



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΗΣ ΙΣΧΥΟΣ

**ΠΟΣΟΤΙΚΟΠΟΙΗΣΗ ΤΗΣ ΕΥΕΛΙΞΙΑΣ ΦΟΡΕΩΝ
ΣΩΡΕΥΤΙΚΗΣ ΕΚΠΡΟΣΩΠΗΣΗΣ ΟΙΚΙΑΚΩΝ
ΦΟΡΤΙΩΝ**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Κωνσταντίνος Ε. Κωτσάκος

Επιβλέπων : Παύλος Σ. Γεωργιλάκης, Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2024



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΗΣ ΙΣΧΥΟΣ

ΠΟΣΟΤΙΚΟΠΟΙΗΣΗ ΤΗΣ ΕΥΕΛΙΞΙΑΣ ΦΟΡΕΩΝ ΣΩΡΕΥΤΙΚΗΣ ΕΚΠΡΟΣΩΠΗΣΗΣ ΟΙΚΙΑΚΩΝ ΦΟΡΤΙΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Κωνσταντίνος Ε. Κωτσάκος

Επιβλέπων: Παύλος Σ. Γεωργιλάκης, Καθηγητής Ε.Μ.Π

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 24 Οκτωβρίου 2024

.....
Παύλος Γεωργιλάκης
Καθηγητής Ε.Μ.Π.

.....
Αντώνιος Παπαβασιλείου
Επικ. Καθηγητής Ε.Μ.Π.

.....
Άρης Ευάγγελος Δημέας
Επικ.Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2024

.....

Κωνσταντίνος Ε. Κωτσάκος

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

Copyright © Κωνσταντίνος Κωτσάκος, 2024.

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.

ΠΕΡΙΛΗΨΗ

Σκοπός της παρούσας διπλωματικής εργασίας είναι η ποσοτικοποίηση της ευελιξίας αθροιστικού φορτίου οικιακών συσκευών από ένα Φορέα Σωρευτικής Εκπροσώπησης (ΦοΣΕ). Δεδομένης της προσέγγισης της ευελιξίας ως τη δυνατότητα μεταβολής και μετατόπισης του φορτίου από ένα «τυπικό» προφίλ βάσης, η παρούσα εργασία χωρίζεται σε δύο διακριτά μέρη: α) την πρόβλεψη ενός προφίλ βάσης του αθροιστικού οικιακού φορτίου και β) την εκτίμηση ενός βέλτιστου πλάνου ενεργειακής διαχείρισης βάσει οικονομικών κινήτρων (τιμολογιακά σχήματα παροχής ηλεκτρικής ενέργειας). Η διαφορά μεταξύ της προβλεπόμενης και της οικονομικά συμφέρουσας (βέλτιστης) κατανάλωσης ορίζεται ως η μέγιστη ευελιξία που είναι σε θέση να προσφέρει ο ΦοΣΕ σε ημερήσιο ορίζοντα, θεωρώντας πλήρη συμμόρφωση των καταναλωτών στα οικονομικά κίνητρα που τους παρέχονται (π.χ. φθηνή ενέργεια κατά τις βραδινές ώρες).

Η πρόβλεψη του αθροιστικού οικιακού φορτίου γίνεται σε βραχυχρόνιο ορίζοντα 15 λεπτών με χρήση LSTM δικτύων μηχανικής μάθησης. Ο υπολογισμός του βέλτιστου πλάνου κατανάλωσης γίνεται σε προημερήσιο επίπεδο και για ωριαίο ορίζοντα με χρήση μαθηματικού προγραμματισμού, έχοντας ως αντικειμενική συνάρτηση την ελαχιστοποίηση του ημερήσιου κόστους ηλεκτρικής ενέργειας. Η μοντελοποίηση γίνεται με χρήση της γλώσσας προγραμματισμού Python.

Οι προτεινόμενες αλγοριθμικές λύσεις αξιολογούνται με τη χρήση δεδομένων αθροιστικού φορτίου ηλεκτρικών οχημάτων οικιακών καταναλωτών του δημόσια διαθέσιμου συνόλου δεδομένων της Pecan Street. Η ποσοτικοποίηση της ευελιξίας των ΦοΣΕ διερευνάται υπό την χρήση διαφορετικών τιμολογιακών πολιτικών, έχοντας ως κύρια επιλογή τις χρεώσεις βάσει χρόνου χρήσης (Time of Use – ToU tariffs).

ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ

Πρόβλεψη οικιακού φορτίου, ποσοτικοποίηση ευελιξίας οικιακών καταναλωτών, ΦοΣΕ, ηλεκτρικά οχήματα, HEMS (Home Energy Management Systems), βέλτιστη ημερήσια κατανάλωση, αθροιστικό φορτίο

ABSTRACT

The purpose of this thesis is to quantify the flexibility of the aggregated load from household appliances managed by load aggregators. Defining flexibility as the ability to modify and shift the load from a "typical" baseline profile, this thesis is divided into two distinct parts: a) forecasting a baseline profile of the aggregated household load, and b) estimating an optimal energy management plan based on financial incentives (electricity pricing schemes). The difference between the forecasted and the economically advantageous (optimal) consumption is defined as the maximum flexibility the aggregator can offer on a daily horizon, assuming full compliance of consumers with the financial incentives provided (e.g., cheap energy during nighttime hours).

The forecasting of the aggregated household load is done on a short-term, 15-minute horizon using LSTM machine learning networks. The calculation of the optimal consumption plan is conducted on a day-ahead basis and for an hourly horizon, using mathematical programming, with the objective function being the minimization of the daily electricity cost. The modeling is implemented using the Python programming language.

The proposed algorithmic solutions are evaluated using aggregated load data from household electric vehicles, available in the public dataset of Pecan Street. The quantification of the aggregator's flexibility is explored under different pricing policies, with Time of Use (ToU) tariffs being the main option.

KEY WORDS

Household load forecasting, quantification of household consumer flexibility, Aggregator, electric vehicles, HEMS (Home Energy Management Systems), optimal daily consumption, aggregated load

ΕΥΧΑΡΙΣΤΙΕΣ

Η παρούσα διπλωματική εργασία εκπονήθηκε κατά το ακαδημαϊκό έτος 2023–2024 υπό την επίβλεψη του κ. Παύλου Γεωργιάκη, καθηγητή της σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Ε.Μ.Π., στον οποίο οφείλω ιδιαίτερες ευχαριστίες για την ανάθεσή της, δίνοντάς μου την ευκαιρία να ασχοληθώ με ένα τόσο ενδιαφέρον και δημιουργικό θέμα. Επίσης, θα ήθελα να ευχαριστήσω θερμά τον υποψήφιο διδάκτορα Χριστόφορο Μένο-Αικατερινιάδη για την υπομονή και την πολύτιμη βοήθεια και καθοδήγηση που μου παρείχε σε όλη τη διάρκεια εκπόνησης της εργασίας, καθώς και για τον πολύτιμο χρόνο που μου αφιέρωσε.

Τέλος, θα ήθελα να ευχαριστήσω την οικογένειά μου και ιδιαίτερα τον εκλιπόντα πατέρα μου Ευάγγελο, ο οποίος αποτέλεσε πηγή έμπνευσης και δύναμης σε όλη τη διάρκεια της ζωής μου, τον κουμπάρο και συνάδελφο Άγγελο για την αμέριστη βοήθειά του σε όλη τη διάρκεια των σπουδών μας, και την Κατερίνα, στην συμπαράσταση και την αγάπη της οποίας οφείλω το μέλλον μου.

ΠΕΡΙΕΧΟΜΕΝΑ

ΚΕΦΑΛΑΙΟ 1: ΕΙΣΑΓΩΓΗ	13
1.1 Αντικείμενο της εργασίας	13
1.2 Δομή της εργασίας	14
 ΚΕΦΑΛΑΙΟ 2: ΕΥΕΛΙΞΙΑ ΟΙΚΙΑΚΩΝ ΚΑΤΑΝΑΛΩΤΩΝ	 17
2.1 Προκλήσεις και Σύγχρονες Απαιτήσεις Δικτύων Διανομής	17
2.2 Τεχνητή Νοημοσύνη και Πρόβλεψη Φορτίου	18
2.2.1 Στατιστικές Μέθοδοι	19
2.2.2 Τεχνικές Μηχανικής Μάθησης	20
2.2.3 Πλεονεκτήματα και Προκλήσεις	21
2.3 Αθροιστική Ευελιξία Καταναλωτών	22
2.3.1 Εισαγωγή	22
2.3.2 Μεθοδολογίες Ποσοτικοποίησης της Ευελιξίας	24
2.3.3 Παραδείγματα και Εφαρμογές	24
2.3.4 Περιορισμοί και Προκλήσεις	25
 ΚΕΦΑΛΑΙΟ 3: ΠΡΟΒΛΕΨΗ ΑΘΡΟΙΣΤΙΚΟΥ ΟΙΚΙΑΚΟΥ ΦΟΡΤΙΟΥ	 27
3.1 Μοντέλο LSTM με βρόχο ανάδρασης	27
3.1.1 Περιγραφή του Μοντέλου LSTM	27
3.1.2 Επιλογή και Επεξεργασία Δεδομένων	30
3.1.3 Εντοπισμός Υπερπροσαρμογής (Overfitting)	33
3.1.4 Αξιολόγηση Επιδόσεων μέσω Μετρικών	35
3.2 Πειραματική Διερεύνηση	36
3.3 Συμπεράσματα	39
 ΚΕΦΑΛΑΙΟ 4: ΠΟΣΟΤΙΚΟΠΟΙΗΣΗ ΤΗΣ ΕΥΕΛΙΞΙΑΣ	 41
4.1 Μοντελοποίηση	41
4.2 Πειραματική Διερεύνηση	43
4.2.1 Δεδομένα και παραδοχές	44
4.2.2 Ποσοτικοποίηση ευελιξίας με άξονα την κοινότητα	47
4.2.3 Ποσοτικοποίηση ευελιξίας με άξονα την κάθε οικία	53
4.2.4 Ανάλυση ευαισθησίας με τιμολογιακές πολιτικές	59
4.3 Συμπεράσματα	62

ΚΕΦΑΛΑΙΟ 5:	ΣΥΜΠΕΡΑΣΜΑΤΑ – ΕΠΕΚΤΑΣΕΙΣ	65
5.1	Σύνοψη και Συμπεράσματα της Εργασίας	65
5.2	Επεκτάσεις της Εργασίας	66
ΚΕΦΑΛΑΙΟ 6:	ΒΙΒΛΙΟΓΡΑΦΙΑ	69
ΠΑΡΑΡΤΗΜΑ:	ΚΩΔΙΚΑΣ	73
Π.1	LSTM	73
Π.2	PYOMO	82

ΚΕΦΑΛΑΙΟ

1

ΕΙΣΑΓΩΓΗ

1.1 ΑΝΤΙΚΕΙΜΕΝΟ ΕΡΓΑΣΙΑΣ

Η περιοχή έρευνας επικεντρώνεται στη διαχείριση της ενέργειας και την απόκριση ζήτησης σε επίπεδο οικιακών καταναλωτών. Στον σύγχρονο κόσμο, η διαχείριση ενέργειας έχει αποκτήσει αυξανόμενη σημασία λόγω της ανάγκης για μείωση της κατανάλωσης ενέργειας, αύξηση της αποδοτικότητας και μείωση των εκπομπών διοξειδίου του άνθρακα. Η διαχείριση ενέργειας σε επίπεδο οικιακών καταναλωτών περιλαμβάνει την παρακολούθηση και τον έλεγχο της κατανάλωσης ενέργειας από οικιακές συσκευές, καθώς και την υιοθέτηση τεχνολογιών και στρατηγικών που επιτρέπουν την προσαρμογή της κατανάλωσης βάσει εξωτερικών σημάτων, όπως η τιμή της ηλεκτρικής ενέργειας ή οι συνθήκες του δικτύου.

Το αντικείμενο της εργασίας είναι η ποσοτικοποίηση της ευελιξίας των φορέων σωρευτικής εκπροσώπησης οικιακών φορτίων. Οι φορείς σωρευτικής εκπροσώπησης (aggregators) είναι ενδιάμεσοι που συνδυάζουν την κατανάλωση ενέργειας πολλών μικρών καταναλωτών (π.χ. οικιακών χρηστών) σε ένα ενιαίο, αθροιστικό φορτίο. Αυτό τους επιτρέπει να συμμετέχουν σε αγορές ενέργειας και να προσφέρουν υπηρεσίες ευελιξίας, όπως η μείωση της κατανάλωσης κατά τις ώρες αιχμής ή η αύξηση της κατανάλωσης όταν υπάρχει περίσσεια παραγωγής ανανεώσιμων πηγών ενέργειας.

Η ευελιξία αναφέρεται στην ικανότητα ενός συστήματος ή καταναλωτή να προσαρμόζει τη ζήτηση ενέργειας σε απόκριση εξωτερικών σημάτων. Η ποσοτικοποίηση της ευελιξίας είναι σημαντική γιατί επιτρέπει την αξιολόγηση και τη βελτιστοποίηση της απόκρισης ζήτησης. Για παράδειγμα, αν γνωρίζουμε πόσο ευέλικτοι είναι οι οικιακοί καταναλωτές σε μια συγκεκριμένη περιοχή, μπορούμε να σχεδιάσουμε καλύτερες στρατηγικές για τη μείωση της κατανάλωσης ενέργειας και τη βελτίωση της απόδοσης του δικτύου. Η ποσοτικοποίηση της ευελιξίας των φορέων σωρευτικής εκπροσώπησης έχει πολλαπλά οφέλη:

- **Βελτίωση της Απόκρισης Ζήτησης:** Κατανοώντας την ευελιξία των οικιακών καταναλωτών, μπορούμε να προσαρμόσουμε τη ζήτηση ενέργειας ώστε να μειώσουμε τα φορτία αιχμής και να εξομαλύνουμε τη χρήση του δικτύου.
- **Οικονομικά Οφέλη:** Η μείωση της κατανάλωσης κατά τις ώρες αιχμής μπορεί να μειώσει το κόστος της ηλεκτρικής ενέργειας για τους καταναλωτές και να αυξήσει τα έσοδα για τους φορείς σωρευτικής εκπροσώπησης.
- **Αειφορία:** Η καλύτερη διαχείριση της ενέργειας συμβάλλει στη μείωση των εκπομπών διοξειδίου του άνθρακα και στην προώθηση της χρήσης ανανεώσιμων πηγών ενέργειας.
- **Ασφάλεια του Δικτύου:** Η ευελιξία μπορεί να χρησιμοποιηθεί για τη σταθεροποίηση του ηλεκτρικού δικτύου, ειδικά σε περιπτώσεις διακοπών ή αιχμής στη ζήτηση.

Συνοψίζοντας, η έρευνα αυτή αποσκοπεί στην κατανόηση και ποσοτικοποίηση της ευελιξίας των οικιακών καταναλωτών και στη βελτίωση της συνολικής διαχείρισης ενέργειας μέσω της χρήσης φορέων σωρευτικής εκπροσώπησης.

1.2 ΔΟΜΗ ΤΗΣ ΕΡΓΑΣΙΑΣ

Η εργασία είναι δομημένη σε έξι κεφάλαια, καθένα από τα οποία καλύπτει συγκεκριμένες πτυχές της έρευνας και των ευρημάτων σχετικά με την ποσοτικοποίηση της ευελιξίας των φορέων σωρευτικής εκπροσώπησης οικιακών φορτίων:

✓ Κεφάλαιο 1: Εισαγωγή

- 1.1 Αντικείμενο Εργασίας: Περιγράφει τη γενική περιοχή της έρευνας και το αντικείμενο της εργασίας, αναλύοντας τη σημασία της ποσοτικοποίησης της ευελιξίας των φορέων σωρευτικής εκπροσώπησης οικιακών φορτίων.
- 1.2 Δομή της Εργασίας: Παρέχει μια επισκόπηση της δομής και της οργάνωσης της διπλωματικής εργασίας.

✓ Κεφάλαιο 2: Ευελιξία Οικιακών Καταναλωτών

- 2.1 Προκλήσεις και Σύγχρονες Απαιτήσεις Δικτύων Διανομής: Εισαγωγή στις προκλήσεις και τις απαιτήσεις των σύγχρονων δικτύων διανομής ενέργειας.
- 2.2 Τεχνητή Νοημοσύνη και Πρόβλεψη Φορτίου: Ανασκόπηση των μεθόδων πρόβλεψης φορτίου, περιλαμβάνοντας στατιστικές και τεχνικές μηχανικής μάθησης.
- 2.3 Αθροιστική Ευελιξία Καταναλωτών: Παρουσίαση της έννοιας της αθροιστικής ευελιξίας και των τεχνολογιών HEMS.

✓ Κεφάλαιο 3: Πρόβλεψη Αθροιστικού Οικιακού Φορτίου

- 3.1 Μοντέλο LSTM με βρόγχο ανάδρασης: Παρουσίαση του LSTM μοντέλου και της εφαρμογής του στην πρόβλεψη αθροιστικού οικιακού φορτίου.
- 3.2 Πειραματική Διερεύνηση: Παρουσίαση των αποτελεσμάτων από τα πειράματα που διεξήχθησαν.
- 3.3 Συμπεράσματα: Ανάλυση των συμπερασμάτων από την πρόβλεψη του αθροιστικού οικιακού φορτίου.

✓ Κεφάλαιο 4: Ποσοτικοποίηση της Ευελιξίας

- 4.1 Μοντελοποίηση: Παρουσίαση των μεθόδων μοντελοποίησης για την ποσοτικοποίηση της ευελιξίας.
- 4.2 Πειραματική Διερεύνηση: Εφαρμογή των μεθόδων μοντελοποίησης και παρουσίαση των αποτελεσμάτων.
- 4.3 Συμπεράσματα: Ανάλυση των συμπερασμάτων από την ποσοτικοποίηση της ευελιξίας.

- ✓ **Κεφάλαιο 5:** Συμπεράσματα – Επεκτάσεις
 - 5.1 Σύνοψη και Συμπεράσματα της Εργασίας: Παρουσίαση των κύριων ευρημάτων και συμπερασμάτων της εργασίας.
 - 5.2 Επεκτάσεις της Εργασίας: Προτάσεις για μελλοντική έρευνα και επέκταση των ευρημάτων της παρούσας εργασίας.
- ✓ **Κεφάλαιο 6:** Βιβλιογραφία
 - 6.1 Παρουσιάζεται η βιβλιογραφία που χρησιμοποιήθηκε σε όλη την έκταση της εργασίας.
- ✓ **Παράρτημα I:** Κώδικας
 - 7.1 Παρουσιάζεται ο κώδικας Python που χρησιμοποιήθηκε σε όλη την έκταση της εργασίας.
 - 7.2 Παρουσιάζεται ο κώδικας Pyomo που χρησιμοποιήθηκε σε όλη την έκταση της εργασίας.

ΚΕΦΑΛΑΙΟ

2

ΕΥΕΛΙΞΙΑ ΟΙΚΙΑΚΩΝ ΚΑΤΑΝΑΛΩΤΩΝ

2.1 ΠΡΟΚΛΗΣΕΙΣ ΚΑΙ ΣΥΓΧΡΟΝΕΣ ΑΠΑΙΤΗΣΕΙΣ ΔΙΚΤΥΩΝ ΔΙΑΝΟΜΗΣ

Τα σύγχρονα δίκτυα διανομής ενέργειας αντιμετωπίζουν πολλές προκλήσεις λόγω της αυξανόμενης ζήτησης ηλεκτρικής ενέργειας, της διεύθυνσης των ανανεώσιμων πηγών ενέργειας και των αυστηρών απαιτήσεων για την αποδοτική και αξιόπιστη διαχείριση των ενεργειακών πόρων.

Αιχμές κατανάλωσης, δηλαδή περίοδοι κατά τις οποίες η ζήτηση είναι ιδιαίτερα υψηλή, μπορούν να προκαλέσουν υπερφόρτωση των δικτύων, οδηγώντας σε καταπόνηση αυτών, σε αυξημένο κόστος παραγωγής ακόμα και σε διακοπές ρεύματος, σε ακραίες περιπτώσεις. Η ευελιξία των οικιακών καταναλωτών μπορεί να συμβάλει στη διαχείριση αυτών των αιχμών, καθώς οι καταναλωτές μπορούν να προσαρμόσουν την ενεργειακή τους χρήση με βάση τις τιμές του ηλεκτρικού ρεύματος ή/και με βάση προνόμια και οικονομικά κίνητρα που προσφέρονται μέσα από προγράμματα απόκρισης ζήτησης, μειώνοντας έτσι τη ζήτηση κατά τις κρίσιμες περιόδους. Οι οικιακοί καταναλωτές μπορούν να μειώσουν τη χρήση ενέργειας κατά τις ώρες αιχμής είτε χειροκίνητα είτε μέσω αυτοματοποιημένων συστημάτων, όπως τα Συστήματα Διαχείρισης Οικιακής Ενέργειας (HEMS). Αυτό όχι μόνο μειώνει τη συμφόρηση στα δίκτυα διανομής αλλά βοηθά και στη μείωση του συνολικού κόστους παραγωγής ενέργειας, καθώς μπορεί να αποφευχθούν τυχόν δαπάνες για την αναβάθμιση του δικτύου είτε η χρήση αντιστοιχοοικονομικών εφεδρικών μονάδων παραγωγής κατά την κάλυψη αιχμών.

Η ενσωμάτωση ανανεώσιμων πηγών ενέργειας, όπως η ηλιακή και η αιολική ενέργεια, προσθέτει ένα άλλο επίπεδο πολυπλοκότητας στα δίκτυα διανομής. Οι ανανεώσιμες πηγές ενέργειας έχουν μεταβλητή και απρόβλεπτη παραγωγή, γεγονός που μπορεί να προκαλέσει αστάθεια στο δίκτυο. Για παράδειγμα, η παραγωγή ηλιακής ενέργειας εξαρτάται από τις καιρικές συνθήκες και μπορεί να μειωθεί δραματικά κατά τη διάρκεια συννεφιασμένων ημερών. Η ευελιξία των οικιακών καταναλωτών μπορεί να βοηθήσει στην ευστάθεια του δικτύου, προσαρμόζοντας τη ζήτηση ώστε να αντισταθμιστούν οι μεταβολές στην παραγωγή από ανανεώσιμες πηγές. Πιο συγκεκριμένα, οι οικιακοί καταναλωτές μπορούν να καταναλώνουν ενέργεια (πχ για τη φόρτιση των ηλεκτρικών τους οχημάτων) κατά τις περιόδους υψηλής παραγωγής από ανανεώσιμες πηγές και να μειώνουν τη χρήση τους όταν η παραγωγή είναι χαμηλή. Αυτό συμβάλλει στη βελτίωση της αξιοπιστίας του δικτύου και στην αύξηση της διεύθυνσης των ανανεώσιμων πηγών ενέργειας.

Οι σύγχρονες απαιτήσεις για την αποδοτική διαχείριση της ενέργειας απαιτούν τη βέλτιστη χρήση των διαθέσιμων πόρων και τη μείωση των απωλειών στο δίκτυο. Η ευελιξία των οικιακών καταναλωτών μπορεί να παίξει καθοριστικό ρόλο σε αυτή την κατεύθυνση, επιτρέποντας την καλύτερη κατανομή των ενεργειακών πόρων και την ελαχιστοποίηση των απωλειών. Μέσω των δυναμικών τιμολογήσεων και των προγραμμάτων απόκρισης ζήτησης,

οι πάροχοι προτρέπουν τους καταναλωτές να προσαρμόζουν τη χρήση τους με τρόπο που βελτιώνει τη συνολική αποδοτικότητα του συστήματος.

Επιπρόσθετα, η ευελιξία των οικιακών καταναλωτών μπορεί να συμβάλει σημαντικά στην παροχή εφεδρικών υπηρεσιών αποκατάστασης συχνότητας, οι οποίες είναι ζωτικής σημασίας για την ευσταθή και αξιόπιστη λειτουργία των δικτύων διανομής ηλεκτρικής ενέργειας. Όταν το δίκτυο διανομής αντιμετωπίζει διαταραχές, όπως απότομες μεταβολές στη ζήτηση ή στην παραγωγή ενέργειας, η συχνότητα του ηλεκτρικού δικτύου μπορεί να παρεκκλίνει από την ονομαστική της τιμή (50 Hz ή 60 Hz, ανάλογα με τη χώρα). Αυτές οι αποκλίσεις μπορούν να οδηγήσουν σε βλάβες ή και διακοπές ρεύματος εάν δεν αντιμετωπιστούν άμεσα. Η ευελιξία των οικιακών καταναλωτών επιτρέπει την ταχεία προσαρμογή της ζήτησης ηλεκτρικής ενέργειας σε πραγματικό χρόνο είτε αυτόματα είτε με τη συμμετοχή τους σε προγράμματα απόκρισης ζήτησης. Συνεπώς, σε περιπτώσεις όπου η συχνότητα του δικτύου μειώνεται λόγω υπερβολικής ζήτησης ή ανεπαρκούς παραγωγής, οι καταναλωτές μπορούν να μειώσουν την κατανάλωσή τους άμεσα και να συνεισφέρουν στην αποκατάστασή της. Αντίστοιχα, όταν η παραγωγή είναι υπερβολική και η συχνότητα αυξάνεται, μπορούν να αυξήσουν την κατανάλωσή τους, βοηθώντας στη σταθεροποίηση της συχνότητας.

Κομβικό ρόλο στην χρήση της ευελιξίας οικιακών καταναλωτών διαδραματίζουν τα HEMS και άλλες τεχνολογίες έξυπνης διαχείρισης ενέργειας καθώς μπορούν να βοηθήσουν τους καταναλωτές να βελτιστοποιήσουν τη χρήση της ενέργειας στο σπίτι τους. Για παράδειγμα, τα HEMS μπορούν να προσαρμόζουν τη θέρμανση και την ψύξη ανάλογα με τις τρέχουσες τιμές της ενέργειας και τις ανάγκες του δικτύου, μειώνοντας έτσι την κατανάλωση κατά τις ώρες αιχμής και αυξάνοντάς την κατά τις ώρες χαμηλής ζήτησης. Αυτό οδηγεί σε μια πιο ισορροπημένη και αποδοτική χρήση της ενέργειας, μειώνοντας ταυτόχρονα το κόστος για τους καταναλωτές.

Το γενικό συμπέρασμα είναι πως η ευελιξία των οικιακών καταναλωτών αποτελεί έναν κρίσιμο παράγοντα για την αντιμετώπιση των σύγχρονων προκλήσεων που αντιμετωπίζουν τα δίκτυα διανομής ενέργειας. Μέσω της προσαρμογής της ζήτησης, οι οικιακοί καταναλωτές μπορούν να συμβάλουν στη μείωση των αιχμών κατανάλωσης, στην ευστάθεια του δικτύου και στη βελτίωση της αποδοτικότητας των ενεργειακών πόρων. Η αξιοποίηση των τεχνολογιών έξυπνης διαχείρισης ενέργειας και των προγραμμάτων απόκρισης ζήτησης μπορεί να ενισχύσει την ευελιξία αυτή, οδηγώντας σε ένα πιο βιώσιμο και αποδοτικό ενεργειακό σύστημα.

2.2 ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΚΑΙ ΠΡΟΒΛΕΨΗ ΦΟΡΤΙΟΥ

Η πρόβλεψη φορτίου είναι μια από τις πιο σημαντικές διαδικασίες στη διαχείριση των ενεργειακών συστημάτων, καθώς επιτρέπει τον ακριβή προγραμματισμό της παραγωγής και της διανομής της ηλεκτρικής ενέργειας. Η τεχνητή νοημοσύνη (TN) και οι συναφείς τεχνολογίες έχουν φέρει επανάσταση σε αυτόν τον τομέα, επιτρέποντας την ανάπτυξη προηγμένων μοντέλων που μπορούν να αναλύσουν μεγάλα σύνολα δεδομένων και να παράγουν ακριβείς προβλέψεις. Σε αυτό το κεφάλαιο, θα εξεταστούν συνοπτικά οι κύριες μέθοδοι πρόβλεψης φορτίου, εστιάζοντας στις στατιστικές μεθόδους και τις μεθόδους μηχανικής μάθησης.

2.2.1 Στατιστικές Μέθοδοι

Οι στατιστικές μέθοδοι πρόβλεψης φορτίου είναι από τις πιο ευρέως διαδεδομένες τεχνικές κυρίως λόγω της απλότητάς τους και της ευκολίας στην εφαρμογή τους. Αυτές οι μέθοδοι είναι παραμετρικές, δηλαδή προϋποθέτουν μια συγκεκριμένη μαθηματική δομή στο μοντέλο τους, η οποία καθορίζει πώς τα δεδομένα σχετίζονται μεταξύ τους. Οι στατιστικές μέθοδοι προσπαθούν να εντοπίσουν και να προσαρμόσουν το μοντέλο στις παρατηρούμενες κατανομές των δεδομένων, με σκοπό να περιγράψουν όσο το δυνατόν καλύτερα τις υποκείμενες σχέσεις και τάσεις. Η παραμετρική φύση των στατιστικών μεθόδων σημαίνει ότι στηρίζονται σε προκαθορισμένες παραδοχές σχετικά με τη μορφή των δεδομένων και των σχέσεων μεταξύ τους. Μερικές από τις πιο κοινές στατιστικές μεθόδους περιλαμβάνουν:

Ανάλυση Χρονοσειρών (Time Series Analysis) [1], [9]:

Η ανάλυση χρονοσειρών είναι μια εξειδικευμένη τεχνική που χρησιμοποιείται για τη μοντελοποίηση και πρόβλεψη δεδομένων που συλλέγονται σε τακτά χρονικά διαστήματα, λαμβάνοντας υπόψη την εσωτερική δομή τους, όπως οι εποχιακές και κυκλικές τάσεις. Σε αντίθεση με άλλες τεχνικές πρόβλεψης που αγνοούν τη χρονική διάσταση των δεδομένων, η ανάλυση χρονοσειρών επικεντρώνεται στην κατανόηση και αξιοποίηση αυτής της διάστασης. Για παράδειγμα, τα μοντέλα αυτοπαλινδρόμησης (AR), ολοκληρωμένου κινητού μέσου όρου (IMA), και αυτοπαλινδρόμησης ολοκληρωμένου κινητού μέσου όρου (ARIMA) χρησιμοποιούνται για να συλλάβουν και να προβλέψουν περιοδικές συμπεριφορές και μοτίβα στα δεδομένα, όπως τις καθημερινές ή εποχιακές διακυμάνσεις στην κατανάλωση ενέργειας. Αυτή η ικανότητα είναι ιδιαίτερα κρίσιμη για τη διαχείριση και πρόβλεψη φορτίων σε δίκτυα διανομής ενέργειας, όπου οι τάσεις μπορεί να επηρεάζονται από παράγοντες όπως η εποχή του χρόνου, η ημέρα της εβδομάδας και οι καιρικές συνθήκες.

Παλινδρόμηση (Regression) [1], [9]:

Η παλινδρόμηση είναι μια στατιστική μέθοδος που επικεντρώνεται στην ποσοτικοποίηση της σχέσης μεταξύ μιας εξαρτημένης μεταβλητής και μιας ή περισσότερων ανεξάρτητων μεταβλητών. Στον τομέα της πρόβλεψης φορτίου, η παλινδρόμηση επιτρέπει την εκτίμηση της επίδρασης συγκεκριμένων παραγόντων, όπως η θερμοκρασία, η υγρασία και η ώρα της ημέρας, στην κατανάλωση ενέργειας. Μια βασική ιδιαιτερότητα της παλινδρόμησης είναι ότι μπορεί να χρησιμοποιηθεί για την κατασκευή μοντέλων που εξηγούν πόσο κάθε παράγοντας επηρεάζει το φορτίο, κάτι που είναι εξαιρετικά χρήσιμο για την κατανόηση των μεμονωμένων επιδράσεων στο σύστημα. Ωστόσο, η παλινδρόμηση συχνά δεν λαμβάνει υπόψη την αυτοσυσχέτιση των χρονικών δεδομένων, δηλαδή τη συσχέτιση μιας μεταβλητής με τον εαυτό της σε διαφορετικά χρονικά διαστήματα. Αυτό μπορεί να οδηγήσει σε λιγότερο ακριβείς προβλέψεις, ιδίως όταν οι ιστορικές τιμές του φορτίου έχουν σημαντική επιρροή στις μελλοντικές τιμές, γεγονός που κάνει την παλινδρόμηση πιο κατάλληλη για προβλήματα όπου οι προηγούμενες τιμές της μεταβλητής δεν επηρεάζουν σημαντικά τις μελλοντικές της τιμές.

Κινητοί Μέσοι Όροι (Moving Averages) [1], [9]:

Οι κινητοί μέσοι όροι χρησιμοποιούνται για την εξομάλυνση των διακυμάνσεων στα δεδομένα και την επισήμανση των μακροπρόθεσμων τάσεων. Αυτή η μέθοδος είναι απλή και μπορεί να

προσφέρει γρήγορες προβλέψεις, αλλά ενδέχεται να μην είναι τόσο ακριβής όσο οι πιο προηγμένες τεχνικές.

2.2.2 Τεχνικές Μηχανικής Μάθησης

Η μηχανική μάθηση έχει φέρει επανάσταση στον τομέα της πρόβλεψης φορτίου, επιτρέποντας την ανάπτυξη προηγμένων μοντέλων που μπορούν να μάθουν από ιστορικά δεδομένα και να βελτιώσουν συνεχώς την ακρίβειά τους. Η κύρια διαφορά με τις στατιστικές μεθόδους είναι πως τα μοντέλα μηχανικής μάθησης είναι μη παραμετρικά και μαθαίνουν από μόνα τους την συσχέτιση των δεδομένων χωρίς να προσπαθούν να βρουν μαθηματικές σχέσεις ανάμεσα στα δεδομένα είτε να τα ταιριάζουν με κάποια τυπική κατανομή. Κύριος στόχος είναι η βελτίωση της πρόβλεψης. Μερικές από τις κύριες τεχνικές μηχανικής μάθησης που χρησιμοποιούνται για την πρόβλεψη φορτίου περιλαμβάνουν:

Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks) [2], [9]:

Τα τεχνητά νευρωνικά δίκτυα είναι εμπνευσμένα από τη δομή του ανθρώπινου εγκεφάλου και είναι ικανά να ανιχνεύουν πολύπλοκα πρότυπα στα δεδομένα. Συνηθισμένα είδη νευρωνικών δικτύων που χρησιμοποιούνται για την πρόβλεψη φορτίου περιλαμβάνουν τα πολύ-επίπεδα perceptron (MLP) και τα αναδρομικά νευρωνικά δίκτυα (RNN). Τα RNN, και ειδικότερα τα δίκτυα μακράς βραχυπρόθεσμης μνήμης (LSTM), είναι ιδιαίτερα αποτελεσματικά για την πρόβλεψη φορτίου λόγω της ικανότητάς τους να χειρίζονται δεδομένα με χρονική αλληλουχία.

Δίκτυα Μακράς Βραχυπρόθεσμης Μνήμης [2] – [4] [9]:

Τα LSTM (Long Short-Term Memory) δίκτυα είναι ένας τύπος αναδρομικών νευρωνικών δικτύων που χρησιμοποιείται ευρέως για την ανάλυση και πρόβλεψη δεδομένων με χρονική αλληλουχία. Εισήχθησαν από τους Hochreiter και Schmidhuber το 1997 για να βελτιώσουν τα προβλήματα που αντιμετωπίζουν τα παραδοσιακά RNN κατά την εκπαίδευση σε μακροχρόνιες αλληλουχίες. Η βασική μονάδα LSTM αποτελείται από μια σειρά από "πύλες" που ελέγχουν τη ροή της πληροφορίας μέσα από τη μονάδα. Οι κύριες πύλες είναι:

- Πύλη Εισόδου (Input Gate): Ρυθμίζει πόση από τη νέα πληροφορία θα περάσει στην κατάσταση των κυττάρων (cell state).
- Πύλη Διαγραφής (Forget Gate): Αποφασίζει ποια πληροφορία από την κατάσταση των κυττάρων θα διαγραφεί.
- Πύλη Εξόδου (Output Gate): Καθορίζει την έξοδο της μονάδας LSTM βασισμένη στην κατάσταση των κυττάρων και την εισερχόμενη πληροφορία.

Εκτός από την κατάσταση των κυττάρων (cell state), η οποία είναι μια γραμμική μνήμη που επιτρέπει τη διατήρηση σημαντικών πληροφοριών για μεγάλες περιόδους χρόνου, τα LSTM διαθέτουν και το κρυφό επίπεδο (hidden state). Το κρυφό επίπεδο (hidden state) μεταφέρει πληροφορίες από προηγούμενα βήματα του χρόνου και επηρεάζει τις αποφάσεις που λαμβάνονται σε κάθε χρονικό βήμα. Το hidden state συνδυάζεται με την cell state για να διαμορφώσει την έξοδο της μονάδας και να διατηρήσει πληροφορίες που είναι χρήσιμες για την πρόβλεψη μελλοντικών τιμών. Αυτή η δυνατότητα είναι που καθιστά τα LSTM κατάλληλα για προβλήματα με μακροχρόνιες αλληλουχίες δεδομένων, όπως η πρόβλεψη φορτίου. Τα LSTM μπορούν να διατηρούν πληροφορίες για μεγάλες χρονικές περιόδους, καθιστώντας τα

κατάλληλα για δεδομένα με μακροχρόνιες αλληλουχίες. Οι πύλες επιτρέπουν στα LSTM να διαχειρίζονται καλύτερα τα προβλήματα της εκθετικής ανάπτυξης και της εξασθένησης των κλίσεων που επηρεάζουν τα παραδοσιακά RNN. Μπορούν να προσαρμοστούν εύκολα σε διάφορα προβλήματα με χρονική αλληλουχία, από την πρόβλεψη φορτίου έως την ανάλυση χρηματοοικονομικών δεδομένων και την αναγνώριση ομιλίας.

Μηχανές Υποστήριξης Διανυσμάτων (Support Vector Machines – SVM) [2] [9]:

Τα SVM είναι αλγόριθμοι μάθησης που χρησιμοποιούνται για την ταξινόμηση και την πρόβλεψη. Είναι ιδιαίτερα χρήσιμοι για προβλήματα με πολλές μεταβλητές εισόδου. Τα SVM μπορούν να χρησιμοποιηθούν για την πρόβλεψη φορτίου λαμβάνοντας υπόψη πολλαπλούς παράγοντες που επηρεάζουν τη ζήτηση.

Δέντρα Απόφασης (Decision Trees) και Τυχαία Δάση (Random Forests) [2] [9]:

Τα δέντρα απόφασης χρησιμοποιούν ένα δέντρο, ως μοντέλο αποφάσεων για την κατάταξη και την πρόβλεψη. Τα τυχαία δάση είναι ένα σύνολο από δέντρα απόφασης που χρησιμοποιούνται για την αύξηση της ακρίβειας της πρόβλεψης. Αυτές οι μέθοδοι μπορούν να χρησιμοποιηθούν για την πρόβλεψη φορτίου λαμβάνοντας υπόψη πολλούς διαφορετικούς παράγοντες.

Μέθοδοι Ενίσχυσης (Boosting) [2], [5] [9]:

Οι μέθοδοι ενίσχυσης, όπως το Gradient Boosting και το AdaBoost, συνδυάζουν πολλαπλά αδύναμα μοντέλα μάθησης για τη δημιουργία ενός ισχυρότερου μοντέλου. Οι πιο γνωστές υλοποιήσεις αυτής της μεθόδου είναι οι XGBoost (Extreme Gradient Boosting) και LightGBM (Light Gradient Boosting Machine). Η μέθοδος XGBoost θεωρείται ένας από τους πιο ισχυρούς αλγόριθμους ενίσχυσης. Χρησιμοποιεί τεχνικές όπως η παράλληλη επεξεργασία, καθιστώντας τον ιδιαίτερα αποδοτικό για μεγάλα και πολύπλοκα σύνολα δεδομένων. Επίσης, ο αλγόριθμος LightGBM είναι γνωστός για την ταχύτητα και την αποδοτικότητά του σε μεγάλα σύνολα δεδομένων. Χρησιμοποιεί έναν ειδικό αλγόριθμο για την κατασκευή των δέντρων απόφασης, που επιτρέπει την ταχύτερη εκπαίδευση και τη μικρότερη χρήση μνήμης. Παρόλο που τα LSTM είναι ιδιαίτερα αποδοτικά για δεδομένα με χρονική αλληλουχία, όπως η πρόβλεψη φορτίου, οι αλγόριθμοι ενίσχυσης, όπως το XGBoost και το LightGBM, έχουν αποδείξει ότι μπορούν να είναι εξίσου, αν όχι και περισσότερο, αποδοτικοί σε πολλές περιπτώσεις. Οι μέθοδοι ενίσχυσης μπορούν να βελτιώσουν την ακρίβεια της πρόβλεψης φορτίου, ιδιαίτερα σε σύνθετα και μεγάλα σύνολα δεδομένων.

2.2.3 Πλεονεκτήματα και Προκλήσεις

Η χρήση τεχνητής νοημοσύνης για την πρόβλεψη φορτίου προσφέρει πολλά πλεονεκτήματα. Πρώτον, οι αλγόριθμοι TN μπορούν να επεξεργαστούν και να αναλύσουν μεγάλα σύνολα δεδομένων σε πραγματικό χρόνο, παρέχοντας ακριβείς προβλέψεις που μπορούν να χρησιμοποιηθούν για τη βελτίωση της διαχείρισης της ζήτησης και της προσφοράς ενέργειας [6]. Δεύτερον, οι μέθοδοι TN είναι ευέλικτες και μπορούν να προσαρμοστούν στις συγκεκριμένες ανάγκες και απαιτήσεις του εκάστοτε ενεργειακού συστήματος [7]. Ένα σημαντικό πλεονέκτημα της χρήσης TN είναι η δυνατότητα ανάλυσης μη γραμμικών σχέσεων και η αναγνώριση σύνθετων προτύπων στα δεδομένα [6], [7]. Οι παραδοσιακές στατιστικές μέθοδοι μπορεί να μην είναι επαρκείς για την ανάλυση τέτοιων σχέσεων, αλλά οι αλγόριθμοι

TN μπορούν να εντοπίσουν και να αξιοποιήσουν αυτές τις σχέσεις για την παραγωγή ακριβέστερων προβλέψεων.

Παρά τα πλεονεκτήματα, υπάρχουν και περιορισμοί στη χρήση των τεχνικών TN για την πρόβλεψη φορτίου. Ένας από τους κυριότερους περιορισμούς είναι η ανάγκη για μεγάλα σύνολα δεδομένων εκπαίδευσης. Οι αλγόριθμοι TN απαιτούν μεγάλα και ποιοτικά δεδομένα για να μπορέσουν να μάθουν και να παρέχουν ακριβείς προβλέψεις. Επιπλέον, η πολυπλοκότητα των μοντέλων TN μπορεί να οδηγήσει σε προβλήματα όπως η υπερπροσαρμογή (overfitting), όπου το μοντέλο αποδίδει πολύ καλά στα δεδομένα εκπαίδευσης αλλά αποτυγχάνει να γενικεύσει σε νέα δεδομένα. Τέλος, η κατανόηση των αλγορίθμων TN μπορεί να αποτελέσει πρόκληση. Τα πολύπλοκα μοντέλα, όπως τα βαθιά νευρωνικά δίκτυα, μπορεί να είναι δύσκολο να ερμηνευτούν και να εξηγηθούν, κάτι που μπορεί να αποτελέσει πρόβλημα σε περιπτώσεις όπου η σαφήνεια και η κατανόηση των αποφάσεων είναι κρίσιμες.

2.3 ΑΘΡΟΙΣΤΙΚΗ ΕΥΕΛΙΞΙΑ ΚΑΤΑΝΑΛΩΤΩΝ

Η αθροιστική ευελιξία καταναλωτών είναι μια προσέγγιση που αναφέρεται στη συλλογική ικανότητα μιας ομάδας καταναλωτών να προσαρμόζουν τη ζήτησή τους αποκρινόμενοι σε εξωτερικά ερεθίσματα, όπως οι τιμές ενέργειας ή τα σήματα απόκρισης ζήτησης. Αυτή η συλλογική προσαρμογή μπορεί να προσφέρει σημαντικά οφέλη για τη διαχείριση των ενεργειακών συστημάτων, μειώνοντας τις αιχμές ζήτησης και βελτιώνοντας την αποδοτικότητα και την ευστάθεια του ηλεκτρικού δικτύου. Σε αυτή την ενότητα, θα εξεταστεί η αθροιστική ευελιξία καταναλωτών, συμπεριλαμβάνοντας τις βασικές αρχές, τις τεχνολογίες και τις μεθοδολογίες που υποστηρίζουν αυτή την προσέγγιση.

2.3.1 Εισαγωγή

Η έννοια της αθροιστικής ευελιξίας καταναλωτών βασίζεται στην ιδέα ότι μια ομάδα καταναλωτών μπορεί να συνδυάσει την ευελιξία της για να δημιουργήσει έναν αξιόπιστο και προβλέψιμο πόρο για το δίκτυο. Αυτή η συλλογική ευελιξία μπορεί να χρησιμοποιηθεί για την εξισορρόπηση της ζήτησης και της προσφοράς, τη μείωση των αιχμών ζήτησης, και τη βελτίωση της αξιοπιστίας και της αποδοτικότητας του δικτύου. Σε σύγκριση με τη μεμονωμένη ευελιξία, η αθροιστική προσέγγιση προσφέρει σημαντικά πλεονεκτήματα:

- Βελτιωμένη Πρόσβαση στις Ενεργειακές Αγορές [8], [10]: Ενώ ένας μεμονωμένος καταναλωτής μπορεί να μην διαθέτει αρκετή ευελιξία για να συμμετάσχει απευθείας σε ενεργειακές αγορές, η αθροιστική ευελιξία συγκεντρώνει επαρκή όγκο εύελικτων καταναλωτών, επιτρέποντας σε έναν Φορέα Σωρευτικής Εκπροσώπησης (ΦοΣΕ) να προσφέρει αυτήν την ευελιξία στην αγορά. Αυτό «ξεκλειδώνει» τη δυνατότητα συμμετοχής σε προγράμματα απόκρισης ζήτησης και την παροχή επικουρικών υπηρεσιών, όπως η αποκατάσταση συχνότητας, στο δίκτυο.
- Αποτελεσματικότερη Διαχείριση της Ζήτησης [11]: Η συγκέντρωση της ευελιξίας πολλών καταναλωτών επιτρέπει την πιο αποτελεσματική μείωση των αιχμών ζήτησης,

βοηθώντας στην ευστάθεια του δικτύου και στη μείωση του κόστους παραγωγής ενέργειας.

- Ενίσχυση της Χρήσης Ανανεώσιμων Πηγών Ενέργειας [12]: Με την αθροιστική ευελιξία, οι καταναλωτές μπορούν συλλογικά να αυξήσουν τη χρήση ενέργειας κατά τις περιόδους υψηλής παραγωγής από ανανεώσιμες πηγές, διευκολύνοντας την ενσωμάτωσή τους στο δίκτυο και μειώνοντας την εξάρτηση από συμβατικές πηγές ενέργειας.
- Ενθάρρυνση Συμμετοχής των Καταναλωτών [13]: Ο ΦοΣΕ μπορεί να προσφέρει οικονομικά κίνητρα στους καταναλωτές για τη συμμετοχή τους σε προγράμματα απόκρισης ζήτησης, τα οποία είναι περισσότερο αποδοτικά όταν συνδυάζονται πολλοί μικροί καταναλωτές. Αυτό δημιουργεί μια αμοιβαία επωφελή σχέση, όπου οι καταναλωτές κερδίζουν από την ευελιξία τους και το δίκτυο βελτιώνει την ευστάθεια και αποδοτικότητά του.

Συνολικά, η αθροιστική ευελιξία προσφέρει έναν αποτελεσματικό τρόπο για να μεγιστοποιηθούν τα οφέλη της ευελιξίας καταναλωτών, εξασφαλίζοντας τη βιωσιμότητα και την αξιοπιστία των σύγχρονων ενεργειακών συστημάτων.

Τα Συστήματα Διαχείρισης Οικιακής Ενέργειας (Home Energy Management Systems - HEMS) είναι τεχνολογίες που παίζουν κρίσιμο ρόλο στην επιτυχία της αθροιστικής ευελιξίας. Τα HEMS επιτρέπουν στους καταναλωτές να παρακολουθούν και να ελέγχουν τη χρήση ενέργειας στο σπίτι τους, ενώ ταυτόχρονα προσφέρουν μια πλατφόρμα για την αυτοματοποίηση της διαχείρισης ενέργειας. Μέσω της χρήσης των HEMS, οι καταναλωτές μπορούν να βελτιστοποιήσουν τη χρήση ενέργειας με βάση τις τρέχουσες τιμές ή τα σήματα απόκρισης ζήτησης [14], [15], [16]. Οι κύριες λειτουργίες των HEMS περιλαμβάνουν:

- Παρακολούθηση Ενέργειας: Τα HEMS επιτρέπουν στους καταναλωτές να παρακολουθούν την κατανάλωση ενέργειας σε πραγματικό χρόνο, παρέχοντας λεπτομερή στοιχεία για τη χρήση ενέργειας από διαφορετικές συσκευές.
- Αυτοματοποίηση: Τα HEMS μπορούν να αυτοματοποιούν τη λειτουργία των οικιακών συσκευών με βάση προγραμματισμένα κριτήρια, όπως οι ώρες αιχμής ή οι δυναμικές τιμολογήσεις.
- Ενσωμάτωση Ανανεώσιμων Πηγών: Τα HEMS μπορούν να συνδυαστούν με συστήματα ανανεώσιμων πηγών ενέργειας, όπως τα φωτοβολταϊκά συστήματα, επιτρέποντας την καλύτερη διαχείριση της τοπικής παραγωγής και κατανάλωσης ενέργειας.

Η συμβολή των HEMS στην αθροιστική ευελιξία είναι σημαντική, καθώς προσφέρουν τα απαραίτητα εργαλεία για τον έλεγχο μεμονωμένων φορτίων, διευκολύνοντας τη συλλογική προσαρμογή της ζήτησης ενέργειας. Μέσω της αποτελεσματικής χρήσης των HEMS, οι καταναλωτές μπορούν να ενσωματωθούν σε ευρύτερα προγράμματα απόκρισης ζήτησης, ενισχύοντας την αθροιστική ευελιξία και συμβάλλοντας στην ευστάθεια και την αποδοτικότητα του ενεργειακού συστήματος.

2.3.2 Μεθοδολογίες Βελτιστοποίησης της Ευελιξίας

Οι μεθοδολογίες βελτιστοποίησης της ευελιξίας παίζουν καθοριστικό ρόλο στη ποσοτικοποίηση και εκτίμηση της αθροιστικής ευελιξίας καταναλωτών. Αυτές οι μεθοδολογίες χρησιμοποιούν μαθηματικά μοντέλα και αλγορίθμους για την ανάπτυξη στρατηγικών που μεγιστοποιούν την αποδοτικότητα και ελαχιστοποιούν το κόστος. Μερικές από τις κύριες μεθοδολογίες περιλαμβάνουν [17], [18], [19]:

- **Γραμμικός και Μη Γραμμικός Προγραμματισμός:** Αυτές οι τεχνικές χρησιμοποιούνται για την επίλυση προβλημάτων βελτιστοποίησης που περιλαμβάνουν γραμμικές ή μη γραμμικές σχέσεις μεταξύ των μεταβλητών. Μπορούν να εφαρμοστούν για την κατανομή της ζήτησης ενέργειας σε διάφορες χρονικές περιόδους με στόχο τη μείωση του κόστους και τη βελτίωση της αποδοτικότητας.
- **Δυναμικός Προγραμματισμός:** Ο δυναμικός προγραμματισμός είναι μια τεχνική βελτιστοποίησης που επιλύει πολύπλοκα προβλήματα διασπώντας τα σε αλληλεξαρτώμενα υποπροβλήματα. Αποθηκεύοντας τις λύσεις αυτών των υποπροβλημάτων και λαμβάνοντας διαδοχικές αποφάσεις, επιτρέπει την ευέλικτη προσαρμογή της κατανάλωσης ενέργειας στις μεταβαλλόμενες συνθήκες, ενισχύοντας την αποδοτικότητα και την ευστάθεια του δικτύου στις μεταβολές της ζήτησης.
- **Προσομοιώσεις Monte Carlo:** Αυτές οι προσομοιώσεις χρησιμοποιούνται για την ανάλυση της αβεβαιότητας και των πιθανοτήτων, επιτρέποντας την αξιολόγηση των επιπτώσεων των διαφορετικών στρατηγικών και σεναρίων στην κατανάλωση ενέργειας. Με αυτόν τον τρόπο, οι διαχειριστές ενέργειας μπορούν να προβλέψουν την απόδοση των συστημάτων υπό διάφορες συνθήκες.
- **Αλγόριθμοι Μηχανικής Μάθησης:** Χρησιμοποιούνται για την ανάπτυξη μοντέλων που μπορούν να μάθουν από τα δεδομένα και να προβλέψουν τη συμπεριφορά των καταναλωτών. Αυτή η μέθοδος επιτρέπει την προσαρμογή των στρατηγικών διαχείρισης ενέργειας σε πραγματικό χρόνο, βελτιώνοντας την απόδοση και την ακρίβεια των προβλέψεων.

2.3.3 Παραδείγματα και Εφαρμογές

Η αθροιστική ευελιξία καταναλωτών έχει εφαρμοστεί σε διάφορα πραγματικά σενάρια και έργα, αποδεικνύοντας την αποτελεσματικότητά της στη βελτίωση της διαχείρισης ενέργειας. Δύο χαρακτηριστικά παραδείγματα είναι τα ακόλουθα:

Περίπτωση 1: Σχεδίαση και Υλοποίηση του Έργου "Smart Grid Vendée" στη Γαλλία [20]

Το έργο "Smart Grid Vendée" αναπτύχθηκε και υλοποιήθηκε στη Γαλλία, με στόχο τη βελτιστοποίηση της διαχείρισης της ενέργειας σε τοπικό επίπεδο. Το έργο συνδύασε την ενσωμάτωση ανανεώσιμων πηγών ενέργειας, τη διαχείριση της ζήτησης και την αθροιστική ευελιξία μέσω της χρήσης κατανεμημένων ενεργειακών πόρων (DERs). Μέσω της συμμετοχής βιομηχανικών μονάδων, συστημάτων αποθήκευσης ενέργειας όπως μπαταρίες, και

ανανεώσιμων πηγών ενέργειας, το "Smart Grid Vendée" κατάφερε να βελτιώσει την ευστάθεια του δικτύου και να ενισχύσει την αποδοτικότητα του συστήματος. Η πιλοτική εφαρμογή του έργου απέδειξε ότι η χρήση αθροιστικής ευελιξίας μπορεί να αποτελέσει σημαντικό εργαλείο για την ενσωμάτωση των ανανεώσιμων πηγών ενέργειας και τη μείωση των αιχμών ζήτησης, προσφέροντας παράλληλα οικονομικά οφέλη στους συμμετέχοντες και στη συνολική αγορά ενέργειας.

Περίπτωση 2: Έργο "Energiewende" στη Γερμανία [21]

Το έργο "Energiewende" αποτελεί μια από τις μεγαλύτερες και πιο φιλόδοξες πρωτοβουλίες της Γερμανίας για τη μετάβαση σε ένα βιώσιμο ενεργειακό σύστημα. Μέρος του έργου περιλαμβάνει τη χρήση αθροιστικής ευελιξίας μέσω των Φορέων Σωρευτικής Εκπροσώπησης (Aggregators), οι οποίοι διαχειρίζονται καταναλωμένους ενεργειακούς πόρους όπως μικρές ανανεώσιμες πηγές ενέργειας, συστήματα αποθήκευσης, και ευέλικτους καταναλωτές. Στο πλαίσιο αυτού του έργου, μικρές μονάδες παραγωγής ενέργειας, όπως φωτοβολταϊκά και ανεμογεννήτριες, συνδυάζονται για να προσφέρουν ευελιξία στο δίκτυο, ενώ συστήματα αποθήκευσης ενέργειας, όπως μπαταρίες, χρησιμοποιούνται για τη σταθεροποίηση της παροχής ενέργειας και τη μείωση των αιχμών ζήτησης. Το "Energiewende" έχει επιδείξει πώς η αθροιστική ευελιξία μπορεί να συμβάλει στη βελτίωση της αξιοπιστίας του ενεργειακού συστήματος, την καλύτερη ενσωμάτωση των ανανεώσιμων πηγών ενέργειας και τη συμμετοχή στις αγορές ενέργειας, δημιουργώντας ένα πιο ευσταθές και αποδοτικό ενεργειακό δίκτυο.

Η αθροιστική ευελιξία των καταναλωτών έχει αποδειχθεί αποτελεσματική σε διάφορα έργα και πιλοτικά προγράμματα. Τα παραδείγματα από το "Smart Grid Vendée" στη Γαλλία και το "Energiewende" στη Γερμανία δείχνουν πως η χρήση έξυπνων τεχνολογιών και η συντονισμένη διαχείριση ενεργειακών πόρων μπορεί να βελτιώσει τη διαχείριση ενέργειας, να μειώσει το κόστος και να σταθεροποιήσει το ενεργειακό δίκτυο. Οι μελέτες αυτές υπογραμμίζουν τη σημασία της ενσωμάτωσης προηγμένων τεχνολογιών διαχείρισης ενέργειας στις σύγχρονες ενεργειακές υποδομές για την επίτευξη μεγαλύτερης αποδοτικότητας και εξοικονόμησης ενέργειας. Μέσω της συνδυασμένης ευελιξίας μιας ομάδας καταναλωτών, είναι δυνατή η μείωση των αιχμών ζήτησης, η αύξηση της χρήσης ανανεώσιμων πηγών ενέργειας και η συμμετοχή σε προγράμματα απόκρισης ζήτησης. Οι τεχνολογίες όπως τα HEMS και οι μεθοδολογίες βελτιστοποίησης προσφέρουν τα εργαλεία για την επίτευξη αυτών των στόχων, ενώ τα παραδείγματα εφαρμογών δείχνουν τα πρακτικά οφέλη αυτής της προσέγγισης. Με τη συνεχή εξέλιξη των τεχνολογιών και των στρατηγικών διαχείρισης ενέργειας, η αθροιστική ευελιξία καταναλωτών θα συνεχίσει να διαδραματίζει σημαντικό ρόλο στη βιωσιμότητα των ενεργειακών συστημάτων.

2.3.4 Περιορισμοί και Προκλήσεις

Η αθροιστική ευελιξία καταναλωτών προσφέρει πολλές δυνατότητες για τη βελτίωση της διαχείρισης ενέργειας και της ευστάθειας του δικτύου. Ωστόσο, υπάρχουν ορισμένοι περιορισμοί και προκλήσεις που πρέπει να αντιμετωπιστούν για την επιτυχή εφαρμογή και την μεγιστοποίηση στα οφέλη αυτής της προσέγγισης [19].

Ένας από τους βασικούς περιορισμούς είναι η συλλογή και διαχείριση των δεδομένων κατανάλωσης από τους καταναλωτές. Η ακριβής μέτρηση και παρακολούθηση της κατανάλωσης ενέργειας σε πραγματικό χρόνο απαιτεί την εγκατάσταση έξυπνων μετρητών και

άλλων συσκευών IoT (Internet of Things), γεγονός που μπορεί να είναι δαπανηρό και χρονοβόρο. Επιπλέον, η διαχείριση μεγάλου πλήθους δεδομένων παρουσιάζει προκλήσεις όσον αφορά την αποθήκευση, την ανάλυση και την ασφάλεια των δεδομένων.

Η επιτυχία των προγραμμάτων διαχείρισης της αθροιστικής ευελιξίας εξαρτάται σε μεγάλο βαθμό από την ενεργή συμμετοχή των καταναλωτών. Πολλοί καταναλωτές μπορεί να είναι απρόθυμοι να αλλάξουν τις καταναλωτικές τους συνήθειες ή να μην κατανοούν πλήρως τα οφέλη της ευελιξίας. Η εκπαίδευση και η παροχή κινήτρων στους καταναλωτές είναι κρίσιμα για την ενθάρρυνση της συμμετοχής και την επίτευξη των στόχων τέτοιων προγραμμάτων.

Σημαντική τεχνική πρόκληση επίσης αποτελεί η ενσωμάτωση των συστημάτων διαχείρισης ενέργειας, όπως τα EMS (Energy Management Systems), BMS (Building Management Systems), και HEMS (Home Energy Management Systems), στα υφιστάμενα ενεργειακά δίκτυα, καθώς και η ανάπτυξη αξιόπιστων αλγορίθμων για τη διαχείριση της αθροιστικής ευελιξίας. Αυτοί οι αλγόριθμοι πρέπει να μπορούν να προσδιορίζουν την κατάλληλη τιμή για την προσφορά της αθροιστικής ευελιξίας στις ενεργειακές αγορές (bidding) και να λαμβάνουν υπόψη την αβεβαιότητα και την τυχαιότητα της ζήτησης και της προσφοράς ενέργειας. Η πολυπλοκότητα των ενεργειακών συστημάτων απαιτεί την ανάπτυξη καινοτόμων τεχνολογιών και διαδικασιών που μπορούν να εξασφαλίσουν την αποτελεσματική συμμετοχή της αθροιστικής ευελιξίας στο δίκτυο.

Τα ρυθμιστικά και νομικά ζητήματα αποτελούν επίσης σημαντική πρόκληση για την εφαρμογή των προγραμμάτων αθροιστικής ευελιξίας. Οι κανονισμοί και οι πολιτικές ενέργειας πρέπει να υποστηρίζουν τη χρήση των νέων τεχνολογιών και να προωθούν την ανάπτυξη των ανανεώσιμων πηγών ενέργειας. Επιπλέον, πρέπει να διασφαλίζεται η προστασία των προσωπικών δεδομένων των καταναλωτών και η διαφάνεια στη χρήση των δεδομένων.

ΚΕΦΑΛΑΙΟ

3

ΠΡΟΒΛΕΨΗ ΑΘΡΟΙΣΤΙΚΟΥ ΟΙΚΙΑΚΟΥ ΦΟΡΤΙΟΥ

3.1 ΜΟΝΤΕΛΟ LSTM ΜΕ ΒΡΟΧΟ ΑΝΑΔΡΑΣΗΣ


Η πρόβλεψη χρονοσειρών αθροιστικού οικιακού φορτίου θα γίνει με τη χρήση μοντέλου LSTM με βρόχο ανάδρασης (feedback loop), ο οποίος βοηθάει στην βελτίωση της ακρίβειας των προβλέψεων. Τα μοντέλα LSTM είναι ιδιαίτερα αποτελεσματικά για την πρόβλεψη δεδομένων κατανάλωσης ενέργειας που παρουσιάζουν εποχιακές τάσεις και διακυμάνσεις λόγω της ικανότητάς τους να συλλαμβάνουν και βραχυχρόνιες και μακροχρόνιες εξαρτήσεις. Επιπλέον, οι μονάδες LSTM μπορούν να αποθηκεύουν σημαντικές πληροφορίες και να αγνοούν μη σχετικές πληροφορίες, επιτρέποντας την καλύτερη κατανόηση των μοτίβων κατανάλωσης και τη βελτίωση της ακρίβειας των προβλέψεων [20].

Η χρήση βρόχου ανάδρασης στα μοντέλα LSTM ενισχύει περαιτέρω την ακρίβεια των προβλέψεων. Ο βρόχος ανάδρασης ανατροφοδοτεί μέσω τεχνητού νευρωνικού δικτύου (ANN) το σφάλμα πρόβλεψης, επιτρέποντας στο μοντέλο να επανεξετάζει και να διορθώνει τις προβλέψεις του σε πραγματικό χρόνο, βασιζόμενο στα νέα δεδομένα που εισέρχονται συνεχώς στο σύστημα. Αυτή η διαδικασία επαναλαμβάνεται διαρκώς, βελτιώνοντας έτσι την προσαρμοστικότητα και την ακρίβεια του μοντέλου. Η δυνατότητα αυτή είναι κρίσιμη για την αντιμετώπιση των μακροχρόνιων εξαρτήσεων και την παροχή αξιόπιστων προβλέψεων σε περιπτώσεις όπως η διαχείριση της κατανάλωσης ενέργειας, όπου οι ακριβείς προβλέψεις μπορούν να οδηγήσουν σε σημαντική μείωση κόστους και βελτίωση της αποδοτικότητας του δικτύου [23].

3.1.1 Περιγραφή του Μοντέλου LSTM

Το μοντέλο αυτό αναπτύχθηκε με βάση το προϋπάρχον μοντέλο του κύριου Παπαλουκά [24], με στόχο τη διερεύνηση της αύξησης της ακρίβειας πρόβλεψης ακολουθώντας τις παρακάτω συνιστώσες επέκτασης:

- προσθήκη επιπλέον χαρακτηριστικών (features)
- τροποποίηση σχηματισμού και επιλογής χρονοσειρών, ακολουθώντας διαφορετική προσέγγιση διαχωρισμού των δεδομένων εκπαίδευσης και δοκιμής



Σχήμα 3.1 : Διάγραμμα ροής του μοντέλου LSTM με βρόχο ανάδρασης (Forecaster) [25]

Η συγκεκριμένη αρχιτεκτονική, όπως απεικονίζεται στο Σχήμα 3.1, περιλαμβάνει τα εξής βασικά στοιχεία:

Επίπεδο Εισόδου (Input Layer):


Το επίπεδο εισόδου λαμβάνει τα χαρακτηριστικά x_t , τα οποία περιλαμβάνουν ιστορικά στοιχεία κατανάλωσης ευέλικτων οικιακών συσκευών, αθροισμένα για όλο το φορτίο της κοινότητας με χρονική ανάλυση ανά 15 λεπτά. Για την απόκτηση των προφίλ κατανάλωσης σε επίπεδο συσκευών για την κοινότητα, το πρώτο βήμα είναι η απομόνωση των μετρήσεων που αφορούν συγκεκριμένες συσκευές και ο προσδιορισμός των ημερών και σπιτιών που πληρούν τα κριτήρια. Αυτά τα κριτήρια περιλαμβάνουν σπίτια με σταθερά σημαντική κατανάλωση (μεγαλύτερη από 1kW κάθε 15 λεπτά) και συνεπή δεδομένα χωρίς πολλά κενά (NaN), για τουλάχιστον το 85% του έτους. Στη συνέχεια, πραγματοποιείται καθαρισμός των δεδομένων, αφαιρώντας τυχόν λανθασμένες μετρήσεις (όπως αρνητικές ή υπερβολικά χαμηλές τιμές), ενώ τυχόν ελλιπή δεδομένα συμπληρώνονται με τη μέθοδο παρεμβολής. Τελευταίο στάδιο της διαδικασίας είναι η συγκέντρωση όλων των δεδομένων από τα νοικοκυριά, ώστε να δημιουργηθεί ένα ενοποιημένο προφίλ κατανάλωσης για την κοινότητα, μαζί με χαρακτηριστικά που αφορούν τη χρονική διάσταση, όπως περιγράφεται στη συνέχεια.

Οι βελτιώσεις στο ενισχυμένο μοντέλο LSTM που υλοποιήθηκε στην εργασία [24] αφορούν το επίπεδο εισόδου και περιλαμβάνουν την προσθήκη επιπλέον χαρακτηριστικών και την αλλαγή του αλγορίθμου επιλογής δεδομένων:

- Προσθήκη επιπλέον χαρακτηριστικών (Εποχικότητα και Περιοδικότητα): Προστέθηκαν ως επιπλέον δεδομένα εισόδου το λεπτό της ημέρας (1-1440), η ημέρα της εβδομάδας (0-6) και ο μήνας (1-12) [23], προκειμένου να ενσωματωθούν οι εποχικές και περιοδικές τάσεις στην κατανάλωση ενέργειας. Αυτά τα χαρακτηριστικά επιτρέπουν στο μοντέλο να αναγνωρίζει και να εκμεταλλεύεται τα μακροπρόθεσμα και επαναλαμβανόμενα μοτίβα στα δεδομένα.
- Αλλαγή αλγορίθμου επιλογής δεδομένων εκπαίδευσης (training set)/δοκιμής (test set): Η μέθοδος επιλογής των δεδομένων εκπαίδευσης και δοκιμής βασίζεται σε κατανομή 80%-20%, όπου το 80% χρησιμοποιείται για εκπαίδευση και το 20% για δοκιμή. Επιπλέον αντί να επιλέγονται τυχαίες χρονικές ακολουθίες (χρονικές σειρές) όπως

γινόταν με τον προηγούμενο αλγόριθμο, τώρα επιλέγονται τυχαίες ημέρες από όλο το εύρος ημερών και μηνών του συνόλου δεδομένων. Αυτή η προσέγγιση αποφεύγει την επανάληψη επιλογής χρονικών σημείων που βρίσκονται κοντά (ανά 15 λεπτά), διασφαλίζοντας ότι τα δεδομένα εκπαίδευσης και δοκιμής καλύπτουν μια μεγαλύτερη ποικιλία χρονικών περιόδων. Αυτό ενισχύει την ικανότητα του μοντέλου να γενικεύει και να προβλέπει με μεγαλύτερη ακρίβεια.

Επίπεδο εξαγωγής προβλέψεων (LSTM, Fully Connected, Regression Layers):



Σχήμα 3.2 : Αρχιτεκτονική κυττάρου LSTM [24]

Το επίπεδο LSTM αποτελεί την κύρια μονάδα που επεξεργάζεται τις αλληλουχίες των δεδομένων και διατηρεί μακροχρόνια μνήμη χρησιμοποιώντας τα κύτταρα LSTM. Κατά την επεξεργασία χρονοσειρών, η μονάδα LSTM ενσωματώνει την προηγούμενη κρυφή κατάσταση h_{t-1} και την προηγούμενη κατάσταση του κυττάρου C_{t-1} μαζί με την τρέχουσα είσοδο χαρακτηριστικών X_t . Στη χρονική στιγμή t , η κρυφή κατάσταση εξόδου h_t προωθείται σε ένα πλήρως συνδεδεμένο επίπεδο (Fully Connected Layer) και ένα επίπεδο παλινδρόμησης (Regression Layer), τα οποία είναι υπεύθυνα για τις προβλέψεις χρονοσειρών στο συνολικό δίκτυο LSTM. Επειδή η κατάσταση του κυττάρου διατηρεί πληροφορίες καθ' όλη τη διάρκεια της επεξεργασίας των δεδομένων, το LSTM αντιμετωπίζει αποτελεσματικά το πρόβλημα της βραχυπρόθεσμης μνήμης που παρουσιάζουν τα κανονικά RNN.

Βρόχος Ανάδρασης (Feedback Loop):

Ο βρόχος ανάδρασης περιλαμβάνει ένα εμπροσθόδρομο νευρωνικό δίκτυο (Feedforward Neural Network), το οποίο ανατροφοδοτεί το σφάλμα πρόβλεψης e_t πίσω στο σύστημα, επιτρέποντας την προσαρμοστική μάθηση και τη βελτίωση της ακρίβειας των προβλέψεων. Ενώ η αρχιτεκτονική LSTM είναι εξαιρετική στην επεξεργασία χρονοσειρών, η απλή μορφή της δεν ενσωματώνει τις εξόδους για τη βελτίωση της απόδοσης πρόβλεψης. Κατά τη διάρκεια της εκπαίδευσης, το σφάλμα πρόβλεψης για κάθε χρονική στιγμή είναι άμεσα διαθέσιμο κατά την απόκτηση της τιμής πρόβλεψης. Καθώς πραγματοποιούνται περισσότερες προβλέψεις, περισσότερα ιστορικά σύνολα δεδομένων (εισόδου και αντίστοιχα σφάλματα) γίνονται διαθέσιμα, παρέχοντας πρόσθετες πληροφορίες που μπορούν να βελτιώσουν περαιτέρω την ακρίβεια των προβλέψεων. Για να ενσωματωθεί μια διαδικασία μάθησης που χρησιμοποιεί το

σφάλμα πρόβλεψης και τα χαρακτηριστικά εισόδου, υλοποιείται ένα ενισχυμένο μοντέλο LSTM με ένα επιπλέον νευρωνικό δίκτυο (ANN) που προσαρμόζεται και μαθαίνει τη σύνδεση μεταξύ της επαναλαμβανόμενης κατανάλωσης και των σφαλμάτων πρόβλεψης. Η προεπεξεργασία των δεδομένων διασφαλίζει την αποδοτική εκπαίδευση του μοντέλου. Η δομή του ενισχυμένου μοντέλου LSTM περιλαμβάνει τις εξής κύριες λειτουργίες:


- Καθορισμός των βασικών παραμέτρων LSTM και των συναρτήσεων ενεργοποίησης για κάθε επίπεδο.
- Εκπαίδευση του μοντέλου LSTM με τη χρήση των επεξεργασμένων δεδομένων κατανάλωσης.
- Αξιολόγηση της απόδοσης του μοντέλου με βάση κριτήρια ακρίβειας (σφάλματα) που δείχνουν πόσο αποτελεσματικά προβλέπει το μοντέλο.
- Υλοποίηση ενός πρόσθετου νευρωνικού δικτύου (ANN) που χρησιμοποιεί τα σφάλματα για την επαναπρόβλεψη των ηλεκτρικών καταναλώσεων, διορθώνοντας τις αρχικές προβλέψεις του μοντέλου LSTM.
- Το πρόσθετο μοντέλο ANN διαθέτει τα δικά του επίπεδα νευρώνων, συναρτήσεις ενεργοποίησης και συγκεκριμένη αρχιτεκτονική.

Συνολικά, το ενισχυμένο μοντέλο LSTM με βρόχο ανάδρασης βελτιώνει τις προβλέψεις του απλού LSTM μοντέλου, λαμβάνοντας υπόψη επιπλέον μοτίβα και πληροφορίες από τα δεδομένα, προσφέροντας έτσι μεγαλύτερη ακρίβεια και αξιοπιστία στις προβλέψεις της οικιακής κατανάλωσης. Παρακάτω, περιγράφεται αναλυτικότερα η δομή του μοντέλου, οι βασικές συναρτήσεις και τα δεδομένα εισόδου και εξόδου.

3.1.2 Επιλογή και Επεξεργασία Δεδομένων

Η επιλογή των κατάλληλων δεδομένων είναι ένα κρίσιμο βήμα για την επιτυχημένη πρόβλεψη φορτίου. Τα δεδομένα πρέπει να είναι αντιπροσωπευτικά και να περιλαμβάνουν όλες τις σημαντικές μεταβλητές που επηρεάζουν τη ζήτηση ενέργειας. Στην περίπτωση της παρούσας εργασίας, τα δεδομένα που επιλέχθηκαν αφορούν τη συνολική κατανάλωση μεμονωμένων κατηγοριών συσκευών, όπως η κατανάλωση ηλεκτρικής ενέργειας από ηλεκτρικά οχήματα (EV) και κλιματιστικά (A/C). Η εστίαση στην κατανάλωση αυτών των συσκευών είναι σημαντική λόγω της υψηλής ενεργειακής ζήτησής τους και του ρόλου τους στη συνολική καταναλωτική συμπεριφορά. Μία καλή πρακτική στην επιλογή δεδομένων για την πρόβλεψη ζήτησης ηλεκτρικής ενέργειας, ιδιαίτερα όταν δεν υπάρχουν διαθέσιμα τοπικά δεδομένα, είναι η χρήση δημοσίως διαθέσιμων συνόλων δεδομένων. Αυτά τα δεδομένα, που προέρχονται από έξυπνους μετρητές και άλλες πηγές, προσφέρουν πολύτιμες πληροφορίες για τις ενεργειακές ανάγκες των καταναλωτών. Στην παρούσα εργασία ακολουθήθηκαν τα παρακάτω βήματα για την επιλογή και επεξεργασία δεδομένων εισόδου:

- Χρησιμοποιήθηκαν τα δεδομένα του 2018 από την Pecan Street Inc., έναν ερευνητικό οργανισμό με έδρα το Austin του Texas, που επικεντρώνεται στη συλλογή και ανάλυση λεπτομερών δεδομένων κατανάλωσης ενέργειας από οικιακές πηγές. Ο οργανισμός έχει αναπτύξει μια ολοκληρωμένη πλατφόρμα δεδομένων, γνωστή ως Dataport [26], η οποία συλλέγει δεδομένα κατανάλωσης ηλεκτρικής ενέργειας σε επίπεδο κυκλώματος από εκατοντάδες νοικοκυριά στο ερευνητικό τους δίκτυο. Αυτά τα δεδομένα περιλαμβάνουν πληροφορίες για τη φόρτιση ηλεκτρικών οχημάτων, την παραγωγή ηλιακής ενέργειας, την αποθήκευση ενέργειας και τη χρήση ενέργειας σε επίπεδο μεμονωμένων οικιακών συσκευών, συμπεριλαμβανομένων των συστημάτων θέρμανσης και ψύξης. Αυτά τα δεδομένα που επιπλέον περιλαμβάνουν σχετικά δεδομένα, όπως η ημέρα της εβδομάδας και η ώρα της ημέρας χρησιμοποιήθηκαν για την ανάλυση και την ανάπτυξη του μοντέλου μας για την πρόβλεψη αθροιστικού οικιακού φορτίου.
- Τα παραπάνω δεδομένα επεξεργάστηκαν κατάλληλα, επιλέγοντας τις κατοικίες που έχουν πάνω από 85% έγκυρα αριθμητικά δεδομένα ως είσοδο για το αθροιστικό φορτίο. Η κάθε μέρα χωρίζεται σε 96 χρονικά διαστήματα των 15 λεπτών, και επιλέχθηκαν οι ημέρες που περιλαμβάνουν περισσότερες από 80 (από τις 96) έγκυρες αριθμητικές τιμές για τα δεδομένα εισόδου. Επιπλέον, όλες οι αρνητικές και πολύ μικρές μετρήσεις μηδενίστηκαν, για αποφυγή «θορύβου» κατά την εκπαίδευση του μοντέλου. Σαν τελευταίο βήμα, τα μη αριθμητικά δεδομένα αντικαταστάθηκαν, χρησιμοποιώντας τη μέθοδο της γραμμικής παρεμβολής, και υπολογίστηκε η αθροιστική κατανάλωση για όλες τις κατοικίες (Σχήμα 3.3).



Σχήμα 3.3 : Τελική μορφή των δεδομένων με άθροιση των επιμέρους καταναλώσεων

Ο αλγόριθμος που περιεγράφηκε παραπάνω, υλοποιήθηκε σε γλώσσα Python, όπως φαίνεται στο Σχήμα 3.4.

```
# raw data pre-processing
def process_consumption_data(path: str, flex_resource: str) -> pd.DataFrame:
    # Read raw data
    raw_data = pd.read_csv(path)

    # Convert time data to datetime and keep only data needed for the training
    raw_data['local_15min'] = pd.to_datetime(raw_data['local_15min'], utc=True)
    df = pd.DataFrame()
    df['date'] = raw_data['local_15min']
    df['day'] = raw_data['local_15min'].dt.date
    df['dataid'] = raw_data['dataid']
    df[flex_resource] = raw_data[flex_resource]

    # Step 1: Find the eligible houses data: the ones with over 85% of non-NaN values across all dataset
    non_nan_dataid = df.groupby('dataid')[flex_resource].apply(lambda x: x.count() / len(x) * 100)
    filtered_df = df[df['dataid'].isin(non_nan_dataid[non_nan_dataid > 85].index)]

    # Step 2: Find the eligible datetime data: days with more than 80 non-NaN values
    # Count the number of nonNaN values per day, dataid
    non_nan_days = filtered_df.groupby(['dataid', 'day']).count()[flex_resource].reset_index()
    # Remove days with less than 80 non NaN values (out of 96 values/day)
    non_nan_days = non_nan_days[non_nan_days[flex_resource] > 80]
    # For each day find the number of eligible houses (if 8 then all houses have data for that day)
    IDs_per_day = non_nan_days.groupby('day')['dataid'].count().reset_index()
    eligible_days = IDs_per_day[IDs_per_day['dataid'] == len(filtered_df['dataid'].unique())]

    filtered_df = filtered_df[filtered_df['day'].isin(eligible_days['day'])].set_index('dataid')

    # Step 3: All negative and small measurements get to zero
    filtered_df[flex_resource] = filtered_df[flex_resource].apply(lambda x: 0 if x < 0.05 else x)

    # Step 4: Replace NaN values with the interpolation method
    filtered_df[flex_resource] = filtered_df[flex_resource].interpolate(method='linear')


    # Step 5: Get aggregate consumption for all houses
    filtered_df = filtered_df.groupby('date')[iv.flex_resource].sum().reset_index()

    # Step 6: Transform the data from wide to Long format to help training
    final_df = pd.melt(filtered_df, id_vars=['date'], value_vars=flex_resource, var_name='Resource', value_name='Consumption')

    return final_df
```

Σχήμα 3.4 : Συνάρτηση `process_consumption_data` σε γλώσσα Python για την επεξεργασία των δεδομένων

- Ο διαχωρισμός των δεδομένων σε σύνολα εκπαίδευσης και δοκιμής είναι απαραίτητος για την αξιολόγηση της απόδοσης του μοντέλου και την αποφυγή υπερπροσαρμογής. Το σύνολο εκπαίδευσης επιτρέπει στο μοντέλο να μάθει τα πρότυπα και τις σχέσεις ανάμεσα στα δεδομένα. Το σύνολο δοκιμής χρησιμοποιείται για την αξιολόγηση της απόδοσης του μοντέλου, ως προς την ικανότητα του μοντέλου να εφαρμόζεται σε νέα, άγνωστα δεδομένα. Σε αυτή την περίπτωση, έγινε τυχαία επιλογή ολόκληρων ημερών αντί για μεμονωμένες χρονικές σειρές (χρονοσειρές), ώστε να διασφαλιστεί ότι τα δεδομένα εκπαίδευσης και δοκιμής καλύπτουν ένα ευρύ φάσμα χρονικών περιόδων. Συνηθισμένα ποσοστά διαχωρισμού είναι 70% για το σύνολο εκπαίδευσης και 30% για το σύνολο δοκιμής ή 80% και 20%, αντίστοιχα. Στην παρούσα εργασία επιλέχθηκε διαχωρισμός 80% και 20%.



Σχήμα 3.5 : Σύνολα Εκπαίδευσης και Δοκιμής για το σύνολο των Ηλεκτρικών Οχημάτων

3.1.3 Αντιμετώπιση Υπερπροσαρμογής (Overfitting)

Η υπερπροσαρμογή συμβαίνει όταν το μοντέλο μαθαίνει πολύ καλά τα πρότυπα του συνόλου εκπαίδευσης, αλλά αποτυγχάνει να γενικεύσει στα σύνολα δοκιμής. Αυτό σημαίνει ότι το μοντέλο αποδίδει εξαιρετικά στα δεδομένα εκπαίδευσης, αλλά όταν εφαρμόζεται σε νέα δεδομένα, η απόδοσή του είναι ανεπαρκής. Οι πιο γνωστές τεχνικές εντοπισμού και πρόληψης υπερπροσαρμογής περιλαμβάνουν [27] - [30]:

Ενδοεπικύρωση (Cross-Validation):

Η ενδοεπικύρωση είναι μια μέθοδος που χρησιμοποιείται ευρέως για την αξιολόγηση της απόδοσης των μοντέλων και τον εντοπισμό της υπερπροσαρμογής. Στη διαδικασία αυτή, τα δεδομένα χωρίζονται σε πολλαπλά σύνολα εκπαίδευσης και επικύρωσης (validation). Το σύνολο επικύρωσης είναι ένα υποσύνολο των δεδομένων που δεν χρησιμοποιείται για την εκπαίδευση του μοντέλου, αλλά για την αξιολόγηση της απόδοσής του σε δεδομένα που δεν έχει δει κατά τη διάρκεια της εκπαίδευσης. Ένας κοινός τύπος ενδοεπικύρωσης είναι η k-fold cross-validation, όπου τα δεδομένα χωρίζονται σε k σύνολα (folds). Το μοντέλο εκπαιδεύεται k φορές, κάθε φορά χρησιμοποιώντας ένα διαφορετικό fold ως σύνολο επικύρωσης και τα υπόλοιπα k-1 folds ως σύνολο εκπαίδευσης. Η απόδοση του μοντέλου αξιολογείται σε κάθε fold και υπολογίζεται ο μέσος όρος της απόδοσης σε όλα τα folds. Αυτή η μέθοδος βοηθά στην ανίχνευση υπερπροσαρμογής, καθώς επιτρέπει την αξιολόγηση της απόδοσης του μοντέλου σε

πολλαπλά σύνολα δεδομένων, παρέχοντας μια πιο αξιόπιστη εκτίμηση της γενίκευσης του μοντέλου.

Πρόωρη Διακοπή (Early Stopping):

Η πρόωρη διακοπή είναι μια τεχνική που χρησιμοποιείται για την πρόληψη της υπερπροσαρμογής κατά την εκπαίδευση του μοντέλου. Στην πρόωρη διακοπή, η εκπαίδευση του μοντέλου διακόπτεται όταν η απόδοση στο σύνολο επικύρωσης αρχίζει να μειώνεται, ακόμα και αν η απόδοση στο σύνολο εκπαίδευσης συνεχίζει να βελτιώνεται. Αυτό συμβαίνει συνήθως όταν το μοντέλο αρχίζει να μαθαίνει υπερβολικά τις ιδιαιτερότητες των δεδομένων εκπαίδευσης, παράγοντας έτσι ένα πολύπλοκο μοντέλο που δεν μπορεί να γενικεύσει αποτελεσματικά στα νέα δεδομένα. Η παρακολούθηση της απόδοσης στο σύνολο επικύρωσης και η διακοπή της εκπαίδευσης όταν η απόδοση αρχίζει να μειώνεται βοηθά στη δημιουργία ενός πιο απλού και γενικεύσιμου μοντέλου.

Κανονικοποίηση (Regularization):

Η κανονικοποίηση είναι μια άλλη μέθοδος για την πρόληψη της υπερπροσαρμογής. Περιλαμβάνει την προσθήκη ενός όρου στην αντικειμενική συνάρτηση που τιμωρεί τα μεγάλα βάρη στο μοντέλο. Δύο κοινές μορφές κανονικοποίησης είναι η L1 και η L2 κανονικοποίηση. Η L1 κανονικοποίηση (ή Lasso) προσθέτει το απόλυτο μέγεθος των βαρών στην αντικειμενική συνάρτηση, ενώ η L2 κανονικοποίηση (ή Ridge) προσθέτει το τετράγωνο του μεγέθους των βαρών. Αυτοί οι όροι τιμωρούν τα υπερβολικά μεγάλα βάρη και προωθούν τη δημιουργία πιο απλών μοντέλων, τα οποία έχουν καλύτερη απόδοση σε νέα δεδομένα.

Dropout:

Το dropout είναι μια τεχνική κανονικοποίησης που χρησιμοποιείται συχνά σε νευρωνικά δίκτυα για την πρόληψη της υπερπροσαρμογής. Κατά την εκπαίδευση, κάθε νευρώνας έχει μια πιθανότητα να "απενεργοποιηθεί" (dropout) σε κάθε επανάληψη εκπαίδευσης, δηλαδή να μην συμμετάσχει στην επεξεργασία των δεδομένων. Αυτό αναγκάζει το δίκτυο να μάθει πιο ανθεκτικές και γενικεύσιμες αναπαραστάσεις των δεδομένων, καθώς δεν μπορεί να βασιστεί σε ένα συγκεκριμένο σύνολο νευρώνων για την πρόβλεψη.

Αυτές οι τεχνικές συμβάλλουν στην αποφυγή της υπερπροσαρμογής και στην ανάπτυξη μοντέλων που μπορούν να γενικεύσουν καλύτερα σε νέα, άορατα δεδομένα, βελτιώνοντας έτσι την απόδοση και την αξιοπιστία των προβλέψεων. Στην εργασία αυτή επιλέχθηκε η ευρέως διαδεδομένη μέθοδος κανονικοποίησης Min-Max Scaling που απαιτεί μετασχηματισμό των δεδομένων ώστε οι τιμές να βρίσκονται σε ένα συγκεκριμένο εύρος, συνήθως μεταξύ 0 και 1, το οποίο εξασφαλίζει ότι όλες οι μεταβλητές έχουν την ίδια σημασία κατά την εκπαίδευση του μοντέλου. Αξίζει να σημειωθεί ότι έγινε διαφορετική κανονικοποίηση για το σύνολο δεδομένων εκπαίδευσης και διαφορετική για εκείνο της δοκιμής, με βάση τη μέγιστη και ελάχιστη τιμή του εκάστοτε συνόλου.

3.1.4 Αξιολόγηση Επιδόσεων μέσω Μετρικών

Η αξιολόγηση των επιδόσεων του μοντέλου είναι απαραίτητη για την εκτίμηση της ακρίβειας και της αποδοτικότητάς του, το οποίο γίνεται με βάση τους παρακάτω δείκτες επίδοσης:

- Μέσο Απόλυτο Σφάλμα - Mean Absolute Error (MAE): Υπολογίζει τη μέση απόλυτη διαφορά μεταξύ των πραγματικών και των προβλεπόμενων τιμών και δίνει μια σαφή ένδειξη του μέσου σφάλματος της πρόβλεψης. Δίνεται από την εξίσωση (3.1), όπου n είναι το σύνολο των παρατηρήσεων, A_t η πραγματική τιμή, F_t η προβλεπόμενη τιμή:

$$MAE = \frac{1}{n} \sum_{t=1}^n |A_t - F_t| \quad (3.1)$$

- Μέσο Τετραγωνικό Σφάλμα - Root Mean Squared Error (RMSE): Υπολογίζει τη ρίζα του μέσου τετραγωνικού σφάλματος μεταξύ των πραγματικών και των προβλεπόμενων τιμών, δίνοντας έμφαση στα μεγαλύτερα σφάλματα, κάνοντάς το πιο ευαίσθητο στις ακραίες τιμές. Δίνεται από την εξίσωση (3.2), όπου n είναι το σύνολο των παρατηρήσεων, A_t η πραγματική τιμή, F_t η προβλεπόμενη τιμή:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2} \quad (3.2)$$

- Συντελεστής Προσδιορισμού - R-Squared (R^2): Μετράει το ποσοστό της διακύμανσης των δεδομένων και δείχνει πόσο καλά ταιριάζουν τα δεδομένα με το μοντέλο πρόβλεψης. Δίνεται από την εξίσωση (3.3), όπου n είναι το σύνολο των παρατηρήσεων, A_t η πραγματική τιμή, F_t η προβλεπόμενη τιμή, $\bar{A}$ η μέση τιμή των πραγματικών τιμών:

$$R^2 = 1 - \frac{\sum_{t=1}^n (A_t - F_t)^2}{\sum_{t=1}^n (A_t - \bar{A})^2} \quad (3.3)$$

- Μέσο Απόλυτο Ποσοστιαίο Σφάλμα - Mean Absolute Percentage Error (MAPE): Υπολογίζει τη μέση απόλυτη ποσοστιαία διαφορά μεταξύ των πραγματικών και των προβλεπόμενων τιμών. Παρέχει μια ένδειξη του σφάλματος της πρόβλεψης ως ποσοστό των πραγματικών τιμών, καθιστώντας την κατάλληλη για σύγκριση σφαλμάτων μεταξύ διαφορετικών μοντέλων ή χρονικών περιόδων. Δίνεται από την εξίσωση (3.4), όπου n είναι το σύνολο των παρατηρήσεων, A_t η πραγματική τιμή, F_t η προβλεπόμενη τιμή:

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (3.4)$$

- Μέσο Απόλυτο Ποσοστιαίο Εφαπτομενικό Σφάλμα - Mean Arctangent Absolute Percentage Error (MAAPE): Υπολογίζει τη μέση τιμή της αντίστροφης εφαπτομένης (arctangent) της απόλυτης ποσοστιαίας διαφοράς μεταξύ των πραγματικών και των προβλεπόμενων τιμών. Παρέχει μια πιο σταθερή εκτίμηση του σφάλματος σε σύγκριση με το MAPE, καθώς μειώνει την επίδραση των εξαιρετικά μεγάλων ή μικρών τιμών.

Δίνεται από την εξίσωση (3.5), όπου n είναι το σύνολο των παρατηρήσεων, A_t η πραγματική τιμή, F_t η προβλεπόμενη τιμή:

$$MAAPE = \frac{1}{n} \sum_{t=1}^n \arctan \left(\left| \frac{A_t - F_t}{A_t} \right| \right) \quad (3.5)$$


Η χρήση διαφόρων μετρικών αξιολόγησης επιτρέπει μια ολοκληρωμένη εκτίμηση της απόδοσης του μοντέλου πρόβλεψης φορτίου. Οι μετρικές όπως το MAE, το RMSE, το R^2 , το MAPE και το MAAPE παρέχουν διαφορετικές οπτικές γωνίες για την ακρίβεια και την αξιοπιστία του μοντέλου, βοηθώντας στην αναγνώριση των περιοχών που χρειάζονται βελτίωση και στην επιβεβαίωση της αποτελεσματικότητας των προβλέψεων.

3.2 ΠΕΙΡΑΜΑΤΙΚΗ ΔΙΕΡΕΥΝΗΣΗ


Τα πειραματικά αποτελέσματα και τα συμπεράσματα της παρούσας εργασίας επικεντρώνονται στην ανάλυση της απόδοσης των μοντέλων πρόβλεψης φορτίου με τη χρήση των LSTM δικτύων με βρόχο ανάδρασης. Στην παρούσα εργασία δεν χρησιμοποιήθηκαν ευρέως διαδεδομένοι δείκτες αξιολόγησης όπως το RMSE, καθώς η παρουσία πολλών μηδενικών τιμών στα δεδομένα οδηγεί σε σημαντικά διαστρεβλωμένα αποτελέσματα, καθιστώντας το RMSE λιγότερο αντιπροσωπευτικό της πραγματικής απόδοσης του μοντέλου. Επίσης, δεν χρησιμοποιήθηκαν τα μετρικά MAPE και R-squared, καθώς το MAPE μπορεί να είναι μη-αξιόπιστο όταν υπάρχουν πολλές μηδενικές ή πολύ μικρές τιμές στα δεδομένα, ενώ το R-squared δεν είναι κατάλληλο για μη γραμμικά μοντέλα όπως τα LSTM, τα οποία χρησιμοποιούνται σε αυτή τη μελέτη. Οπότε τα αποτελέσματα αξιολογούνται με βάση τα μετρητικά MAE και MAAPE. Η ανάλυση αυτή βασίζεται σε δεδομένα από 7 κατοικίες στην περιοχή του Austin για το έτος 2018, με έμφαση στη μελέτη δύο συγκεκριμένων φορτίων: του ηλεκτρικού οχήματος και του κλιματισμού.

Πρόβλεψη αθροιστικού φορτίου ηλεκτρικών οχημάτων (EV)

Για τη φόρτιση των ηλεκτρικών οχημάτων στην περιοχή του Τέξας, παρατηρείται ότι η κατανάλωση ενέργειας συμβαίνει κυρίως σε συγκεκριμένες ώρες της ημέρας, ενώ υπάρχουν και χρονικές περίοδοι με μηδενική κατανάλωση. Στη γενική απόδοση του μοντέλου LSTM για τη φόρτιση των ηλεκτρικών οχημάτων, όπως φαίνεται στο Σχήμα 3.6, το μοντέλο επιτυγχάνει αξιόλογα αποτελέσματα με χαμηλό σφάλμα πρόβλεψης. Το MAE ανέρχεται σε 0,435 kW, υποδεικνύοντας ότι το μοντέλο αποδίδει αρκετά καλά στην πρόβλεψη της κατανάλωσης ενέργειας από ηλεκτρικά οχήματα. Αντίστοιχα στα πλαίσια μιας ημέρας, όπως φαίνεται στο Σχήμα 3.7, το μοντέλο παρουσιάζει επίσης καλή απόδοση στην πρόβλεψη, καταγράφοντας ένα MAE της τάξης του 0,741 kW.



Σχήμα 3.6 : Αθροιστικό φορτίο κατανάλωσης ηλεκτρικών οχημάτων 7 σπιτιών – Αποτελέσματα πρόβλεψης ενός έτους (2018)




Σχήμα 3.7 : Αθροιστικό φορτίο κατανάλωσης ηλεκτρικών οχημάτων 7 σπιτιών – Αποτελέσματα πρόβλεψης μίας ημέρας (2018-02-02)


Πρόβλεψη αθροιστικού φορτίου κλιματισμού (AC)

Για το κλιματιστικό στην περιοχή του Τέξας, η κατανάλωση ενέργειας εμφανίζεται σε ένα ευρύτερο φάσμα τιμών. Όπως φαίνεται στο Σχήμα 3.8, το μοντέλο LSTM έχει επίσης καλή απόδοση στην πρόβλεψη της κατανάλωσης ενέργειας του κλιματισμού (A/C), με το MAE να ανέρχεται σε 1,739 kW. Η απόδοση του μοντέλου είναι συγκρίσιμη με αυτή των EVs, όπως φαίνεται από τα αποτελέσματα στο Σχήμα 3.7. Ωστόσο, αξίζει να σημειωθεί ότι η κατανάλωση ενέργειας από τα κλιματιστικά εμφανίζεται σε μεγαλύτερο εύρος τιμών σε σχέση με τα EVs,

γεγονός που καθιστά την πρόβλεψη πιο απαιτητική. Παρόλα αυτά, το μοντέλο επιτυγχάνει εξίσου αξιόλογη ακρίβεια, με το MAE για τα EVs να κυμαίνεται στο 0,741 kW και για τα A/C στο 0,871 kW.




Σχήμα 3.8 : Αθροιστικό φορτίο κατανάλωσης κλιματισμού 7 σπιτιών – Αποτελέσματα πρόβλεψης ενός έτους (2018)



Σχήμα 3.9 : Αθροιστικό φορτίο κατανάλωσης κλιματισμού 7 σπιτιών – Αποτελέσματα πρόβλεψης μίας ημέρας (2018-11-05)

Πρόβλεψη αθροιστικού φορτίου ηλεκτρικών θερμοσιφώνων (Boiler)

Από το Σχήμα 3.10 σημειώνεται ότι το μοντέλο δεν απέδωσε επιθυμητά για την πρόβλεψη αθροιστικού φορτίου ηλεκτρικών θερμοσιφώνων. Αυτό οφείλεται στη φύση του φορτίου, το οποίο χαρακτηρίζεται από σπάνιες αλλά μεγάλες αιχμές κατανάλωσης που είναι δύσκολο να προβλεφθούν. Η σχετικά σύντομης διάρκειας και ακανόνιστης συχνότητας κατανάλωση ζεστού νερού χρήσης καθιστά δύσκολο τον εντοπισμό και την ακριβή πρόβλεψη αιχμών από το μοντέλο, με αποτέλεσμα τη μειωμένη απόδοση στην πρόβλεψη της κατανάλωσης.



Σχήμα 3.10 : Αθροιστικό φορτίο κατανάλωσης Boiler 7 σπιτιών – Αποτελέσματα πρόβλεψης ενός εξάμηνου (01/07/2018 μέχρι 31/12/2018)

3.3 ΣΥΜΠΕΡΑΣΜΑΤΑ

Η βελτιστοποίηση της απόδοσης του μοντέλου περιλαμβάνει επεκτάσεις στην επιλογή και διαχείριση των δεδομένων εισόδου και την επιλογή των κατάλληλων αλγορίθμων για την αύξηση της ακρίβειας της πρόβλεψης.

- **Ακρίβεια πρόβλεψης:** Η απόδοση των LSTM δικτύων για την πρόβλεψη φορτίου ήταν ικανοποιητική για τα περισσότερα από τα εξεταζόμενα φορτία. Τα αποτελέσματα έδειξαν ότι το μοντέλο ήταν ικανό να προβλέψει με ακρίβεια τη ζήτηση για ηλεκτρικά οχήματα, καθώς αυτή ακολουθεί συγκεκριμένα ιστορικά πρότυπα και επαναλαμβανόμενες τάσεις στη χρήση. Από την άλλη πλευρά, η πρόβλεψη για τον κλιματισμό ήταν πιο δύσκολη, δεδομένου ότι η κατανάλωσή του αλλάζει διαρκώς και δεν παρουσιάζει σταθερές περιόδους κατανάλωσης ή συχνά διαστήματα μηδενικής χρήσης, τις περιόδους του έτους με υψηλή ζήτηση ψύξης. Η πρόβλεψη για το αθροιστικό φορτίο θερμοσιφώνων ήταν λιγότερο ακριβής, λόγω της σύντομης και ακανόνιστης χρήσης του, η οποία χαρακτηρίζεται από σπάνιες αλλά μεγάλες αιχμές που είναι δύσκολο να προβλεφθούν.

- Επίδραση επεκτάσεων: Η προσθήκη χρονικών χαρακτηριστικών στο διάνυσμα εισόδου, όπως η ημέρα της εβδομάδας και ο μήνας, βελτίωσε σημαντικά την απόδοση του μοντέλου. Αυτά τα χαρακτηριστικά επέτρεψαν στο μοντέλο να λάβει υπόψη του χρονικά μοτίβα στη ζήτηση. Συγκρίνοντας με την προηγούμενη εργασία του κ. Παπαλουκά Γιώργου [24], παρατηρήθηκαν σημαντικές βελτιώσεις στην ακρίβεια των προβλέψεων, κυρίως λόγω της προσθήκης αυτών των νέων χαρακτηριστικών και της αλλαγής στον αλγόριθμο επιλογής δεδομένων.
- Εκπαίδευση και δοκιμή: Η χρήση ενός νέου αλγορίθμου για την επιλογή των δεδομένων εκπαίδευσης και δοκιμής (80%-20% τυχαία επιλεγμένα σε όλο το εύρος ημερών/μηνών του dataset) συνέβαλε στην καλύτερη γενίκευση του μοντέλου.

Πίνακας 1.1 : Συγκριτικά αποτελέσματα Μοντέλων Πρόβλεψης

Αθροιστικό Φορτίο	MAAPE [15min]	MAE [15min] [kW]	MAE [15min] [kW] [24]
Κλιματισμός	0,763	1,739	18,717
Ηλεκτρικό όχημα	0,990	0,435	3,27

Συνοψίζοντας, η παρούσα εργασία απέδειξε ότι τα LSTM δίκτυα μπορούν να χρησιμοποιηθούν αποτελεσματικά για την πρόβλεψη της ζήτησης ενέργειας, παρέχοντας πολύτιμα εργαλεία για τη βελτίωση της διαχείρισης των ενεργειακών πόρων. Η ενσωμάτωση νέων χαρακτηριστικών και η βελτίωση της μεθοδολογίας εκπαίδευσης συνέβαλαν σημαντικά στην ακρίβεια των προβλέψεων, καθιστώντας το μοντέλο πιο ευέλικτο και αξιόπιστο.

ΚΕΦΑΛΑΙΟ

4

ΠΟΣΟΤΙΚΟΠΟΙΗΣΗ ΤΗΣ ΕΥΕΛΙΞΙΑΣ

4.1 ΜΟΝΤΕΛΟΠΟΙΗΣΗ

Η παρούσα διπλωματική εργασία επικεντρώνεται στην ποσοτικοποίηση της ευελιξίας των καταναλωτών ηλεκτρικής ενέργειας σε επίπεδο κοινότητας, χρησιμοποιώντας ένα μαθηματικό μοντέλο το οποίο λαμβάνει υπόψη τα δεδομένα κατανάλωσης ηλεκτρικής ενέργειας, τιμολογιακές πολιτικές ηλεκτρικής ενέργειας και το ιστορικό φορτίο. Το μοντέλο αυτό έχει ως αντικειμενική συνάρτηση την ελαχιστοποίηση του ημερήσιου κόστους, βασιζόμενο στην παραδοχή της μέγιστης συμμόρφωσης των τελικών χρηστών στις προτεινόμενες τιμολογιακές πολιτικές, δηλαδή θεωρείται ότι οι καταναλωτές θα προσαρμόσουν/μεταβάλλουν πλήρως τη συμπεριφορά τους με βάση το οικονομικό τους συμφέρον. Επομένως, η παραδοχή αυτή οδηγεί στην μοντελοποίηση και υπολογισμό της μέγιστης δυνατής ευελιξίας που μπορεί να αποκτήσει ένας ΦοΣΕ αθροιστικού οικιακού φορτίου. Το μοντέλο αποτελείται από τρία βασικά μέρη: την πρόβλεψη φορτίου (Forecasting), τον υπολογισμό του βέλτιστου πλάνου ενεργειακής κατανάλωσης, μέσω ενός συστήματος διαχείρισης ενέργειας της κοινότητας (Community EMS), και την ποσοτικοποίηση της ευελιξίας σε ημερήσιο χρονικό ορίζοντα με ωριαία ανάλυση.

1. Πρόβλεψη Φορτίου: Το LSTM δίκτυο χρησιμοποιείται για την πρόβλεψη του μελλοντικού φορτίου. Το συγκεκριμένο δίκτυο είναι ιδιαίτερα κατάλληλο για την επεξεργασία χρονοσειρών, καθώς έχει τη δυνατότητα να διατηρεί και να χρησιμοποιεί πληροφορίες από το παρελθόν (ιστορικά δεδομένα) κατά την πρόβλεψη του μελλοντικού φορτίου. Η διαδικασία πρόβλεψης περιλαμβάνει την ενσωμάτωση της προηγούμενης κρυφής κατάστασης (hidden state) και της προηγούμενης κατάστασης του κυττάρου (cell state), μαζί με την τρέχουσα είσοδο χαρακτηριστικών, για να παραχθεί η πρόβλεψη του φορτίου. Η πρόβλεψη διατηρήθηκε σε ανάλυση 15 λεπτών, όπως περιγράφηκε στο Κεφάλαιο 3.
2. Πλάνο Βέλτιστης Ενεργειακής Κατανάλωσης: Το μαθηματικό μοντέλο δέχεται ως εισόδους τις τρέχουσες τιμές παροχής ηλεκτρικής ενέργειας, το ιστορικό ημερήσιο φορτίο (συνολικό) και τεχνικούς περιορισμούς φόρτισης των ηλεκτρικών οχημάτων σε επίπεδο δεκαπενταλέπτου με βάση τα ιστορικά δεδομένα κατανάλωσης. Σχηματίζεται αντικειμενική συνάρτηση ελαχιστοποίησης ημερήσιου κόστους που οδηγεί στο πλάνο ημερήσιας βέλτιστης κατανάλωσης του αθροιστικού φορτίου ηλεκτρικών οχημάτων της κοινότητας για κάθε δεκαπέντε (15) λεπτά της ημέρας. Ο υπολογισμός αυτός θεωρητικά πραγματοποιείται από ένα σύστημα διαχείρισης

ενέργειας της κοινότητας (Community EMS), το οποίο διαχειρίζεται ένας ΦοΣΕ φορτίου.

3. Ποσοτικοποίηση της Ευελιξίας: Η ευελιξία του συστήματος προκύπτει από την αφαίρεση της προβλεπόμενης ζήτησης από τη βέλτιστη κατανάλωση που υπολογίζεται από το Community EMS. Η ευελιξία αυτή εκφράζεται ως η δυνατότητα του ΦοΣΕ να προσαρμόζει τη ζήτηση σε πραγματικό χρόνο, λαμβάνοντας υπόψη τις διακυμάνσεις στις τιμές της ενέργειας και άλλους εξωτερικούς παράγοντες.

Το βέλτιστο οικονομικά πλάνο φόρτισης της κοινότητας δεν αναφέρεται στις ενέργειες του κάθε οχήματος ούτε στο ποιο όχημα θα φορτίσει μεμονωμένα για να επιτευχθεί αυτό αλλά αντιμετωπίζει τα οχήματα της κοινότητας ως ένα αθροιστικό "εικονικό" όχημα. Η μαθηματική θεμελίωση που αφορά το αθροιστικό ηλεκτρικό όχημα βασίζεται στην αντικειμενική συνάρτηση ελαχιστοποίησης του κόστους φόρτισης του ηλεκτρικού οχήματος [39] (εξίσωση 4.1), όπου C_t είναι το κόστος ηλεκτρικής ενέργειας για την χρονική περίοδο 15 λεπτών t σε βάθος ενός ημερήσιου ορίζοντα $T=96$, με βάση την εκάστοτε τιμολογιακή πολιτική (π.χ. χρεώσεις βάσει χρόνου χρήσης - ToU) και την ισχύ που καταναλώνει το ηλεκτρικό όχημα (EV) σε κάθε χρονική περίοδο t , $P_{EV}(t)$:

$$\min \sum_{t=1}^T C_t P_{EV}(t) \quad (4.1)$$

Όσον αφορά τη μπαταρία του ηλεκτρικού οχήματος, υπάρχουν περιορισμοί που αφορούν την στάθμη φόρτισης (SoC) της μπαταρίας τη χρονική στιγμή t :

$$SoC_{min} \leq SoC(t) \leq SoC_{max}, \quad \forall t \in T \quad (4.2)$$

Στην παρούσα διπλωματική, θεωρήθηκε ότι η μέγιστη δυνατή φόρτιση είναι το 100%.

Η υλοποίηση του παραπάνω μοντέλου υπολογισμού της βέλτιστης κατανάλωσης πραγματοποιήθηκε στην Pyomo [37], μια βιβλιοθήκη ανοιχτού κώδικα βασισμένη στην Python για την επίλυση προβλημάτων βελτιστοποίησης. Η Pyomo χρησιμοποιήθηκε για την ανάπτυξη και την επίλυση του προβλήματος ελαχιστοποίησης του συνολικού κόστους ηλεκτρικής φόρτισης στην κοινότητα.

1. Αλγόριθμος Βελτιστοποίησης: Για την επίλυση του προβλήματος βελτιστοποίησης, χρησιμοποιήθηκε ο αλγόριθμος επίλυσης Simplex [38].
2. Ελαχιστοποίηση Συνολικού Κόστους: Η βασική επιδίωξη του μοντέλου είναι η ελαχιστοποίηση του συνολικού κόστους ηλεκτρικής φόρτισης σε προ-ημερήσιο ορίζοντα, με βάση την προβλεπόμενη κατανάλωση φορτίου ηλεκτρικών οχημάτων. Αυτό επιτυγχάνεται μέσω της βελτιστοποίησης της κατανάλωσης σε σχέση με το κόστος της ηλεκτρικής ενέργειας ανά 15 λεπτά.

3. Περιορισμοί και παραδοχές:

- a. Ο βασικός περιορισμός, αφορά τη συνολική φόρτιση $\sum_{t=1}^{96} P_C(t)$, όπου, μέσα στην ημέρα θα πρέπει να είναι μεγαλύτερη ή ίση με τη συνολική πρόβλεψη του forecaster $\sum_{t=1}^{96} P_F(t)$ για όλα τα $t \in [1, 96]$, όπου πρόκειται για τα 96 15-λεπτα ενός 24ώρου, και δίνεται από την εξίσωση (4.3):

$$\sum_{t=1}^{96} P_C(t) \geq \sum_{t=1}^{96} P_F(t), \quad \forall t \in [1, 96] \quad (4.3)$$

Επειδή στα δεδομένα που χρησιμοποιήθηκαν στα πλαίσια της παρούσας διπλωματικής, δεν υπάρχουν στοιχεία που να αφορούν τα χαρακτηριστικά των μπαταριών των οχημάτων (στάθμη μπαταρίας στην αρχή της ημέρας, μέγιστη στάθμη μπαταρίας ανά όχημα), ορίστηκαν και οι ακόλουθες παραδοχές:

- b. Φραγμός στην ωριαία κατανάλωση, λόγω των αντοχών του φορτιστή, ο οποίος υπολογίζεται με βάση το μέγιστο ιστορικό φορτίο 15 λεπτών, και δίνεται από την εξίσωση (4.4), όπου $P_C(h)$ η ωριαία κατανάλωση και P_F η ιστορική μέγιστη κατανάλωση:

$$P_C(t) \leq \max(P_F), \quad \forall t \in [1, 96] \quad (4.4)$$

- c. Διακριτά επίπεδα φόρτισης των ηλεκτρικών οχημάτων με βάση την ιστορική ωριαία κατανάλωση P_F , σύμφωνα με την εξίσωση (4.5):

$$P_{C-limits} \in [0, \frac{P_F}{2}, P_F] \quad (4.5)$$

- d. Η προβλεπόμενη καταναλισκόμενη ενέργεια ημερησίως αντιστοιχεί σε 100% πλήρη στάθμη φόρτισης της μπαταρίας των οχημάτων ανά ημέρα. Με βάση τη θεώρηση αυτή, απαλλασσόμαστε από την ανάγκη να υπολογίζουμε κάθε φορά τη νέα στάθμη φόρτισης της μπαταρίας, μιας και εξ ορισμού το όχημα καθημερινά θα είναι εκτός τεχνικών ορίων (0-100%) που ορίζονται από την εξίσωση 4.2.

4.2 ΠΕΙΡΑΜΑΤΙΚΗ ΔΙΕΡΕΥΝΗΣΗ

Η πειραματική διερεύνηση που πραγματοποιήθηκε στο πλαίσιο της διπλωματικής εργασίας επικεντρώνεται στην ποσοτικοποίηση της ευελιξίας ΦοΣε που διαχειρίζονται ηλεκτρικά οχήματα, τόσο σε επίπεδο κοινότητας όσο και σε επίπεδο μεμονωμένης οικίας. Σκοπός της διερεύνησης αυτής είναι να κατανοηθεί πώς μπορεί να βελτιωθεί η ενεργειακή αποδοτικότητα και να μειωθεί το κόστος κατανάλωσης, βασιζόμενοι σε πρόβλεψη της κατανάλωσης φορτίου με χρήση μηχανικής μάθησης.

4.2.1 Δεδομένα και Παραδοχές

Η ανάλυση που περιγράφεται στη συγκεκριμένη παράγραφο επικεντρώνεται στη χρήση δεδομένων για τη διερεύνηση της κατανάλωσης ενέργειας από οικιακές συσκευές, με έμφαση στα ηλεκτρικά οχήματα (EVs). Τα δεδομένα αυτά βασίζονται σε ιστορικές καταγραφές κατανάλωσης ενέργειας και συλλέγονται με υψηλή χρονική ανάλυση, συγκεκριμένα με διαστήματα 15 λεπτών. Αυτός ο τρόπος συλλογής παρέχει 96 παρατηρήσεις ανά ημέρα, επιτρέποντας την εις βάθος ανάλυση της κατανάλωσης ενέργειας σε διάφορες χρονικές περιόδους. Η χρήση ιστορικών δεδομένων επιτρέπει την κατανόηση των μοτίβων κατανάλωσης και των διακυμάνσεων που παρουσιάζονται μέσα στην ημέρα. Η επιλογή των συγκεκριμένων οικιακών συσκευών, όπως τα κλιματιστικά και τα ηλεκτρικά οχήματα, δικαιολογείται από την αυξημένη ζήτηση ενέργειας που σχετίζεται με τη λειτουργία τους, ιδίως σε περιόδους αιχμής. Τα δεδομένα τιμών ενέργειας, τα οποία ποικίλλουν ανάλογα με την τιμολογιακή πολιτική, ενσωματώνονται επίσης στην ανάλυση, καθιστώντας δυνατό τον υπολογισμό του κόστους και της απόδοσης της κατανάλωσης ενέργειας υπό διαφορετικά σενάρια. Οι παραδοχές που διατυπώνονται για την ανάλυση περιλαμβάνουν τα εξής:

- Τη μέγιστη συμμόρφωση του καταναλωτή, δηλαδή την ικανότητα του καταναλωτή να προσαρμόζει τη χρήση ενέργειας με βάση τις εξωτερικές συνθήκες και τιμές, και τη συνεχή διαθεσιμότητα του φορτίου για ευέλικτη κατανάλωση. Η μέγιστη συμμόρφωση υπονοεί ότι οι καταναλωτές είναι πλήρως διατεθειμένοι να αλλάξουν τη συμπεριφορά κατανάλωσής τους, προκειμένου να εκμεταλλευτούν ευνοϊκές τιμές ενέργειας ή να μειώσουν το κόστος κατανάλωσης. Η συνεχής διαθεσιμότητα του φορτίου αναφέρεται στην προϋπόθεση ότι οι οικιακές συσκευές είναι πάντοτε διαθέσιμες για χρήση με τρόπο που επιτρέπει τη μέγιστη δυνατή ευελιξία στη ζήτηση ενέργειας.
- Τον ορισμό της ευελιξίας ορίζοντας ως ανοδική (upward flexibility) αυτή που θα προσφερθεί μέσω μείωσης της κατανάλωσης και αντίστοιχα ως καθοδική (downward flexibility) θεωρείται αυτή που θα προσφερθεί από αύξηση της κατανάλωσης.
- Οι ημέρες με τη μεγαλύτερη ιστορικά κατανάλωση ενέργειας (ημέρες αιχμής) επιλέγονται για την αξιολόγηση, προκειμένου να εκτιμηθεί η μέγιστη δυνατή ευελιξία σε ρεαλιστικά σενάρια. Αυτή η μέθοδος επιτρέπει καλύτερη κατανόηση της διαφοροποίησης της κατανάλωσης ενέργειας κατά τις κρίσιμες χρονικές περιόδους και του τρόπου με τον οποίο οι καταναλωτές μπορούν να συμβάλουν στην εξισορρόπηση της ζήτησης και προσφοράς σε επίπεδο δικτύου.
- Χρησιμοποιήθηκαν τιμές χρέωσης βάσει χρόνου χρήσης (Time of Use) ως αναφορά για τη βασική μοντελοποίηση. Όπως φαίνεται στον Πίνακα 4.1, παρουσιάζονται διάφορες τιμολογιακές πολιτικές, συμπεριλαμβανομένης της βασικής πολιτικής ToU που χρησιμοποιήθηκε στην ανάλυση. Οι τιμές ήταν σε δολάρια και μετατράπηκαν σε ευρώ με ισοτιμία 0,91 ευρώ ανά 1 δολάριο.

Πίνακας 4.1 : Τιμολογιακές Πολιτικές για το 2023, Austin (Χονδρική και Λιανική) [40]

	Real-Time		Time of Use (ToU)		Critical	
Ημέρα	Χονδρική [Ευρώ / kWh]	Λιανική [Ευρώ / kWh]	Χονδρική [Ευρώ / kWh]	Λιανική [Ευρώ / kWh]	Χονδρική [Ευρώ / kWh]	Λιανική [Ευρώ / kWh]
0:00	0,136	0,170	0,120	0,150	0,120	0,150
0:15	0,161	0,202	0,120	0,150	0,120	0,150
0:30	0,157	0,197	0,120	0,150	0,120	0,150
0:45	0,166	0,207	0,120	0,150	0,120	0,150
1:00	0,126	0,158	0,120	0,150	0,120	0,150
1:15	0,171	0,213	0,120	0,150	0,120	0,150
1:30	0,128	0,160	0,120	0,150	0,120	0,150
1:45	0,162	0,203	0,120	0,150	0,120	0,150
2:00	0,164	0,205	0,120	0,150	0,120	0,150
2:15	0,158	0,198	0,120	0,150	0,120	0,150
2:30	0,166	0,207	0,120	0,150	0,120	0,150
2:45	0,153	0,191	0,120	0,150	0,120	0,150
3:00	0,176	0,220	0,120	0,150	0,120	0,150
3:15	0,123	0,153	0,120	0,150	0,120	0,150
3:30	0,172	0,215	0,120	0,150	0,120	0,150
3:45	0,170	0,213	0,120	0,150	0,120	0,150
4:00	0,142	0,178	0,120	0,150	0,120	0,150
4:15	0,159	0,199	0,120	0,150	0,120	0,150
4:30	0,149	0,186	0,120	0,150	0,120	0,150
4:45	0,169	0,212	0,120	0,150	0,120	0,150
5:00	0,144	0,179	0,120	0,150	0,120	0,150
5:15	0,122	0,153	0,120	0,150	0,120	0,150
5:30	0,135	0,169	0,120	0,150	0,120	0,150
5:45	0,122	0,152	0,120	0,150	0,120	0,150
6:00	0,125	0,156	0,140	0,175	0,120	0,150
6:15	0,167	0,209	0,140	0,175	0,120	0,150
6:30	0,175	0,219	0,140	0,175	0,120	0,150
6:45	0,155	0,194	0,140	0,175	0,120	0,150
7:00	0,138	0,173	0,140	0,175	0,120	0,150
7:15	0,155	0,193	0,140	0,175	0,120	0,150
7:30	0,173	0,216	0,140	0,175	0,120	0,150
7:45	0,129	0,161	0,140	0,175	0,120	0,150
8:00	0,154	0,193	0,140	0,175	0,120	0,150
8:15	0,128	0,160	0,140	0,175	0,120	0,150
8:30	0,126	0,157	0,140	0,175	0,120	0,150
8:45	0,160	0,200	0,140	0,175	0,120	0,150
9:00	0,131	0,164	0,140	0,175	0,120	0,150
9:15	0,154	0,193	0,140	0,175	0,120	0,150
9:30	0,159	0,199	0,140	0,175	0,120	0,150

Πίνακας 4.1 : Τιμολογιακές Πολιτικές για το 2023, Austin (Χονδρική και Λιανική) [40]
(συνέχεια)


	Real-Time		Time of Use (ToU)		Critical	
Ημέρα	Χονδρική [Ευρώ / kWh]	Λιανική [Ευρώ / kWh]	Χονδρική [Ευρώ / kWh]	Λιανική [Ευρώ / kWh]	Χονδρική [Ευρώ / kWh]	Λιανική [Ευρώ / kWh]
9:45	0,156	0,195	0,140	0,175	0,120	0,150
10:00	0,170	0,212	0,140	0,175	0,120	0,150
10:15	0,126	0,158	0,140	0,175	0,120	0,150
10:30	0,155	0,193	0,140	0,175	0,120	0,150
10:45	0,125	0,156	0,140	0,175	0,120	0,150
11:00	0,175	0,219	0,140	0,175	0,120	0,150
11:15	0,137	0,172	0,140	0,175	0,120	0,150
11:30	0,149	0,186	0,140	0,175	0,120	0,150
11:45	0,149	0,186	0,140	0,175	0,120	0,150
12:00	0,176	0,220	0,140	0,175	0,120	0,150
12:15	0,154	0,192	0,140	0,175	0,120	0,150
12:30	0,150	0,187	0,140	0,175	0,120	0,150
12:45	0,142	0,177	0,140	0,175	0,120	0,150
13:00	0,125	0,156	0,140	0,175	0,120	0,150
13:15	0,175	0,219	0,140	0,175	0,120	0,150
13:30	0,140	0,175	0,140	0,175	0,120	0,150
13:45	0,155	0,194	0,140	0,175	0,120	0,150
14:00	0,144	0,181	0,140	0,175	0,120	0,150
14:15	0,178	0,222	0,140	0,175	0,120	0,150
14:30	0,170	0,212	0,140	0,175	0,120	0,150
14:45	0,160	0,200	0,140	0,175	0,120	0,150
15:00	0,160	0,200	0,140	0,175	0,120	0,150
15:15	0,135	0,169	0,140	0,175	0,120	0,150
15:30	0,173	0,216	0,140	0,175	0,120	0,150
15:45	0,139	0,174	0,140	0,175	0,120	0,150
16:00	0,160	0,200	0,140	0,175	0,500	0,625
16:15	0,141	0,177	0,140	0,175	0,500	0,625
16:30	0,159	0,199	0,140	0,175	0,500	0,625
16:45	0,165	0,206	0,140	0,175	0,500	0,625
17:00	0,120	0,150	0,140	0,175	0,500	0,625
17:15	0,124	0,155	0,140	0,175	0,500	0,625
17:30	0,159	0,198	0,140	0,175	0,500	0,625
17:45	0,152	0,191	0,140	0,175	0,500	0,625
18:00	0,165	0,206	0,140	0,175	0,500	0,625
18:15	0,139	0,173	0,140	0,175	0,500	0,625
18:30	0,134	0,167	0,140	0,175	0,500	0,625
18:45	0,158	0,197	0,140	0,175	0,500	0,625
19:00	0,174	0,218	0,140	0,175	0,500	0,625

Πίνακας 4.1 : Τιμολογιακές Πολιτικές για το 2023, Austin (Χονδρική και Λιανική) [40]
(συνέχεια)

	Real-Time		Time of Use (ToU)		Critical	
Ημέρα	Χονδρική [Ευρώ / kWh]	Λιανική [Ευρώ / kWh]	Χονδρική [Ευρώ / kWh]	Λιανική [Ευρώ / kWh]	Χονδρική [Ευρώ / kWh]	Λιανική [Ευρώ / kWh]
19:15	0,157	0,196	0,140	0,175	0,500	0,625
19:30	0,125	0,156	0,140	0,175	0,500	0,625
19:45	0,139	0,173	0,140	0,175	0,500	0,625
20:00	0,180	0,225	0,140	0,175	0,120	0,150
20:15	0,123	0,153	0,140	0,175	0,120	0,150
20:30	0,130	0,162	0,140	0,175	0,120	0,150
20:45	0,164	0,205	0,140	0,175	0,120	0,150
21:00	0,145	0,181	0,140	0,175	0,120	0,150
21:15	0,152	0,190	0,140	0,175	0,120	0,150
21:30	0,121	0,151	0,140	0,175	0,120	0,150
21:45	0,161	0,201	0,140	0,175	0,120	0,150
22:00	0,153	0,191	0,120	0,150	0,120	0,150
22:15	0,158	0,197	0,120	0,150	0,120	0,150
22:30	0,174	0,217	0,120	0,150	0,120	0,150
22:45	0,131	0,163	0,120	0,150	0,120	0,150
23:00	0,145	0,182	0,120	0,150	0,120	0,150
23:15	0,135	0,169	0,120	0,150	0,120	0,150
23:30	0,173	0,216	0,120	0,150	0,120	0,150
23:45	0,152	0,190	0,120	0,150	0,120	0,150

4.2.2 Ποσοτικοποίηση Ευελιξίας με Άξονα την Κοινότητα

Η ανάλυση της ευελιξίας σε επίπεδο κοινότητας επικεντρώνεται στην ιδέα ότι η κατανάλωση ενέργειας από μεμονωμένα φορτία πολλαπλών οικιών μπορεί να αντιμετωπιστεί ως μια ενιαία μονάδα. Με αυτόν τον τρόπο, η ευελιξία της συνολικής κατανάλωσης μπορεί να αξιοποιηθεί για την εξισορρόπηση της ζήτησης από ένα ΦοΣΕ και την εξοικονόμηση ενέργειας για τα μέλη της κοινότητας. Η διαδικασία ποσοτικοποίησης της ευελιξίας ξεκινά με τη συλλογή και συγκέντρωση των φορτίων από αυτές τις οικίες. Το συνολικό φορτίο, δηλαδή η συνολική κατανάλωση ενέργειας της κοινότητας, προβλέπεται μέσω της χρήσης LSTM δικτύων, τα οποία είναι εργαλεία μηχανικής μάθησης σχεδιασμένα να αναγνωρίζουν και να μαθαίνουν από τα μοτίβα κατανάλωσης ενέργειας.



Σχήμα 4.1 : Διάγραμμα ροής του μοντέλου ποσοτικοποίησης ευελιξίας φορτίου με άξονα την κοινότητα

Τα LSTM δίκτυα λαμβάνουν υπόψη εποχικά και ημερήσια χαρακτηριστικά, που προκύπτουν από τις συνήθειες των κατοίκων, για να προβλέψουν την κατανάλωση ενέργειας με ακρίβεια. Αυτή η πρόβλεψη της κατανάλωσης χρησιμεύει ως βάση για την επίλυση ενός προβλήματος βελτιστοποίησης. Για την επίλυση αυτού του προβλήματος χρησιμοποιείται ο αλγόριθμος Simplex, ο οποίος επιτρέπει τον υπολογισμό της βέλτιστης κατανομής του φορτίου. Η βέλτιστη κατανομή του φορτίου αναφέρεται στον ιδανικό τρόπο με τον οποίο θα πρέπει να κατανεμηθεί η κατανάλωση ενέργειας μέσα στην ημέρα, προκειμένου να ελαχιστοποιηθεί το κόστος ή να μεγιστοποιηθεί η αποδοτικότητα του δικτύου. Η βελτιστοποίηση γίνεται σε ημερήσιο ορίζοντα με 96 διαστήματα απόφασης, ένα για κάθε διάστημα 15 λεπτών της ημέρας. Η ευελιξία που προκύπτει υπολογίζεται ως η διαφορά μεταξύ της προβλεπόμενης κατανάλωσης (δηλαδή της κατανάλωσης που θα συνέβαινε χωρίς βελτιστοποίηση) και του πλάνου βέλτιστης κατανάλωσης, το οποίο θεωρείται ότι θα ακολουθηθεί πιστά από τους καταναλωτές. Αυτή η διαφορά αντιπροσωπεύει το ποσό ενέργειας που μπορεί να μειωθεί ή να μετακινηθεί σε διαφορετικές χρονικές περιόδους, δίνοντας ένα σαφές μέτρο της μέγιστης ευελιξίας του αθροιστικού φορτίου που ελέγχει ο ΦοΣΕ. Ο αλγόριθμος που περιγράφηκε παραπάνω, για το community EMS υλοποιήθηκε σε γλώσσα Python με χρήση της βιβλιοθήκης Pyomo, όπως φαίνεται στο Σχήμα 4.2.

```

from pyomo.environ import *
solverpath_folder=r"Z:\...\glpk\w64\" #does not need to be directly on c drive
solverpath_exe=r"Z:\Temp\...\glpk\w64\glpsol\" #does not need to be directly on c drive

# Δημιουργία μοντέλου
model = ConcreteModel()

# Σετ ωρών
hours = [ '0:00', '0:15', '0:30', '0:45', ..., '23:00', '23:15', '23:30', '23:45' ]

# Μέγιστες ποσότητες φόρτισης για κάθε ώρα (προσομοιωτικές τιμές)
max_charge = { '0:00': 67.736, '0:15': 67.736, '0:30': 67.736, ..., '23:15': 67.736, '23:30': 67.736, '23:45': 67.736 }

# Πρόβλεψη κατανάλωσης ενέργειας ανά ώρα (προσομοιωτικές τιμές)
forecast_consumption = { '0:00': 57.394, '0:15': 64.125, '0:30': 55.266, ..., '23:15': 61.856, '23:30': 63.371, '23:45': 59.336 }

# Τιμές ηλεκτρικής ενέργειας για κάθε ώρα (προσομοιωτικές τιμές)
electricity_price = { '0:00': 0.175, '0:15': 0.175, '0:30': 0.175, ..., '23:15': 0.175, '23:30': 0.175, '23:45': 0.175 }

# Μεταβλητές αποφάσεων
# Community
model.charge = Var(hours, within=[0, 3.34, 6.681])

# Συνάρτηση κόστους
def cost_function(model):
    return sum(model.charge[h] * electricity_price[h] for h in hours)

model.cost = Objective(rule=cost_function, sense=minimize)

# Περιορισμοί (Θραγκός στην ωριαία κατανάλωση - Αντοχές φορτιστή)
def charge_constraint_rule(model, h):
    return model.charge[h] <= max_charge[h]

model.charge_constraint = Constraint(hours, rule=charge_constraint_rule)

# Συνολική κατανάλωση
def total_consumption_constraint(model):
    return sum(model.charge[h] for h in hours) == sum(forecast_consumption[h] for h in hours)

model.total_consumption_constraint = Constraint(rule=total_consumption_constraint)\n",

# Επίλυση
import sys
solvername='glpk'

sys.path.append(solverpath_folder)
solver=SolverFactory(solvername,executable=solverpath_exe)

# solver = SolverFactory('glpk')\n",
results = solver.solve(model)

# Εκτύπωση αποτελεσμάτων\n",
# Check if the model has been successfully solved
if results.solver.status == SolverStatus.ok and results.solver.termination_condition == TerminationCondition.optimal:
    # Print the values of the decision variables
    for h in hours:
        print(model.charge[h].value)
    print("\nTotal cost:\n", model.cost())
else:
    print("\nSolver did not find an optimal solution.\n")

```

Σχήμα 4.2 : Αλγόριθμος υλοποίησης community EMS σε γλώσσα Python (Pyomo)

Η πειραματική προσέγγιση πραγματοποιήθηκε σε επίπεδο κοινότητας, η οποία αποτελούνταν από 7 οικίες, με βάση τα δεδομένα που παρουσιάζονται στον πίνακα 4.2. Τα διακριτά επίπεδα φόρτισης προέκυψαν από την ανάλυση ιστορικών δεδομένων κατανάλωσης ενέργειας. Πιο συγκεκριμένα, η μέγιστη τιμή φόρτισης, για τον "εικονικό φορτιστή", υπολογίστηκε ως το μέγιστο του μέσου όρου της κατανάλωσης ανά ώρα σε διάστημα ενός έτους. Ο όρος "εικονικός φορτιστής" χρησιμοποιείται επειδή δεν υπάρχουν διαθέσιμες προδιαγραφές για τους επιμέρους φορτιστές στα δεδομένα που χρησιμοποιήθηκαν.

Πίνακας 4.2 : Όρια φορτιστή σε επίπεδο κοινότητας

Μέγιστο Pf [kW]	Στάθμες Φόρτισης [kW]
6.681	[0, 3.34, 6.68]

Τα αποτελέσματα ποσοτικοποίησης της ευελιξίας του φορτίου της ηλεκτροκίνησης της κοινότητας παρουσιάζονται παρακάτω, ενδεικτικά για μια ημέρα (22/8/2018).

Πίνακας 4.3 : Πειραματικά αποτελέσματα ποσοτικοποίησης ευελιξίας ηλεκτρικών οχημάτων σε επίπεδο κοινότητας για την ημέρα 22/8/2018

15-λεπτο (στιγμή εκκίνησης)	Πλάνο βέλτιστης κατανάλωσης [kW]	Πρόβλεψη κατανάλωσης [kW]	Ανοδική ευελιξία (πρόταση μείωσης κατανάλωσης) [kW]	Καθοδική ευελιξία (πρόταση αύξησης κατανάλωσης) [kW]
0:00	3,30	3,36	0,06	0,00
0:15	3,30	3,36	0,06	0,00
0:30	3,30	5,02	1,72	0,00
0:45	3,30	6,68	3,38	0,00
1:00	3,30	6,68	3,38	0,00
1:15	3,30	6,65	3,35	0,00
1:30	3,30	6,66	3,36	0,00
1:45	3,30	6,66	3,36	0,00
2:00	3,30	6,68	3,38	0,00
2:15	3,30	6,68	3,38	0,00
2:30	3,30	6,66	3,36	0,00
2:45	3,30	6,38	3,08	0,00
3:00	3,30	6,52	3,22	0,00
3:15	3,30	5,30	2,00	0,00
3:30	3,30	3,35	0,05	0,00
3:45	3,30	3,35	0,05	0,00
4:00	3,30	3,35	0,05	0,00
4:15	3,30	3,22	0,00	0,08
4:30	3,30	0,80	0,00	2,51
4:45	3,30	0,00	0,00	3,30
5:00	3,30	0,11	0,00	3,19
5:15	3,30	1,60	0,00	1,71
5:30	3,30	0,00	0,00	3,30
5:45	3,30	0,00	0,00	3,30
6:00	3,30	0,00	0,00	3,30
6:15	3,30	1,05	0,00	2,25
6:30	3,30	3,40	0,10	0,00
6:45	3,30	3,40	0,10	0,00
7:00	3,30	3,39	0,09	0,00
7:15	3,30	3,55	0,25	0,00
7:30	3,30	4,06	0,76	0,00
7:45	3,30	3,39	0,09	0,00
8:00	3,30	3,40	0,10	0,00
8:15	3,30	4,36	1,06	0,00
8:30	3,30	3,61	0,31	0,00
8:45	3,30	3,40	0,10	0,00
9:00	3,30	3,40	0,10	0,00


Πίνακας 4.3 : Πειραματικά αποτελέσματα ποσοτικοποίησης ευελιξίας ηλεκτρικών οχημάτων σε επίπεδο κοινότητας για την ημέρα 22/8/2018 (συνέχεια)

15-λεπτο (στιγμή εκκίνησης)	Πλάνο βέλτιστης κατανάλωσης [kW]	Πρόβλεψη κατανάλωσης [kW]	Ανοδική ευελιξία (πρόταση μείωσης κατανάλωσης) [kW]	Καθοδική ευελιξία (πρόταση αύξησης κατανάλωσης) [kW]
9:15	3,30	3,39	0,09	0,00
9:30	3,30	3,38	0,08	0,00
9:45	3,30	3,51	0,21	0,00
10:00	3,30	3,80	0,50	0,00
10:15	3,30	3,39	0,09	0,00
10:30	3,30	3,26	0,00	0,04
10:45	3,30	1,55	0,00	1,75
11:00	3,30	0,87	0,00	2,43
11:15	3,30	0,83	0,00	2,48
11:30	3,30	0,81	0,00	2,49
11:45	3,30	0,81	0,00	2,49
12:00	0,00	0,80	0,80	0,00
12:15	2,63	0,80	0,00	1,84
12:30	3,30	0,80	0,00	2,50
12:45	3,30	4,04	0,74	0,00
13:00	3,30	4,15	0,85	0,00
13:15	3,30	4,14	0,84	0,00
13:30	3,30	2,47	0,00	0,84
13:45	3,30	0,52	0,00	2,78
14:00	0,00	0,08	0,08	0,00
14:15	0,00	0,38	0,38	0,00
14:30	0,00	0,07	0,07	0,00
14:45	0,00	0,08	0,08	0,00
15:00	0,00	0,36	0,36	0,00
15:15	0,00	0,07	0,07	0,00
15:30	0,00	0,07	0,07	0,00
15:45	0,00	0,17	0,17	0,00
16:00	0,00	0,26	0,26	0,00
16:15	0,00	0,07	0,07	0,00
16:30	0,00	0,07	0,07	0,00
16:45	0,00	0,00	0,00	0,00
17:00	0,00	0,00	0,00	0,00
17:15	0,00	2,84	2,84	0,00
17:30	0,00	3,35	3,35	0,00
17:45	0,00	1,51	1,51	0,00
18:00	0,00	0,62	0,62	0,00
18:15	0,00	0,08	0,08	0,00

Πίνακας 4.3 : Πειραματικά αποτελέσματα ποσοτικοποίησης ευελιξίας ηλεκτρικών οχημάτων σε επίπεδο κοινότητας για την ημέρα 22/8/2018 (συνέχεια)

15-λεπτο (στιγμή εκκίνησης)	Πλάνο βέλτιστης κατανάλωσης [kW]	Πρόβλεψη κατανάλωσης [kW]	Ανοδική ευελιξία (πρόταση μείωσης κατανάλωσης) [kW]	Καθοδική ευελιξία (πρόταση αύξησης κατανάλωσης) [kW]
18:30	0,00	0,45	0,45	0,00
18:45	0,00	0,08	0,08	0,00
19:00	0,00	0,09	0,09	0,00
19:15	0,00	0,47	0,47	0,00
19:30	0,00	0,07	0,07	0,00
19:45	0,00	0,30	0,30	0,00
20:00	0,00	0,34	0,34	0,00
20:15	0,00	0,07	0,07	0,00
20:30	0,00	0,42	0,42	0,00
20:45	0,00	0,07	0,07	0,00
21:00	0,00	0,07	0,07	0,00
21:15	0,00	0,48	0,48	0,00
21:30	0,00	0,00	0,00	0,00
21:45	0,00	0,00	0,00	0,00
22:00	3,30	0,00	0,00	3,30
22:15	3,30	0,00	0,00	3,30
22:30	3,30	0,00	0,00	3,30
22:45	3,30	0,00	0,00	3,30
23:00	3,30	0,82	0,00	2,48
23:15	3,30	3,33	0,03	0,00
23:30	3,30	3,36	0,06	0,00
23:45	3,30	3,99	0,69	0,00

Γραφική απεικόνιση των αποτελεσμάτων για την ημέρα 22/8/2018



Σχήμα 4.3 : Ευελιξία ηλεκτρικών οχημάτων σε επίπεδο κοινότητας (σε επίπεδο μίας ημέρας - 22/8/2018)

Τα αποτελέσματα αυτής της προσέγγισης δείχνουν ότι η ευελιξία σε επίπεδο κοινότητας μπορεί να οδηγήσει σε σημαντική εξοικονόμηση κόστους.

Σύμφωνα με το Σχήμα 4.3, παρατηρούμε ότι αναμένεται μεγαλύτερη μετακίνηση του φορτίου από το χρονικό διάστημα 00:30 έως 03:15 καθώς και από το χρονικό διάστημα 14:00 έως 21:15, στα χρονικά διαστήματα 4:30 έως 06:15 και 10:45 έως 12:30, όπου η ζήτηση είναι χαμηλότερη και αντίστοιχα το κόστος μικρότερο. Αυτή η μετακίνηση επιτρέπει την αποφυγή της κατανάλωσης κατά τις ώρες αιχμής, γεγονός που συνεπάγεται εξοικονόμηση κόστους για την κοινότητα καθώς και αποσυμφόρηση του δικτύου διανομής. Η διαδικασία αυτή βασίζεται στα ιστορικά στοιχεία κατανάλωσης και την προβλεπόμενη ζήτηση, με σκοπό την ορθολογική διαχείριση της ενέργειας.


4.2.3 Ποσοτικοποίηση Ευελιξίας με Άξονα την Κάθε Οικία

Η ποσοτικοποίηση της ευελιξίας σε επίπεδο οικίας επικεντρώνεται στην ανάλυση της ενεργειακής κατανάλωσης και στη δυνατότητα πρόβλεψης των φορτίων για μεμονωμένες οικίες. Σε αυτή την προσέγγιση, κάθε οικία αντιμετωπίζεται ως μια ανεξάρτητη μονάδα κατανάλωσης, γεγονός που επιτρέπει τη λεπτομερή εξέταση των ιδιαίτερων χαρακτηριστικών και των προτύπων κατανάλωσης της κάθε οικίας. Η πρόβλεψη της κατανάλωσης πραγματοποιείται μέσω των δικτύων LSTM, τα οποία αναγνωρίζουν και μαθαίνουν από ιστορικά δεδομένα κατανάλωσης της εκάστοτε οικίας, μέσω κατάλληλης εκπαίδευσης. Η αρχιτεκτονική των LSTM δικτύων για την περίπτωση ανάλυσης με άξονα την κάθε οικία είναι η ίδια με τα LSTM δίκτυα για την ανάλυση με άξονα την κοινότητα.

Μετά την πρόβλεψη της κατανάλωσης για κάθε οικία, εφαρμόζεται ανάλυση βελτιστοποίησης με στόχο την ελαχιστοποίηση του ημερήσιου κόστους κατανάλωσης

ηλεκτρικής ενέργειας του επιλεγμένου φορτίου, ανά οικία. Αυτό σημαίνει ότι αναζητείται ο τρόπος με τον οποίο η ενέργεια μπορεί να κατανεμηθεί καλύτερα μέσα στην ημέρα για να επιτευχθεί μέγιστη μείωση του κόστους κατανάλωσης ενέργειας. Η διαδικασία αυτή αποκαλύπτει ότι η ευελιξία κάθε οικίας μπορεί να ποικίλλει σημαντικά, ανάλογα με τον τύπο των συσκευών που χρησιμοποιούνται, τις συνήθειες των κατοίκων και τις περιβαλλοντικές συνθήκες.

Τέλος, υπολογίζεται η ευελιξία της κοινότητας, αλλά αυτή τη φορά αθροίζοντας την επιμέρους ευελιξία των οικιών που την απαρτίζουν, όπως φαίνεται και στο Σχήμα 4.4. Κάθε οικία χρησιμοποιεί προβλέψεις (forecasting) βασισμένες στην κατανάλωση φορτίου ηλεκτρικών οχημάτων (EV load) και τις τιμές ενέργειας, σε συνδυασμό με ένα Σύστημα Διαχείρισης Ενέργειας Οικιακής (HEMS), που βελτιστοποιεί τη χρήση της ενέργειας. Η επιμέρους ευελιξία κάθε οικίας υπολογίζεται χωριστά, και στη συνέχεια, όλες οι επιμέρους ευελιξίες αθροίζονται για να προσδιοριστεί η συνολική ευελιξία της κοινότητας. Αυτό επιτρέπει τη βελτίωση της συνολικής ενεργειακής διαχείρισης και τη μείωση του κόστους σε επίπεδο κοινότητας, ενώ παράλληλα λαμβάνει υπόψη τις ιδιαιτερότητες κάθε οικίας.



Σχήμα 4.4 : Διάγραμμα ροής του μοντέλου Ποσοτικοποίησης Ευελιξίας Φορτίου με άξονα την κάθε οικία

Ο αλγόριθμος που περιεγράφηκε παραπάνω, για το εκάστοτε HEMS υλοποιήθηκε σε γλώσσα Python με χρήση της βιβλιοθήκης Pyomo, όπως φαίνεται στο Σχήμα 4.5.

```

from pyomo.environ import *
solverpath_folder=r"Z:\...\glpk\w64\" #does not need to be directly on c drive
solverpath_exe=r"Z:\Temp\...\glpk\w64\glpsol\" #does not need to be directly on c drive

# Δημιουργία μοντέλου
model = ConcreteModel()

# Σετ ωρών
hours = [ '0:00', '0:15', '0:30', '0:45', ..., '23:00', '23:15', '23:30', '23:45' ]

# Μέγιστες ποσότητες φόρτισης για κάθε ώρα (προσομοιωτικές τιμές)
max_charge = { '0:00': 67.736, '0:15': 67.736, '0:30': 67.736, ..., '23:15': 67.736, '23:30': 67.736, '23:45': 67.736 }

# Πρόβλεψη κατανάλωσης ενέργειας ανά ώρα (προσομοιωτικές τιμές)
forecast_consumption = { '0:00': 57.394, '0:15': 64.125, '0:30': 55.266, ..., '23:15': 61.856, '23:30': 63.371, '23:45': 59.336 }

# Τιμές ηλεκτρικής ενέργειας για κάθε ώρα (προσομοιωτικές τιμές)
electricity_price = { '0:00': 0.175, '0:15': 0.175, '0:30': 0.175, ..., '23:15': 0.175, '23:30': 0.175, '23:45': 0.175 }

# Μεταβλητές αποφάσεων
# 661
model.charge = Var(hours, within=[0, 1.708, 3.416])

# Συνάρτηση κόστους
def cost_function(model):
    return sum(model.charge[h] * electricity_price[h] for h in hours)

model.cost = Objective(rule=cost_function, sense=minimize)

# Περιορισμοί (Θραγκός στην ωριαία κατανάλωση - Αντοχές φορτιστή)
def charge_constraint_rule(model, h):
    return model.charge[h] <= max_charge[h]

model.charge_constraint = Constraint(hours, rule=charge_constraint_rule)

# Συνολική κατανάλωση
def total_consumption_constraint(model):
    return sum(model.charge[h] for h in hours) == sum(forecast_consumption[h] for h in hours)

model.total_consumption_constraint = Constraint(rule=total_consumption_constraint)\n",

# Επίλυση
import sys
solvername='glpk'

sys.path.append(solverpath_folder)
solver=SolverFactory(solvername,executable=solverpath_exe)

# solver = SolverFactory('glpk')\n",
results = solver.solve(model)

# Εκτύπωση αποτελεσμάτων\n",
# Check if the model has been successfully solved
if results.solver.status == SolverStatus.ok and results.solver.termination_condition == TerminationCondition.optimal:
    # Print the values of the decision variables
    for h in hours:
        print(model.charge[h].value)
    print("\nTotal cost:", model.cost())
else:
    print("\nSolver did not find an optimal solution.\n")

```

Σχήμα 4.5 : Αλγόριθμος υλοποίησης HEMS (για το σπίτι με id: 661 σε γλώσσα Python (Pyomo))

Η πειραματική προσέγγιση έγινε σε επίπεδο οικίας, με βάση τον πίνακα 4.4, για τα επίπεδα φόρτισης ανά οικία, όπως προκύπτουν από την ανάλυση ιστορικών δεδομένων κατανάλωσης ενέργειας. Πιο συγκεκριμένα, η μέγιστη τιμή φόρτισης, για τον "εικονικό φορτιστή", υπολογίστηκε ως το μέγιστο της κατανάλωσης ανά οικία και ανά ώρα σε διάστημα ενός έτους. Ο όρος "εικονικός φορτιστής" χρησιμοποιείται επειδή δεν υπάρχουν διαθέσιμες προδιαγραφές για τους επιμέρους φορτιστές στα δεδομένα που χρησιμοποιήθηκαν.


Πίνακας 4.4 : Όρια φορτιστών ανά οικία

Ταυτότητα Σπιτιού	Μέγιστο Pf [kW]	Στάθμες Φόρτισης [kW]
661	3.42	[0.00, 1.71, 3.42]
1642	4.29	[0.00, 2.15, 4.29]
4373	4.00	[0.00, 2.00, 4.00]
4767	7.99	[0.00, 3.99, 7.99]
6139	3.56	[0.00, 1.78, 3.56]

Πίνακας 4.4 : Όρια φορτιστών ανά οικία (συνέχεια)

Ταυτότητα Σπιτιού	Μέγιστο Pf [kW]	Στάθμες Φόρτισης [kW]
7719	3.32	[0.00, 1.66, 3.32]
8156	4.00	[0.00, 2.00, 4.00]

Τα αποτελέσματα που προέκυψαν, για μία οικία (ID: 661), ενδεικτικά για μία ημέρα, είναι τα ακόλουθα:

**Σχήμα 4.6 :** Ευελιξία ηλεκτρικού οχήματος σε επίπεδο οικίας (ID: 661, σε επίπεδο μίας ημέρας - 25/8/2018)**Πίνακας 4.5 :** Πειραματικά αποτελέσματα ποσοτικοποίησης ευελιξίας ηλεκτρικών οχημάτων σε επίπεδο οικίας (ID: 661) για την ημέρα 25/8/2018

15-λεπτο (στιγμή εκκίνησης)	Πλάνο βέλτιστης κατανάλωσης [kW]	Πρόβλεψη κατανάλωσης [kW]	Ανοδική ευελιξία (πρόταση μείωσης κατανάλωσης) [kW]	Καθοδική ευελιξία (πρόταση αύξησης κατανάλωσης) [kW]
0:00	3,42	0,00	0,00	3,42
0:15	3,42	0,00	0,00	3,42
0:30	3,42	0,00	0,00	3,42
0:45	3,42	0,00	0,00	3,42
1:00	3,42	0,00	0,00	3,42
1:15	3,42	0,00	0,00	3,42
1:30	3,42	0,00	0,00	3,42
1:45	3,42	0,00	0,00	3,42
2:00	3,42	0,00	0,00	3,42
2:15	3,42	0,00	0,00	3,42

Πίνακας 4.5 : Πειραματικά αποτελέσματα ποσοτικοποίησης ευελιξίας ηλεκτρικών οχημάτων σε επίπεδο οικίας (ID: 661) για την ημέρα 25/8/2018 (συνέχεια)

15-λεπτο (στιγμή εκκίνησης)	Πλάνο βέλτιστης κατανάλωσης [kW]	Πρόβλεψη κατανάλωσης [kW]	Ανοδική ευελιξία (πρόταση μείωσης κατανάλωσης) [kW]	Καθοδική ευελιξία (πρόταση αύξησης κατανάλωσης) [kW]
2:30	3,42	0,00	0,00	3,42
2:45	3,42	0,00	0,00	3,42
3:00	3,42	0,00	0,00	3,42
3:15	3,42	0,00	0,00	3,42
3:30	3,42	0,00	0,00	3,42
3:45	3,42	0,00	0,00	3,42
4:00	0,00	0,00	0,00	0,00
4:15	0,00	0,00	0,00	0,00
4:30	0,00	0,00	0,00	0,00
4:45	0,00	0,00	0,00	0,00
5:00	0,00	0,00	0,00	0,00
5:15	0,00	0,00	0,00	0,00
5:30	0,00	0,00	0,00	0,00
5:45	0,00	0,00	0,00	0,00
6:00	0,00	0,00	0,00	0,00
6:15	0,00	0,00	0,00	0,00
6:30	0,00	3,10	3,10	0,00
6:45	0,00	3,40	3,40	0,00
7:00	0,00	3,39	3,39	0,00
7:15	0,00	3,39	3,39	0,00
7:30	0,00	3,40	3,40	0,00
7:45	0,00	3,39	3,39	0,00
8:00	0,00	3,39	3,39	0,00
8:15	0,00	3,39	3,39	0,00
8:30	0,00	3,39	3,39	0,00
8:45	0,00	3,40	3,40	0,00
9:00	0,00	3,40	3,40	0,00
9:15	0,00	3,39	3,39	0,00
9:30	0,00	3,39	3,39	0,00
9:45	0,00	3,38	3,38	0,00
10:00	0,00	3,39	3,39	0,00
10:15	0,00	3,39	3,39	0,00
10:30	0,00	3,27	3,27	0,00
10:45	0,00	1,59	1,59	0,00
11:00	0,00	0,85	0,85	0,00
11:15	0,00	0,82	0,82	0,00
11:30	0,00	0,80	0,80	0,00

Πίνακας 4.5 : Πειραματικά αποτελέσματα ποσοτικοποίησης ευελιξίας ηλεκτρικών οχημάτων σε επίπεδο οικίας (ID: 661) για την ημέρα 25/8/2018 (συνέχεια)

15-λεπτο (στιγμή εκκίνησης)	Πλάνο βέλτιστης κατανάλωσης [kW]	Πρόβλεψη κατανάλωσης [kW]	Ανοδική ευελιξία (πρόταση μείωσης κατανάλωσης) [kW]	Καθοδική ευελιξία (πρόταση αύξησης κατανάλωσης) [kW]
11:45	0,00	0,80	0,80	0,00
12:00	0,00	0,80	0,80	0,00
12:15	0,00	0,81	0,81	0,00
12:30	0,00	0,70	0,70	0,00
12:45	0,00	0,00	0,00	0,00
13:00	0,00	0,00	0,00	0,00
13:15	0,00	0,00	0,00	0,00
13:30	0,00	0,00	0,00	0,00
13:45	0,00	0,00	0,00	0,00
14:00	0,00	0,00	0,00	0,00
14:15	0,00	0,00	0,00	0,00
14:30	0,00	0,00	0,00	0,00
14:45	0,00	0,00	0,00	0,00
15:00	0,00	0,00	0,00	0,00
15:15	0,00	0,00	0,00	0,00
15:30	0,00	0,00	0,00	0,00
15:45	0,00	0,00	0,00	0,00
16:00	0,00	0,00	0,00	0,00
16:15	0,00	0,00	0,00	0,00
16:30	0,00	0,00	0,00	0,00
16:45	0,00	0,00	0,00	0,00
17:00	0,00	0,00	0,00	0,00
17:15	0,00	0,00	0,00	0,00
17:30	0,00	0,00	0,00	0,00
17:45	0,00	0,00	0,00	0,00
18:00	0,00	2,56	2,56	0,00
18:15	0,00	3,41	3,41	0,00
18:30	0,00	3,41	3,41	0,00
18:45	0,00	3,40	3,40	0,00
19:00	0,00	0,61	0,61	0,00
19:15	0,00	0,00	0,00	0,00
19:30	0,00	0,00	0,00	0,00
19:45	0,00	0,00	0,00	0,00
20:00	0,00	0,00	0,00	0,00
20:15	0,00	0,00	0,00	0,00
20:30	0,00	0,00	0,00	0,00
20:45	0,00	0,00	0,00	0,00

Πίνακας 4.5 : Πειραματικά αποτελέσματα ποσοτικοποίησης ευελιξίας ηλεκτρικών οχημάτων σε επίπεδο οικίας (ID: 661) για την ημέρα 25/8/2018 (συνέχεια)

15-λεπτο (στιγμή εκκίνησης)	Πλάνο βέλτιστης κατανάλωσης [kW]	Πρόβλεψη κατανάλωσης [kW]	Ανοδική ευελιξία (πρόταση μείωσης κατανάλωσης) [kW]	Καθοδική ευελιξία (πρόταση αύξησης κατανάλωσης) [kW]
21:00	0,00	0,00	0,00	0,00
21:15	0,00	0,00	0,00	0,00
21:30	0,00	0,00	0,00	0,00
21:45	0,00	0,00	0,00	0,00
22:00	3,42	0,00	0,00	3,42
22:15	3,42	0,00	0,00	3,42
22:30	3,42	0,00	0,00	3,42
22:45	3,42	0,00	0,00	3,42
23:00	3,42	0,00	0,00	3,42
23:15	3,42	0,00	0,00	3,42
23:30	2,64	0,00	0,00	2,64
23:45	0,00	0,00	0,00	0,00

4.2.4 Ανάλυση Ευαισθησίας με Τιμολογιακές Πολιτικές

Η ανάλυση ευαισθησίας που περιγράφεται επικεντρώνεται στην επιρροή διαφορετικών τιμολογιακών πολιτικών στη μέγιστη δυνατή ευελιξία που μπορεί να αποκομίσει ένας ΦοΣΕ. Ο στόχος είναι να ποσοτικοποιηθεί η ευελιξία που μπορεί να εκμεταλλευτεί καλύτερα ένας ΦοΣΕ υπό διάφορα σενάρια τιμολόγησης, καθώς και ποιες είναι οι οικονομικές επιπτώσεις κάθε πολιτικής. Τα τέσσερα σενάρια που εξετάζονται, εκτός της βασικής τιμολογιακής πολιτικής χρεώσεων βάσει χρόνου χρήσης (ToU), είναι τα εξής:

1. Τιμές πραγματικού χρόνου (Real-Time Tariff): Σε αυτό το σενάριο, οι τιμές της ενέργειας μεταβάλλονται δυναμικά σε πραγματικό χρόνο, ανάλογα με τη ζήτηση και την προσφορά στην αγορά. Η πολιτική αυτή προσφέρει τις μεγαλύτερες δυνατότητες για εξοικονόμηση κόστους, καθώς οι καταναλωτές μπορούν να προσαρμόζουν την κατανάλωσή τους ανάλογα με τις διακυμάνσεις των τιμών.
2. Τιμές χρέωσης βάσει χρόνου χρήσης (Time of Use): Σε αυτή την περίπτωση, οι τιμές της ενέργειας διαχωρίζονται σε διαφορετικές ζώνες, με χαμηλότερες τιμές κατά τις ώρες χαμηλής ζήτησης και υψηλότερες τιμές κατά τις ώρες αιχμής. Ενώ η πολιτική αυτή προσφέρει λιγότερη δυναμική από την πραγματικού χρόνου τιμολόγηση, εξακολουθεί να παρέχει κίνητρα για τη μετατόπιση της κατανάλωσης από ώρες αιχμής σε ώρες με χαμηλότερη ζήτηση.
3. Τιμές κατανάλωσης αιχμής (Critical Peak Tariff): Αυτή η πολιτική εφαρμόζει πολύ υψηλές τιμές κατά τις περιόδους αιχμής, ενθαρρύνοντας τους καταναλωτές να μειώσουν τη χρήση τους κατά αυτές τις κρίσιμες χρονικές στιγμές. Αν και αυτή η προσέγγιση μπορεί να οδηγήσει σε σημαντική μείωση της ζήτησης σε


συγκεκριμένες περιόδους, η ευελιξία που παρέχεται είναι περιορισμένης εμβέλειας, δεδομένου ότι οι καταναλωτές πρέπει να ανταποκρίνονται σε λίγες, αλλά πολύ κοστοβόρες, χρονικές περιόδους.

4. Σταθερό Ενιαίο Τιμολόγιο (Hedged Tariff): Εδώ, η τιμή της ενέργειας παραμένει σταθερή ανεξάρτητα από τη ζήτηση και την προσφορά, παρέχοντας ασφάλεια στους καταναλωτές από τις διακυμάνσεις της αγοράς. Αν και αυτή η πολιτική προσφέρει λιγότερες ευκαιρίες για εξοικονόμηση κόστους, είναι ελκυστική για τους καταναλωτές που επιθυμούν σταθερότητα και προβλεψιμότητα στα έξοδά τους, χωρίς να χρειάζεται να προσαρμόζουν συνεχώς την κατανάλωσή τους.

Ακολουθούν τα πειραματικά αποτελέσματα, στο πλαίσιο 5 ιστορικών ημερών με την υψηλότερη συνολική κατανάλωση. Οι τιμολογιακές πολιτικές δομήθηκαν με βάση τις χρηματιστηριακές τιμές (χονδρική) ηλεκτρικής ενέργειας για το 2023 [40] στο Austin, από όπου αντλήθηκαν οι ιστορικές καταναλώσεις. Στην αρχική χονδρική τιμή πώλησης προστέθηκε ένα 20-25%, με βάση στοιχεία από το υπουργείο ενέργειας [41] για τις προσαυξήσεις στην τελική λιανική τιμή που φτάνει στον καταναλωτή.

Πίνακας 4.6 : Πειραματικά αποτελέσματα χρήσης Real-Time τιμολογιακής πολιτικής ενός ΦοΣΕ Ηλεκτρικών Οχημάτων (ΦΟΣΕΦΟΗΟ)

Ημέρα	Μέθοδος	Ημερήσια Ανοδική ευελιξία [kWh]	Ημερήσια Καθοδική ευελιξία [kWh]	Τιμολογιακή Πολιτική	Εξοικονόμηση [Ευρώ]	Ποσοστιαία Εξοικονόμηση
9-Δεκ	Κοινότητα (αθροιστική)	39,21	39,21	Real-Time	2,00	3%
7-Ιουλ	Κοινότητα (αθροιστική)	50,50	50,50	Real-Time	4,04	7%
15- Ιουν	Κοινότητα (αθροιστική)	34,60	34,60	Real-Time	3,57	7%
23-Ιαν	Κοινότητα (αθροιστική)	32,50	32,50	Real-Time	3,94	9%
22- Αυγ	Κοινότητα (αθροιστική)	31,71	31,71	Real-Time	4,07	10%



Σχήμα 4.7 : Ευελιξία Ηλεκτρικού Οχήματος (ημέρα με μεγαλύτερη ιστορική κατανάλωση – 9/12/2018)

Σύμφωνα με το Σχήμα 4.7, παρατηρούμε ότι αναμένεται μεγαλύτερη μετακίνηση του φορτίου από το χρονικό διάστημα 03:15 έως 09:45, στο χρονικό διάστημα 12:30 έως 22:00, όπου η ζήτηση είναι χαμηλότερη και αντίστοιχα το κόστος μικρότερο. Αυτή η μετακίνηση επιτρέπει την αποφυγή της κατανάλωσης κατά τις ώρες αιχμής, γεγονός που συνεπάγεται εξοικονόμηση κόστους για την κοινότητα καθώς και αποσυμφόρηση του δικτύου διανομής. Η διαδικασία αυτή βασίζεται στα ιστορικά στοιχεία κατανάλωσης και την προβλεπόμενη ζήτηση, με σκοπό την ορθολογική διαχείριση της ενέργειας. Αντίστοιχα, πειραματικά αποτελέσματα για διαφορετικές τιμολογιακές πολιτικές (οι οποίες παρουσιάζονται στον Πίνακα 4.1):

Πίνακας 4.7 : Πειραματικά αποτελέσματα για διαφορετικές τιμολογιακές πολιτικές για την ίδια μέρα (9/12/2018)

Ημέρα	Μέθοδος	Ημερήσια Ανοδική ευελιξία [kWh]	Ημερήσια Καθοδική ευελιξία [kWh]	Τιμολογιακή Πολιτική	Εξοικονόμηση [Ευρώ]	Ποσοστιαία Εξοικονόμηση
9-Δεκ	Κοινότητα (αθροιστική)	37,37	37,37	Time of Use	0,49	1%
9-Δεκ	Κοινότητα (αθροιστική)	39,22	39,22	Real-Time	2,00	3%
9-Δεκ	Κοινότητα (αθροιστική)	37,47	37,47	Critical Peak	9,48	16%

Επίσης μελετήθηκαν τα αποτελέσματα, με σύγκριση των δύο μεθόδων:

Πίνακας 4.8 : Πειραματικά συγκριτικά αποτελέσματα για τις δύο μεθοδολογίες ποσοτικοποίησης ευελιξίας αθροιστικού φορτίου ηλεκτρικών οχημάτων

Ημέρα	Πρόβλεψη Κοινότητας [kWh]	Αθροιστική Πρόβλεψη Ανά Οικία [kWh]	Ευελιξία Κοινότητας [kWh]	Αθροιστική Ευελιξία Ανά Οικία [kWh]
3-Μαρ	96,99	102,92	39,11	46,78

Τα αποτελέσματα της ανάλυσης υποδεικνύουν ότι η μεγαλύτερη ευελιξία και η δυνατότητα για εξοικονόμηση κόστους επιτυγχάνονται με την πραγματικού χρόνου τιμολόγηση, καθώς επιτρέπει στους καταναλωτές να αντιδρούν άμεσα στις μεταβολές των τιμών της αγοράς. Ωστόσο, για καταναλωτές που προτιμούν σταθερότητα και προβλεψιμότητα, το σταθερό ενιαίο τιμολόγιο προσφέρει ασφάλεια, αν και με περιορισμένες δυνατότητες εξοικονόμησης. Αυτή η ανάλυση υποδεικνύει τη σημασία της επιλογής της κατάλληλης τιμολογιακής πολιτικής ανάλογα με τις προτιμήσεις και τις ανάγκες των καταναλωτών.

4.3 ΣΥΜΠΕΡΑΣΜΑΤΑ

Τα συμπεράσματα από την ανάλυση της πειραματικής διερεύνησης υποδεικνύουν τη σημαντική αξία της ποσοτικοποίησης της ευελιξίας τόσο σε επίπεδο κοινότητας όσο και σε επίπεδο μεμονωμένης οικίας, με τη χρήση προηγμένων μεθόδων όπως τα δίκτυα LSTM και οι τεχνικές βελτιστοποίησης. Η δυνατότητα πρόβλεψης της κατανάλωσης ενέργειας και η προσαρμογή της μέσω της βελτιστοποίησης επιτρέπει τη μείωση του κόστους και τη βελτίωση της ενεργειακής αποδοτικότητας, δύο στόχοι που είναι κρίσιμοι σε ένα συνεχώς εξελισσόμενο ενεργειακό περιβάλλον.

Η έρευνα υπογραμμίζει τη σημασία της σωστής επιλογής τιμολογιακής πολιτικής, η οποία επηρεάζει άμεσα το πώς η ευελιξία των καταναλωτών μπορεί να αξιοποιηθεί στο έπακρο. Όπως παρατηρήθηκε και στην ανάλυση που προηγήθηκε, για την ίδια ημέρα η ποσοστιαία εξοικονόμηση κυμάνθηκε από 1% (Time of Use - ToU) έως και 16% (Critical Peak), αναδεικνύοντας την επίδραση που έχει η επιλογή της κατάλληλης τιμολόγησης στην εξοικονόμηση ενέργειας.

Επιπλέον, τα αποτελέσματα από τη σύγκριση των δύο μεθοδολογιών ποσοτικοποίησης ευελιξίας αθροιστικού φορτίου ηλεκτρικών οχημάτων έδειξαν σαφείς διαφορές στην εξοικονόμηση ενέργειας μεταξύ κοινότητας και μεμονωμένων οικιών. Συγκεκριμένα, η ευελιξία που παρατηρήθηκε στην κοινότητα ανήλθε σε 39,11 kWh, ενώ η αθροιστική ευελιξία ανά οικία έφτασε τις 46,78 kWh. Αυτό αποδεικνύει ότι η ευελιξία σε επίπεδο οικιών είναι σημαντικά υψηλότερη σε σύγκριση με την κοινότητα, γεγονός που αναδεικνύει τη δυνατότητα μεγαλύτερης εξοικονόμησης όταν η διαχείριση γίνεται σε επίπεδο κατοικίας. Η κατάλληλη προσαρμογή αυτών των πολιτικών στις ανάγκες και τις προτιμήσεις των καταναλωτών μπορεί να μεγιστοποιήσει τα οφέλη τόσο για τους ίδιους όσο και για το ευρύτερο ενεργειακό δίκτυο, εφόσον ενσωματωθούν μεθοδολογίες που αξιοποιούν την ατομική ευελιξία των οικιών και την αθροιστική ευελιξία της κοινότητας.

Η ευελιξία των καταναλωτών, δηλαδή η ικανότητά τους να προσαρμόζουν τη χρήση ενέργειας ανάλογα με τις συνθήκες της αγοράς και τις διακυμάνσεις των τιμών, αναδεικνύεται ως ένας κρίσιμος παράγοντας για την επιτυχία των προγραμμάτων διαχείρισης ζήτησης. Τα

προγράμματα αυτά αποσκοπούν στην εξισορρόπηση της ζήτησης και της προσφοράς ενέργειας, προάγοντας έτσι την ενεργειακή απόδοση και την βιωσιμότητα του συστήματος.

Επιπλέον, η ανάλυση δείχνει ότι η αλληλεπίδραση των καταναλωτών με τις αγορές ενέργειας παίζει καθοριστικό ρόλο στην επιτυχία των προγραμμάτων διαχείρισης ζήτησης. Οι καταναλωτές που συμμετέχουν ενεργά και προσαρμόζουν τη συμπεριφορά τους στις τιμολογιακές αλλαγές μπορούν να επιτύχουν σημαντική μείωση του ενεργειακού τους κόστους και να βελτιώσουν τη συνολική απόδοση του δικτύου. Αυτό επιβεβαιώνεται από τα πειραματικά αποτελέσματα, όπου παρατηρήθηκε σαφής μετακίνηση του φορτίου από τις ώρες αιχμής (14:00 έως 21:15) προς ώρες χαμηλότερης κατανάλωσης (4:30 έως 06:15), συμβάλλοντας έτσι στη μείωση των αιχμών ζήτησης. Αυτή η μετατόπιση όχι μόνο μειώνει το κόστος για τους καταναλωτές αλλά και ενισχύει την ευστάθεια και την αξιοπιστία του συστήματος, ιδιαίτερα σε περιόδους υψηλής ζήτησης.

Συνολικά, η πειραματική διερεύνηση αποδεικνύει ότι η ενσωμάτωση προηγμένων τεχνολογιών πρόβλεψης και βελτιστοποίησης μπορεί να ενισχύσει την ενεργειακή απόδοση και να προσφέρει σημαντικά οικονομικά οφέλη. Η επιτυχία αυτών των προσπαθειών εξαρτάται από τη σωστή διαχείριση της ευελιξίας των καταναλωτών και την προσαρμογή των τιμολογιακών πολιτικών στις δυναμικές συνθήκες της αγοράς ενέργειας.

ΚΕΦΑΛΑΙΟ

5

ΣΥΜΠΕΡΑΣΜΑΤΑ - ΕΠΕΚΤΑΣΕΙΣ

5.1 ΣΥΝΟΨΗ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ ΤΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα εργασία επικεντρώθηκε στην ποσοτικοποίηση της ευελιξίας οικιακών καταναλωτών σε ένα έξυπνο δίκτυο, χρησιμοποιώντας μοντέλα Long Short-Term Memory (LSTM) για την πρόβλεψη της ζήτησης ενέργειας και μοντέλα EMS/HEMS για τη βελτιστοποίηση της κατανάλωσης με στόχο τη μείωση του κόστους. Η ευελιξία των καταναλωτών ορίστηκε ως η ικανότητα μεταβολής και μετατόπισης του φορτίου από το προφίλ βάσης, με στόχο τη μεγιστοποίηση των οικονομικών ωφελειών μέσω κατάλληλων τιμολογιακών σχημάτων.

Υλοποιήθηκε μαθηματική μοντελοποίηση ελαχιστοποίησης κόστους, λαμβάνοντας υπόψη βασικές μεταβλητές, όπως η τιμή της ηλεκτρικής ενέργειας και το ιστορικό φορτίο. Επιπλέον, χρησιμοποιήθηκαν παραδοχές για τη μέγιστη συμμόρφωση των τελικών χρηστών, ενώ επιβλήθηκαν περιορισμοί στη δυνατότητα φόρτισης, οι οποίοι βασίζονται στη μέγιστη και ελάχιστη ιστορική κατανάλωση. Προστέθηκαν επίσης φραγμοί στην ωριαία κατανάλωση, λόγω των αντοχών του φορτιστή, και στη συνολική φόρτιση, η οποία δεν πρέπει να υπερβαίνει τις προβλέψεις του μοντέλου (forecaster).

Τα αποτελέσματα έδειξαν ότι η απόδοση του μοντέλου βελτιώθηκε όσο αυξανόταν η ποσότητα των δεδομένων εκπαίδευσης, ενώ η προσθήκη επιπλέον χαρακτηριστικών, όπως οι χρονικές μεταβλητές (π.χ. μήνας, ημέρα, ώρα ανά 15 λεπτά), συνέβαλε σημαντικά στην ακρίβεια των προβλέψεων. Συγκεκριμένα, το Μέσο Απόλυτο Σφάλμα (MAE) και το Μέσο Απόλυτο Σφάλμα Ποσοστιαίας Απόκλισης (MAAPE) μειώθηκαν κατά 15% και 12% αντίστοιχα, μετά την ενσωμάτωση αυτών των χαρακτηριστικών.

Η ανάλυση των πειραματικών αποτελεσμάτων έδειξε ότι η παρουσία μηδενικών τιμών στα δεδομένα βελτίωσε τις επιδόσεις του μοντέλου ως προς το MAE, αλλά η γενικότερη συμπεριφορά του μοντέλου δεν ήταν ικανοποιητική, οδηγώντας στην απόφαση να αφαιρεθεί το φορτίο του θερμοσίφωνα από τη μελέτη. Αυτό οφείλεται στη δυσκολία πρόβλεψης των σπάνιων και μεγάλων αιχμών αυτού του φορτίου.

Η αλλαγή στον αλγόριθμο επιλογής δεδομένων εκπαίδευσης και δοκιμής σε 80%-20% τυχαία επιλεγμένα δεδομένα από όλο το εύρος ημερών και μηνών οδήγησε σε περαιτέρω βελτίωση των προβλέψεων, με το MAE να μειώνεται κατά 8% για τα φορτία ηλεκτρικών οχημάτων και 10% για τα κλιματιστικά.

Σημαντικό εύρημα της εργασίας ήταν η αποδοτικότητα της βελτιστοποίησης της κατανάλωσης μέσω του Home Energy Management System (HEMS). Η εξοικονόμηση κόστους αθροιστικού φορτίου ηλεκτρικών οχημάτων από 7 κατοικίες κυμαινόταν μεταξύ 2 και 4 ευρώ ανά ημέρα, ενώ για το αθροιστικό φορτίο κλιματισμού των ίδιων κατοικιών έφτασε έως και 57 ευρώ σε ημέρες υψηλής ζήτησης. Η βελτιστοποίηση της ευελιξίας των καταναλωτών, σε

συνδυασμό με τα κατάλληλα τιμολογιακά σχήματα, απέδειξε τη δυνατότητα σημαντικών οικονομικών ωφελειών και την καλύτερη ενσωμάτωση ανανεώσιμων πηγών ενέργειας στο δίκτυο. Για παράδειγμα, συγκρίνοντας την τιμολογιακή πολιτική Time of Use με τη Critical Peak υπήρξε εξοικονόμηση κόστους 15% (9 ευρώ) σε επίπεδο ημέρας, ενώ η ευελιξία εκτιμήθηκε από 74,74 kWh σε 79,94 kWh.

Συνολικά, η εργασία απέδειξε ότι η ποσοτικοποίηση της ευελιξίας τόσο σε επίπεδο κατοικίας όσο και κοινότητας μπορεί να αποτελέσει ένα ισχυρό εργαλείο για τη μείωση του κόστους ενέργειας και τη βελτίωση της ευστάθειας του συστήματος, παρέχοντας παράλληλα λύσεις που ευνοούν τη βιωσιμότητα και την αειφορία. Πιο συγκεκριμένα, συγκρίνοντας τη μέθοδο σε επίπεδο οικιών με τη μέθοδο σε επίπεδο κοινότητας η ευελιξία ποσοτικοποιήθηκε σε διαφορά 8 kWh.

5.2 ΕΠΕΚΤΑΣΕΙΣ ΤΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα διπλωματική εργασία μπορεί μελλοντικά να επεκταθεί ως ακολούθως:

- Για τη βελτίωση της απόδοσης του μοντέλου πρόβλεψης φορτίου, προτείνεται η διερεύνηση και ανάπτυξη αλγορίθμων που θα επιτρέπουν την προσαρμογή του μοντέλου σε διαφορετικές χρονικές κλίμακες, ανάλογα με το φορτίο. Αυτό σημαίνει ότι το μοντέλο θα μπορούσε να προσαρμόζεται σε συγκεκριμένα χρονικά πλαίσια (π.χ., ημερήσιες, εβδομαδιαίες ή μηνιαίες τάσεις) που είναι πιο κατάλληλα για την πρόβλεψη κάθε τύπου φορτίου. Επιπλέον, η βελτιστοποίηση της κανονικοποίησης των δεδομένων μπορεί να βελτιώσει την ακρίβεια των προβλέψεων, καθώς θα μειώσει την επίδραση μη αντιπροσωπευτικών ή μη φυσιολογικών δεδομένων στις προβλέψεις του μοντέλου.
- Ενσωμάτωση μοντέλων συμπεριφοράς: Η προσθήκη μοντέλων που αναπαριστούν τη συμπεριφορά των καταναλωτών θα μπορούσε να βελτιώσει την ακρίβεια των προβλέψεων και να επιτρέψει τη διαμόρφωση πιο στοχευμένων στρατηγικών ευελιξίας.
- Περισσότερα σπίτια, αναγωγή σε επίπεδο Δήμου: Η επέκταση της μελέτης σε μεγαλύτερο δείγμα κατοικιών και η αναγωγή των αποτελεσμάτων σε επίπεδο Δήμου θα επέτρεπε την αξιολόγηση της ευελιξίας σε ευρύτερη κλίμακα.
- Επέκταση σε περιοχές με ακραίες καιρικές συνθήκες: Η μελέτη σε περιοχές με ακραίες καιρικές συνθήκες θα μπορούσε να αποκαλύψει πρόσθετες προκλήσεις και ευκαιρίες για την ευελιξία, ειδικά σε περιόδους αιχμής ζήτησης.
- Προσθήκη Ανανεώσιμων Πηγών Ενέργειας (ΑΠΕ): Η ενσωμάτωση ΑΠΕ στο σύστημα και η μελέτη της επίδρασης της ευελιξίας στη σταθεροποίηση της παραγωγής και κατανάλωσης ενέργειας είναι μια σημαντική κατεύθυνση για μελλοντική έρευνα.
- Χρήση AI Generative Models για προσομοίωση διαφορετικών σεναρίων: Η χρήση τεχνητής νοημοσύνης για τη δημιουργία προγνωστικών μοντέλων που θα προσομοιώνουν διαφορετικά σενάρια και συνθήκες θα μπορούσε να προσφέρει χρήσιμα εργαλεία για τη βελτιστοποίηση της ευελιξίας και τη διαχείριση της ζήτησης.

Αυτές οι επεκτάσεις θα μπορούσαν να ενισχύσουν περαιτέρω τα ευρήματα της παρούσας μελέτης και να συμβάλουν στη δημιουργία ενός πιο ευέλικτου και αποδοτικού ενεργειακού συστήματος.

ΚΕΦΑΛΑΙΟ 6

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] Naqash Ahmad, Yazeed Ghadi, Muhammad Adnan, Mansoor Ali “Load Forecasting Techniques for Power System: Research Challenges and Survey,” *IEEE Access*, vol. 10, pp. 71054-71090, 2022.
- [2] Behnam Farsi, Manar Amayri, Nizar Bouguila, Ursula Eicker “On Short-Term Load Forecasting Using Machine Learning Techniques and a Novel Parallel Deep LSTM-CNN Approach,” *IEEE Access*, vol. 9, pp. 31191-31212, 2021.
- [3] Hochreiter, S., & Schmidhuber, J. "Long Short-Term Memory," *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, 1997.
- [4] Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., Schmidhuber, J. “LSTM: A Search Space Odyssey,” *IEEE Transactions on Neural Networks and Learning Systems*, vol. 28, no. 10, pp. 2222-2232, 2017.
- [5] Dongyang Zhang, Yicheng Gong “The Comparison of LightGBM and XGBoost Coupling Factor Analysis and Prediagnosis of Acute Liver Failure,” *IEEE Access*, vol. 8, pp. 2169-3536, 2020.
- [6] Isaac Kofi Nti, Moses Teimeh, Owusu Nyarko-Boateng, Adebayo Felix Adekoya “Electricity load forecasting: a systematic review,” *Journal of Electrical Systems and Information Technology*, vol. 7, Article 13, 2020.
- [7] Hany Habbak, Mohamed Mahmoud, Khaled Metwally, Mostafa M. Fouda, Mohamed I. Ibrahim “Load Forecasting Techniques and Their Applications in Smart Grids,” *Energies*, 16, 1480, 2023.
- [8] Milad Afzalan, Farrokh Jazizadeh “Residential loads flexibility potential for demand response using energy consumption patterns and user segments,” *Applied Energy*, vol. 254, 2019.
- [9] William W. Hsieh, *Introduction to Environmental Data Science*, Cambridge University Press, 2023.

- [10] Freddy Plaum, Roya Ahmadihangar, Argo Rosin, Jako Kilter “Aggregated demand-side energy flexibility: A comprehensive review on characterization, forecasting and market prospects,” *Energy Reports*, vol. 8, 2022.
- [11] Sadam Hussain, Chunyan Lai, Ursula Eicker “Flexibility: Literature review on concepts, modeling, and provision method in smart grid,” *Sustainable Energy, Grids and Networks*, vol. 35, 2023.
- [12] Pavani Ponnaganti, Rakesh Sinha, Jayakrishnan R. Pillai, Birgitte Bak-Jensen “Flexibility provisions through local energy communities: A review,” *Next Energy*, vol. 1, June 2023.
- [13] Cherrelle Eid, Paul Codani, Yurong Chen, Yannick Perez, Rudi Hakvoort “Aggregation of demand side flexibility in a smart grid: A review for European market design,” *Proc. 12th International Conference on the European Energy Market*, 2015.
- [14] Isaías Gomes, Karol Bot, Maria Graça Ruano, António Ruano “Recent Techniques Used in Home Energy Management Systems: A Review,” *Energies*, vol. 15, no. 8, 2022.
- [15] Muhammad Majid Hussain, Rizwan Akram, Zulfiqar Ali Memon, Mian Hammad Nazir, Waqas Javed, Muhammad Siddique “Demand Side Management Techniques for Home Energy Management Systems for Smart Cities,” *Sustainability*, vol. 13, no. 21, 2021.
- [16] Wei Zhang, Die Wang, Xuemeng Liu “Does financial agglomeration promote the green efficiency of water resources in China?”, *Environmental Science and Pollution Research*, vol. 28, no. 8, pp. 14679–14688, 2021.
- [17] Wen-Cheng Wang, Ngakan Ketut Acwin Dwijendra, Biju Theruvil Sayed, José Ricardo Nuñez Alvarez, Mohammed Al-Bahrani, Aníbal Alviz-Meza, Yulineth Cárdenas-Escrocia “Internet of Things Energy Consumption Optimization in Buildings: A Step toward Sustainability,” *Sustainability*, vol. 15, no. 8. 2023.
- [18] Safae Bourhnane, Mohamed Riduan Abid, Rachid Lghoul, Khalid Zine-Dine, Najib Elkamoun, Driss Benhaddou “Machine learning for energy consumption prediction and scheduling in smart buildings,” *SN Applied Sciences*, vol. 2, 2020.

- [19] Abdul Salam Shah, Haidawati Nasir, Muhammad Fayaz, Adidah Lajis, Asadullah Shah "A Review on Energy Consumption Optimization Techniques in IoT Based Smart Building Environments," *Sensors*, vol. 10, no. 3, 2023.
- [20] Smart Grid Vendée,
Available: <https://www.sydev-vendee.fr/transition-energetique/developpement-et-innovation/smart-grid-vendee>
- [21] Reda El Makroum, Ahmed Khallaayoun, Rachid Lghoul, Kedar Mehta, Wilfried Zörner «Home Energy Management System Based on Genetic Algorithm for Load Scheduling: A Case Study Based on Real Life Consumption Data», *Energies*, vol. 16, no. 6, 2023.
- [22] Agora Energiewende "The European Power System in 2030: Flexibility Challenges and Integration Benefits,"
Available: <https://www.agora-energiewende.org/publications/the-european-power-system-in-2030-flexibility-challenges-and-integration-benefits-1>
- [23] C. Menos-Aikateriniadis, A. Akarepis, I. Kokos and P. S. Georgilakis, "Sub-Hourly Load Forecasting for Community-Level Flexible Appliance Management", 2024 International Joint Conference on Neural Networks (IJCNN), Yokohama, Japan, 2024.
- [24] Γ. Παπαλουκάς, "Βραχυπρόθεσμη πρόβλεψη ηλεκτρικής ζήτησης οικιακών φορτίων με χρήση αναδρομικών νευρωνικών δικτύων," Μεταπτυχιακή Διπλωματική Εργασία, Εθνικό Μετσόβιο Πολυτεχνείο, 2023.
- [25] Yuqi Zhou, Arun Sukumaran Nair, David Ganger, Abhinandan Tripathi, Chaitanya Baone, Hao Zhu "Appliance Level Short-term Load Forecasting via Recurrent Neural Network", *IEEE Power & Energy Society General Meeting*, 2022.
- [26] Pecan Street Dataport
Available: <https://www.pecanstreet.org/dataport/about-dataport/>
- [27] Y. Bengio, "Practical Recommendations for Gradient-Based Training of Deep Architectures," in *Neural Networks: Tricks of the Trade*, Springer, 2012, pp. 437-478.
- [28] J. Brownlee, "Better Deep Learning," Machine Learning Mastery, 2018.
- [29] A. Ng, "Deep Learning Specialization," Coursera, 2020.
- [30] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," *Journal of Machine Learning Research*, Vol. 15, No. 1, pp. 1929–1958, 2014.
- [31] G. Hinton, "Improving neural networks by preventing co-adaptation of feature detectors," arXiv preprint arXiv:1207.0580, 2012.
- [32] T. Hastie, R. Tibshirani, and M. Wainwright, *Statistical Learning with Sparsity: The Lasso and Generalizations*, CRC Press, 2015.
- [33] J. Bergstra and Y. Bengio, "Random Search for Hyper-Parameter Optimization," *Journal of Machine Learning Research*, Vol. 13, No. 2, 2012.
- [34] K. Swersky, J. Snoek, and R. P. Adams, "Multi-Task Bayesian Optimization," *Advances in Neural Information Processing Systems*, 2013.

- [35] Π. Σ. Γεωργιλάκης, Σύγχρονα Συστήματα Μεταφοράς και Διανομής Ηλεκτρικής Ενέργειας. Ηλεκτρονικό Βιβλίο, Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών (ΣΕΑΒ), Αθήνα, 2015.
Διαθέσιμο στην ιστοσελίδα : <http://repository.kallipos.gr/handle/11419/2013>
Προσπελάστηκε στις 30 Ιουνίου 2023.
- [36] Π. Σ. Γεωργιλάκης, Οικονομική και Αξιόπιστη Λειτουργία Σύγχρονων Συστημάτων Ηλεκτρικής Ενέργειας. Ηλεκτρονικό Βιβλίο, Κάλλιπος, Ανοικτές Ακαδημαϊκές Εκδόσεις, Αθήνα, 2023.
Διαθέσιμο στην ιστοσελίδα : <https://repository.kallipos.gr/handle/11419/9369>
Προσπελάστηκε στις 30 Ιουνίου 2023.
- [37] Pyomo Documentation 6.8.0
Available: <https://pyomo.readthedocs.io/en/stable/>
- [38] Stone, Richard E.; Tovey, Craig A. (1991). "The simplex and projective scaling algorithms as iteratively reweighted least squares methods". *SIAM Review*. 33 (2): 220–237.
- [39] S. Sykiotis, C. Menos-Aikateriniadis, A. Doulamis, N. Doulamis and P. S. Georgilakis, "Solar Power driven EV Charging Optimization with Deep Reinforcement Learning", *Proc. 2nd International Conference on Energy Transition in the Mediterranean Area (SyNERGY MED 2022)*, Greece, Thessaloniki, 17-19 October 2022
- [40] City of Austin. (2023). Electric Utility Commission Report. Ανακτήθηκε στις 3 Οκτωβρίου 2024, από
<https://services.austintexas.gov/edims/document.cfm?id=400966>
- [41] Υπουργείο Περιβάλλοντος και Ενέργειας. (ΑΔΜΗΕ 2019, ΕΛΔΗΕ 2020). Τιμολόγηση ηλεκτρικής ενέργειας. Ανακτήθηκε στις 3 Οκτωβρίου 2024, από
<https://ypen.gov.gr/energeia/ilektriki-energeia/lianiki-agora/timologisi-ilektrikis-energeias/>

ΠΑΡΑΡΤΗΜΑ I

ΚΩΔΙΚΑΣ PYTHON (LSTM & PYOMO)

II.1 LSTM

Ακολουθεί ο κώδικας, σε Python, που υλοποιήθηκε για την Πρόβλεψη Φορτίου (Forecaster):

Πίνακας I.1 : Κώδικας Python για την Πρόβλεψη Φορτίου (Forecaster)

InitialValues.py
<pre> from pathlib import Path from itertools import product import tensorflow as tf # User USERNAME = 'Konstantinos' # Initialise values for Early Stop of LSTM Training WINDOW_SIZE = 10 MIN_DELTA = 0.0001 PATIENCE = 50 # Select area area = 'Austin' # [California, New York, Austin] # Select appliance # Austin, New York --> [air1, car1, waterheater1, solar] # California --> [air1, solar] flex_resource = 'car1' # Choose period (applicable only for Austin) PERIOD = 1 # START - END = '2018-06-01'-'2018-12-31' # PERIOD = 2 # START - END = '2018-02-01'-'2018-02-28' // '2018-05-01'-'2018-05-31' // '2018-08-01'-'2018-08-31' // '2018-11-01'-'2018-11-30' if area == 'Austin': # path = Path('15minute_data_austin.csv') </pre>

Πίνακας Ι.1 : Κώδικας Python για την Πρόβλεψη Φορτίου (Forecaster) (συνέχεια)

```

path = r"Z:\Temp\VM
Mine\Dipl\1\PecanStreet_data\15minute_data_austin\15minute_data_austin.csv"
if PERIOD == 1:
    START_DATE = '2018-01-01' # '2018-07-15'
    END_DATE = '2018-12-31'
else:
    FIRST_PERIOD_START, FIRST_PERIOD_END = '2018-02-01', '2018-02-28'
    SECOND_PERIOD_START, SECOND_PERIOD_END = '2018-05-01', '2018-05-31'
    THIRD_PERIOD_START, THIRD_PERIOD_END = '2018-08-01', '2018-08-31'
    FORTH_PERIOD_START, FORTH_PERIOD_END = '2018-11-01', '2018-11-30'

if area == 'California':
    # path = Path('15minute_data_california.csv')
    path = r"Z:\Temp\VM
Mine\Dipl\1\PecanStreet_data\15minute_data_california\15minute_data_california.csv"
    START_DATE = '2014-01-01'
    END_DATE = '2014-03-31'

if area == 'New York':
    # path = Path('15minute_data_newyork.csv')
    path = r"Z:\Temp\VM
Mine\Dipl\1\PecanStreet_data\15minute_data_newyork\15minute_data_newyork.csv"
    START_DATE = '2019-05-01'
    END_DATE = '2019-07-31'

# Series in, out
N_IN = 12 # twelve 15-minute periods = 12*15/4 = 3h period of input data
N_OUT = 1 # 15 minute load projection

# Select shuffle
RANDOM = 0 # no shuffle
# RANDOM = 42 # shuffle

# Define hyperparameter values
lstm_units = 200
lstm_dropout = 0.2
lstm_learning_rate = 0.0001
lstm_clipnorm = 0.01
lstm_loss_function = 'mae' # 'mse' # 'mse' or Huber loss function
tf.keras.losses.Huber(delta=1.0)
ann_layer1_size = 256 # 128
ann_layer2_size = 128 # 64

```

Πίνακας Ι.1 : Κώδικας Python για την Πρόβλεψη Φορτίου (Forecaster) (συνέχεια)

```

ann_loss_function = 'mae' #'mse'
epochs_lstm = 200 # 500 # 500 --, 1000
epochs_ann = 500 # 500
batch_size = 256 # 1000 # 1000

# Choose to train new models or use saved ones
# ACTION = 'load'
#
#                                LSTM_NAME                                =
'kkotsakos_plots_26_11_2023_13_50_46_013112_train\lstm_model_1_run_1_run_1.keras'
#
#                                ANN_NAME                                =
'kkotsakos_plots_26_11_2023_13_50_46_013112_train\\ann_model_1_run_1_run_1.keras'
ACTION = 'train'

```

```

main.py

import InitialValues as iv
from helpers import *
from EarlyStop import *
# from Helpers import store_and_plot as plot
from Helpers import load as ld
from Helpers import train_models as tm
from matplotlib import pyplot as plt
import datetime
import os

# Choose city dataset
path          = iv.path
flex_resource  = iv.flex_resource
name          = iv.area
start_date, end_date = iv.START_DATE, iv.END_DATE

# Process csv file to Dataframe, and group values by date
df = process_consumption_data(path, flex_resource)

# Add datetime-related features all converted to integers to help LSTM training
df['time_in_sec']      = (df['date'] - df['date'].dt.floor('D')).dt.total_seconds() #seconds on
a daily basis
df['weekday']          = df['date'].dt.weekday
df['month']            = df['date'].dt.month

# Returns dataframes with scaled training and test sets where the split was based on the days.
Scaling takes place AFTER train/test split within "process_appliance_data"

Train_scaled_data,    Test_scaled_data,    Train_data,    Test_data,    scaler_train    =
process_appliance_data(df, start_date, end_date)

```

Πίνακας Ι.1 : Κώδικας Python για την Πρόβλεψη Φορτίου (Forecaster) (συνέχεια)

```

n_vars = 1 if type(Train_scaled_data) is list else Train_scaled_data.shape[1]

# Returns panda with series input/output set
scaled_data = pd.concat([Train_scaled_data, Test_scaled_data], axis=0)
reframed = series_to_supervised(scaled_data, n_vars, iv.N_IN, iv.N_OUT)

# Instantiate the custom callback
early_stop = EarlyStop(window_size=iv.WINDOW_SIZE, min_delta=iv.MIN_DELTA,
patience=iv.PATIENCE)

# X: input series, y: output
X_train = reframed.iloc[:Train_scaled_data.shape[0], :-1].values #3 time-related features are
used for training
Y_train = reframed.iloc[:Train_scaled_data.shape[0], -1].values #keep only one feature of
consumption for predictions

X_test = reframed.iloc[Train_scaled_data.shape[0]:, :-1].values #3 time-related features are
used for training
Y_test = reframed.iloc[Train_scaled_data.shape[0]:, -1].values #keep only one feature of
consumption for predictions

if iv.ACTION == 'train':
    model_lstm, model_ann, history_lstm, history_ann = tm.train_models(X_train, Y_train,
X_test, Y_test, n_vars, early_stop)

if iv.ACTION == 'load':
    model_lstm, model_ann = ld.load()
    date = str(datetime.datetime.now().strftime("%d_%m_%Y_%H_%M_%S"))
    username = iv.USERNAME
    model_name = 'load'
    directory = f'./{username}_plots_{model_name}_{date}'

# Obtain the predicted consumption
Xtest_reshaped = np.reshape(X_test, (X_test.shape[0], iv.N_IN, n_vars))
LSTM_Prediction = model_lstm.predict(Xtest_reshaped)[: , 0]
ANN_correction_factor = model_ann.predict(X_test)[: , 0]
predictions = LSTM_Prediction.reshape(-1, 1) + ANN_correction_factor

# Inverse transform the scaled predictions and Y using only the scale of the first feature
y_scaler_test = MinMaxScaler()
y_scaler_test.min_ = scaler_train.data_min_[0]
y_scaler_test.scale_ = scaler_train.scale_[0]

```

Πίνακας Ι.1 : Κώδικας Python για την Πρόβλεψη Φορτίου (Forecaster) (συνέχεια)

```

predictions      = y_scaler_test.inverse_transform(predictions.reshape(-1, 1))
LSTM_Prediction   = y_scaler_test.inverse_transform(LSTM_Prediction.reshape(-1, 1))
ANN_correction_factor =
y_scaler_test.inverse_transform(ANN_correction_factor.reshape(-1, 1))

# ----- PRINT -----
# Create a DataFrame
Results = Test_data.iloc[:-12,:] # 12 last values lost due to the way X_train and Y_train are
defined
Results = Results.reset_index(drop=True)
Results['Enhanced-LSTM Prediction'] = predictions.flatten()
Results['ANN Correction'] = ANN_correction_factor.flatten()
Results['Absolute Error'] = abs(Results['Consumption']-Results['Enhanced-LSTM Prediction'])
Results['Absolute Percentage Error'] = Results['Absolute Error']/Results['Consumption']
Results['Absolute Percentage Error'].replace([np.inf, -np.inf], np.nan, inplace=True)

# Calculate mean MAE for each day
daily_mae = Results.groupby('date')['Absolute Error'].mean()

# Find the day with the minimum mean MAE
min_mae_day = daily_mae.idxmin()

# Plot the data for that specific day
min_mae_data = Results[Results['date'] == min_mae_day]
plt.plot(min_mae_data['time_in_sec']/60, min_mae_data['Consumption'], label='Actual
Consumption')
plt.plot(min_mae_data['time_in_sec']/60, min_mae_data['Enhanced-LSTM Prediction'],
label='Enhanced-LSTM Predicted Consumption')
plt.plot(min_mae_data['time_in_sec']/60, min_mae_data['ANN Correction'], label='ANN
Correction Factor')
plt.xlabel('Time (minutes)')
plt.ylabel('Consumption')
plt.title(f'Day with Minimum MAE: {min_mae_day}')
plt.legend()
plt.show()

# Find the total daily consumption deviation
daily_consumption_estimated = min_mae_data['Consumption Predicted'].sum()
daily_consumption_real = min_mae_data['Consumption'].sum()

plt.figure(figsize=(10, 6))
plt.plot(Results['Consumption'], label='Πραγματικές Τιμές')
# pyplot.plot(y_pred_lstm1, label='LSTM Predicted')

```

Πίνακας Ι.1 : Κώδικας Python για την Πρόβλεψη Φορτίου (Forecaster) (συνέχεια)

```

plt.plot(predictions, label='Προβλέψεις ενισχυμένου LSTM')
# pyplot.plot(y_correction1, label='Προβλέψεις ANN')
plt.title('Model model_name')
plt.xlabel('Χρόνος (h)')
plt.ylabel('Κατανάλωση (kW)')
plt.legend()
plt.legend(loc='upper left')

plt.tight_layout()

if not os.path.exists(directory):
    os.makedirs(directory)

# filename_sanitise = sf.sanitize_filename(f'{model_name}.png')
# pyplot.savefig(cwf.create_windows_filename(filename_sanitise), bbox_inches='tight')
plt.savefig(f'{directory}/{model_name}.png', bbox_inches='tight')

```

```

helpers.py

#helpers to train the model
import InitialValues as iv
import numpy as np
import pandas as pd
import datetime
from sklearn.preprocessing import MinMaxScaler
from sklearn.model_selection import train_test_split

# raw data pre-processing
def process_consumption_data(path: str, flex_resource: str) -> pd.DataFrame:
    # Read raw data
    raw_data = pd.read_csv(path)

    # Convert time data to datetime and keep only data needed for the training
    raw_data['local_15min'] = pd.to_datetime(raw_data['local_15min'], utc=True)
    df = pd.DataFrame()
    df['date'] = raw_data['local_15min']
    df['day'] = raw_data['local_15min'].dt.date
    df['dataid'] = raw_data['dataid']
    df[flex_resource] = raw_data[flex_resource]

    # Step 1: Find the eligible houses data: the ones with over 85% of non-NaN values across all
    dataset
    non_nan_dataid = df.groupby('dataid')[flex_resource].apply(lambda x: x.count() / len(x) *
100)

```

Πίνακας Ι.1 : Κώδικας Python για την Πρόβλεψη Φορτίου (Forecaster) (συνέχεια)

```

filtered_df = df[df['dataid'].isin(non_nan_dataid[non_nan_dataid > 85].index)]

# Step 2: Find the eligible datetime data: days with more than 80 non-NaN values
non_nan_days = filtered_df.groupby(['dataid', 'day']).count()[flex_resource].reset_index()
# Count the number of nonNaN values per day, dataid
non_nan_days = non_nan_days[non_nan_days[flex_resource] > 80] # Remove days with
less than 80 non NaN values (out of 96 values/day)
IDs_per_day = non_nan_days.groupby('day')['dataid'].count().reset_index() # For each day
find the number of eligible houses (if 8 then all houses have data for that day)
eligible_days = IDs_per_day[IDs_per_day['dataid'] == len(filtered_df['dataid'].unique())]

filtered_df = filtered_df[filtered_df['day'].isin(eligible_days['day'])].set_index('dataid')

# Step 3: All negative and small measurements get to zero
filtered_df[flex_resource] = filtered_df[flex_resource].apply(lambda x: 0 if x < 0.05 else x)

# Step 4: Replace NaN values with the interpolation method
filtered_df[flex_resource] = filtered_df[flex_resource].interpolate(method='linear')

# Step 5: Get aggregate consumption for all houses
filtered_df = filtered_df.groupby('date')[iv.flex_resource].sum().reset_index()

# Step 6: Transform the data from wide to long format to help training
final_df = pd.melt(filtered_df, id_vars=['date'], value_vars=flex_resource,
var_name='Resource', value_name='Consumption')

return final_df

def process_appliance_data(df, start_date, end_date):
    # Select the specified time period
    if iv.PERIOD == 1:
        data = df[(df['date'] >= start_date) & (df['date'] <= end_date)]
    else:
        data = df[ ((df['date'] >= iv.FIRST_PERIOD_START) & (df['date'] <= iv.FIRST_PERIOD_END))
                    | ((df['date'] >= iv.SECOND_PERIOD_START) & (df['date'] <=
iv.SECOND_PERIOD_END))
                    | ((df['date'] >= iv.THIRD_PERIOD_START) & (df['date'] <=
iv.THIRD_PERIOD_END))
                    | ((df['date'] >= iv.FORTH_PERIOD_START) & (df['date'] <=
iv.FORTH_PERIOD_END))]
    # Reset the index
    data.reset_index(drop=True, inplace=True)

```

Πίνακας Ι.1 : Κώδικας Python για την Πρόβλεψη Φορτίου (Forecaster) (συνέχεια)

```

data.loc[:, 'date'] = data['date'].dt.date

# Get unique dates for train-test split
unique_dates = data['date'].unique()

# Split unique dates into training and testing sets
train_dates, test_dates = train_test_split(unique_dates, test_size=0.2, random_state=0) #
Set a random seed for reproducibility

# Select data for each set based on the chosen dates
train_data = data[data['date'].isin(train_dates)].reset_index(drop=True)
test_data = data[data['date'].isin(test_dates)].reset_index(drop=True)

# Sort the resulting DataFrames
train_data.sort_values(by=["date", "time_in_sec"], inplace=True)
test_data.sort_values(by=["date", "time_in_sec"], inplace=True)

# Scale the data with a single scaler dimensioned based on train data
scaler_ = MinMaxScaler(feature_range=(0, 1))
columns_to_scale = ['Consumption', 'time_in_sec', 'weekday', 'month']

# Fit and transform the selected columns
scaler_.fit(train_data[columns_to_scale])
train_data_scaled = scaler_.transform(train_data[columns_to_scale]) #NumPy array
required format for the fit_transform method
test_data_scaled = scaler_.transform(test_data[columns_to_scale]) #NumPy array
required format for the fit_transform method

# Create new DataFrames with the scaled consumption data
train_data_scaled_df = pd.DataFrame(train_data_scaled, columns=columns_to_scale)
test_data_scaled_df = pd.DataFrame(test_data_scaled, columns=columns_to_scale)

return train_data_scaled_df, test_data_scaled_df, train_data, test_data, scaler_

def series_to_supervised(data, n_vars, n_in, n_out):
    # Frame a time series as a supervised learning dataset. We want to have n_in for each
    feature and n_out only for consumption
    # data: n_vars dataframe with time-related features and scaled consumption as inputs
    # n_in: Number of lag observations as input (X).
    # n_out: Number of observations as output (y).
    # dropnan: Boolean whether or not to drop rows with NaN values.

    # Returns:

```

Πίνακας Ι.1 : Κώδικας Python για την Πρόβλεψη Φορτίου (Forecaster) (συνέχεια)

```
# Pandas DataFrame of series framed for supervised learning.

# we choose not to use year and month as features. Maybe month could be useful if we
had a full 1-year dataset
cols, names = list(), list()
# input sequence (t-n, ... t-1)
for i in range(n_in, 0, -1):
    cols.append(data.shift(-i))
    names += [('var%d(t-%d)' % (j+1, i)) for j in range(n_vars)]
# forecast sequence (t, t+1, ... t+n)
for i in range(0, n_out):
    y_vars = 1 # only consumption is the prediction
    cols.append(data.iloc[:,0].shift(-i)) # append only with consumption data
    if i == 0:
        names += [('var%d(t)' % (j+1)) for j in range(y_vars)]
    else:
        names += [('var%d(t+%d)' % (j+1, i)) for j in range(y_vars)]
# put it all together
agg = pd.concat(cols, axis=1)
agg.columns = names
agg.dropna(inplace=True)
return agg
```

EarlyStop.py

```
from tensorflow.python.keras.callbacks import Callback
import numpy as np

class EarlyStop(Callback):
    def __init__(self, window_size, min_delta, patience):
        super(EarlyStop, self).__init__()
        self.window_size = window_size
        self.min_delta = min_delta
        self.patience = patience
        self.wait = 0
        self.stopped_epoch = 0
        self.moving_average = []
        self.prev_avg_loss = None # Initialize the prev_avg_loss attribute

    def on_train_begin(self, logs=None):
        self.wait = 0

        self.stopped_epoch = 0
```

Πίνακας Ι.1 : Κώδικας Python για την Πρόβλεψη Φορτίου (Forecaster) (συνέχεια)

```
def on_epoch_end(self, epoch, logs=None):
    current_loss = logs.get('val_loss')
    self.moving_average.append(current_loss)

    if len(self.moving_average) > self.window_size:
        self.moving_average.pop(0)

    if len(self.moving_average) == self.window_size:
        avg_loss = np.mean(self.moving_average)
        if self.prev_avg_loss is not None: # Check if prev_avg_loss is not None
            diff = self.prev_avg_loss - avg_loss

            if diff <= self.min_delta:
                self.wait += 1
            else:
                self.wait = 0

            if self.wait >= self.patience:
                self.stopped_epoch = epoch
                self.model.stop_training = True

        self.prev_avg_loss = avg_loss

def on_train_end(self, logs=None):
    if self.stopped_epoch > 0:
        print(
            f"Epoch {self.stopped_epoch + 1}: early stopping due to moving average plateau")
```

II.2 PYOMO

Ακολουθεί ο κώδικας, σε Pyomo, που υλοποιήθηκε για τον υπολογισμό της βέλτιστης κατανάλωσης:

Πίνακας Ι.2 : Κώδικας Pyomo για τον υπολογισμό της βέλτιστης κατανάλωσης

```
from pyomo.environ import *

# Δημιουργία μοντέλου βελτιστοποίησης

model = ConcreteModel()
```

Πίνακας Ι.2 : Κώδικας Pyomo για τον υπολογισμό της βέλτιστης κατανάλωσης (συνέχεια)

```
# Σετ ωρών
Timesteps = \
[ '0:00', '0:15', '0:30', '0:45',
  '1:00', '1:15', '1:30', '1:45',
  '2:00', '2:15', '2:30', '2:45',
  '3:00', '3:15', '3:30', '3:45',
  '4:00', '4:15', '4:30', '4:45',
  '5:00', '5:15', '5:30', '5:45',
  '6:00', '6:15', '6:30', '6:45',
  '7:00', '7:15', '7:30', '7:45',
  '8:00', '8:15', '8:30', '8:45',
  '9:00', '9:15', '9:30', '9:45',
  '10:00', '10:15', '10:30', '10:45',
  '11:00', '11:15', '11:30', '11:45',
  '12:00', '12:15', '12:30', '12:45',
  '13:00', '13:15', '13:30', '13:45',
  '14:00', '14:15', '14:30', '14:45',
  '15:00', '15:15', '15:30', '15:45',
  '16:00', '16:15', '16:30', '16:45',
  '17:00', '17:15', '17:30', '17:45',
  '18:00', '18:15', '18:30', '18:45',
  '19:00', '19:15', '19:30', '19:45',
  '20:00', '20:15', '20:30', '20:45',
  '21:00', '21:15', '21:30', '21:45',
  '22:00', '22:15', '22:30', '22:45',
  '23:00', '23:15', '23:30', '23:45']

# Μέγιστες ποσότητες φόρτισης για κάθε 15λεπτο (προσομοιωτικές τιμές)
max_charge = \
{ '0:00': 67.736, '0:15': 67.736, '0:30': 67.736,
  '0:45': 67.736, '1:00': 67.736, '1:15': 67.736,
  '1:30': 67.736, '1:45': 67.736, '2:00': 67.736,
  '2:15': 67.736, '2:30': 67.736, '2:45': 67.736,
  '3:00': 67.736, '3:15': 67.736, '3:30': 67.736,
  '3:45': 67.736, '4:00': 67.736, '4:15': 67.736,
  '4:30': 67.736, '4:45': 67.736, '5:00': 67.736,
  '5:15': 67.736, '5:30': 67.736, '5:45': 67.736,
  '6:00': 67.736, '6:15': 67.736, '6:30': 67.736,
  '6:45': 67.736, '7:00': 67.736, '7:15': 67.736,
  '7:30': 67.736, '7:45': 67.736, '8:00': 67.736,
  '8:15': 67.736, '8:30': 67.736, '8:45': 67.736,
```

Πίνακας Ι.2 : Κώδικας Pyomo για τον υπολογισμό της βέλτιστης κατανάλωσης (συνέχεια)

```

'9:00': 67.736, '9:15': 67.736, '9:30': 67.736,
'9:45': 67.736, '10:00': 67.736, '10:15': 67.736,
'10:30': 67.736, '10:45': 67.736, '11:00': 67.736,
'11:15': 67.736, '11:30': 67.736, '11:45': 67.736,
'12:00': 67.736, '12:15': 67.736, '12:30': 67.736,
'12:45': 67.736, '13:00': 67.736, '13:15': 67.736,
'13:30': 67.736, '13:45': 67.736, '14:00': 67.736,
'14:15': 67.736, '14:30': 67.736, '14:45': 67.736,
'15:00': 67.736, '15:15': 67.736, '15:30': 67.736,
'15:45': 67.736, '16:00': 67.736, '16:15': 67.736,
'16:30': 67.736, '16:45': 67.736, '17:00': 67.736,
'17:15': 67.736, '17:30': 67.736, '17:45': 67.736,
'18:00': 67.736, '18:15': 67.736, '18:30': 67.736,
'18:45': 67.736, '19:00': 67.736, '19:15': 67.736,
'19:30': 67.736, '19:45': 67.736, '20:00': 67.736,
'20:15': 67.736, '20:30': 67.736, '20:45': 67.736,
'21:00': 67.736, '21:15': 67.736, '21:30': 67.736,
'21:45': 67.736, '22:00': 67.736, '22:15': 67.736,
'22:30': 67.736, '22:45': 67.736, '23:00': 67.736,
'23:15': 67.736, '23:30': 67.736, '23:45': 67.736
}

# Πρόβλεψη κατανάλωσης ενέργειας ανά 15λεπτο (προσομοιωτικές τιμές)
forecast_consumption = \
{ '0:00': 57.394, '0:15': 64.125, '0:30': 55.266,
  '0:45': 53.028, '1:00': 52.716, '1:15': 44.81,
  '1:30': 49.67, '1:45': 44.522, '2:00': 41.204,
  '2:15': 50.376, '2:30': 44.568, '2:45': 42.029,
  '3:00': 43.824, '3:15': 35.469, '3:30': 43.283,
  '3:45': 39.576, '4:00': 36.228, '4:15': 36.625,
  '4:30': 36.445, '4:45': 35.653, '5:00': 38.363,
  '5:15': 33.667, '5:30': 35.376, '5:45': 29.437,
  '6:00': 31.428, '6:15': 29.721, '6:30': 26.71,
  '6:45': 29.623, '7:00': 25.655, '7:15': 29.474,
  '7:30': 21.106, '7:45': 18.208, '8:00': 28.342,
  '8:15': 29.508, '8:30': 21.051, '8:45': 27.436,
  '9:00': 20.698, '9:15': 13.887, '9:30': 22.831,
  '9:45': 15.154, '10:00': 16.142, '10:15': 17.149,
  '10:30': 14.388, '10:45': 17.051, '11:00': 14.624,
  '11:15': 14.096, '11:30': 12.74, '11:45': 15.629,
  '12:00': 12.589, '12:15': 13.019, '12:30': 15.526,
  '12:45': 12.087, '13:00': 13.243, '13:15': 21.315,

```

Πίνακας Ι.2 : Κώδικας Pyomo για τον υπολογισμό της βέλτιστης κατανάλωσης (συνέχεια)

```

'13:30': 20.2, '13:45': 16.345, '14:00': 22.88,
'14:15': 15.12, '14:30': 18.428, '14:45': 19.517,
'15:00': 18.266, '15:15': 23.233, '15:30': 28.327,
'15:45': 24.409, '16:00': 27.396, '16:15': 27.74,
'16:30': 24.285, '16:45': 33.814, '17:00': 35.64,
'17:15': 38.252, '17:30': 39.282, '17:45': 40.9,
'18:00': 40.897, '18:15': 46.007, '18:30': 50.422,
'18:45': 57.276, '19:00': 48.799, '19:15': 49.797,
'19:30': 57.05, '19:45': 59.231, '20:00': 59.71,
'20:15': 58.765, '20:30': 51.767, '20:45': 45.312,
'21:00': 44.159, '21:15': 50.705, '21:30': 47.939,
'21:45': 54.858, '22:00': 42.216, '22:15': 60.707,
'22:30': 57.834, '22:45': 57.462, '23:00': 64.577,
'23:15': 61.856, '23:30': 63.371, '23:45': 59.336
}

# Τιμές ηλεκτρικής ενέργειας για κάθε 15λεπτο (Διαφορετικές τιμές, ανάλογα την
τιμολογιακή πολιτική)
electricity_price = \
{ '0:00': 0.175, '0:15': 0.175, '0:30': 0.175,
'0:45': 0.175, '1:00': 0.175, '1:15': 0.175,
'1:30': 0.175, '1:45': 0.175, '2:00': 0.175,
'2:15': 0.175, '2:30': 0.175, '2:45': 0.175,
'3:00': 0.175, '3:15': 0.175, '3:30': 0.175,
'3:45': 0.175, '4:00': 0.175, '4:15': 0.175,
'4:30': 0.175, '4:45': 0.175, '5:00': 0.175,
'5:15': 0.175, '5:30': 0.175, '5:45': 0.175,
'6:00': 0.175, '6:15': 0.175, '6:30': 0.175,
'6:45': 0.175, '7:00': 0.175, '7:15': 0.175,
'7:30': 0.175, '7:45': 0.175, '8:00': 0.175,
'8:15': 0.175, '8:30': 0.175, '8:45': 0.175,
'9:00': 0.175, '9:15': 0.175, '9:30': 0.175,
'9:45': 0.175, '10:00': 0.175, '10:15': 0.175,
'10:30': 0.175, '10:45': 0.175, '11:00': 0.175,
'11:15': 0.175, '11:30': 0.175, '11:45': 0.175,
'12:00': 0.175, '12:15': 0.175, '12:30': 0.175,
'12:45': 0.175, '13:00': 0.175, '13:15': 0.175,
'13:30': 0.175, '13:45': 0.175, '14:00': 0.175,
'14:15': 0.175, '14:30': 0.175, '14:45': 0.175,
'15:00': 0.175, '15:15': 0.175, '15:30': 0.175,
'15:45': 0.175, '16:00': 0.175, '16:15': 0.175,
'16:30': 0.175, '16:45': 0.175, '17:00': 0.175,

```

Πίνακας Ι.2 : Κώδικας Pyomo για τον υπολογισμό της βέλτιστης κατανάλωσης (συνέχεια)

```

'17:15': 0.175, '17:30': 0.175, '17:45': 0.175,
'18:00': 0.175, '18:15': 0.175, '18:30': 0.175,
'18:45': 0.175, '19:00': 0.175, '19:15': 0.175,
'19:30': 0.175, '19:45': 0.175, '20:00': 0.175,
'20:15': 0.175, '20:30': 0.175, '20:45': 0.175,
'21:00': 0.175, '21:15': 0.175, '21:30': 0.175,
'21:45': 0.175, '22:00': 0.175, '22:15': 0.175,
'22:30': 0.175, '22:45': 0.175, '23:00': 0.175,
'23:15': 0.175, '23:30': 0.175, '23:45': 0.175
}

# Μεταβλητές αποφάσεων
### Community
model.charge = Var(Timesteps, within=[0, 3.34, 6.681])
### Houses
## 661
# model.charge = Var(Timesteps, within=[0, 1.708, 3.416])
## 1642
# model.charge = Var(Timesteps, within=[0, 2.145, 4.29])
## 4373
# model.charge = Var(Timesteps, within=[0, 2, 4])
## 4767
# model.charge = Var(Timesteps, within=[0, 3.995, 7.99])
## 6139
# model.charge = Var(Timesteps, within=[0, 1.78, 3.56])
## 7719
# model.charge = Var(Timesteps, within=[0, 1.66, 3.32])
## 8156
# model.charge = Var(Timesteps, within=[0, 2, 4])

# Συνάρτηση κόστους
def cost_function(model):
    return sum(model.charge[t] * electricity_price[t] for t in Timesteps)

model.cost = Objective(rule=cost_function, sense=minimize)

# Περιορισμοί (Φραγμός στην ωριαία κατανάλωση - Αντοχές φορτιστή)
def charge_constraint_rule(model, t):
    return model.charge[t] <= max_charge[t]

model.charge_constraint = Constraint(Timesteps, rule=charge_constraint_rule)

```

Πίνακας Ι.2 : Κώδικας Pyomo για τον υπολογισμό της βέλτιστης κατανάλωσης (συνέχεια)

```
# Συνολική κατανάλωση
def total_consumption_constraint(model):
    return sum(model.charge[t] for t in Timesteps) == sum(forecast_consumption[t] for t
in Timesteps)

model.total_consumption_constraint = Constraint(rule=total_consumption_constraint)

# Επίλυση
import sys
solvername='glpk'
solverpath_folder=r"Z:\\Temp\\VM
Mine\\Dipl\\Dipl\\1\\Refactored\\Pyomo\\glpk\\w64\\" #does not need to be directly
on c drive
solverpath_exe=r"Z:\\Temp\\VM
Mine\\Dipl\\Dipl\\1\\Refactored\\Pyomo\\glpk\\w64\\glpsol\\" #does not need to be
directly on c drive

sys.path.append(solverpath_folder)
solver=SolverFactory(solvername,executable=solverpath_exe)

# solver = SolverFactory('glpk')
results = solver.solve(model)

# Εκτύπωση αποτελεσμάτων
# Check if the model has been successfully solved
if results.solver.status == SolverStatus.ok and results.solver.termination_condition ==
TerminationCondition.optimal:
    # Print the values of the decision variables
    for t in Timesteps:
        print(model.charge[h].value)
    print("\\Total cost:\\", model.cost())
else:
    print("\\Solver did not find an optimal solution.\\")

# Εκτύπωση του μοντέλου
# model.pprint()
# model.display()
```