία εκπαίδευσης ενός νευρωνικού δικτύου περιλαμβάνει την προσαρμογή των βαρών και των συνδέσεων μεταξύ των κόμβων, ώστε να ελαχιστοποιηθεί η διαφορά μεταξύ της προβλεπόμενης εξόδου του νευρωνικού δικτύου και της πραγματικής εξόδου. Η διαδικασία αυτή, συνήθως, επιτυγχάνεται μέσω της χρήσης ενός συνόλου δεδομένων εκπαίδευσης, το οποίο αποτελείται από ζεύγη εισόδου/εξόδου που χρησιμοποιεί το νευρωνικό δίκτυο για να μάθει τη σχέση μεταξύ των μεταβλητών εισόδου και εξόδου.

Τα νευρωνικά δίκτυα έχουν αρκετά πλεονεκτήματα έναντι παραδοσιακότερων αλγορίθμων μηχανικής μάθησης, όπως οι αλγόριθμοι Γραμμικής Παλινδρόμησης (Linear Regression), συμπεριλαμβανομένης της ικανότητάς τους να αποτυπώνουν μη γραμμικές σχέσεις μεταξύ των μεταβλητών εισόδου και εξόδου, της ικανότητάς τους να χειρίζονται μεγάλες ποσότητες δεδομένων και της ικανότητάς τους να μαθαίνουν και να προσαρμόζονται με την πάροδο του χρόνου. Ωστόσο, έχουν επίσης αρκετούς περιορισμούς, όπως η τάση τους να προσαρμόζονται υπερβολικά στα δεδομένα εκπαίδευσης, η υπολογιστική τους πολυπλοκότητα και η έλλειψη πλήρους κατανόησης και ερμηνείας της επεξεργασμένης πληροφορίας σε κάθε στάδιο εκπαίδευσης του αλγορίθμου. Παρά τους περιορισμούς αυτούς, αποτελούν σημαντικό εργαλείο στον τομέα της μηχανικής μάθησης και έχουν χρησιμοποιηθεί με επιτυχία σε διάφορες εφαρμογές. Καθώς ο τομέας της μηχανικής μάθησης συνεχίζει να εξελίσσεται, είναι πιθανό ότι θα συνεχίσουν να διαδραματίζουν σημαντικό ρόλο στην ανάπτυξη νέων αλγορίθμων και εφαρμογών.

Τα νευρωνικά δίκτυα έχουν παίξει σημαντικό ρόλο και στη διαδικασία πρόβλεψης φορτίου. Στο Σχήμα 3.1 φαίνεται, φαίνεται μια κατηγοριοποίηση των βασικών μοντέλων πρόβλεψης φορτίων,

με βάση τη βιβλιογραφία [12]. Οι μέθοδοι πρόβλεψης χωρίζονται σε στατιστικά μοντέλα, αλγορίθμους μηχανικής μάθησης και σε υβριδικές μεθόδους. Όπως παρουσιάζεται στο Σχήμα 3.1, τα νευρωνικά δίκτυα αποτελούν σημαντικό κομμάτι των αλγορίθμων μηχανικής μάθησης που χρησιμοποιούνται για την πρόβλεψη φορτίου.



Σχήμα 3.1: Ταξινόμηση μεθόδων πρόβλεψης [12]

3.2 Νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης

Τα νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης (Feed Forward Neural Networks) έχουν αναδειχθεί σε δημοφιλή μέθοδο πρόβλεψης φορτίου λόγω της ικανότητάς τους να συλλαμβάνουν μη γραμμικές σχέσεις στα δεδομένα. Σε αυτή την ενότητα, παρουσιάζεται μια ολοκληρωμένη επισκόπηση των νευρωνικών δικτύων εμπρόσθιας τροφοδότησης και του τρόπου με τον οποίο μπορούν να χρησιμοποιηθούν για την πρόβλεψη φορτίου.

Τα νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης είναι ένας τύπος τεχνητού νευρωνικού δικτύου (ANN) που έχει σχεδιαστεί για να επεξεργάζεται διαδοχικά τα δεδομένα εισόδου και να παράγει μια ακολουθία προβλέψεων για τη μεταβλητή εξόδου. Αποτελούνται από ένα στρώμα εισόδου, ένα ή περισσότερα κρυφά στρώματα και ένα στρώμα εξόδου. Κάθε στρώμα αποτελείται από πολλαπλούς κόμβους, γνωστούς και ως νευρώνες, οι οποίοι εκτελούν υπολογισμούς στα δεδομένα εισόδου και μεταβιβάζουν τα αποτελέσματα στο επόμενο στρώμα. Οι συνδέσεις μεταξύ των κόμβων είναι σταθμισμένες και η έξοδος του δικτύου καθορίζεται από τα βάρη των κόμβων, τα

οποία μπορούν να ρυθμιστούν κατά τη διάρκεια της διαδικασίας εκπαίδευσης για τη βελτίωση της ακρίβειας των προβλέψεων.


Συγκεκριμένα, κατά την πρόβλεψη φορτίου, τα δεδομένα συχνά επηρεάζονται από διάφορους παράγοντες, όπως ο καιρός, η ώρα της ημέρας και η ημέρα της εβδομάδας. Τα νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης είναι σε θέση να συλλάβουν αυτές τις μη γραμμικές σχέσεις με τη διαδοχική επεξεργασία των δεδομένων εισόδου και τη δημιουργία μιας ακολουθίας προβλέψεων για τη μεταβλητή εξόδου. Η πρόβλεψη φορτίου με τη χρήση νευρωνικών δικτύων εμπρόσθιας τροφοδότησης περιλαμβάνει την εκπαίδευση ενός μοντέλου σε ιστορικά δεδομένα και άλλους παράγοντες, όπως δεδομένα καιρού, και στη συνέχεια τη δημιουργία μιας ακολουθίας προβλέψεων για το μελλοντικό φορτίο.

Τα νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης έχουν αρκετά πλεονεκτήματα έναντι άλλων αλγορίθμων μηχανικής μάθησης, καθώς είναι σχετικά εύκολο να υλοποιηθούν και μπορούν να εκπαιδευτούν σε μεγάλα σύνολα δεδομένων με χαμηλότερους υπολογιστικούς πόρους. Ωστόσο, η επιλογή των κατάλληλων υπερπαραμέτρων παραμένει μια πρόκληση και απαιτείται περαιτέρω έρευνα για την ανάπτυξη ακριβέστερων και ανθεκτικότερων μοντέλων πρόβλεψης φορτίου βασισμένων σε νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης [22], [23]. Ένα άλλο πλεονέκτημα της χρήσης νευρωνικών δικτύων εμπρόσθιας τροφοδότησης για την πρόβλεψη φορτίου είναι η ικανότητά τους να χειρίζονται δεδομένα που λείπουν και 'θορυβώδη' δεδομένα. Τα δεδομένα φορτίου μπορεί να είναι θορυβώδη και να περιέχουν ελλιπείς τιμές, γεγονός που μπορεί να δυσχεράνει την εκπαίδευση των μοντέλων. Τα νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης έχουν τη δυνατότητα να "μάθουν" από τα δεδομένα εκπαίδευσης και να εξάγουν συμπεράσματα με βάση αυτά τα δεδομένα, να αναγνωρίζουν τις γενικές τάσεις και τα μοτίβα στα δεδομένα, παρά την παρουσία του θορύβου.

3.3 Αναδρομικά νευρωνικά δίκτυα (RNN)

Τα τελευταία χρόνια, τα αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Networks) αποτελούν μια ακόμα δημοφιλή μέθοδο για την πρόβλεψη φορτίου, λόγω της ικανότητάς τους να «συλλαμβάνουν» τις χρονικές εξαρτήσεις στα δεδομένα. Σε αυτή την ενότητα, παρουσιάζεται μια επισκόπηση των RNNs και πώς μπορούν να χρησιμοποιηθούν για την πρόβλεψη φορτίου.

Τα αναδρομικά νευρωνικά δίκτυα είναι ένας τύπος νευρωνικού δικτύου που είναι κατάλληλος για την επεξεργασία διαδοχικών δεδομένων, όπως τα δεδομένα χρονοσειρών. Το βασικό χαρακτηριστικό των RNN είναι η χρήση αναδρομικών συνδέσεων μεταξύ των κόμβων του δικτύου. Αυτές οι συνδέσεις επιτρέπουν την επιστροφή της εξόδου ενός κόμβου στην είσοδο ενός άλλου κόμβου, επιτρέποντας στο δίκτυο να διατηρεί μνήμη προηγούμενων εισόδων. Αυτή η μνήμη είναι ιδιαίτερα χρήσιμη για την επεξεργασία διαδοχικών δεδομένων, όπου η τρέχουσα έξοδος εξαρτάται από τις προηγούμενες εισόδους [24]. Παρακάτω, όπως φαίνεται και στο Σχήμα 3.2, μελετάται συνοπτικά η αρχιτεκτονική ενός βασικού RNN δικτύου [24] :



Σχήμα 3.2: Αρχιτεκτονική βασικού RNN δικτύου [24]


Στην αριστερή πλευρά του Σχήματος 3.2 φαίνεται ο συμβολισμός ενός RNN και στη δεξιά πλευρά ένα RNN που ξεδιπλώνεται σε ένα πλήρες δίκτυο. Με το ξετύλιγμα τονίζεται ότι απεικονίζεται το δίκτυο για την πλήρη ακολουθία. Η βασική αρχιτεκτονική ενός RNN περιλαμβάνει έναν αναδρομικό κόμβο που επαναλαμβάνεται σε κάθε χρονικό βήμα της εισόδου. Αυτός ο κόμβος, αποτελείται από έναν συναρτησιακό νευρώνα, ο οποίος λαμβάνει δύο εισόδους: την τρέχουσα είσοδο στο χρονικό βήμα $x(t)$ και την κατάσταση του νευρωνικού δικτύου από το προηγούμενο χρονικό βήμα $h(t-1)$. Στη συνέχεια, ο κόμβος υπολογίζει έναν ενδιάμεσο χώρο κρυφής κατάστασης, ο οποίος αντιπροσωπεύει τη μνήμη του δικτύου και κρατά την πληροφορία από προηγούμενες εισόδους. Η ενδιάμεση κρυφή κατάσταση (hidden state) $h(t)$ του RNN υπολογίζεται με βάση την τρέχουσα είσοδο και την κατάσταση του δικτύου από το προηγούμενο χρονικό βήμα: $h(t) = f(Ux(t) + Wh(t-1))$. Η συνάρτηση f θεωρείται ότι είναι ένας μη γραμμικός μετασχηματισμός όπως \tanh , ReLU . Στη συνέχεια, η κρυφή κατάσταση χρησιμοποιείται για την παραγωγή της εξόδου στο τρέχον χρονικό βήμα, και ταυτόχρονα μεταβιβάζεται ως είσοδος στον κόμβο στο επόμενο χρονικό βήμα. Αυτή η αναδρομή επιτρέπει στο δίκτυο να διατηρεί και να ενημερώνει τη μνήμη του καθώς επεξεργάζεται την ακολουθία των εισόδων. Το RNN έχει είσοδο προς τις κρυφές συνδέσεις που παραμετροποιούνται από έναν πίνακα βαρών U , κρυφές προς κρυφές αναδρομικές συνδέσεις που παραμετροποιούνται από έναν πίνακα βαρών W , και συνδέσεις κρυφές προς την έξοδο που παραμετροποιούνται από έναν πίνακα βαρών V και όλα αυτά τα βάρη (U, V, W) μοιράζονται στον χρόνο. Τέλος, μπορεί να είναι σε θέση να αναπτύξει κατανοητή έξοδο $o(t)$ που βασίζεται στο πλαίσιο των προηγούμενων εισόδων. Ωστόσο, ένα απλό RNN μπορεί να αντιμετωπίσει προβλήματα όταν χρειάζεται να χειριστεί μακροπρόθεσμες εξαρτήσεις ή όταν η ακολουθία είναι πολύ μεγάλη. Αυτό οφείλεται σε ένα φαινόμενο που ονομάζεται "απώλεια μνήμης". Το πρόβλημα της απώλειας μνήμης στα απλά RNN αφορά τη δυσκολία του δικτύου να διατηρήσει πληροφορίες από αρκετά χρονικά βήματα πριν. Αυτό συμβαίνει, επειδή κατά την εκπαίδευση του δικτύου, οι αναγνώσεις τους εξαρτώνται από το περιεχόμενο της τρέχουσας εισόδου και της κρυφής κατάστασης. Όσο το δίκτυο επεξεργάζεται ακολουθίες που είναι πολύ μακριά στον χρόνο, η επίδραση αυτής της περιορισμένης μνήμης εξασθενεί και η απώλεια μνήμης προκαλεί την απώλεια σημαντικών πληροφοριών [24].

Η πρόβλεψη φορτίου είναι μια σημαντική εφαρμογή των RNNs στο σύστημα ηλεκτρικής ενέργειας, καθώς είναι τύποι νευρωνικών δικτύων που έχουν τη δυνατότητα να "θυμούνται" πληροφορίες από προηγούμενες εισόδους, καθιστώντας τα ιδανικά για την επεξεργασία χρονοσειρών δεδομένων, όπως η κατανάλωση ηλεκτρικής ενέργειας. Ο πιο συνηθισμένος τύπος RNN είναι το δίκτυο μακράς βραχυπρόθεσμης μνήμης (LSTM), όπως αναλύεται στην Ενότητα 3.4.

3.4 Δίκτυα μακράς βραχυπρόθεσμης μνήμης

Ανάμεσα στους αλγόριθμους μηχανικής μάθησης που χρησιμοποιούνται όλο και περισσότερο τα τελευταία χρόνια για την πρόβλεψη φορτίου, τα δίκτυα μακράς βραχυπρόθεσμης μνήμης (Long Short-Term Memory - LSTM) έχουν αναδειχθεί ως δημοφιλής μέθοδος λόγω της ικανότητάς τους να συλλαμβάνουν τις μακροπρόθεσμες εξαρτήσεις στα δεδομένα. Χρησιμοποιούν μια σειρά από πύλες για τον έλεγχο της ροής των πληροφοριών μέσω του δικτύου, επιτρέποντας στο δίκτυο να ξεχνά ή να θυμάται επιλεκτικά προηγούμενες εισόδους. Σε αυτή την ενότητα, παρουσιάζεται μια λεπτομερής επισκόπηση των δικτύων LSTM και πώς μπορούν να χρησιμοποιηθούν για την πρόβλεψη φορτίου.

Η βασική αρχιτεκτονική ενός LSTM δικτύου αποτελεί μια εξέλιξη των αναδρομικών νευρωνικών δικτύων, η οποία αντιμετωπίζει το πρόβλημα της απώλειας μνήμης. Το LSTM μοντέλο εισάγει έναν πιο πολύπλοκο μηχανισμό για τη διαχείριση της μνήμης, επιτρέποντας στο δίκτυο να διατηρεί πληροφορίες για μεγαλύτερα χρονικά διαστήματα. Τα δίκτυα LSTM χρησιμοποιούν ένα "κύτταρο μνήμης" που απομονώνει τις «σημαντικές» πληροφορίες, ενημερώνεται και συγκρατεί επιλεκτικά πληροφορίες με βάση τα δεδομένα εισόδου, «ξεχνώντας» τις μη απαραίτητες πληροφορίες. Πρόκειται για μια οριζόντια γραμμή που διατρέχει την κορυφή του κυττάρου μνήμης, όπως φαίνεται στο Σχήμα 3.3, και μπορεί να θεωρηθεί ως ένας "ιμάντας μεταφοράς" της ροής των πληροφοριών.



Σχήμα 3.3: Μοντέλο μακράς βραχυπρόθεσμης μνήμης (LSTM)[25]

Αυτό το κύτταρο μνήμης ελέγχεται από τρεις βασικές συναρτήσεις πύλης: την πύλη εισόδου (input gate), την πύλη λήθης (forget gate) και την πύλη εξόδου (output gate). Αυτές οι πύλες ελέγχουν ποιες πληροφορίες περνούν από το κελί LSTM και ποιες απορρίπτονται. Οι πύλες αυτές είναι υπεύθυνες για τη ροή της πληροφορίας μέσα στο κελί. Η πύλη εισόδου αποφασίζει ποιες νέες πληροφορίες θα εισέλθουν στο κελί LSTM από την τρέχουσα είσοδο. Η πύλη λήθης καθορίζει ποιες πληροφορίες από την προηγούμενη κρυφή κατάσταση θα διατηρηθούν. Τέλος, η πύλη εξόδου ελέγχει ποια πληροφορία από την τρέχουσα κατάσταση του κελιού LSTM θα προωθηθεί στην έξοδο του δικτύου. Η λειτουργία των πυλών επιτυγχάνεται μέσω διαφορετικών μαθηματικών λειτουργιών. Για παράδειγμα, η πύλη εισόδου μπορεί να χρησιμοποιεί σιγμοειδή (sigmoid) συνάρτηση για να προσδιορίσει το ποσοστό των νέων πληροφοριών που θα εισέλθουν στο κελί LSTM. Η πύλη λήθης μπορεί να χρησιμοποιεί επίσης σιγμοειδή συνάρτηση για να αποφασίσει ποια παλαιότερα δεδομένα θα διατηρηθούν. Τέλος, η πύλη εξόδου χρησιμοποιεί διάφορες αριθμητικές λειτουργίες για να υπολογίσει την έξοδο του κελιού LSTM, λαμβάνοντας υπόψη την τρέχουσα κατάσταση και την είσοδο.

Στην πρόβλεψη φορτίου, τα δίκτυα LSTM είναι ιδιαίτερα κατάλληλα για τη σύλληψη των μακροπρόθεσμων εξαρτήσεων στα δεδομένα, όπως τα εβδομαδιαία και εποχιακά μοτίβα, τα οποία μπορεί να είναι σημαντικά για ακριβείς προβλέψεις φορτίου. Η πρόβλεψη φορτίου με χρήση δικτύων LSTM περιλαμβάνει την εκπαίδευση ενός μοντέλου σε ιστορικά δεδομένα φορτίου και άλλους παράγοντες, όπως δεδομένα καιρού, και στη συνέχεια τη δημιουργία μιας ακολουθίας προβλέψεων για το μελλοντικό φορτίο. Το μοντέλο εκπαιδεύεται σε ένα σύνολο εκπαίδευσης με ιστορικά δεδομένα και στη συνέχεια αξιολογείται σε ένα ξεχωριστό σύνολο επικύρωσης για να διασφαλιστεί ότι είναι σε θέση να γενικεύσει σε νέα δεδομένα [25], [26].

3.5 Βασικές υπερπαράμετροι

Τα νευρωνικά δίκτυα είναι ένα ισχυρό εργαλείο μηχανικής μάθησης που μπορεί να μάθει πολύπλοκα μοτίβα και σχέσεις στα δεδομένα. Ωστόσο, διαθέτουν αρκετές υπερπαραμέτρους που πρέπει να οριστούν πριν από την εκπαίδευση του μοντέλου. Αυτές οι υπερπαραμέτροι μπορούν να επηρεάσουν σημαντικά την ακρίβεια και τη δυνατότητα γενίκευσης του μοντέλου. Σε αυτή την ενότητα θα δοθεί μια επισκόπηση των βασικών υπερπαραμέτρων των νευρωνικών δικτύων και πώς μπορούν να ρυθμιστούν για να βελτιωθεί η απόδοση του μοντέλου. Με βάση την βιβλιογραφία, παρουσιάζονται οι βασικές υπερπαραμέτροι [27], [28] :

- Αριθμός κρυφών στρωμάτων (hidden units) : Ο αριθμός των κρυφών στρωμάτων σε ένα νευρωνικό δίκτυο έχει να κάνει με τον αριθμό των νευρώνων μέσα σε ένα κρυμμένο επίπεδο. Αυτά τα κρυμμένα επίπεδα βρίσκονται ανάμεσα στο επίπεδο εισόδου και στο επίπεδο εξόδου του δικτύου. Αυτός ο αριθμός των κρυφών στρωμάτων καθορίζει την πολυπλοκότητα του μοντέλου και το επίπεδο αφαίρεσης που μπορεί να επιτύχει το δίκτυο. Ένας μεγαλύτερος αριθμός κρυφών στρωμάτων μπορεί να επιτρέψει στο μοντέλο να συλλάβει πιο σύνθετες σχέσεις στα δεδομένα, αλλά μπορεί επίσης να αυξήσει τον κίνδυνο

υπερπροσαρμογής των δεδομένων. Ένας μικρότερος αριθμός κρυφών στρωμάτων μπορεί να καταστήσει το μοντέλο απλούστερο και αποτελεσματικότερο, αλλά μπορεί να οδηγήσει σε υποπροσαρμογή των δεδομένων. Η επιλογή του βέλτιστου αριθμού κρυφών στρωμάτων είναι ένα κρίσιμο βήμα στον σχεδιασμό ενός νευρωνικού δικτύου.

- **Ρυθμός μάθησης (Learning Rate)** : Ο ρυθμός μάθησης καθορίζει το μέγεθος του βήματος που κάνει το μοντέλο για την ενημέρωση των συντελεστών βαρύτητας που συνδέουν δύο κόμβους. Ένας υψηλότερος ρυθμός μάθησης μπορεί να επιτρέψει στο μοντέλο να συγκλίνει ταχύτερα, αλλά μπορεί επίσης να οδηγήσει σε ταλάντωση και απόκλιση του αλγορίθμου. Ένας χαμηλότερος ρυθμός μάθησης μπορεί να κάνει το μοντέλο πιο σταθερό, αλλά μπορεί επίσης να οδηγήσει σε αργή σύγκλιση του αλγορίθμου και να οδηγήσει σε τοπικά βέλτιστα, επειδή το δίκτυο μπορεί να μην κάνει επαρκώς μεγάλα βήματα κατά την ενημέρωση των παραμέτρων του για να βγει από την τοπική περιοχή του χώρου των παραμέτρων. Επομένως, το δίκτυο μπορεί να κολλήσει σε μία τοπικά βέλτιστη λύση και να μην είναι σε θέση να εντοπίσει την ολικά βέλτιστη λύση. Η επιλογή του βέλτιστου ρυθμού μάθησης είναι σημαντική για να εξασφαλιστεί η αποτελεσματική και σταθερή εκπαίδευση του νευρωνικού δικτύου.
- **Αριθμός εποχών (epochs)** : Οι εποχές είναι μια άλλη σημαντική υπερπαραμέτρος στα νευρωνικά δίκτυα. Ο αριθμός των εποχών καθορίζει πόσες φορές το μοντέλο θα δει ολόκληρο το σύνολο των δεδομένων κατά τη διάρκεια της διαδικασίας εκπαίδευσης. Ο βέλτιστος αριθμός εποχών μπορεί να εξαρτάται από την πολυπλοκότητα του προβλήματος, το μέγεθος του συνόλου δεδομένων και τις επιλεγμένες υπερπαραμέτρους. Για τον προσδιορισμό του βέλτιστου αριθμού εποχών, αποτελεί κοινή πρακτική η παρακολούθηση της απόδοσης του μοντέλου σε ένα σύνολο μάθησης (training set) κατά τη διάρκεια της εκπαίδευσης και η διακοπή της όταν η απόδοση στο σύνολο μάθησης (training set) αρχίζει να μειώνεται.
- **Συνάρτηση ενεργοποίησης (Activation Function)** : Η συνάρτηση ενεργοποίησης αποφασίζει αν ένας νευρώνας πρέπει να ενεργοποιηθεί ή όχι. Αυτό σημαίνει ότι θα αποφασίσει αν η είσοδος του νευρώνα στο δίκτυο είναι σημαντική ή όχι στην διαδικασία της πρόβλεψης, χρησιμοποιώντας μαθηματικές πράξεις. Υπάρχουν διάφορες συναρτήσεις ενεργοποίησης που μπορούν να χρησιμοποιηθούν, όπως η σιγμοειδής (sigmoid) και η υπερβολική εφαπτομένη (tanh). Η επιλογή της συνάρτησης ενεργοποίησης μπορεί να έχει σημαντικό αντίκτυπο στην απόδοση του νευρωνικού δικτύου, καθώς διαφορετικές συναρτήσεις ενεργοποίησης μπορούν να αποτυπώσουν διαφορετικούς τύπους μη γραμμικών σχέσεων στα δεδομένα.
- **Μέγεθος παρτίδας (batch size)**: Το μέγεθος της παρτίδας αφορά τον αριθμό των δεδομένων εκπαίδευσης που χρησιμοποιούνται σε κάθε ενημέρωση των βαρών του δικτύου. Η εκπαίδευση, λοιπόν, μπορεί να γίνει με παρτίδες αντί για όλα τα δεδομένα ταυτόχρονα, προκειμένου να βελτιστοποιηθεί ο υπολογιστικός χρόνος και η μνήμη.
- **Κανονικοποίηση (Regularization)** : Ένας τρόπος για να μειωθεί η υπερπροσαρμογή του μοντέλου είναι να προστεθεί ένας όρος κανονικοποίησης στα κριτήρια εκπαίδευσης. Συγκεκριμένα, οι τεχνικές κανονικοποίησης αποτρέπουν την υπερβολική προσαρμογή στα δεδομένα εισόδου, προσφέροντας ομοιογένεια ως προς τις μονάδες μέτρησης και το εύρος των πιθανών τιμών. Έτσι, με την εισαγωγή πρόσθετων περιορισμών στα βάρη και τις

πολώσεις των κόμβων επιτυγχάνεται εκπαίδευση σε ένα πιο «αμερόληπτο» σύνολο δεδομένων εισόδου. Η επιλογή της τεχνικής κανονικοποίησης μπορεί να εξαρτάται από την πολυπλοκότητα του προβλήματος και το μέγεθος του συνόλου δεδομένων.

Ο συντονισμός υπερπαραμέτρων είναι η διαδικασία επιλογής των βέλτιστων υπερπαραμέτρων για ένα δεδομένο πρόβλημα. Υπάρχουν διάφορες τεχνικές που μπορούν να χρησιμοποιηθούν για τον συντονισμό υπερπαραμέτρων, όπως η αναζήτηση πλέγματος (grid search), η τυχαία αναζήτηση (random search) και η βελτιστοποίηση κατά Bayes (Bayesian optimization). Η αναζήτηση πλέγματος περιλαμβάνει τον καθορισμό ενός πλέγματος τιμών υπερπαραμέτρων και την αξιολόγηση της απόδοσης του μοντέλου για κάθε διαφορετικό συνδυασμό υπερπαραμέτρων. Η τυχαία αναζήτηση περιλαμβάνει την τυχαία δειγματοληψία τιμών υπερπαραμέτρων από ένα δεδομένο εύρος και την αξιολόγηση της απόδοσης του μοντέλου για κάθε σύνολο υπερπαραμέτρων. Η βελτιστοποίηση κατά Bayes περιλαμβάνει τη χρήση πιθανοτικών μοντέλων για την καθοδήγηση της αναζήτησης των βέλτιστων υπερπαραμέτρων.

Συμπερασματικά, η επιλογή των κατάλληλων υπερπαραμέτρων είναι κρίσιμη για την ανάπτυξη ακριβών και γενικεύσιμων μοντέλων νευρωνικών δικτύων. Ο συντονισμός των υπερπαραμέτρων μπορεί να είναι υπολογιστικά δαπανηρός και χρονοβόρος, ιδίως για μεγάλα σύνολα δεδομένων και πολύπλοκα μοντέλα. Για την αντιμετώπιση αυτής της πρόκλησης, έχουν αναπτυχθεί διάφορες αυτοματοποιημένες τεχνικές συντονισμού υπερπαραμέτρων, όπως το AutoML και η αναζήτηση νευρωνικής αρχιτεκτονικής. Αυτές οι τεχνικές χρησιμοποιούν αλγορίθμους μηχανικής μάθησης για την αυτοματοποίηση της διαδικασίας συντονισμού υπερπαραμέτρων και επιλογής μοντέλων [29]. Το AutoML, για παράδειγμα, είναι ένα εργαλείο λογισμικού που αυτοματοποιεί όλες τις διαδικασίες της μηχανικής μάθησης, από την προ-επεξεργασία δεδομένων έως την επιλογή μοντέλου και τον συντονισμό υπερπαραμέτρων. Η αναζήτηση νευρωνικής αρχιτεκτονικής είναι μια τεχνική που χρησιμοποιεί αλγορίθμους μηχανικής μάθησης για την αυτόματη σχεδίαση της βέλτιστης αρχιτεκτονικής των νευρωνικών δικτύων. Ο συντονισμός υπερπαραμέτρων είναι ένας ενεργός τομέας έρευνας στον τομέα της μηχανικής μάθησης. Αρκετές πρόσφατες μελέτες έχουν δείξει ότι ο συντονισμός υπερπαραμέτρων μπορεί να βελτιώσει σημαντικά την απόδοση των νευρωνικών δικτύων. Εκτός από τη βελτίωση της απόδοσης των νευρωνικών δικτύων, η ρύθμιση των υπερπαραμέτρων μπορεί επίσης να οδηγήσει σε μοντέλα που είναι πιο ερμηνεύσιμα και που μπορούν να γενικευτούν σε πολλές περιπτώσεις, αλλά και σε πιο ευσταθή δίκτυα, μειώνοντας την ευαισθησία του μοντέλου [30].

ΚΕΦΑΛΑΙΟ 4^ο ΔΕΔΟΜΕΝΑ

4.1 Επιλογή δεδομένων

Τα τελευταία χρόνια, η χρήση μοντέλων μηχανικής μάθησης για τη βραχυπρόθεσμη πρόβλεψη της οικιακής ζήτησης ηλεκτρικής ενέργειας έχει γίνει όλο και πιο δημοφιλής. Τα αναδρομικά νευρωνικά δίκτυα (RNN) είναι ιδιαίτερα κατάλληλα για το έργο αυτό, ωστόσο, η επιλογή των κατάλληλων δεδομένων για την εκπαίδευση αυτών των μοντέλων είναι ζωτικής σημασίας για την απόδοση τους.

Υπάρχουν διάφοροι παράγοντες που πρέπει να ληφθούν υπόψη κατά την επιλογή των δεδομένων, όπως η διαθεσιμότητα, η αντιπροσωπευτικότητα, και η ποιότητα των δεδομένων. Σε γενικές γραμμές, τα δεδομένα πρέπει να είναι καλής ποιότητας, χωρίς πολλές ελλιπείς μετρήσεις είτε λανθασμένες μετρήσεις, να καλύπτουν ένα αντιπροσωπευτικό εύρος προτύπων ζήτησης ηλεκτρικής ενέργειας και να διαθέτουν επαρκή αριθμό δεδομένων για την αποδοτική εκπαίδευση του μοντέλου.

Μια δημοφιλής προσέγγιση για την επιλογή δεδομένων είναι η χρήση δημοσίως διαθέσιμων συνόλων δεδομένων που έχουν σχεδιαστεί ειδικά για την πρόβλεψη της ζήτησης ηλεκτρικής ενέργειας. Αυτά τα σύνολα δεδομένων, έχουν συλλεχθεί από έξυπνους μετρητές και άλλες πηγές. Για τους σκοπούς της παρούσας εργασίας, η επιλογή των δεδομένων πραγματοποιήθηκε από την Pecan Street, έναν ερευνητικό οργανισμό που συλλέγει δεδομένα χρήσης ενέργειας από κατοικίες στις Ηνωμένες Πολιτείες. Η ερευνητική τεχνογνωσία της Pecan Street γεννήθηκε στη γειτονιά Mueller του Austin, όπου εξοπλίστηκαν υφιστάμενες κατοικίες με προηγμένους μετρητές κατανάλωσης ενέργειας. Από το 2009, το δίκτυο των εθελοντών καταναλωτών έχει αυξηθεί σε αριθμό και γεωγραφία, καθώς και σε ερευνητικό πεδίο και τεχνογνωσία. Το ερευνητικό δίκτυο περιλαμβάνει ενεργούς συμμετέχοντες, συμπεριλαμβανομένων χρηστών ηλιακών πάνελ και ιδιοκτητών ηλεκτρικών οχημάτων. Η παραγωγή και η χρήση ενέργειας κάθε κατοικίας μετριέται σε διαστήματα που κυμαίνονται από ένα δευτερόλεπτο έως 15 λεπτά και οι συμμετέχοντες μπορούν να έχουν πρόσβαση στις μετρήσεις με ασφάλεια μέσω μιας εφαρμογής τηλεφώνου ή ενός προγράμματος περιήγησης [31]. Το σύνολο των δεδομένων του συγκεκριμένου οργανισμού είναι ιδιαίτερα κατάλληλο για την εκπαίδευση μοντέλων πρόβλεψης οικιακών φορτίων για διάφορους λόγους:

- Μέγεθος και ποικιλομορφία: Το σύνολο δεδομένων Pecan Street είναι εκτεταμένο, παρέχοντας μεγάλο όγκο δεδομένων από διάφορα νοικοκυριά. Αυτό το μέγεθος και η ποικιλομορφία επιτρέπουν την εκπαίδευση ισχυρών μοντέλων που μπορούν να γενικεύσουν ικανοποιητικά σε διαφορετικά νοικοκυριά και πρότυπα χρήσης.
- Υψηλή ανάλυση: Το σύνολο δεδομένων είναι υψηλής ανάλυσης, παρέχοντας δεδομένα κατανάλωσης από δευτερόλεπτα μέχρι και ανά 15 λεπτά. Αυτό το επίπεδο λεπτομέρειας επιτρέπει ακριβέστερη και λεπτομερέστερη μοντελοποίηση.

- Πολυδιάστατα χαρακτηριστικά: Το σύνολο δεδομένων περιλαμβάνει διάφορα χαρακτηριστικά, όπως η χρήση ενέργειας από διάφορες συσκευές, η παραγωγή ηλιακών συλλεκτών, τα δεδομένα ηλεκτρικών οχημάτων και άλλα. Αυτά τα ποικίλα χαρακτηριστικά μπορούν να επιτρέψουν τη δημιουργία σύνθετων μοντέλων που λαμβάνουν υπόψη πολλαπλές πτυχές της χρήσης ενέργειας.
- Διαχρονικά δεδομένα: Το σύνολο δεδομένων περιλαμβάνει μακροπρόθεσμα χρονικά δεδομένα, τα οποία είναι ζωτικής σημασίας για τη δημιουργία μοντέλων που κατανοούν χρονικά εξαρτώμενα μοτίβα, όπως τα μοντέλα πρόβλεψης φορτίου.
- Δεδομένα πραγματικού κόσμου: Τα δεδομένα συλλέγονται από πραγματικά νοικοκυριά, καθιστώντας τα αντιπροσωπευτικά των προτύπων κατανάλωσης ενέργειας στον πραγματικό κόσμο. Αυτό μπορεί να οδηγήσει σε μοντέλα που είναι πιο πρακτικά και εφαρμόσιμα σε σενάρια του πραγματικού κόσμου.
- Διαθεσιμότητα: Το σύνολο δεδομένων είναι δημόσια διαθέσιμο, γεγονός που καθιστά εύκολη την πρόσβαση και τη χρήση του για την εκπαίδευση μοντέλων νευρωνικών δικτύων.
- Προηγούμενη εμπειρία: Υπήρχε γνώση εντός της εργαστηριακής ομάδας από την συγκεκριμένη βάση δεδομένων.

Αυτά τα χαρακτηριστικά καθιστούν το σύνολο δεδομένων Pecan Street έναν πολύτιμο πόρο για την εκπαίδευση μοντέλων νευρωνικών δικτύων που σχετίζονται με την κατανάλωση ενέργειας, την πρόβλεψη φορτίου, την παραγωγή ηλιακής ενέργειας και άλλα. Ερευνητές από όλο τον κόσμο έχουν χρησιμοποιήσει τα δεδομένα της Pecan Street για να δημοσιεύσουν πάνω από 500 εργασίες σε θέματα που κυμαίνονται από τη φόρτιση ηλεκτρικών οχημάτων και την αποθήκευση ενέργειας έως την ηλιακή ενέργεια και την τιμολόγηση της ηλεκτρικής ενέργειας [32]. Ωστόσο, είναι επίσης σημαντικό να σημειωθεί ότι, όπως και με κάθε σύνολο δεδομένων, χρειάστηκε προσεκτική προεπεξεργασία και επιλογή χαρακτηριστικών για να διασφαλιστεί η βέλτιστη απόδοση του μοντέλου.

Συγκριτικά, παρόλο που το σύνολο δεδομένων Pecan Street έχει πολλά πλεονεκτήματα, δεν είναι το μόνο σύνολο δεδομένων που είναι διαθέσιμο για την πρόβλεψη της ζήτησης ηλεκτρικής ενέργειας. Άλλα σύνολα δεδομένων, όπως τα σύνολα δεδομένων LV και HV του UK Power Networks, το REDD και το GEFCom, έχουν επίσης χρησιμοποιηθεί ευρέως στη βιβλιογραφία. Κάθε ένα από αυτά τα σύνολα δεδομένων έχει τα δικά του πλεονεκτήματα και μειονεκτήματα.

Τα σύνολα δεδομένων LV και HV των UK Power Networks περιέχουν δεδομένα που συλλέγονται από έξυπνους μετρητές στο Ηνωμένο Βασίλειο, παρέχοντας ένα αντιπροσωπευτικό δείγμα των οικιακών και εμπορικών προτύπων κατανάλωσης ενέργειας. Ωστόσο, τα δεδομένα συλλέγονται σε χαμηλότερη ανάλυση από το σύνολο δεδομένων της Pecan Street και δεν περιλαμβάνουν δεδομένα σε επίπεδο συσκευής, περιορίζοντας τη χρησιμότητά τους για την πρόβλεψη της χρήσης συγκεκριμένων συσκευών.

Το REDD είναι ένα δημόσια διαθέσιμο σύνολο δεδομένων που περιέχει δεδομένα χρήσης ηλεκτρικής ενέργειας από έξι σπίτια στις ΗΠΑ. Το σύνολο δεδομένων περιέχει δεδομένα σε

επίπεδο συσκευής και περιλαμβάνει καιρικά δεδομένα, καθιστώντας το κατάλληλη επιλογή για μοντέλα πρόβλεψης της ζήτησης ηλεκτρικής ενέργειας με βάση το RNN. Ωστόσο, το σύνολο δεδομένων είναι σχετικά μικρό σε σύγκριση με το σύνολο δεδομένων Pecan Street, περιορίζοντας τη χρησιμότητά του για την εκπαίδευση μεγάλων μοντέλων.

4.2 Ανάλυση δεδομένων

Στο πλαίσιο της παρούσας διπλωματικής εργασίας, χρησιμοποιούνται δεδομένα από τη βάση του Pecan Street για τρεις περιοχές των ΗΠΑ: την Καλιφόρνια, το Τέξας και τη Νέα Υόρκη. Σε κάθε περιοχή, έχουν συλλεχθεί δεδομένα σχετικά με την ηλεκτρική κατανάλωση διάφορων οικιακών συσκευών. Αυτά τα δεδομένα παρουσιάζουν εξαιρετικό ενδιαφέρον, καθώς παρέχουν πολύτιμες πληροφορίες για την ενεργειακή συμπεριφορά των νοικοκυριών σε αυτές τις περιοχές. Αναλυτικότερα:

- Για την περιοχή του Τέξας, τα δεδομένα καλύπτουν 25 κατοικίες και έχουν συλλεχθεί για διάστημα ενός έτους (2018), με μέτρηση κάθε 15 λεπτά. Τα δεδομένα αυτά αποκαλύπτουν πολύτιμες πληροφορίες για το πώς οι κάτοικοι του Τέξας χρησιμοποιούν την ενέργειά τους.
- Στην Καλιφόρνια, τα δεδομένα καλύπτουν 23 κατοικίες και έχουν συλλεχθεί για διάστημα ενός έτους (2014), με μέτρηση κάθε 15 λεπτά. Τα δεδομένα αυτά είναι πολύτιμα για την κατανόηση των ενεργειακών προτύπων των κατοίκων της Καλιφόρνιας.
- Στη Νέα Υόρκη, τα δεδομένα καλύπτουν 25 κατοικίες και έχουν συλλεχθεί για διάστημα έξι μηνών, από τον Μάιο μέχρι και τον Οκτώβρη του 2019, με μέτρηση κάθε 15 λεπτά. Παρόλο που το χρονικό διάστημα είναι μικρότερο σε σχέση με τις άλλες δύο περιοχές, τα δεδομένα αυτά είναι εξίσου σημαντικά για την κατανόηση της ενεργειακής κατανάλωσης στη Νέα Υόρκη.

Πίνακας 4.1 : Διαθέσιμα Δεδομένα από Pecan Street

Περιοχή	Σύνολο Δεδομένων	Πλήθος Κατοικιών	Χρονική Περίοδος	
			Από	Έως
Τέξας	873.286	25	1/1/18	31/12/18
Καλιφόρνια	805.524	23	1/1/14	31/12/14
Νέα Υόρκη	441.599	25	1/5/19	31/10/19

Τα συγκεκριμένα δεδομένα είναι σημαντικά, καθώς επιτρέπουν να κατανοηθεί η ενεργειακή κατανάλωση ηλεκτρικών οικιακών συσκευών των τριών διαφορετικών περιοχών. Συγκεκριμένα μπορεί να εξεταστεί ποιες οικιακές συσκευές χρησιμοποιούν περισσότερη ενέργεια, ποιες ώρες της ημέρας έχουν την μεγαλύτερη κατανάλωση ενέργειας, και πώς αυτά τα πρότυπα κατανάλωσης μπορεί να διαφέρουν ανάλογα με την περιοχή.

Δεδομένου ότι υπάρχουν διαθέσιμα δεδομένα για πολλές διαφορετικές ηλεκτρικές συσκευές, επιλέχθηκαν οι πιο ενεργειακά σημαντικές για την ανάλυση και την δημιουργία του μοντέλου. Συγκεκριμένα αναλύθηκαν: το κλιματιστικό, το ψυγείο, το ηλεκτρικό όχημα, το πλυντήριο πιάτων, το στεγνωτήριο, ο θερμοσίφοντας και το φωτοβολταϊκό πάνελ. Επίσης λήφθηκε υπόψη η συνολική κατανάλωση ανά κατοικία που δινόταν για κάθε περιοχή με την επωνυμία “δίκτυο”.

4.3 Επεξεργασία δεδομένων

Η επεξεργασία των δεδομένων αφορά κυρίως την εκπαίδευση του μοντέλου LSTM και περιλάμβανε διάφορες διαδικασίες. Αυτή η επεξεργασία είναι σημαντική για τη βελτιστοποίηση της εκπαίδευσης του μοντέλου και την επίτευξη καλύτερων αποτελεσμάτων πρόβλεψης. Στην ενότητα αυτή, περιγράφεται η διαδικασία επεξεργασίας των δεδομένων.

Κατά την επεξεργασία ενός συνόλου δεδομένων με ηλεκτρικές καταναλώσεις για την υλοποίηση ενός κώδικα πρόβλεψης μελλοντικών καταναλώσεων, υπάρχουν μερικές πιθανές και βοηθητικές επεξεργασίες που μπορούν να γίνουν. Ορισμένες από αυτές περιλαμβάνουν:

- Την μετατροπή των τύπων δεδομένων: Στήλες με ημερομηνίες, ώρες και ηλεκτρικές καταναλώσεις έχουν τους κατάλληλους τύπους δεδομένων. Οι ημερομηνίες και οι ώρες πρέπει να μετατραπούν σε αντίστοιχους τύπους (π.χ. `datetime`), ενώ οι ηλεκτρικές καταναλώσεις πρέπει να είναι αριθμητικές τιμές.
- Την εξερεύνηση και τον καθαρισμό των δεδομένων: Κατά την εξερεύνηση ενός συνόλου δεδομένων ελέγχεται η έλλειψη μετρήσεων (ύπαρξη `NaN` τιμών) ή διπλότυπων τιμών. Απουσιάζουσες τιμές μπορούν να αντιμετωπιστούν είτε με απόρριψη των δεδομένων της αντίστοιχης ημέρας είτε με αναπλήρωση τους με διάφορες μεθόδους.
- Κανονικοποίηση δεδομένων: Ανάλογα με τον αλγόριθμο πρόβλεψης, ενδέχεται να χρειαστεί να κανονικοποιηθούν τα δεδομένα ώστε να έρθουν σε ένα καθορισμένο εύρος τιμών, όμοιο ανεξαρτήτως της συσκευής κατανάλωσης.
- Εξαγωγή χαρακτηριστικών: Μπορούν κατά την διαδικασία της προ-επεξεργασίας να εξαχθούν χρήσιμα χαρακτηριστικά από τα δεδομένα, όπως η μέση ηλεκτρική κατανάλωση ανά μήνα ή η τάση της κατανάλωσης στη διάρκεια του χρόνου.

Με βάση και τα παραπάνω, αρχικά πραγματοποιήθηκε μετατροπή του τύπου των δεδομένων, για τις στήλες της ημερομηνίας και της ώρας των ηλεκτρικών καταναλώσεων. Συγκεκριμένα, η μετατροπή του τύπου δεδομένων της ώρας και ημερομηνίας σε `datetime` είναι συχνά απαραίτητη για να επιτραπεί η επεξεργασία και η ανάλυση των χρονοσειρών αλλά και η αποκωδικοποίηση των χρονικών πληροφοριών. Με τη μετατροπή σε `datetime`, μπορούν για παράδειγμα να εκτελεστούν αριθμητικές επεξεργασίες μεταξύ χρονικών διαστημάτων, όπως ο υπολογισμός μέσης τιμής ή συνολικού αθροίσματος ενός χρονικού διαστήματος.

Κατά τη διάρκεια της εξερεύνησης των δεδομένων, παρατηρήθηκαν λανθασμένες τιμές κατανάλωσης για ορισμένες ηλεκτρικές συσκευές, που αφορούσαν κυρίως αρνητικές

καταναλώσεις. Για να αποφευχθούν προβλήματα κατά την εκπαίδευση του μοντέλου, εφαρμόστηκε γραμμική παρεμβολή, όπου αντικαταστάθηκαν οι αρνητικές τιμές με αντίστοιχες θετικές τιμές που προκύπτουν από τις πλησιέστερες «φυσιολογικές» καταναλώσεις. Ταυτόχρονα, πραγματοποιήθηκε αντικατάσταση με την μέθοδο της γραμμικής παρεμβολής των πολύ μικρών καταναλώσεων, μικρότερων των 0,05 kW. Αυτό πραγματοποιήθηκε προκειμένου να αφαιρεθούν τυχόν «θόρυβοι» ή αστάθειες στα δεδομένα κατανάλωσης που μπορεί να επηρεάσουν την εκπαίδευση και συνεπώς την πρόβλεψη του μοντέλου. Επομένως, με την αφαίρεση αυτών των πολύ μικρών καταναλώσεων, το μοντέλο εστιάζει στις πιο σημαντικές ενεργειακές καταναλώσεις, υποβοηθώντας έτσι την ικανότητα πρόβλεψης.

Έπειτα, πραγματοποιήθηκε κανονικοποίηση των δεδομένων, με χρήση της εντολής MinMaxScaler της Python. Η κανονικοποίηση των δεδομένων οριοθετεί τις τιμές των χαρακτηριστικών σε ένα ορισμένο εύρος και μπορεί να βοηθήσει στην ταχύτερη σύγκλιση του μοντέλου κατά τη διάρκεια της εκπαίδευσης. Αυτό συμβαίνει διότι οι αλγόριθμοι βελτιστοποίησης εργάζονται καλύτερα με μικρότερες τιμές. Επιπρόσθετα, μπορεί να βοηθήσει στην αποφυγή προβλημάτων αστάθειας κατά την εκπαίδευση των νευρωνικών δικτύων, μειώνοντας τις διακυμάνσεις στα δεδομένα. Συγκεκριμένα, όταν τα χαρακτηριστικά έχουν διαφορετικά εύρη, ορισμένα χαρακτηριστικά με μεγάλες τιμές μπορεί να επηρεάσουν υπερβολικά την εκπαίδευση, ενώ τα χαρακτηριστικά με μικρές τιμές μπορεί να μην έχουν σημασία. Η κανονικοποίηση βοηθάει στην εξισορρόπηση αυτής της ανισορροπίας και μπορεί να βελτιώσει την ακρίβεια του μοντέλου. Επιπρόσθετα, η κανονικοποίηση των δεδομένων μπορεί να μειώσει την επίδραση των ακραίων τιμών στην εκπαίδευση. Ακραίες τιμές σε ένα χαρακτηριστικό μπορεί να επηρεάσουν αρνητικά την απόδοση του μοντέλου, καθώς μπορεί να παραπλανήσουν την εκπαίδευση και να προκαλέσουν υπερπροσαρμογή (overfitting). Η κανονικοποίηση μπορεί να μειώσει αυτήν την επίδραση και να καταστήσει το μοντέλο πιο ανθεκτικό σε ακραίες τιμές [32].

Τέλος, τα δεδομένα ομαδοποιήθηκαν με τρόπο τέτοιο ώστε να βοηθιέται η εκπαίδευση του μοντέλου. Συγκεκριμένα, υπολογίστηκε η αθροιστική κατανάλωση των επιλεγμένων ηλεκτρικών συσκευών μεμονωμένα, συλλέγοντας τα επεξεργασμένα δεδομένα όλων των κατοικιών, ανά περιοχή μελέτης. Συνολικά, η προ-επεξεργασία δεδομένων που πραγματοποιήθηκε συμβάλλει στη βελτίωση της ακρίβειας και της απόδοσης του μοντέλου στην πρόβλεψη ηλεκτρικής ζήτησης. Επιτυγχάνεται έτσι μια πιο αξιόπιστη και αποτελεσματική εκπαίδευση του μοντέλου, παρέχοντας «καθαρότερα» δεδομένα και μια πιο σταθερή και αμερόληπτη εκπαίδευση.

ΚΕΦΑΛΑΙΟ 5^ο

ΜΟΝΤΕΛΟ

5.1 Εισαγωγή

Στο κεφάλαιο αυτό παρουσιάζεται το μοντέλο βραχυπρόθεσμης πρόβλεψης φορτίου (STLF) οικιακών συσκευών. Η ακριβής πρόβλεψη φορτίου είναι κρίσιμη για την ηλεκτρική ενέργεια, για διάφορες λειτουργίες της αγοράς και εργασίες λήψης αποφάσεων σε πραγματικό χρόνο στα συστήματα ηλεκτρικής ενέργειας. Το συγκεκριμένο μοντέλο, επικεντρώνεται στη βραχυπρόθεσμη πρόβλεψη φορτίου, η οποία αποσκοπεί στην βραχυπρόθεσμη εκτίμηση της ηλεκτρικής κατανάλωσης διάφορων οικιακών συσκευών.

Αρκετές ερευνητικές εργασίες, σχετικές με την βραχυπρόθεσμη πρόβλεψη φορτίου, επικεντρώνονται κυρίως στην πρόβλεψη του συγκεντρωτικού (αθροιστικού) φορτίου είτε για ένα σύστημα τροφοδοσίας είτε για ένα μεμονωμένο πελάτη, ενώ λιγότερες κάνουν προσπάθειες για την πρόβλεψη του φορτίου σε επίπεδο μεμονωμένης συσκευής [26]. Το διαφορετικό, επομένως που προσδίδει το συγκεκριμένο μοντέλο, έγκειται στο γεγονός ότι επικεντρώνεται στην κατανάλωση «ευέλικτων» ηλεκτρικών συσκευών και όχι γενικά στην οικιακή κατανάλωση σε επίπεδο κατοικίας ή κοινότητας. Η ανάλυση αυτή είναι ιδιαίτερα σημαντική, καθώς βοηθάει στην δημιουργία ενός μοτίβου κατανάλωσης με αναφορά την οικιακή ηλεκτρική συσκευή.

Το κριτήριο επιλογής των οικιακών ηλεκτρικών συσκευών που μελετήθηκαν σχετίζεται με την χρησιμότητά τους ως φορτία, την συχνότητα χρήσης τους αλλά και το πλήθος των διαθέσιμων ιστορικών καταναλώσεων, προκειμένου να είναι εφικτή η εκπαίδευση του μοντέλου και η πρόβλεψη με ακρίβεια. Έτσι, επιλέγονται συσκευές όπως το ηλεκτρικό όχημα, το ψυγείο, το κλιματιστικό, το φωτοβολταϊκό πάνελ και ο θερμοσίφοντας. Ταυτόχρονα, προβλέπονται και οι συνολικές ηλεκτρικές καταναλώσεις των κατοικιών ανά περιοχή.

Όλες οι εφαρμογές του μοντέλου που ακολουθούν έγιναν σε περιβάλλον python και H/Y με τα ακόλουθα τεχνικά χαρακτηριστικά:

- Επεξεργαστής AMD Ryzen 7 – 5800H @ 3.20 GHz
- Μνήμη RAM 16 GB
- Λειτουργικό σύστημα Windows 11

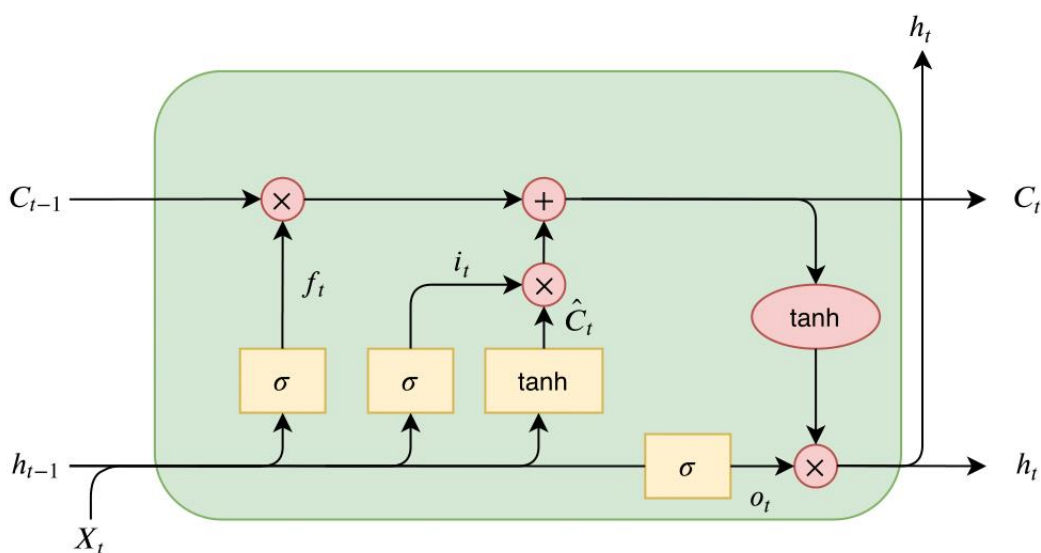
5.2 Περιγραφή μοντέλου

Ο κώδικας που παρουσιάζεται αναλύει και προβλέπει την οικιακή κατανάλωση χρησιμοποιώντας ένα μοντέλο LSTM. Βάση, αποτελεί το paper “Appliance level short term load forecasting via RNN” [26]. Η συμβολή της συγκεκριμένης εργασίας είναι τριπλή:

- Παρουσιάζεται ένας συγκεντρωτικός αλγόριθμος STLF σε επίπεδο συσκευής για οικιακά φορτία χρησιμοποιώντας δεδομένα έξυπνων μετρητών.
- Το προτεινόμενο μοντέλο μπορεί να παρακολουθεί προσαρμοστικά το σφάλμα πρόβλεψης από προηγούμενα δείγματα δεδομένων, βελτιώνοντας έτσι την ακρίβεια πρόβλεψης για κάθε συσκευή.
- Χρησιμοποιούνται πραγματικά ιστορικά δεδομένα ηλεκτρικών καταναλώσεων οικιακών συσκευών.

Συγκεκριμένα, οι εισοδοί του μοντέλου είναι ιστορικά δεδομένα κατανάλωσης οικιακών συσκευών τριών (3) μηνών περιόδου Ιανουαρίου – Μαρτίου για τις περιοχές του Τέξας και της Καλιφόρνιας και Μαΐου – Ιουλίου για την περιοχή της Νέας Υόρκης, ενώ η έξοδος είναι η πρόβλεψη της οικιακής κατανάλωσης για τις επόμενες 5 ημέρες, ανά 15 λεπτά.

Κατά την επεξεργασία χρονοσειρών, χρησιμοποιείται η μονάδα LSTM. Όπως παρουσιάζεται στο Σχήμα 5.1, στη χρονική στιγμή t ενσωματώνει την προηγούμενη κρυφή κατάσταση h_{t-1} και την προηγούμενη κατάσταση του κυττάρου C_{t-1} , μαζί με την τρέχουσα είσοδο χαρακτηριστικών X_t . Η κρυφή κατάσταση εξόδου h_t της μονάδας LSTM στη χρονική στιγμή t προωθείται στη συνέχεια σε ένα πλήρως συνδεδεμένο επίπεδο και ένα επίπεδο παλινδρόμησης (για προβλέψεις χρονοσειρών) στο συνολικό δίκτυο LSTM. Επειδή η κατάσταση του κυττάρου διατηρεί πληροφορίες σε όλη την διάρκεια της ακολουθίας επεξεργασίας δεδομένων, το LSTM αντιμετωπίζει αποτελεσματικά το πρόβλημα της βραχυπρόθεσμης μνήμης που αντιμετωπίζουν τα κανονικά RNN.



Σχήμα 5.1 : Αρχιτεκτονική κυττάρου LSTM

Αν και η LSTM είναι γνωστό ότι είναι πολύ ισχυρή στην αντιμετώπιση με δεδομένα χρονοσειρών, η απλή LSTM αρχιτεκτονική δεν ενσωματώνει αποτελέσματα εξόδου για τη βελτίωση της απόδοσης πρόβλεψης. Στην πραγματικότητα, στο στάδιο της εκπαίδευσης, το σφάλμα πρόβλεψης για κάθε χρονική στιγμή περίπτωση είναι άμεσα διαθέσιμο κατά την απόκτηση της τιμής

πρόβλεψης. Καθώς πραγματοποιούνται περισσότερες προβλέψεις, περισσότερα ιστορικά σύνολα δεδομένων (είσοδος, ακολουθίες και τα αντίστοιχα σφάλματα) καθίστανται διαθέσιμα, τα οποία μπορούν να παράσχουν πρόσθετες πληροφορίες για τη βελτίωση περαιτέρω της ακρίβειας των προβλέψεων. Προκειμένου να ενσωματωθεί μια διαδικασία μάθησης που χρησιμοποιεί το σφάλμα πρόβλεψης και τα χαρακτηριστικά εισόδου, υλοποιείται ένα επαυξημένο μοντέλο LSTM το οποίο διαθέτει ένα πρόσθετο νευρωνικό δίκτυο ANN που προσαρμόζεται και μαθαίνει τη σύνδεση μεταξύ της επαναλαμβανόμενης κατανάλωσης και των σφαλμάτων πρόβλεψης. Συνοπτικά, πραγματοποιήθηκε η προ-επεξεργασία των δεδομένων προκειμένου να μπορεί να εκπαιδευτεί αποδοτικά το μοντέλο. Στη συνέχεια, η μοντελοποίηση του επαυξημένου μοντέλου LSTM δομήθηκε γύρω από τις εξής κύριες λειτουργίες:

- Ορίζονται οι βασικοί παράμετροι LSTM και οι συναρτήσεις ενεργοποίησης για κάθε επίπεδο.
- Εκπαιδεύεται το μοντέλο LSTM χρησιμοποιώντας τα επεξεργασμένα δεδομένα κατανάλωσης.
- Αξιολογείται η απόδοση του μοντέλου, υπολογίζοντας κριτήρια ακρίβειας (σφάλματα), τα οποία προσδιορίζουν το πόσο αποδοτικά προβλέπει το μοντέλο.
- Υλοποιείται ένα πρόσθετο νευρωνικό δίκτυο, το οποίο χρησιμοποιεί ως είσοδο τα σφάλματα αυτά και προβλέπει εκ νέου τις ηλεκτρικές καταναλώσεις. Η πρόβλεψη αυτή αναλογεί στην "διόρθωση" των προβλέψεων του μοντέλου LSTM.
- Το πρόσθετο μοντέλο ANN έχει δικά του επίπεδα νευρώνων, τις αντίστοιχες συναρτήσεις ενεργοποίησης και τη συγκεκριμένη αρχιτεκτονική που ορίζεται στον κώδικα παρακάτω.

Συνολικά, το ενισχυμένο μοντέλο ANN βελτιώνει τις προβλέψεις του μοντέλου LSTM, λαμβάνοντας υπόψη πρόσθετα μοτίβα και πληροφορίες από τα δεδομένα, προσφέροντας έτσι μεγαλύτερη ακρίβεια και αξιοπιστία στις προβλέψεις της οικιακής κατανάλωσης. Στη συνέχεια περιγράφεται αναλυτικότερα η δομή του μοντέλου, οι βασικές συναρτήσεις και τα δεδομένα εισόδου κι εξόδου.

5.3 Δομή μοντέλου

5.3.1 Κύριος κώδικας

Το κύριο μέρος του κώδικα εκτελεί μια σειρά εργασιών για την εκπαίδευση και την πρόβλεψη της κατανάλωσης μιας συσκευής χρησιμοποιώντας ένα μοντέλο LSTM και ένα μοντέλο ANN. Συγκεκριμένα:

- Ορίζονται οι βασικοί παράμετροι των μοντέλων, όπως αυτές υποδεικνύονται και από το [26]. Συγκεκριμένα ο αριθμός των κρυφών μονάδων (hidden units) ίσος με 200, ο ρυθμός

μάθησης (learning rate) ίσος με 0,0001, ο αριθμός των εποχών (epochs) ίσος με 500 και η dropout¹ ίση με 0,2.

- Εσωτερικά στον βρόχο, δημιουργείται ένα νέο μοντέλο LSTM και ένα μοντέλο ANN για κάθε επανάληψη.
- Εκπαιδεύονται τα μοντέλα LSTM και ANN χρησιμοποιώντας τα δεδομένα εισόδου και εξόδου που έχουν προετοιμαστεί.
- Οι προβλέψεις γίνονται χρησιμοποιώντας τα εκπαιδευμένα μοντέλα των δεδομένων ελέγχου.
- Οι προβλέψεις αντιστρέφονται στις αρχικές μονάδες κατανάλωσης δεδομένου ότι έχει πραγματοποιηθεί κατά την διαδικασία της προ-επεξεργασίας κανονικοποίηση των δεδομένων με την χρήση της εντολής MinMaxScaler.
- Υπολογίζονται οι μετρικές αξιολόγησης, όπως το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE) και η απόκλιση των προβλέψεων από τις πραγματικές τιμές.
- Αποθηκεύονται τα αποτελέσματα και οι γραφικές παραστάσεις σε αρχεία.
- Τα αποτελέσματα αποθηκεύονται σε ένα αρχείο Excel για εύκολη ανάγνωση και ανάλυση.

Συνολικά, το κύριο μέρος του κώδικα εκπαιδεύει και αξιολογεί τα μοντέλα πρόβλεψης κατανάλωσης οικιακών φορτίων με διάφορους συνδυασμούς παραμέτρων. Το μοντέλο LSTM αναλαμβάνει την πρόβλεψη των καταναλώσεων, ενώ το μοντέλο ANN διορθώνει τυχόν σφάλματα των προβλέψεων του LSTM. Τα αποτελέσματα αξιολόγησης αποθηκεύονται και αναλύονται για να παρέχουν πληροφορίες σχετικά με την ακρίβεια και την απόδοση των μοντέλων. Στο Σχήμα 5.2 παρουσιάζεται το κομμάτι του κυρίου μέρους του κώδικα που είναι υπεύθυνο για την προβλεπτική διαδικασία και την αποκατάσταση των κανονικοποιημένων προβλέψεων και πραγματικών δεδομένων πριν την αποθήκευσή τους. Συγκεκριμένα, υλοποιούνται προβλέψεις χρησιμοποιώντας τα μοντέλα LSTM και ANN για τα δεδομένα εισόδου (`X_metric`). Στη συνέχεια, συνδυάζονται οι προβλέψεις του μοντέλου LSTM και του ANN, προσθέτοντας τις αντίστοιχες προβλέψεις, και αποθηκεύει το αποτέλεσμα στη μεταβλητή `y_pred`. Τέλος, γίνεται αποκατάσταση των κανονικοποιημένων καταναλώσεων (`rescalling`) χρησιμοποιώντας την εντολή `inverse_transform` του `scaler`.

¹ Η παράμετρος `dropout` αντιμετωπίζει την υπερεκπαίδευση με τυχαία απομάκρυνση (μηδενισμός) ενός συγκεκριμένου ποσοστού των νευρώνων εισόδου, μαζί με τις αντίστοιχες συνδέσεις τους, κατά τη διάρκεια της φάσης εκπαίδευσης.

```

for model_key, model_data in all_models.items():
    params = model_data['params']

    model_dir = f'{directory}/model_{model_key}_{params}'

    for run_num, model_run in enumerate(model_data['models']):

        model_lstm = model_run['model_lstm']
        model_ann = model_run['model_ann']
        model_name = model_run['name']

        # Make predictions using LSTM model
        y_pred_lstm = model_lstm.predict(X_metric)[: , 0]

        # Make predictions using ANN model
        y_correction = model_ann.predict(X_metric)[: , 0]

        y_pred = y_pred_lstm + y_correction

        # Inverse the scaling for the predictions y_pred_ann, y_test, y_pred_lstm
        y_pred = scaler_.inverse_transform(y_pred.reshape(-1, 1))
        y_test = scaler_.inverse_transform(y_metric.reshape(-1, 1))
        y_correction = scaler_.inverse_transform(y_correction.reshape(-1, 1))
        y_pred_lstm = scaler_.inverse_transform(y_pred_lstm.reshape(-1, 1))

```

Σχήμα 5.2: Κύριο μέρος κώδικα

Ταυτόχρονα, βοηθητικές συναρτήσεις, που θα αναλυθούν στην Ενότητα 5.3.2, πλαισιώνουν το κύριο μέρος του κώδικα.

5.3.2 Βασικές συναρτήσεις

Παρακάτω αναλύονται οι βασικές συναρτήσεις που χρησιμοποιούνται στον παραπάνω κώδικα και παρουσιάζονται μέρη του κώδικα με τις κύριες συναρτήσεις:

- `sanitize_filename(filename)`: Αυτή η συνάρτηση χρησιμοποιείται για να αφαιρέσει μη έγκυρους χαρακτήρες από ένα όνομα αρχείου. Αντικαθιστά τους μη έγκυρους χαρακτήρες με κάτω παύλες και συντομεύει το όνομα του αρχείου αν υπερβαίνει ένα μέγιστο μήκος.
- `MovingAverageEarlyStopping`: Αυτή η συνάρτηση υπολογίζει τον κινητό μέσο όρο του σφάλματος εκπαίδευσης και χρησιμοποιεί αυτόν τον μέσο όρο για να παρακολουθήσει τη σύγκλιση του μοντέλου. Εάν η διαφορά του μέσου όρου από την προηγούμενη εποχή είναι μικρότερη από ένα καθορισμένο κατώφλι, τότε οι επαναλήψεις συνεχίζονται. Αν η διαφορά ξεπεράσει το κατώφλι για μια συγκεκριμένη περίοδο χρόνου, το μοντέλο τερματίζεται πρόωρα.
- `process_consumption_data` : Αυτή η συνάρτηση χρησιμοποιείται για την επεξεργασία των δεδομένων κατανάλωσης και παρουσιάζεται στο Σχήμα 5.3. Συγκεκριμένα, αφαιρούνται οι στήλες που περιέχουν μόνο NaN τιμές, χρησιμοποιώντας την εντολή `dropna`. Στη συνέχεια, αντικαθίστανται οι αρνητικές και οι πολύ μικρές καταναλώσεις (<0,05kW) με NaN. Επιπλέον, η στήλη `local_15min` μετατρέπεται από συμβολοσειρά σε τύπο `datetime`, αντλώντας τον χρόνο χωρίς τα τελευταία 6 ψηφία. Τέλος, ομαδοποιούνται τα δεδομένα με βάση την ημερομηνία και αθροίζοντας τις καταναλώσεις για κάθε ημερομηνία, χρησιμοποιώντας τις εντολές `groupby` και `sum`.

```

def process_consumption_data(path: str, consumers: list) -> pd.DataFrame:
    # Read data
    df = pd.read_csv(path)

    # Drop columns with all NaN values
    df.dropna(axis=1, how='all', inplace=True)

    # Replace all consumers negative values with NaN
    for consumer in consumers:
        df[consumer] = df[consumer].apply(lambda x: np.nan if x < 0.05 else x)

    # Convert datatype from str to datetime
    df['local_15min_edited'] = df['local_15min'].str[: -6]
    df['date'] = pd.to_datetime(df['local_15min_edited'], format="%Y-%m-%d %H:%M")

    # Group for each dataid and sum (or mean) the values - sum up all dataids
    df = df.groupby('date').sum().reset_index()

    # Transform the data from wide to long format
    df = pd.melt(df, id_vars=['date'], value_vars=consumers, var_name='Consumer', value_name='Consumption')

    return df

```

Σχήμα 5.3: Συνάρτηση process_consumption_data

- process_appliance_data: Αυτή η συνάρτηση επεξεργάζεται τα δεδομένα κατανάλωσης για μία συγκεκριμένη οικιακή συσκευή. Επιλέγει τα δεδομένα για τη συσκευή αυτή, αντικαθιστά τις τιμές NaN με τη μέθοδο παρεμβολής γραμμικής παρεμβολής, επιλέγει την χρονική περίοδο εκπαίδευσης και μετατρέπει τις καταναλώσεις σε ένα συγκεκριμένο εύρος χρησιμοποιώντας τον MinMaxScaler.
- series_to_supervised: Αυτή η συνάρτηση μετατρέπει μια ακολουθία χρονοσειρών σε ένα σύνολο δεδομένων που μπορεί να χρησιμοποιηθεί για επιβλεπόμενη μάθηση σε ένα μοντέλο LSTM. Λαμβάνει ως είσοδο μια λίστα ή έναν πίνακα με παρατηρήσεις και δημιουργεί ένα πλαίσιο δεδομένων που αποτελείται από προηγούμενες (n_in) παρατηρήσεις ως είσοδο (X) και την επόμενη (n_out) παρατήρηση ως έξοδο (y).
- train_models : Αυτή η συνάρτηση εκπαιδεύει και αξιολογεί τα μοντέλα LSTM και ANN, όπως παρουσιάζεται στο Σχήμα 5.4. Συγκεκριμένα, δημιουργείται ένα σύνολο εκπαίδευσης (X_train, y_train) και ένα σύνολο ελέγχου (X_test, y_test) με χρήση της εντολής train_test_split. Στη συνέχεια, δημιουργούνται τα μοντέλα LSTM και ANN με τη χρήση της κλάσης Sequential και πραγματοποιείται η εκπαίδευσή τους με την εντολή fit χρησιμοποιώντας την moving_average_early_stopping για την σύγκλιση του μοντέλου. Τέλος, επιστρέφονται τα μοντέλα LSTM και ANN, καθώς και τα ιστορικά εκπαίδευσης και τα σφάλματα εκπαίδευσης για το μοντέλο LSTM.

```

# Create train and test sets
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.33, random_state=0)

# Create the LSTM model
model_lstm = Sequential()
model_lstm.add(LSTM(lstm_units, input_shape=(X_train.shape[1], 1), return_sequences=True))
model_lstm.add(Dropout(lstm_dropout))
model_lstm.add(Dense(1))

# Set gradient threshold and learning rate
opt = optimizers.Adam(learning_rate=lstm_learning_rate, clipnorm=lstm_clipnorm)
model_lstm.compile(loss=lstm_loss_function, optimizer=opt)

# Fit the LSTM model
history_lstm = model_lstm.fit(X_train,
                              y_train,
                              epochs=epochs_lstm,
                              batch_size=batch_size,
                              validation_data=(X_test, y_test),
                              verbose=1,
                              callbacks=[moving_average_early_stopping])

# Calculate the training and test errors for the LSTM model
y_error_train = model_lstm.predict(X_train)[: , 0]
error_train = y_train.reshape(-1, 1) - y_error_train

y_error_test = model_lstm.predict(X_test)[: , 0]
error_test = y_test.reshape(-1, 1) - y_error_test

# Create the ANN model
model_ann = Sequential()
model_ann.add(Dense(ann_layer1_size, input_shape=(X_train.shape[1], 1), activation='relu'))
model_ann.add(Dense(ann_layer2_size, activation='relu'))
model_ann.add(Dense(1))

# Compile the ANN model
model_ann.compile(loss=ann_loss_function, optimizer='adam')

# Fit the ANN model
history_ann = model_ann.fit(X_train,
                            error_train,
                            epochs=epochs_ann,
                            batch_size=batch_size,
                            validation_data=(X_test, error_test),
                            verbose=1,
                            callbacks=[moving_average_early_stopping])

return model_lstm, model_ann, history_lstm, history_ann, error_train

```

Σχήμα 5.4: Συνάρτηση train_models

Αυτές είναι οι βασικές συναρτήσεις που περιλαμβάνονται στον κώδικα και εξηγούνται οι λειτουργίες τους. Κάθε συνάρτηση εκτελεί συγκεκριμένες εργασίες που συμβάλλουν στην προετοιμασία των δεδομένων, την εκπαίδευση των μοντέλων και την αξιολόγηση των αποτελεσμάτων.

5.3.3 Δεδομένα εισόδου – εξόδου

Τα δεδομένα εισόδου και εξόδου χρησιμοποιούνται για την εκπαίδευση και την αξιολόγηση των μοντέλων πρόβλεψης κατανάλωσης οικιακών φορτίων. Συγκεκριμένα:

- Δεδομένα εισόδου (X): Αντιπροσωπεύουν την είσοδο του μοντέλου LSTM. Είναι ένας πίνακας που περιέχει ιστορικά δεδομένα κατανάλωσης οικιακού φορτίου για κάθε χρονική στιγμή. Ο πίνακας έχει διαστάσεις (N, T, 1), όπου N είναι ο αριθμός των δεδομένων που χρησιμοποιούνται για την κάθε πόλη ανά 15 λεπτά και T είναι ο αριθμός των προηγούμενων δεδομένων κατανάλωσης που χρησιμοποιούνται ως είσοδος για κάθε

παρατήρηση και είναι ίσος με 12. Οι τιμές του X είναι σε συγκεκριμένο εύρος με τη βοήθεια της εντολής `MinMaxScaler` της `Python`.

- Δεδομένα εξόδου (y): Αντιπροσωπεύει την έξοδο του μοντέλου πρόβλεψης. Είναι ένας πίνακας που περιέχει τις προβλεπόμενες τιμές κατανάλωσης οικιακού φορτίου για κάθε χρονική στιγμή. Οι τιμές του y αντιστοιχούν στην επόμενη χρονική στιγμή μετά τις παρατηρήσεις που χρησιμοποιούνται ως είσοδοι (X) για την αντίστοιχη παρατήρηση που θα προβλεφθεί.

5.4 Κριτήρια ακριβείας μοντέλου

Τα κριτήρια ακριβείας που χρησιμοποιήθηκαν για την αξιολόγηση του μοντέλου πρόβλεψης οικιακού φορτίου είναι το μέσο απόλυτο ποσοστό σφάλματος ($MAPE$), το μέσο απόλυτο σφάλμα (MAE) και το συμμετρικό μέσο απόλυτο ποσοστιαίο σφάλμα ($sMAPE$). Αυτά τα κριτήρια ακριβείας χρησιμοποιούνται ευρέως στον τομέα της πρόβλεψης για να μετρήσουν την απόκλιση μεταξύ των πραγματικών τιμών και των προβλέψεων του μοντέλου.

Το μέσο απόλυτο ποσοστό σφάλματος ($MAPE$) είναι ένα κριτήριο που μετρά τον απόλυτο μέσο όρο των αποκλίσεων των προβλέψεων από τις πραγματικές τιμές, εκφρασμένο ως ποσοστό της πραγματικής τιμής. Υψηλότερες τιμές του $MAPE$ υποδεικνύουν υψηλότερη απόκλιση και χαμηλότερη ακρίβεια του μοντέλου. Δίνεται από την εξίσωση (5.1), όπου n το σύνολο των παρατηρήσεων, A_t η πραγματική τιμή, F_t η προβλεπόμενη τιμή:

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (5.1)$$

Το μέσο απόλυτο σφάλμα (MAE) αποτελεί τον απόλυτο μέσο όρο των αποκλίσεων των προβλέψεων από τις πραγματικές τιμές. Αυτό το κριτήριο μετρά το μέγεθος των σφαλμάτων, αγνοώντας την κατεύθυνση της απόκλισης. Αν παρατηρείται χαμηλό MAE , αυτό υποδεικνύει ότι το μοντέλο έχει μικρές αποκλίσεις από τις πραγματικές τιμές. Έχει την ίδια μονάδα μέτρησης με τη μεταβλητή που προβλέπεται και χρησιμοποιείται για να προσδιορίσει τη μέση απόκλιση των προβλέψεων από τις πραγματικές τιμές. Δίνεται από την εξίσωση (5.2), όπου n είναι το σύνολο των παρατηρήσεων, A_t η πραγματική τιμή, F_t η προβλεπόμενη τιμή:

$$MAE = \frac{1}{n} \sum_{t=1}^n |A_t - F_t| \quad (5.2)$$

Το συμμετρικό μέσο απόλυτο ποσοστιαίο σφάλμα ($sMAPE$) είναι ένα κριτήριο που συνδυάζει την έννοια του απόλυτου ποσοστού σφάλματος (APE) με την έννοια του μέσου όρου. Το $sMAPE$ είναι ένα μέτρο ποσοστιαίας ακριβείας και προσφέρει μια ιδέα για τη μέση ποσοστιαία απόκλιση των προβλέψεων από τις πραγματικές τιμές. Δίνεται από την εξίσωση (5.3), όπου n το σύνολο των παρατηρήσεων, A_t η πραγματική τιμή, F_t η προβλεπόμενη τιμή:

$$sMAPE = \frac{1}{n} \sum_{t=1}^n \left(2 * \frac{|A_t - F_t|}{|A_t + F_t|} * 100\% \right) \quad (5.3)$$

Οι διαφορές μεταξύ αυτών των κριτηρίων ακρίβειας είναι οι εξής:

- Το MAPE μετρά το ποσοστό απόκλισης των προβλέψεων από τις πραγματικές τιμές και είναι ιδιαίτερα χρήσιμο όταν οι πραγματικές τιμές κινούνται σε διαφορετικό εύρος.
- Το MAE μετρά τον απόλυτο μέσο όρο των αποκλίσεων και αγνοεί την κατεύθυνση της απόκλισης. Είναι πιο ανθεκτικό σε ακραίες τιμές σφάλματος.
- Το sMAPE συνδυάζει την έννοια του απόλυτου ποσοστού σφάλματος με την έννοια του μέσου όρου, δίνοντας μεγαλύτερη βαρύτητα στις μεγαλύτερες αποκλίσεις.

Καθένα από αυτά τα κριτήρια έχει τα πλεονεκτήματά του και πρέπει να επιλεγεί ανάλογα με τον σκοπό της αξιολόγησης και τα χαρακτηριστικά των δεδομένων σας. Τα συγκεκριμένα σφάλματα (MAPE, MAE και sMAPE) βοηθούν να οριστεί η αξιοπιστία του μοντέλου στην πρόβλεψη οικιακού φορτίου. Αν τα σφάλματα είναι χαμηλά και κοντά στο μηδέν, τότε το μοντέλο είναι αξιόπιστο και οι προβλέψεις του είναι ακριβείς. Αντίθετα, υψηλά σφάλματα υποδεικνύουν ότι το μοντέλο μπορεί να χρειάζεται βελτίωση ή προσαρμογή στα δεδομένα. Συνολικά, αυτά τα σφάλματα αποτελούν μια πολύτιμη μετρική για την αξιολόγηση της ακρίβειας του μοντέλου πρόβλεψης οικιακού φορτίου.

ΚΕΦΑΛΑΙΟ 6^ο ΕΦΑΡΜΟΓΕΣ

6.1 Γενικά

Στο κεφάλαιο αυτό παρουσιάζονται τα αποτελέσματα των διάφορων υποπεριπτώσεων που πραγματεύεται η διπλωματική. Η ανάλυση πραγματοποιήθηκε σε τρεις διαφορετικές περιοχές των Ηνωμένων Πολιτειών: το Τέξας, την Καλιφόρνια και τη Νέα Υόρκη. Με βάση τα διαθέσιμα δεδομένα για κάθε περιοχή, αλλά και τις υποδείξεις του [26], επιλέχθηκαν για ανάλυση οι παρακάτω ηλεκτρικές συσκευές ανά περιοχή:

- Τέξας: ψυγείο, κλιματιστικό, ηλεκτρικό όχημα, φωτοβολταϊκό πάνελ και συνολικές ηλεκτρικές καταναλώσεις των κατοικιών.
- Καλιφόρνια: ψυγείο, κλιματιστικό, φωτοβολταϊκό πάνελ και συνολικές ηλεκτρικές καταναλώσεις των κατοικιών.
- Νέα Υόρκη: ψυγείο, κλιματιστικό, ηλεκτρικό όχημα, φωτοβολταϊκό πάνελ, θερμοσίφωνα και συνολικές ηλεκτρικές καταναλώσεις των κατοικιών.

Το ενισχυμένο μοντέλο LSTM, που δημιουργήθηκε, εκπαιδεύεται με δεδομένα ιστορικών καταναλώσεων διάρκειας τριών μηνών με στόχο να προβλέψει τις καταναλώσεις 5 ημερών, οι οποίες ελέγχονται μέσω σύγκρισης με τις πραγματικές τιμές. Σημειώνεται ακόμα, ότι οι διάφορες συσκευές παρουσιάζουν διαφορετικά μοτίβα χρήσης, ανάλογα με τη συχνότητα, την εποχικότητα ή και άλλους παράγοντες, γεγονός που εξηγεί τις διαφοροποιήσεις στην ακρίβεια των προβλέψεων του μοντέλου. Κριτήριο ακρίβειας του μοντέλου, όπως έχει επισημανθεί, αποτελεί το Μέσο Απόλυτο Ποσοστιαίο Σφάλμα το οποίο συγκρίνεται με τα αντίστοιχα του [26] καθώς και με αυτό του απλού μοντέλου LSTM.

Σχετικά με τα διαθέσιμα δεδομένα, υπολογίστηκαν στο στάδιο της προ-επεξεργασίας, για κάθε περιοχή και συσκευή, ορισμένα κλασσικά στατιστικά μεγέθη όπως το πλήθος, η μέση τιμή και η τυπική απόκλιση. Το πλήθος των διαθέσιμων δεδομένων και η τυπική τους απόκλιση μπορούν να επηρεάσουν την εκπαίδευση και την απόδοση ενός μοντέλου μηχανικής μάθησης. Συγκεκριμένα, μεγαλύτερο πλήθος δεδομένων μπορεί να εκπαιδεύσει επαρκέστερα το μοντέλο και να προβλέπει με μεγαλύτερη ακρίβεια. Ταυτόχρονα, η τυπική απόκλιση περιγράφει το επίπεδο της διακύμανσης των δεδομένων. Αν η τυπική απόκλιση είναι χαμηλή, τότε σημαίνει ότι τα δεδομένα συγκεντρώνονται κοντά στη μέση τους τιμή. Αντίθετα, αν η τυπική απόκλιση είναι υψηλή, τότε τα δεδομένα είναι πιο διασκορπισμένα παράγοντας που μπορεί να «δυσκολέψει» το μοντέλο. Στους Πίνακες 6.1, 6.2, 6.3, παρουσιάζονται τα μεγέθη αυτά για τις τρεις περιοχές που αναλύονται, χωρίς να λαμβάνονται υπόψη οι NaN παρατηρήσεις και λανθασμένες τιμές (αρνητικές ή πολύ μικρές).

Πίνακας 6.1 : Χαρακτηριστικά μεγέθη διαθέσιμων δεδομένων για τις συσκευές του Τέξας

Συσκευή/Μέγεθος	Πλήθος διαθέσιμων δεδομένων	Μέση τιμή (kW)	Τυπική απόκλιση (kW)
Ψυγείο	195.036	0,082	0,064
Κλιματιστικό	159.266	0,566	0,451
Ηλεκτρικό Όχημα	50.728	1,753	2,597
Φωτοβολταϊκό πάνελ	37.308	1,405	2,316
Δίκτυο	170.477	0,976	1,050

Πίνακας 6.2 : Χαρακτηριστικά μεγέθη διαθέσιμων δεδομένων για τις συσκευές της Καλιφόρνια

Συσκευή/Μέγεθος	Πλήθος διαθέσιμων δεδομένων	Μέση τιμή (kW)	Τυπική απόκλιση (kW)
Ψυγείο	152.652	0,075	0,084
Κλιματιστικό	85.121	0,327	0,617
Φωτοβολταϊκό πάνελ	52.191	0,965	0,659
Δίκτυο	151.762	0,551	0,524

Πίνακας 6.3 : Χαρακτηριστικά μεγέθη διαθέσιμων δεδομένων για τις συσκευές της Νέας Υόρκης

Συσκευή/Μέγεθος	Πλήθος διαθέσιμων δεδομένων	Μέση τιμή (kW)	Τυπική απόκλιση (kW)
Ψυγείο	177.844	0,059	0,057
Κλιματιστικό	146.982	0,342	0,483
Ηλεκτρικό Όχημα	39.125	0,930	1,689
Φωτοβολταϊκό πάνελ	74.532	2,096	2,628
Θερμοσίφωνα	60.375	0,879	0,903
Δίκτυο	177.757	0,867	0,983


Όπως γίνεται εμφανές, περισσότερες πραγματικές μετρήσεις είναι διαθέσιμες για τις συσκευές του ψυγείου, του κλιματιστικού αλλά και για τις συνολικές καταναλώσεις (δίκτυο). Από την άλλη, παρατηρείται αρκετά μικρότερο πλήθος διαθέσιμων δεδομένων για τις συσκευές του ηλεκτρικού οχήματος και του φωτοβολταϊκού πάνελ. Οι συσκευές αυτές παρουσιάζουν ταυτόχρονα και υψηλές τυπικές αποκλίσεις, συνδυασμός που δυσκολεύει τις ακριβείς προβλέψεις του μοντέλου. Στις επόμενες ενότητες, θα παρουσιαστούν λεπτομερώς τα αποτελέσματα του μοντέλου πρόβλεψης, με βάση τα παραπάνω, για κάθε περιοχή και συσκευή.

6.2 Τέξας

Για την περιοχή του Τέξας, αναλύθηκαν το ψυγείο, το κλιματιστικό, το ηλεκτρικό όχημα, το φωτοβολταϊκό πάνελ και οι συνολικές ηλεκτρικές καταναλώσεις των κατοικιών. Στη συνέχεια, παρουσιάζονται τα αποτελέσματα των προβλέψεων του μοντέλου σε σύγκριση με τις πραγματικές τιμές, υπό την μορφή διαγραμμάτων.

- Ψυγείο

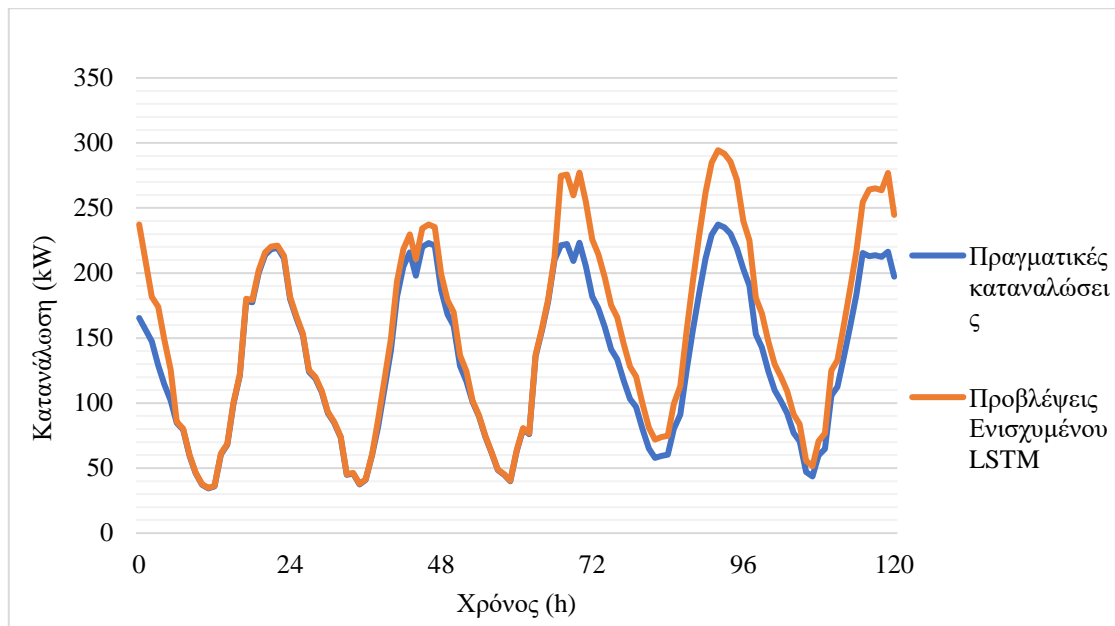
Για την συσκευή ψυγείο και την περιοχή του Τέξας, παρατηρείται κατανάλωση σε συγκεκριμένο εύρος τιμών, χωρίς μηδενικές καταναλώσεις. Το πλήθος των διαθέσιμων δεδομένων είναι αρκετά μεγάλο για το τρίμηνο που εκπαιδεύεται το μοντέλο με σχετικά μικρή τυπική απόκλιση. Όπως φαίνεται και στο Σχήμα 6.1, το μοντέλο ανταποκρίνεται σχετικά ικανοποιητικά, σημειώνοντας MAPE ίσο με 2,04%.



Σχήμα 6.1 : Σύγκριση προβλέψεων – πραγματικών τιμών για το ψυγείο στην περιοχή του Τέξας

- Κλιματιστικό


Για την συσκευή κλιματιστικό και την περιοχή του Τέξας, παρατηρείται κατανάλωση σε μεγαλύτερο εύρος τιμών, χωρίς μηδενικές καταναλώσεις. Το πλήθος των διαθέσιμων δεδομένων και η τυπική απόκλιση κυμαίνονται στα ίδια επίπεδα με το ψυγείο. Όπως φαίνεται και στο Σχήμα 6.2, το μοντέλο ανταποκρίνεται ικανοποιητικά, σημειώνοντας MAPE ίσο με 12,38%.



Σχήμα 6.2 : Σύγκριση προβλέψεων – πραγματικών τιμών για το κλιματιστικό στην περιοχή του Τέξας

- Ηλεκτρικό Οχημα


Για την φόρτιση του ηλεκτρικού οχήματος και την περιοχή του Τέξας, παρατηρείται κατανάλωση σε συγκεκριμένες ώρες της ημέρας, ενώ παρατηρούνται μέσα στην ημέρα και μηδενικές καταναλώσεις. Το πλήθος των διαθέσιμων δεδομένων είναι αρκετά χαμηλότερο ενώ παρατηρείται και σχετικά μεγαλύτερη τυπική απόκλιση. Όπως φαίνεται και στο Σχήμα 6.3, το μοντέλο ανταποκρίνεται με αδυναμία, σημειώνοντας MAPE ίσο με 27,28%.



Σχήμα 6.3 : Σύγκριση προβλέψεων – πραγματικών τιμών για το ηλεκτρικό όχημα στην περιοχή του Τέξας

- Φωτοβολταϊκό πάνελ


Για το φωτοβολταϊκό πάνελ και την περιοχή του Τέξας, παρατηρείται παραγωγή συγκεκριμένες ώρες της ημέρας όπου προφανώς υπάρχει ηλιοφάνεια. Το εύρος διακύμανσης της παραγωγής είναι αρκετά μεγαλύτερο συγκριτικά με τις υπόλοιπες συσκευές. Ταυτόχρονα, το πλήθος των διαθέσιμων δεδομένων είναι μικρό καθώς δεν διαθέτουν όλες οι κατοικίες ΦΒ οροφής. Επομένως, πρόκειται για ένα μοτίβο με μεγάλες αυξομειώσεις στο εύρος τιμών και μικρό αριθμό δεδομένων για την επαρκή εκπαίδευση του μοντέλου. Όπως φαίνεται στο Σχήμα 6.4, το μοντέλο ανταποκρίνεται σχετικά ικανοποιητικά στο μοτίβο παραγωγής αλλά πιο αδύναμα στο εύρος διακύμανσης, σημειώνοντας MAPE ίσο με 24,92%.



Σχήμα 6.4 : Σύγκριση προβλέψεων – πραγματικών τιμών για το φωτοβολταϊκό πάνελ στην περιοχή του Τέξας

- Συνολικές καταναλώσεις

Για τις συνολικές καταναλώσεις των διαθέσιμων κατοικιών και την περιοχή του Τέξας, υπάρχει μεγάλος αριθμός διαθέσιμων δεδομένων με χαμηλή τυπική απόκλιση και, όπως φαίνεται στο Σχήμα 6.5, το μοντέλο ανταποκρίνεται σχετικά ικανοποιητικά σημειώνοντας MAPE ίσο με 8,39%.



Σχήμα 6.5 : Σύγκριση προβλέψεων – πραγματικών τιμών για την συνολική κατανάλωση κατοικιών στην περιοχή του Τέξας

- Παρουσίαση συγκριτικών αποτελεσμάτων

Με βάση και το [26] πραγματοποιήθηκε σύγκριση των αποτελεσμάτων με κριτήριο ακρίβειας το Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (MAPE). Οι συσκευές για τις οποίες έχει πραγματοποιηθεί ανάλυση κι υπάρχουν τα διαθέσιμα σφάλματα είναι το ψυγείο, το κλιματιστικό, το ηλεκτρικό όχημα και το δίκτυο. Το προτεινόμενο μοντέλο πετυχαίνει μικρότερα σφάλματα για όλες τις συσκευές εκτός του δικτύου. Αντίστοιχα, πραγματοποιήθηκε σύγκριση των αποτελεσμάτων του ενισχυμένου LSTM μοντέλου (LSTM+) με το απλό LSTM μοντέλο, με κριτήριο το MAPE. Οι προβλέψεις του ενισχυμένου LSTM μοντέλου παρουσιάζουν εμφανώς μικρότερα σφάλματα από αυτές του απλού LSTM για όλες τις συσκευές που αναλύθηκαν. Τα αποτελέσματα παρουσιάζονται στον Πίνακα 6.4.

Πίνακας 6.4 : Συγκριτικά αποτελέσματα MAPE του επαυξημένου μοντέλου (LSTM+), του [26] και του απλού (LSTM) για τις προβλέψεις των συσκευών του Τέξας

Συσκευή	LSTM+	[26]	LSTM
Ψυγείο	2,04%	4,64%	17,85%
Κλιματιστικό	12,38%	18,89%	55,31%
Ηλεκτρικό όχημα	27,28%	126,37%	75,02%
Φωτοβολταϊκό πάνελ	24,92%	-	95,65%
Δίκτυο	8,39%	6,62%	36,17%

Τέλος, υπολογίστηκαν τα αποτελέσματα των διαφορετικών κριτηρίων ακρίβειας MAPE, MAE, sMAPE του επαυξημένου μοντέλου (LSTM+). Τα συγκεντρωτικά αποτελέσματα για τις συσκευές που αναλύθηκαν στην περιοχή του Τέξας παρουσιάζονται στον Πίνακα 6.5:

Συσκευή	MAPE	MAE (kW)	sMAPE
Ψυγείο	2,04%	0,248	4,33%
Κλιματιστικό	12,38%	18,717	10,35%
Ηλεκτρικό όχημα	27,28%	3,27	29,19%
Φωτοβολταϊκό πάνελ	24,92%	20,142	25,59%
Δίκτυο	8,39%	33,351	11,79%


Πίνακας 6.5 : Συγκριτικά αποτελέσματα σφαλμάτων MAPE, MAE, sMAPE του ενισχυμένου μοντέλου (LSTM+) για τις προβλέψεις των συσκευών του Τέξας

6.3 Καλιφόρνια

Για την περιοχή της Καλιφόρνια από τα διαθέσιμα ιστορικά δεδομένα αναλύθηκαν οι συσκευές: ψυγείο, κλιματιστικό, φωτοβολταϊκό πάνελ καθώς και η συνολική κατανάλωση του δικτύου. Στη συνέχεια, παρουσιάζονται τα αποτελέσματα των προβλέψεων του μοντέλου σε σύγκριση με τις πραγματικές τιμές, υπό την μορφή διαγραμμάτων.

- Ψυγείο

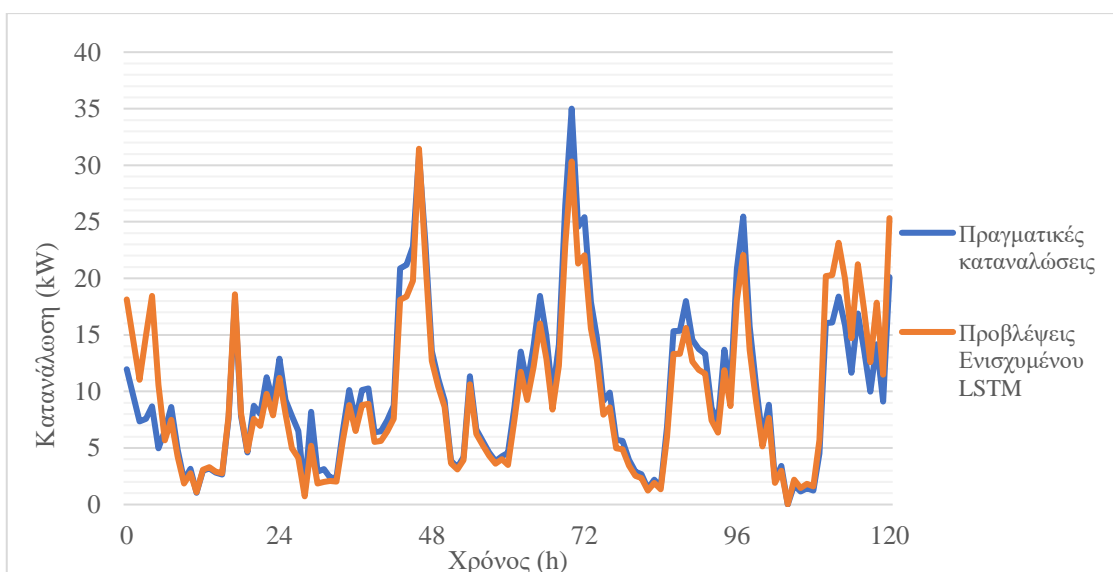
Για την συσκευή ψυγείο και την περιοχή του Τέξας, παρατηρείται κατανάλωση σε συγκεκριμένο εύρος τιμών, χωρίς μηδενικές καταναλώσεις. Το πλήθος των διαθέσιμων δεδομένων είναι αρκετά μεγάλο για το τρίμηνο που εκπαιδεύεται το μοντέλο, με σχετικά μικρή τυπική απόκλιση. Όπως φαίνεται στο Σχήμα 6.6, το μοντέλο ανταποκρίνεται σχετικά ικανοποιητικά, σημειώνοντας MAPE ίσο με 6,14%.



Σχήμα 6.6 : Σύγκριση προβλέψεων – πραγματικών τιμών για το ψυγείο στην περιοχή της Καλιφόρνια

- Κλιματιστικό


Για την συσκευή του κλιματιστικού και την περιοχή της Καλιφόρνια, παρατηρείται κατανάλωση σε μεγαλύτερο εύρος τιμών, χωρίς μηδενικές καταναλώσεις. Τα διαθέσιμα δεδομένα παρουσιάζουν μεγάλη τυπική απόκλιση και όπως φαίνεται στο Σχήμα 6.7, το μοντέλο ανταποκρίνεται σχετικά πιο αδύναμα, σημειώνοντας MAPE ίσο με 17,54%.



Σχήμα 6.7 : Σύγκριση προβλέψεων – πραγματικών τιμών για την συσκευή του κλιματιστικού στην περιοχή της Καλιφόρνια

- Φωτοβολταϊκό πάνελ


Για το φωτοβολταϊκό πάνελ και την περιοχή της Καλιφόρνια, παρατηρείται παραγωγή συγκεκριμένες ώρες της ημέρας, ενώ αρκετές ώρες όπως είναι φυσιολογικό, δεν παρατηρείται παραγωγή. Το εύρος διακύμανσης της παραγωγής είναι αρκετά μεγαλύτερο συγκριτικά με τις υπόλοιπες συσκευές. Τα διαθέσιμα δεδομένα είναι λιγότερα με μικρή όμως τυπική απόκλιση και όπως φαίνεται στο Σχήμα 6.8, το μοντέλο ανταποκρίνεται σχετικά ικανοποιητικά στο μοτίβο παραγωγής αλλά πιο αδύναμα στο εύρος διακύμανσης, σημειώνοντας MAPE ίσο με 17,61%.



Σχήμα 6.8 : Σύγκριση προβλέψεων – πραγματικών τιμών για το φωτοβολταϊκό πάνελ στην περιοχή της Καλιφόρνια

- Συνολικές καταναλώσεις

Για τις συνολικές καταναλώσεις των κατοικιών της Καλιφόρνια, το πλήθος των διαθέσιμων δεδομένων είναι αρκετά μεγάλο γεγονός που βοηθάει την εκπαίδευση του μοντέλου. Όπως φαίνεται στο Σχήμα 6.9, το μοντέλο ανταποκρίνεται σχετικά ικανοποιητικά, σημειώνοντας MAPE ίσο με 5,09%.



Σχήμα 6.9 : Σύγκριση προβλέψεων – πραγματικών τιμών για την συνολική κατανάλωση κατοικιών στην περιοχή της Καλιφόρνια

- Παρουσίαση συγκριτικών αποτελεσμάτων

Με βάση και το [26] πραγματοποιήθηκε σύγκριση των αποτελεσμάτων με κριτήριο ακρίβειας το Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (MAPE). Οι συσκευές για τις οποίες έχει πραγματοποιηθεί ανάλυση κι υπάρχουν τα διαθέσιμα σφάλματα είναι το ψυγείο, το κλιματιστικό, το ηλεκτρικό όχημα και το δίκτυο. Το προτεινόμενο μοντέλο πετυχαίνει μικρότερα σφάλματα για όλες τις συσκευές εκτός του ψυγείου. Αντίστοιχα, πραγματοποιήθηκε σύγκριση των αποτελεσμάτων του ενισχυμένου LSTM μοντέλου (LSTM+) με το απλό LSTM μοντέλο, με κριτήριο το MAPE. Οι προβλέψεις του ενισχυμένου LSTM μοντέλου παρουσιάζουν εμφανώς μικρότερα σφάλματα από αυτές του απλού LSTM για όλες τις συσκευές που αναλύθηκαν. Τα αποτελέσματα παρουσιάζονται στον Πίνακα 6.6.

Πίνακας 6.6: Συγκριτικά αποτελέσματα MAPE του επαυξημένου μοντέλου (LSTM+), του [26] και του απλού (LSTM) για τις προβλέψεις των συσκευών της Καλιφόρνια

Συσκευή	LSTM+	[26]	LSTM
Ψυγείο	6,14%	4,64%	19,87%
Κλιματιστικό	17,54%	18,89%	67,22%
Φωτοβολταϊκό πάνελ	17,61%	-	71,06%
Δίκτυο	5,09%	6,62%	42,25%

Τέλος, υπολογίστηκαν τα αποτελέσματα των διαφορετικών κριτηρίων ακρίβειας MAPE, MAE, sMAPE του επαυξημένου μοντέλου (LSTM+). Τα συγκεντρωτικά αποτελέσματα για τις συσκευές που αναλύθηκαν στην περιοχή της Καλιφόρνια παρουσιάζονται στον Πίνακα 6.7.

Πίνακας 6.7: Συγκριτικά αποτελέσματα σφαλμάτων MAPE, MAE, sMAPE του ενισχυμένου μοντέλου (LSTM+) για τις προβλέψεις των συσκευών της περιοχής Καλιφόρνια


Συσκευή / Μοντέλο	MAPE	MAE (kW)	sMAPE
Ψυγείο	6,14%	0,189	7,71%
Κλιματιστικό	17,54%	1,654	16,98%
Φωτοβολταϊκό πάνελ	17,61%	7,117	16,37%
Δίκτυο	5,09%	5,319	4,89%

6.4 Νέα Υόρκη

Για την περιοχή της Νέας Υόρκης από τα διαθέσιμα ιστορικά δεδομένα αναλύθηκαν οι συσκευές: ψυγείο, κλιματιστικό, ηλεκτρικό όχημα, φωτοβολταϊκό πάνελ, θερμοσίφωνα καθώς και η συνολική κατανάλωση του δικτύου. Στη συνέχεια, παρουσιάζονται τα αποτελέσματα των προβλέψεων του μοντέλου σε σύγκριση με τις πραγματικές τιμές, υπό την μορφή διαγραμμάτων.

- Ψυγείο


Για την συσκευή ψυγείο και την περιοχή της Νέας Υόρκης, παρατηρείται κατανάλωση σε συγκεκριμένο εύρος τιμών, χωρίς μηδενικές καταναλώσεις. Το πλήθος των διαθέσιμων δεδομένων είναι αρκετά μεγάλο για την εκπαίδευση του μοντέλου και όπως φαίνεται και στο Σχήμα 6.10, το μοντέλο ανταποκρίνεται σχετικά ικανοποιητικά, σημειώνοντας MAPE ίσο με 5,19%.



Σχήμα 6.10 : Σύγκριση προβλέψεων – πραγματικών τιμών για το ψυγείο στην περιοχή της Νέας Υόρκης

- Κλιματιστικό


Για την συσκευή του κλιματιστικού και την περιοχή της Νέας Υόρκης, παρατηρείται κατανάλωση σε μεγαλύτερο εύρος τιμών, χωρίς μηδενικές καταναλώσεις. Το πλήθος των διαθέσιμων δεδομένων είναι μεγάλο, ωστόσο παρατηρείται υψηλή τυπική απόκλιση στα δεδομένα. Όπως φαίνεται και στο Σχήμα 6.11, το μοντέλο ανταποκρίνεται πιο αδύναμα, σημειώνοντας MAPE ίσο με 12,41%.



Σχήμα 6.11 : Σύγκριση προβλέψεων – πραγματικών τιμών για το κλιματιστικό στην περιοχή της Νέας Υόρκης

- Ηλεκτρικό Όχημα


Για την φόρτιση του ηλεκτρικού οχήματος και την περιοχή της Νέας Υόρκης, παρατηρείται κατανάλωση σε συγκεκριμένες ώρες της ημέρας. Είναι διαθέσιμο μικρό πλήθος δεδομένων καθώς λίγες κατοικίες διαθέτουν ηλεκτρικό όχημα. Ταυτόχρονα, παρατηρείται μεγάλη τυπική απόκλιση, συνδυασμός που δυσκολεύει το μοντέλο να εκπαιδευτεί επαρκώς και να προβλέψει με ακρίβεια. Όπως φαίνεται και στο Σχήμα 6.12, το μοντέλο ανταποκρίνεται σχετικά αδύναμα, σημειώνοντας MAPE ίσο με 32,26%.



Σχήμα 6.12 : Σύγκριση προβλέψεων – πραγματικών τιμών για το ηλεκτρικό όχημα και την περιοχή της Νέας Υόρκης

- Φωτοβολταϊκό πάνελ


Για το φωτοβολταϊκό πάνελ και την περιοχή της Νέας Υόρκης, παρατηρείται παραγωγή στις ώρες της ημέρας όπου υπάρχει ηλιοφάνεια. Το πλήθος των δεδομένων είναι ικανοποιητικό ενώ παρατηρείται και σχετικά μικρή τυπική απόκλιση. Όπως φαίνεται στο Σχήμα 6.13, το μοντέλο ανταποκρίνεται σχετικά ικανοποιητικά, σημειώνοντας MAPE ίσο με 10,51%.



Σχήμα 6.13 : Σύγκριση προβλέψεων – πραγματικών τιμών για το φωτοβολταϊκό πάνελ στην περιοχή της Νέας Υόρκης

- Θερμοσίφωνα


Για τον θερμοσίφωνα και την περιοχή της Νέας Υόρκης, παρατηρείται συνεχής κατανάλωση κατά την διάρκεια της ημέρας. Πρόκειται για ένα μοτίβο με μικρή τυπική απόκλιση γεγονός που διευκολύνει το μοντέλο να πραγματοποιήσει ακριβέστερη πρόβλεψη. Όπως φαίνεται στο Σχήμα 6.14, το μοντέλο ανταποκρίνεται σχετικά ικανοποιητικά σημειώνοντας MAPE ίσο με 9,76%.



Σχήμα 6.14 : Σύγκριση προβλέψεων – πραγματικών τιμών για τον ηλεκτρικό θερμοσίφωνα στην περιοχή της Νέας Υόρκης

- Συνολικές καταναλώσεις

Για τις συνολικές καταναλώσεις των κατοικιών της Νέας Υόρκης, παρατηρείται συνεχής κατανάλωση κατά την διάρκεια της ημέρας. Όπως φαίνεται και στο Σχήμα 6.15 το μοντέλο ανταποκρίνεται σχετικά ικανοποιητικά, σημειώνοντας MAPE ίσο με 5,77%.



Σχήμα 6.15 : Σύγκριση προβλέψεων – πραγματικών τιμών για την συνολική κατανάλωση κατοικιών στην περιοχή της Νέας Υόρκης

- Παρουσίαση συγκριτικών αποτελεσμάτων

Με βάση και το [26] πραγματοποιήθηκε σύγκριση των αποτελεσμάτων με κριτήριο ακρίβειας το Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (MAPE). Οι συσκευές για τις οποίες έχει πραγματοποιηθεί ανάλυση κι υπάρχουν τα διαθέσιμα σφάλματα είναι το ψυγείο, το κλιματιστικό, το ηλεκτρικό όχημα και το δίκτυο. Το προτεινόμενο μοντέλο πετυχαίνει μικρότερα σφάλματα για όλες τις συσκευές εκτός του ψυγείου. Αντίστοιχα, πραγματοποιήθηκε σύγκριση των αποτελεσμάτων του ενισχυμένου LSTM μοντέλου (LSTM+) με το απλό LSTM μοντέλο, με κριτήριο το MAPE. Οι προβλέψεις του ενισχυμένου LSTM μοντέλου παρουσιάζουν μικρότερα σφάλματα από αυτές του απλού LSTM για όλες τις συσκευές που αναλύθηκαν, όπως παρουσιάζεται στον Πίνακα 6.8.

Πίνακας 6.8 : Συγκριτικά αποτελέσματα MAPE του επαυξημένου μοντέλου (LSTM+), του [26] και του απλού (LSTM) για τις προβλέψεις των συσκευών της Νέας Υόρκης

Συσκευή	LSTM+	[26]	LSTM
Ψυγείο	5,19%	4,64%	17,85%
Κλιματιστικό	12,41%	18,89%	39,75%
Ηλεκτρικό όχημα	32,26%	126,37%	70,80%
Φωτοβολταϊκό πάνελ	10,51%	-	61,16%
Θερμοσίφωνα	9,76%	-	18,47%
Δίκτυο	5,77%	6,62%	26,10%

Τέλος, υπολογίστηκαν τα αποτελέσματα των διαφορετικών κριτηρίων ακρίβειας MAPE, MAE, sMAPE του επαυξημένου μοντέλου (LSTM+). Τα συγκεντρωτικά αποτελέσματα για τις συσκευές που αναλύθηκαν στην περιοχή της Νέας Υόρκης παρουσιάζονται στον Πίνακα 6.9.

Πίνακας 6.9 : Συγκριτικά αποτελέσματα σφαλμάτων MAPE, MAE, sMAPE του ενισχυμένου μοντέλου (LSTM+) για τις προβλέψεις των συσκευών της Νέας Υόρκης

Συσκευή / Μοντέλο	MAPE	MAE (kW)	sMAPE
Ψυγείο	5,19%	0,284	6,81%
Κλιματιστικό	12,41%	2,338	16,04%
Ηλεκτρικό όχημα	32,26%	2,266	28,57%
Φωτοβολταϊκό πάνελ	10,51%	11,282	10,26%
Θερμοσίφονας	9,76%	0,915	14,28%
Δίκτυο	5,77%	4,07	4,89%

6.5 Ανάλυση ευαισθησίας

Η ανάλυση ευαισθησίας σε ένα μοντέλο νευρωνικού δικτύου αποτελεί μια τεχνική που επιτρέπει την εκτίμηση του πώς αλλάζει η απόδοση του μοντέλου με βάση τις διαφοροποιήσεις σημαντικών υπερπαραμέτρων ή άλλων παραγόντων που επηρεάζουν την εκπαίδευση ή την αξιολόγησή του. Με απλά λόγια, η ανάλυση ευαισθησίας δίνει μια κατανόηση του πώς οι αλλαγές σε μια υπερπαραμέτρο επηρεάζουν την απόδοση του μοντέλου. Κατά την διαδικασία της ανάλυσης ευαισθησίας, λοιπόν, εξερευνώνται διάφορες τιμές υπερπαραμέτρων οι οποίες επηρεάζουν την ακρίβεια του δικτύου. Με αυτόν τον τρόπο, επιλέγονται οι βέλτιστες υπερπαραμέτροι που θα οδηγήσουν στη βέλτιστη απόδοση του μοντέλου.

Η χρησιμότητα της ανάλυσης ευαισθησίας είναι πολύ σημαντική για τους επιστήμονες δεδομένων και τους μηχανικούς μηχανικής μάθησης. Αυτή η ανάλυση επιτρέπει να κατανοηθεί και να αξιολογηθεί η επίδραση των υπερπαραμέτρων στην απόδοση του μοντέλου. Βοηθά να κατανοηθεί ποιες υπερπαραμέτροι είναι οι πλέον κρίσιμες για την επίτευξη καλύτερης απόδοσης και ποιοι παράγοντες μπορεί να επηρεάσουν αρνητικά την απόδοση του μοντέλου. Επιπλέον, η ανάλυση ευαισθησίας επιτρέπει να κατανοηθεί καλύτερα η σημασία των υπερπαραμέτρων. Βοηθά να αποκτηθεί πιο ευρεία γνώση για τον τρόπο λειτουργίας του μοντέλου και την επίδραση που μπορούν να έχουν οι υπερπαραμέτροι στην απόδοσή του. Αυτό επιτρέπει την αποτελεσματικότερη επιλογή και ρύθμιση των υπερπαραμέτρων για τα μοντέλα.

Συνολικά, η ανάλυση ευαισθησίας είναι μια πολύτιμη εργαλειοθήκη για την καλύτερη κατανόηση, αξιολόγηση και βελτιστοποίηση των υπερπαραμέτρων σε ένα μοντέλο νευρωνικού δικτύου. Με την αξιοποίηση αυτής της ανάλυσης, διαμορφώνονται μοντέλα με καλύτερη απόδοση, προσαρμόζοντας τις υπερπαραμέτρους στις ανάγκες και τις προδιαγραφές του προβλήματος που είναι προς επίλυση.

Στο συγκεκριμένο πρόβλημα επιλέχθηκαν για την ανάλυση ευαισθησίας οι εξής υπερπαραμέτροι: ο αριθμός των κρυφών επιπέδων (hidden units), ο ρυθμός μάθησης (learning rate) και ο αριθμός των εποχών (epochs). Οι επιλεγμένες υπερπαραμέτροι είναι σημαντικές για το μοντέλο και η ανάλυση ευαισθησίας βοηθά να προσδιοριστούν οι βέλτιστες τιμές τους. Αυτό μπορεί να οδηγήσει σε ένα βελτιστοποιημένο μοντέλο με βελτιωμένη απόδοση και ικανότητα γενίκευσης σε νέα δεδομένα καθώς οι υπερπαραμέτροι αυτές είναι ιδιαίτερα κρίσιμοι.

Συγκεκριμένα, ο αριθμός των κρυφών επιπέδων (hidden units) όπως έχει ήδη αναλυθεί στο κεφάλαιο 3, είναι σημαντικός για την ικανότητα του μοντέλου να μάθει και να αναπαραστήσει πολύπλοκα μοτίβα στα δεδομένα. Ταυτόχρονα, ο ρυθμός μάθησης (learning rate) είναι επίσης ένας σημαντικός παράγοντας που επηρεάζει την εκπαίδευση του μοντέλου. Τέλος, μεταβάλλοντας τον αριθμό των εποχών (epochs), μπορεί να προσδιοριστεί ο βέλτιστος αριθμός των επαναλήψεων που απαιτούνται για την εκπαίδευση του μοντέλου. Κατά την διαδικασία της ανάλυσης ευαισθησίας των τριών υπερπαραμέτρων μεταβαλλόταν η τιμή της μίας ενώ οι υπόλοιπες δύο παρέμεναν σταθερές στις τιμές που υποδεικνύονται από το [26]. Η ανάλυση ευαισθησίας πραγματοποιήθηκε για την περιοχή της Νέας Υόρκης. Στην περιοχή αυτή υπάρχουν διαθέσιμα δεδομένα για περισσότερες συσκευές καλύπτοντας με αυτό τον τρόπο διαφορετικά μοτίβα κατανάλωσης. Ο βέλτιστος συνδυασμός υπερπαραμέτρων, αριθμός κρυφών επιπέδων ίσος με 200, ρυθμός μάθησης ίσος με 0,0001 και αριθμός εποχών ίσος με 500 χρησιμοποιήθηκε στην εξαγωγή των αποτελεσμάτων των ενοτήτων 6.2, 6.3 και 6.4. Τα αποτελέσματα παρουσιάζονται ανά υπερπαραμέτρο:

- Αριθμός κρυφών επιπέδων (hidden units): κατά την ανάλυση ευαισθησίας της συγκεκριμένης υπερπαραμέτρου οι άλλες δύο παραμένουν σταθερές στις τιμές που υποδεικνύονται από το [26] και συγκεκριμένα ο αριθμός εποχών (epochs) ίσος με 500 και ο ρυθμός μάθησης (learning rate) ίσος με 0,0001. Οι τιμές που επιλέχθηκαν είναι από 100 έως 300 με βήμα 50 για τις οποίες υπολογίζεται το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE). Από τα αποτελέσματα παρατηρείται ότι το μοντέλο εμφανίζει το μικρότερο σφάλμα όταν η τιμή των κρυφών επιπέδων είναι ίση με 200. Ταυτόχρονα, παρατηρούνται διακυμάνσεις έως και 185% στο σφάλμα για τις διάφορες τιμές της παραμέτρου. Μεγαλύτερη ευαισθησία παρατηρείται στις συσκευές με τα λιγότερα διαθέσιμα δεδομένα, όπως το ηλεκτρικό όχημα. Στους Πίνακες 6.10 και 6.11, παρουσιάζονται τα αποτελέσματα της ανάλυσης ευαισθησίας του αριθμού κρυφών επιπέδων (hidden units) για όλες τις συσκευές της Νέας Υόρκης.

Πίνακας 6.10 : Ανάλυση ευαισθησίας για τα κρυφά επίπεδα (hidden units) και τις συσκευές ψυγείο, κλιματιστικό και ηλεκτρικό όχημα της Νέας Υόρκης

Ψυγείο		Κλιματιστικό		Ηλεκτρικό Όχημα	
Hidden Units	MAPE	Hidden Units	MAPE	Hidden Units	MAPE
100	8,04%	100	17,00%	100	59,68%
150	5,61%	150	13,78%	150	38,07%
200	5,19%	200	12,41%	200	32,26%
250	5,35%	250	13,28%	250	35,16%
300	6,64%	300	14,77%	300	45,65%

Πίνακας 6.11 : Ανάλυση ευαισθησίας για τα κρυφά επίπεδα (hidden units) και τις συσκευές φωτοβολταϊκό πάνελ, θερμοσίφωνα και τις συνολικές καταναλώσεις των κατοικιών (Δίκτυο) της Νέας Υόρκης

Φωτοβολταϊκό πάνελ		Θερμοσίφωνα		Δίκτυο	
Hidden Units	MAPE	Hidden Units	MAPE	Hidden Units	MAPE
100	16,29%	100	15,13%	100	8,94%
150	11,35%	150	10,54%	150	6,23%
200	10,51%	200	9,76%	200	5,77%
250	11,25%	250	10,17%	250	5,83%
300	14,11%	300	12,10%	300	7,04%

- Ρυθμός μάθησης (learning rate): κατά την ανάλυση ευαισθησίας της συγκεκριμένης υπερπαραμέτρου οι άλλες δύο παραμένουν σταθερές στις τιμές που υποδεικνύονται από το [26] και συγκεκριμένα ο αριθμός εποχών (epochs) ίσος με 500 και ο αριθμός κρυφών επιπέδων (hidden units) ίσος με 200 . Οι τιμές που επιλέχθηκαν είναι από 0,1 έως 0,00001 με βήμα 0,1 για τις οποίες υπολογίζεται το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE). Από τα αποτελέσματα παρατηρείται ότι το μοντέλο εμφανίζει το μικρότερο σφάλμα όταν η τιμή της παραμέτρου learning rate είναι 0,0001. Ταυτόχρονα παρατηρούνται διακυμάνσεις έως και 275% περίπου στο σφάλμα για τις διάφορες τιμές της παραμέτρου. Μεγαλύτερη ευαισθησία παρατηρείται στις συσκευές με τα λιγότερα διαθέσιμα δεδομένα, όπως το φωτοβολταϊκό πάνελ. Στους Πίνακες 6.12 και 6.13, παρουσιάζονται τα αποτελέσματα της ανάλυσης ευαισθησίας του ρυθμού μάθησης (learning rate) για όλες τις συσκευές της Νέας Υόρκης.

Πίνακας 6.12 : Ανάλυση ευαισθησίας για τον ρυθμό μάθησης (learning rate) και τις συσκευές ψυγείο, κλιματιστικό και ηλεκτρικό όχημα της Νέας Υόρκης

Ψυγείο		Κλιματιστικό		Ηλεκτρικό Όχημα	
Learning rate	MAPE	Learning rate	MAPE	Learning rate	MAPE
0,1	10,94%	0,1	31,55%	0,1	84,60%
0,01	10,06%	0,01	25,66%	0,01	80,47%
0,001	6,69%	0,001	18,12%	0,001	57,02%
0,0001	5,19%	0,0001	12,41%	0,0001	32,26%
0,00001	5,81%	0,00001	12,91%	0,00001	31,29%

Πίνακας 6.13 : Ανάλυση ευαισθησίας για τον ρυθμό μάθησης (learning rate) και τις συσκευές φωτοβολταϊκό πάνελ, θερμοσίφωνα και τις συνολικές καταναλώσεις των κατοικιών (Δίκτυο) της Νέας Υόρκης

Φωτοβολταϊκό πάνελ		Θερμοσίφωνα		Δίκτυο	
Learning rate	MAPE	Learning rate	MAPE	Learning rate	MAPE
0,1	28,86%	0,1	25,01%	0,1	11,63%
0,01	22,63%	0,01	21,45%	0,01	10,26%
0,001	18,11%	0,001	15,87%	0,001	7,04%
0,0001	10,51%	0,0001	9,76%	0,0001	5,77%
0,00001	11,77%	0,00001	9,86%	0,00001	6,12%

- Αριθμός εποχών (epochs): κατά την ανάλυση ευαισθησίας της συγκεκριμένης υπερπαραμέτρου οι άλλες δύο παραμένουν σταθερές στις τιμές που υποδεικνύονται από το [26] και συγκεκριμένα ο αριθμός κρυφών επιπέδων (hidden units) ίσος με 200 και ο ρυθμός μάθησης (learning rate) ίσος με 0,0001. Οι τιμές που επιλέχθηκαν είναι από 100 έως 1000 με βήμα 250 για τις οποίες υπολογίζεται το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE). Χρειάζεται να σημειωθεί ότι εφαρμόζεται η τεχνική του Early Stopping, η οποία αποτελεί μια μέθοδο για να αποτραπεί η υπερπροσαρμογή (overfitting) κατά την εκπαίδευση ενός μηχανικού μοντέλου μάθησης. Έτσι, όταν παρατηρείται πως η απόδοση δεν βελτιώνεται μετά από έναν καθορισμένο αριθμό εποχών, η εκπαίδευση «σταματά» πρόωρα. Ως εκ τούτου, μετά την βέλτιστη τιμή του epochs, όσο και να αυξάνεται παρατηρείται ίδιο ποσοστό σφάλματος. Συγκεκριμένα, από τα αποτελέσματα παρατηρείται ότι το μοντέλο γενικά εμφανίζει το μικρότερο σφάλμα όταν η τιμή των εποχών είναι ίση με 500. Ταυτόχρονα, παρατηρούνται μικρότερες διακυμάνσεις στο σφάλμα έως και 25% για τις διάφορες τιμές της παραμέτρου, γεγονός που μαρτυράει ότι το μοντέλο είναι λιγότερο ευαίσθητο στην μεταβολή του αριθμού των εποχών. Στους πίνακες 6.14 και 6.15 παρουσιάζονται τα αποτελέσματα της ανάλυσης ευαισθησίας του αριθμού των εποχών (epochs) για όλες τις συσκευές της Νέας Υόρκης.

Πίνακας 6.14 : Ανάλυση ευαισθησίας για τον αριθμό των εποχών (epochs) και τις συσκευές ψυγείο, κλιματιστικό και ηλεκτρικό όχημα της Νέας Υόρκης

Ψυγείο		Κλιματιστικό		Ηλεκτρικό Όχημα	
epochs	MAPE	epochs	MAPE	epochs	MAPE
100	5,45%	100	14,52%	100	40,33%
250	5,29%	250	13,17%	250	36,18%
500	5,19%	500	12,41%	500	32,26%
750	5,19%	750	12,41%	750	32,26%
1000	5,19%	1000	12,41%	1000	32,26%

Πίνακας 6.15 : Ανάλυση ευαισθησίας για τον αριθμό των εποχών (epochs) και τις συσκευές φωτοβολταϊκό πάνελ, θερμοσίφωνα και τις συνολικές καταναλώσεις των κατοικιών (Δίκτυο) της Νέας Υόρκης

Φωτοβολταϊκό πάνελ		Θερμοσίφωνα		Δίκτυο	
epochs	MAPE	epochs	MAPE	epochs	MAPE
100	13,61%	100	11,67%	100	6,61%
250	12,24%	250	10,21%	250	5,94%
500	10,51%	500	9,76%	500	5,77%
750	10,11%	750	9,76%	750	5,77%
1000	10,11%	1000	9,76%	1000	5,77%

ΚΕΦΑΛΑΙΟ 7^ο

ΣΥΜΠΕΡΑΣΜΑΤΑ - ΕΠΕΚΤΑΣΕΙΣ

7.1 Συμπεράσματα

Στην παρούσα εργασία, προτείνεται ένα μοντέλο για την βραχυπρόθεσμη πρόβλεψη φορτίου μεμονωμένων συσκευών σε επίπεδο κοινότητας. Αναπτύσσεται το δίκτυο LSTM, και ενσωματώνεται ένα νευρωνικό δίκτυο για να βελτιωθεί το σφάλμα μέσω της εκπαίδευσης. Έτσι, κάθε αρχικό αποτέλεσμα πρόβλεψης μπορεί να ρυθμιστεί με έναν εκτιμώμενο όρο σφάλματος για καλύτερη πρόβλεψη απόδοσης. Αριθμητικές δοκιμές με χρήση πραγματικών δεδομένων οικιακού φορτίου δείχνουν την εγκυρότητα και τη βελτιωμένη απόδοση του προτεινόμενου αλγορίθμου. Όπως παρουσιάζεται και στους συγκεντρωτικούς πίνακες του Κεφαλαίου 6, συμπεραίνεται πως ο αλγόριθμος μηχανικής μάθησης που υλοποιείται καταφέρνει να ανταποκριθεί ικανοποιητικά στην απαίτηση για βραχυπρόθεσμη πρόβλεψη της ηλεκτρικής ζήτησης οικιακών συσκευών. Συγκεκριμένα:

- Το μοντέλο ανταποκρίνεται, προβλέποντας την βραχυπρόθεσμη κατανάλωση διάφορων οικιακών συσκευών με ικανοποιητικό μέσο απόλυτο ποσοστιαίο σφάλμα συγκρινόμενο με αντίστοιχα σφάλματα δημοσιευμένης εργασίας [26].
- Παρατηρείται ότι το μοντέλο προβλέπει με μεγαλύτερη ακρίβεια την κατανάλωση συσκευών για τις οποίες το πλήθος των διαθέσιμων ιστορικών δεδομένων είναι επαρκές και η τυπική απόκλιση είναι σχετικά μικρή.
- Το μοντέλο προσαρμόζεται ικανοποιητικά στα διαφορετικά μοτίβα κατανάλωσης, με μια αδυναμία σε αυτά που παρουσιάζουν μεγάλες διακυμάνσεις στο εύρος κατανάλωσης κατά την διάρκεια της ημέρας.
- Κατά την ανάλυση ευαισθησίας σε συγκεκριμένες υπερπαραμέτρους παρατηρήθηκε ότι το προτεινόμενο μοντέλο εμφανίζει μεγαλύτερο βαθμό ευαισθησίας στον αριθμό των κρυφών επιπέδων (hidden units) και στον ρυθμό μάθησης (learning rate). Η ευαισθησία σε αυτές τις υπερπαραμέτρους υποδηλώνει ότι οι τιμές του μπορεί να επηρεάσουν σημαντικά την εκπαίδευση του μοντέλου. Επομένως, χρειάζεται να επιλεγούν οι βέλτιστες τιμές που εξισορροπούν την ταχύτητα σύγκλισης, την απόδοση και τον κίνδυνο υπερπροσαρμογής, προσαρμοσμένες στις ανάγκες του προβλήματος πρόβλεψης της ηλεκτρικής ζήτησης των διάφορων οικιακών συσκευών.
- Στην ανάλυση των αποτελεσμάτων του μοντέλου με βάση επιπλέον σφάλματα παρατηρείται ότι εμφανίζονται παρόμοια αποτελέσματα για το συμμετρικό μέσο απόλυτο ποσοστιαίο σφάλμα (sMAPE) και για το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE). Αυτό υποδηλώνει πως οι προβλέψεις του μοντέλου έχουν παρόμοιο βαθμό απόκλισης από τις πραγματικές τιμές, ανεξάρτητο από την κατεύθυνση της απόκλισης. Συγκεκριμένα, η απόκλιση μεταξύ των προβλέψεων του μοντέλου και των πραγματικών τιμών δεν εξαρτάται από το εάν οι προβλέψεις είναι υπερεκτιμήσεις (θετικές αποκλίσεις) ή υποεκτιμήσεις (αρνητικές αποκλίσεις). Επιπλέον, οι σχετικά χαμηλές τιμές του μέσου απόλυτου σφάλματος (MAE) υποδηλώνουν πως οι προβλέψεις μπορούν να αξιοποιηθούν για διάφορες εφαρμογές, με μικρή απόκλιση από την πραγματική κατανάλωση.

- Συνολικά, μικρό σφάλμα πρόβλεψης σημαίνει αξιοποίηση των προβλέψεων για διάφορες ρυθμίσεις του δικτύου.

7.2 Επεκτάσεις

Με βάση τα αποτελέσματα του μοντέλου, της ανάλυσης ευαισθησίας και τη σύγκριση με απλούστερα μοντέλα, μπορούν να προταθούν ορισμένες προτάσεις για επέκταση της παρούσας εργασίας. Παρακάτω παρουσιάζονται ορισμένες ιδέες για πιθανές επεκτάσεις:

- Διερεύνηση απόκρισης μοντέλου σε διαφορετικά σύνολο δεδομένων και αξιολόγηση του με περισσότερα μετρητικά όπως το μέσο τετραγωνικό σφάλμα (MSE) ή η ρίζα του μέσου τετραγωνικού σφάλματος (RMSE). Αυτά τα μεγέθη μπορούν να προσφέρουν μια πιο ολοκληρωμένη εικόνα της απόδοσης του μοντέλου.
- Εκπαίδευση του μοντέλου με την πλήρη έκδοση του pcap (μεγαλύτερος αριθμός δεδομένων).
- Αξιοποίηση περισσότερων παραμέτρων εισόδου: Μπορεί να εξεταστεί η ενσωμάτωση επιπλέον δεδομένων στο μοντέλο, όπως δεδομένα για εποχικές καταναλώσεις και άλλους παράγοντες που μπορεί να επηρεάζουν την ηλεκτρική ζήτηση. Η ενσωμάτωση αυτών των δεδομένων μπορεί να βελτιώσει την ακρίβεια των προβλέψεων και να επιτρέψει να ανταποκρίνονται σε συγκεκριμένα γεγονότα ή περιβαλλοντικές συνθήκες.
- Εξερεύνηση διαφορετικών αρχιτεκτονικών νευρωνικών δικτύων: Μπορούν να ερευνηθούν διάφορες αρχιτεκτονικές νευρωνικών δικτύων, όπως πολύ-επίπεδα νευρωνικά δίκτυα (MLP), ή ακόμα και μοντέλα βαθιάς μάθησης όπως τα συνελκτικά νευρωνικά δίκτυα (CNN). Αυτές οι διαφορετικές αρχιτεκτονικές θα μπορούσαν να προσφέρουν βελτιωμένη απόδοση σε σχέση με το αρχικό μοντέλο.
- Επέκταση εφαρμογών: Μπορεί να επεκταθεί η εφαρμογή του μοντέλου στην αποδοτικότερη διαχείριση της ενέργειας καθώς και στην εκτίμηση ευελιξίας ενός συνόλου καταναλωτών. Χρησιμοποιώντας τις προβλέψεις, μπορεί να αναλυθούν μοτίβα κατανάλωσης και να ληφθούν μέτρα για την εξοικονόμηση ενέργειας, όπως η αυτόματη ρύθμιση της λειτουργίας συσκευών ή η αντιμετώπιση περιόδων υψηλής ζήτησης από όλους τους συμμετέχοντες στην παραγωγή και διανομή της ηλεκτρικής ενέργειας (πάροχοι, ΦοΣΕ, καταναλωτές).
- Δυναμική τιμολόγηση: Μπορεί να έχει άμεση εφαρμογή στη δυναμική τιμολόγηση ενέργειας, ένα σύστημα όπου οι τιμές προσαρμόζονται ανάλογα με τη ζήτηση και την προσφορά σε πραγματικό χρόνο. Η πρόβλεψη της κατανάλωσης ενέργειας επιτρέπει την προσέγγιση της πιθανής ζήτησης, επιτρέποντας την κατάλληλη ρύθμιση των τιμών ενέργειας από τους παρόχους. Επιπρόσθετα η ενσωμάτωση αυτού του συστήματος σε κάποια εφαρμογή που θα χρησιμοποιείται από τους καταναλωτές, θα τους επιτρέψει να επωφεληθούν από χαμηλότερες τιμές κατά τις περιόδους χαμηλότερης ζήτησης.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] Π. Σ. Γεωργιλιάκης, Σύγχρονα Συστήματα Μεταφοράς και Διανομής Ηλεκτρικής Ενέργειας. Ηλεκτρονικό Βιβλίο, Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών (ΣΕΑΒ), Αθήνα, 2015. Retrieved June 30, 2023, from <http://repository.kallipos.gr/handle/11419/2013>.
- [2] Iea. (2022). World Energy Outlook 2022. IEA. Retrieved June 2, 2023, from <https://www.iea.org/reports/world-energy-outlook-2022>.
- [3] Iea. (2022). CO2 Emissions in 2022. IEA. Retrieved June 2, 2023, from <https://www.iea.org/reports/co2-emissions-in-2022>.
- [4] Horschig, T. (2022). "Are offshore energy islands the future of hydrogen and e-fuel production?" Retrieved June 5, 2023, from <https://www.dnv.com/energy-transition/>.
- [5] I. Alotaibi, et al., "A Comprehensive Review of Recent Advances in Smart Grids: A Sustainable Future with Renewable Energy Resources". Energies, Vol. 13, No. 23, November 2020.
- [6] Πουλλικιάς, Α. (2020). Τί είναι το έξυπνο ηλεκτρικό δίκτυο. Retrieved June 10, 2023, from <https://energypress.gr/>.
- [7] Eurostat. (2022). Energy consumption in households. Retrieved June 8, 2023, from <https://ec.europa.eu/eurostat/statistics-explained/index.php>.
- [8] Y. Liu, et al., "Review of Smart Home Energy Management Systems". Energy Procedia, Vol. 104, pp. 504–508, December 2016.
- [9] Asare-Bediako, B., Ribeiro, P. F., & Kling, W. L. (2012), "Integrated Energy Optimization with Smart Home Energy Management Systems". 3rd IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe), pp. 1–8, October 2012.
- [10] G. Gosnell, D. McCoy, "Market Failures and Willingness to Accept the Smart Energy Transition: Experimental Evidence from the UK". Journal of Environmental Economics and Management, Vol. 118, pp. 102756, March 2023.
- [11] E. Almeshaie, H. Soltan, "A Methodology for Electric Power Load Forecasting". Alexandria Engineering Journal, Vol. 50, No. 2, pp. 137–144, 2011.
- [12] M. A. Hammad, et al., "Methods and Models for Electric Load Forecasting: A Comprehensive Review". Logistics & Sustainable Transport, Vol. 11, pp. 51–76, February 2020.
- [13] I. Nti, et al., "Electricity Load Forecasting: A Systematic Review". Journal of Electrical Systems and Information Technology, Vol. 7, September 2020.
- [14] IEA. (2022). "Empowering people to act: How awareness and behaviour campaigns can enable citizens to save energy during and beyond today's energy crisis." IEA. Retrieved June 10, 2023, from

<https://www.iea.org/commentaries/empowering-people-to-act-how-awareness-and-behaviour-campaigns-can-enable-citizens-to-save-energy-during-and-beyond-today-s-energy-crisis>.

[15] IRENA – International Renewable Energy Agency. (2019). "Demand-side flexibility for power sector transformation." Retrieved June 10, 2023, from https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2019/Dec/IRENA_Demand-side_flexibility_2019.pdf.

[16] Tee, Chin Yen, et al., "Short-Term Load Forecasting Using Artificial Neural Networks", 41st North American Power Symposium, pp. 1–6, Starkville, MS, USA, October 2009.

[17] K. Shahare, et al., "Performance Analysis and Comparison of Various Techniques for Short-Term Load Forecasting". Energy Reports, Vol. 9, pp. 799–808, March 2023.

[18] J. W. Taylor, and P. E. McSharry, "Short-Term Load Forecasting Methods: An Evaluation Based on European Data". IEEE Transactions on Power Systems, Vol. 22, No. 4, pp. 2213–2219, December 2007.

[19] A. Baliyan, et al., "A Review of Short-Term Load Forecasting Using Artificial Neural Network Models". Procedia Computer Science, Vol. 48, pp. 121–125, December 2015.

[20] D. Salman, and M. Kusaf, "Short-Term Unit Commitment by Using Machine Learning to Cover the Uncertainty of Wind Power Forecasting". Sustainability, Vol. 13, No. 24, December 2021.

[21] Vandeput, N. (2021). "A Brief History of Neural Networks". Retrieved June 12, 2023, from <https://medium.com/analytics-vidhya>.

[22] S. Sharif, and J. Taylor, "Short-Term Load Forecasting by Feed-Forward Neural Networks". Vol. Al Ain, United Arab Emirates, May 2000.

[23] I. Goodfellow, et al., "Deep Feedforward Networks" in Deep Learning, MIT Press, 2016.

[24] I. Goodfellow, et al., "Sequence Modeling: Recurrent and Recursive Nets" in Deep Learning, MIT Press, 2016.

[25] (n.d). "Comprehensive Guide to LSTM & RNNs". Retrieved June 12, 2023, from <https://www.turing.com/>.

[26] Y. Zhou, et al., "Appliance Level Short-Term Load Forecasting via Recurrent Neural Network". arXiv [Cs.LG], November 2021.

[27] Y. Bengio, "Practical Recommendations for Gradient-Based Training of Deep Architectures" in Neural Networks: Tricks of the Trade: Second Edition, G. Montavon et al. (Editors), Springer Berlin Heidelberg, 2012.

[28] Jain, S. (2018). "An Overview of Regularization Techniques in Deep Learning (with Python code)". Retrieved June 12, 2023, from <https://www.analyticsvidhya.com/>.

[29] Feurer, M., & Hutter, "Hyperparameter Optimization" in Automated Machine Learning: Methods, Systems, Challenges (pp. 3-33), Cham: Springer International Publishing, 2019.

[30] J. Bergstra, and Y. Bengio, "Random Search for Hyper-Parameter Optimization". Journal of Machine Learning Research, Vol. 13, No. 10, pp. 281–305, 2012.

[31] (2023). "Innovation at Pecan Street". Retrieved June 12, 2023, from <https://www.pecanstreet.org>.

[32] (2023). "Pecan Street Dataport". Retrieved June 12, 2023, from <https://www.pecanstreet.org/dataport/>.

[33] Π. Σ. Γεωργιάκης, Οικονομική και Αξιόπιστη Λειτουργία Σύγχρονων Συστημάτων Ηλεκτρικής Ενέργειας. Ηλεκτρονικό Βιβλίο, Κάλλιπος, Ανοικτές Ακαδημαϊκές Εκδόσεις, Αθήνα, 2023. Retrieved June 30, 2023, from <https://repository.kallipos.gr/handle/11419/9369>.

ΠΗΓΕΣ ΣΧΗΜΑΤΩΝ

Κεφάλαιο 3

Σχήμα 3.1

[12] M. A. Hammad, et al., "Methods and Models for Electric Load Forecasting: A Comprehensive Review". Logistics & Sustainable Transport, Vol. 11, pp. 51–76, February 2020.

Σχήμα 3.2

[24] I. Goodfellow, et al., "Sequence Modeling: Recurrent and Recursive Nets" in Deep Learning, MIT Press, 2016.

Σχήμα 3.3

[25] (n.d). "Comprehensive Guide to LSTM & RNNs". Retrieved June 12, 2023, from <https://www.turing.com/>.