



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ
ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Μη Παρεμβατική Παρακολούθηση Ηλεκτρικού Φορτίου με Denoising Autoencoders

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Λουκάς Λάμπρος Σ. Παπαπέτρου

Επιβλέπων : Ευάγγελος Μαρινάκης
Επίκουρος Καθηγητής Ε.Μ.Π.

Αθήνα, Φεβρουάριος 2025



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ
ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Μη Παρεμβατική Παρακολούθηση Ηλεκτρικού Φορτίου με Denoising Autoencoders

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Λουκάς Λάμπρος Σ. Παπαπέτρου

Επιβλέπων : Ευάγγελος Μαρινάκης
Επίκουρος Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 24^η Φεβρουαρίου 2025.

.....
Ευάγγελος Μαρινάκης,
Επίκουρος Καθηγητής Ε.Μ.Π

.....
Δημήτριος Ασκούνης,
Καθηγητής Ε.Μ.Π

.....
Ιωάννης Ψαρράς,
Καθηγητής Ε.Μ.Π.

Αθήνα, Φεβρουάριος 2025



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ
ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

.....
Λουκάς Λάμπρος Σ. Παπαπέτρου

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

Copyright © Λουκάς Λάμπρος Σ. Παπαπέτρου 2025.
Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Στη σύγχρονη εποχή, η συνεχώς αυξανόμενη κατανάλωση ηλεκτρικής ενέργειας στις κατοικίες αποτελεί ένα από τα σημαντικότερα προβλήματα της κοινωνίας. Με την ταχεία ανάπτυξη της τεχνολογίας και την αυξημένη εξάρτηση από ηλεκτρικές συσκευές, η ζήτηση για ενέργεια αυξάνεται συνεχώς. Ταυτόχρονα αυτή η αύξηση στην κατανάλωση ενέργειας επηρεάζει σημαντικά τόσο το περιβάλλον όσο και το δίκτυο διανομής. Για αυτό το λόγο είναι πιο σημαντικό από ποτέ να εφαρμόσουμε τεχνικές επίβλεψης και περιορισμού της κατανάλωσης. Σε αυτό το πλαίσιο τεχνικές όπως η μη Παρεμβατική Παρακολούθηση Ηλεκτρικού Φορτίου non-intrusive load monitoring (NILM) προσφέρει μια οικονομική και αποδοτική λύση. Το NILM μας επιτρέπει την παρακολούθηση κατανάλωσης ηλεκτρικής ενέργειας κάθε συσκευής μέσα στον χώρο χωρίς όμως να χρειάζεται η εγκατάσταση αισθητήρων σε κάθε συσκευή. Πιο συγκεκριμένα το NILM αναλύει τα δεδομένα κατανάλωσης από τον ηλεκτρικό πίνακα της κατοικίας, και στη συνέχεια αναγνωρίζει τα χαρακτηριστικά κατανάλωσης κάθε συσκευής. Στην παρούσα διπλωματική εργασία χρησιμοποιούμε πραγματικά δεδομένα ενεργειακής κατανάλωσης από δύο διαφορετικές πηγές (το σύνολο δεδομένων REDD και το UKDALE) για να συγκρίνουμε την ακρίβεια τριών αλγορίθμων που προβλέπουν την κατανάλωση ενέργειας των συσκευών, χρησιμοποιώντας μόνο τα δεδομένα κατανάλωσης από τον ηλεκτρικό πίνακα της κατοικίας. Συγκεκριμένα, εξετάζουμε τους αλγόριθμους Combinatorial Optimization, Factorial Hidden Markov Models, και έναν αλγόριθμο μηχανικής μάθησης βασισμένο στην αρχιτεκτονική Denoising Autoencoders. Συγκρίνουμε την αποτελεσματικότητα αυτών των αλγορίθμων χρησιμοποιώντας κατάλληλες μετρικές (recall, precision, accuracy, F1 score, root mean square error), τόσο σε προβλέψεις για κατοικίες που ανήκουν στο σύνολο δεδομένων εκπαίδευσης, όσο και για κατοικίες που ανήκουν σε διαφορετικά σύνολα δεδομένων, με στόχο να αξιολογήσουμε κατά πόσο τα μοντέλα μπορούν να γενικευτούν με επιτυχία.

Λέξεις κλειδιά: Μη παρεμβατική παρακολούθηση φορτίου, αποσύνθεση ενέργειας, κρυφά μαρκοβιανά μοντέλα, συνδυαστική βελτιστοποίηση, μηχανική μάθηση, νευρωνικά δίκτυα, denoising autoencoders

Abstract

In modern times, the steadily rising demand for electricity in residential areas has become a major societal issue. With rapid technological advancement and greater dependence on electrical devices, energy demand is constantly rising. This increase in energy consumption greatly impacts both the environment and the distribution grid. Therefore, it is more critical than ever to implement monitoring and consumption-limiting techniques. In this context, techniques like Non-Intrusive Load Monitoring (NILM) offer an affordable and efficient solution. NILM enables the monitoring of each device's electricity consumption in a household without requiring sensor installation on each device. Specifically, NILM analyzes consumption data from the household's main electrical panel, then identifies the consumption characteristics of each device. In this thesis, we use real energy consumption data from two different sources (the REDD and UKDALE datasets) to compare the accuracy of three algorithms that predict appliance energy consumption using only data from the household's main electrical panel. Specifically, we examine the Combinatorial Optimization, Factorial Hidden Markov Models, and a machine learning algorithm based on Denoising Autoencoder architecture. We compare these algorithms performance using relevant metrics (recall, precision, accuracy, F1 score, and root mean square error) both on predictions for homes included in the training dataset and on homes from different datasets, aiming to determine how well the models can generalize successfully.

Keywords: Non-intrusive load monitoring, energy disaggregation, hidden Markov models, combinatorial optimization, machine learning, neural networks, denoising autoencoders

Ευχαριστίες

Με την ολοκλήρωση αυτής της διπλωματικής εργασίας θα ήθελα να ευχαριστήσω τον κ. Ευάγγελο Μαρινάκη, επίκουρο καθηγητή της σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Ηλεκτρονικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου για την εμπιστοσύνη και την ευκαιρία που μου έδωσε με την ανάθεση ενός ενδιαφέροντος θέματος για την εκπόνηση της διπλωματικής μου εργασίας.

Επιπλέον, θα ήθελα να ευχαριστήσω θερμά τους υποψήφιους διδάκτορες κ. Ιωάννη Παπία και Βασίλη Μιχαλακόπουλο για την υπομονή, την πολύτιμη βοήθεια και καθοδήγηση που μου παρείχαν σε όλη την διάρκεια εκπόνησης της εργασίας, καθώς και για τον πολύτιμο χρόνο που μου αφιέρωσαν.

Τέλος, θα ήθελα από καρδιάς να ευχαριστήσω την μητέρα μου, Γεωργία, τον πατέρα μου, Σεραφείμ, τον αδελφό μου Βασίλη καθώς και τους φίλους μου για την συνεχή στήριξη τους όλα αυτά τα χρόνια που ήταν καίρια για την ολοκλήρωση των σπουδών μου.

Λουκάς Λάμπρος Παπαπέτρου
Αθήνα, Φεβρουάριος 2025

Περιεχόμενα

Περίληψη	5
Abstract.....	7
Ευχαριστίες	9
Περιεχόμενα.....	11
Λίστα Σχημάτων	13
Λίστα Πινάκων.....	15
Κεφάλαιο 1. Εισαγωγή	17
1.1 Αντικείμενο εργασίας.....	17
1.2 Δομή Διπλωματικής	18
Κεφάλαιο 2. Μη παρεμβατική παρακολούθηση φορτίου	19
2.1 Ορισμός και σημασία	19
2.2 Ιστορική Αναδρομή	20
2.3 Τεχνικές και προσεγγίσεις.....	22
2.4 Οφέλη στη Διαχείριση Ενέργειας	23
Κεφάλαιο 3. Θεωρητικό υπόβαθρο.....	27
3.1 Combinatorial optimization.....	27
3.1.1 Επισκόπηση.....	27
3.1.2 Εφαρμογές στην ενεργειακή αποδόμηση	27
3.2 Factorial hidden markov models.....	28
3.2.1 Επισκόπηση.....	28
3.2.2 Εφαρμογές στην ενεργειακή αποδόμηση	29
3.3 Μηχανική Μάθηση	30
3.3.1 Νευρωνικά δίκτυα	34
3.3.2 Συναρτήσεις Ενεργοποίησης.....	35
3.3.3 Συνάρτηση κόστους.....	40
3.3.4 Αλγόριθμος οπισθοδιάδοσης	45
3.3.5 Μεταφορά Μάθησης	47
3.4 Denoising Autoencoders	48
3.4.1 Επισκόπηση.....	48
3.4.2 Βασικές αρχές	50
3.4.3 Εφαρμογές στην ενεργειακή αποδόμηση	51
Κεφάλαιο 4. Μεθοδολογία	54
4.1 Περιγραφή Συνόλου Δεδομένων	54

4.1.1 UKDALE	55
4.1.2 REDD	55
4.2 Επιλογή συσκευών.....	56
4.3 Μοντέλο	58
4.4 Προεπεξεργασία δεδομένων.....	61
4.5 Μετρικές.....	62
4.6 Πειραματική μέθοδος.....	65
Κεφάλαιο 5. Αποτελέσματα	67
5.1 Σετ δεδομένων REDD.....	67
5.1.1 Fridge	67
5.1.2 Microwave	68
5.1.3 Washing machine	70
5.1.4 Dish washer	71
5.2 Σετ δεδομένων UKDALE	72
5.2.1 Fridge	73
5.2.2 Microwave	74
5.2.3 Washing machine	75
5.2.4 Dish washer	77
5.3 Ανάμεικτα δεδομένα	78
5.3.1 Σετ δεδομένων REDD μοντέλα UKDALE και REDD	78
5.3.2 Σετ δεδομένων UKDALE μοντέλα UKDALE και REDD	81
Κεφάλαιο 6. Επίλογος.....	84
6.1 Συμπεράσματα.....	84
6.2 Μελλοντικές προεκτάσεις	85
Βιβλιογραφία	88

Λίστα Σχημάτων

Σχήμα 1: Προβλεπόμενη ενεργειακή κατανάλωση ανά περιοχή μέχρι το 2050 [4]	19
Σχήμα 2: Ποσοστό ετήσιας εξοικονόμησης ενέργειας από ανατροφοδότηση πληροφοριών στους καταναλωτές για τις ενεργειακές τους συνήθειες [6]	24
Σχήμα 3: Κατηγορίες μηχανικής μάθησης [11]	31
Σχήμα 4: Νευρώνας ανθρώπου [14]	34
Σχήμα 5: Τεχνητός νευρώνας [15]	34
Σχήμα 6: Multi-Layered Perceptron [16]	35
Σχήμα 7: Συνάρτηση ενεργοποίησης γραμμικής [17]	36
Σχήμα 8: Συνάρτηση ενεργοποίησης ReLu [17]	37
Σχήμα 9: Συνάρτηση ενεργοποίησης σιγμοειδής [17]	38
Σχήμα 10: Συνάρτηση ενεργοποίησης υπερβολικής εφαπτομένης [17]	39
Σχήμα 11: Συνάρτηση ενεργοποίησης softmax [17]	40
Σχήμα 12: Γραφική παράσταση συνάρτησης κόστους MSE [18]	41
Σχήμα 13: Γραφική παράσταση συνάρτησης κόστους MAE [18]	42
Σχήμα 14: Γραφική παράσταση συνάρτησης κόστους Log Loss [18]	43
Σχήμα 15: Γραφική παράσταση συνάρτησης κόστους Hinge Loss [18]	44
Σχήμα 16: Γραφική παράσταση συνάρτησης κόστους Huber Loss [18]	45
Σχήμα 17: Δομή Denoising Autoencoders [20]	48
Σχήμα 18: Ροή εργασίας ενός DAE σε φωτογραφίες αριθμών [21]	49
Σχήμα 19: Dataset REDD, appliance fridge, metric recall	67
Σχήμα 20: Dataset REDD, appliance fridge, metric precision	67
Σχήμα 21: Dataset REDD, appliance fridge, metric accuracy	67
Σχήμα 22: Dataset REDD, appliance fridge, metric f1 score	68
Σχήμα 23: Dataset REDD, appliance fridge, metric rmse	68
Σχήμα 24: Dataset REDD, appliance microwave, metric recall	69
Σχήμα 25: Dataset REDD, appliance microwave, metric precision	69
Σχήμα 26: Dataset REDD, appliance microwave, metric accuracy	69
Σχήμα 27: Dataset REDD, appliance microwave, metric f1 score	69
Σχήμα 28: Dataset REDD, appliance microwave, metric rmse	69
Σχήμα 29: Dataset REDD, appliance washing machine, metric recall	70
Σχήμα 30: Dataset REDD, appliance washing machine, metric precision	70
Σχήμα 31: Dataset REDD, appliance washing machine, metric accuracy	70
Σχήμα 32: Dataset REDD, appliance washing machine, metric f1 score	70
Σχήμα 33: Dataset REDD, appliance washing machine, metric rmse	70
Σχήμα 34: Dataset REDD, appliance dish washer, metric recall	71
Σχήμα 35: Dataset REDD, appliance dish washer, metric precision	71
Σχήμα 36: Dataset REDD, appliance dish washer, metric accuracy	71
Σχήμα 37: Dataset REDD, appliance dish washer, metric f1 score	72
Σχήμα 38: Dataset REDD, appliance dish washer, metric rmse	72
Σχήμα 39: Dataset UKDALE, appliance fridge, metric recall	73
Σχήμα 40: Dataset UKDALE, appliance fridge, metric precision	73
Σχήμα 41: Dataset UKDALE, appliance fridge, metric accuracy	73
Σχήμα 42: Dataset UKDALE, appliance fridge, metric f1 score	73
Σχήμα 43: Dataset UKDALE, appliance fridge, metric rmse	73

Σχήμα 44: Dataset UKDALE, appliance microwave, metric recall.....	74
Σχήμα 45: Dataset UKDALE, appliance microwave, metric precision	74
Σχήμα 46: Dataset UKDALE, appliance microwave, metric accuracy	74
Σχήμα 47: Dataset UKDALE, appliance microwave, metric f1 score	75
Σχήμα 48: Dataset UKDALE, appliance microwave, metric rmse.....	75
Σχήμα 49: Dataset UKDALE, appliance washing machine, metric recall	76
Σχήμα 50: Dataset UKDALE, appliance washing machine, metric precision	76
Σχήμα 51: Dataset UKDALE, appliance washing machine, metric accuracy	76
Σχήμα 52: Dataset UKDALE, appliance washing machine, metric f1 score	76
Σχήμα 53: Dataset UKDALE, appliance washing machine, metric rmse	76
Σχήμα 54: Dataset UKDALE, appliance dish washer, metric recall	77
Σχήμα 55: Dataset UKDALE, appliance dish washer, metric precision	77
Σχήμα 56: Dataset UKDALE, appliance dish washer, metric accuracy	77
Σχήμα 57: Dataset UKDALE, appliance dish washer, metric f1 score.....	77
Σχήμα 58: Dataset UKDALE, appliance dish washer, metric rmse	77
Σχήμα 59: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset REDD appliance fridge.....	79
Σχήμα 60: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset REDD appliance microwave.....	79
Σχήμα 61: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset REDD appliance washing machine	79
Σχήμα 62: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset REDD appliance dish washer.....	79
Σχήμα 63: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset UKDALE appliance fridge	81
Σχήμα 64: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset UKDALE appliance microwave.....	81
Σχήμα 65: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset UKDALE appliance washing machine.....	81
Σχήμα 66: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset UKDALE appliance dish washer	81

Λίστα Πινάκων

Πίνακας 1: Στρώματα πειραματικού μοντέλου DAE.....	59
Πίνακας 2: Confusion Matrix	63
Πίνακας 3: Σύγκριση CO,FHMM,DAE συσκευής fridge στο dataset REDD	67
Πίνακας 4: Σύγκριση CO,FHMM,DAE συσκευής MICROWAVE στο dataset REDD	68
Πίνακας 5: Σύγκριση CO,FHMM,DAE συσκευής WASHING MACHINE στο dataset REDD	70
Πίνακας 6: Σύγκριση CO,FHMM,DAE συσκευής DISH WASHER στο dataset REDD	71
Πίνακας 7: Σύγκριση CO,FHMM,DAE συσκευής FRIDGE στο dataset UKDALE ..	73
Πίνακας 8: Σύγκριση CO,FHMM,DAE συσκευής MICROWAVE στο dataset UKDALE	74
Πίνακας 9: Σύγκριση CO,FHMM,DAE συσκευής WASHING MACHINE στο dataset UKDALE	75
Πίνακας 10: Σύγκριση CO,FHMM,DAE συσκευής DISH WASHER στο dataset UKDALE	77
Πίνακας 11: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset REDD	78
Πίνακας 12: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset UKDALE	81

Κεφάλαιο 1. Εισαγωγή

1.1 Αντικείμενο εργασίας

Τα τελευταία χρόνια η ραγδαία ανάπτυξη της τεχνολογίας έχει προσφέρει πολλά οφέλη στην ανθρωπότητα, βελτιώνοντας την ποιότητα ζωής, διευκολύνοντας την επικοινωνία και αυξάνοντας την παραγωγικότητα. Ταυτόχρονα όμως αυτή η τεχνολογική πρόοδος έχει και αρνητικές επιπτώσεις. Η συνεχής χρήση και εξάρτηση από ηλεκτρονικές συσκευές έχει οδηγήσει σε αυξανόμενη ζήτηση για ηλεκτρική ενέργεια, επιβαρύνοντας το περιβάλλον και αυξάνοντας περαιτέρω τις εκπομπές αερίων του θερμοκηπίου. Επομένως, είναι πολύ σημαντικό να εφαρμοστούν τεχνικές περιορισμού της ενεργειακής κατανάλωσης.

Ένας τρόπος με τον οποίο μπορεί να περιοριστεί η ενεργειακή κατανάλωση είναι τα έξυπνα δίκτυα. Τα έξυπνα δίκτυα είναι προηγμένα δίκτυα διανομής ενέργειας που χρησιμοποιούν ψηφιακή τεχνολογία για την παρακολούθηση και τη διαχείριση της παραγωγής και κατανάλωσης ενέργειας σε πραγματικό χρόνο. Μέσω της συνεχούς συλλογής και ανάλυσης δεδομένων κατανάλωσης, αυτά τα δίκτυα μπορούν να βελτιώσουν την αποδοτικότητα της διανομής ενέργειας, μειώνοντας τις απώλειες και προσαρμόζοντας την παροχή ενέργειας στις εκάστοτε ανάγκες των χρηστών. Επιπλέον, οι ατομικές επιλογές των νοικοκυριών παίζουν καθοριστικό ρόλο στην προσπάθεια περιορισμού της ενεργειακής κατανάλωσης. Με την υιοθέτηση απλών αλλά σημαντικών πρακτικών, όπως η χρήση ενεργειακά αποδοτικών συσκευών και η συνειδητή κατανάλωση ενέργειας τα νοικοκυριά μπορούν να συμβάλουν ουσιαστικά στη μείωση της ζήτησης ηλεκτρικής ενέργειας. Όμως για την υλοποίηση τόσο των έξυπνων δικτύων αλλά και την τροποποίηση των ατομικών επιλογών των νοικοκυριών είναι αναγκαία η συλλογή δεδομένων κατανάλωσης συσκευών σε κάθε νοικοκυριό. Το παραπάνω αποτελεί ένα σημαντικό εμπόδιο καθώς απαιτείται η εγκατάσταση αισθητήρων σε κάθε συσκευή κάτι το οποίο είναι κοστοβόρο και αρκετές φορές δεν είναι εφικτό, κάνοντας έτσι αρκετά δύσκολη την συλλογή δεδομένων ενεργειακής κατανάλωσης.

Το Non-intrusive load monitoring (NILM) [1] είναι μια τεχνολογία που μπορεί να συμβάλει καθοριστικά στην παρακολούθηση της κατανάλωσης των οικιακών συσκευών χωρίς την χρήση πολλαπλών αισθητήρων, κάτι το οποίο την καθιστά μια οικονομική και πρακτική λύση που μπορεί να εφαρμοστεί πολύ εύκολα σε ένα νοικοκυριό ή μια επιχείρηση αυξάνοντας έτσι τον όγκο των δεδομένων ενεργειακής κατανάλωσης. Ο τρόπος με τον οποίο λειτουργεί το NILM είναι συλλέγοντας δεδομένα μόνο από τον κεντρικό μετρητή της οικίας και στη συνέχεια χρησιμοποιεί αλγόριθμους για να αναγνωρίσει τις ενεργειακές ανάγκες κάθε συσκευής [1]. Αυτό παρέχει στον διαχειριστή του χώρου ακριβείς πληροφορίες για το πότε και πόση ενέργεια καταναλώνει η κάθε συσκευή, επιτρέποντας στους καταναλωτές να εντοπίσουν σπατάλες ώστε να προσαρμόσουν τις συνήθειες τους.

1.2 Δομή Διπλωματικής

Η διπλωματική εργασία επικεντρώνεται στην ανάλυση και αξιολόγηση των μεθόδων τεχνητής νοημοσύνης για την ενεργειακή αποδόμηση μέσω της χρήσης Denoising Autoencoders. Η μελέτη περιλαμβάνει πειραματικά αποτελέσματα που βασίζονται σε διαφορετικά σύνολα δεδομένων, καθώς και συγκρίσεις με παραδοσιακές μεθόδους αποδόμησης ενέργειας. Πιο συγκεκριμένα:

- **Κεφάλαιο 1: Εισαγωγή**

Στο κεφάλαιο αυτό παρουσιάζεται το αντικείμενο της διπλωματικής εργασίας, το οποίο αφορά τη μελέτη και εφαρμογή μεθόδων για τη μη παρεμβατική παρακολούθηση φορτίου και την αποδόμηση ενεργειακής κατανάλωσης.

- **Κεφάλαιο 2: Μη παρεμβατική παρακολούθηση φορτίου**

Εξετάζεται η μη παρεμβατική παρακολούθηση φορτίου, με αναφορές στον ορισμό της, την ιστορική της αναδρομή, τις διάφορες τεχνικές και προσεγγίσεις, καθώς και τα οφέλη της στη διαχείριση ενέργειας.

- **Κεφάλαιο 3: Θεωρητικό Υπόβαθρο**

Το κεφάλαιο αυτό καλύπτει τις θεωρητικές έννοιες της συνδυαστικής βελτιστοποίησης, των κρυφών μοντέλων Markov και των τεχνικών μηχανικής μάθησης, όπως τα νευρωνικά δίκτυα και οι Denoising Autoencoders, με αναφορά στις εφαρμογές τους στην αποδόμηση ενέργειας.

- **Κεφάλαιο 4: Μεθοδολογία**

Στο κεφάλαιο αυτό περιγράφονται τα πειραματικά βήματα της διπλωματικής εργασίας. Αναλύονται τα σύνολα δεδομένων που χρησιμοποιήθηκαν (UKDALE και REDD), οι τεχνικές προεπεξεργασίας που εφαρμόστηκαν και η εφαρμογή των μοντέλων DAE για την αποδόμηση. Τέλος, γίνεται αναφορά στις διατάξεις των μοντέλων και στο περιβάλλον εκτέλεσης.

- **Κεφάλαιο 5: Πειραματικά Αποτελέσματα**

Το κεφάλαιο αυτό εστιάζει στην παρουσίαση των αποτελεσμάτων που προέκυψαν από την εφαρμογή της προτεινόμενης μεθοδολογίας, με έμφαση στη σύγκριση αποτελεσμάτων μεταξύ των συνόλων δεδομένων REDD και UKDALE. Περιλαμβάνονται, επίσης, πειράματα που αξιολογούν την απόδοση των μοντέλων DAE σε σύνολα δεδομένων διαφορετικά από αυτά στα οποία εκπαιδεύτηκαν.

- **Κεφάλαιο 6: Συμπεράσματα και Μελλοντικές Κατευθύνσεις**


Συνοψίζονται τα κύρια συμπεράσματα της εργασίας και η συνολική συνεισφορά της στη μελέτη της ενεργειακής αποδόμησης. Προτείνονται επίσης μελλοντικές κατευθύνσεις για περαιτέρω έρευνα, όπως η βελτίωση των μοντέλων DAE ή η εφαρμογή σε διαφορετικά σύνολα δεδομένων.

Η εργασία στοχεύει στην παρουσίαση μιας ολοκληρωμένης εικόνας της μεθοδολογίας και των αποτελεσμάτων, προσφέροντας μια συγκριτική ανάλυση των μεθόδων που χρησιμοποιήθηκαν για την αποδόμηση ενέργειας.

Κεφάλαιο 2. Μη παρεμβατική παρακολούθηση φορτίου

2.1 Ορισμός και σημασία

Περίπου το 55% του ανθρώπινου πληθυσμού ζει σε αστικές περιοχές και το ποσοστό αυτό προβλέπεται να αυξηθεί στο 68% μέχρι το 2050 [2]. Ταυτόχρονα, οι αστικές περιοχές, λόγω του πυκνού πληθυσμού τους και της συγκέντρωσης των οικονομικών δραστηριοτήτων τους, είναι κύριοι καταναλωτές ενέργειας και ευθύνονται για ένα σημαντικό μέρος της παγκόσμιας χρήσης ενέργειας και των εκπομπών αερίων του θερμοκηπίου. Μελέτες δείχνουν ότι οι πόλεις αντιπροσωπεύουν περίπου το 75% της παγκόσμιας κατανάλωσης ενέργειας και παρόμοιο ποσοστό των εκπομπών άνθρακα σύμφωνα με εκτιμήσεις [3]. Επομένως, είναι πάρα πολύ σημαντικό να αναπτυχθούν και να εφαρμοστούν τεχνικές οι οποίες θα περιορίσουν το ενεργειακό αποτύπωμα των πόλεων.



Σχήμα 1: Προβλεπόμενη ενεργειακή κατανάλωση ανά περιοχή μέχρι το 2050 [4]

Η μείωση της κατανάλωσης ενέργειας στις αστικές περιοχές είναι μια πολύπλοκη και πολύπλευρη πρόκληση που απαιτεί ποικίλες στρατηγικές. Με τα χρόνια, πόλεις σε όλο τον κόσμο έχουν εφαρμόσει διάφορες μεθόδους για την αντιμετώπιση αυτού του ζητήματος μεταξύ άλλων είναι η ανακαίνιση παλαιών κτιρίων [5], εγκατάσταση πιο αποδοτικών συσκευών, κατασκευή πράσινων κτηρίων, προώθηση των μέσων μαζικής μεταφοράς και εγκατάσταση υποδομών ποδηλασίας, καθεμία με τα δικά της πλεονεκτήματα και προκλήσεις [6] [7]. Μεταξύ αυτών των προσεγγίσεων, αρκετές έχουν αποδειχθεί ιδιαίτερα αποτελεσματικές στη σημαντική μείωση της χρήσης ενέργειας. Ωστόσο, αξίζει να σημειωθεί ότι ενώ αυτές οι στρατηγικές επιφέρουν τα επιθυμητά αποτελέσματα περιορίζοντας την κατανάλωση ηλεκτρικής ενέργειας και κατά συνέπεια εκπομπών ρύπων, συχνά συνοδεύονται από σημαντικό οικονομικό κόστος καθώς περιλαμβάνουν σημαντικές επενδύσεις σε προηγμένες τεχνολογίες, υποδομές και συστήματα και η υλοποίησή τους είναι αρκετά χρονοβόρα καθώς ο εκτενής σχεδιασμός, ο συντονισμός και οι ρυθμιστικές απαιτήσεις που απαιτούνται συχνά συμβάλλουν σε παρατεταμένα χρονοδιαγράμματα. Επιπλέον, η εξασφάλιση εγκρίσεων από δημόσιους αξιωματούχους και αρμόδιες αρχές μπορεί να είναι μια χρονοβόρα διαδικασία, καθώς περιλαμβάνει πολλαπλά επίπεδα ελέγχου, τήρηση των κανονισμών και μερικές φορές δημόσιες διαβουλεύσεις.

Οι πρόσφατες εξελίξεις στο Διαδίκτυο των πραγμάτων (IoT), τον υπολογισμό αιχμής (edge computing), τα έξυπνα δίκτυα (smart grids), την μηχανική μάθηση (machine learning) και τους έξυπνους μετρητές παρέχουν όλες τις απαραίτητες προϋποθέσεις για να ανοίξει ο δρόμος προς βιώσιμες έξυπνες πόλεις (smart cities) που είναι σε θέση να περιορίσουν την κατανάλωση ενέργειας με σχετικά μικρό κόστος ειδικά σε σύγκριση με εγκατάσταση νέων υποδομών. Οι έξυπνες πόλεις παρέχουν διάφορες τεχνικές με τις οποίες μπορεί να περιοριστεί η κατανάλωση ενέργειας και ο κοινός παρονομαστής σε αρκετές από αυτές είναι η λεπτομερής γνώση της κατανάλωσης ηλεκτρικής ενέργειας. Προηγούμενες μελέτες δείχνουν ότι οι πληροφορίες σε επίπεδο συσκευής μπορούν να συμβάλουν στη μείωση της κατανάλωσης ενέργειας αυξάνοντας την ευαισθητοποίηση των καταναλωτών και διευκολύνοντας νέες εφαρμογές εξοικονόμησης ενέργειας για βιώσιμες έξυπνες πόλεις [8].

Για την συλλογή δεδομένων κατανάλωσης των επιμέρους συσκευών μέσα σε μια οικία υπάρχουν 2 κυρίαρχες μέθοδοι, η παρεμβατική παρακολούθηση φορτίου (ILM) και η μη παρεμβατική παρακολούθηση φορτίου (NILM). Το ILM περιλαμβάνει την εγκατάσταση μετρητών σε κάθε ξεχωριστή συσκευή [9]. Αυτή η διαδικασία παρέχει λεπτομερή δεδομένα αλλά προσθέτει πολυπλοκότητα στην εγκατάσταση, καθώς απαιτεί τεχνική εξειδίκευση και ενδέχεται να διαταράξει την υπάρχουσα ηλεκτρική υποδομή. Παρά την υψηλή ακρίβεια που προσφέρει, το ILM έχει σημαντικό κόστος και είναι χρονοβόρο [9]. Επιπλέον, τα συστήματα ILM απαιτούν συνεχή συντήρηση, καθώς κάθε αισθητήρας πρέπει να διατηρείται σε κατάσταση λειτουργίας, γεγονός που μπορεί να οδηγήσει σε υψηλότερο μακροπρόθεσμο κόστος και λειτουργικές προκλήσεις. Τέλος η επεμβατική φύση του ILM το καθιστά επίσης λιγότερο πρακτικό για ευρεία υιοθέτηση, ειδικά σε περιβάλλοντα μεγάλης κλίμακας όπου η παρακολούθηση πολλών συσκευών μεμονωμένα είναι δύσκολη.

Σε αντίθεση με το ILM, το NILM χρησιμοποιεί έναν μόνο έξυπνο μετρητή (smart-meter) εγκατεστημένο στον κεντρικό ηλεκτρικό πίνακα για να παρακολουθεί τη συνολική κατανάλωση ενέργειας ενός νοικοκυριού ή μιας εγκατάστασης. Στη συνέχεια κάνοντας χρήση εξειδικευμένων αλγόριθμων αποσυνθέτει την αρχική κατανάλωση σε ξεχωριστές καταναλώσεις των επιμέρους συσκευών [1]. Το κύριο πλεονέκτημα του NILM είναι η μη επεμβατική φύση του, καθώς εξαλείφει την ανάγκη για πολλαπλούς αισθητήρες, μειώνοντας σημαντικά το κόστος εγκατάστασης και συντήρησης. Επιπλέον, η ευκολία εγκατάστασης του NILM θα βοηθήσει στην ταχύτερη υιοθέτηση του με αποτέλεσμα την συλλογή περισσότερων δεδομένων. Επομένως, η ικανότητά του να παρέχει λεπτομερείς πληροφορίες για την ενέργεια χωρίς την πολυπλοκότητα και τα έξοδα που σχετίζονται με το ILM καθιστά το NILM μια ανώτερη επιλογή τόσο για οικιακούς όσο και για βιομηχανικούς χώρους.

2.2 Ιστορική Αναδρομή

Η έννοια της μη παρεμβατικής παρακολούθησης ηλεκτρικού φορτίου (NILM) αναφέρεται για πρώτη φορά το 1992 από τον George W. Hart και τους συνεργάτες του στο Τεχνολογικό Ινστιτούτο της Μασαχουσέτης (MIT) [1]. Το πρωτοποριακό τους έργο είχε ως κίνητρο την ανάγκη παρακολούθησης της κατανάλωσης ενέργειας σε κατοικίες με οικονομικό και μη παρεμβατικό τρόπο. Πριν την έννοια της μη παρεμβατικής παρακολούθησης ο μόνος τρόπος για την παρακολούθηση της κατανάλωσης ήταν η εγκατάσταση αισθητήρων σε κάθε συσκευή της οικίας, κάτι το οποίο είναι κοστοβόρο απαιτεί χρόνο για την εγκατάσταση και δεν είναι ιδιαίτερα

πρακτικό ειδικά σε κλίμακες μεγάλου μεγέθους. Η καινοτομία του George W. Hart ήταν να καταγράφει την ηλεκτρική κατανάλωση όλου του σπιτιού πριν από τον ηλεκτρικό πίνακα και στην συνέχεια να αναλύει το ηλεκτρικό σήμα στις επιμέρους συσκευές της οικίας με βάση την ηλεκτρική τους υπογραφή. Το αρχικό σύστημα του Hart για το NILM βασιζόταν στην καταγραφή μεταβατικών καταστάσεων (electrical transients). Οι μεταβατικές καταστάσεις είναι βραχύχρονες διαταραχές ή αλλαγές που συμβαίνουν σε ένα ηλεκτρικό κύκλωμα ή σύστημα. Αυτές οι διαταραχές μπορούν να προκληθούν από ξαφνικές μεταβολές στην τάση ή το ρεύμα. Η ενεργοποίηση ή απενεργοποίηση μιας συσκευής παράγει διακριτές μεταβατικές καταστάσεις οι οποίες μπορούν να συσχετιστούν με συσκευές [10]. Οι αρχικές μέθοδοι βασίζονταν σε προσεγγίσεις βασισμένες σε κανόνες, οι οποίες περιλάμβαναν προκαθορισμένες υπογραφές για διαφορετικές συσκευές [1]. Ενώ αυτά τα πρώιμα συστήματα για την εποχή τους ήταν πρωτοποριακά, είχαν περιορισμούς όσον αφορά την ακρίβεια των αποτελεσμάτων καθώς και στην επέκταση σε μεγάλη κλίμακα, ειδικά σε περιπτώσεις όπου υπάρχουν πολλές συσκευές και κάποιες από αυτές έχουν πανομοιότυπη υπογραφή κατανάλωσης.

Καθώς το πεδίο του NILM εξελίχθηκε κατά τη διάρκεια της δεκαετίας του 1990 και στις αρχές της δεκαετίας του 2000, οι ερευνητές άρχισαν να αναπτύσσουν πιο εξελιγμένες τεχνικές επεξεργασίας σήματος και να ενσωματώνουν στατιστικές μεθόδους για τη βελτίωση της ακρίβειας του διαχωρισμού φορτίου. Αυτή η περίοδος σηματοδότησε μια μετάβαση από το NILM που ήταν πρωταρχικά μια ακαδημαϊκή επιδίωξη στο να εξεταστεί για πρακτικές εφαρμογές στην παρακολούθηση της ενέργειας κατοικιών. Η πρόοδος της μηχανικής μάθησης και της τεχνητής νοημοσύνης στα τέλη της δεκαετίας του 2000 και στις αρχές της δεκαετίας του 2010 έφερε επανάσταση στο NILM. Αυτές οι τεχνολογίες επέτρεψαν την ανάπτυξη πιο ακριβών και ευέλικτων συστημάτων NILM που θα μπορούσαν να μάθουν από τα δεδομένα και να βελτιωθούν με την πάροδο του χρόνου. Οι αλγόριθμοι μηχανικής μάθησης επέτρεψαν στα συστήματα NILM να προσαρμοστούν σε ένα ευρύτερο φάσμα συσκευών και μοτίβων χρήσης, βελτιώνοντας σημαντικά την απόδοσή τους. Επιπλέον, η αυξανόμενη διαθεσιμότητα υπολογιστικής ισχύος και προηγμένων τεχνικών επεξεργασίας δεδομένων διευκόλυνε την εφαρμογή συστημάτων NILM σε πραγματικό χρόνο, με αποτέλεσμα να υπάρχει η δυνατότητα να παρέχουν άμεση ανατροφοδότηση στους χρήστες.

Σήμερα, το NILM είναι σε θέση να αποτελέσει βασικό συστατικό των έξυπνων πόλεων και των συστημάτων IoT, παίζοντας κρίσιμο ρόλο στην παρακολούθηση και τη διαχείριση της χρήσης ενέργειας. Καθώς οι πόλεις γίνονται πιο έξυπνες και πιο διασυνδεδεμένες, η δυνατότητα παρακολούθησης της κατανάλωσης ενέργειας σε επίπεδο συσκευής χρησιμοποιώντας το NILM είναι απαραίτητη για τη βελτιστοποίηση της διανομής ενέργειας, τη μείωση της σπατάλης και τη βελτίωση της βιωσιμότητας. Οι συνεχιζόμενες εξελίξεις στην τεχνητή νοημοσύνη και στην ανάλυση μεγάλων δεδομένων ωθούν συνεχώς τα όρια του NILM, καθιστώντας το ένα ολοένα και πιο σημαντικό εργαλείο για τη μετάβαση σε έξυπνα δίκτυα και βιώσιμα αστικά περιβάλλοντα.

2.3 Τεχνικές και προσεγγίσεις

Η ακρίβεια των συστημάτων NILM είναι υψίστης σημασίας, καθώς καθορίζει την αξιοπιστία των πληροφοριών που δημιουργούνται, οι οποίες με τη σειρά τους επηρεάζουν τις στρατηγικές ενεργειακής απόδοσης, τη συμπεριφορά χρήσης της συσκευής και τις ευρύτερες εφαρμογές έξυπνου δικτύου. Οι δύο παράγοντες που επηρεάζουν ριζικά την ακρίβεια του NILM είναι η ποιότητα των δεδομένων που συλλέγονται από τους έξυπνους μετρητές και οι τεχνικές που χρησιμοποιούνται για τον διαχωρισμό αυτών των δεδομένων. Ενώ και οι δύο παράγοντες είναι ιδιαίτερα σημαντικοί, οι τεχνικές που χρησιμοποιούνται στη διαδικασία διαχωρισμού παίζουν καίριο ρόλο στον καθορισμό του πόσο αποτελεσματικά τα συστήματα NILM μπορούν να διακρίνουν μεταξύ διαφορετικών συσκευών και να παρέχουν ακριβείς μετρήσεις.

Οι τεχνικές και οι προσεγγίσεις που χρησιμοποιούνται στο NILM έχουν εξελιχθεί σημαντικά τις τελευταίες δεκαετίες, με γνώμονα την πρόοδο στην επεξεργασία σήματος, τη μηχανική μάθηση, την τεχνητή νοημοσύνη και την ενσωμάτωση συσκευών IoT. Αυτές οι εξελίξεις επέτρεψαν στα συστήματα NILM να αναλύουν τη συνολική κατανάλωση ενέργειας με μεγαλύτερη ακρίβεια. Οι στατιστικές μέθοδοι ήταν από τις πρώτες προσεγγίσεις που χρησιμοποιήθηκαν στο NILM. Αυτές οι τεχνικές βασίζονται στην υπόθεση ότι κάθε συσκευή έχει ένα μοναδικό σήμα κατανάλωσης ενέργειας, το οποίο μπορεί να προσδιοριστεί από το συνολικό φορτίο. Μία από τις παλαιότερες στατιστικές μεθόδους είναι η συνδυαστική βελτιστοποίηση (Combinatorial optimization - CO), όπου η συνολική κατανάλωση ενέργειας μοντελοποιείται ως συνδυασμός πολλών πιθανών καταστάσεων της συσκευής [1]. Συγκρίνοντας το παρατηρούμενο αθροιστικό σήμα με τους προβλεπόμενους συνδυασμούς, το σύστημα μπορεί να εκτιμήσει τις πιο πιθανές καταστάσεις μεμονωμένων συσκευών. Μια άλλη στατιστική προσέγγιση είναι η χρήση των Factorial Hidden Markov Models (FHMMs), τα οποία μοντελοποιούν τις μεταβάσεις μεταξύ διαφορετικών καταστάσεων της συσκευής ως στοχαστική διαδικασία [11]. Τα FHMM είναι ιδιαίτερα χρήσιμα για συσκευές που έχουν διαφορετικούς κύκλους λειτουργίας, όπως πλυντήρια ρούχων ή πλυντήρια πιάτων. Το μοντέλο μπορεί να μάθει τα τυπικά μοτίβα κατανάλωσης ενέργειας αυτών των κύκλων και να χρησιμοποιήσει αυτές τις πληροφορίες για να διαχωρίσει το αθροιστικό σήμα.

Ενώ οι στατιστικές μέθοδοι ήταν επιτυχείς σε πολλές εφαρμογές, συχνά παλεύουν με πολύπλοκα περιβάλλοντα όπου πολλές συσκευές με παρόμοια υπογραφή ισχύος λειτουργούν ταυτόχρονα. Επιπλέον, αυτές οι μέθοδοι μπορεί να είναι υπολογιστικά εντατικές, απαιτώντας σημαντική επεξεργαστική ισχύ και χρόνο, ειδικά σε εφαρμογές σε πραγματικό χρόνο. Με την πάροδο του χρόνου και εξελίξεις στην τεχνολογία και την ανάπτυξη της τεχνητής νοημοσύνης (AI) δημιουργήθηκαν νέες τεχνικές αποδόμησης ενέργειας. Η μηχανική μάθηση έχει αναδειχθεί ως ένα ισχυρό εργαλείο στο NILM, προσφέροντας πιο ευέλικτες και ακριβείς μεθόδους για τον διαχωρισμό των δεδομένων κατανάλωσης ενέργειας. Οι προσεγγίσεις μηχανικής μάθησης μπορούν να χωριστούν σε εποπτευόμενη και μη εποπτευόμενη μάθηση. Στην εποπτευόμενη μάθηση, το σύστημα NILM εκπαιδεύεται σε δεδομένα με ετικέτα, όπου είναι γνωστά το συνολικό σήμα ισχύος και τα αντίστοιχα δεδομένα σε επίπεδο συσκευής. Αυτή η διαδικασία εκπαίδευσης επιτρέπει στο σύστημα να μάθει τα χαρακτηριστικά μοτίβα διαφορετικών συσκευών. Μόλις εκπαιδευτεί, το σύστημα μπορεί να εφαρμόσει αυτές τις γνώσεις για να αναλύσει ενεργειακές καταναλώσεις που δεν έχει ξαναδεί στα επιμέρους στοιχεία τους. Οι κοινές τεχνικές εποπτευόμενης μάθησης που


χρησιμοποιούνται στο NILM περιλαμβάνουν δέντρα αποφάσεων, μηχανές διανυσμάτων υποστήριξης (SVM), δίκτυα μακράς βραχύχρονης μνήμης (LSTM) και μεθόδους συνόλου όπως τυχαία δάση [12] [13]. Η μάθηση χωρίς επίβλεψη, από την άλλη πλευρά, δεν απαιτεί δεδομένα με ετικέτα. Αντίθετα, αυτές οι μέθοδοι στοχεύουν στον εντοπισμό μοτίβων και συστάδων (clusters) στο αθροιστικό σήμα που αντιστοιχούν σε διαφορετικές συσκευές. Οι αλγόριθμοι ομαδοποίησης, όπως τα k-means και τα Gaussian Mixture Models (GMM), χρησιμοποιούνται συχνά σε μη εποπτευόμενο NILM. Ενώ η μάθηση χωρίς επίβλεψη είναι πιο δύσκολη λόγω της έλλειψης δεδομένων με ετικέτα, μπορεί να είναι ιδιαίτερα χρήσιμη σε σενάρια όπου τα δεδομένα με ετικέτα είναι δύσκολο ή ακριβό να αποκτηθούν.

Οι προσεγγίσεις μηχανικής μάθησης προσφέρουν πολλά πλεονεκτήματα σε σχέση με τις παραδοσιακές στατιστικές μεθόδους, όπως βελτιωμένη ακρίβεια, επεκτασιμότητα και προσαρμοστικότητα σε διαφορετικά περιβάλλοντα. Ωστόσο, απαιτούν επίσης μεγάλες ποσότητες δεδομένων για εκπαίδευση και επικύρωση και η απόδοσή τους μπορεί να εξαρτάται σε μεγάλο βαθμό από την ποιότητα των δεδομένων και την επιλογή των παραμέτρων του μοντέλου. Για την αντιμετώπιση των περιορισμών των μεμονωμένων τεχνικών, έχουν αναπτυχθεί υβριδικές και συνολικές (ensemble) μέθοδοι στο NILM. Αυτές οι μέθοδοι συνδυάζουν πολλαπλές προσεγγίσεις, όπως στατιστικά μοντέλα, αλγόριθμους μηχανικής μάθησης και νευρωνικά δίκτυα, για να βελτιώσουν τη συνολική ακρίβεια και ευρωστία των συστημάτων NILM. Για παράδειγμα, μια υβριδική προσέγγιση μπορεί να χρησιμοποιήσει ένα στατιστικό μοντέλο για να εκτελέσει έναν αρχικό διαχωρισμό, ακολουθούμενο από ένα μοντέλο μηχανικής μάθησης για να βελτιώσει τις εκτιμήσεις. Εναλλακτικά, μια μέθοδος συνόλου μπορεί να συνδυάζει τα αποτελέσματα πολλών διαφορετικών μοντέλων, χρησιμοποιώντας τεχνικές όπως η ψηφοφορία ή ο σταθμισμένος μέσος όρος για να παραχθεί ένα τελικό αποτέλεσμα διαχωρισμού. Οι υβριδικές μέθοδοι και οι μέθοδοι συνόλου προσφέρουν έναν τρόπο αξιοποίησης των δυνατοτήτων διαφορετικών προσεγγίσεων, με αποτέλεσμα πιο ακριβή και αξιόπιστα συστήματα NILM. Ωστόσο, προσθέτουν επίσης πολυπλοκότητα στο σύστημα, απαιτώντας προσεκτική ρύθμιση και βαθμονόμηση για την επίτευξη βέλτιστης απόδοσης.

2.4 Οφέλη στη Διαχείριση Ενέργειας

Η σημασία του NILM στο πλαίσιο της διαχείρισης ενέργειας και της ενεργειακής απόδοσης έχει πολλές διαφορετικές πτυχές, περιλαμβάνοντας μια σειρά από οφέλη που συμβάλλουν τόσο στην εξοικονόμηση πόρων όσο και στην περιβαλλοντική βιωσιμότητα. Καθώς η παγκόσμια κατανάλωση ενέργειας συνεχίζει να αυξάνεται, λόγω παραγόντων όπως η αστικοποίηση, η αυξημένη χρήση ηλεκτρονικών συσκευών και η αύξηση του πληθυσμού, η ανάγκη για αποτελεσματικές στρατηγικές διαχείρισης ενέργειας γίνεται όλο και πιο κρίσιμη. Ένα από τα κύρια πλεονεκτήματα του NILM είναι η ικανότητά του να ενισχύει την ενεργειακή ευαισθητοποίηση των καταναλωτών. Παρέχοντας λεπτομερείς πληροφορίες σχετικά με τη χρήση ενέργειας μεμονωμένων συσκευών, το NILM επιτρέπει στους χρήστες να κατανοούν ακριβώς πού και πότε καταναλώνεται ενέργεια. Αυτό το επίπεδο λεπτομερούς παρακολούθησης είναι ζωτικής σημασίας για τον εντοπισμό αναποτελεσματικών και σπάταλων πρακτικών που διαφορετικά θα μπορούσαν να περάσουν απαρατήρητες. Για παράδειγμα, το NILM μπορεί να βοηθήσει τους χρήστες να εντοπίσουν συσκευές που καταναλώνουν μεγάλες ποσότητες ενέργειας ακόμη και όταν δεν χρησιμοποιούνται ενεργά, όπως συσκευές που έχουν παραμείνει σε κατάσταση αναμονής. Μπορεί επίσης να αποκαλύψει τον

αντίκτυπο συμπεριφορών, όπως το να αφήνεις τα φώτα αναμμένα σε άδεια δωμάτια ή τη χρήση συσκευών υψηλής ενέργειας κατά τις ώρες αιχμής. Έχοντας αυτή τη γνώση, οι καταναλωτές μπορούν να λάβουν κατάλληλες ενέργειες για να μειώσουν την κατανάλωση ενέργειας, όπως αποσύνδεση συσκευών όταν δεν χρησιμοποιούνται.



Σχήμα 2: Ποσοστό ετήσιας εξοικονόμησης ενέργειας από ανατροφοδότηση πληροφοριών στους καταναλωτές για τις ενεργειακές τους συνήθειες [14]

Επιπλέον οι λεπτομερείς πληροφορίες που παρέχονται από το NILM μπορούν να οδηγήσουν άμεσα σε εξοικονόμηση κόστους τόσο για οικιακούς όσο και για εμπορικούς χρήστες. Προσδιορίζοντας τις συγκεκριμένες συσκευές και συμπεριφορές που συμβάλλουν περισσότερο στην κατανάλωση ενέργειας, το NILM επιτρέπει στους χρήστες να λαμβάνουν τεκμηριωμένες αποφάσεις που μειώνουν τη συνολική τους κατανάλωση ενέργειας και μειώνουν τους λογαριασμούς ηλεκτρικής ενέργειας. Σε οικιακούς χώρους, αυτό μπορεί να περιλαμβάνει απλές αλλαγές, όπως χρήση συσκευών κατά τις ώρες μειωμένης ζήτησης, όταν οι τιμές ηλεκτρικής ενέργειας είναι χαμηλότερες, ή επένδυση σε ενεργειακά αποδοτικές συσκευές που καταναλώνουν λιγότερη ενέργεια για το ίδιο επίπεδο απόδοσης. Σε εμπορικά και βιομηχανικά περιβάλλοντα, οι δυνατότητες εξοικονόμησης κόστους είναι ακόμη μεγαλύτερες. Οι διαχειριστές εγκαταστάσεων μπορούν να χρησιμοποιήσουν το NILM για να βελτιστοποιήσουν τη χρήση ενέργειας σε διαφορετικές διαδικασίες και συστήματα, εντοπίζοντας ευκαιρίες για μείωση της κατανάλωσης χωρίς να διακυβεύεται η λειτουργική απόδοση. Συγκεκριμένα, το NILM μπορεί να βοηθήσει ένα εργοστάσιο παραγωγής να εντοπίσει ενεργοβόρες διαδικασίες που θα μπορούσαν να επαναπρογραμματιστούν σε ώρες μειωμένης ενεργειακής ζήτησης όπου η τιμή του ρεύματος είναι χαμηλότερη. Μπορεί επίσης να ανιχνεύσει εξοπλισμό που δεν λειτουργεί αποτελεσματικά ή απαιτεί συντήρηση, επιτρέποντας έγκαιρες παρεμβάσεις που αποτρέπουν τη σπατάλη ενέργειας και μειώνουν το λειτουργικό κόστος. Ακόμα εάν το σύστημα εντοπίσει ασυνήθιστη ή απρόβλεπτη κατανάλωση ενέργειας που δεν αντιστοιχεί σε γνωστές συσκευές, θα μπορούσε να υποδηλώνει πιθανή κλοπή

ενέργειας. Επιπλέον, εάν η συνολική κατανάλωση ενέργειας που αναφέρεται από τον πάροχο ηλεκτρικής ενέργειας είναι σημαντικά υψηλότερη από το άθροισμα της χρήσης ενέργειας που προσδιορίζεται από το NILM, αυτό θα μπορούσε να είναι ένδειξη ότι υπάρχει κάποια βλάβη στο ηλεκτρικό σύστημα ή κάποιος κλέβει ρεύμα. Έτσι, το NILM δίνει στους χρήστες τη δυνατότητα να παρακολουθούν στενά τη χρήση ενέργειας, διευκολύνοντας τον εντοπισμό ανωμαλιών που υποδηλώνουν κλοπή ή μη εξουσιοδοτημένη χρήση

Η μείωση της κατανάλωσης ενέργειας μέσω της χρήσης NILM όχι μόνο οδηγεί σε εξοικονόμηση κόστους αλλά έχει και σημαντικά περιβαλλοντικά οφέλη. Η χαμηλότερη κατανάλωση ενέργειας μεταφράζεται άμεσα σε μειωμένες εκπομπές αερίων θερμοκηπίου, καθώς χρειάζεται να παράγεται λιγότερη ηλεκτρική ενέργεια, συχνά από σταθμούς ηλεκτροπαραγωγής που λειτουργούν με την καύση υδρογονανθράκων. Επιτρέποντας πιο αποδοτική χρήση ενέργειας, το NILM συμβάλλει στην παγκόσμια προσπάθεια για την καταπολέμηση της κλιματικής αλλαγής και τη μείωση των περιβαλλοντικών επιπτώσεων των ανθρώπινων δραστηριοτήτων. Ειδικότερα, το NILM μπορεί να υποστηρίξει τη μετάβαση σε ένα πιο βιώσιμο ενεργειακό σύστημα διευκολύνοντας την ενσωμάτωση των ανανεώσιμων πηγών ενέργειας. Παρέχοντας λεπτομερείς πληροφορίες για τα πρότυπα χρήσης ενέργειας, το NILM επιτρέπει στους χρήστες να μεταφέρουν τη χρήση ορισμένων συσκευών τις ώρες που υπάρχει διαθεσιμότητα ανανεώσιμων πηγών ενέργειας, όπως η ηλιακή ή η αιολική ενέργεια [15]. Για παράδειγμα, ένα νοικοκυριό με ηλιακούς συλλέκτες μπορεί να χρησιμοποιήσει το NILM για να προγραμματίσει ενεργειακά απαιτητικές δραστηριότητες σε περιόδους αυξημένης ηλιακής παραγωγής, μεγιστοποιώντας τη χρήση καθαρής ενέργειας και μειώνοντας την εξάρτηση από την ηλεκτρική ενέργεια του δικτύου.

Επίσης το NILM παίζει σημαντικό ρόλο στα προγράμματα ανταπόκρισης ζήτησης (demand response) και την ανάπτυξη έξυπνων δικτύων (smart grids). Η ανταπόκριση στη ζήτηση περιλαμβάνει προσαρμογή της κατανάλωσης ενέργειας ως απόκριση σε σήματα από το δίκτυο, όπως αλλαγές τιμών ή αιτήματα για μείωση του φορτίου σε περιόδους υψηλής ζήτησης [16]. Το NILM παρέχει τα λεπτομερή δεδομένα σε πραγματικό χρόνο που απαιτούνται για την αποτελεσματική συμμετοχή σε αυτά τα προγράμματα, επιτρέποντας στους χρήστες να προσαρμόσουν τη χρήση ενέργειας με τρόπο που να ωφελεί τόσο τους ίδιους όσο και το ευρύτερο ενεργειακό σύστημα. Στο πλαίσιο των έξυπνων δικτύων, τα οποία βασίζονται σε προηγμένες τεχνολογίες επικοινωνίας και ελέγχου για τη βελτιστοποίηση της παραγωγής, διανομής και κατανάλωσης ηλεκτρικής ενέργειας, το NILM προσφέρει πολύτιμα δεδομένα που μπορούν να βελτιώσουν την απόδοση και την αξιοπιστία του δικτύου. Παρέχοντας πληροφορίες για το πώς και πότε χρησιμοποιείται η ενέργεια σε επίπεδο συσκευής, το NILM μπορεί να βοηθήσει τους παρόχους ηλεκτρικής ενέργειας να εξισορροπήσουν την προσφορά και τη ζήτηση πιο αποτελεσματικά, μειώνοντας την ανάγκη για δαπανηρές και ρυπογόνες μονάδες ηλεκτροπαραγωγής.

Το NILM έχει επίσης σημαντικές επιπτώσεις στην ενεργειακή πολιτική και ρύθμιση. Οι κυβερνήσεις και οι ρυθμιστικοί φορείς μπορούν να χρησιμοποιήσουν δεδομένα NILM για να κατανοήσουν καλύτερα τα πρότυπα κατανάλωσης ενέργειας σε διαφορετικούς τομείς και περιοχές. Αυτές οι πληροφορίες μπορούν να ωθήσουν την ανάπτυξη πολιτικών που στοχεύουν στη μείωση της ενεργειακής κατανάλωσης, όπως κίνητρα για αναβάθμιση σε ενεργειακά αποδοτικές συσκευές ή κανονισμούς που

απαιτούν ορισμένα πρότυπα ενεργειακής απόδοσης στα κτίρια. Τέλος, το NILM μπορεί να χρησιμοποιηθεί για την παρακολούθηση της συμμόρφωσης με τους κανονισμούς ενεργειακής απόδοσης. Με την ανάλυση των μοτίβων ενεργειακής κατανάλωσης των κτιρίων, οι ρυθμιστικές αρχές μπορούν να εντοπίσουν παραβάσεις και να λάβουν τα κατάλληλα μέτρα για την επιβολή των κανονισμών.

Κεφάλαιο 3. Θεωρητικό υπόβαθρο

3.1 Combinatorial optimization

3.1.1 Επισκόπηση

Η συνδυαστική βελτιστοποίηση αναφέρεται στη διαδικασία αναζήτησης μιας βέλτιστης λύσης από ένα διακριτό σύνολο εφικτών λύσεων. Περιλαμβάνει την εύρεση του καλύτερου δυνατού συνδυασμού στοιχείων από ένα πεπερασμένο ή μετρήσιμα άπειρο σύνολο σύμφωνα με συγκεκριμένους περιορισμούς και μια αντικειμενική συνάρτηση [17]. Η πολυπλοκότητα τέτοιων προβλημάτων πηγάζει συχνά από την εκθετική αύξηση του χώρου λύσης καθώς αυξάνεται ο αριθμός των στοιχείων. Το πεδίο σχετίζεται στενά με άλλους κλάδους της βελτιστοποίησης και της επιστήμης των υπολογιστών, συμπεριλαμβανομένης της θεωρίας γραφημάτων και του γραμμικού προγραμματισμού. Πολλά προβλήματα συνδυαστικής βελτιστοποίησης είναι NP-hard, που σημαίνει ότι δεν υπάρχει γνωστός αλγόριθμος που να μπορεί να λύσει όλες τις περιπτώσεις του προβλήματος σε πολυωνυμικό χρόνο [18]. Ως αποτέλεσμα, η εύρεση ακριβών λύσεων είναι συχνά υπολογιστικά κοστοβόρα, ειδικά για προβλήματα μεγάλης κλίμακας. Αντίθετα, heuristic αλγόριθμοι και αλγόριθμοι προσέγγισης χρησιμοποιούνται συχνά για την εύρεση σχεδόν βέλτιστων λύσεων.

Ένα από τα βασικά χαρακτηριστικά της συνδυαστικής βελτιστοποίησης είναι η αναγκαιότητα λήψης διακριτών αποφάσεων, όπως η επιλογή ενός υποσυνόλου στοιχείων, η ανάθεση πόρων σε εργασίες ή ο καθορισμός μιας ακολουθίας πράξεων. Αυτές οι αποφάσεις μπορούν να αναπαρασταθούν ως δυαδικές μεταβλητές, όπου κάθε μεταβλητή υποδεικνύει εάν ένα συγκεκριμένο στοιχείο περιλαμβάνεται στη λύση. Σε ορισμένες περιπτώσεις, το πρόβλημα μπορεί να μοντελοποιηθεί χρησιμοποιώντας ακέραιες μεταβλητές, που αντιπροσωπεύουν τον αριθμό των φορών που επιλέγεται ένα στοιχείο ή τη σειρά με την οποία εκτελούνται οι εργασίες. Τα προβλήματα συνδυαστικής βελτιστοποίησης μπορούν να ταξινομηθούν σε δύο κύριους τύπους. Αυτά που περιλαμβάνουν την εύρεση μιας εφικτής λύσης που ικανοποιεί ένα σύνολο περιορισμών και αυτά που περιλαμβάνουν τη βελτιστοποίηση μιας αντικειμενικής συνάρτησης. Πολλά προβλήματα εμπίπτουν και στις δύο κατηγορίες, όπου ο στόχος είναι να βρεθεί η καλύτερη δυνατή λύση που να μεγιστοποιεί ή να ελαχιστοποιεί μια δεδομένη αντικειμενική συνάρτηση. Πολλά γνωστά προβλήματα εμπίπτουν στην κατηγορία της συνδυαστικής βελτιστοποίησης, συμπεριλαμβανομένων του προβλήματος του περιοδεύοντος πωλητή (TSP), του προβλήματος του σακιδίου και του προβλήματος ελάχιστου συνδετικού δέντρου. Αυτά τα προβλήματα έχουν πολυάριθμες εφαρμογές σε όλους τους κλάδους, από το σχεδιασμό και τον προγραμματισμό δικτύων μέχρι την εφοδιαστική και την κατανομή πόρων.

3.1.2 Εφαρμογές στην ενεργειακή αποδόμηση

Η ενεργειακή αποδόμηση, γνωστή και ως μη παρεμβατική παρακολούθηση φορτίου (NILM), είναι η διαδικασία ανάλυσης της συνολικής κατανάλωσης ενέργειας ενός νοικοκυριού σε μεμονωμένη χρήση συσκευής. Αυτό επιτρέπει την καλύτερη κατανόηση και διαχείριση της κατανάλωσης ενέργειας, οδηγώντας σε βελτιωμένη ενεργειακή απόδοση και μειωμένο κόστος. Οι τεχνικές συνδυαστικής βελτιστοποίησης διαδραματίζουν κρίσιμο ρόλο στην αποδόμηση ενέργειας, βοηθώντας στον εντοπισμό του βέλτιστου συνδυασμού συσκευών που εξηγούν το παρατηρούμενο σήμα

κατανάλωσης ενέργειας. Μία από τις κύριες προκλήσεις στον ενεργειακό διαχωρισμό είναι ο μεγάλος αριθμός πιθανών συνδυασμών χρήσης των συσκευών μπορεί να δημιουργήσει την ίδια συνολική κατανάλωση ενέργειας. Το πρόβλημα μπορεί να μοντελοποιηθεί ως πρόβλημα συνδυαστικής βελτιστοποίησης, όπου ο στόχος είναι να βρεθεί ο καλύτερος συνδυασμός συσκευών που ελαχιστοποιεί τη διαφορά μεταξύ της παρατηρούμενης και της προβλεπόμενης κατανάλωσης ενέργειας [1]. Αυτό συχνά διατυπώνεται ως πρόβλημα αντιστοίχισης, όπου κάθε συσκευή ταιριάζει με ένα μέρος της συνολικής κατανάλωσης ενέργειας. Σε αυτό το πλαίσιο, θεωρούμε ότι έχουμε έναν πεπερασμένο αριθμό συσκευών, και κάθε συσκευή μπορεί να λειτουργεί σε έναν συγκεκριμένο αριθμό καταστάσεων.

Αντιμετωπίζοντας το ζήτημα από μαθηματική σκοπιά μπορούμε να θεωρήσουμε ότι το $P(t)$ είναι η πραγματική συνολική κατανάλωση της οικίας την στιγμή t , το s_i είναι μια πιθανή κατάσταση κατανάλωσης της συσκευής i , όπου για απλές συσκευές μπορεί να έχει μόνο 2 (on/off) ενώ για πιο περίπλοκες να έχει παραπάνω και ο σκοπός μας είναι να βρούμε τις ενεργειακές καταστάσεις s των συσκευών i τη χρονική στιγμή t για τις οποίες ελαχιστοποιείται η διαφορά ανάμεσα στη συνολική κατανάλωση και το άθροισμα των ενεργειακών καταστάσεων των συσκευών της οικίας. Με βάση τα παραπάνω ορίζεται ο τύπος:

$$\hat{s}(t) = \underset{s}{\operatorname{argmin}} \left| P(t) - \sum_{i=1}^n s_i \right|$$

Επομένως για κάθε χρονική στιγμή δημιουργούμε μια εκτίμηση της ενεργειακής κατανάλωσης κάθε συσκευής. Ενώ αυτή η εκτίμηση είναι αποδοτική, είναι και αρκετά περιπλοκή στον υπολογισμό της καθώς για κάθε χρονική στιγμή υπάρχουν s^n πιθανοί συνδυασμοί χρήσης συσκευών, όπου s είναι το πλήθος των ενεργειακών καταστάσεων κάθε συσκευής και n το πλήθος των συσκευών, με αποτέλεσμα να είναι υπολογιστικά κοστοβόρα η εφαρμογή της σε πραγματικές συνθήκες όπου το πλήθος των συσκευών είναι μεγάλο.

3.2 Factorial hidden markov models

3.2.1 Επισκόπηση

Τα Factorial Hidden Markov Models (FHMM) είναι μια κατηγορία πιθανοτικών μοντέλων που βασίζονται στα τυπικά Hidden Markov Models (HMM), αλλά εισάγουν μια πιο εξελιγμένη δομή για να διαχειρίζονται πολλαπλές μεταβλητές κρυφής κατάστασης που εξελίσσονται ανεξάρτητα με την πάροδο του χρόνου [19]. Αυτή η επέκταση μοντέλου καθιστά τα FHMM ένα ισχυρό εργαλείο για την ανάλυση και την πρόβλεψη σύνθετων χρονοσειρών, όπου το υποκείμενο σύστημα αποτελείται από πολλαπλούς ανεξάρτητους παράγοντες που συμβάλλουν στις παρατηρούμενες μετρήσεις. Τα FHMM έχουν βρει εκτεταμένες εφαρμογές σε διάφορους τομείς, συμπεριλαμβανομένης της αναγνώρισης ομιλίας, της επεξεργασίας φυσικής γλώσσας, και ιδιαίτερα στον τομέα της ενεργειακής διάσπασης, όπου διαπρέπουν στην αποτύπωση της συμπεριφοράς σε επίπεδο συσκευής από τα συνολικά δεδομένα κατανάλωσης ενέργειας [11].

Σε ένα HMM, μια μεμονωμένη μεταβλητή κρυφής κατάστασης χρησιμοποιείται για τη δημιουργία των παρατηρούμενων δεδομένων, που εξελίσσονται μέσα στο χρόνο

σύμφωνα με μια διαδικασία Markov. Αυτή η κρυφή κατάσταση αντιπροσωπεύει την κατάσταση του συστήματος που μοντελοποιείται, ενώ τα παρατηρούμενα δεδομένα συνδέονται με την κρυφή κατάσταση μέσω μιας πιθανότητας εκπομπής. Σε πολλές πρακτικές εφαρμογές, ωστόσο, τα παρατηρούμενα δεδομένα επηρεάζονται από περισσότερες από μία κρυφές διεργασίες. Για παράδειγμα, στο πλαίσιο της ενεργειακής διάσπασης, πολλαπλές συσκευές, καθεμία με τις δικές της καταστάσεις λειτουργίας, συμβάλλουν στη συνολική κατανάλωση ενέργειας που μετριέται σε επίπεδο νοικοκυριού. Ένα HMM μιας κατάστασης θα δυσκολευόταν να διαχωρίσει τις συνεισφορές κάθε συσκευής. Τα FHMM επεκτείνουν το πλαίσιο HMM μοντελοποιώντας πολλαπλές μεταβλητές κρυφής κατάστασης ταυτόχρονα, καθεμία από τις οποίες εξελίσσεται ανεξάρτητα αλλά συμβάλλει συλλογικά στα παρατηρούμενα δεδομένα [19]. Η βασική ιδέα πίσω από τα FHMM είναι ότι η κρυφή κατάσταση σε οποιαδήποτε δεδομένη στιγμή δεν είναι μια ενιαία μεταβλητή αλλά ένα διάνυσμα πολλαπλών κρυφών μεταβλητών. Κάθε συστατικό αυτού του διανύσματος ακολουθεί τη δική του διαδικασία Markov και η κοινή επίδραση αυτών των κρυφών μεταβλητών καθορίζει τα παρατηρούμενα δεδομένα. Αυτή η προσέγγιση επιτρέπει τη μοντελοποίηση συστημάτων με πολλές συνιστώσες που αλληλεπιδρούν μεταξύ τους με τρόπο που τα HMM δεν μπορούν, επιτρέποντας την αναπαράσταση πιο περίπλοκων εξαρτήσεων μεταξύ των παρατηρούμενων και κρυφών επιπέδων.

3.2.2 Εφαρμογές στην ενεργειακή αποδόμηση

Τα FHMM είναι εξαιρετικά αποτελεσματικά για την ενεργειακή αποδόμηση, μια διαδικασία όπου η συνολική κατανάλωση ενέργειας ενός νοικοκυριού ή ενός κτιρίου αναλύεται στην κατανάλωση μεμονωμένων συσκευών. Κάθε συσκευή σε ένα FHMM μοντελοποιείται ως HMM με ένα σύνολο κρυφών καταστάσεων. Αυτές οι καταστάσεις αντιπροσωπεύουν τα διαφορετικά επίπεδα κατανάλωσης ενέργειας για τη συγκεκριμένη συσκευή. Για παράδειγμα, ένα ψυγείο μπορεί να έχει δύο καταστάσεις on/off. Μια πιο σύνθετη συσκευή, όπως ένα πλυντήριο, θα μπορούσε να έχει πολλές καταστάσεις, όπως off, πλύσιμο, στύψιμο και ξέπλυμα. Αυτές οι καταστάσεις είναι κρυφές επειδή, στην πραγματικότητα, δεν μπορούμε να παρατηρήσουμε άμεσα εάν η συσκευή είναι ενεργοποιημένη ή απενεργοποιημένη. Αντίθετα, βλέπουμε μόνο τη συνδυασμένη κατανάλωση ενέργειας από όλες τις συσκευές ανά πάσα στιγμή. Το FHMM θεωρεί ως παρατηρούμενα δεδομένα τη συνολική κατανάλωση ενέργειας για να συμπεράνει τις κρυφές καταστάσεις κάθε συσκευής [20] [21].

Το κλειδί για τον τρόπο με τον οποίο τα FHMM εκτελούν την ενεργειακή αποδόμηση βρίσκεται στην αθροιστική φύση της χρήσης ενέργειας. Η συνολική κατανάλωση ενέργειας σε κάθε δεδομένη στιγμή είναι το άθροισμα της ισχύος που καταναλώνει κάθε συσκευή, ανάλογα με την τρέχουσα κατάστασή της. Εάν ένα ψυγείο είναι ενεργοποιημένο και χρησιμοποιεί 100W και ένας φούρνος μικροκυμάτων είναι ενεργοποιημένος με 500W, η συνολική ισχύς που παρατηρείται θα είναι 600W. Το FHMM το μοντελοποιεί συνδυάζοντας την κατανάλωση ενέργειας από την κρυφή κατάσταση κάθε συσκευής και προσπαθεί να την αντιστοιχίσει με τη συνολική παρατηρούμενη κατανάλωση ενέργειας. Επειδή τα FHMM μοντελοποιούν κάθε συσκευή ξεχωριστά, μπορούν να διαχειριστούν πολλές συσκευές που λειτουργούν ταυτόχρονα. Αυτό είναι ένα σημαντικό πλεονέκτημα σε σχέση με τις απλούστερες μεθόδους ενεργειακής αποδόμησης. Το HMM κάθε συσκευής εξελίσσεται ανεξάρτητα, πράγμα που σημαίνει ότι οι καταστάσεις του ψυγείου δεν επηρεάζονται από τις καταστάσεις του πλυντηρίου. Ωστόσο, οι μεμονωμένες ενεργειακές τους έξοδοι


συνδυάζονται για να σχηματίσουν τη συνολική κατανάλωση ενέργειας και το FHMM πρέπει να συμπεράνει ποιος συνδυασμός καταστάσεων συσκευής παρήγαγε πιθανότατα τις παρατηρούμενες μετρήσεις ισχύος.

Η διαδικασία αποδόμησης με χρήση FHMM περιλαμβάνει πιθανοτικό συμπέρασμα. Δεδομένης της παρατηρούμενης συνολικής κατανάλωσης ενέργειας, το μοντέλο υπολογίζει τις πιο πιθανές καταστάσεις κάθε συσκευής σε κάθε χρονική στιγμή. Αυτό το πιθανοτικό συμπέρασμα υπολογίζεται χρησιμοποιώντας αλγόριθμους που υπολογίζουν ποιες συσκευές είναι ενεργοποιημένες και πόση ενέργεια καταναλώνει η καθεμία. Στην πράξη, το ακριβές συμπέρασμα μπορεί να είναι υπολογιστικά απαιτητική, ειδικά όταν υπάρχουν πολλές συσκευές, επομένως χρησιμοποιούνται συχνά μέθοδοι προσέγγισης για να γίνει η διαδικασία πιο γρήγορη.

3.3 Μηχανική Μάθηση

Η μηχανική μάθηση (Machine Learning) είναι ένας κλάδος της τεχνητής νοημοσύνης (Artificial Intelligence) που επικεντρώνεται στην ανάπτυξη συστημάτων και μεθόδων που προσπαθούν να προσομοιάσουν την ικανότητα των ανθρώπων να λύνουν προβλήματα, έτσι ώστε όπως οι άνθρωποι, να μπορούν να επιλύουν προβλήματα και να παίρνουν αποφάσεις μόνοι τους χωρίς να τους έχουν δοθεί ρητές οδηγίες για το πώς θα το κάνουν [22]. Οι αλγόριθμοι που δημιουργούνται, προκειμένου να έχουν την επιθυμητή συμπεριφορά, τροφοδοτούνται με δεδομένα που είναι σχετικά με το πρόβλημα που θέλουμε να λύσουμε. Αυτά μπορεί να είναι επιστημονικά δεδομένα, κείμενο, εικόνες, ήχος ή οποιοδήποτε άλλο είδος πληροφορίας. Στη συνέχεια προσπαθούν να ανιχνεύσουν κάποιο μοτίβο, σύμφωνα με το οποίο θα είναι σε θέση να κάνουν μελλοντικές προβλέψεις. Σε αντίθεση ο κλασικός τρόπος δημιουργίας αλγορίθμων απαιτεί τον ρητό προγραμματισμό μιας ακολουθίας βημάτων ή κανόνων για την επίλυση ενός συγκεκριμένου προβλήματος. Επομένως είναι εμφανές ότι συγκριτικά με τις παραδοσιακές μεθόδους προγραμματισμού, όπου οι αλγόριθμοι ακολουθούν συγκεκριμένες εντολές, οι αλγόριθμοι μηχανικής μάθησης μπορούν να μάθουν και να βελτιώνονται με την πάροδο του χρόνου, καθιστώντας τους κατάλληλους για εργασίες όπου ο ρητός προγραμματισμός είναι δύσκολος ή αδύνατος.

Επιπλέον, η μηχανική μάθηση διαδραματίζει καθοριστικό ρόλο στον τομέα της επιστήμης δεδομένων, λειτουργώντας ως η κινητήρια δύναμη που οδηγεί την έξυπνη ανάλυση και την προγνωστική μοντελοποίηση (Predictive modelling). Η ικανότητά της να επεξεργάζεται τεράστιες ποσότητες δεδομένων και να εντοπίζει κρυφά μοτίβα έχει μεταμορφώσει πολλές βιομηχανίες, επιτρέποντας πιο σωστή λήψη αποφάσεων στον τομέα των οικονομικών, του μάρκετινγκ και πολλούς άλλους. Για την ανθρωπότητα, η μηχανική μάθηση έχει τη δυνατότητα να αντιμετωπίσει παγκόσμιες προκλήσεις, από τη βελτίωση των ιατρικών διαγνώσεων έως την πρόβλεψη των επιπτώσεων της κλιματικής αλλαγής και τη βελτιστοποίηση της διαχείρισης των πόρων. Η σημασία των συνόλων δεδομένων σε αυτό το πλαίσιο είναι ανεκτίμητη. Τα υψηλής ποιότητας, ποικιλόμορφα σύνολα δεδομένων αποτελούν τη βάση πάνω στην οποία χτίζονται τα μοντέλα μηχανικής μάθησης, καθώς παρέχουν τις απαραίτητες πληροφορίες για την εκπαίδευση, τη δοκιμή και τη βελτίωση των μοντέλων. Χωρίς καλά οργανωμένα και αντιπροσωπευτικά σύνολα δεδομένων, τα συστήματα μηχανικής εκμάθησης θα δυσκολεύονταν να προσφέρουν ακριβείς και αξιόπιστες πληροφορίες, καθιστώντας τα δεδομένα τον ακρογωνιαίο λίθο των επιτυχημένων εφαρμογών μηχανικής εκμάθησης.



Σχήμα 3: Κατηγορίες μηχανικής μάθησης [23]

Ο κλάδος της μηχανικής μάθησης έχει κατηγοριοποιηθεί σε 3 διαφορετικούς τύπους λόγω της ποικιλόμορφης φύσης των δεδομένων και των διαφορετικών τύπων προβλημάτων που καλούνται να λύσουν. Κάθε μία από αυτές τις κατηγορίες δημιουργήθηκε για να αντιμετωπίσει συγκεκριμένες προκλήσεις σχετικά με το πώς οι μηχανές μπορούν να μάθουν από δεδομένα, δεδομένης της πολυπλοκότητας και της διαθεσιμότητας αυτών των δεδομένων. Με τη διάκριση μεταξύ αυτών των κατηγοριών, τα μοντέλα μηχανικής μάθησης μπορούν να βελτιστοποιηθούν για να χειρίζονται διάφορα σενάρια, που κυμαίνονται από ξεκάθαρες προγνωστικές εργασίες έως πολύπλοκα περιβάλλοντα λήψης αποφάσεων με αποτέλεσμα να είναι σε θέση να λύσουν μεγαλύτερο εύρος προβλημάτων. Πιο Συγκεκριμένα:

- **Επιβλεπόμενη μάθηση (Supervised Learning)**

Η επιβλεπόμενη μάθηση είναι μια από τις πιο θεμελιώδεις και ευρέως υιοθετημένες προσεγγίσεις μηχανικής μάθησης. Με αυτή την τεχνική, ο αλγόριθμος εκπαιδεύεται σε ένα σύνολο δεδομένων που περιέχει ζεύγη εισόδου-εξόδου, όπου κάθε είσοδος συνδέεται με μια σωστή έξοδο [22]. Αυτές οι εξοδοί, που συχνά αναφέρονται ως ετικέτες, λειτουργούν ως οδηγός κατά τη διάρκεια της μαθησιακής διαδικασίας, επιτρέποντας στο μοντέλο να κάνει προβλέψεις. Ο στόχος του μοντέλου είναι να συσχετίσει τα δεδομένα εισόδου με τα κατάλληλα δεδομένα εξόδου και να γενικεύσει αυτή τη γνώση για να κάνει ακριβείς προβλέψεις για νέα δεδομένα που δεν έχει ξαναδεί. Υπάρχουν δύο κύριοι τύποι επιβλεπόμενης μάθησης: ταξινόμηση (classification) και παλινδρόμηση (Regression). Στην ταξινόμηση, το μοντέλο ταξινομεί τα δεδομένα εισόδου σε προκαθορισμένες διακριτές κατηγορίες ή ετικέτες. Για παράδειγμα, ένα email μπορεί να ταξινομηθεί ως επιθυμητό ή ανεπιθυμητό με

βάση το περιεχόμενό του. Στην παλινδρόμηση, το μοντέλο προβλέπει μια συνεχή τιμή, όπως η εκτίμηση των τιμών των κατοικιών με βάση χαρακτηριστικά όπως το μέγεθος, η τοποθεσία και ο αριθμός των υπνοδωματίων. Το κλειδί για την επίτευξη καλών αποτελεσμάτων με αυτή την τεχνική είναι η χρήση ενός καλά κατηγοριοποιημένου συνόλου δεδομένων και επαρκών παραδειγμάτων από τα οποία μπορεί να μάθει το μοντέλο. Καθώς το μοντέλο εκτίθεται σε περισσότερα δεδομένα, προσαρμόζει τις παραμέτρους του για να μειώσει τα σφάλματα και να βελτιώσει την ακρίβεια των προβλέψεων. Ένα από τα κύρια πλεονεκτήματα της επιβλεπόμενης μάθησης είναι η αποτελεσματικότητά της σε καταστάσεις όπου υπάρχει μεγάλος όγκος κατηγοριοποιημένων δεδομένων και η εργασία απαιτεί σαφή πρόβλεψη. Έχει εφαρμογές σε διάφορους τομείς, συμπεριλαμβανομένης της ιατρικής διάγνωσης, όπου μπορεί να προβλέψει ασθένειες με βάση τα συμπτώματα των ασθενών, ανίχνευση απάτης σε οικονομικές συναλλαγές, ακόμη και συστήματα αναγνώρισης φωνής, όπως μετατροπή ομιλίας σε κείμενο (speech to text). Όμως παρά τα πλεονεκτήματά που προσφέρει η επιβλεπόμενη μάθηση έχει και ορισμένους περιορισμούς, όπως η απαίτηση μεγάλου όγκου δεδομένων που πρέπει πρώτα να κατηγοριοποιηθούν από ανθρώπους κάτι το οποίο είναι αρκετά δαπανηρό και χρονοβόρο.

- **Μη επιβλεπόμενη μάθηση (Unsupervised Learning)**

Η μη επιβλεπόμενη μάθηση είναι μια διαφορετική προσέγγιση στη μηχανική μάθηση, όπου σε αντίθεση με την επιβλεπόμενη μάθηση το μοντέλο εκπαιδεύεται σε μη κατηγοριοποιημένα δεδομένα [24]. Αυτό το καθιστά ιδιαίτερα χρήσιμο όταν δεν έχουμε πρόσβαση σε προκαθορισμένα αποτελέσματα ή κατηγοριοποιημένα δεδομένα και ο στόχος είναι να ανακαλύψουμε κρυφά μοτίβα ή σχέσεις ανάμεσα στα δεδομένα. Οι αλγόριθμοι πρέπει να βρουν από μόνοι τους δομή στα δεδομένα, χρησιμοποιώντας τεχνικές όπως η ομαδοποίηση (clustering), και η μείωση διαστάσεων (Dimensionality reduction) για να οργανώσουν και να απλοποιήσουν τις πληροφορίες. Οι πιο συνηθισμένες εφαρμογές με αυτή την προσέγγιση είναι η ομαδοποίηση παρόμοιων δεδομένων και η συσχέτιση (association) που είναι προσδιορισμός σχέσεων μεταξύ των δεδομένων. Στην ομαδοποίηση, ο αλγόριθμος κατηγοριοποιεί δεδομένων που έχουν παρόμοια χαρακτηριστικά. Μια δημοφιλής περίπτωση χρήσης είναι η τμηματοποίηση πελατών, όπου μια επιχείρηση μπορεί να ομαδοποιήσει τους πελάτες με βάση τις αγοραστικές τους συνήθειες χωρίς να έχει πρότερη γνώση τις συμπεριφοράς των πελατών. Αυτό βοηθά τις εταιρείες να προσαρμόσουν τις στρατηγικές μάρκετινγκ ή να βελτιώσουν την εμπειρία των πελατών. Στη μείωση διαστάσεων, το μοντέλο απλοποιεί μεγάλα σύνολα δεδομένων μειώνοντας τον αριθμό των χαρακτηριστικών ή μεταβλητών διατηρώντας παράλληλα τις πιο σημαντικές πληροφορίες. Αυτό χρησιμοποιείται συχνά για να διευκολύνει την οπτικοποίηση των δεδομένων ή για τη βελτίωση της απόδοσης άλλων μοντέλων μηχανικής εκμάθησης. Ένα από τα μεγαλύτερα πλεονεκτήματα της μάθησης χωρίς επίβλεψη είναι η ικανότητά της να αντιμετωπίζει μεγάλα, χωρίς ετικέτα σύνολα δεδομένων, καθιστώντας την ιδανική για διερευνητική ανάλυση


δεδομένων. Βοηθά στην εύρεση μοτίβων που μπορεί να μην είναι άμεσα ορατά από ανθρώπους. Ωστόσο, ένα από τα μειονεκτήματα που αντιμετωπίζει είναι ότι τα αποτελέσματα του μοντέλου μπορεί να είναι πιο δύσκολο να αξιολογηθούν σε σύγκριση με την επιβλεπόμενη μάθηση, καθώς δεν υπάρχουν σαφείς ετικέτες για σύγκριση. Παρ' όλα αυτά, χρησιμοποιείται ευρέως σε εφαρμογές όπως η ανίχνευση ανωμαλιών, η συμπίεση εικόνας και η επεξεργασία φυσικής γλώσσας, καθιστώντας την ένα πολύτιμο εργαλείο για την κατανόηση πολύπλοκων συνόλων δεδομένων και την απόκτηση πρακτικών πληροφοριών.

- **Ενισχυτική μάθηση (Reinforcement Learning)**


Η ενισχυτική μάθηση είναι ένας ξεχωριστός τύπος μηχανικής μάθησης που περιστρέφεται γύρω από τη λήψη αποφάσεων και τη μάθηση μέσω της αλληλεπίδρασης με ένα περιβάλλον. Σε αντίθεση με την επιβλεπόμενη μάθηση ή την μη επιβλεπόμενη μάθηση, όπου τα μοντέλα μαθαίνουν από στατικά σύνολα δεδομένων, η ενισχυτική μάθηση περιλαμβάνει έναν πράκτορα (agent) που μαθαίνει εκτελώντας ενέργειες σε ένα περιβάλλον με σκοπό να μεγιστοποιήσει τις συνολικές ανταμοιβές του [25]. Ο πράκτορας αλληλεπιδρά με το περιβάλλον, λαμβάνοντας ανατροφοδότηση με τη μορφή ανταμοιβών ή ποινών, ανάλογα με το αποτέλεσμα των ενεργειών του, και προσαρμόζει τη στρατηγική του ώστε να επιτυγχάνει υψηλότερες ανταμοιβές με την πάροδο του χρόνου. Επομένως η διαδικασία μάθησης είναι δυναμική, που σημαίνει ότι ο πράκτορας πρέπει συνεχώς να προσαρμόζεται και να βελτιώνεται με βάση τις αποφάσεις που πήρε στο παρελθόν. Η ενισχυτική μάθηση είναι ιδιαίτερα χρήσιμη σε σενάρια όπου οι αποφάσεις είναι διαδοχικές και οι ενέργειες που λαμβάνονται σε ένα βήμα μπορούν να επηρεάσουν τα μελλοντικά αποτελέσματα. Για παράδειγμα, στην αυτόνομη οδήγηση, ένας πράκτορας μπορεί να μάθει να πλοηγείται στους δρόμους προσαρμόζοντας την ταχύτητα, το τιμόνι και το φρενάρισμα με βάση τα δεδομένα που δέχεται από τους αισθητήρες, μαθαίνοντας τελικά πώς να αποφεύγει τα εμπόδια και να φτάνει σε προορισμούς με ασφάλεια. Ομοίως, σε παιχνίδια, όπως το σκάκι ή το Go, οι πράκτορες βελτιώνονται συνεχώς παίζοντας εναντίον του εαυτού τους ή άλλων αντιπάλων, μαθαίνοντας τόσο από τις νίκες όσο και από τις ήττες για να βελτιώσουν τις στρατηγικές τους. Ένα βασικό πλεονέκτημα της ενισχυτικής μάθησης είναι η ικανότητά της να χειρίζεται πολύπλοκα περιβάλλοντα όπου δεν υπάρχουν διαθέσιμες προκαθορισμένες οδηγίες ή ετικέτες. Ο πράκτορας μαθαίνει δοκιμάζοντας διαφορετικές επιλογές, βελτιώνοντας την απόδοσή του μέσω επαναλαμβανόμενων αλληλεπιδράσεων. Ωστόσο, πολλές φορές είναι υπολογιστικά ακριβή, απαιτώντας σημαντική επεξεργαστική ισχύ και χρόνο για να πετύχει την βέλτιστη απόδοση. Παρά αυτές τις προκλήσεις έχει εφαρμοστεί με επιτυχία στη ρομποτική, την ανάπτυξη παιχνιδιών, τα οικονομικά και την υγειονομική περίθαλψη, ιδιαίτερα σε εργασίες όπου η λήψη αποφάσεων σε πραγματικό χρόνο και η προσαρμοστικότητα είναι ζωτικής σημασίας για την επιτυχία.

3.3.1 Νευρωνικά δίκτυα

Τα νευρωνικά δίκτυα είναι υπολογιστικά μοντέλα εμπνευσμένα από τον τρόπο λειτουργίας του ανθρώπινου εγκεφάλου, σχεδιασμένα να επεξεργάζονται πληροφορίες και να λαμβάνουν αποφάσεις με τρόπο παρόμοιο με τον τρόπο που κάνουν οι άνθρωποι. Ακριβώς όπως ο εγκέφαλος αποτελείται από δισεκατομμύρια διασυνδεδεμένους νευρώνες, τα νευρωνικά δίκτυα αποτελούνται από στρώματα τεχνητών νευρώνων ή κόμβων, που συνεργάζονται για να αναλύουν δεδομένα, να αναγνωρίζουν μοτίβα και να μαθαίνουν από εμπειρίες. Αυτή η δομή επιτρέπει στα νευρωνικά δίκτυα να προσομοιώνουν ανθρώπινες διαδικασίες μάθησης και επίλυσης προβλημάτων, επιτρέποντας στις μηχανές να χειρίζονται εργασίες όπως η αναγνώριση εικόνας, η κατανόηση γλώσσας και η λήψη αποφάσεων, όπως θα έκανε ο ανθρώπινος εγκέφαλος. Στον ανθρώπινο εγκέφαλο, οι νευρώνες λαμβάνουν σήματα μέσω των δενδριτών, επεξεργάζονται αυτά τα σήματα και τα μεταδίδουν σε άλλους νευρώνες μέσω νευραξόνων εάν το σήμα είναι αρκετά ισχυρό. Ομοίως, σε ένα νευρωνικό δίκτυο, κάθε τεχνητός νευρώνας λαμβάνει εισόδους, τις επεξεργάζεται εφαρμόζοντας βάρη (που προσδιορίζουν τη σημασία κάθε εισόδου) και μεταβιβάζει το αποτέλεσμα στο επόμενο στρώμα νευρώνων εφόσον πληροί ένα συγκεκριμένο όριο. Αυτό μιμείται τον τρόπο με τον οποίο οι βιολογικοί νευρώνες ενεργοποιούνται με βάση τα εισερχόμενα σήματα. Επιπλέον, όπως ο ανθρώπινος εγκέφαλος ενισχύει ή αποδυναμώνει τις συνδέσεις μεταξύ των νευρώνων μέσω της μάθησης, τα νευρωνικά δίκτυα προσαρμόζουν τα βάρη των συνδέσεών τους κατά τη διάρκεια της προπόνησης. Αυτή η διαδικασία, γνωστή ως οπισθοδιάδοση (backpropagation), επιτρέπει στο δίκτυο να μαθαίνει από τα λάθη και να βελτιώνει την απόδοσή του με την πάροδο του χρόνου, όπως οι άνθρωποι βελτιώνουν τις δεξιότητές τους μέσω της πρακτικής και της εμπειρίας.



Σχήμα 4: Νευρώνας ανθρώπου [26]




Σχήμα 5: Τεχνητός νευρώνας [27]

Τα νευρωνικά δίκτυα είναι επίσης παρόμοια με την ανθρώπινη γνώση ως προς την ικανότητά τους να χειρίζονται περίπλοκες, μη γραμμικές σχέσεις. Ο εγκέφαλος υπερέχει στην αναγνώριση προτύπων σε τεράστια, αδόμητα δεδομένα, όπως η αναγνώριση ενός προσώπου σε ένα πλήθος ή η κατανόηση του νοήματος πίσω από τις προφορικές λέξεις. Τα νευρωνικά δίκτυα προσπαθούν να το μιμηθούν αυτό επεξεργάζομενα την είσοδο σε επίπεδα, με κάθε διαδοχικό στρώμα να αναγνωρίζει όλο και πιο αφηρημένα μοτίβα στα δεδομένα, παρόμοια με το πώς διαφορετικές περιοχές του εγκεφάλου επεξεργάζονται αισθητηριακές πληροφορίες σε διάφορα επίπεδα λεπτομέρειας. Στην ουσία, τα νευρωνικά δίκτυα έχουν σχεδιαστεί για να μιμούνται την ανθρώπινη μάθηση, καθιστώντας τα ισχυρά εργαλεία για εργασίες που απαιτούν συλλογισμό, αναγνώριση προτύπων και λήψη αποφάσεων που είναι βασικές πτυχές της ανθρώπινης νοημοσύνης. Ενώ αυτά τα τεχνητά συστήματα δεν είναι τόσο περίπλοκα όσο ο ανθρώπινος εγκέφαλος, βασίζονται σε μεγάλο βαθμό στις αρχές του, με στόχο

να αναπαράγουν την αποτελεσματικότητά του στην επεξεργασία και την κατανόηση πληροφοριών.

Το βασικό συστατικό των νευρωνικών δικτύων είναι οι τεχνητοί νευρώνες (perceptrons), οι οποίοι έχουν διαμορφωθεί σύμφωνα με τη συμπεριφορά των βιολογικών νευρώνων στον ανθρώπινο εγκέφαλο. Κάθε perceptron λαμβάνει πολλαπλές τιμές εισόδου, τις επεξεργάζεται εφαρμόζοντας βάρη που αντιπροσωπεύουν τη σημασία κάθε εισόδου και αθροίζει αυτές τις σταθμισμένες εισόδους. Ένας όρος πόλωση (bias) προστίθεται συχνά για να μετατοπίσει τη λειτουργία ενεργοποίησης και να επιτρέψει μεγαλύτερη ευελιξία στην έξοδο του μοντέλου. Έπειτα το άθροισμα των εισόδων περνά μέσω μιας συνάρτησης ενεργοποίησης (activation function), η οποία καθορίζει εάν ο νευρώνας πυροδοτεί και στέλνει ένα σήμα στο επόμενο στρώμα νευρώνων. Αυτό μιμείται τον τρόπο με τον οποίο οι βιολογικοί νευρώνες λαμβάνουν, επεξεργάζονται και αναμεταδίδουν σήματα. Ενώ τα ενός επιπέδου (Single Layer Perceptron) νευρωνικά δίκτυα περιορίζονται στην επίλυση απλών, γραμμικών προβλημάτων, η πραγματική δύναμη των perceptrons αναδύεται στα πολυεπίπεδα (Multi-Layered Perceptron) νευρωνικά δίκτυα. Αυτά τα δίκτυα αποτελούνται από πολλαπλά στρώματα τεχνητών νευρώνων που επιτρέπουν τη μοντελοποίηση πολύπλοκων, μη γραμμικών σχέσεων στα δεδομένα. Περνώντας δεδομένα μέσα από πολλά επίπεδα, κάθε επίπεδο εξάγει όλο και πιο αφηρημένα χαρακτηριστικά, καθιστώντας το δίκτυο ικανό να λύνει περίπλοκες εργασίες όπως η αναγνώριση εικόνας ή η κατανόηση φυσικής γλώσσας. Οι αλληλεπιδράσεις μεταξύ των νευρώνων, μέσω των βαρών και της πόλωσης τους, επιτρέπουν στο δίκτυο να μάθει αυτά τα πολύπλοκα μοτίβα και η διαδικασία οπισθοδιάδοσης διασφαλίζει ότι τα λάθη ελαχιστοποιούνται κατά τη διάρκεια της εκπαίδευσης. Αυτή η προσαρμογή των βαρών αντικατοπτρίζει τον τρόπο με τον οποίο η ανθρώπινη μάθηση ενισχύει ή αποδυναμώνει τις νευρικές συνδέσεις. Η πολυεπίπεδη δομή των νευρωνικών δικτύων, που τροφοδοτείται τους νευρώνες, είναι απαραίτητη για την αντιμετώπιση περίπλοκων προβλημάτων, προσφέροντας τεράστιες βελτιώσεις στην απόδοση σε σχέση με δίκτυα μονού επιπέδου.



Σχήμα 6: Multi-Layered Perceptron [28]

3.3.2 Συναρτήσεις Ενεργοποίησης

Οι συναρτήσεις ενεργοποίησης είναι κρίσιμες στα νευρωνικά δίκτυα καθώς εισάγουν μη γραμμικότητα, επιτρέποντας στο μοντέλο να μαθαίνει και να μοντελοποιεί πολύπλοκα μοτίβα στα δεδομένα. Χωρίς αυτά, ένα νευρωνικό δίκτυο θα συμπεριφερόταν σαν μια γραμμική συνάρτηση, περιορίζοντας την ικανότητά του να


λύνει πραγματικά προβλήματα που απαιτούν μη γραμμικά όρια απόφασης. Υπάρχουν διαφορετικές συναρτήσεις ενεργοποίησης για την επίλυση συγκεκριμένων προβλημάτων, η καθεμία με τα δικά της πλεονεκτήματα και περιορισμούς. Παρακάτω είναι μερικές σημαντικές συναρτήσεις ενεργοποίησης.

Γραμμική συνάρτηση

Η συνάρτηση γραμμικής ενεργοποίησης είναι η απλούστερη μορφή ενεργοποίησης, όπου η έξοδος είναι ευθέως ανάλογη με την είσοδο. Η κύρια χρήση της είναι στο επίπεδο εξόδου ενός νευρωνικού δικτύου που χρησιμοποιείται για παλινδρόμηση. Αν και είναι εύκολο να εφαρμοστεί και να ερμηνευτεί, έχει σημαντικούς περιορισμούς. Ένα σημαντικό μειονέκτημα είναι ότι δεν μπορεί να μοντελοποιήσει πολύπλοκες, μη γραμμικές σχέσεις στα δεδομένα. Ανεξάρτητα από το πόσα επίπεδα νευρώνων έχει το μοντέλο, με την χρήση γραμμικής ενεργοποίησης, το συνολικό δίκτυο παραμένει μια γραμμική συνάρτηση. Επιπλέον, η κλίση τη γραμμικής συνάρτησης είναι σταθερή, γεγονός που εμποδίζει την αποτελεσματική μάθηση μέσω της οπισθοδιάδοσης, καθώς τα βαθύτερα στρώματα δεν καταφέρνουν να συλλάβουν περίπλοκα μοτίβα.

Ο τύπος της είναι:

$$f(x) = x$$



Σχήμα 7: Συνάρτηση ενεργοποίησης γραμμικής [29]


Ενεργοποίησης διορθωμένης γραμμικής μονάδας (ReLU)

Η συνάρτηση ReLU εισήχθη για την αντιμετώπιση προκλήσεων στην εκπαίδευση των βαθιών νευρωνικών δικτύων, ιδιαίτερα του προβλήματος της κλίσης εξαφάνισης (vanishing gradient problem), το οποίο εμφανίζεται συχνά σε συναρτήσεις ενεργοποίησης όπως η σιγμοειδής και υπερβολικής εφαστομένης. Η ReLU παρέχει μια απλή αλλά αποτελεσματική λύση βγάζοντας απευθείας την είσοδο εάν είναι θετική, ενώ επιστρέφει μηδέν για οποιαδήποτε αρνητική είσοδο. Αυτό επιτρέπει την αποτελεσματική ροή κλίσης μέσω βαθιών δικτύων, καθιστώντας ευκολότερη την εκπαίδευση μοντέλων με πολλά επίπεδα. Επιπλέον είναι ταχύτερη και ευκολότερη

στην εφαρμογή σε σύγκριση με άλλες πιο πολύπλοκες συναρτήσεις ενεργοποίησης. Ωστόσο έχει τους περιορισμούς της, πάσχει από το ετοιμοθάνατο πρόβλημα ReLU (dying ReLU problem), όπου οι νευρώνες μπορεί να γίνουν ανενεργοί κατά τη διάρκεια της προπόνησης. Εάν ένας νευρώνας λαμβάνει συνεχώς αρνητικές εισόδους, βγάζει μηδέν και σταματά να μαθαίνει. Αυτό το ζήτημα είναι ιδιαίτερα ορατό όταν τα βάρη δεν αρχικοποιούνται σωστά ή ο ρυθμός εκμάθησης είναι πολύ υψηλός. Παρά αυτό το μειονέκτημα, η ReLU παραμένει μια δημοφιλής επιλογή για κρυφά επίπεδα σε βαθιά νευρωνικά δίκτυα λόγω της αποτελεσματικότητάς του και της ευκολίας χρήσης του.

Ο τύπος της είναι:

$$f(x) = \max(0, x)$$




Σχήμα 8: Συνάρτηση ενεργοποίησης ReLu [29]

Σιγμοειδή

Η σιγμοειδής συνάρτηση, ήταν μια από τις πρώτες συναρτήσεις ενεργοποίησης που χρησιμοποιήθηκαν στα νευρωνικά δίκτυα. Αντιστοιχίζει τις τιμές εισόδου σε ένα εύρος μεταξύ 0 και 1, καθιστώντας το ιδιαίτερα χρήσιμη για εργασίες δυαδικής ταξινόμησης όπου οι έξοδοι πρέπει να ερμηνεύονται ως πιθανότητες. Η ομαλή καμπύλη σχήματος S επιτρέπει σταδιακές μεταβάσεις μεταξύ των εξόδων, καθιστώντας την μια φυσική επιλογή όταν χρειάζονται πιθανότητες. Ωστόσο, έχει σημαντικούς περιορισμούς, ιδιαίτερα στα βαθιά δίκτυα. Ένα σημαντικό ζήτημα είναι το πρόβλημα της κλίσης εξαφάνισης. Όταν οι τιμές εισόδου είναι μεγάλες (είτε θετικές είτε αρνητικές), η έξοδος πλησιάζει ασυμπτωτικά τις τιμές 0 και 1, με αποτέλεσμα οι διαβαθμίσεις να γίνονται εξαιρετικά μικρές. Αυτό επιβραδύνει δραστικά τη μάθηση, ειδικά σε βαθύτερα επίπεδα, καθώς το μοντέλο δυσκολεύεται να ενημερώσει τα βάρη. Επιπλέον, δεδομένου ότι οι έξοδοι είναι πάντα θετικές, οι κλίσεις του δικτύου τείνουν να είναι προκατειλημμένες (biased gradient), γεγονός που μπορεί να κάνει την εκπαίδευση ακόμη πιο αργή.

Ο τύπος της είναι:

$$f(x) = \frac{1}{1 + e^{-x}}$$




Σχήμα 9: Συνάρτηση ενεργοποίησης σιγμοειδής [29]

Υπερβολική εφαπτομένη

Η συνάρτηση υπερβολικής εφαπτομένης εισήχθη ως βελτίωση της σιγμοειδής συνάρτησης, παρέχοντας μια έξοδο μηδενικού κέντρου (zero-centered) που διευκολύνει τη σύγκλιση του δικτύου. Αντιστοιχίζει τις τιμές εισόδου σε ένα εύρος μεταξύ -1 και 1, επιτρέποντας καλύτερη κανονικοποίηση των δεδομένων και βελτιωμένη εκμάθηση του δικτύου. Επειδή οι έξοδοι είναι κεντραρισμένες γύρω από το μηδέν, οι διαβαθμίσεις κατά την οπισθοδιάδοση είναι πιο ισορροπημένες, αποφεύγοντας το πρόβλημα προκατειλημμένης κλίσης που προκύπτει με την σιγμοειδή συνάρτηση. Αυτό το χαρακτηριστικό την κάνει καλύτερη επιλογή από την σιγμοειδή συνάρτηση σε πολλές περιπτώσεις, ιδιαίτερα για κρυφά επίπεδα. Ωστόσο, και αυτή επηρεάζεται από το πρόβλημα της κλίσης που εξαφανίζεται, ειδικά στα βαθιά δίκτυα. Όταν οι τιμές εισόδου είναι μεγάλες, οι τιμές εξόδου ισοπεδώνονται, με αποτέλεσμα να έχει μικρή κλίση και να μειώνεται ο ρυθμός εκπαίδευσης. Παρά αυτόν τον περιορισμό χρησιμοποιείται συχνά σε περιπτώσεις όπου οι εξόδους με μηδενικό κέντρο είναι ωφέλιμες, όπως σε επαναλαμβανόμενα νευρωνικά δίκτυα (RNN) και σε άλλες αρχιτεκτονικές που βασίζονται σε κανονικοποιημένα δεδομένα.

Ο τύπος της είναι:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$




Σχήμα 10: Συνάρτηση ενεργοποίησης υπερβολικής εφαιτομένης [29]

Softmax

Η softmax είναι μια συνάρτηση ενεργοποίησης ειδικά σχεδιασμένη για προβλήματα ταξινόμησης πολλών κατηγοριών. Σε αντίθεση με τις συναρτήσεις σιγμοειδή, υπερβολικής εφαιτομένης και ReLU που λειτουργούν σε μεμονωμένους νευρώνες, η softmax λειτουργεί συνήθως στο στρώμα εξόδου ενός νευρωνικού δικτύου. Μετατρέπει τις ακατέργαστες βαθμολογίες (logits) σε πιθανότητες, καθιστώντας το ιδανικό όταν η εργασία περιλαμβάνει πρόβλεψη περισσότερων από δύο κλάσεων. Η softmax μετατρέπει κάθε έξοδο σε τιμή μεταξύ 0 και 1, διασφαλίζοντας ότι το άθροισμα όλων των τιμών εξόδου είναι ίσο με 1, γεγονός που επιτρέπει μια πιθανολογική ερμηνεία. Αυτό καθιστά εύκολο τον προσδιορισμό της πιθανότητας κάθε κατηγορίας σε προβλήματα ταξινόμησης, όπως ο προσδιορισμός εάν μια εικόνα περιέχει γάτα, σκύλο ή πουλί. Ένα από τα βασικά πλεονεκτήματα είναι η ικανότητά του να χειρίζεται πολλαπλές εξόδους, διασφαλίζοντας παράλληλα ότι κάθε έξοδος είναι κατάλληλα σταθμισμένη σε σχέση με τις άλλες. Ωστόσο, το έχει ορισμένα μειονεκτήματα. Είναι υπολογιστικά πιο απαιτητική σε σύγκριση με απλούστερες λειτουργίες ενεργοποίησης όπως η ReLU, ειδικά όταν χρησιμοποιείται σε δίκτυα με πολλές κλάσεις. Επιπλέον μπορεί να είναι ευαίσθητη σε ακραίες τιμές στα δεδομένα, που σημαίνει ότι μια μόνο μεγάλη είσοδος μπορεί να παραμορφώσει την κατανομή πιθανοτήτων. Παρά αυτές τις προκλήσεις, η softmax είναι ένα πολύ σημαντικό εργαλείο για προβλήματα που απαιτούν ταξινόμηση πολλαπλών κλάσεων και χρησιμοποιείται ευρέως σε αρχιτεκτονικές βαθιάς μάθησης.

Ο τύπος της είναι:

$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}}$$



Σχήμα 11: Συνάρτηση ενεργοποίησης softmax [29]

Κάθε συνάρτηση ενεργοποίησης αναπτύχθηκε για την επίλυση συγκεκριμένων προβλημάτων στα νευρωνικά δίκτυα. Η γραμμική ενεργοποίηση είναι χρήσιμη σε εργασίες παλινδρόμησης, αλλά είναι περιορισμένη λόγω της αδυναμίας της να μοντελοποιήσει περίπλοκες σχέσεις. Η ReLU χρησιμοποιείται ευρέως για την αποτελεσματικότητά της σε βαθιά δίκτυα, αν και έχει τους περιορισμούς του με τους νεκρούς νευρώνες. Η σιγμοειδής και υπερβολική εφαστομένη ήταν σημαντικές συναρτήσεις πρώιμης ενεργοποίησης, αλλά έχουν αντικατασταθεί σε μεγάλο βαθμό σε κρυφά επίπεδα λόγω του προβλήματος εξαφανιζόμενης κλίσης. Ωστόσο, και οι δύο εξακολουθούν να είναι χρήσιμες σε συγκεκριμένα προβλήματα, όπως η δυαδική ταξινόμηση. Τέλος, η Softmax είναι απαραίτητη για ταξινόμηση πολλαπλών κλάσεων, αλλά οι υπολογιστικές απαιτήσεις και η ευαισθησία της σε ακραίες τιμές σημαίνει ότι πρέπει να χρησιμοποιείται προσεκτικά. Η επιλογή της συνάρτησης ενεργοποίησης είναι καθοριστικής σημασίας για την ικανότητα του δικτύου να μαθαίνει, να γενικεύει και να εκτελεί αποτελεσματικά όλες τις εργασίες που του ανατίθενται. Επηρεάζει τον τρόπο με τον οποίο το δίκτυο επεξεργάζεται τα δεδομένα και προσαρμόζεται κατά την εκπαίδευση, συμβάλλοντας σημαντικά στην απόδοσή του.

3.3.3 Συνάρτηση κόστους

Η συνάρτηση κόστους, γνωστή επίσης ως συνάρτηση απώλειας, είναι ένα κρίσιμο συστατικό στη μηχανική μάθηση και στα νευρωνικά δίκτυα. Ο σκοπός της είναι να μετρά τη διαφορά μεταξύ της προβλεπόμενης εξόδου του μοντέλου και των πραγματικών τιμών. Με άλλα λόγια, η συνάρτηση κόστους ποσοτικοποιεί το πόσο καλά συμφωνούν οι προβλέψεις του μοντέλου με τα πραγματικά δεδομένα. Ο στόχος της εκπαίδευσης ενός νευρωνικού δικτύου είναι να ελαχιστοποιήσει τη συνάρτηση κόστους, βελτιώνοντας έτσι την ακρίβεια του μοντέλου. Κατά τη διάρκεια της εκπαιδευτικής διαδικασίας, το μοντέλο κάνει προβλέψεις με βάση τα δεδομένα εισόδου και η συνάρτηση κόστους υπολογίζει το σφάλμα μεταξύ των προβλεπόμενων και των πραγματικών τιμών. Ο αλγόριθμος εκπαίδευσης, που χρησιμοποιεί συχνά τεχνικές όπως η διαβάθμιση κλίσης (gradient descent), στη συνέχεια προσαρμόζει τις παραμέτρους του μοντέλου (βάρη και πολώσεις) για να ελαχιστοποιήσει το σφάλμα.


Όσο μικρότερη είναι η τιμή της συνάρτησης κόστους, τόσο καλύτερα αποδίδει το μοντέλο. Παρακάτω είναι μερικές σημαντικές συναρτήσεις κόστους.

Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error)

Το μέσο τετραγωνικό σφάλμα είναι μια από τις πιο συχνά χρησιμοποιούμενες συναρτήσεις κόστους σε προβλήματα παλινδρόμησης, όπου ο στόχος είναι η πρόβλεψη μιας συνεχούς τιμής. Υπολογίζει τον μέσο όρο της τετραγωνικής διαφοράς μεταξύ των προβλεπόμενων και των πραγματικών τιμών. Η διαφορά στο τετράγωνο δίνει έμφαση σε μεγαλύτερα σφάλματα, καθιστώντας το μοντέλο πιο ευαίσθητο στις ακραίες τιμές. Όταν το σφάλμα είναι μεγάλο, ο τετραγωνισμός αυτού του σφάλματος μεγεθύνει τον αντίκτυπό του, ωθώντας το μοντέλο να εργαστεί σκληρότερα για να μειώσει αυτές τις μεγάλες αποκλίσεις. Ωστόσο, αυτή η έμφαση στα ακραία σημεία μπορεί μερικές φορές να είναι ένα μειονέκτημα, ειδικά εάν τα δεδομένα περιέχουν θόρυβο ή κακά στοιχεία που επηρεάζουν δυσανάλογα την εκπαίδευση του μοντέλου. Για παράδειγμα, εάν υπάρχουν μερικά ακραία σημεία δεδομένων, το μοντέλο μπορεί να διορθώσει υπερβολικά και να δώσει προτεραιότητα στην ελαχιστοποίηση των σφαλμάτων για αυτά τα σημεία σε βάρος της γενικής απόδοσης στα υπόλοιπα δεδομένα.

Ο τύπος της είναι:

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



Σχήμα 12: Γραφική παράσταση συνάρτησης κόστους MSE [30]


Μέσο Απόλυτο Σφάλμα (Mean Absolute Error)

Το μέσο απόλυτο σφάλμα μετρά τον μέσο όρο των απόλυτων διαφορών μεταξύ των προβλεπόμενων και των πραγματικών τιμών. Σε αντίθεση με το μέσο τετραγωνικό σφάλμα, δεν τετραγωνίζει τα σφάλματα, γεγονός που το καθιστά λιγότερο ευαίσθητο σε ακραίες τιμές. Χρησιμοποιείται συχνά όταν θέλουμε να δώσουμε την ίδια βαρύτητα

σε όλα τα σφάλματα, ανεξάρτητα από το μέγεθός τους με αποτέλεσμα να μην τιμωρεί δυσανάλογα τα μεγαλύτερα λάθη. Αυτό το καθιστά πιο ανθεκτικό σε ακραίες τιμές σε σύγκριση με το μέσο τετραγωνικό σφάλμα. Σε σενάρια όπου το μοντέλο χρειάζεται να ελαχιστοποιήσει το συνολικό σφάλμα χωρίς να ανησυχεί πολύ για τις ακραίες αποκλίσεις, προτιμάται συχνά. Για παράδειγμα, κατά την πρόβλεψη των τιμών των κατοικιών είναι προτιμότερο να χρησιμοποιηθεί καθώς μερικά ασυνήθιστα ακριβά σπίτια δεν θα πρέπει να επηρεάζουν σε μεγάλο βαθμό το μοντέλο. Ωστόσο, ένα μειονέκτημα του είναι ότι στερείται το τετράγωνο συστατικό, με αποτέλεσμα να μην είναι πολύ καλό στον εντοπισμό μεγάλων σφαλμάτων. Αυτό μπορεί να είναι ένα μειονέκτημα εάν η μείωση των μεγάλων σφαλμάτων αποτελεί προτεραιότητα.

Ο τύπος του είναι:

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




Σχήμα 13: Γραφική παράσταση συνάρτησης κόστους MAE [30]

Binary Cross-Entropy (Log Loss)

Η log loss είναι μια συνάρτηση κόστους που χρησιμοποιείται συνήθως σε προβλήματα δυαδικής ταξινόμησης. Υπολογίζει τη διαφορά μεταξύ της προβλεπόμενης πιθανότητας ενός αποτελέσματος και της πραγματικής δυαδικής ετικέτας και έχει εύρος τιμών από 0 μέχρι 1. Στη δυαδική ταξινόμηση, ο στόχος είναι να αποδοθεί μια πιθανότητα σε κάθε τάξη και η log loss παρέχει ένα μέτρο του πόσο καλά συμφωνούν οι προβλεπόμενες πιθανότητες του μοντέλου με τις πραγματικές ετικέτες. Λειτουργεί τιμωρώντας το μοντέλο πιο αυστηρά όταν κάνει μια λανθασμένη πρόβλεψη με μεγάλη βεβαιότητα. Για παράδειγμα, εάν το μοντέλο προβλέπει υψηλή πιθανότητα για την κλάση 0, αλλά η πραγματική ετικέτα είναι η κατηγορία 1, η ποινή θα είναι αυστηρή. Αυτό ωθεί το μοντέλο να είναι προσεκτικό και ακριβές με τις προβλέψεις του. Ωστόσο, η log loss μπορεί να είναι πολύ ευαίσθητη σε ακραίες προβλέψεις, όπου οι προβλεπόμενες πιθανότητες είναι πολύ κοντά στο 0 ή το 1. Αυτό μπορεί να προκαλέσει προβλήματα εάν το μοντέλο είναι υπερβολικά σίγουρο για τις λάθος προβλέψεις του, με αποτέλεσμα μια μεγάλη ποινή.

Ο τύπος της είναι:

$$L = -\frac{1}{m} \sum_{i=1}^m (y_i \cdot \log(\hat{y}_i) + (1 - y_i) \cdot \log(1 - \hat{y}_i))$$




Σχήμα 14: Γραφική παράσταση συνάρτησης κόστους Log Loss [30]

Hinge Loss

Η συνάρτηση hinge loss χρησιμοποιείται συνήθως σε μηχανές διανυσμάτων υποστήριξης (SVM) για προβλήματα ταξινόμησης. Εξασφαλίζει ότι η σωστή ταξινόμηση δεν προβλέπεται απλώς, αλλά προβλέπεται με μεγάλη βεβαιότητα. Για παράδειγμα, η σωστή κατηγορία πρέπει να προβλεφθεί με ποσοστό βεβαιότητας που να απέχει ένα συγκεκριμένο εύρος από το όριο απόφασης. Εάν η πρόβλεψη είναι σωστή και εντός του περιθωρίου, η απώλεια είναι μηδενική. Ωστόσο, εάν η πρόβλεψη είναι λανθασμένη ή πολύ κοντά στο όριο απόφασης, η απώλεια αυξάνεται. Αυτή η προσέγγιση που βασίζεται στο εύρος καθιστά αποτελεσματική την hinge loss για εργασίες ταξινόμησης όπου η μεγιστοποίηση του εύρους ανάμεσα στην πρόβλεψη και του ορίου απόφασης είναι σημαντική, όπως στα SVM. Ωστόσο, δεν συνηθίζεται στα νευρωνικά δίκτυα και τείνει να χρησιμοποιείται περισσότερο σε μοντέλα μηχανικής εκμάθησης.

Ο τύπος της είναι:

$$L = \max(0, 1 - y \cdot f(x))$$




Σχήμα 15: Γραφική παράσταση συνάρτησης κόστος Hinge Loss [30]

Huber Loss

Η απώλεια Huber είναι ένας συνδυασμός του μέσου τετραγωνικού σφάλματος και του μέσου απόλυτου σφάλματος, που χρησιμοποιείται συχνά όταν θέλουμε να είμαστε λιγότερο ευαίσθητοι σε ακραίες τιμές από το μέσο τετραγωνικό σφάλμα, αλλά πιο ευαίσθητοι από το μέσο απόλυτο σφάλμα. Συμπεριφέρεται σαν μέσο τετραγωνικό σφάλμα για μικρά λάθη και σαν μέσο απόλυτο σφάλμα για μεγάλα σφάλματα, παρέχοντας μια ισορροπία μεταξύ των δύο.

Ο τύπος της είναι:

$$L_{\delta}(y, f(x)) = \begin{cases} \frac{1}{2}(y - f(x))^2 & \text{για } |y - f(x)| \leq \delta \\ \frac{1}{2}\delta|y - f(x)| - \frac{1}{2}\delta^2 & \text{για } |y - f(x)| > \delta \end{cases}$$



Σχήμα 16: Γραφική παράσταση συνάρτησης κόστος Huber Loss [30]

Κάθε συνάρτηση κόστους έχει τα πλεονεκτήματα και τις αδυναμίες της, και η επιλογή της συνάρτησης που θα χρησιμοποιηθεί εξαρτάται από τη συγκεκριμένη φύση του προβλήματος. Το μέσο απόλυτο σφάλμα και μέσο τετραγωνικό σφάλμα χρησιμοποιούνται συνήθως σε εργασίες παλινδρόμησης, με το μέσο τετραγωνικό σφάλμα να είναι πιο ευαίσθητο σε μεγάλα σφάλματα, ενώ το μέσο απόλυτο σφάλμα παρέχει ανθεκτικότητα έναντι των ακραίων τιμών. Η log loss είναι απαραίτητη για προβλήματα ταξινόμησης. Εξειδικευμένες συναρτήσεις κόστους, όπως η hinge loss και η huber loss παρέχουν πρόσθετο έλεγχο σε περιπτώσεις όπου τα περιθώρια ταξινόμησης ή η ανθεκτικότητα έναντι των ακραίων τιμών είναι σημαντικά. Η συνάρτηση κόστους που επιλέγετε παίζει σημαντικό ρόλο στο πόσο αποτελεσματικά μαθαίνει το μοντέλο από τα δεδομένα και πόσο καλά γενικεύεται σε νέα παραδείγματα που δεν έχει δει στην προπόνηση.

3.3.4 Αλγόριθμος οπισθοδιάδοσης

Η οπισθοδιάδοση είναι ένας θεμελιώδης αλγόριθμος στην εκπαίδευση των νευρωνικών δικτύων, ιδιαίτερα για μοντέλα βαθιάς μάθησης. Είναι ο μηχανισμός που επιτρέπει στο δίκτυο να μάθει από τα λάθη του, προσαρμόζοντας τα βάρη των νευρώνων με βάση το σφάλμα μεταξύ της προβλεπόμενης εξόδου και της πραγματικής τιμής. Ο αλγόριθμος λειτουργεί υπολογίζοντας τη κλίση της συνάρτησης κόστους (η οποία μετρά το σφάλμα του μοντέλου) σε σχέση με κάθε βάρη στο δίκτυο. Αυτή η κλίση λέει στο δίκτυο πόσο κάθε βάρη συνεισφέρει στο σφάλμα. Στη συνέχεια, ο αλγόριθμος προσαρμόζει τα βάρη στην αντίθετη κατεύθυνση της κλίσης για να ελαχιστοποιήσει το σφάλμα, μια διαδικασία γνωστή ως διαβάθμιση κλίσης (gradient descent). Κατά τη διάρκεια πολλαπλών επαναλήψεων που το δίκτυο προπονείται πάνω στα δεδομένα, η οπισθοδιάδοση βοηθά στη βελτιστοποίηση των βαρών του δικτύου, μειώνοντας το συνολικό σφάλμα και βελτιώνοντας την απόδοση του δικτύου. Παρακάτω είναι μερικοί σημαντικοί αλγόριθμοι οπισθοδιάδοσης.

Stochastic Gradient Descent (SGD)

Ο SGD είναι ένας από τους πιο ευρέως χρησιμοποιούμενους αλγόριθμους οπισθοδιάδοσης. Ενημερώνει τα βάρη του μοντέλου υπολογίζοντας τη διαβάθμιση της συνάρτησης απώλειας χρησιμοποιώντας ένα μόνο παράδειγμα εκπαίδευσης (ή μια μικρή παρτίδα παραδειγμάτων) σε κάθε επανάληψη, αντί για ολόκληρο το σύνολο δεδομένων. Αυτό κάνει τον αλγόριθμο πολύ πιο γρήγορο και πιο αποτελεσματικό, ειδικά όταν έχουμε να κάνουμε με μεγάλα σύνολα δεδομένων. Ο όρος στοχαστική αναφέρεται στο γεγονός ότι κάθε ενημέρωση βασίζεται σε ένα τυχαίο υποσύνολο δεδομένων, το οποίο εισάγει θόρυβο στις ενημερώσεις κλίσης. Αν και αυτός ο θόρυβος μπορεί να επιβραδύνει τη σύγκλιση, βοηθά επίσης το μοντέλο να ξεφύγει από τα τοπικά ελάχιστα και να βρει καλύτερα καθολικά ελάχιστα.

Batch Gradient Descent (BGD)

Το BGD υπολογίζει τη διαβάθμιση της συνάρτησης κόστους για ολόκληρο το σύνολο δεδομένων εκπαίδευσης σε κάθε επανάληψη. Αυτό παρέχει πιο ακριβείς κλίσεις και πιο ομαλές ενημερώσεις σε σύγκριση με το SGD. Ωστόσο, είναι υπολογιστικά ακριβό, ιδιαίτερα για μεγάλα σύνολα δεδομένων, επειδή κάθε ενημέρωση βάρους απαιτεί διέλευση από ολόκληρο το σύνολο δεδομένων. Το BGD χρησιμοποιείται σπάνια στην πράξη λόγω της αναποτελεσματικότητάς του, αλλά χρησιμεύει ως καλή αναφορά για την κατανόηση των βασικών στοιχείων της διαβάθμισης κλίσης.

Mini-batch Gradient Descent

Το Mini-batch Gradient Descent είναι μια λύση ανάμεσα στο SGD και το BGD. Αντί να ενημερώνονται τα βάρη μετά από κάθε παράδειγμα εκπαίδευσης ή μετά από ολόκληρο το σύνολο δεδομένων, η mini-batch gradient descent χωρίζει το σύνολο δεδομένων σε μικρές παρτίδες και ενημερώνει τα βάρη μετά την επεξεργασία κάθε παρτίδας. Αυτή η προσέγγιση συνδυάζει την υπολογιστική απόδοση του SGD με τη σταθερότητα του BGD. Χρησιμοποιείται ευρέως στην πράξη επειδή παρέχει ταχύτερη σύγκλιση και πιο σταθερές ενημερώσεις βαρών.

Adam

Ο Adam είναι ένας από τους πιο δημοφιλείς αλγόριθμους βελτιστοποίησης για οπισθοδιάδοση στη βαθιά μάθηση. Παρακολουθεί τον μέσο όρο της κλίσης και το τετράγωνο του μέσου όρου της κλίσης για κάθε παράμετρο. Στη συνέχεια χρησιμοποιεί αυτές τις πληροφορίες για να προσαρμόσει δυναμικά τον ρυθμό εκμάθησης για κάθε βάρους. Αυτός ο δυναμικός μηχανισμός επιτρέπει στον Adam να αποδίδει καλά σε ένα ευρύ φάσμα καταστάσεων χωρίς να χρειάζεται εκτενές συντονισμό υπερπαραμέτρων.

Η οπισθοδιάδοση είναι η ραχοκοκαλιά της εκπαίδευσης των νευρωνικών δικτύων, επιτρέποντας στα μοντέλα να προσαρμόζουν επαναληπτικά τα βάρη τους για να ελαχιστοποιήσουν τα σφάλματα και να βελτιώσουν την απόδοση. Με τα χρόνια, έχουν αναπτυχθεί διάφοροι αλγόριθμοι για τη βελτιστοποίηση της εκπαιδευτικής διαδικασίας, καθένας με τα δικά του πλεονεκτήματα και περιορισμούς. Το SGD, με την ταχύτητα και την αποτελεσματικότητά του, χρησιμοποιείται ευρέως, ειδικά σε εφαρμογές μεγάλης κλίμακας. Ο Adam προτιμάται στην βαθιά μάθηση λόγω του προσαρμοστικού ρυθμού μάθησης και της γρήγορης σύγκλισης. Η επιλογή του

αλγορίθμου οπισθοδιάδοσης εξαρτάται από τα ειδικά χαρακτηριστικά του προβλήματος, των δεδομένων και της αρχιτεκτονικής δικτύου, αλλά καθεμία από αυτές τις μεθόδους διαδραματίζει κρίσιμο ρόλο στην ευελιξίας των σύγχρονων μοντέλων μηχανικής μάθησης.

3.3.5 Μεταφορά Μάθησης


Στην μηχανική εκμάθηση, τα μοντέλα συνήθως εκπαιδεύονται από την αρχή χρησιμοποιώντας μεγάλες ποσότητες δεδομένων. Ωστόσο, αυτή η προσέγγιση δεν είναι πάντα αποτελεσματική ενώ είναι αρκετά δαπανηρή, ειδικά όταν αντιμετωπίζουμε σύνθετα προβλήματα. Η μεταφορά μάθησης είναι μια τεχνική κατά την οποία η γνώση που αποκτάται από την εκπαίδευση ενός μοντέλου σε ένα πρόβλημα μεταφέρεται για να βοηθήσει στην επίλυση ενός άλλου σχετικού, αλλά διαφορετικού προβλήματος. Πιο συγκεκριμένα η μεταφορά μάθησης περιλαμβάνει τη λήψη ενός προεκπαιδευμένου μοντέλου που έχει εκπαιδευτεί σε ένα μεγάλο σύνολο δεδομένων για ένα συγκεκριμένο πρόβλημα (όπως η αναγνώριση εικόνας στο ImageNet) και την προσαρμογή του σε ένα νέο, μικρότερο σύνολο δεδομένων με διαφορετικό αλλά σχετικό πρόβλημα. Η βασική ιδέα είναι ότι τα πρώτα στρώματα ενός νευρωνικού δικτύου καταγράφουν συνήθως γενικά χαρακτηριστικά (όπως άκρες, υφές ή σχήματα στην αναγνώριση εικόνας) που μπορούν να είναι χρήσιμα σε πολλαπλές εργασίες. Τα τελευταία επίπεδα του δικτύου τείνουν να επικεντρώνονται περισσότερο στα ιδιαίτερα χαρακτηριστικά τις εκάστοτε εργασίας (όπως ο εντοπισμός συγκεκριμένων αντικειμένων ή κατηγοριών). Η μεταφορά μάθησης έχει βρει ευρεία χρήση σε διάφορους τομείς, ειδικά σε πεδία όπου τα δεδομένα με ετικέτα είναι σπάνια ή ακριβά στη συλλογή τους. Μία από τις πιο κοινές εφαρμογές της είναι σε εργασίες όρασης υπολογιστή, όπως η ανίχνευση αντικειμένων και η ταξινόμηση εικόνων. Τα προεκπαιδευμένα μοντέλα όπως το VGG16, το ResNet και το Inception εκπαιδεύονται σε μεγάλα σύνολα δεδομένων όπως το ImageNet και στη συνέχεια ρυθμίζονται με ακρίβεια για εξειδικευμένες εργασίες, όπως η ταξινόμηση ιατρικών εικόνων ή η αναγνώριση προσώπου. Αυτό μειώνει την ανάγκη για τεράστια σύνολα δεδομένων με ετικέτα. Επιπλέον έχει χρησιμοποιηθεί αρκετά στην επεξεργασία φυσικής γλώσσας επιτρέποντας την επαναχρησιμοποίηση μεγάλων μοντέλων που έχουν εκπαιδευτεί σε τεράστια όγκο κειμένου. Μοντέλα όπως το BERT, το GPT και το T5 είναι προεκπαιδευμένα σε δισεκατομμύρια λέξεις και στη συνέχεια μπορούν να ρυθμιστούν με ακρίβεια για συγκεκριμένες εργασίες όπως η ανάλυση συναισθήματος, η αυτόματη μετάφραση και η απάντηση ερωτήσεων. Αυτή η προσέγγιση έχει βελτιώσει σημαντικά την απόδοση των μοντέλων, ειδικά σε γλώσσες που δεν υπάρχουν πολλά δεδομένα ή εξειδικευμένους τομείς. Επίσης ένας ακόμα τομέας που έχει επωφεληθεί αρκετά είναι η αναγνώριση ομιλίας όπου τα προεκπαιδευμένα μοντέλα αναγνώρισης ομιλίας μπορούν να ρυθμιστούν με ακρίβεια ώστε να κατανοούν διαφορετικές γλώσσες, τόνους ή ακόμα και συγκεκριμένους τύπους θορύβου από το περιβάλλον. Αυτό έχει διευκολύνει την ανάπτυξη συστημάτων ομιλίας σε κείμενο για συγκεκριμένους κλάδους, γλώσσες ή περιβάλλοντα χωρίς να απαιτούνται εκτεταμένα σύνολα δεδομένων εκπαίδευσης για κάθε παραλλαγή.

Αν και είναι εξαιρετικά ωφέλιμη, η μεταφορά μάθησης έχει ορισμένους περιορισμούς. Ένα βασικό ζήτημα είναι ότι λειτουργεί καλύτερα όταν το πρόβλημα από το οποίο προέρχεται το μοντέλο είναι παρόμοιο με το πρόβλημα που θέλουμε να λύσουμε, εάν τα προβλήματα είναι αρκετά διαφορετικά, η μεταφορά μάθησης μπορεί να είναι αναποτελεσματική ή ακόμη και επιζήμια, ένα φαινόμενο γνωστό ως αρνητική μεταφορά. Επιπλέον, η προσαρμογή μεγάλων προεκπαιδευμένων μοντέλων απαιτεί

πολλές φορές αρκετούς υπολογιστικούς πόρους, οι οποίοι μπορεί να αποτελέσουν εμπόδιο για ορισμένες εφαρμογές. Υπάρχει επίσης ο κίνδυνος υπερβολικής προσαρμογής κατά την προσαρμογή του σε νέα μικρά σύνολα δεδομένων, καθώς το μοντέλο μπορεί να γίνει πολύ εξειδικευμένο στο νέο πρόβλημα, μειώνοντας την ικανότητά του να γενικεύει. Τέλος, η επιτυχής εφαρμογή της μεταφορά μάθησης απαιτεί συχνά προσεκτική προσαρμογή και πειραματισμό για να βρεθεί η σωστή ισορροπία μεταξύ της χρήσης προεκπαιδευμένων βαρών και της προσαρμογής του μοντέλου για τη νέα εργασία.

3.4 Denoising Autoencoders

Οι αυτόματοι κωδικοποιητές αφαίρεσης θορύβου (DAE) αντιπροσωπεύουν μια εξέλιξη των παραδοσιακών αυτόματων κωδικοποιητών, ειδικά σχεδιασμένων για να χειρίζονται θορυβώδη δεδομένα μαθαίνοντας ισχυρές αναπαραστάσεις ικανές να ανακατασκευάζουν καθαρά δεδομένα από την κατεστραμμένη έκδοσή τους [31]. Ενώ οι αυτόματοι κωδικοποιητές εστιάζουν στην κωδικοποίηση και την αποκωδικοποίηση δεδομένων σε μια πιο συμπίεσμένη αναπαράσταση, οι DAE επεκτείνουν αυτή την ιδέα προσθέτοντας θόρυβο στα δεδομένα εισόδου και εκπαιδεύοντας το δίκτυο να ανακτά τα αρχικά, μη αλλοιωμένα δεδομένα [31]. Αυτή η διαδικασία όχι μόνο ενισχύει την ικανότητα του δικτύου να γενικεύει και να μαθαίνει σημαντικά χαρακτηριστικά, αλλά αποδεικνύεται επίσης πολύτιμο σε πραγματικές εφαρμογές όπου τα δεδομένα είναι συχνά ελλιπή ή θορυβώδη.




Σχήμα 17: Δομή Denoising Autoencoders [32]

3.4.1 Επισκόπηση

Οι αυτόματοι κωδικοποιητές χρησιμοποιούνται εδώ και πολύ καιρό στον τομέα της μηχανικής μάθησης, κυρίως για εργασίες όπως η μείωση διαστάσεων και η μάθηση χωρίς επίβλεψη. Στόχος τους είναι να κωδικοποιήσουν τα δεδομένα εισόδου σε μια συμπίεσμένη μορφή, που ονομάζεται λανθάνων χώρος (latent space), και στη συνέχεια να αποκωδικοποιήσουν αυτόν τον λανθάνοντα χώρο σε μια ανακατασκευή που μοιάζει πολύ με τα αρχικά δεδομένα. Ωστόσο, τα δεδομένα των πραγματικών προβλημάτων

συχνά περιέχουν θόρυβο ή είναι ελλιπή και οι παραδοσιακοί αυτόματες κωδικοποιητές δυσκολεύονται να αποδώσουν αποτελεσματικά όταν αντιμετωπίζουν κατεστραμμένα δεδομένα εισόδου. Εδώ μπαίνουν στο παιχνίδι οι DAE εκπαιδεύοντας το δίκτυο να αφαιρεί το θόρυβο από τα δεδομένα εισόδου, ενώ παράλληλα μπορεί να ανακτήσει την υποκείμενη καθαρή δομή. Το κίνητρο πίσω από τους DAE είναι απλό, τα δεδομένα στον πραγματικό κόσμο σπάνια είναι τέλεια. Σε πολλούς τομείς όπως η επεξεργασία εικόνας, η ανάλυση ήχου, ακόμη και στην ιατρική διαγνωστική, τα δεδομένα με τα οποία εργαζόμαστε συχνά περιέχουν θόρυβο. Ο θόρυβος μπορεί να εκδηλωθεί με πολλές μορφές, όπως τυχαίες διαταραχές εικονοστοιχείων σε μια εικόνα, background noise σε αρχείο ήχου ή ελλιπείς μετρήσεις σε επιστημονικά σύνολα δεδομένων. Εάν ένα μοντέλο εκπαιδεύεται αποκλειστικά σε καθαρά δεδομένα, ενδέχεται να μην έχει καλή απόδοση όταν αντιμετωπίζει θορυβώδη δεδομένα. Επομένως, τα DAE έχουν σχεδιαστεί για να εκπαιδεύουν μοντέλα που μπορούν να χειριστούν αυτές τις ατέλειες και να παράγουν ακριβή αποτελέσματα.

Στην περίπτωση επεξεργασίας εικόνας, για παράδειγμα, τα DAE χρησιμοποιούνται για τον καθαρισμό εικόνων που έχουν καταστραφεί από τυχαίο θόρυβο, κακές συνθήκες φωτισμού ή ατέλειες στον αισθητήρα. Εκπαιδεύοντας το μοντέλο σε θορυβώδεις εκδόσεις εικόνων και αναμένοντας να παράγει καθαρές εικόνες, το DAE μαθαίνει να απορρίπτει το θόρυβο και να εστιάζει στα βασικά χαρακτηριστικά των δεδομένων. Αυτή η ικανότητα είναι ανεκτίμητη σε εφαρμογές όπως η αποκατάσταση εικόνων, όπου ο στόχος είναι η ανάκτηση καθαρών, υψηλής ποιότητας εικόνων από θορυβώδεις ή υποβαθμισμένες εκδόσεις. Ομοίως, στον τομέα της επεξεργασίας ομιλίας, μπορούν να χρησιμοποιηθούν DAE για τον καθαρισμό θορυβωδών ηχογραφήσεων. Για παράδειγμα, εάν ένα αρχείο ήχου περιέχει background noise λόγω περιβαλλοντικών παραγόντων, μπορεί να χρησιμοποιηθεί ένα DAE για την αφαίρεση αυτού του θορύβου και την παραγωγή μιας καθαρότερης έκδοσης του ήχου. Αυτό έχει σημαντικές επιπτώσεις σε πεδία όπως η αναγνώριση φωνής, όπου ο θόρυβος μπορεί να υποβαθμίσει σημαντικά την ακρίβεια των μοντέλων speech to text. Επιπλέον εκπαιδεύοντας ένα DAE για την αφαίρεση του θορύβου από το σήμα ήχου, το καθαρότερο σήμα που προκύπτει μπορεί να βελτιώσει την απόδοση μοντέλων που δέχονται αυτό τον ήχο σαν είσοδο.



Σχήμα 18: Ροή εργασίας ενός DAE σε φωτογραφίες αριθμών [33]

Οι DAE δεν είναι μόνο χρήσιμοι για το χειρισμό του θορύβου, αλλά διαδραματίζουν επίσης καίριο ρόλο στην εκμάθηση χαρακτηριστικών. Στην εκμάθηση χωρίς επίβλεψη, όπου τα δεδομένα με ετικέτα είναι σπάνια ή ακριβά για να αποκτηθούν, τα DAE μπορούν να βοηθήσουν στην εκμάθηση χρήσιμων αναπαραστάσεων από μη επισημασμένα ή θορυβώδη σύνολα δεδομένων. Για παράδειγμα, εκπαιδεύοντας ένα DAE για την αφαίρεση του θορύβου από τα δεδομένα εισόδου, το δίκτυο μαθαίνει να εξάγει τα πιο σημαντικά χαρακτηριστικά, τα οποία στη συνέχεια μπορούν να χρησιμοποιηθούν για άλλες εργασίες, όπως ταξινόμηση ή ομαδοποίηση. Αυτό καθιστά

τα DAE ένα ισχυρό εργαλείο για ημι-εποπτευόμενες και μη εποπτευόμενες εργασίες μάθησης, όπου ο στόχος είναι να αποκαλυφθούν μοτίβα σε δεδομένα χωρίς να βασίζονται σε μεγάλο βαθμό σε παραδείγματα με ετικέτα. Μια βασική πτυχή των DAE είναι η ικανότητά τους να γενικεύουν. Στη μηχανική μάθηση, η γενίκευση αναφέρεται στην ικανότητα ενός μοντέλου να αποδίδει καλά σε νέα, αόρατα δεδομένα, αντί να απομνημονεύει απλώς τα παραδείγματα στα οποία έχει εκπαιδευτεί. Οι DAE, με το να εκπαιδεύονται για την αφαίρεση του θορύβου, πρέπει να μάθουν να εξάγουν την υποκείμενη δομή των δεδομένων και να αποφεύγουν την υπερβολική προσαρμογή σε συγκεκριμένα μοτίβα θορύβου στα δεδομένα εκπαίδευσης. Αυτό τα καθιστά πιο αποτελεσματικά όταν αντιμετωπίζουν νέα θορυβώδη δεδομένα που δεν έχουν ξαναδεί, κάτι που είναι απαραίτητο χαρακτηριστικό για πρακτικές εφαρμογές.

3.4.2 Βασικές αρχές

Η βασική δομή ενός DAE αποτελείται από δύο κύρια στοιχεία, έναν κωδικοποιητή και έναν αποκωδικοποιητή. Αυτά τα δύο στοιχεία συνεργάζονται για να επεξεργαστούν τα δεδομένα εισόδου και να τα μετατρέψουν σε μια ουσιαστική αναπαράσταση [31]. Ο κωδικοποιητής είναι υπεύθυνος για τη συμπίεση των δεδομένων εισόδου σε μια μικρότερη, λανθάνουσα αναπαράσταση και ο αποκωδικοποιητής ανακατασκευάζει τα αρχικά δεδομένα από αυτήν τη συμπιεσμένη έκδοση. Στην περίπτωση DAE, τα δεδομένα εισόδου πρώτα αλλοιώνονται με θόρυβο πριν περάσουν μέσω του κωδικοποιητή. Στη συνέχεια, ο αποκωδικοποιητής επιχειρεί να ανακατασκευάσει την καθαρή έκδοση των δεδομένων από αυτή τη συμπιεσμένη αναπαράσταση, ουσιαστικά αφαιρώντας τον θόρυβο της εισόδου. Με την πάροδο του χρόνου, το δίκτυο μαθαίνει να απορρίπτει τον θόρυβο στην είσοδο και να επικεντρώνεται στην ανακατασκευή της αρχικής, καθαρής έκδοσης των δεδομένων.

Η διαδικασία εκπαίδευσης για ένα DAE διαφέρει από αυτή ενός παραδοσιακού αυτόματου κωδικοποιητή λόγω της προσθήκης θορύβου στα δεδομένα εισόδου. Ο θόρυβος που προστίθεται στα δεδομένα εισόδου κατά τη διάρκεια της εκπαίδευσης μπορεί να πάρει διάφορες μορφές. Μια κοινή προσέγγιση είναι η προσθήκη θορύβου Gauss στα δεδομένα εισόδου, που εισάγει τυχαίες διαταραχές εικονοστοιχείων στις εικόνες ή τυχαίες διακυμάνσεις στα ηχητικά σήματα. Εναλλακτικά, μπορεί επίσης να χρησιμοποιηθεί δομημένος θόρυβος, όπως αποκλεισμός τμημάτων μιας εικόνας ή αφαίρεση ορισμένων pixel. Η επιλογή του θορύβου εξαρτάται από το είδος της αλλοίωσης που αναμένεται να χειριστεί το μοντέλο στην πράξη. Για παράδειγμα, εάν ο στόχος είναι ο χειρισμός θορυβωδών εικόνων, ο τυχαίος Gaussian θόρυβος μπορεί να είναι κατάλληλος, ενώ ο δομημένος θόρυβος μπορεί να είναι πιο χρήσιμος για εργασίες όπου λείπουν ή αποκλείονται μέρη των δεδομένων. Οι DAE εκπαιδεύονται χρησιμοποιώντας έναν αλγόριθμο οπισθοδιάδοσης, παρόμοιο με άλλα νευρωνικά δίκτυα. Το δίκτυο προσαρμόζει τα βάρη του με βάση τις κλίσεις που υπολογίζονται από τη συνάρτηση απώλειας και με την πάροδο του χρόνου μαθαίνει να αναδομεί καθαρά δεδομένα από θορυβώδεις εισόδους με μεγαλύτερη ακρίβεια. Καθώς προχωρά η εκπαίδευση, το δίκτυο γίνεται πιο ικανό στο να αγνοεί το θόρυβο και να εστιάζει στα βασικά χαρακτηριστικά των δεδομένων.

Μία από τις σημαντικές πτυχές των DAE είναι το μέγεθος του latent space. Ο λανθάνοντας χώρος αντιπροσωπεύει τη συμπιεσμένη μορφή των δεδομένων εισόδου και το μέγεθός του έχει σημαντικό αντίκτυπο στην απόδοση του DAE. Εάν ο λανθάνοντας χώρος είναι πολύ μεγάλος, το δίκτυο ενδέχεται να μην μάθει ισχυρά

χαρακτηριστικά και αντίθετα μπορεί να απομνημονεύσει τα δεδομένα εκπαίδευσης. Αυτό θα είχε ως αποτέλεσμα κακή γενίκευση σε νέα δεδομένα. Από την άλλη πλευρά, εάν ο λανθάνοντας χώρος είναι πολύ μικρός, το δίκτυο μπορεί να δυσκολευτεί να διατηρήσει αρκετές πληροφορίες για να ανακατασκευάσει με ακρίβεια τα καθαρά δεδομένα. Επομένως, ο προσεκτικός συντονισμός του μεγέθους του λανθάνοντος χώρου είναι ζωτικής σημασίας για να διασφαλιστεί ότι το DAE μαθαίνει ουσιαστικές, ισχυρές αναπαραστάσεις των δεδομένων. Επιπλέον τα DAE επωφελούνται από μια μορφή τακτοποίησης (regularization), η οποία βοηθά στην αποφυγή υπερβολικής προσαρμογής. Η τακτοποίηση είναι μια τεχνική που χρησιμοποιείται στη μηχανική μάθηση για να διασφαλιστεί ότι το μοντέλο γενικεύεται καλά σε νέα δεδομένα και δεν απομνημονεύει απλώς τα παραδείγματα εκπαίδευσης. Στην περίπτωση των DAE, ο θόρυβος που προστίθεται στην είσοδο κατά τη διάρκεια της εκπαίδευσης λειτουργεί ως μια μορφή τακτοποίησης, αναγκάζοντας το δίκτυο να μάθει πιο ισχυρές αναπαραστάσεις. Αυτό αποτρέπει την υπερβολική προσαρμογή του μοντέλου σε συγκεκριμένα μοτίβα στα δεδομένα εκπαίδευσης και το βοηθά να αποδίδει καλά σε νέα, αόρατα θορυβώδη δεδομένα.

Μια άλλη ενδιαφέρουσα πτυχή των DAE είναι η σχέση τους με άλλες μορφές μοντέλων μάθησης χωρίς επίβλεψη. Για παράδειγμα, μοιράζονται κάποιες ομοιότητες με τους αυτόματους κωδικοποιητές παραλλαγών (VAE), οι οποίοι είναι ένας άλλος τύπος αυτόματου κωδικοποιητή που χρησιμοποιείται για εργασίες δημιουργίας δεδομένων. Ενώ τα VAE έχουν σχεδιαστεί για να μαθαίνουν έναν πιθανοτικό λανθάνοντα χώρο από τον οποίο μπορούν να δημιουργηθούν νέα δεδομένα, τα DAE επικεντρώνονται στην εκμάθηση μιας ντετερμινιστικής χαρτογράφησης που μπορεί να αφαιρέσει το θόρυβο από τα κατεστραμμένα δεδομένα. Και οι δύο τύποι αυτόματων κωδικοποιητών έχουν τα δυνατά τους σημεία και χρησιμοποιούνται συχνά με συμπληρωματικούς τρόπους, ανάλογα με τη συγκεκριμένη εργασία.

Συνοψίζοντας, οι DAE είναι ένα ισχυρό εργαλείο για την αντιμετώπιση δεδομένων με θόρυβο σε διάφορα πεδία. Με την εκμάθηση ισχυρών αναπαραστάσεων που μπορούν να αφαιρέσουν αποτελεσματικά το θόρυβο, τα DAE ενισχύουν την ποιότητα και την αξιοπιστία της ανακατασκευής δεδομένων, καθιστώντας τα πολύτιμα σε εφαρμογές που κυμαίνονται από την επεξεργασία εικόνας και ήχου έως την μάθηση χωρίς επίβλεψη. Η ικανότητά τους να γενικεύουν σε νέα, αόρατα θορυβώδη δεδομένα και η ευελιξία τους στον χειρισμό διαφόρων μορφών θορύβου τα καθιστούν βασικό συστατικό των σύγχρονων μοντέλων μηχανικής μάθησης.

3.4.3 Εφαρμογές στην ενεργειακή αποδόμηση

Η βασική πρόκληση στην αποδόμηση ενέργειας είναι ότι η συνολική κατανάλωση ενέργειας είναι συχνά ένα θορυβώδες σήμα που αποτελείται από επικαλυπτόμενες κατανάλωσης πολλαπλών συσκευών. Οι παραδοσιακές τεχνικές έχουν επικεντρωθεί σε μεθόδους εξαγωγής χαρακτηριστικών, επεξεργασίας σήματος και ομαδοποίησης, αλλά αυτές είναι λιγότερο αποτελεσματικές στο χειρισμό θορυβωδών δεδομένων ή συσκευών που έχουν πολύπλοκα και επικαλυπτόμενα σήματα κατανάλωσης. Σε αυτό το πλαίσιο, η μηχανική μάθηση, ιδιαίτερα τα μοντέλα βαθιάς μάθησης, όπως οι DAE, έχουν κερδίσει όλο και περισσότερο ενδιαφέρον για την επίλυση του προβλήματος της αποδόμησης ενέργειας. Οι DAE προσφέρουν μια ενδιαφέρουσα προσέγγιση για τη διαχείριση του θορύβου στα δεδομένα κατανάλωσης ενέργειας. Η ικανότητά τους να ανασυνθέτουν καθαρά σήματα από θορυβώδη δεδομένα τα καθιστά ιδανικά για την

απομόνωση των μεμονωμένων προτύπων χρήσης των συσκευών από τα δεδομένα συνολικής κατανάλωσης ενέργειας. Εκπαιδεύοντας ένα DAE για την αφαίρεση του θορύβου από το σήμα συνολικής ενέργειας, είναι δυνατό να ανακτηθούν καθαρά, διαχωρισμένα σήματα σε επίπεδο συσκευής που διαφορετικά θα κρυβόταν από επικαλυπτόμενη χρήση [34].

Σε ένα τυπικό σενάριο κατανάλωσης ενέργειας, πολλές συσκευές λειτουργούν ταυτόχρονα και τα σήματα ενέργειας τους επικαλύπτονται. Αυτό δημιουργεί ένα σύνθετο σήμα που είναι δύσκολο να διαχωριστεί σε μεμονωμένα στοιχεία. Για παράδειγμα, ένα νοικοκυριό μπορεί να έχει το ψυγείο, το κλιματιστικό, το πλυντήριο ρούχων και τα φώτα να λειτουργούν ταυτόχρονα. Κάθε συσκευή έχει το μοναδικό μοτίβο κατανάλωσης, αλλά αυτά τα μοτίβα συνδυάζονται στα συνολικά δεδομένα κατανάλωσης ενέργειας, καθιστώντας δύσκολη την εξαγωγή πληροφοριών σχετικά με τη συνεισφορά κάθε συσκευής. Τα DAE μπορούν να εφαρμοστούν στο NILM μοντελοποιώντας τη διαδικασία αποδόμησης ενέργειας ως πρόβλημα ανακατασκευής σήματος. Το συνολικό σήμα κατανάλωσης ενέργειας μπορεί να θεωρηθεί ως μια θορυβώδης εκδοχή των μεμονωμένων σημάτων της συσκευής και ο στόχος είναι να αναδημιουργηθούν τα καθαρά, μεμονωμένα σήματα από αυτό το θορυβώδες σύνολο. Σε αυτή την περίπτωση, το DAE λειτουργεί ως φίλτρο, μαθαίνοντας να αφαιρεί τον θόρυβο που δημιουργείται από την επικαλυπτόμενη χρήση ενέργειας πολλών συσκευών και να απομονώνει το καθαρό σήμα της συσκευής στην οποία έχει προπονηθεί. Η τυπική ροή εργασίας για την εφαρμογή DAE στην ενεργειακή αποδόμηση περιλαμβάνει τα παρακάτω βήματα.

Συλλογή και προεπεξεργασία δεδομένων

Αρχικά, συλλέγονται τα δεδομένα συνολικής κατανάλωσης ενέργειας, είτε από έναν έξυπνο μετρητή είτε από άλλο σύστημα παρακολούθησης ενέργειας. Αυτά τα δεδομένα συλλέγονται συνήθως σε τακτά χρονικά διαστήματα, με αποτέλεσμα να δημιουργείται μια χρονοσειρά κατανάλωσης ενέργειας. Δεδομένου ότι τα δεδομένα είναι θορυβώδη λόγω της ταυτόχρονης λειτουργίας πολλαπλών συσκευών, απαιτείται προεπεξεργασία για την τυποποίηση και την κανονικοποίηση των δεδομένων.

Εκπαίδευση του Μοντέλου DAE

Το DAE εκπαιδεύεται χρησιμοποιώντας ως είσοδο τη συνολική κατανάλωση ενέργειας, καθώς και τα δεδομένα κατανάλωσης μιας μεμονωμένης συσκευής. Κατά την εκπαίδευση, το συνολικό ενεργειακό σήμα περνά από τον κωδικοποιητή, ο οποίος το μετατρέπει σε μια συμπίεσμένη αναπαράσταση. Στη συνέχεια, ο αποκωδικοποιητής προσπαθεί να ανακατασκευάσει το σήμα της συγκεκριμένης συσκευής από αυτή τη συμπίεσμένη αναπαράσταση. Το μοντέλο συγκρίνει την ανακατασκευασμένη έξοδο του αποκωδικοποιητή με τα πραγματικά δεδομένα της συσκευής που θέλουμε να ανιχνεύσουμε, και προσπαθεί να ελαχιστοποιήσει το σφάλμα ανακατασκευής. Ο στόχος είναι το ανακατασκευασμένο σήμα να μοιάζει όσο το δυνατόν περισσότερο με το σήμα της συσκευής, μειώνοντας την επιρροή των υπόλοιπων συσκευών.

Ανίχνευση σήματος συσκευής

Αφού εκπαιδευτεί, το DAE μπορεί πλέον να χρησιμοποιηθεί για την ανίχνευση της κατανάλωσης ενέργειας της συσκευής στην οποία έχει εκπαιδευτεί. Όταν το μοντέλο λαμβάνει ένα σήμα με τη συνολική κατανάλωση ενέργειας, παράγει ένα καθαρό, διαχωρισμένο σήμα που αντιστοιχεί στην κατανάλωση της συγκεκριμένης συσκευής. Έτσι, καταφέρνει να απομονώσει αποτελεσματικά τη συμβολή της συσκευής από το συνολικό ενεργειακό φορτίο.

Επομένως, αν θέλουμε να ανιχνεύσουμε την κατανάλωση ενέργειας για κάθε συσκευή σε έναν χώρο χρησιμοποιώντας μόνο το συνολικό ενεργειακό σήμα, πρέπει να δημιουργήσουμε ένα μοντέλο DAE για κάθε συσκευή που μας ενδιαφέρει. Κάθε ένα από αυτά τα μοντέλα θα εκπαιδευτεί ξεχωριστά με τα δεδομένα της αντίστοιχης συσκευής, ώστε να μάθει να αναγνωρίζει το συγκεκριμένο μοτίβο κατανάλωσης ενέργειας μέσα στο συνολικό σήμα. Στη συνέχεια, όταν έχουμε ένα συνολικό σήμα κατανάλωσης, το περνάμε από κάθε ένα από αυτά τα μοντέλα. Κάθε μοντέλο θα απομονώσει το σήμα της συσκευής για την οποία έχει εκπαιδευτεί, διαχωρίζοντας τη δική της κατανάλωση από την υπόλοιπη συνολική κατανάλωση στον χώρο. Με αυτόν τον τρόπο, μπορούμε να έχουμε μια ακριβή εικόνα για την κατανάλωση ενέργειας κάθε συσκευής, χωρίς την ανάγκη επιμέρους μετρητών. Η χρήση των DAE στην ενεργειακή αποδόμηση έχει πολλά σημαντικά οφέλη. Πρώτον, μειώνει την εξάρτηση από τις προκαθορισμένες υπογραφές της συσκευής, επιτρέποντας στο μοντέλο να μάθει τα σχετικά χαρακτηριστικά απευθείας από τα δεδομένα. Αυτό είναι ιδιαίτερα χρήσιμο σε σενάρια όπου οι ενεργειακές υπογραφές συσκευών δεν είναι γνωστές εκ των προτέρων ή όπου ενδέχεται να εισαχθούν νέες συσκευές που δεν είχαν εμφανιστεί προηγουμένως. Δεύτερον, τα DAE είναι ανθεκτικά στο θόρυβο και τις διακυμάνσεις στα δεδομένα. Σε πολλές εφαρμογές NILM, η χρήση ενέργειας των συσκευών μπορεί να ποικίλλει λόγω παραγόντων όπως οι αλλαγές στα πρότυπα χρήσης ή οι εξωτερικές συνθήκες όπως η θερμοκρασία που επηρεάζει τα συστήματα κλιματισμού. Συνοψίζοντας, οι DAE μπορούν να παίξουν καθοριστικό ρόλο στη βελτίωση της ακρίβειας και της ανθεκτικότητας της αποσύνθεσης ενέργειας, διαχωρίζοντας αποτελεσματικά τα αλληλεπικαλυπτόμενα και θορυβώδη σήματα κατανάλωσης ενέργειας. Η ικανότητά τους να μαθαίνουν συμπιεσμένες αναπαραστάσεις δεδομένων και να ανακατασκευάζουν τα μεμονωμένα σήματα των συσκευών τα καθιστά κατάλληλα για τις προκλήσεις της NILM. Μέσα από τη διαδικασία φιλτραρίσματος του θορύβου και της εστίασης στα κύρια μοτίβα που σχετίζονται με κάθε συσκευή, οι DAE προσφέρουν μια ισχυρή προσέγγιση για την ακριβή αποδόμηση της κατανάλωσης ενέργειας σε οικιακό και εμπορικό επίπεδο. Ο αντίκτυπος των DAE εκτείνεται πέρα από την άμεση διαχείριση ενέργειας, επιτρέποντας πιο ακριβή παρακολούθηση, καλύτερη λήψη αποφάσεων για εξοικονόμηση ενέργειας και παρέχοντας μια λύση για την βελτίωση των έξυπνων δικτύων και προγραμμάτων ανταπόκρισης ζήτησης. Καθώς η αποσύνθεση ενέργειας συνεχίζει να εξελίσσεται, τα DAE αναμένεται να αποτελέσουν θεμελιώδες συστατικό για την αντιμετώπιση των σύνθετων προκλήσεων της ανάλυσης και βελτιστοποίησης της κατανάλωσης ενέργειας.

Κεφάλαιο 4. Μεθοδολογία

Σε αυτό το κεφάλαιο περιγράφεται η διαδικασία που ακολουθήθηκε για την εφαρμογή της μη παρεμβατικής παρακολούθησης φορτίου χρησιμοποιώντας ένα μοντέλο DAE. Η μέθοδος αυτή στοχεύει στην ανάλυση των ενεργειακών καταναλώσεων των συσκευών μέσα σε μια οικία με βάση τη συνολική της κατανάλωση. Για την υλοποίηση της μεθόδου χρησιμοποιήθηκαν δύο σύνολα δεδομένων, το UKDALE [35] και REDD [36], τα οποία παρέχουν δεδομένα κατανάλωσης ενέργειας από πραγματικές οικίες. Η μεθοδολογία περιλαμβάνει τα εξής στάδια: αρχικά, γίνεται περιγραφή των δεδομένων που χρησιμοποιήθηκαν και στη συνέχεια επιλέγονται οι συσκευές των οποίων η κατανάλωση θα αποδομηθεί. Το επόμενο βήμα είναι η δημιουργία και η εκπαίδευση του μοντέλου DAE. Τέλος, περιγράφεται η διαδικασία προεπεξεργασίας των δεδομένων για την καλύτερη δυνατή ακρίβεια στο μοντέλο αποδόμησης καθώς και οι μετρικές που θα χρησιμοποιηθούν για την αξιολόγηση της απόδοσης του μοντέλου. Αυτές οι μετρικές θα βοηθήσουν στην εκτίμηση της ακρίβειας του μοντέλου στην αναγνώριση και αποδόμηση των ενεργειακών καταναλώσεων των οικιακών συσκευών από τα συνολικά δεδομένα κατανάλωσης.

4.1 Περιγραφή Συνόλου Δεδομένων

Τα σύνολα δεδομένων διαδραματίζουν καθοριστικό ρόλο στη διαδικασία της ενεργειακής αποδόμησης και η συμβολή τους είναι ανεκτίμητη. Αποτελούν τη θεμελιώδη βάση για την ανάπτυξη και την αξιολόγηση μοντέλων, καθώς η αποτελεσματικότητά τους εξαρτάται σε μεγάλο βαθμό από την ποιότητα των δεδομένων. Για να προχωρήσουμε στην πειραματική διαδικασία, είχαμε δύο επιλογές αναφορικά με τα δεδομένα κατανάλωσης ενέργειας, είτε να δημιουργήσουμε ένα νέο σύνολο δεδομένων είτε να αξιοποιήσουμε ένα υπάρχον.

Η δημιουργία ενός νέου συνόλου δεδομένων για τη μέτρηση του οικιακού ηλεκτρικού δικτύου και της συνολικής κατανάλωσης ενέργειας παρουσιάζει αρκετές προκλήσεις. Μία από τις σημαντικότερες δυσκολίες έγκειται στη ρύθμιση της υποδομής συλλογής δεδομένων, η οποία περιλαμβάνει την εγκατάσταση αισθητήρων, όπως έξυπνων μετρητών, που είναι κατάλληλα ρυθμισμένοι για να διασφαλίζουν ακριβείς μετρήσεις. Το κόστος απόκτησης και συντήρησης αυτών των αισθητήρων μπορεί να είναι σημαντικό, ειδικά όταν το έργο κλιμακώνεται ώστε να περιλαμβάνει πολλά νοικοκυριά. Επιπλέον, η διαχείριση του τεράστιου όγκου δεδομένων που παράγονται από μετρήσεις υψηλής συχνότητας αποτελεί πρόκληση, καθώς το μέγεθος των δεδομένων αυξάνεται γρήγορα με την πάροδο του χρόνου, απαιτώντας ισχυρές λύσεις αποθήκευσης και αποτελεσματικές δυνατότητες επεξεργασίας [37]. Ένα άλλο βασικό πρόβλημα είναι η διασφάλιση της συμμετοχής και της ιδιωτικής ζωής των νοικοκυριών. Το να πείσουμε τους συμμετέχοντες να επιτρέψουν τους αισθητήρες στα σπίτια τους μπορεί να είναι δύσκολο, καθώς μπορεί να έχουν ανησυχίες σχετικά με το απόρρητο ή να μην είναι πρόθυμοι να αντιμετωπίσουν την ταλαιπωρία της εγκατάστασης. Το απόρρητο είναι ένα σημαντικό ζήτημα, καθώς τα πρότυπα κατανάλωσης ενέργειας μπορούν να αποκαλύψουν προσωπικές λεπτομέρειες σχετικά με τις οικιακές δραστηριότητες. Επομένως, ο ασφαλής χειρισμός δεδομένων είναι ουσιαστικής σημασίας για τη διατήρηση της εμπιστοσύνης των συμμετεχόντων. Τέλος οι διαχρονικές μελέτες, οι οποίες συχνά απαιτούνται για την καταγραφή ολοκληρωμένων προτύπων στην κατανάλωση ενέργειας, περιπλέκουν περαιτέρω τη διαδικασία. Η συλλογή δεδομένων για εκτεταμένες περιόδους αυξάνει την πιθανότητα

υποβάθμισης του αισθητήρα και εγκατάλειψης των συμμετεχόντων. Το μακροπρόθεσμο κόστος που σχετίζεται με τη συντήρηση του υλικού, την αποθήκευση μεγάλων συνόλων δεδομένων και την αποζημίωση των συμμετεχόντων μπορεί επίσης να είναι σημαντικό. Για τους παραπάνω λόγους καθώς και το γεγονός ότι τα τελευταία χρόνια έχουν δημιουργηθεί και είναι διαθέσιμα αρκετά σύνολα δεδομένων με μεγάλο εύρος καταγραφών επιλέξαμε να χρησιμοποιήσουμε έτοιμα set δεδομένων. Πιο συγκεκριμένα επιλέξαμε τα set δεδομένων REDD και UKDALE

4.1.1 UKDALE

Το σύνολο δεδομένων UKDALE (UK Domestic Appliance-Level Electricity) αποτελεί μια από τις πιο διαδεδομένες βάσεις δεδομένων στον τομέα της ενεργειακής αποδόμησης. Αναπτύχθηκε από τον Jack Kelly στο Imperial College [35]. Περιέχει δεδομένα κατανάλωσης ενέργειας σε επίπεδο συσκευής από 5 κατοικίες στο Ηνωμένο Βασίλειο για μια περίοδο 2.5 ετών και ο αριθμός των συσκευών που καταγράφηκαν κυμαίνεται από 5 μέχρι 54. Η καταγραφή της συνολικής κατανάλωσής γίνεται με συχνότητα 16 kHz ενώ για τις συσκευές η συχνότητα δειγματοληψίας γίνεται με 1/6 Hz. Το UKDALE είναι ένα από τα πιο αξιόπιστα και λεπτομερή σύνολα δεδομένων για την αποδόμηση της ενεργειακής κατανάλωσης, καθώς καλύπτει τόσο τη συνολική κατανάλωση της οικίας όσο και την κατανάλωση επιμέρους συσκευών όπως το ψυγείο, το πλυντήριο, η τηλεόραση, και άλλες κοινές οικιακές συσκευές. Η πολυπλοκότητα και το βάθος των δεδομένων το καθιστούν εξαιρετικά χρήσιμο για την εκπαίδευση και τη δοκιμή μοντέλων αποδόμησης. Ένα από τα μεγάλα πλεονεκτήματα του UKDALE είναι ότι προσφέρει δεδομένα από πραγματικές οικίες σε βάθος χρόνου, κάτι που επιτρέπει τη μελέτη της μεταβλητότητας στη χρήση των συσκευών με την πάροδο του χρόνου. Οι διαφορετικές συνήθειες κατανάλωσης ενέργειας των νοικοκυριών αντικατοπτρίζονται με ακρίβεια, και αυτό βοηθάει τα μοντέλα αποδόμησης να μάθουν να διαχωρίζουν τις συσκευές ακόμα και όταν αυτές χρησιμοποιούνται σε συνθήκες που δεν έχουν εκπαιδευτεί άμεσα.

4.1.2 REDD

Το σύνολο δεδομένων REDD (Reference Energy Disaggregation Dataset) είναι επίσης ένα από τα πλέον χρησιμοποιούμενα σύνολα δεδομένων στον τομέα της αποδόμησης ενεργειακών δεδομένων. Αναπτύχθηκε από τους J.Zico Kolter και Matthew J. Johnson στο MIT. Περιέχει δεδομένα από 6 κατοικίες στις ΗΠΑ [36]. Τα δεδομένα του REDD καλύπτουν τόσο τη συνολική κατανάλωση των οικιών και την κατανάλωση συγκεκριμένων συσκευών, η διάρκεια καταγραφής κυμαίνεται από 3 μέχρι 19 ημέρες, επιπλέον ο αριθμός των συσκευών που καταγράφηκαν κυμαίνεται από 10 μέχρι 24 και περιλαμβάνει συσκευές όπως φωτιστικά, θερμοσίφωνες, ψυγεία, και άλλες, με καταγραφές να γίνονται με συχνότητα 1 Hz για την συνολική κατανάλωση και 1/3 Hz για τις συσκευές. Το REDD είναι ιδιαίτερα σημαντικό για την εκπαίδευση και την αξιολόγηση μοντέλων αποδόμησης λόγω της διαφορετικής γεωγραφικής περιοχής που καλύπτει, προσφέροντας δεδομένα από αμερικανικά νοικοκυριά. Οι ενεργειακές συνήθειες και τα πρότυπα κατανάλωσης στις ΗΠΑ ενδέχεται να διαφέρουν από αυτά σε άλλες χώρες, όπως το Ηνωμένο Βασίλειο, και αυτό καθιστά το REDD ένα πολύτιμο συμπλήρωμα του UKDALE για την εκπαίδευση μοντέλων που είναι ανθεκτικά σε διαφορετικά περιβάλλοντα χρήσης. Επιπλέον, το REDD είναι ιδιαίτερα χρήσιμο για την ανάλυση βραχυπρόθεσμων δεδομένων λόγω της υψηλής συχνότητας καταγραφής των συσκευών. Αυτό επιτρέπει την ακριβή ταυτοποίηση των αλλαγών στην

κατανάλωση των συσκευών και μπορεί να βοηθήσει στην ανάπτυξη μοντέλων που ανιχνεύουν γρήγορα μεταβολές στη χρήση των συσκευών. Ωστόσο, σε αντίθεση με το UKDALE, το REDD καλύπτει μικρότερο χρονικό διάστημα, γεγονός που περιορίζει τη δυνατότητα ανάλυσης μακροπρόθεσμων μοτίβων κατανάλωσης.

4.2 Επιλογή συσκευών

Στο πλαίσιο της παρακολούθησης μη παρεμβατικού φορτίου (NILM) και της ενεργειακής κατανομής, η επιλογή των σωστών συσκευών είναι ένας από τους πιο κρίσιμους παράγοντες για τη διασφάλιση της συνολικής επιτυχίας της διαδικασίας διαχωρισμού. Για αυτήν τη μελέτη, οι συσκευές που επιλέχθηκαν ήταν το ψυγείο, ο φούρνος μικροκυμάτων, το πλυντήριο ρούχων και το πλυντήριο πιάτων. Οι παραπάνω συσκευές επιλέχθηκαν λόγω της σημαντικής συμβολής τους στην κατανάλωση ενέργειας του νοικοκυριού, καθώς και της παρουσίας τους σχεδόν σε κάθε σπίτι. Αυτές οι συσκευές παρουσιάζουν επίσης προβλέψιμα μοτίβα χρήσης, τα οποία προσθέτουν ένα σημαντικό επίπεδο αξιοπιστίας και συνέπειας στη διαδικασία διαχωρισμού. Η σημασία αυτών των επιλογών εκτείνεται πέρα από το πεδίο της συγκεκριμένης μελέτης, καθώς τα μοντέλα που αναπτύχθηκαν εδώ μπορούν να εφαρμοστούν σε διάφορα οικιακά περιβάλλοντα, καθιστώντας τα αποτελέσματα ευρύτερα εφαρμόσιμα.

Εφαρμογή στα νοικοκυριά

Ο πρώτος λόγος που επιλέχθηκαν αυτές οι τέσσερις συσκευές είναι η παρουσία τους σε νοικοκυριά σε όλο τον κόσμο. Το ψυγείο, ο φούρνος μικροκυμάτων, το πλυντήριο ρούχων και το πλυντήριο πιάτων είναι απαραίτητες συσκευές στα περισσότερα σπίτια, γεγονός που τα καθιστά ιδιαίτερα σημαντικά για μελέτες που στοχεύουν στη διάσπαση της κατανάλωσης ενέργειας. Εστιάζοντας σε αυτές τις ευρέως χρησιμοποιούμενες συσκευές, τα μοντέλα που δημιουργήθηκαν μέσω αυτής της μελέτης είναι πιο πιθανό να είναι χρήσιμα και εφαρμόσιμα αλλού, ανεξάρτητα από τις διαφορές στην οικιακή τεχνολογία από σπίτι σε σπίτι. Αυτό είναι ένα σημαντικό ζήτημα, επειδή ο απώτερος στόχος της ενεργειακής αποδόμησης δεν είναι απλώς η κατανόηση των προτύπων χρήσης ενέργειας ενός συγκεκριμένου νοικοκυριού, αλλά η ανάπτυξη μοντέλων που μπορούν να γενικευθούν σε διαφορετικά νοικοκυριά, συμβάλλοντας στην πιο αποτελεσματική διαχείριση ενέργειας και δυναμική εξοικονόμηση ενέργειας σε ευρύτερη κλίμακα. Η ευρεία χρήση αυτών των συσκευών διασφαλίζει επίσης ότι τα μοντέλα που αναπτύχθηκαν σε αυτή τη μελέτη μπορούν να εφαρμοστούν σε μεγάλο αριθμό κατοικιών. Εάν, για παράδειγμα, η μελέτη επικεντρωνόταν σε εξειδικευμένες ή λιγότερο κοινές συσκευές, ο αντίκτυπος των αποτελεσμάτων θα περιοριζόταν σε ένα μικρότερο υποσύνολο νοικοκυριών. Ωστόσο, επιλέγοντας συσκευές που είναι σχεδόν σε κάθε σπίτι, τα ευρήματα της μελέτης έχουν εκτεταμένες επιπτώσεις. Οι πάροχοι ενέργειας, οι προγραμματιστές έξυπνων κατοικιών και οι καταναλωτές μπορούν όλοι να επωφεληθούν από μοντέλα που προβλέπουν και αναλύουν με ακρίβεια τη χρήση ενέργειας για αυτές τις βασικές συσκευές.

Προβλέψιμα μοτίβα χρήσης ενέργειας

Ένας άλλος βασικός λόγος που επιλέχθηκαν αυτές οι συσκευές είναι ότι έχουν σχετικά προβλέψιμα μοτίβα χρήσης ενέργειας, γεγονός που τις καθιστά υποψήφιες για ενεργειακό διαχωρισμό. Σε αντίθεση με πιο μεταβλητές συσκευές, όπως υπολογιστές ή συστήματα ψυχαγωγίας, η κατανάλωση ενέργειας αυτών των τεσσάρων συσκευών είναι γενικά σταθερή και ακολουθεί τις αναμενόμενες λειτουργικές συμπεριφορές.

- **Ψυγείο:** Το ψυγείο λειτουργεί συνεχώς, αλλά η κατανάλωση ενέργειας ακολουθεί ένα κυκλικό μοτίβο, καθώς διατηρεί μια σταθερή εσωτερική θερμοκρασία. Ο συμπιεστής μπαίνει σε τακτά χρονικά διαστήματα για να κρυώσει ξανά το ψυγείο μόλις φτάσει σε ένα ορισμένο όριο θερμοκρασίας, δημιουργώντας μια χαρακτηριστική ενεργειακή υπογραφή. Αυτή η κυκλική φύση της κατανάλωσης ενέργειας καθιστά το ψυγείο μία από τις πιο προβλέψιμες συσκευές στο νοικοκυριό. Η συνεχής λειτουργία του και οι τακτικές απότομες αυξήσεις κατανάλωσης είναι εύκολα αναγνωρίσιμες στα συνολικά δεδομένα οικιακής ενέργειας, γεγονός που συμβάλλει στη βελτίωση της ακρίβειας των μοντέλων διαχωρισμού. Επιπλέον, η κατανάλωση ενέργειας του ψυγείου δεν είναι ιδιαίτερα μεταβλητή με την πάροδο του χρόνου, γεγονός που καθιστά ευκολότερη την πρόβλεψη και τον διαχωρισμό από τη συνολική κατανάλωση ενέργειας του νοικοκυριού.
- **Φούρνος μικροκυμάτων:** Σε αντίθεση με το ψυγείο, ο φούρνος μικροκυμάτων καταναλώνει μεγάλη ποσότητα ενέργειας σε πολύ σύντομα χρονικά διαστήματα. Η χρήση του είναι συνήθως σύντομη και έντονη, με υψηλή κατανάλωση ισχύος κατά τη λειτουργία. Παρά τη μεταβλητότητα στη συχνότητα χρήσης, το μοτίβο κατανάλωσης ενέργειας του φούρνου μικροκυμάτων είναι προβλέψιμο λόγω της σταθερής ισχύος που αντλεί κάθε φορά που χρησιμοποιείται. Αυτό δημιουργεί έντονες αυξήσεις στα δεδομένα κατανάλωσης που είναι σχετικά εύκολο να εντοπιστούν και να απομονωθούν από άλλες συσκευές. Η προβλεψιμότητα αυτών των σύντομων εκρήξεων ενέργειας καθιστά το φούρνο μικροκυμάτων εξαιρετικό υποψήφιο για ενεργειακή διάσπαση, καθώς έχει ένα διακριτό και αναγνωρίσιμο λειτουργικό προφίλ.
- **Πλυντήριο ρούχων:** Το πλυντήριο είναι πιο περίπλοκο, καθώς λειτουργεί σε πολλαπλές φάσεις, καθεμία με διαφορετικές ενεργειακές απαιτήσεις. Για παράδειγμα, μπορεί να αντλεί σημαντική ισχύ κατά τη φάση θέρμανσης όταν ζεσταίνεται νερό, ακολουθούμενη από χαμηλότερη κατανάλωση ενέργειας κατά τη διάρκεια των κύκλων πλύσης και ξεβγάλματος και, στη συνέχεια, άλλη μια αιχμή κατά τη διάρκεια του κύκλου στύψιματος. Ενώ η κατανάλωση ενέργειας του πλυντηρίου ρούχων έχει αρκετά περισσότερες διαφοροποιήσεις από αυτή του ψυγείου ή του φούρνου μικροκυμάτων, εξακολουθεί να είναι σε μεγάλο βαθμό προβλέψιμη επειδή αυτές οι φάσεις συμβαίνουν σε μια καθορισμένη σειρά. Τα πρότυπα λειτουργίας των πλυντηρίων ρούχων είναι αρκετά συνεπή σε διαφορετικά νοικοκυριά, καθώς τα περισσότερα μηχανήματα λειτουργούν με παρόμοιο τρόπο. Αυτό διευκολύνει τη δημιουργία μοντέλων διαχωρισμού που μπορούν να διαχωρίσουν αξιόπιστα την κατανάλωση ενέργειας του πλυντηρίου από το συνολικό ενεργειακό φορτίο.

- **Πλυντήριο πιάτων:** Όπως το πλυντήριο ρούχων, το πλυντήριο πιάτων λειτουργεί σε διακριτές φάσεις που ακολουθούν μια προβλέψιμη σειρά. Συνήθως καταναλώνει ενέργεια σε στάδια, όπως η θέρμανση του νερού, η κυκλοφορία του κατά τη διάρκεια του κύκλου πλύσης και το στέγνωμα των πιάτων. Αυτές οι φάσεις δημιουργούν ένα αναγνωρίσιμο μοτίβο κατανάλωσης ενέργειας που, αν και ελαφρώς μεταβλητό σε ένταση, ακολουθεί μια δομημένη εξέλιξη. Η προβλέψιμη λειτουργία πολλαπλών φάσεων του πλυντηρίου πιάτων το καθιστά ιδανική συσκευή για την ενεργειακή διάσπαση, καθώς η χρήση του μπορεί να αναγνωριστεί μέσω της διακριτής ενεργειακής υπογραφής του. Ενώ η ακριβής κατανάλωση ενέργειας μπορεί να διαφέρει ελαφρώς ανάλογα με το μέγεθος του φορτίου ή τη ρύθμιση του κύκλου, το συνολικό μοτίβο παραμένει σταθερό.

4.3 Μοντέλο

Το μοντέλο που χρησιμοποιείται για τον διαχωρισμό των δεδομένων κατανάλωσης ενέργειας είναι ένα DAE, το οποίο βασίστηκε στο DAE των Jack Kelly και William Knottenbelt [38]. Το DAE είναι ένας τύπος νευρωνικού δικτύου που έχει σχεδιαστεί κυρίως για να παίρνει μια είσοδο που περιέχει θόρυβο και στη συνέχεια να την ανακατασκευάζει φιλτράροντας τον θόρυβο. Σε αυτό το πλαίσιο, ορίζουμε το καθαρό σήμα ως την κατανάλωση ενέργειας μιας μεμονωμένης συσκευής, ενώ το σήμα με θόρυβο είναι η κατανάλωση ενέργειας ολόκληρου του σπιτιού, η οποία περιλαμβάνει τη χρήση ενέργειας από όλες τις συσκευές. Ο θόρυβος, σε αυτή την περίπτωση, είναι η συνδυασμένη κατανάλωση όλων των άλλων συσκευών εκτός από αυτήν που προσπαθούμε να απομονώσουμε ως το καθαρό σήμα. Αυτή η αρχιτεκτονική του DAE είναι κατάλληλη για NILM, καθώς στόχος του είναι να διαχωρίσει την κατανάλωση ενέργειας μιας συγκεκριμένης συσκευής από τη συνολική οικιακή κατανάλωση. Το μοντέλο το επιτυγχάνει αυτό εντοπίζοντας μοτίβα στην ολική ενεργειακή κατανάλωση και μαθαίνοντας να ανακατασκευάζει το καθαρό σήμα μιας συγκεκριμένης συσκευής. Ουσιαστικά φιλτράρει από την είσοδο τις ενεργειακές συνεισφορές των άλλων συσκευών, πέραν αυτής που μας ενδιαφέρει.

Η δομή του DAE που χρησιμοποιήθηκε περιλαμβάνει convolutional layers, dense layers, ένα flattening layer καθώς και ένα reshaping layer. Αρχικά περιείχε και dropout layers αλλά αφαιρέθηκαν καθώς δεν υπήρξε βελτίωση των αποτελεσμάτων. Αυτά τα στρώματα συνεργάζονται για να μειώσουν την πολυπλοκότητα της εισόδου (δηλαδή την κατανάλωση ενέργειας ολόκληρου του σπιτιού) κωδικοποιώντας την σε ένα χώρο χαμηλότερης διάστασης που καταγράφει τα βασικά χαρακτηριστικά της εισόδου και στη συνέχεια ανακατασκευάζοντας την κατανάλωση της συγκεκριμένης συσκευής. Κατά τη διάρκεια της εκπαίδευσης, το μοντέλο ελαχιστοποιεί το σφάλμα ανακατασκευής, στοχεύοντας να διαχωρίσει με ακρίβεια τη χρήση ενέργειας της μεμονωμένης συσκευής από το συνολικό θορυβώδες σήμα οικιακής χρήσης, εκτελώντας έτσι αποτελεσματικά την αποσύνθεση. Παρακάτω είναι η αρχιτεκτονική του μοντέλου που χρησιμοποιήθηκε.

Στρώματα μοντέλου	Παράμετροι στρωμάτων
Input Layer	shape=(sequence_length, 1)
1D convolution layer	kernel_size=4, strides=1, filters=8, activation="linear"
Flatten layer	shape=sequence_length*8
Dense layer	units=sequence_length*8, activation='relu'
Dense layer	units=128, activation='relu'
Dense layer	units=sequence_length*8, activation='relu'
Reshape layer	target_shape=(sequence_length, 8)
1D convolution layer	kernel_size = 4, strides=1, filters = 1, activation="linear"

Πίνακας 1: Στρώματα πειραματικού μοντέλου DAE

Ας αναλύσουμε την αρχιτεκτονική του μοντέλου του DAE στρώμα προς στρώμα για να κατανοήσουμε καλύτερα τη λειτουργία του.

Input Layer

Το μοντέλο ξεκινά με ένα Input Layer που δέχεται ακολουθίες δεδομένων κατανάλωσης ενέργειας. Οι διαστάσεις της εισόδου είναι (sequence_length, 1), όπου το sequence length αντιπροσωπεύει το μήκος της ακολουθίας και το 1 αντιπροσωπεύει το πλήθος των χαρακτηριστικών, όπου στο μοντέλο μας είναι μόνο η κατανάλωση ενέργειας.

1o 1D convolution layer

Το convolution layer λειτουργεί εφαρμόζοντας φίλτρα στα δεδομένα εισόδου προκειμένου να εξαχθούν σημαντικά χαρακτηριστικά. Αυτό το επίπεδο εξάγει μοτίβα από την χρονοσειρά, όπως μεταβάσεις στην κατανάλωση ενέργειας που προκαλούνται από την ενεργοποίηση ή απενεργοποίηση διαφορετικών συσκευών. Λειτουργεί εκτελώντας συνέλιξη μεταξύ της χρονοσειράς και των φίλτρων με σκοπό να δημιουργήσει ένα feature map με τα πιο σημαντικά χαρακτηριστικά της χρονοσειράς. Στο μοντέλο μας έχουμε βάλει 8 φίλτρα μεγέθους 4, επιπλέον η συνάρτηση ενεργοποίησης είναι γραμμική καθώς θέλουμε να διατηρήσουμε την δομή της χρονοσειράς. Η έξοδος του στρώματος έχει διάσταση (sequence_length, 8).

Flatten Layer

Αυτό το επίπεδο μετατρέπει την διδιάστατη έξοδο του 1D convolution layer σε ένα μονοδιάστατο διάνυσμα. Στην περίπτωση αυτή, η έξοδος με διαστάσεις (sequence_length, 8) ισοπεδώνεται σε ένα διάνυσμα μήκους sequence_length*8. Αυτή η διαδικασία προετοιμάζει τα δεδομένα για τα Dense Layers που ακολουθούν μετατρέποντας, την ακολουθία σε επίπεδη δομή.

1o Dense Layer

Το Dense Layer στρώμα έχει $\text{sequence_length} \times 8$ νευρώνες και χρησιμοποιεί τη συνάρτηση ενεργοποίησης ReLU για να εισάγει τη μη γραμμικότητα και να επιτρέψει στο μοντέλο να μάθει πολύπλοκες σχέσεις στα δεδομένα. Αυτό το επίπεδο αυξάνει την ικανότητα του μοντέλου να αναπαραστήσει το σήμα κατανάλωσης ενέργειας σε έναν χώρο περισσότερων διαστάσεων, επιτρέποντάς του να κωδικοποιήσει σημαντικά χαρακτηριστικά που συμβάλλουν στην απομόνωση του καθαρού σήματος.

2o Dense Layer

Το Dense Layer στρώμα συμπιέζει την έξοδο σε 128 νευρώνες. Αυτό λειτουργεί ως εμπόδιο που αναγκάζει το μοντέλο να μάθει μια συμπαγή αναπαράσταση των δεδομένων κατανάλωσης ενέργειας. Μειώνοντας τη διάσταση, το μοντέλο εστιάζει στην καταγραφή των πιο σημαντικών πληροφοριών για την αποσύνθεση ενέργειας.

3o Dense Layer

Μετά το εμπόδιο που εισάγει το 2o Dense Layer, το 3o Dense Layer επαναφέρει την έξοδο στους $\text{sequence_length} \times 8$ νευρώνες. Αυτή η αύξηση στους νευρώνες βοηθά το μοντέλο να ανακατασκευάσει το αρχικό σήμα μετά τη διαδικασία κωδικοποίησης και το προετοιμάζει για τα τελικά στάδια της ανακατασκευής.

Reshape Layer

Μετά την επεξεργασία μέσω των Dense Layers, η έξοδος αναδιαμορφώνεται σε μια διδιάστατη δομή σχήματος (sequence_length , 8), που ταιριάζει με τη μορφή της αρχικής εξόδου στρώματος 1D convolution layer. Αυτό το βήμα είναι απαραίτητο για την προετοιμασία των δεδομένων για το τελικό convolution layer, το οποίο θα ανακατασκευάσει το καθαρό σήμα.

1D convolution layer

Το τελικό convolution layer, με 1 φίλτρο μεγέθους 4 και συνάρτηση γραμμικής ενεργοποίησης, αναδομεί το σήμα ώστε να ταιριάζει με το αρχικό σχήμα εισόδου (sequence_length , 1). Αυτό το επίπεδο παίρνει τα χαρακτηριστικά που έχουν μάθει από τα προηγούμενα επίπεδα και τα μετατρέπει στην τελική πρόβλεψη, ένα καθαρό σήμα που δεν έχει θόρυβο και αντιστοιχεί στην κατανάλωση ενέργειας της συσκευής. Το μοντέλο εξάγει μια ακολουθία του ίδιου μήκους με την είσοδο, αλλά με τον θόρυβο φιλτραρισμένο. Η λειτουργία ενεργοποίησης είναι γραμμική, η οποία διασφαλίζει ότι οι τιμές εξόδου μπορούν να κυμαίνονται ελεύθερα και να αντιστοιχίζονται απευθείας στα πραγματικά επίπεδα κατανάλωσης ενέργειας.

Το μοντέλο χρησιμοποιεί το μέσο τετραγωνικό σφάλμα (MSE) ως συνάρτηση απώλειας. Το MSE μετρά τον μέσο όρο των τετραγωνικών διαφορών μεταξύ των προβλεπόμενων και των πραγματικών τιμών. Για το NILM, αυτό είναι ιδιαίτερα χρήσιμο επειδή τιμωρεί μεγάλα σφάλματα, τα οποία θα μπορούσαν να αντιστοιχούν σε σημαντικές εσφαλμένες προβλέψεις στην κατανάλωση ενέργειας. Τέλος για αλγόριθμο οπισθοδιάδοσης χρησιμοποιεί Adam optimizer. Ο Adam είναι ένας ευρέως χρησιμοποιούμενος αλγόριθμος βελτιστοποίησης που προσαρμόζει τον ρυθμό

εκμάθησης για κάθε παράμετρο, οδηγώντας σε πιο αποτελεσματική εκπαίδευση. Ο Adam είναι ιδιαίτερα κατάλληλος για μοντέλα όπως το DAE, όπου η εκμάθηση πρέπει να είναι γρήγορη και σταθερή.

4.4 Προεπεξεργασία δεδομένων

Πριν από την τροφοδοσία των δεδομένων κατανάλωσης ενέργειας στο μοντέλο του DAE, πραγματοποιήθηκαν κάποια βήματα προεπεξεργασίας για να διασφαλιστεί ότι τα δεδομένα ήταν στη κατάλληλη μορφή για τη διαδικασία της εκπαίδευσης του μοντέλου και στην συνέχεια της αποδόμησης ηλεκτρικής ενέργειας. Η προεπεξεργασία ήταν απαραίτητη τόσο για τη βελτίωση της απόδοσης του μοντέλου όσο και για τη διασφάλιση σωστών αποτελεσμάτων. Παρακάτω είναι τα βήματα της προεπεξεργασίας.

• Αφαίρεση τιμών NaN

Πριν προχωρήσουμε σε οποιαδήποτε περαιτέρω επεξεργασία, αντιμετωπίσαμε δεδομένα που λείπουν ή είναι ελλιπή, αφαιρώντας τυχόν τιμές NaN από το σύνολο δεδομένων. Αυτές οι τιμές NaN μπορεί να εμφανιστούν λόγω διαφόρων ζητημάτων, όπως δυσλειτουργίες αισθητήρα, διακοπές στη συλλογή δεδομένων ή ατελής καταγραφή της κατανάλωσης ενέργειας με την πάροδο του χρόνου. Εάν δεν αφαιρεθούν από τα δεδομένα, αυτές οι τιμές που λείπουν θα μπορούσαν να δημιουργήσουν σφάλματα, να παραμορφώσουν τη διαδικασία εκμάθησης ή να ωθήσουν το μοντέλο να παράγει αναξιόπιστα αποτελέσματα. Καταργώντας τις καταχωρήσεις NaN, διασφαλίζουμε ότι το σύνολο δεδομένων είναι καθαρό και έτοιμο για χρήση στην εκπαίδευση του μοντέλου. Αυτό το βήμα είναι κρίσιμο για τη διατήρηση της ακρίβειας και της ακεραιότητας των προβλέψεων του μοντέλου.

• Κανονικοποίηση δεδομένων

Τα δεδομένα κατανάλωσης ενέργειας συνήθως ποικίλλουν σημαντικά σε μέγεθος μεταξύ διαφορετικών συσκευών και μεταξύ διαφορετικών νοικοκυριών. Για να αποτρέψουμε αυτές τις διαφοροποιήσεις να επηρεάσουν αρνητικά τη διαδικασία εκπαίδευσης του μοντέλου, εφαρμόσαμε κανονικοποίηση ελάχιστης μέγιστης τιμής. Δεδομένου ότι οι τιμές κατανάλωσης ενέργειας είναι πάντα μη αρνητικές, η ελάχιστη τιμή ορίστηκε στο 0 και η μέγιστη τιμή ορίστηκε στην υψηλότερη παρατηρούμενη κατανάλωση ενέργειας στο σύνολο δεδομένων. Αυτή η μέθοδος μετατρέπει κάθε κατανάλωση σε ένα εύρος μεταξύ 0 και 1, με βάση τον τύπο:

$$normalized_value = \frac{value - min}{max - min}$$

στην περίπτωση μας, το min ήταν πάντα 0 οπότε ο τύπος απλοποιείται σε:

$$normalized_value = \frac{value}{max}$$

Αυτή η κανονικοποίηση διασφαλίζει ότι όλες οι εισοδοί εμπίπτουν σε ένα κοινό εύρος, το οποίο είναι απαραίτητο για το μοντέλο να επικεντρωθεί στην εκμάθηση των μοτίβων στα δεδομένα ισχύος χωρίς να επηρεάζεται από το μέγεθος της χρήσης ενέργειας των διαφορετικών συσκευών. Η κανονικοποίηση ελάχιστης μέγιστης

τιμής εμποδίζει επίσης τις μεγάλες τιμές να κυριαρχούν στη διαδικασία εκμάθησης και εξασφαλίζει ομαλότερη σύγκλιση κατά τη διάρκεια της εκπαίδευσης μοντέλων.

- **Ευθυγράμμιση χρονοσειρών**

Ένα σημαντικό βήμα στην προεπεξεργασία ήταν η ευθυγράμμιση των δύο χρονοσειρών. Η μία αντιπροσώπευε την συνολική κατανάλωση ενέργειας τις οικίας και η άλλη αντιπροσώπευε την κατανάλωση ενέργειας μιας μεμονωμένης συσκευής. Αυτές οι δύο σειρές έχουν συχνά ελαφρώς διαφορετικά timestamps λόγω διακυμάνσεων στα διαστήματα εγγραφής. Για να διασφαλίσουμε την ακριβή εκπαίδευση και σύγκριση, πραγματοποιήσαμε μια τομή των δύο χρονοσειρών, διατηρώντας μόνο τα δεδομένα που είχαν κοινά timestamps και στις δύο σειρές. Αυτή η ευθυγράμμιση είναι σημαντική για τη διατήρηση μιας συνεπούς χρονικής σχέσης μεταξύ της συνολικής χρήσης ενέργειας και της κατανάλωσης για τη συσκευή, επιτρέποντας στο μοντέλο να μαθαίνει αποτελεσματικά από συγχρονισμένα δεδομένα.

- **Προσαρμογή μήκους χρονοσειράς**

Για να διασφαλίσουμε ότι η χρονοσειρά μπορεί να επεξεργαστεί σωστά από το μοντέλο, τροποποιούμε το μήκος των δεδομένων ώστε να είναι ένα ακέραιο πολλαπλάσιο του `sequence_length`. Αυτό έγινε συμπληρώνοντας το τέλος της χρονοσειράς με μηδενικά μέχρι να φτάσει στο απαιτούμενο μήκος. Το μοντέλο επεξεργάζεται τα δεδομένα σε κομμάτια μεγέθους `sequence_length` και προσαρμόζουμε αυτήν την παράμετρο με βάση τον τυπικό κύκλο ισχύος της συσκευής που αναλύεται. Για μεγαλύτερους κύκλους συσκευής, επιλέγεται μεγαλύτερο `sequence_length` για να καταγράψει την πλήρη διάρκεια της λειτουργίας της συσκευής. Αυτό το βήμα διασφαλίζει ότι οι χρονοσειρές είναι κατάλληλα διαμερισμένες για εκπαίδευση, χωρίς να έχουν απομείνει, ημιτελείς ακολουθίες.

- **Αναδιαμόρφωση διαστάσεων χρονοσειράς**

Το τελευταίο βήμα προεπεξεργασίας περιλαμβάνει την αναδιαμόρφωση των χρονοσειρών ώστε να έχουν τις σωστές διαστάσεις για εισαγωγή στο μοντέλο. Αφού ρυθμίσαμε το μήκος της χρονοσειράς, τη μετατρέπουμε σε πίνακα 3 διαστάσεων με διαστάσεις (μήκος_χρονοσειράς / `sequence_length`, `sequence_length`, 1). Αυτός ο μετασχηματισμός διασφαλίζει ότι τα δεδομένα οργανώνονται στην απαιτούμενη τρισδιάστατη δομή, όπου κάθε τμήμα αντιστοιχεί σε ένα κομμάτι της χρονοσειράς με μήκος `sequence_length`, έτοιμο να τροφοδοτηθεί στο μοντέλο. Αυτή η αναδιαμόρφωση είναι απαραίτητη για να ταιριάζουν τα δεδομένα με την είσοδο που περιμένει το μοντέλο.

4.5 Μετρικές

Ένα σύστημα NILM, προκειμένου να είναι ολοκληρωμένο πρέπει μετά την διαδικασία της ενεργειακής αποδόμησης να είναι σε θέση να αξιολογήσει τη ποιότητα των αποτελεσμάτων που παράγει. Η επιλογή των μετρικών αξιολόγησης επηρεάζει άμεσα τη δυνατότητα σύγκρισης διαφορετικών μοντέλων ή αλγορίθμων, καθώς και τον εντοπισμό περιοχών προς βελτίωση. Οι μετρήσεις παρέχουν αντικειμενικά κριτήρια

που καθοδηγούν τη βελτίωση και την ρύθμιση του μοντέλου, διασφαλίζοντας ότι το σύστημα μπορεί να παρέχει αξιόπιστες πληροφορίες ενέργειας σε πραγματικό χρόνο στους χρήστες. Για συνεχείς προβλέψεις κατανάλωσης ενέργειας, όπως το μοντέλο που έχουμε δημιουργήσει είναι σημαντικό να υπάρχει μια μετρική που να καταγράφει τη διαφορά μεταξύ της πραγματικής και της προβλεπόμενης χρήσης ενέργειας. Στην περίπτωση μας, χρησιμοποιήσαμε το Root Mean Square Error (RMSE) για να αξιολογήσουμε τα αποτελέσματα. Το RMSE είναι ιδιαίτερα αποτελεσματικό για το NILM, καθώς παρέχει ένα σαφές μέτρο του πόσο κοντά είναι οι προβλέψεις του μοντέλου στις πραγματικές ενεργειακές τιμές, με χαμηλότερες τιμές RMSE να υποδεικνύουν μεγαλύτερη ακρίβεια στον διαχωρισμό ενέργειας. Αυτό το καθιστά απαραίτητο εργαλείο για τη μέτρηση της συνολικής απόδοσης του συστήματος NILM.

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

Εκτός από το RMSE, χρησιμοποιήσαμε επίσης τον πίνακα σύγχυσης (Confusion Matrix) ως βάση για την αξιολόγηση της απόδοσης του μοντέλου μας. Ενώ το RMSE εστιάζει στη μέτρηση της ακρίβειας των προβλέψεων συνεχούς κατανάλωσης ενέργειας, το Confusion Matrix παρέχει πολύτιμες πληροφορίες σχετικά με την ικανότητα του μοντέλου να αξιολογεί αν η συσκευή βρίσκεται σε λειτουργία ή όχι. Στο Confusion Matrix κάθε στήλη έχει τα πραγματικά αποτελέσματα της κλάσεις ενώ κάθε γραμμή έχει τα αποτελέσματα που έχουν προβλεφθεί, όπως φαίνεται στον ακόλουθο πίνακα:

		Actual Class	
		Positive (P)	Negative (N)
Predicted Class	Positive (P)	True Positive (TP)	False Positive (FP)
	Negative (N)	False Negative (FN)	True Negative (TN)

Πίνακας 2: Confusion Matrix

- **True Positives (TP):** Προβλέψεις όπου το μοντέλο προσδιορίζει με ακρίβεια τη θετική κατηγορία.
- **True Negatives (TN):** Προβλέψεις όπου το μοντέλο προσδιορίζει με ακρίβεια την αρνητική κατηγορία.
- **False Positives (FP):** Προβλέψεις όπου το μοντέλο προέβλεψε τη θετική κατηγορία, αλλά η πραγματική κατηγορία ήταν αρνητική.
- **False Negatives (FN):** Προβλέψεις όπου το μοντέλο προέβλεψε την αρνητική κατηγορία, αλλά η πραγματική κατηγορία ήταν θετική

Ο τρόπος που το χρησιμοποιούμε στο NILM είναι με την υπόθεση ότι όταν μια συσκευή καταναλώνει περισσότερα από 10 watt, θεωρείται πως βρίσκεται σε κατάσταση λειτουργίας, ενώ όταν καταναλώνει λιγότερα από 10 watt, θεωρείται πως δεν βρίσκεται σε λειτουργία. Επομένως, ορίζουμε την κατάσταση λειτουργίας ως Positive, και της μη λειτουργίας ως Negative. Με βάση αυτήν την προσέγγιση, οι όροι του Confusion Matrix μετατρέπονται ως εξής:

- **True Positives (TP):** Η συσκευή λειτουργεί και το μοντέλο πρόβλεψε ότι η συσκευή βρίσκεται σε κατάσταση λειτουργίας.
- **True Negatives (TN):** Η συσκευή δεν λειτουργεί και το μοντέλο πρόβλεψε ότι η συσκευή δεν βρίσκεται σε κατάσταση λειτουργίας.
- **False Positives (FP):** Η συσκευή δεν λειτουργεί και το μοντέλο πρόβλεψε ότι η συσκευή βρίσκεται σε κατάσταση λειτουργίας.
- **False Negatives (FN):** Η συσκευή λειτουργεί και το μοντέλο πρόβλεψε ότι η συσκευή δεν βρίσκεται σε κατάσταση λειτουργίας.

Με βάση αυτές τις μεταβλητές χρησιμοποιούμε τις μετρικές accuracy, precision, recall και f1 score για την αξιολόγηση της αποτελεσματικότητας του μοντέλου.

Accuracy

Το Accuracy αντιπροσωπεύει τη συνολική ορθότητα του μοντέλου μετρώντας την αναλογία των σωστών προβλέψεων, τόσο των αληθινών θετικών όσο και των αληθινών αρνητικών, από όλες τις προβλέψεις που έγιναν. Υπολογίζεται ως ο λόγος των σωστά ταξινομημένων προβλέψεων προς τον συνολικό αριθμό των προβλέψεων. Η ακρίβεια δίνει μια γενική ιδέα για το πόσο καλά αποδίδει το μοντέλο, αλλά μερικές φορές μπορεί να είναι παραπλανητική, ειδικά σε περιπτώσεις όπου το σύνολο δεδομένων δεν είναι ισορροπημένο με αποτέλεσμα μια κατηγορία να υπερτερεί σημαντικά από την άλλη. Για παράδειγμα, εάν μια συσκευή βρίσκεται σε μη λειτουργία για μεγάλο χρονικό διάστημα, ένα μοντέλο μπορεί να έχει υψηλή ακρίβεια απλώς προβλέποντας μη λειτουργία τις περισσότερες φορές, ακόμη και αν δεν καταγράφει τότε πως οι συσκευές βρίσκονται σε λειτουργία.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Precision

Το precision είναι ένα μέτρο για το πόσες από τις προβλέψεις όπου η συσκευή βρισκόταν σε κατάσταση λειτουργίας ήταν πραγματικά σωστές. Είναι ιδιαίτερα σημαντικό όταν το κόστος των ψευδώς θετικών είναι υψηλό, που σημαίνει ότι εάν το μοντέλο συχνά ταξινομεί εσφαλμένα τις συσκευές ως ενεργοποιημένες όταν είναι πραγματικά απενεργοποιημένες, θα οδηγούσε σε ανακριβή αποτελέσματα διαχωρισμού. Το precision υπολογίζεται ως ο λόγος των αληθινών θετικών προς το άθροισμα των αληθινών θετικών και των ψευδώς θετικών και το υψηλό precision σημαίνει ότι το μοντέλο είναι αξιόπιστο όταν προβλέπει ότι μια συσκευή χρησιμοποιείται.

$$Precision = \frac{TP}{TP + FP}$$

Recall

Το recall, μετρά πόσο καλά το μοντέλο είναι σε θέση να ανιχνεύσει όλες τις πραγματικές περιπτώσεις δραστηριότητας της συσκευής. Υπολογίζεται ως ο λόγος των αληθινών θετικών προς το άθροισμα των αληθινών θετικών και των ψευδών αρνητικών. Υψηλό recall δείχνει ότι το μοντέλο είναι αποτελεσματικό στον εντοπισμό συσκευών που χρησιμοποιούνται, ακόμα κι αν μερικές φορές παράγει ψευδώς θετικά αποτελέσματα. Σε σενάρια όπου είναι κρίσιμο να αποτυπωθεί κάθε περίπτωση μιας συσκευής σε λειτουργία, ακόμη και με το κόστος ορισμένων ψευδών θετικών στοιχείων, είναι επιθυμητό το υψηλό recall. Για παράδειγμα, στην κατανομή ενέργειας, το recall είναι σημαντικό, επειδή η έλλειψη μιας συσκευής που χρησιμοποιείται θα μπορούσε να οδηγήσει σε ελλιπή ή λανθασμένα δεδομένα χρήσης ενέργειας, παραμορφώνοντας την ανάλυση της κατανάλωσης ενέργειας.

$$Recall = \frac{TP}{TP + FN}$$

F1 Score

Το f1 score είναι ιδιαίτερα χρήσιμο όταν θέλουμε να εξισορροπήσουμε τις αντισταθμίσεις μεταξύ recall και precision. Παρέχει μια ενιαία μετρική που λαμβάνει υπόψη τόσο τα ψευδώς θετικά όσο και τα ψευδώς αρνητικά, καθιστώντας την ιδιαίτερα πολύτιμη όταν το κόστος αυτών των δύο τύπων σφαλμάτων είναι εξίσου σημαντικό. Μια υψηλή βαθμολογία F1 υποδηλώνει ότι το μοντέλο έχει καλή απόδοση τόσο στο recall όσο και στο precision, πράγμα που σημαίνει ότι είναι αποτελεσματικό στον εντοπισμό πότε χρησιμοποιείτε η συσκευή και στην αποφυγή εσφαλμένης ταξινόμησης όταν δεν χρησιμοποιείται. Αυτή η ισορροπία είναι κρίσιμη στο NILM, όπου τόσο η υπερεκτίμηση όσο και η υποεκτίμηση της δραστηριότητας της συσκευής μπορεί να οδηγήσει σε εσφαλμένες προβλέψεις κατανάλωσης ενέργειας.

$$F1\ Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} = 2 \cdot \frac{TP}{2 \cdot TP + FP + FN}$$

4.6 Πειραματική μέθοδος

Η διαδικασία των πειραμάτων που πραγματοποιήθηκαν βασίστηκε στη χρήση των συνόλων δεδομένων REDD και UKDALE και στην εφαρμογή του μοντέλου DAE, το οποίο περιγράφεται αναλυτικά στην ενότητα 4.3. Το κύριο ζητούμενο της μεθοδολογίας ήταν να αξιολογηθεί η απόδοση του DAE μοντέλου στην αποδόμηση ενέργειας, τόσο εντός του ίδιου συνόλου δεδομένων στο οποίο εκπαιδεύτηκε όσο και μεταξύ διαφορετικών συνόλων δεδομένων. Για τη διεκπεραίωση των πειραμάτων, χρησιμοποιήθηκε η βιβλιοθήκη NILMTK [39], η οποία παρείχε τη δυνατότητα εφαρμογής των αλγορίθμων CO και FHMM για συγκριτική αξιολόγηση.

Αρχικά, εκπαιδεύτηκαν τέσσερα μοντέλα DAE, ένα για κάθε επιλεγμένη συσκευή (ψυγείο, φούρνος μικροκυμάτων, πλυντήριο ρούχων, πλυντήριο πιάτων),

χρησιμοποιώντας δεδομένα από το σπίτι 1 του συνόλου δεδομένων REDD. Η εκπαίδευση πραγματοποιήθηκε χρησιμοποιώντας δεδομένα που καλύπτουν την περίοδο από τις 18-04-2011 έως τις 30-04-2011. Αυτή η περίοδος επιλέχθηκε ως αντιπροσωπευτικό δείγμα για την εκπαίδευση του μοντέλου, δεδομένου ότι καλύπτει επαρκές χρονικό διάστημα από το συνολικό σετ δεδομένων για την καταγραφή της κατανάλωσης των συσκευών. Αφού ολοκληρώθηκε η εκπαίδευση των μοντέλων, ακολούθησε η φάση των δοκιμών, κατά την οποία τα μοντέλα DAE δοκιμάστηκαν χρησιμοποιώντας δεδομένα από την επόμενη χρονική περίοδο, δηλαδή από τις 30-04-2011 έως τις 24-05-2011 για το ίδιο σπίτι. Αυτή η φάση επέτρεψε την αξιολόγηση της απόδοσης των μοντέλων όταν εφαρμόζονται σε δεδομένα που δεν χρησιμοποιήθηκαν κατά την εκπαίδευση. Παράλληλα, πραγματοποιήθηκαν δοκιμές και με τους αλγόριθμους CO και FHMM, οι οποίοι εφαρμόστηκαν στα ίδια δεδομένα μέσω της βιβλιοθήκης NILMTK, επιτρέποντας έτσι την άμεση σύγκριση των αποτελεσμάτων με εκείνα των DAE μοντέλων. Στη συνέχεια, η ίδια διαδικασία ακολουθήθηκε για το σύνολο δεδομένων UKDALE. Για την εκπαίδευση των μοντέλων, χρησιμοποιήθηκαν δεδομένα από το σπίτι 1 του UKDALE, καλύπτοντας την περίοδο από την 01-01-2014 έως την 01-01-2016. Η εκπαίδευση πραγματοποιήθηκε χρησιμοποιώντας αυτό το εκτεταμένο χρονικό διάστημα, επιτρέποντας στο μοντέλο να μάθει τα πρότυπα κατανάλωσης των συσκευών σε μακροχρόνια βάση. Αφού εκπαιδεύτηκαν τα τέσσερα μοντέλα DAE για το UKDALE, δοκιμάστηκαν στη χρονική περίοδο από τις 02-05-2016 έως τις 18-06-2016, για το ίδιο σπίτι. Σε αυτήν την περίπτωση, εφαρμόστηκαν επίσης οι αλγόριθμοι CO και FHMM από το NILMTK στα ίδια δεδομένα, με στόχο να συγκριθούν τα αποτελέσματα με εκείνα των μοντέλων DAE. Ένα κρίσιμο στάδιο της μεθοδολογίας ήταν η διασταυρωμένη αξιολόγηση των μοντέλων. Για να εξεταστεί η ικανότητα γενίκευσης των μοντέλων DAE σε διαφορετικά σύνολα δεδομένων, τα τέσσερα μοντέλα που είχαν εκπαιδευτεί χρησιμοποιώντας τα δεδομένα του REDD δοκιμάστηκαν στα δεδομένα του UKDALE, κατά την περίοδο από τις 02-05-2016 έως τις 18-06-2016. Αυτή η δοκιμή έγινε για τις ίδιες συσκευές, δηλαδή, εάν το μοντέλο είχε εκπαιδευτεί για ψυγείο στο REDD, δοκιμάστηκε μόνο για το ψυγείο στο UKDALE. Η ίδια διαδικασία ακολούθησε για τα μοντέλα που είχαν εκπαιδευτεί στο UKDALE. Τα μοντέλα αυτά δοκιμάστηκαν στο σύνολο δεδομένων του REDD, κατά την περίοδο από τις 30-04-2011 έως τις 24-05-2011, και πάλι για τις αντίστοιχες συσκευές.

Κεφάλαιο 5. Αποτελέσματα


5.1 Σετ δεδομένων REDD

Παρακάτω παραθέτονται τα αποτελέσματα της πειραματικής διαδικασίας για το σετ δεδομένων REDD. Παρουσιάζουμε τα αποτελέσματα εφαρμογής των μεθόδων ενεργειακής αποδόμησης DAE, CO και FHMM στο σετ δεδομένων REDD. Πιο συγκεκριμένα κάναμε προπόνηση με τις 3 μεθόδους στο 1ο σπίτι από τις 18-04-2011 έως τις 30-04-2011 στις συσκευές ψυγείο, φούρνο μικροκυμάτων, πλυντήριο ρούχων και πλυντήριο πιάτων και στη συνέχεια αξιολογήσαμε την αποτελεσματικότητά τους στο 1ο σπίτι από τις 30-04-2011 έως τις 24-05-2011.


5.1.1 Fridge

	CO	FHMM	DAE
Recall	0.4576	0.9566	0.9977
Precision	0.2641	0.399	0.8069
Accuracy	0.5027	0.5939	0.8056
F1 Score	0.3349	0.5631	0.8922
RMSE	167.8999	163.7218	77.9235


Πίνακας 3: Σύγκριση CO,FHMM,DAE συσκευής fridge στο dataset REDD




Σχήμα 19: Dataset REDD, appliance fridge, metric recall




Σχήμα 20: Dataset REDD, appliance fridge, metric precision



Σχήμα 21: Dataset REDD, appliance fridge, metric accuracy



Σχήμα 22: Dataset REDD, appliance fridge, metric f1 score




Σχήμα 23: Dataset REDD, appliance fridge, metric rmse

Τα αποτελέσματα ενεργειακής αποδόμησης για το ψυγείο χρησιμοποιώντας το σύνολο δεδομένων REDD αποκαλύπτουν σημαντικές διαφορές στην απόδοση των μοντέλων CO, FHMM και DAE. Η μετρική recall δείχνει ότι το DAE (0,9977) καταγράφει σχεδόν όλες τις περιπτώσεις ενεργοποίησης του ψυγείου, ενώ το FHMM έχει επίσης καλή απόδοση (0,9566). Αντίθετα, το CO (0,4576) χάνει αρκετές ενεργοποιήσεις, αντανakλώντας μια ασθενέστερη ικανότητα ανίχνευσης λειτουργίας του ψυγείου. Όσον αφορά την μετρική precision, το DAE (0,8069) προηγείται με μεγάλο περιθώριο, υποδηλώνοντας ότι κάνει λιγότερες ψευδώς θετικές προβλέψεις σε σύγκριση με το FHMM (0,399) και το CO (0,2641), που και τα δύο κάνουν αρκετές εσφαλμένες ανιχνεύσεις λειτουργίας. Η μετρική accuracy υποστηρίζει περαιτέρω την ισχύ του DAE (0,8056), με το CO (0,5027) και το FHMM (0,5939) να υπολείπονται. Τέλος η μετρική f1 score, δείχνει το DAE (0,8922) ως το πιο αξιόπιστο μοντέλο, ενώ το FHMM (0,5631) και το CO (0,3349) δείχνουν λιγότερο σταθερές επιδόσεις. Τέλος, το RMSE δείχνει ότι το DAE (77,9235) έχει τη μικρότερη απόκλιση μεταξύ της προβλεπόμενης και της πραγματικής κατανάλωσης ενέργειας, καθιστώντας την πιο ακριβή όσον αφορά την εκτίμηση της ισχύος. Τόσο το FHMM (163,7218) όσο και το CO (167,8999) παρουσιάζουν πολύ μεγαλύτερα σφάλματα, ενισχύοντας τις σχετικές αδυναμίες τους. Συνολικά, το DAE επιδεικνύει ανώτερη απόδοση, καθιστώντας το την καλύτερη επιλογή για την κατανομή της κατανάλωσης ψυγείου σε αυτό το σύνολο δεδομένων.


5.1.2 Microwave

	CO	FHMM	DAE
Recall	0.6919	0.5545	0.9999
Precision	0.0199	0.1448	0.7424
Accuracy	0.4162	0.9366	0.7424
F1 Score	0.0387	0.2296	0.8521
RMSE	261.8168	232.5942	118.865


Πίνακας 4: Σύγκριση CO,FHMM,DAE συσκευής MICROWAVE στο dataset REDD




Σχήμα 24: Dataset REDD, appliance microwave, metric recall




Σχήμα 25: Dataset REDD, appliance microwave, metric precision



Σχήμα 26: Dataset REDD, appliance microwave, metric accuracy



Σχήμα 27: Dataset REDD, appliance microwave, metric f1 score



Σχήμα 28: Dataset REDD, appliance microwave, metric rmse


Οι μετρικές ενεργειακής αποδόμησης για τον φούρνο μικροκυμάτων στο σύνολο δεδομένων REDD παρουσιάζουν διαφορετικά επίπεδα απόδοσης μεταξύ των μοντέλων CO, FHMM και DAE. Η μετρική recall δείχνει ότι το DAE (0,9999) καταγράφει σχεδόν όλα τα συμβάντα ενεργοποίησης μικροκυμάτων, ενώ το CO (0,6919) και το FHMM (0,5545) είναι λιγότερο αποτελεσματικά στην ανίχνευση της χρήσης μικροκυμάτων. Το precision παρουσιάζει ακόμα μεγαλύτερη διαφορά ανάμεσα στις 3 μεθόδους, με το CO (0,0199) και το FHMM (0,1448) να δείχνουν πολύ κακή ακρίβεια, που σημαίνει ότι έχουν πολλά ψευδώς θετικά. Το DAE (0,7424) προηγείται σημαντικά εδώ, υποδεικνύοντας λιγότερες ψευδές ενεργοποιήσεις των χρήσης μικροκυμάτων. Όσον αφορά το accuracy, το FHMM (0,9366) αποδίδει καλύτερα, υποδηλώνοντας ότι η συνολική ταξινόμηση, τόσο οι σωστές ανιχνεύσεις ενεργοποίησης όσο και οι σωστές ανιχνεύσεις μη ενεργοποίησης, είναι καλά ισορροπημένες σε αυτό το μοντέλο. Καλές επιδόσεις έχει και το DAE (0,7424), ενώ το CO (0,4162) υστερεί πολύ. Η μετρική f1 score, η οποία εξισορροπεί το precision και το accuracy, αναδεικνύει το DAE (0,8521) ως το πιο αξιόπιστο, ενώ το FHMM (0,2296) και το CO (0,0387) έχουν κακή απόδοση.

Τέλος, το RMSE δείχνει το DAE (118.865) με το χαμηλότερο σφάλμα, καθιστώντας το πιο ακριβές στην εκτίμηση της κατανάλωσης ενέργειας. Τα FHMM (232.5942) και CO (261.8168) έχουν πολύ μεγαλύτερα σφάλματα, αντανακλώντας τη ανικανότητα τους στην καταγραφή της πραγματικής χρήσης ενέργειας μικροκυμάτων. Συνολικά, το DAE αποδεικνύεται και πάλι το ανώτερο μοντέλο.


5.1.3 Washing machine

	CO	FHMM	DAE
Recall	0.8762	0.7178	0.8152
Precision	0.2752	0.4785	0.6757
Accuracy	0.9207	0.9653	0.6107
F1 Score	0.4189	0.5742	0.7389
RMSE	286.1899	301.8658	335.326


Πίνακας 5: Σύγκριση CO,FHMM,DAE συσκευής WASHING MACHINE στο dataset REDD




Σχήμα 29: Dataset REDD, appliance washing machine, metric recall




Σχήμα 30: Dataset REDD, appliance washing machine, metric precision



Σχήμα 31: Dataset REDD, appliance washing machine, metric accuracy



Σχήμα 32: Dataset REDD, appliance washing machine, metric f1 score




Σχήμα 33: Dataset REDD, appliance washing machine, metric rmse

Τα αποτελέσματα ενεργειακής αποδόμησης για το πλυντήριο ρούχων που χρησιμοποιεί το σύνολο δεδομένων REDD δείχνουν έναν συνδυασμό απόδοσης στα μοντέλα CO, FHMM και DAE. Ξεκινώντας με το recall, το CO (0,8762) αποδίδει καλύτερα, καταγράφοντας τις περισσότερες ενεργοποιήσεις του πλυντηρίου, ακολουθούμενο από το DAE (0,8152), ενώ το FHMM (0,7178) δείχνει ελαφρώς χαμηλότερη αποτελεσματικότητα στην ανίχνευση ενεργοποιήσεων. Όσον αφορά το precision, το DAE (0,6757) προηγείται, υποδεικνύοντας λιγότερες λανθασμένες ανιχνεύσεις λειτουργίας σε σύγκριση με το FHMM (0,4785) και το CO (0,2752). Αυτό υποδηλώνει ότι το DAE είναι πιο καλό στον σωστό εντοπισμό του πότε χρησιμοποιείται το πλυντήριο ρούχων, ενώ το CO, παρά το υψηλό recall, τείνει να δημιουργεί περισσότερες εσφαλμένες ανιχνεύσεις. Το accuracy ευνοεί το FHMM (0,9653), υποδηλώνοντας ότι εξισορροπεί σωστές και λανθασμένες προβλέψεις καλύτερα από το CO (0,9207) και το DAE (0,6107). Ωστόσο, το f1 score, κατατάσσει το DAE (0,7389) ως το πιο αξιόπιστο μοντέλο, ακολουθούμενο από το FHMM (0,5742) και το CO (0,4189), ενισχύοντας τη συνολική δύναμη του DAE στην αναγνώριση της δραστηριότητας του πλυντηρίου ρούχων. Είναι ενδιαφέρον ότι οι τιμές RMSE δείχνουν ότι όλα τα μοντέλα δυσκολεύονται να προβλέψουν με ακρίβεια την κατανάλωση ενέργειας του πλυντηρίου, με το CO (286,1899) να έχει το χαμηλότερο σφάλμα, ακολουθούμενο από το FHMM (301,8658) και το DAE (335,326), που υποδηλώνει ότι παρά τα δυνατά σημεία του DAE σε άλλες μετρικές, αντιμετωπίζει προκλήσεις στην εκτίμηση της πραγματικής κατανάλωσης ενέργειας.


5.1.4 Dish washer

	CO	FHMM	DAE
Recall	0.588	0.6678	0.9796
Precision	0.0958	0.0501	0.7499
Accuracy	0.7349	0.4233	0.7398
F1 Score	0.1647	0.0933	0.8495
RMSE	238.6079	241.1024	130.1636


Πίνακας 6: Σύγκριση CO,FHMM,DAE συσκευής DISH WASHER στο dataset REDD




Σχήμα 34: Dataset REDD, appliance dish washer, metric recall




Σχήμα 35: Dataset REDD, appliance dish washer, metric precision



Σχήμα 36: Dataset REDD, appliance dish washer, metric accuracy



Σχήμα 37: Dataset REDD, appliance dish washer, metric f1 score



Σχήμα 38: Dataset REDD, appliance dish washer, metric rmse

Τα αποτελέσματα αποδόμησης για το πλυντήριο πιάτων στο σύνολο δεδομένων REDD εμφανίζουν σημαντικές διαφορές στην απόδοση μεταξύ των μοντέλων CO, FHMM και DAE. Το recall δείχνει ότι το DAE (0,9796) υπερέχει στην ανίχνευση λειτουργίας του πλυντηρίου πιάτων, ξεπερνώντας σημαντικά τόσο το CO (0,588) όσο και το FHMM (0,6678). Ωστόσο, το precision αποκαλύπτει τις ελλείψεις του CO (0,0958) και του FHMM (0,0501), υποδεικνύοντας ότι κάνουν πολλές ψευδώς θετικές προβλέψεις. Το DAE, με ακρίβεια 0,7499, παρέχει μια πολύ πιο αξιόπιστη πρόβλεψη της χρήσης του πλυντηρίου πιάτων, διακρίνοντας το με ακρίβεια από άλλες συσκευές. Στη μετρική του accuracy, το DAE (0,7398) και το CO (0,7349) είναι σχετικά κοντά, ενώ το FHMM (0,4233) υστερεί. Αυτό αντικατοπτρίζει μια πιο ισορροπημένη απόδοση για το DAE και CO όσον αφορά τις συνολικές προβλέψεις, αν και το DAE παραμένει η ισχυρότερη απόδοση. Το f1 score, το οποίο εξισορροπεί το precision και το recall, δείχνει ξεκάθαρα το DAE (0,8495) ως το καλύτερο μοντέλο, ενώ το CO (0,1647) και το FHMM (0,0933) δυσκολεύονται να εξισορροπήσουν την ακρίβεια ανίχνευσης και τα ψευδώς θετικά. Τέλος, το RMSE τονίζει το χαμηλότερο σφάλμα του DAE (130,1636), υποδεικνύοντας ότι προβλέπει με μεγαλύτερη ακρίβεια την κατανάλωση ενέργειας σε σύγκριση με το CO (238,6079) και το FHMM (241,1024). Συνολικά, το DAE ξεχωρίζει ως το πιο αποτελεσματικό μοντέλο για την ενεργειακή αποδόμηση του πλυντηρίου πιάτων.


5.2 Σετ δεδομένων UKDALE

Παρακάτω παραθέτονται τα αποτελέσματα της πειραματικής διαδικασίας για το σετ δεδομένων UKDALE. Παρουσιάζουμε τα αποτελέσματα εφαρμογής των μεθόδων ενεργειακής αποδόμησης DAE, CO και FHMM στο σετ δεδομένων UKDALE. Πιο συγκεκριμένα κάναμε προπόνηση με τις 3 μεθόδους στο 1ο σπίτι από τις 01-01-2014 έως τις 01-01-2016 στις συσκευές ψυγείο, φούρνο μικροκυμάτων, πλυντήριο ρούχων και πλυντήριο πιάτων και στην συνέχεια αξιολογήσαμε την αποτελεσματικότητά τους στο 1ο σπίτι από τις 02-05-2016 έως τις 18-06-2016.


5.2.1 Fridge

	CO	FHMM	DAE
Recall	0.6521	0.7938	0.7198
Precision	0.5114	0.5099	0.9384
Accuracy	0.5877	0.5885	0.7016
F1 Score	0.5732	0.6209	0.8147
RMSE	97.9708	84.3776	44.1072


Πίνακας 7: Σύγκριση CO,FHMM,DAE συσκευής FRIDGE στο dataset UKDALE




Σχήμα 39: Dataset UKDALE, appliance fridge, metric recall




Σχήμα 40: Dataset UKDALE, appliance fridge, metric precision



Σχήμα 41: Dataset UKDALE, appliance fridge, metric accuracy



Σχήμα 42: Dataset UKDALE, appliance fridge, metric f1 score



Σχήμα 43: Dataset UKDALE, appliance fridge, metric rmse


Τα αποτελέσματα ενεργειακής αποδόμησης για το ψυγείο στο σύνολο δεδομένων UKDALE παρουσιάζουν σημαντικές διαφορές μεταξύ των μοντέλων CO, FHMM και DAE. Το recall δείχνει το FHMM (0,7938) ως το καλύτερο στον εντοπισμό χρήσης ψυγείου, ακολουθούμενο από το DAE (0,7198) και το CO (0,6521). Αυτό δείχνει ότι το FHMM καταγράφει περισσότερα συμβάντα λειτουργίας του ψυγείου, αν και το

DAE αποδίδει επίσης καλά. Ωστόσο, η μετρική precision αποκαλύπτει, την ικανότητα του DAE (0,9384), δείχνοντας ότι κάνει πολύ λιγότερες λανθασμένες θετικές προβλέψεις σε σύγκριση με το CO (0,5114) και το FHMM (0,5099). Αυτό υποδηλώνει ότι το DAE είναι πολύ πιο καλό στον εντοπισμό της χρήσης του ψυγείου χωρίς να το συγχέει με άλλες συσκευές. Το accuracy υποστηρίζει περαιτέρω τη συνολική απόδοση του DAE (0,7016), ξεπερνώντας τόσο το CO (0,5877) όσο και το FHMM (0,5885). Αυτό αντανakλά την ικανότητα του DAE να προβλέπει σωστά τη χρήση του ψυγείου. Η βαθμολογία F1, η οποία εξισορροπεί την ακρίβεια και την ανάκληση, δείχνει και πάλι το DAE (0,8147) ως το πιο αξιόπιστο μοντέλο, ενώ το CO (0,5732) και το FHMM (0,6209) αποδίδουν λιγότερο σταθερά. Τέλος, το RMSE τονίζει την ανώτερη ικανότητα του DAE να προβλέπει με ακρίβεια την κατανάλωση ενέργειας, με το χαμηλότερο σφάλμα (44,1072) σε σύγκριση με το CO (97,9708) και το FHMM (84,3776). Συνολικά, το DAE αποδεικνύεται ότι είναι το πιο αποτελεσματικό μοντέλο για την ενεργειακή αποδόμηση του ψυγείου στο σύνολο δεδομένων UKDALE, προσφέροντας μια καλή ισορροπία μεταξύ ακρίβειας ανίχνευσης και εκτίμησης κατανάλωσης ενέργειας.


5.2.2 Microwave

	CO	FHMM	DAE
Recall	0.7935	0.8706	0.49
Precision	0.0144	0.011	0.0556
Accuracy	0.6766	0.5356	0.9475
F1 Score	0.0283	0.0217	0.0998
RMSE	169.9221	166.414	86.161


Πίνακας 8: Σύγκριση CO,FHMM,DAE συσκευής MICROWAVE στο dataset UKDALE




Σχήμα 44: Dataset UKDALE, appliance microwave, metric recall




Σχήμα 45: Dataset UKDALE, appliance microwave, metric precision



Σχήμα 46: Dataset UKDALE, appliance microwave, metric accuracy



Σχήμα 47: Dataset UKDALE, appliance microwave, metric f1 score




Σχήμα 48: Dataset UKDALE, appliance microwave, metric rmse

Τα αποτελέσματα αποδόμησης ενέργειας για τον φούρνο μικροκυμάτων στο σύνολο δεδομένων UKDALE δείχνουν μικτή απόδοση σε μοντέλα CO, FHMM και DAE. Το recall δείχνει ότι το FHMM (0,8706) καταγράφει τα περισσότερα συμβάντα χρήσης μικροκυμάτων, ακολουθούμενο από το CO (0,7935). Το DAE υστερεί σημαντικά με recall (0,49), υποδηλώνοντας ότι χάνει περισσότερα συμβάντα λειτουργίας μικροκυμάτων από τα άλλα δύο μοντέλα. Ωστόσο, το precision δείχνει πως όλα τα μοντέλα δυσκολεύονται, με το DAE να πετυχαίνει ελαφρώς καλύτερο αποτέλεσμα (0,0556) από το CO (0,0144) και το FHMM (0,011). Αυτό σημαίνει ότι ενώ το FHMM και το CO καταγράφουν περισσότερα γεγονότα, κάνουν επίσης πολλές ψευδώς θετικές προβλέψεις, οδηγώντας σε χαμηλές βαθμολογίες precision. Το accuracy εμφανίζει την ισχυρή απόδοση του DAE (0,9475), που υπερβαίνει κατά πολύ το CO (0,6766) και το FHMM (0,5356). Αυτό υποδηλώνει ότι ενώ το DAE μπορεί να χάσει ορισμένα γεγονότα, οι συνολικές προβλέψεις του, τόσο θετικές όσο και αρνητικές είναι πιο αξιόπιστες. Το f1 score παραμένει χαμηλό για όλα τα μοντέλα, αλλά το DAE (0,0998) εξακολουθεί να υπερτερεί των CO (0,0283) και του FHMM (0,0217), υποδηλώνοντας ότι επιτυγχάνει καλύτερη ισορροπία, αν και με περιορισμούς. Τέλος, το RMSE υπογραμμίζει περαιτέρω το πλεονέκτημα του DAE στην ακριβή πρόβλεψη της κατανάλωσης ενέργειας, με πολύ χαμηλότερο σφάλμα (86.161) σε σύγκριση με το CO (169.9221) και το FHMM (166.414). Συνολικά, ενώ το DAE παλεύει με το recall και το accuracy η απόδοση εκτίμησης ενέργειας το καθιστούν μια πιο ισορροπημένη επιλογή για την αποδόμηση ενέργειας μικροκυμάτων σε αυτό το σύνολο δεδομένων.


5.2.3 Washing machine

	CO	FHMM	DAE
Recall	0.656	0.7204	0.9999
Precision	0.0793	0.0714	0.8544
Accuracy	0.7061	0.6437	0.8544
F1 Score	0.1415	0.1299	0.9214
RMSE	206.6484	211.0386	150.9796


Πίνακας 9: Σύγκριση CO,FHMM,DAE συσκευής WASHING MACHINE στο dataset UKDALE




Σχήμα 49: Dataset UKDALE, appliance washing machine, metric recall




Σχήμα 50: Dataset UKDALE, appliance washing machine, metric precision



Σχήμα 51: Dataset UKDALE, appliance washing machine, metric accuracy



Σχήμα 52: Dataset UKDALE, appliance washing machine, metric f1 score



Σχήμα 53: Dataset UKDALE, appliance washing machine, metric rmse


Οι μετρικές αποδόμησης ενέργειας για το πλυντήριο ρούχων στο σύνολο δεδομένων UKDALE αποκαλύπτουν ένα σαφές χάσμα απόδοσης μεταξύ του μοντέλου DAE και των άλλων δύο, CO και FHMM. Το recall δείχνει ότι το DAE (0,9999) είναι εξαιρετικά αποτελεσματικό στην καταγραφή σχεδόν όλων των περιπτώσεων λειτουργίας του πλυντηρίου, ξεπερνώντας κατά πολύ το CO (0,656) και το FHMM (0,7204). Το precision εμφανίζει ότι το DAE (0,8544) ξεχωρίζει σημαντικά, υποδεικνύοντας ότι κάνει πολύ λιγότερες ψευδώς θετικές προβλέψεις σε σύγκριση με το CO (0,0793) και το FHMM (0,0714). Αυτό υπογραμμίζει την ακρίβεια του DAE στον σωστό προσδιορισμό της χρήσης του πλυντηρίου ρούχων, ενώ το CO και το FHMM δυσκολεύονται να ξεχωρίσουν το πλυντήριο από άλλες συσκευές. Όσον αφορά το accuracy, το DAE έχει και πάλι τις καλύτερες επιδόσεις (0,8544), παρέχοντας μια ισορροπημένη συνολική απόδοση πρόβλεψης, ενώ το CO (0,7061) και το FHMM (0,6437) είναι λιγότερο αξιόπιστα. Το f1 score, όπου εξισορροπεί το precision και το recall, δείχνει το DAE (0,9214) να είναι σημαντικά καλύτερο, με το CO (0,1415) και το FHMM (0,1299) να υστερούν πολύ, υποδηλώνοντας πολύ λιγότερο αξιόπιστη

απόδοση. Τέλος, το RMSE υπογραμμίζει την ανώτερη εκτίμηση κατανάλωσης ενέργειας του DAE, με το χαμηλότερο σφάλμα (150,9796), αρκετά καλύτερη από το CO (206,6484) και το FHMM (211,0386). Συνολικά, το DAE είναι το πιο αποτελεσματικό μοντέλο για αποδόμηση ενέργειας των πλυντηρίων ρούχων σε αυτό το σύνολο δεδομένων.

5.2.4 Dish washer

	CO	FHMM	DAE
Recall	0.7046	0.8444	0.9328
Precision	0.0339	0.0409	0.0766
Accuracy	0.5068	0.5173	0.7262
F1 Score	0.0647	0.0781	0.1416
RMSE	238.4122	240.8623	226.049


Πίνακας 10: Σύγκριση CO,FHMM,DAE συσκευής DISH WASHER στο dataset UKDALE




Σχήμα 54: Dataset UKDALE, appliance dish washer, metric recall

Σχήμα 55: Dataset UKDALE, appliance dish washer, metric precision

Σχήμα 56: Dataset UKDALE, appliance dish washer, metric accuracy



Σχήμα 57: Dataset UKDALE, appliance dish washer, metric f1 score



Σχήμα 58: Dataset UKDALE, appliance dish washer, metric rmse

Τα αποτελέσματα αποδόμησης ενέργειας για το πλυντήριο πιάτων στο σύνολο δεδομένων UKDALE παρουσιάζουν σημαντικές διαφορές στην απόδοση των μοντέλων CO, FHMM και DAE. Η μετρική recall δείχνει το DAE (0,9328) ως το καλύτερο στην καταγραφή συμβάντων χρήσης του πλυντηρίου πιάτων, ακολουθούμενο από το FHMM (0,8444) και το CO (0,7046). Αυτό υποδηλώνει ότι το DAE είναι το πιο αποτελεσματικό στον εντοπισμό της λειτουργίας του πλυντηρίου πιάτων σε όλο το σύνολο δεδομένων. Ωστόσο, το precision δείχνει ότι όλα τα μοντέλα παλεύουν με ψευδώς θετικά αποτελέσματα, με το DAE (0,0766) να ξεπερνά ελαφρώς το FHMM (0,0409) και το CO (0,0339). Αν και το DAE έχει καλύτερη recall, εξακολουθεί να υποφέρει από ανακριβείς προβλέψεις όσον αφορά τον σωστό προσδιορισμό της χρήσης του πλυντηρίου πιάτων. Το accuracy επιβεβαιώνει περαιτέρω το πλεονέκτημα του DAE (0,7262) έναντι του CO (0,5068) και του FHMM (0,5173), αντικατοπτρίζοντας τη συνολική καλύτερη απόδοσή του στην αποδόμηση της κατανάλωσης ενέργειας του πλυντηρίου πιάτων. Το f1 score, παραμένει χαμηλό για όλα τα μοντέλα, με το DAE (0,1416) να έχει καλύτερες επιδόσεις από το CO (0,0647) και το FHMM (0,0781), αλλά εξακολουθεί να μην φτάνει σε υψηλό επίπεδο αξιοπιστίας. Τέλος, το RMSE δείχνει το DAE με το χαμηλότερο σφάλμα (226.049), υποδεικνύοντας καλύτερη ακρίβεια στην πρόβλεψη της κατανάλωσης ενέργειας σε σύγκριση με το CO (238.4122) και το FHMM (240.8623). Συνολικά, το DAE έχει τα καλύτερα αποτελέσματα, αλλά εξακολουθεί να αντιμετωπίζει προκλήσεις στο precision.

5.3 Ανάμεικτα δεδομένα


Σε αυτό το υποκεφάλαιο, διερευνούμε τις δυνατότητες γενίκευσης των μοντέλων DAE δοκιμάζοντας τα σε διαφορετικά σύνολα δεδομένων από αυτά στα οποία προπονήθηκαν. Συγκεκριμένα, παίρνουμε τα μοντέλα DAE που έχουν εκπαιδευτεί στα σύνολα δεδομένων UKDALE, REDD και αξιολογούμε την απόδοσή τους στο σύνολο δεδομένων REDD και UKDALE αντίστροφα. Αυτή η δοκιμή συνόλων δεδομένων μάς επιτρέπει να αξιολογήσουμε πόσο καλά αποδίδουν τα μοντέλα όταν εφαρμόζονται σε δεδομένα με διαφορετικά οικιακά πρότυπα κατανάλωσης ενέργειας, κάτι που είναι κρίσιμο για την κατανόηση της ανθεκτικότητας και της προσαρμοστικότητας των μοντέλων σε πραγματικά σενάρια. Τα αποτελέσματα από αυτήν την ανάλυση θα προσφέρουν πληροφορίες σχετικά με τη δυνατότητα μεταφοράς των μοντέλων αποδόμησης και θα τονίσουν τυχόν περιορισμούς στην ικανότητά τους να γενικεύουν σε διάφορα σύνολα δεδομένων.

5.3.1 Σετ δεδομένων REDD μοντέλα UKDALE και REDD


Παρακάτω είναι τα αποτελέσματα από την σύγκριση μεταξύ μοντέλων που εκπαιδεύτηκαν στο UKDALE και δοκιμάστηκαν στο σύνολο δεδομένων REDD, έναντι αυτών που εκπαιδεύτηκαν και δοκιμάστηκαν στο ίδιο το σύνολο δεδομένων REDD.

	Fridge		Microwave		Washing machine		Dish washer	
	UKDALE MODEL	REDD MODEL	UKDALE MODEL	REDD MODEL	UKDALE MODEL	REDD MODEL	UKDALE MODEL	REDD MODEL
Recall	0.704	0.9977	0.5734	0.9999	0.9999	0.8152	0.3713	0.9796
Precision	0.8366	0.8069	0.1326	0.7424	0.6757	0.6757	0.0953	0.7499
Accuracy	0.6503	0.8056	0.9289	0.7424	0.6757	0.6107	0.8385	0.7398
F1 Score	0.7646	0.8922	0.2154	0.8521	0.8065	0.7389	0.1517	0.8495
RMSE	82.56	77.92	138.63	118.86	285.19	335.32	145.12	130.16


Πίνακας 11: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset REDD




Σχήμα 59: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset REDD appliance fridge



Σχήμα 60: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset REDD appliance microwave



Σχήμα 61: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset REDD appliance washing machine



Σχήμα 62: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset REDD appliance dish washer

Για το ψυγείο, το μοντέλο που έχει εκπαιδευτεί στο UKDALE αποδίδει αρκετά καλά, επιτυγχάνοντας recall (0,704) σε σύγκριση με το σχεδόν τέλει (0,9977) του μοντέλου που έχει εκπαιδευτεί στο REDD. Αυτό δείχνει ότι το μοντέλο UKDALE χάνει περισσότερα συμβάντα ενεργοποίησης του ψυγείου. Ωστόσο, το μοντέλο UKDALE επιδεικνύει ελαφρώς καλύτερο precision (0,8366 έναντι 0,8069), που σημαίνει ότι παράγει λιγότερα ψευδώς θετικά αποτελέσματα. Όσον αφορά το accuracy, το μοντέλο που έχει εκπαιδευτεί στο REDD (0,8056) ξεπερνά σημαντικά το μοντέλο UKDALE (0,6503), αντικατοπτρίζοντας καλύτερη συνολική απόδοση. Το f1 score (0,8922 έναντι 0,7646) ευνοεί επίσης το μοντέλο REDD, υποδεικνύοντας καλύτερη ισορροπία μεταξύ recall και precision. Οι τιμές RMSE, (82,569) για μοντέλο UKDALE και (77,9235) για REDD, υποδηλώνουν ότι και τα δύο μοντέλα έχουν παρόμοια απόδοση όσον αφορά την πρόβλεψη της κατανάλωσης ενέργειας, με το μοντέλο REDD να έχει ένα μικρό πλεονέκτημα.

Για τον φούρνο μικροκυμάτων, το μοντέλο που έχει εκπαιδευτεί στο UKDALE δυσκολεύεται περισσότερο. Έχει recall (0,5734) σε σύγκριση με το σχεδόν τέλει (0,9999) του μοντέλου REDD, υποδεικνύοντας ότι χάνει πολλά συμβάντα μικροκυμάτων. Το precision του μοντέλου UKDALE είναι πολύ χαμηλό (0,1326) σε

σύγκριση με (0,7424) για το μοντέλο REDD, επισημαίνοντας σημαντικά ζητήματα με ψευδώς θετικά αποτελέσματα. Είναι ενδιαφέρον ότι το accuracy του μοντέλου UKDALE (0,9289) είναι υψηλότερο από αυτό του μοντέλου REDD (0,7424), πιθανότατα λόγω της πιο συντηρητικής προσέγγισής του. Ωστόσο, το f1 score για το μοντέλο UKDALE (0,2154) είναι πολύ χαμηλότερο από αυτό του μοντέλου REDD (0,8521), δείχνοντας ότι παρέχει πολύ καλύτερη ισορροπία. Το RMSE (138,6366 έναντι 118,865) για UKDALE και REDD αντίστοιχα, αντικατοπτρίζει τη δυσκολία του μοντέλου UKDALE να προβλέψει με ακρίβεια την κατανάλωση ενέργειας μικροκυμάτων.

Στην περίπτωση του πλυντηρίου ρούχων, το μοντέλο UKDALE έχει σχεδόν τέλει recall (0,9999), ξεπερνώντας σημαντικά το μοντέλο REDD (0,8152), που σημαίνει ότι προσδιορίζει σχεδόν όλα τα συμβάντα λειτουργίας του πλυντηρίου. Και τα δύο μοντέλα έχουν το ίδιο precision (0,6757), δείχνοντας ότι είναι εξίσου ικανά να ελαχιστοποιήσουν τα ψευδώς θετικά. Το μοντέλο UKDALE έχει ελαφρώς υψηλότερο accuracy (0,6757 έναντι 0,6107) και καλύτερο f1 score (0,8065 έναντι 0,7389), γεγονός που δείχνει ότι επιτυγχάνει καλύτερη ισορροπία μεταξύ recall και precision. Ωστόσο, το RMSE το μοντέλο UKDALE είναι χαμηλότερο (285,1994 έναντι 335,326), υποδηλώνοντας ότι είναι καλύτερο στην εκτίμηση της κατανάλωσης ενέργειας του πλυντηρίου ρούχων.

Τα αποτελέσματα του πλυντηρίου πιάτων δείχνουν ότι το μοντέλο που έχει εκπαιδευτεί στο UKDALE δυσκολεύεται αρκετά. Το recall του είναι πολύ χαμηλότερο (0,3713 έναντι 0,9796), που σημαίνει ότι χάνει πολλά συμβάντα χρήσης του πλυντηρίου πιάτων. Επιπλέον, το precision του μοντέλου UKDALE είναι αρκετά χαμηλό (0,0953 έναντι 0,7499), υποδηλώνοντας υψηλό ποσοστό ψευδώς θετικών. Παρά το γεγονός ότι έχει ελαφρώς καλύτερο accuracy ακρίβεια (0,8385 έναντι 0,7398), το χαμηλό f1 score του μοντέλου UKDALE (0,1517 έναντι 0,8495) υπογραμμίζει την κακή ισορροπία μεταξύ recall και precision. Οι τιμές RMSE (145,125 έναντι 130,1636) για UKDALE και REDD αντίστοιχα, υποδηλώνουν ότι το μοντέλο UKDALE δυσκολεύεται επίσης να προβλέψει με ακρίβεια την κατανάλωση ενέργειας στο πλυντήριο πιάτων.


Η σύγκριση δείχνει ότι τα μοντέλα που έχουν εκπαιδευτεί στο σύνολο δεδομένων REDD αποδίδουν σημαντικά καλύτερα κατά την αποδόμηση ηλεκτρικής ενέργειας όταν εφαρμόζονται στο ίδιο σύνολο δεδομένων. Για το ψυγείο, το φούρνο μικροκυμάτων και το πλυντήριο πιάτων, τα μοντέλα που έχουν εκπαιδευτεί στο REDD εμφανίζουν υψηλότερο recall, f1 score και precision, υποδηλώνοντας ότι είναι καλύτερα κατάλληλα για τον εντοπισμό συμβάντων ενεργοποίησης της συσκευής και την εξισορρόπηση του recall και precision. Ωστόσο, τα μοντέλα που έχουν εκπαιδευτεί στο UKDALE παρουσιάζουν καλύτερη απόδοση εκτίμησης ενέργειας (χαμηλότερο RMSE) για ορισμένες συσκευές όπως το πλυντήριο ρούχων, αντιστακώνοντας τη δύναμή τους στην πρόβλεψη κατανάλωσης ενέργειας. Τα μοντέλα που έχουν εκπαιδευτεί στο UKDALE έχουν σχετικά καλή απόδοση για το ψυγείο και το πλυντήριο ρούχων, αλλά δυσκολεύονται αρκετά με το φούρνο μικροκυμάτων και το πλυντήριο πιάτων, όπου τα μοντέλα που έχουν εκπαιδευτεί στο REDD υπερέχουν. Αυτά τα αποτελέσματα επισημαίνουν τη δυσκολία μεταφοράς μοντέλων μεταξύ συνόλων δεδομένων.

5.3.2 Σετ δεδομένων UKDALE μοντέλα UKDALE και REDD


Παρακάτω είναι τα αποτελέσματα από την σύγκριση μεταξύ μοντέλων που εκπαιδεύτηκαν στο REDD και δοκιμάστηκαν στο σύνολο δεδομένων UKDALE, έναντι αυτών που εκπαιδεύτηκαν και δοκιμάστηκαν στο ίδιο το σύνολο δεδομένων UKDALE.

	Fridge		Microwave		Washing machine		Dish washer	
	REDD MODEL	UKDALE MODEL	REDD MODEL	UKDALE MODEL	REDD MODEL	UKDALE MODEL	REDD MODEL	UKDALE MODEL
Recall	0.998	0.7198	0.9999	0.49	0.8161	0.9999	0.9793	0.9328
Precision	0.9113	0.9384	0.8506	0.0556	0.8544	0.8544	0.8524	0.0766
Accuracy	0.9097	0.7016	0.8506	0.9475	0.7241	0.8544	0.8378	0.7262
F1 Score	0.9527	0.8147	0.9192	0.0998	0.8348	0.9214	0.9114	0.1416
RMSE	57.45	44.10	145.20	86.16	163.42	150.97	239.67	226.04


Πίνακας 12: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset UKDALE




Σχήμα 63: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset UKDALE appliance fridge



Σχήμα 64: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset UKDALE appliance microwave



Σχήμα 65: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset UKDALE appliance washing machine



Σχήμα 66: Σύγκριση μοντέλων DAE εκπαιδευμένων σε dataset UKDALE, REDD στο dataset UKDALE appliance dish washer

Για το ψυγείο, το μοντέλο που εκπαιδεύεται στο REDD αποδίδει σημαντικά καλύτερα όσον αφορά το recall (0,998 έναντι 0,7198), που σημαίνει ότι καταγράφει περισσότερα συμβάντα χρήσης του ψυγείου σε σύγκριση με το μοντέλο που έχει εκπαιδευτεί στο

UKDALE. Ωστόσο, το μοντέλο UKDALE δείχνει ελαφρώς καλύτερο precision (0,9384 έναντι 0,9113), γεγονός που δείχνει ότι κάνει λιγότερα ψευδώς θετικά αποτελέσματα. Όσον αφορά τη συνολική απόδοση, το μοντέλο REDD επιτυγχάνει υψηλότερο accuracy (0,9097 έναντι 0,7016) και f1 score (0,9527 έναντι 0,8147), δείχνοντας καλύτερη ισορροπία μεταξύ recall και precision. Είναι ενδιαφέρον ότι το RMSE αποκαλύπτει ότι το μοντέλο UKDALE (44.1072) ξεπερνά ελαφρώς το μοντέλο REDD (57.4523) όσον αφορά την πρόβλεψη κατανάλωσης ενέργειας, υποδηλώνοντας μια ισχυρότερη ικανότητα εκτίμησης της χρήσης ενέργειας του ψυγείου, παρόλο που το μοντέλο REDD εντοπίζει περισσότερα συμβάντα.

Τα αποτελέσματα αποδόμησης ενέργειας του φούρνου μικροκυμάτων δείχνουν μια έντονη αντίθεση ανάμεσα στα μοντέλα. Το μοντέλο REDD εμφανίζει σχεδόν τέλειο recall (0,9999) σε σύγκριση με την πολύ χαμηλότερο recall του μοντέλου UKDALE (0,49), που σημαίνει ότι το μοντέλο REDD προσδιορίζει σχεδόν όλα τα συμβάντα ενεργοποίησης μικροκυμάτων. Το precision για το μοντέλο REDD είναι επίσης πολύ υψηλότερο (0,8506 έναντι 0,0556), υποδεικνύοντας ότι το μοντέλο UKDALE παλεύει με σημαντικό αριθμό ψευδώς θετικών. Παρόλα αυτά, το μοντέλο UKDALE επιτυγχάνει υψηλότερο accuracy (0,9475 έναντι 0,8506), το οποίο πιθανότατα οφείλεται στις συντηρητικές προβλέψεις του, αλλά το f1 score (0,0998) είναι πολύ χαμηλότερο από αυτό του μοντέλου REDD (0,9192), δείχνοντας ότι το μοντέλο REDD έχει καλύτερη ισορροπία recall και precision. Το RMSE δείχνει ότι το μοντέλο UKDALE (86.161) αποδίδει καλύτερα στην εκτίμηση της ενέργειας σε σύγκριση με το εκπαιδευμένο μοντέλο REDD (145.2094), παρά το ότι δυσκολεύεται με την αναγνώριση συμβάντων.

Για το πλυντήριο ρούχων, το μοντέλο UKDALE έχει εξαιρετικά καλή απόδοση στο recall (0,9999), ανιχνεύοντας σχεδόν κάθε συμβάν λειτουργίας του πλυντηρίου σε σύγκριση με το μοντέλο REDD (0,8161). Και τα δύο μοντέλα, ωστόσο, επιτυγχάνουν το ίδιο precision (0,8544), που σημαίνει ότι είναι εξίσου καλά στην αποφυγή ψευδών θετικών. Το μοντέλο UKDALE ξεπερνά ελαφρώς το μοντέλο REDD όσον αφορά το accuracy (0,8544 έναντι 0,7241) και το f1 score (0,9214 έναντι 0,8348), υποδεικνύοντας συνολικά καλύτερη απόδοση στον εντοπισμό και την εξισορρόπηση της αναγνώρισης συμβάντων ενεργοποίησης. Όσον αφορά το RMSE, το μοντέλο UKDALE (150,9796) υπερτερεί του μοντέλου REDD (163,4236), υποδηλώνοντας καλύτερη πρόβλεψη κατανάλωσης ενέργειας για αυτήν τη συσκευή.

Τα αποτελέσματα του πλυντηρίου πιάτων δείχνουν ότι το μοντέλο REDD υπερτερεί του μοντέλου UKDALE σε όλες σχεδόν τις μετρήσεις. Το μοντέλο REDD επιτυγχάνει υψηλότερο recall (0,9793 έναντι 0,9328), που σημαίνει ότι καταγράφει περισσότερα συμβάντα χρήσης του πλυντηρίου πιάτων και σημαντικά υψηλότερο precision (0,8524 έναντι 0,0766), υποδεικνύοντας ότι το μοντέλο UKDALE δημιουργεί πολλά ψευδώς θετικά αποτελέσματα. Αυτό οδηγεί σε πολύ καλύτερο f1 score για το μοντέλο REDD (0,9114 έναντι 0,1416) και υψηλότερο accuracy (0,8378 έναντι 0,7262). Όσον αφορά το RMSE, το μοντέλο UKDALE (226.049) ξεπερνά ελαφρώς το μοντέλο REDD (239.678), υποδεικνύοντας καλύτερη πρόβλεψη ενέργειας, αν και η συνολική απόδοση εξακολουθεί να είναι σαφώς υπέρ του μοντέλου που εκπαιδεύεται σε REDD.

Τα αποτελέσματα δείχνουν ότι τα μοντέλα που έχουν εκπαιδευτεί στα δεδομένα REDD γενικά αποδίδουν καλύτερα όταν αναλύουν τα δεδομένα UKDALE, ιδιαίτερα για το ψυγείο, το φούρνο μικροκυμάτων και το πλυντήριο πιάτων. Τείνουν να επιτυγχάνουν υψηλότερο recall, f1 score και accuracy, γεγονός που τονίζει την ικανότητά τους να

γενικεύουν μεταξύ των συνόλων δεδομένων. Ωστόσο, τα μοντέλα που έχουν εκπαιδευτεί στο UKDALE εμφανίζουν καλύτερη εκτίμηση ενέργειας (χαμηλότερο RMSE) σε αρκετές περιπτώσεις, ιδιαίτερα για το ψυγείο και το πλυντήριο ρούχων, υποδηλώνοντας ότι μπορεί να καταγράφουν τα πρότυπα χρήσης ενέργειας πιο αποτελεσματικά, παρά τη χαμηλότερη ανίχνευση συμβάντων. Αυτά τα αποτελέσματα επισημαίνουν τις προκλήσεις της μεταφοράς μοντέλων μεταξύ συνόλων δεδομένων με διαφορετικά μοτίβα χρήσης συσκευών και δείχνουν ότι υπάρχει δυνατότητα εξέλιξης των μοντέλων για τη βελτίωση τόσο της γενίκευσης όσο και της ακριβούς αποδόμησης ενέργειας μεταξύ των συνόλων δεδομένων.

Κεφάλαιο 6. Επίλογος

6.1 Συμπεράσματα

Σε αυτή τη διπλωματική εργασία είχαμε δύο στόχους. Πρώτον, να συγκρίνουμε την ικανότητα των Denoising Autoencoders (DAE) να πραγματοποιήσουν αποδόμηση ενέργειας έναντι δύο παραδοσιακών αλγορίθμων, του Combinatorial Optimization (CO) και των Factorial Hidden Markov Models (FHMM) και δεύτερον, να ελέγξουμε την ικανότητα γενίκευσης των DAE αξιολογώντας την απόδοσή τους σε διαφορετικό σύνολο δεδομένων από εκείνο στο οποίο εκπαιδεύτηκαν. Αυτά τα πειράματα διεξήχθησαν χρησιμοποιώντας το πλαίσιο NILMTK, το οποίο παρείχε μια τυποποιημένη πλατφόρμα για τις αξιολογήσεις μας σε δύο γνωστά σύνολα δεδομένων, το REDD και το UKDALE.

Όσον αφορά τον πρώτο στόχο, τα αποτελέσματά μας έδειξαν ότι τα DAE υπερείχαν σταθερά τόσο το CO όσο και το FHMM στην κατανομή της κατανάλωσης ενέργειας για όλες τις συσκευές που δοκιμάσαμε και στα δύο σύνολα δεδομένων. Για τις τέσσερις συσκευές που εξετάστηκαν (ψυγείο, φούρνος μικροκυμάτων, πλυντήριο ρούχων και πλυντήριο πιάτων), τα DAE πέτυχαν υψηλότερες βαθμολογίες precision, recall, accuracy, f1 score σε σύγκριση με το CO και το FHMM. Αυτή η ανώτερη απόδοση ήταν συνεπής και στα δύο σύνολα δεδομένων, καθιστώντας τα DAE το μοντέλο με την καλύτερη απόδοση σε όλες τις δοκιμασμένες περιπτώσεις. Τα DAE ξεχώρισαν ιδιαίτερα στον διαχωρισμό συσκευών με πιο σύνθετα και απρόβλεπτα μοτίβα κατανάλωσης, όπως τα μικροκύματα και τα πλυντήρια πιάτων, όπου το CO και το FHMM δυσκολευτήκαν να δώσουν ακριβή αποτελέσματα. Για πιο απλές συσκευές όπως τα ψυγεία, ενώ τα CO και FHMM απέδωσαν ικανοποιητικά, οι DAE πέτυχαν ακόμη καλύτερα αποτελέσματα. Αυτό τονίζει την ικανότητα των DAE να αναγνωρίζουν τόσο απλά όσο και σύνθετα μοτίβα κατανάλωσης των συσκευών, καθιστώντας τα μια ιδανική λύση για εργασίες αποδόμησης ενέργειας. Η σταθερή υπεροχή των DAE σε όλες τις συσκευές και τα σύνολα δεδομένων υπογραμμίζει το πλεονέκτημά τους έναντι των παραδοσιακών αλγορίθμων όσον αφορά την εκμάθηση και τη μοντελοποίηση ενεργειακών προτύπων σε επίπεδο συσκευής.

Για τον δεύτερο στόχο μας, προσπαθήσαμε να αξιολογήσουμε την ικανότητα γενίκευσης των DAE εκπαιδεύοντάς τα σε ένα σύνολο δεδομένων και στη συνέχεια δοκιμάζοντάς τα σε διαφορετικό σύνολο δεδομένων. Αυτή η αξιολόγηση μεταξύ συνόλων δεδομένων ήταν καθοριστική για την κατανόηση του πόσο καλά οι DAE μπορούσαν να προσαρμοστούν σε νέες συνθήκες και μοτίβα χρήσης συσκευών, καθώς οι πραγματικές εφαρμογές του NILM συχνά απαιτούν τα μοντέλα να χειρίζονται δεδομένα που είναι διαφορετικά από αυτά στα οποία είχαν αρχικά εκπαιδευτεί. Όταν τα DAE εκπαιδεύτηκαν και δοκιμάστηκαν στο ίδιο σύνολο δεδομένων, παρουσίασαν άριστες επιδόσεις στην αποδόμηση ενέργειας σε επίπεδο συσκευής, επιτυγχάνοντας υψηλό precision, recall, accuracy, f1 score στις περισσότερες συσκευές. Ωστόσο, όταν τα DAE εκπαιδεύτηκαν σε ένα σύνολο δεδομένων και δοκιμάστηκαν σε άλλο, η απόδοσή τους μειώθηκε. Ένας από τους πιθανούς λόγους αυτής της πτώσης στην απόδοση είναι οι διαφορές μεταξύ των συνόλων δεδομένων. Σύνολα δεδομένων όπως το REDD και το UKDALE, ενώ και τα δύο χρησιμοποιούνται ευρέως στην έρευνα NILM, αντιπροσωπεύουν διαφορετικά οικιακά περιβάλλοντα, συμπεριφορές χρήσης συσκευών και συνθήκες συλλογής δεδομένων. Για παράδειγμα, οι παραλλαγές στις ενεργειακές συνήθειες του νοικοκυριού, οι ρυθμίσεις αισθητήρων και η παρουσία

επικαλυπτόμενου θορύβου από άλλες συσκευές μπορούν όλα να επηρεάσουν το πόσο καλά μπορεί να αποδώσει ένα μοντέλο που έχει εκπαιδευτεί σε ένα σύνολο δεδομένων όταν εφαρμόζεται σε άλλο. Αυτές οι μικρές αλλά σημαντικές διαφορές δυσκόλεψαν τα DAE να διατηρήσουν το ίδιο επίπεδο απόδοσης στα σύνολα δεδομένων, αναδεικνύοντας την πρόκληση της εφαρμογής εποπτευόμενων μοντέλων μάθησης όπως τα DAE σε πιο γενικευμένες εφαρμογές NILM.

Συνοψίζοντας, τα πειράματά μας έδειξαν ότι τα DAE ήταν ανώτερα από το CO και το FHMM για την κατανομή της κατανάλωσης ενέργειας σε όλες τις συσκευές και τα σύνολα δεδομένων που δοκιμάστηκαν. Η ικανότητα των DAE να μοντελοποιούν απλά και σύνθετα μοτίβα χρήσης συσκευών τους έκανε την καλύτερη επιλογή για εργασίες NILM. Ωστόσο, οι DAE εμφάνισαν περιορισμούς στη γενίκευση σε νέα σύνολα δεδομένων, υποδεικνύοντας την ανάγκη για περαιτέρω εργασία για τη βελτίωση της απόδοσής τους μεταξύ συνόλων δεδομένων.

6.2 Μελλοντικές προεκτάσεις

Αν και τα πειράματά μας παρείχαν πολύτιμες πληροφορίες για την απόδοση των DAE για την ενεργειακή αποδόμηση, τόνισαν επίσης αρκετούς τομείς για μελλοντική έρευνα. Σε αυτή την ενότητα, περιγράφουμε ορισμένες υποσχόμενες κατευθύνσεις για περαιτέρω εξερεύνηση, εστιάζοντας στη βελτίωση της γενίκευσης του μοντέλου και στην επέκταση της εφαρμογής της τεχνολογίας NILM.

1. **Γενίκευση σε όλα τα σύνολα δεδομένων.** Ένα από τα πιο κρίσιμα ζητήματα που εμφανίζονται σε αυτή τη εργασία είναι η αδυναμία των DAE να γενικεύουν αποτελεσματικά μεταξύ των συνόλων δεδομένων. Η μελλοντική έρευνα θα μπορούσε να διερευνήσει διάφορες τεχνικές για την αντιμετώπιση αυτού του περιορισμού. Για παράδειγμα, με την χρήση μεταφοράς μάθησης, όπου ένα μοντέλο που εκπαιδεύεται σε ένα σύνολο δεδομένων μπορεί να επανεκπαιδευτεί εν μέρει σε ένα άλλο, διατηρώντας έτσι χρήσιμες γνώσεις από την αρχική εκπαίδευση ενώ προσαρμόζεται στα νέα δεδομένα. Επιπλέον, η δημιουργία πιο ολοκληρωμένων και διαφορετικών συνόλων δεδομένων NILM θα μπορούσε να βελτιώσει τη γενίκευση του μοντέλου. Τα σύνολα δεδομένων που καλύπτουν ένα ευρύ φάσμα νοικοκυριών, συσκευών και γεωγραφικών τοποθεσιών θα μπορούσαν να παρέχουν τη μεταβλητότητα που απαιτείται για την εκπαίδευση μοντέλων που αποδίδουν καλά σε πραγματικά σενάρια.
2. **Ενσωμάτωση προηγμένων νευρωνικών αρχιτεκτονικών.** Ενώ τα DAE έχουν επιδείξει σταθερή απόδοση σε εργασίες NILM, η μελλοντική έρευνα θα μπορούσε να εξερευνήσει πιο προηγμένες αρχιτεκτονικές βαθιάς μάθησης όπως τα Συνελικτικά Νευρωνικά Δίκτυα (CNN) και τα δίκτυα Μακροπρόθεσμης Βραχυπρόθεσμης Μνήμης (LSTM). Αυτές οι αρχιτεκτονικές έχουν αποδειχθεί ότι καταγράφουν χρονικά και χωρικά μοτίβα πιο αποτελεσματικά από τα DAE, γεγονός που μπορεί να οδηγήσει σε καλύτερη απόδοση αποδόμησης. Τα υβριδικά μοντέλα που συνδυάζουν τα πλεονεκτήματα των DAE, CNN και LSTM θα μπορούσαν επίσης να διερευνηθούν για να αξιοποιήσουν τα πλεονεκτήματα κάθε αρχιτεκτονικής.

3. **Ανάλυση ενέργειας σε πραγματικό χρόνο.** Μια σημαντική πρόκληση στην έρευνα NILM είναι η ανάπτυξη μοντέλων που μπορούν να λειτουργούν σε πραγματικό χρόνο. Τα περισσότερα υπάρχοντα μοντέλα, συμπεριλαμβανομένων των DAE που χρησιμοποιούνται σε αυτή την εργασία, απαιτούν επεξεργασία δεδομένων εκτός σύνδεσης. Ωστόσο, η αποδόμηση ενέργειας σε πραγματικό χρόνο θα παρείχε άμεση ανατροφοδότηση στους χρήστες, επιτρέποντάς τους να λαμβάνουν πιο ενημερωμένες αποφάσεις σχετικά με τη χρήση της ενέργειας τους. Μελλοντικές εργασίες θα μπορούσαν να διερευνήσουν τεχνικές για τη βελτιστοποίηση της υπολογιστικής απόδοσης των μοντέλων DAE ή να αναπτύξουν ελαφριά μοντέλα ικανά να λειτουργούν σε συσκευές αιχμής, όπως έξυπνους μετρητές ή συστήματα διαχείρισης ενέργειας στο σπίτι.
4. **Εφαρμογές σε έξυπνα δίκτυα και απόκριση ζήτησης.** Καθώς τα ενεργειακά συστήματα κινούνται προς πιο έξυπνες, πιο αποκεντρωμένες αρχιτεκτονικές, ο ρόλος του NILM θα γίνεται ολοένα και πιο σημαντικός στα έξυπνα δίκτυα και στα προγράμματα απόκρισης ζήτησης. Το NILM μπορεί να παρέχει στους παρόχους ενέργειας και στους καταναλωτές λεπτομερείς πληροφορίες σχετικά με τα πρότυπα χρήσης ενέργειας, επιτρέποντας πιο αποτελεσματική διαχείριση ενέργειας και μειώνοντας τη συνολική κατανάλωση. Μελλοντική έρευνα θα μπορούσε να διερευνήσει πώς το NILM μπορεί να ενσωματωθεί με τεχνολογίες έξυπνων δικτύων για την παροχή δεδομένων σε πραγματικό χρόνο για απόκριση ζήτησης, πρόβλεψη φορτίου και δυναμική τιμολόγηση. Επιπλέον, η ενοποίηση του NILM με ανανεώσιμες πηγές ενέργειας και συστήματα αποθήκευσης μπαταριών θα μπορούσε να βοηθήσει στη βελτιστοποίηση της χρήσης ανανεώσιμων πηγών ενέργειας και στη μείωση της εξάρτησης από την ηλεκτρική ενέργεια του δικτύου κατά τις ώρες αιχμής. Αυτό θα μπορούσε να έχει σημαντικά περιβαλλοντικά και οικονομικά οφέλη, ειδικά καθώς ο κόσμος κινείται προς ένα πιο βιώσιμο ενεργειακό μέλλον.
5. **Θέματα απορρήτου και ασφάλειας.** Καθώς η τεχνολογία NILM γίνεται πιο διαδεδομένη, θα πρέπει να αντιμετωπιστούν οι ανησυχίες σχετικά με το απόρρητο και την ασφάλεια. Η δυνατότητα αποδόμησης δεδομένων ενεργειακής κατανάλωσης σε επίπεδο συσκευής αναδεικνύει πιθανά ζητήματα απορρήτου, καθώς λεπτομερή πρότυπα χρήσης ενέργειας θα μπορούσαν να αποκαλύψουν ευαίσθητες πληροφορίες σχετικά με τις οικιακές δραστηριότητες. Η μελλοντική έρευνα θα πρέπει να διερευνήσει τεχνικές για την ανωνυμοποίηση ή την κρυπτογράφηση ενεργειακών δεδομένων, ενώ θα εξακολουθεί να επιτρέπει την ακριβή αποδόμηση. Αυτό θα μπορούσε να περιλαμβάνει την ανάπτυξη αλγορίθμων διατήρησης του απορρήτου ή τη χρήση τεχνικών federated learning, όπου τα μοντέλα εκπαιδεύονται τοπικά σε συσκευές χρηστών χωρίς να μοιράζονται ακατέργαστα δεδομένα με εξωτερικούς χρήστες.
6. **Επέκταση της κάλυψης συσκευών και περιπτώσεις χρήσης.** Ενώ πολλές μελέτες επικεντρώνονται σε ένα βασικό σύνολο κοινών συσκευών, οι μελλοντικές εργασίες θα πρέπει να διευρύνουν το φάσμα των συσκευών που καλύπτονται από μοντέλα αποδόμησης συμπεριλαμβανομένων πιο εξειδικευμένων ή βιομηχανικών συσκευών. Αυτό θα μπορούσε να ανοίξει νέες περιπτώσεις χρήσης για το NILM, όπως η παρακολούθηση της κατανάλωσης

ενέργειας σε εργοστάσια, γραφεία ή δημόσια κτίρια. Επιπλέον, το NILM θα μπορούσε να εφαρμοστεί σε αναδυόμενους τομείς όπως η φόρτιση ηλεκτρικών οχημάτων, επιτρέποντας πιο λεπτομερή παρακολούθηση και διαχείριση της χρήσης ενέργειας σε βιώσιμα συστήματα μεταφορών.

Τα πειράματα που παρουσιάζονται σε αυτή την εργασία αναδεικνύουν τη δυνατότητα των DAE για διάσπαση ενέργειας. Ωστόσο, εξακολουθούν να υπάρχουν αρκετές προκλήσεις, ιδιαίτερα όσον αφορά τη γενίκευση του μοντέλου σε διαφορετικά σύνολα δεδομένων. Αντιμετωπίζοντας αυτές τις προκλήσεις και εξερευνώντας μελλοντικές κατευθύνσεις όπως προηγμένες νευρωνικές αρχιτεκτονικές, διαχωρισμός σε πραγματικό χρόνο και ενοποίηση με τεχνολογίες έξυπνων δικτύων, μπορούμε να συνεχίσουμε να βελτιώνουμε τις μεθόδους NILM και να επεκτείνουμε τις εφαρμογές τους στον ενεργειακό τομέα. Με συνεχή έρευνα και ανάπτυξη, το NILM έχει τη δυνατότητα να διαδραματίσει βασικό ρόλο στην προώθηση της ενεργειακής απόδοσης και της βιωσιμότητας στο μέλλον.

Βιβλιογραφία

- [1] G. W. Hart, "Nonintrusive appliance load monitoring," *Proceedings of the IEEE*, vol. 80, no. 12, p. 1870–1891, 1992.
- [2] United Nations, "68% of the World Population Projected to Live in Urban Areas by 2050, Says UN," United Nations Department of Economic and Social Affairs, 16 May 2018. [Online]. Available: <https://www.un.org/development/desa/en/news/population/2018-revision-of-world-urbanization-prospects.html>. [Accessed 27 October 2024].
- [3] "Executive summary – Empowering Urban Energy Transitions – Analysis," IEA, [Online]. Available: <https://www.iea.org/reports/empowering-urban-energy-transitions/executive-summary>. [Accessed 27 October 2024].
- [4] "Total electricity generation projections," Enerdata, [Online]. Available: <https://eneroutlook.enerdata.net/total-electricity-generation-projections.html>. [Accessed 27 October 2024].
- [5] C. C. de Oliveira, I. M. I. C. Vaz και E. Ghisi, «Retrofit strategies to improve energy efficiency in buildings: An integrative review,» *Energy and Buildings*, τόμ. 321, p. 114624, 2024.
- [6] M. K. Nematchoua, M. Sadeghi και S. Reiter, «Strategies and scenarios to reduce energy consumption and CO2 emission in the urban, rural and sustainable neighbourhoods,» *Sustainable Cities and Society*, τόμ. 72, p. 103053, 2021.
- [7] A. Colmenar-Santos, L. Noemí, D. Borge-Diez και M. Castro-Gil, «Solutions to reduce energy consumption in the management of large buildings},,» *Energy and Buildings*, τόμ. 56, pp. 66-77, 2013.
- [8] G. Kormpakis, A. Lekidis, E. Sarma, I. Papias, F. Serepas, G. Stravodimos και V. Marinakis, «Home Energy Management Systems: Challenges, Heterogeneity & Integration Architecture Towards A Smart City Ecosystem,» *2024 IEEE International Conference on Engineering, Technology, and Innovation (ICE/ITMC)*, pp. 1-10, 2024 .
- [9] A. Zoha, A. Gluhak, M. A. Imran και S. Rajasegarar, «Non-Intrusive Load Monitoring Approaches for Disaggregated Energy Sensing: A Survey,» *Sensors*, τόμ. 12, pp. 16838--16866, 2012.
- [10] S. B. Leeb, S. R. Shaw και J. L. Kirtley, «Transient Event Detection in Spectral Envelope Estimates for Nonintrusive Load Monitoring,» *IEEE Transactions on Power Delivery*, τόμ. 10, pp. 1200--1208, 1995.
- [11] X. Wang, J. Wang, D. Shi and M. E. Khodayar, "A Factorial Hidden Markov Model for Energy Disaggregation based on Human Behavior Analysis," *2018 IEEE Power & Energy Society General Meeting (PESGM)*, pp. 1-5, 2018.

- [12] L. Mauch και B. Yang, «A new approach for supervised power disaggregation by using a deep recurrent LSTM network,» σε *2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, 2015, pp. 63-67.
- [13] M. Kaselimi, N. Doulamis, A. Voulodimos, E. Protopapadakis και A. Doulamis, «Context Aware Energy Disaggregation Using Adaptive Bidirectional LSTM Models,» *IEEE Transactions on Smart Grid*, τόμ. 11, pp. 3054-3067, 2020.
- [14] K. C. Armel, A. Gupta, G. Shrimali and A. Albert, "Is disaggregation the holy grail of energy efficiency? The case of electricity," *Energy Policy*, vol. 52, pp. 213-234, 2013.
- [15] c. a. o. Demand side management through load shifting in IoT based HEMS: Overview, S. Sharda, M. Singh και K. Sharma, «Demand side management through load shifting in IoT based HEMS: Overview, challenges and opportunities,» *Sustainable Cities and Society*, τόμ. 65, p. 102517, 2021.
- [16] I. Papias, V. Michalakopoulos, E. Sarma και V. Marinakis, «Aggregated Flexibility Dynamic Forecasting of Residential Energy Prosumers for DR Programs,» *2024 15th International Conference on Information, Intelligence, Systems & Applications (IISA)*, pp. 1-9, 2024.
- [17] B. Korte and J. Vygen, *Combinatorial Optimization : Theory and Algorithms*, Berlin, 2018.
- [18] T. H. Cormen, C. E. Leiserson, R. L. Rivest and C. Stein, *Introduction to Algorithms*, Cambridge, Massachusetts: The MIT Press, 2009.
- [19] Z. Ghahramani and M. I. Jordan , "Factorial Hidden Markov Models," *Machine Learning*, vol. 29, no. 2, p. 245–273, 1997.
- [20] «Approximate Inference in Additive Factorial HMMs with Application to Energy Disaggregation,» σε *Proceedings of the Fifteenth International Conference on Artificial Intelligence and Statistics*, La Palma, Canary Islands, PMLR, 2012, pp. 1472-1482.
- [21] H. Kim, M. Marwah, M. Arlitt, G. Lyon και J. Han, «Unsupervised Disaggregation of Low Frequency Power Measurements,» σε *Proceedings of the 2011 SIAM International Conference on Data Mining (SDM)*, 2011, pp. 747-758.
- [22] E. Alpaydin, *Introduction to Machine Learning*, S.L.: Mit Press, 2020.
- [23] V. Rawatt, "Medium," 2020. [Online]. Available: <https://medium.com/@vaani.rawatt/introduction-to-machine-learning-a5ddc31ce404>. [Accessed 27 October 2024].
- [24] J. D. Kelleher, B. M. Namee and A. D'arcy, *Fundamentals of machine learning for predictive data analytics : algorithms, worked examples, and case studies*, Cambridge, Massachusetts: The Mit Press, 2015.
- [25] M. Mohri, A. Rostamizadeh and A. Talwalkar, *Foundations of machine learning*, Cambridge, Massachusetts: Mit Press, 2012.

- [26] "Wikimedia," 2013. [Online]. Available: https://commons.wikimedia.org/wiki/File:Neuron_el.svg. [Accessed 27 October 2024].
- [27] Daniel, "Deep Learning: All about this concept," 2021. [Online]. Available: <https://datascientest.com/en/all-about-deep-learning>. [Accessed 27 October 2024].
- [28] A. Navalni, "Multi-Layer Perceptron Neural Network using Python - Machine Learning Geek," [Online]. Available: <https://machinelearninggeek.com/multi-layer-perceptron-neural-network-using-python/>. [Accessed 27 October 2024].
- [29] M. Ali, "Introduction to Activation Functions in Neural Networks," Datacamp, 2023. [Online]. Available: <https://www.datacamp.com/tutorial/introduction-to-activation-functions-in-neural-networks>. [Accessed 27 October 2024].
- [30] S. Gupta, "The 7 Most Common Machine Learning Loss Functions," builtin, [Online]. Available: <https://builtin.com/machine-learning/common-loss-functions>. [Accessed 27 October 2024].
- [31] V. Pascal, L. Hugo, I. Lajoie, Y. Bengio and P. A. Manzagol, "Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion," *Journal of Machine Learning Research*, vol. 11, pp. 3371 - 3408, 2010.
- [32] S. Park, M. S. Gil, H. Im and Y. S. Moon, "Measurement Noise Recommendation for Efficient Kalman Filtering over a Large Amount of Sensor Data," *Sensors*, vol. 19, no. 5, p. 1168, 2019.
- [33] O. Pramod, "Autoencoders Explained," Medium, 2024. [Online]. Available: <https://medium.com/@ompramod9921/autoencoders-explained-9196c38af6f6>. [Accessed 27 October 2024].
- [34] R. Bonfigli, A. Felicetti, E. Principi, M. Fagiani, S. Squartini και F. Piazza, «Denoising Autoencoders for Non-Intrusive Load Monitoring: Improvements and Comparative Evaluation,» *Energy and Buildings*, τόμ. 158, pp. 1461-1474, 2017.
- [35] J. Kelly, *UK Domestic Appliance Level Electricity(UK-DALE-2017)-Disaggregated appliance/whole house power [Data set]*, 2017.
- [36] J. Z. Kolter and M. J. Johnson, "REDD: A Public Data Set for Energy Disaggregation Research," *Workshop on Data Mining Applications in Sustainability (SIGKDD)*, vol. 25, p. 59–62, 2011.
- [37] F. Serepas, I. Papias, N. Bellos και V. Marinakis, «A Comprehensive Approach to Real-Time and Batch Processing for Energy-Efficient IoT Homes: Leveraging Lambda Architecture and Data Lakes,» *2024 15th International Conference on Information, Intelligence, Systems & Applications (IISA)*,,, pp. 1-6, 2024.
- [38] J. Kelly and W. Knottenbelt, "Neural NILM: Deep Neural Networks Applied to Energy Disaggregation," *Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments*, pp. 55 - 64, 2015.

- [39] N. Batra, J. Kelly, O. Parson, H. Dutta, W. Knottenbelt, A. Rogers, A. Singh και M. Srivastava, «NILMTK: an open source toolkit for non-intrusive load monitoring,» *Proceedings of the 5th international conference on Future energy systems*, pp. 265-276, 2014.