



ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ ΚΑΙ
ΤΕΧΝΟΛΟΓΙΑΣ (Σ.Θ.Ε.Τ.)

ΜΕΤΑΠΤΥΧΙΑΚΗ ΕΞΕΙΔΙΚΕΥΣΗ ΣΤΑ
ΠΛΗΡΟΦΟΡΙΑΚΑ ΣΥΣΤΗΜΑΤΑ - ΠΣ ΠΛΣ

Διπλωματική Εργασία

Ανάπτυξη μοντέλου πρόβλεψης ενεργειακής ζήτησης σε λιμενικές
εγκαταστάσεις με χρήση τεχνικών μηχανικής μάθησης

ΕΝΤΜΟΝΣ ΑΛΙΚΗ

Επιβλέπων καθηγητής: ΣΗΦΑΚΗΣ ΝΙΚΟΛΑΟΣ

Πάτρα, Ιούλιος 2026

Η παρούσα εργασία αποτελεί πνευματική ιδιοκτησία του/της φοιτητή/φοιτήτριας («συγγραφέας/δημιουργός») που την εκπόνησε. Στο πλαίσιο της πολιτικής ανοικτής πρόσβασης ο συγγραφέας/δημιουργός εκχωρεί στο ΕΑΠ, μη αποκλειστική άδεια χρήσης του δικαιώματος αναπαραγωγής, προσαρμογής, δημόσιου δανεισμού, παρουσίασης στο κοινό και ψηφιακής διάχυσής τους διεθνώς, σε ηλεκτρονική μορφή και σε οποιοδήποτε μέσο, για διδακτικούς και ερευνητικούς σκοπούς, άνευ ανταλλάγματος και για όλο το χρόνο διάρκειας των δικαιωμάτων πνευματικής ιδιοκτησίας. Η ανοικτή πρόσβαση στο πλήρες κείμενο για μελέτη και ανάγνωση δεν σημαίνει καθ' οιονδήποτε τρόπο παραχώρηση δικαιωμάτων διανοητικής ιδιοκτησίας του συγγραφέα/δημιουργού ούτε επιτρέπει την αναπαραγωγή, αναδημοσίευση, αντιγραφή, αποθήκευση, πώληση, εμπορική χρήση, μετάδοση, διανομή, έκδοση, εκτέλεση, «μεταφόρτωση» (downloading), «ανάρτηση» (uploading), μετάφραση, τροποποίηση με οποιονδήποτε τρόπο, τμηματικά ή περιληπτικά της εργασίας, χωρίς τη ρητή προηγούμενη έγγραφη συναίνεση του συγγραφέα/δημιουργού. Ο συγγραφέας/δημιουργός διατηρεί το σύνολο των ηθικών και περιουσιακών του δικαιωμάτων.

Ανάπτυξη μοντέλου πρόβλεψης ενεργειακής ζήτησης σε λιμενικές εγκαταστάσεις με χρήση τεχνικών μηχανικής μάθησης

ΕΝΤΜΟΝΣ ΑΛΙΚΗ

Επιτροπή Επίβλεψης Διπλωματικής Εργασίας

Επιβλέπων Καθηγητής:
ΝΙΚΟΛΑΟΣ ΣΗΦΑΚΗΣ,
ΕΑΠ, ΤΥΣ

Συν-Επιβλέπων Καθηγητής:
ΚΑΡΛΟΣ ΣΤΑΜΑΤΗΣ,
ΕΑΠ

Πάτρα, Ιούλιος 2026

Αφιερώνεται στον πατέρα μου

*Ευχαριστώ τον επιβλέποντα καθηγητή Δρ. Νικόλαο Σηφάκη και το ΕΑΠ για την στήριξη τους
και την καθοδήγηση τους στην εκπόνηση της παρούσας διπλωματικής εργασίας.*

Περίληψη

Η παρούσα διπλωματική εργασία εξετάζει το πρόβλημα της βραχυπρόθεσμης πρόβλεψης της ηλεκτρικής ζήτησης σε λιμενικές εγκαταστάσεις, με μελέτη περίπτωσης τον Νότιο Λιμένα Πατρών. Η ενεργειακή ζήτηση των σύγχρονων λιμένων αποκτά αυξανόμενη σημασία στο πλαίσιο της ναυτιλιακής απανθρακοποίησης, της ηλεκτροδότησης πλοίων εν στάσει (OPS) και της μετάβασης προς το πρότυπο του σχεδόν μηδενικής ενεργειακής κατανάλωσης λιμένα (nZEP), καθιστώντας την ακριβή πρόβλεψη φορτίου προϋπόθεση για την αποδοτική ενεργειακή διαχείριση. Αξιοποιήθηκαν ωριαία δεδομένα κατανάλωσης ηλεκτρικής ενέργειας για την περίοδο 2021–2025, σε συνδυασμό με μετεωρολογικά δεδομένα (Open-Meteo) και ημερολογιακά χαρακτηριστικά. Μετά από διερευνητική ανάλυση που ανέδειξε έντονη ημερήσια και εβδομαδιαία περιοδικότητα στη χρονοσειρά, αναπτύχθηκαν και συγκρίθηκαν τέσσερα μοντέλα πρόβλεψης: Γραμμική Παλινδρόμηση (μοντέλο αναφοράς), Random Forest, XGBoost και δίκτυα LSTM (μονομεταβλητή και πολυμεταβλητή διαμόρφωση, για ακολουθιακά παράθυρα εισόδου 24 και 168 ωρών), με χρήση χρονικά ορθής διαδικασίας επικύρωσης τύπου rolling-origin. Τα αποτελέσματα δείχνουν ότι τα μοντέλα βασισμένα σε δέντρα απόφασης (Random Forest, XGBoost) πέτυχαν ανταγωνιστική έως καλύτερη απόδοση σε σχέση με τα πολυπλοκότερα δίκτυα LSTM, υποδηλώνοντας ότι η αύξηση της αλγοριθμικής πολυπλοκότητας δεν οδηγεί απαραίτητα σε ανάλογη βελτίωση της προγνωστικής ακρίβειας για το συγκεκριμένο πρόβλημα. Η ανάλυση σημαντικότητας χαρακτηριστικών ανέδειξε τις μεταβλητές χρονικής υστέρησης ως κυρίαρχο παράγοντα πρόβλεψης. Τα ευρήματα παρέχουν πρακτικές κατευθύνσεις για την επιλογή μοντέλων βραχυπρόθεσμης πρόβλεψης φορτίου σε λιμενικά περιβάλλοντα.

Λέξεις – Κλειδιά

βραχυπρόθεσμη πρόβλεψη φορτίου; ενεργειακή ζήτηση λιμένων; μηχανική μάθηση; LSTM; Random Forest

Development of a Machine Learning-Based Energy Demand Forecasting Model for Port Facilities

EDMUNDS ALICE

Abstract

This thesis addresses short-term electrical load forecasting for port facilities, using the South Port of Patras as a case study. Energy demand in modern ports is of growing importance in the context of maritime decarbonisation, onshore power supply (OPS) for berthed vessels, and the transition toward the nearly-zero-energy port (nZEP) concept, making accurate load forecasting a prerequisite for effective energy management. Hourly electricity consumption data for the period 2021-2025 were combined with weather data (Open-Meteo) and calendar features. Following exploratory analysis that revealed strong daily and weekly periodicity in the series, four forecasting models were developed and compared: Linear Regression (benchmark), Random Forest, XGBoost, and LSTM networks (univariate and multivariate configurations, for 24- and 168-hour input windows), evaluated using a time-respecting rolling-origin validation procedure. Results show that tree-based models (Random Forest, XGBoost) achieved competitive-to-superior performance compared to the more complex LSTM networks, indicating that increased algorithmic complexity does not necessarily translate into proportional gains in forecasting accuracy for this problem. Feature importance analysis identified lagged-demand variables as the dominant predictors. The findings offer practical guidance for model selection in short-term load forecasting for port environments.

Keywords

short-term load forecasting; port energy demand; machine learning; LSTM; Random Forest

Περιεχόμενα

Περίληψη.....	v
Abstract	vi
Περιεχόμενα	vii
Κατάλογος Εικόνων και Σχημάτων	xi
Κατάλογος Πινάκων	xiii
Συνοτομογραφίες & Ακρωνύμια	xiv
ΚΕΦΑΛΑΙΟ 1. ΕΙΣΑΓΩΓΗ	1
1.1. Εξέλιξη και σύγχρονος ρόλος των θαλάσσιων λιμένων	1
1.1.1. Οι λιμένες ως κρίσιμοι κόμβοι του παγκόσμιου εμπορίου	1
1.1.2. Από τον μεταφορικό κόμβο στο ολοκληρωμένο οικοσύστημα εφοδιαστικής αλυσίδας	1
1.1.3. Ψηφιοποίηση και ανάδυση του έξυπνου λιμένα	2
1.2. Περιβαλλοντικές και κοινωνικές επιπτώσεις των λιμενικών δραστηριοτήτων	3
1.2.1. Ατμοσφαιρικές εκπομπές και δημόσια υγεία.....	3
1.2.2. Επιπτώσεις στο φυσικό περιβάλλον.....	3
1.2.3. Η διαπαφή λιμένα–πόλης και η κοινωνική άδεια λειτουργίας.....	4
1.3. Βιώσιμη, πράσινη και έξυπνη λιμενική ανάπτυξη.....	4
1.3.1. Εννοιολογικές διακρίσεις και συμπληρωματικότητα	4
1.3.2. Περιβαλλοντική, οικονομική και κοινωνική διάσταση της βιωσιμότητας	5
1.3.3. Συστήματα περιβαλλοντικής διαχείρισης και εργαλεία διακυβέρνησης	5
1.3.4. Δείκτες επίδοσης, συγκριτική αξιολόγηση (benchmarking) και συνεχής βελτίωσης.....	6
1.4. Ενεργειακή μετάβαση και έξυπνη διαχείριση ηλεκτρικής ενέργειας στους λιμένες.....	6
1.4.1. Σύνθεση και δυναμική της ηλεκτρικής κατανάλωσης	6
1.4.2. Εξηλεκτρισμός, ηλεκτροδότηση από ξηράς (OPS) και νέα ευέλικτα φορτία.....	7
1.4.3. Ανανεώσιμες πηγές ενέργειας (ΑΠΕ), αποθήκευση, μικροδίκτυα (microgrids) και συστήματα ενεργειακής διαχείρισης.....	7
1.4.4. Από την παρακολούθηση στη βραχυπρόθεσμη πρόβλεψη φορτίου	8
1.5. Κανονιστικό και στρατηγικό πλαίσιο της λιμενικής ηλεκτροδότησης.....	8
1.5.1. Διεθνής ναυτιλιακή απανθρακοποίηση	8
1.5.2. Ευρωπαϊκό πλαίσιο AFIR και FuelEU Maritime.....	9
1.5.3. Περιβαλλοντικά, οικονομικά και δικτυακά κίνητρα.....	10
1.5.4. Συνέπειες της ηλεκτροδότησης για τον ενεργειακό σχεδιασμό.....	10
1.6. Αντικείμενο και ευρύτερο πλαίσιο.....	11
1.6.1. Οι λιμένες ως σύνθετα ενεργειακά και επιχειρησιακά συστήματα.....	11
1.6.2. Ετερογένεια φορτίων και λιμενικών τύπων	12
1.6.3. Από τον παθητικό καταναλωτή στον ενεργό ενεργειακό κόμβο	14
1.7. Η ενεργειακή ζήτηση ως πρόβλημα πρόβλεψης.....	14
1.7.1. Μεταβλητή-στόχος, χρονική ανάλυση και ορίζοντας.....	14
1.7.2. Χρονική δομή, μη στασιμότητα και σπάνια συμβάντα.....	15
1.7.3. Πολυπηγικά δεδομένα και πραγματική διαθεσιμότητα πληροφορίας	15
1.7.4. Επιχειρησιακές χρήσεις της πρόβλεψης.....	16
1.7.5. Ταξινόμηση του προβλήματος και επίπεδα δυσκολίας.....	17

1.8. Διατύπωση του ερευνητικού προβλήματος.....	18
1.8.1. Αποσύνθεση του λιμενικού φορτίου.....	18
1.8.2. Συνάρτηση πρόβλεψης και σύνολο πληροφορίας.....	18
1.8.3. Εκπαίδευση και τακτικοποίηση μοντέλων πρόβλεψης.....	19
1.8.4. Πιθανοτική πρόβλεψη και αβεβαιότητα	19
1.9. Μεθοδολογικό πλαίσιο ανάπτυξης συστημάτων πρόβλεψης ηλεκτρικού φορτίου .	20
1.10. Σκοπός και επιμέρους στόχοι.....	21
1.11. Ερευνητικά ερωτήματα	22
1.12. Αναμενόμενη συμβολή της εργασίας.....	23
1.13. Δομή της διπλωματικής εργασίας	23
2. ΚΕΦΑΛΑΙΟ 2 — ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ ΚΑΙ ΜΕΘΟΔΟΛΟΓΙΕΣ ΠΡΟΒΛΕΨΗΣ.....	24
2.1. Η έννοια και χαρακτηριστικά της χρονοσειράς	24
2.1.1. Η έννοια της χρονοσειράς	24
2.1.2. Αποσύνθεση της χρονοσειράς σε συνιστώσες.....	24
2.1.3. Σημασία της πρόβλεψης ηλεκτρικού φορτίου	25
2.1.4. Χρονικοί ορίζοντες πρόβλεψης (forecasting horizons)	26
2.2. Παράγοντες που επηρεάζουν το ηλεκτρικό φορτίο	28
2.2.1. Ιστορικά δεδομένα φορτίου	28
2.2.2. Μετεωρολογικές μεταβλητές	29
2.2.3. Ημερολογιακές μεταβλητές	29
2.2.4. Κοινωνικοοικονομικοί, συμπεριφορικοί και άλλοι παράγοντες.....	30
2.2.5. Επιχειρησιακά και ναυτιλιακά δεδομένα	30
2.3. Μέθοδοι πρόβλεψης χρονοσειρών ηλεκτρικού φορτίου.....	31
2.3.1. Κλασικές Στατιστικές Μέθοδοι	31
2.3.2. Μέθοδοι Μηχανικής Μάθησης	33
2.3.3. Μέθοδοι Βαθιάς Μάθησης.....	39
2.3.4. Σύγχρονες και υβριδικές μέθοδοι και μέθοδοι συνόλων	47
2.4. Πιθανοτική πρόβλεψη και αβεβαιότητα	49
2.5. Θεμελιώδεις Αρχές Εκπαίδευσης Αλγορίθμων Μηχανικής Μάθησης.....	50
2.5.1. Συνάρτηση Απώλειας και Πρόβλημα Βελτιστοποίησης.....	50
2.5.2. Οπισθοδιάδοση Σφάλματος και Κατάβαση Κλίσης κατά την εκπαίδευση νευρωνικών δικτύων (Backpropagation of Error & Gradient Descent).....	50
2.5.3. Γενίκευση, Υπερπροσαρμογή και Υποπροσαρμογή.....	53
2.5.4. Πρωτόκολλα εκπαίδευσης και χρονικά ορθή επικύρωση.....	53
2.6. Μετρικές αξιολόγησης μοντέλων πρόβλεψης.....	54
2.6.1. Συντελεστής Προσδιορισμού (Coefficient of determination - R ²).....	55
2.6.2. Μέσο Απόλυτο Σφάλμα (Mean Absolute Error, MAE).....	55
2.6.3. Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error, MSE).....	55
2.6.4. Ρίζα Μέσου Τετραγωνικού Σφάλματος (Root Mean Squared Error - RMSE).56	
2.6.5. Συντελεστής Μεταβλητότητας του RMSE (Coefficient of Variation of Root Mean Squared Error - CVRMSE)	56
2.6.6. Κανονικοποιημένη Ρίζα Μέσου Τετραγωνικού Σφάλματος (Normalised Root Mean Squared Error - NRMSE).....	56
2.6.7. Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (MAPE)	57
2.6.8. Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (sMAPE).....	57

2.6.9. Μέσο Απόλυτο Κλιμακωμένο Σφάλμα (Mean Absolute Scaled Error – MASE)	57
2.6.10. Συμπληρωματικοί και ειδικοί δείκτες αξιολόγησης	58
2.7. Βιβλιογραφική ανασκόπηση εφαρμογών ELF σε λιμένες	59
2.8. Ερευνητικά κενά	61
2.9. Σύνδεση της βιβλιογραφίας με την παρούσα εργασία	63
2.10. Σύγχρονες ερευνητικές προκλήσεις	64
3. ΚΕΦΑΛΑΙΟ 3 – Περιγραφή δεδομένων και διερευνητική ανάλυση	65
3.1. Περιγραφή περίπτωσης μελέτης	65
3.1.1. Ο Λιμένας Πατρών ως αντικείμενο μελέτης	65
3.1.2. Επιβατική κίνηση στον Λιμένα Πατρών την περίοδο 2021-2025	66
3.1.3. Εμπορευματική κίνηση στον Λιμένα Πατρών την περίοδο 2021-2025	67
3.2. Ενεργειακά δεδομένα	68
3.3. Μετεωρολογικά δεδομένα	68
3.4. Διερευνητική ανάλυση δεδομένων	69
3.4.1. Χρονική εξέλιξη της κατανάλωσης ηλεκτρικής ενέργειας	69
3.4.2. Ημερήσια, εβδομαδιαία και εποχικά πρότυπα κατανάλωσης	69
3.4.3. Κατανομή της κατανάλωσης και ανάλυση αιχμών φορτίου	72
3.4.4. Αυτοσυσχέτιση και χρονική εξάρτηση της χρονοσειράς	74
4. Κεφάλαιο 4 — Μεθοδολογία	76
4.1. Συνολικό πλαίσιο πρόβλεψης	76
4.1.1. Περιβάλλον υλοποίησης και λογισμικό	76
4.2. Προεπεξεργασία δεδομένων	76
4.2.1. Έλεγχος δεδομένων και χρονολογική συνέπεια	76
4.2.2. Διαχείριση μηδενικών τιμών και ανωμαλιών	77
4.2.3. Χρονολογικός διαχωρισμός εκπαίδευσης–ελέγχου	77
4.3. Μηχανική χαρακτηριστικών (Feature Engineering)	77
4.3.1. Μεταβλητές χρονικής υστέρησης	78
4.3.2. Μετεωρολογικές μεταβλητές	78
4.3.3. Μεταβλητή χρονικής τάσης	79
4.3.4. Ημερολογιακές μεταβλητές	79
4.4. Κλιμάκωση δεδομένων	80
4.4.1. Τυποποίηση (standardization)	80
4.4.2. Κανονικοποίηση (Normalization)	80
4.5. Ανάπτυξη μοντέλων πρόβλεψης	81
4.5.1. Μοντέλο Γραμμικής Παλινδρόμησης	81
4.5.2. Μοντέλο τυχαίου δάσους (Random Forest)	81
4.5.3. Μοντέλο XGBoost	82
4.5.4. Ανάπτυξη των μοντέλων LSTM	83
4.6. Μετρικές σφάλματος και διαγνωστική αξιολόγηση των μοντέλων	88
4.6.1. Αριθμητικές μετρικές αξιολόγησης	88
4.6.2. Διαγνωστική αξιολόγηση μοντέλων	88
5. ΚΕΦΑΛΑΙΟ 5 — ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΣΥΖΗΤΗΣΗ	88
5.1. Αποτελέσματα Γραμμικής Παλινδρόμησης	88
5.1.1. Μετρικές απόδοσης	89
5.1.2. Πραγματικές και προβλεπόμενες τιμές χρονοσειράς	89

5.1.3. Χρονική συμπεριφορά των υπολοίπων	92
5.1.4. Συντελεστές μοντέλου.....	93
5.2. Αποτελέσματα μοντέλου τυχαίου δάσους (Random Forest)	94
5.2.1. Μετρικές απόδοσης.....	94
5.2.2. Πραγματικές και προβλεπόμενες τιμές χρονοσειράς.....	95
5.2.3. Χρονική συμπεριφορά των υπολοίπων	97
5.2.4. Σημαντικότητα χαρακτηριστικών	99
5.3. Αποτελέσματα XGBoost.....	100
5.3.1. Μετρικές απόδοσης.....	100
5.3.2. Πραγματικές και προβλεπόμενες τιμές χρονοσειράς.....	101
5.3.3. Χρονική συμπεριφορά των υπολοίπων	103
5.3.4. Σημαντικότητα χαρακτηριστικών	105
5.4. Αποτελέσματα LSTM	106
5.4.1. Μετρικές απόδοσης.....	106
5.4.2. Αποτελέσματα διασταυρωμένης επικύρωσης.....	107
5.4.3. Τελική αξιολόγηση στο σύνολο ελέγχου	108
5.4.4. Πραγματικές και προβλεπόμενες τιμές χρονοσειράς.....	108
5.4.5. Χρονική συμπεριφορά των υπολοίπων	111
5.4.6. Επίδραση των εξωγενών μεταβλητών στα πολυμεταβλητά μοντέλα LSTM	113
5.5. Συγκριτική Αξιολόγηση Μοντέλων	116
5.5.1. Σύγκριση προγνωστικής επίδοσης	116
5.5.2. Επίδραση της χρονικής πληροφορίας	117
5.5.3. Επίδραση των εξωγενών μεταβλητών.....	118
5.5.4. Ερμηνεία της επίδοσης των μοντέλων	119
5.6. Συζήτηση και σύνδεση με τη βιβλιογραφία.....	120
5.6.1. Επισκόπηση των κύριων ευρημάτων	120
5.6.2. Προγνωστική απόδοση και οικογένεια μοντέλων	121
5.6.3. Ο ρόλος της ιστορικής πληροφορίας και της μηχανικής χαρακτηριστικών ...	125
5.6.4. Ερμηνεία των ευρημάτων και πρακτικές προεκτάσεις	127
6. ΚΕΦΑΛΑΙΟ 6 - ΣΥΜΠΕΡΑΣΜΑΤΑ	128
6.1. Σύνοψη της έρευνας.....	128
6.2. Βασικά συμπεράσματα.....	129
6.3. Παραδοχές και περιορισμοί της μελέτης	130
6.4. Προτάσεις για μελλοντική έρευνα	131

Κατάλογος Εικόνων και Σχημάτων

Εικόνα 1. Δορυφορική απεικόνιση του Λιμένα Πατρών. Διακρίνονται οι κύριες θαλάσσιες συνδέσεις του λιμένα προς την Ιταλία και τα νησιά του Ιονίου (Google Maps).....	65
Σχήμα 1. Κύριες συνιστώσες της ηλεκτρικής ζήτησης σε λιμενικές εγκαταστάσεις	12
Σχήμα 2. Ενδεικτική ροή ανάπτυξης, επικύρωσης και αξιοποίησης του μοντέλου πρόβλεψης.	21
Σχήμα 3. Τριμηνιαία επιβατική κίνηση λιμένα Πατρών 2021-2025	66
Σχήμα 4. Τριμηνιαία διακίνηση εμπορευμάτων στον Λιμένα Πατρών 2021-2025.....	68
Σχήμα 5. Ωριαία κατανάλωση ηλεκτρικής ενέργειας λιμένα Πάτρας 2021-2025.....	69
Σχήμα 6. Μέσο ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας λιμένα Πάτρας 2021-2025	70
Σχήμα 7. Διάγραμμα κουτιού (boxplot) κατανάλωσης ηλεκτρικής ενέργειας λιμένα Πάτρας ανά ημέρα της εβδομάδας.	70
Σχήμα 8. Διάγραμμα κουτιού (boxplot) κατανάλωσης ηλεκτρικής ενέργειας λιμένα Πάτρας ανά μήνα του έτους.	71
Σχήμα 9. Μέση μηνιαία κατανάλωση ηλεκτρικής ενέργειας λιμένα Πάτρας 2021-2025 ..	72
Σχήμα 10. Μέση ωριαία κατανάλωση ηλεκτρικής ενέργειας ανά μήνα στο λιμάνι της Πάτρας 2021-2025	72
Σχήμα 11. Κατανομή κατανάλωσης ηλεκτρικής ενέργειας λιμένα Πάτρας 2021-2025.....	73
Σχήμα 12. Ανάλυση αιχμών κατανάλωσης ηλεκτρικής ενέργειας στο λιμάνι της Πάτρας	74
Σχήμα 13. Διορθογράμματα αυτοσυσχέτισης της κατανάλωσης ηλεκτρικής ενέργειας στο λιμάνι της Πάτρας για την περίοδο 2021–2025 για 0–175 υστερήσεις (άνω) και 0-48 υστερήσεις για εστίαση στην ημερήσια περιοδικότητα (κάτω).	75
Σχήμα 14: Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου στο σύνολο ελέγχου για το μοντέλο γραμμικής παλινδρόμησης	89
Σχήμα 15. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου για τις 10 πρώτες ημέρες του συνόλου ελέγχου στο μοντέλο γραμμικής παλινδρόμησης.....	90
Σχήμα 16. Συσχέτιση μεταξύ πραγματικών και προβλεπόμενων τιμών φορτίου στο σύνολο ελέγχου για το μοντέλο γραμμικής παλινδρόμησης	91
Σχήμα 17. Υπόλοιπα του μοντέλου γραμμικής παλινδρόμησης στο σύνολο ελέγχου.	92
Σχήμα 18. Συνάρτηση αυτοσυσχέτισης (ACF) των υπολοίπων του μοντέλου γραμμικής παλινδρόμησης.	93
Σχήμα 19. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου στο σύνολο ελέγχου για το μοντέλο τυχαίου δάσους.....	95
Σχήμα 20. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου για τις 10 πρώτες ημέρες του συνόλου ελέγχου στο μοντέλο τυχαίου δάσους (Random Forest).....	96
Σχήμα 21. Συσχέτιση μεταξύ πραγματικών και προβλεπόμενων τιμών φορτίου στο σύνολο ελέγχου για το μοντέλο τυχαίου δάσους (Random Forest).	97
Σχήμα 22. Υπόλοιπα του μοντέλου τυχαίου δάσους (Random Forest) στο σύνολο ελέγχου.	98
Σχήμα 23. Συνάρτηση αυτοσυσχέτισης (ACF) των υπολοίπων του μοντέλου τυχαίου δάσους (Random Forest).	99

Σχήμα 24. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου στο σύνολο ελέγχου για το μοντέλο XGBoost	101
Σχήμα 25. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου για τις 10 πρώτες ημέρες του συνόλου ελέγχου στο μοντέλο XGBoost	102
Σχήμα 26. Συσχέτιση μεταξύ πραγματικών και προβλεπόμενων τιμών φορτίου στο σύνολο ελέγχου για το μοντέλο XGBoost	103
Σχήμα 27. Υπόλοιπα του μοντέλου XGBoost στο σύνολο ελέγχου.	104
Σχήμα 28. Συνάρτηση αυτοσυσχέτισης (ACF) των υπολοίπων για το μοντέλο XGBoost	105
Σχήμα 29. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου στο σύνολο ελέγχου για το βέλτιστο μοντέλο LSTM	109
Σχήμα 30. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου για τις 10 πρώτες ημέρες του συνόλου ελέγχου στο βέλτιστο μοντέλο LSTM.....	110
Σχήμα 31. Συσχέτιση μεταξύ πραγματικών και προβλεπόμενων τιμών φορτίου στο σύνολο ελέγχου για το βέλτιστο μοντέλο LSTM	111
Σχήμα 32. Υπόλοιπα του βέλτιστου μοντέλου LSTM στο σύνολο ελέγχου.	112
Σχήμα 33. Συνάρτηση αυτοσυσχέτισης (ACF) των υπολοίπων του βέλτιστου μοντέλου LSTM.	113
Σχήμα 34. Σημασία χαρακτηριστικών (permutation importance) για το πολυμεταβλητό μοντέλο LSTM με παράθυρο εισόδου 24 ωρών.	114
Σχήμα 35. Σημασία χαρακτηριστικών (permutation importance) για το πολυμεταβλητό μοντέλο LSTM με παράθυρο εισόδου 168 ωρών.	115

Κατάλογος Πινάκων

Πίνακας 1. Συγκριτική διάκριση πράσινου, βιώσιμου και έξυπνου λιμένα και σύνδεση με την πρόβλεψη ηλεκτρικού φορτίου.....	4
Πίνακας 2. Ενδεικτικές συνιστώσες φορτίου και προσδιοριστικοί παράγοντες.....	13
Πίνακας 3. Χρονικοί ορίζοντες πρόβλεψης ηλεκτρικού φορτίου και αντιπροσωπευτικές εφαρμογές και συνήθειες μεταβλητές εισόδου.....	27
Πίνακας 4. Πλεονεκτήματα και περιορισμοί βασικών δεικτών.....	58
Πίνακας 5. Επιλεγμένες μελέτες πρόβλεψης ή μοντελοποίησης λιμενικής ηλεκτρικής ζήτησης.....	62
Πίνακας 6. Μετεωρολογικές μεταβλητές που χρησιμοποιήθηκαν	79
Πίνακας 7. Χαρακτηριστικά βέλτιστου μονομεταβλητού μοντέλου LSTM με ιστορικό παράθυρο 24 ωρών.....	86
Πίνακας 8. Μετρικές απόδοσης μοντέλου γραμμικής παλινδρόμησης	89
Πίνακας 9. Συντελεστές του μοντέλου γραμμικής παλινδρόμησης.....	93
Πίνακας 10. Μετρικές απόδοσης μοντέλου Random Forest	95
Πίνακας 11. Σημαντικότητα χαρακτηριστικών του μοντέλου τυχαίου δάσους (Random Forest).	99
Πίνακας 12. Μετρικές απόδοσης μοντέλου XGBoost.....	101
Πίνακας 13. Σημαντικότητα χαρακτηριστικών του μοντέλου XGBoost.....	105
Πίνακας 14. Βέλτιστες υπερπαράμετροι των μοντέλων LSTM.....	107
Πίνακας 15. Αποτελέσματα διασταυρωμένης επικύρωσης	107
Πίνακας 16. Τελική αξιολόγηση των μοντέλων LSTM στο σύνολο ελέγχου	108
Πίνακας 17. Σύγκριση προγνωστικής επίδοσης των μοντέλων.....	116

Συντομογραφίες & Ακρωνύμια

ΑΠΕ	Ανανεώσιμες Πηγές Ενέργειας	
ΔΕ	Διπλωματική Εργασία	
ΕΑΠ	Ελληνικό Ανοικτό Πανεπιστήμιο	
ΕΛΣΤΑΤ	Ελληνική Στατιστική Αρχή	
ACF	Autocorrelation Function	Συνάρτηση Αυτοσυσχέτισης
Adam	Adaptive Moment Estimation	
	Βελτιστοποιητής Adaptive Moment Estimation	
AFIR	Alternative Fuels Infrastructure Regulation	
	Κανονισμός για τις Υποδομές Εναλλακτικών Καυσίμων	
AGV	Automated Guided Vehicle	
	Αυτοματοποιημένο όχημα καθοδηγούμενης μετακίνησης	
AI	Artificial Intelligence	Τεχνητή Νοημοσύνη
AIS	Automatic Identification System	
	Σύστημα Αυτόματης Αναγνώρισης Πλοίων	
ANN	Artificial Neural Network	Τεχνητό Νευρωνικό Δίκτυο
API	Application Programming Interface	
	Διεπαφή Προγραμματισμού Εφαρμογών	
AR	Autoregressive	Αυτοπαλίνδρομο
ARIMA	Autoregressive Integrated Moving Average	
	Αυτοπαλίνδρομο Ολοκληρωμένο Μοντέλο Κινούμενου Μέσου	
ARMA	Autoregressive Moving Average	
	Αυτοπαλίνδρομο Μοντέλο Κινούμενου Μέσου	
BESS	Battery Energy Storage System	
	Σύστημα Αποθήκευσης Ενέργειας με Συσσωρευτές	
BMS	Building Management System	Σύστημα Διαχείρισης Κτιρίου
CNN	Convolutional Neural Network	Συνελικτικό Νευρωνικό Δίκτυο
CO ₂	Carbon Dioxide	Διοξείδιο του Άνθρακα
CV	Cross-Validation	Διασταυρούμενη Επικύρωση
CV(RMSE)	Coefficient of Variation of the Root Mean Square Error	
	Συντελεστής Μεταβλητότητας του RMSE	
DL	Deep Learning	Βαθιά Μάθηση

DR	Demand Response	Απόκριση Ζήτησης
ELF	Electricity Load Forecasting	Πρόβλεψη Ηλεκτρικού Φορτίου
EMS	Energy Management System	Σύστημα Διαχείρισης Ενέργειας
ESS	Energy Storage System	Σύστημα Αποθήκευσης Ενέργειας
FuelEU Maritime	FuelEU Maritime Regulation	Κανονισμός FuelEU Maritime
GRU	Gated Recurrent Unit	Μονάδα Gated Recurrent Unit
GT	Gross Tonnage	Ολική Χωρητικότητα
HVAC	Heating, Ventilation and Air Conditioning	Θέρμανση, Αερισμός και Κλιματισμός
IMO	International Maritime Organization	Διεθνής Ναυτιλιακός Οργανισμός
IoT	Internet of Things	Διαδίκτυο των Πραγμάτων
k-NN	k-Nearest Neighbors	Αλγόριθμος k Πλησιέστερων Γειτόνων
LR	Linear Regression	Γραμμική Παλινδρόμηση
LSTM	Long Short-Term Memory	Δίκτυο Long Short-Term Memory
LTLF	Long-Term Load Forecasting	Μακροπρόθεσμη Πρόβλεψη Ηλεκτρικού Φορτίου
MA	Moving Average	Κινούμενος Μέσος
MAE	Mean Absolute Error	Μέσο Απόλυτο Σφάλμα
MAPE	Mean Absolute Percentage Error	Μέσο Απόλυτο Ποσοστιαίο Σφάλμα
ML	Machine Learning	Μηχανική Μάθηση
MLP	Multi-Layer Perceptron	Πολυστρωματικό Αντιληπτικό Δίκτυο
MTLF	Medium-Term Load Forecasting	Μεσοπρόθεσμη Πρόβλεψη Ηλεκτρικού Φορτίου
nZEP	nearly Zero Energy Port	Λιμένας Σχεδόν Μηδενικής Ενεργειακής Κατανάλωσης
OPS	Onshore Power Supply	Ηλεκτροδότηση Πλοίων από την Ξηρά
PCS	Port Community System	Σύστημα Λιμενικής Κοινότητας
PLC	Programmable Logic Controller	Προγραμματιζόμενος Λογικός Ελεγκτής
R ²	Coefficient of Determination	Συντελεστής Προσδιορισμού
RES	Renewable Energy Sources	Ανανεώσιμες Πηγές Ενέργειας

RF	Random Forest	Τυχαίο Δάσος
RMG	Rail-Mounted Gantry Crane	Γερανογέφυρα επί Σιδηροτροχιών
RMSE	Root Mean Square Error	Τετραγωνική Ρίζα του Μέσου Τετραγωνικού Σφάλματος
RNN	Recurrent Neural Network	Αναδρομικό Νευρωνικό Δίκτυο
RTG	Rubber-Tyred Gantry (Crane)	Γερανογέφυρα με ελαστικοφόρους τροχούς
SARIMA	Seasonal Autoregressive Integrated Moving Average	Εποχικό Αυτοπαλίνδρομο Ολοκληρωμένο Μοντέλο Κινούμενου Μέσου
SARIMAX	SARIMA with Exogenous Variables	Εποχικό Αυτοπαλίνδρομο Ολοκληρωμένο Μοντέλο Κινούμενου Μέσου με Εξωγενείς Μεταβλητές
SCADA	Supervisory Control and Data Acquisition	Σύστημα Εποπτικού Ελέγχου και Συλλογής Δεδομένων
SGD	Stochastic Gradient Descent	Στοχαστική Κατάβαση Κλίσης
sMAPE	symmetric MAPE	συμμετρικό MAPE
SOC	State Of Charge	Κατάσταση Φόρτισης
STLF	Short-Term Load Forecasting	Βραχυπρόθεσμη Πρόβλεψη Ηλεκτρικού Φορτίου
STS	Ship-to-Shore Crane	Γερανογέφυρα Πλοίου–Ξηράς
SVR	Support Vector Regression	Παλινδρόμηση Διανυσμάτων Υποστήριξης
TOS	Terminal Operating System	Σύστημα Διαχείρισης Τερματικού Σταθμού
UNCTAD	United Nations Conference on Trade and Development	Διάσκεψη των Ηνωμένων Εθνών για το Εμπόριο και την Ανάπτυξη
VSTLF	Very Short-Term Load Forecasting	Πολύ Βραχυπρόθεσμη Πρόβλεψη Ηλεκτρικού Φορτίου
XGBoost	Extreme Gradient Boosting	Αλγόριθμος Extreme Gradient Boosting

ΚΕΦΑΛΑΙΟ 1. ΕΙΣΑΓΩΓΗ

1.1. Εξέλιξη και σύγχρονος ρόλος των θαλάσσιων λιμένων

Η πρόβλεψη βραχυπρόθεσμου ηλεκτρικού φορτίου (Short-Term Load Forecasting – STLF) αποτελεί τη διαδικασία εκτίμησης της μελλοντικής ζήτησης ηλεκτρικής ενέργειας σε βραχυπρόθεσμο χρονικό ορίζοντα και συνιστά θεμελιώδες εργαλείο για τον ενεργειακό σχεδιασμό, τη λειτουργία και τη διαχείριση σύγχρονων ενεργειακών συστημάτων (Hong & Fan, 2016). Στην παρούσα εργασία η εφαρμογή της διερευνάται στο πλαίσιο των λιμένων, όπου η ενεργειακή μετάβαση, η ψηφιοποίηση και οι απαιτήσεις βιώσιμης ανάπτυξης δημιουργούν νέες προκλήσεις για τη διαχείριση της ηλεκτρικής ζήτησης. Για τον λόγο αυτό, το παρόν κεφάλαιο δεν περιορίζεται στην παρουσίαση του θεωρητικού υπόβαθρου των σύγχρονων λιμένων, αλλά αναδεικνύει συστηματικά τη σύνδεση κάθε θεματικής ενότητας με την πρόβλεψη ηλεκτρικού φορτίου, ώστε να τεκμηριωθεί ο ρόλος της ως εργαλείου υποστήριξης του ενεργειακού σχεδιασμού και της λήψης αποφάσεων.

1.1.1. Οι λιμένες ως κρίσιμοι κόμβοι του παγκόσμιου εμπορίου

Οι θαλάσσιοι λιμένες αποτελούν θεμελιώδεις υποδομές του παγκόσμιου συστήματος μεταφορών, επειδή συγκεντρώνουν και συντονίζουν τη μετάβαση εμπορευμάτων και επιβατών μεταξύ θαλάσσιων και χερσαίων δικτύων. Η σημασία τους δεν είναι μόνο μεταφορική. Οι λιμένες επηρεάζουν το κόστος εφοδιασμού, την απρόσκοπτη λειτουργία των αλυσίδων εφοδιασμού, την περιφερειακή απασχόληση, τη βιομηχανική χωροθέτηση και την ανθεκτικότητα της οικονομίας σε εξωτερικές διαταραχές. Σύμφωνα με την UNCTAD, περισσότερο από το 80% του διεθνούς εμπορίου αγαθών ως προς τον όγκο μεταφέρεται διά θαλάσσης, γεγονός που καθιστά τη λειτουργική συνέχεια των λιμένων κρίσιμη για την παγκόσμια οικονομία (United Nations Conference on Trade and Development, 2024). Η αύξηση των εμπορευματικών ροών, η εμπορευματοκιβωτοποίηση και η διεθνοποίηση των παραγωγικών δικτύων διεύρυναν σταδιακά τόσο την κλίμακα όσο και την πολυπλοκότητα των λιμενικών λειτουργιών. Στη σύγχρονη εφοδιαστική αλυσίδα, ο λιμένας δεν λειτουργεί ως μεμονωμένο σημείο μεταφόρτωσης αλλά ως κόμβος συγχρονισμού πολλών φορέων: λιμενικών αρχών, διαχειριστών τερματικών σταθμών, ναυτιλιακών εταιρειών, μεταφορέων, τελωνείων, παρόχων ενέργειας, βιομηχανικών χρηστών και τοπικής αυτοδιοίκησης. Η επιχειρησιακή απόδοση του συστήματος εξαρτάται από τον συντονισμό αφίξεων πλοίων, κατανομής θέσεων ελλιμενισμού, γερανογεφυρών, αποθήκευσης, χερσαίων μεταφορών και ανθρώπινων πόρων. Η ενεργειακή ζήτηση είναι ενδογενές αποτέλεσμα αυτού του συγχρονισμού: αυξάνεται όταν συμπίπτουν λειτουργίες υψηλής ισχύος και μειώνεται όταν η δραστηριότητα αποσυμφορείται. Επομένως, η κατανόηση του θεσμικού και λειτουργικού ρόλου του λιμένα αποτελεί προϋπόθεση για την ορθή μοντελοποίηση του ηλεκτρικού του φορτίου (Notteboom & Rodrigue, 2005).

1.1.2. Από τον μεταφορικό κόμβο στο ολοκληρωμένο οικοσύστημα εφοδιαστικής αλυσίδας

Η εξέλιξη των λιμένων μπορεί να περιγραφεί μέσω διαδοχικών γενεών, όχι ως απόλυτη και ομοιόμορφη ταξινόμηση, αλλά ως αναλυτικό σχήμα που αποτυπώνει τη διεύρυνση των λειτουργιών τους. Οι πρώτοι λιμένες επικεντρώνονταν στη φυσική σύνδεση θαλάσσιων και χερσαίων μεταφορών. Στη συνέχεια ενσωμάτωσαν εμπορικές και βιομηχανικές δραστηριότητες, ενώ η εμπορευματοκιβωτιοποίηση τους μετέτρεψε σε οργανωμένους κόμβους εφοδιασμού και συνδυασμένων μεταφορών. Η επόμενη φάση χαρακτηρίστηκε από δικτύωση, διεθνείς συνεργασίες, εξειδικευμένες υπηρεσίες και στενότερη ενσωμάτωση στις παγκόσμιες αλυσίδες εφοδιασμού. Σήμερα, οι πλέον προηγμένοι λιμένες επιδιώκουν να συνδυάσουν λειτουργική αποδοτικότητα, περιβαλλοντική βιωσιμότητα, ψηφιακή διασύνδεση και ενεργειακή ευελιξία (Bakar et al., 2021; Molavi et al., 2019). Η μετάβαση αυτή μεταβάλλει και τα κριτήρια αξιολόγησης της απόδοσης των λιμένων, καθώς οι συμβατικοί δείκτες, όπως ο χρόνος εξυπηρέτησης πλοίου, η παραγωγικότητα γερανογεφυρών και ο όγκος διακίνησης, παραμένουν κρίσιμοι, αλλά δεν επαρκούν. Οι σύγχρονοι λιμένες αξιολογούνται επίσης ως προς την ενεργειακή ένταση των λειτουργιών τους, τις εκπομπές ρύπων, την αξιοποίηση των υποδομών τους, την ποιότητα των συλλεγόμενων δεδομένων, την κυβερνοασφάλεια, την ανθεκτικότητα και την κοινωνική τους αποδοχή. Κατά συνέπεια, το ενεργειακό σύστημα ενός λιμένα δεν αποτελεί πλέον βοηθητική υποδομή στο περιθώριο της λιμενικής λειτουργίας, αλλά εξελίσσεται σε βασικό παραγωγικό συντελεστή, του οποίου η επάρκεια και η ευφυής διαχείριση είναι άρρηκτα συνδεδεμένες με την αξιοπιστία και την ανταγωνιστικότητα του λιμένα. (Notteboom & Rodrigue, 2005)

1.1.3. Ψηφιοποίηση και ανάδυση του έξυπνου λιμένα

Η έννοια του έξυπνου λιμένα εκφράζει τη μετάβαση από αποσπασματικά πληροφοριακά συστήματα σε ένα διασυνδεδεμένο περιβάλλον συλλογής, ανταλλαγής και αξιοποίησης δεδομένων. Έξυπνοι μετρητές, αισθητήρες IoT, συστήματα SCADA, Port Community Systems, αυτοματοποιημένος εξοπλισμός, τεχνολογίες εντοπισμού και πλατφόρμες ανάλυσης δημιουργούν συνεχή ροή πληροφοριών για την κατάσταση των υποδομών και των λειτουργιών. Το προτεινόμενο Smart Port Index αποτελεί δείκτη που οργανώνει την έννοια γύρω από τις λειτουργίες, το περιβάλλον, την ενέργεια και την ασφάλεια, αναδεικνύοντας ότι η “ευφυΐα” ενός λιμένα δεν ταυτίζεται με την αυτοματοποίηση ενός μόνο τερματικού σταθμού (Molavi et al., 2019). Στο πλαίσιο αυτό, η ψηφιοποίηση των λιμένων υποστηρίζει διαδοχικά επίπεδα αναλυτικής, μεταβαίνοντας από περιγραφική, η οποία απαντά στο “τι συνέβη;”, σε διαγνωστική, η οποία απαντά στο “γιατί συνέβη;” σε προγνωστική, η οποία εκτιμά τι είναι πιθανό να συμβεί, και τελικά σε κανονιστική, η οποία προτείνει ποια απόφαση πρέπει να ληφθεί. Η πρόβλεψη ηλεκτρικού φορτίου αποτελεί τον συνδετικό κρίκο που μετατρέπει τα ιστορικά και πραγματικού χρόνου δεδομένα σε μελλοντική πληροφόρηση, η οποία μπορεί να τροφοδοτήσει συστήματα ενεργειακής διαχείρισης, προγράμματα φόρτισης, λειτουργίες αποθήκευσης και διαδικασίες προμήθειας επόμενης ημέρας. Χωρίς αξιόπιστη πρόβλεψη, ένα ψηφιακό ενεργειακό σύστημα παραμένει απλώς εργαλείο παρακολούθησης και δεν μπορεί να υποστηρίξει την προληπτική λήψη αποφάσεων.

1.2. Περιβαλλοντικές και κοινωνικές επιπτώσεις των λιμενικών δραστηριοτήτων

1.2.1. Ατμοσφαιρικές εκπομπές και δημόσια υγεία

Οι λιμένες συγκεντρώνουν σε περιορισμένο χώρο πηγές εκπομπών με διαφορετικά χαρακτηριστικά λειτουργίας: κύριες και βοηθητικές μηχανές πλοίων, λέβητες, οχήματα βαρέως τύπου, σιδηροδρομικές μηχανές, εξοπλισμό διακίνησης φορτίων και βιομηχανικές εγκαταστάσεις. Οι δραστηριότητες αυτές εκπέμπουν διοξείδιο του άνθρακα, οξείδια του αζώτου και του θείου, αιωρούμενα σωματίδια, πτητικές οργανικές ενώσεις και μαύρο άνθρακα. Οι εκπομπές θερμοκηπιακών αερίων συνδέονται με την κλιματική αλλαγή, ενώ οι τοπικοί ρύποι επηρεάζουν άμεσα την ποιότητα του αέρα στις λιμενικές και γειτονικές αστικές περιοχές (Bailey & Solomon, 2004; Shen et al., 2025; Wang & Li, 2023). Η χωρική εγγύτητα πολλών λιμένων με πυκνοκατοικημένες περιοχές αυξάνει τη σημασία της έκθεσης του πληθυσμού. Η ευρωπαϊκή βιβλιογραφία έχει καταγράψει ότι η ναυτιλία μπορεί να συνεισφέρει περίπου 1–7% στις συγκεντρώσεις PM₁₀ (αιωρούμενα σωματίδια με διάμετρο <10 μm), 1–14% στις συγκεντρώσεις PM_{2.5} (αιωρούμενα σωματίδια με διάμετρο <2,5 μm) και 7–24% στις συγκεντρώσεις NO₂ σε παράκτιες περιοχές, με σημαντικές διαφοροποιήσεις ανά τοποθεσία και μετεωρολογικές συνθήκες (Viana et al., 2014). Οι επιπτώσεις δεν κατανέμονται ομοιόμορφα: εργαζόμενοι, κάτοικοι κοντά σε οδικούς διαδρόμους και κοινωνικές ομάδες με περιορισμένη δυνατότητα αποφυγής της έκθεσης μπορεί να επιβαρύνονται δυσανάλογα. Η περιβαλλοντική διαχείριση του λιμένα συνδέεται συνεπώς με τη δημόσια υγεία και την περιβαλλοντική δικαιοσύνη, όχι μόνο με τη συμμόρφωση προς τεχνικά όρια εκπομπών. Η υιοθέτηση από τους λιμένες τεχνολογιών όπως η ηλεκτροδότηση από την ξηρά, ο εξηλεκτρισμός του εξοπλισμού και η λειτουργική βελτιστοποίηση μπορούν να μειώσουν τις εκπομπές στο σημείο χρήσης, αλλά η πραγματική περιβαλλοντική επίδοση εξαρτάται από το ηλεκτρικό μίγμα, τον βαθμό αξιοποίησης της υποδομής και το χρονικό προφίλ της κατανάλωσης. Η μετατόπιση ενός φορτίου σε ώρα υψηλής ανθρακικής έντασης του δικτύου δεν είναι περιβαλλοντικά ισοδύναμη με την κάλυψή του από τοπική ανανεώσιμη παραγωγή ή κατά τη διάρκεια περιόδων χαμηλότερης έντασης άνθρακα. Η πρόβλεψη ζήτησης επιτρέπει επομένως τον χρονικό συντονισμό των παρεμβάσεων και ενισχύει τη μετάβαση από την απλή ηλεκτροδότηση στην πραγματική απανθρακοποίηση.

1.2.2. Επιπτώσεις στο φυσικό περιβάλλον

Το περιβαλλοντικό αποτύπωμα των λιμένων εκτείνεται πέρα από τις ατμοσφαιρικές εκπομπές. Η διαχείριση θαλάσσιου έρματος, καταλοίπων καυσίμων, υγρών αποβλήτων και υπολειμμάτων φορτίου δημιουργεί κινδύνους για το θαλάσσιο περιβάλλον. Οι εργασίες εκβάθυνσης μπορούν να επαναιωρήσουν ρυπασμένα ιζήματα και να μεταβάλουν τη μορφολογία του πυθμένα, ενώ η επέκταση προβλητών και αποθηκευτικών χώρων μπορεί να οδηγήσει σε απώλεια παράκτιων οικοτόπων, κατακερματισμό οικοσυστημάτων και μεταβολές στη βιοποικιλότητα. Η διαχείριση αυτών των επιπτώσεων απαιτεί χωρικό σχεδιασμό, παρακολούθηση, πρόληψη ατυχημάτων και συντονισμό με τις περιβαλλοντικές αρχές (Lam & Notteboom, 2014). Ο θόρυβος αποτελεί επίσης σημαντική περιβαλλοντική επιβάρυνση. Προέρχεται από μηχανές πλοίων, γερανογέφυρες, μεταλλικές κρούσεις κατά τη διακίνηση φορτίων, βαρέα οχήματα και δραστηριότητες που εκτελούνται σε εικοσιτετράωρη βάση. Ο εξηλεκτρισμός μπορεί να μειώσει μέρος του μηχανικού θορύβου, αλλά δεν εξαλείφει πηγές που συνδέονται με την ίδια τη διαχείριση φορτίων. Επιπλέον, η ένταση φωτισμού, η κυκλοφοριακή συμφόρηση και η κατάληψη του παράκτιου χώρου επηρεάζουν την ποιότητα ζωής και τη σχέση λιμένα–πόλης. Η βιώσιμη ανάπτυξη απαιτεί

συνεπώς πολυκριτηριακή προσέγγιση, η οποία λαμβάνει υπόψη εκτός από τις εκπομπές αερίων του θερμοκηπίου και τις ευρύτερες περιβαλλοντικές και κοινωνικές επιπτώσεις των λιμενικών δραστηριοτήτων.

1.2.3. Η διεπαφή λιμένα–πόλης και η κοινωνική άδεια λειτουργίας

Οι λιμένες παράγουν οικονομικά οφέλη που συχνά διαχέονται σε περιφερειακή ή εθνική κλίμακα, ενώ σημαντικό μέρος των περιβαλλοντικών και κυκλοφοριακών επιβαρύνσεων συγκεντρώνεται τοπικά. Αυτή η ασυμμετρία δημιουργεί συγκρούσεις ως προς τη χρήση γης, την επέκταση υποδομών, την κυκλοφορία φορτηγών και την ποιότητα του αστικού περιβάλλοντος. Η κοινωνική άδεια λειτουργίας δεν αποτελεί τυπική διοικητική άδεια, αλλά τη διαρκή αποδοχή των δραστηριοτήτων από τις κοινότητες και τα ενδιαφερόμενα μέρη. Διαφάνεια, δημοσιοποίηση δεικτών, συμμετοχή στον σχεδιασμό και τεκμηριωμένη αξιολόγηση επιπτώσεων είναι αναγκαίες για τη διατήρησή της. Η ενεργειακή μετάβαση μπορεί να ενισχύσει τη σχέση λιμένα–πόλης όταν μειώνει τοπικές εκπομπές, θόρυβο και κόστος, αλλά μπορεί επίσης να δημιουργήσει νέες πιέσεις: υποσταθμούς, γραμμές μεταφοράς, συστήματα αποθήκευσης ενέργειας και αυξημένη ζήτηση σε δίκτυα που εξυπηρετούν ταυτόχρονα αστικούς καταναλωτές. Η αξιόπιστη πρόβλεψη βοηθά να ποσοτικοποιηθεί τότε και σε ποιο βαθμό θα εμφανιστούν αυτές οι πιέσεις. Έτσι, λειτουργεί ως τεχνικό μέσο διαφάνειας και διαλόγου, επειδή επιτρέπει τη σύγκριση σεναρίων και την τεκμηρίωση της αναγκαιότητας επενδύσεων (Hall, 2007).

1.3. Βιώσιμη, πράσινη και έξυπνη λιμενική ανάπτυξη

1.3.1. Εννοιολογικές διακρίσεις και συμπληρωματικότητα

Οι όροι “πράσινος”, “βιώσιμος” και “έξυπνος” λιμένες χρησιμοποιούνται συχνά ως συνώνυμοι, αλλά εκφράζουν διαφορετικές προτεραιότητες. Ο πράσινος λιμένας εστιάζει πρωτίστως στον περιορισμό περιβαλλοντικών επιπτώσεων μέσω πρόληψης ρύπανσης, μείωσης εκπομπών, αποδοτικής χρήσης πόρων και περιβαλλοντικής παρακολούθησης. Ο βιώσιμος λιμένας διευρύνει το πεδίο και επιδιώκει μακροχρόνια ισορροπία μεταξύ περιβαλλοντικής προστασίας, οικονομικής ανταγωνιστικότητας και κοινωνικής ευημερίας. Ο έξυπνος λιμένας επικεντρώνεται στις ψηφιακές και οργανωτικές ικανότητες που επιτρέπουν καλύτερο συντονισμό, αυτοματοποίηση και λήψη αποφάσεων βάσει δεδομένων. Οι έννοιες είναι συμπληρωματικές: η ψηφιακή ωριμότητα μπορεί να επιταχύνει τη βιωσιμότητα, αλλά δεν την εγγυάται αν τα κριτήρια βελτιστοποίησης περιορίζονται αποκλειστικά στην παραγωγικότητα (Lam & Notteboom, 2014; Molavi et al., 2019). Η σύγκριση των τριών εννοιών ως προς τα κύρια χαρακτηριστικά τους φαίνεται στον πίνακα 1.

Πίνακας 1. Συγκριτική διάκριση πράσινου, βιώσιμου και έξυπνου λιμένα και σύνδεση με την πρόβλεψη ηλεκτρικού φορτίου.

Έννοια	Κύριος προσανατολισμός	Ενδεικτικές διαστάσεις	Σχέση με την πρόβλεψη φορτίου
Πράσινος λιμένας	Μείωση περιβαλλοντικών επιπτώσεων	Εκπομπές, νερό, θόρυβος, απόβλητα και ενεργειακή απόδοση	Κατανάλωση, αιχμές και αποτίμηση της δυνατότητας μείωσης εκπομπών.

Έννοια	Κύριος προσανατολισμός	Ενδεικτικές διαστάσεις	Σχέση με την πρόβλεψη φορτίου
Βιώσιμος λιμένας	Ισορροπία περιβαλλοντικής, οικονομικής και κοινωνικής επίδοσης	Κόστος, ανθεκτικότητα, υγεία, ασφάλεια και κοινωνική αποδοχή	Επενδυτικός σχεδιασμός και αξιολόγηση πολυκριτηριακών συμβιβασμών.
Έξυπνος λιμένας	Δεδομενοκεντρική βελτιστοποίηση και αυτοματοποίηση	IoT, SCADA, PCS, τεχνητή νοημοσύνη και ψηφιακά δίδυμα	Προγνωστική είσοδος στο ψηφιακό οικοσύστημα και στο EMS.
Ενεργειακός κόμβος λιμένα	Συντονισμός παραγωγής, αποθήκευσης και ευέλικτων φορτίων	OPS, ΑΠΕ, BESS, EV/AGV, μικροδίκτυο και απόκριση ζήτησης	Day-ahead προγραμματισμός, peak shaving και ασφάλεια δικτύου.

1.3.2. Περιβαλλοντική, οικονομική και κοινωνική διάσταση της βιωσιμότητας

Η περιβαλλοντική διάσταση αφορά τη μείωση εκπομπών και ρύπανσης, την προστασία των οικοσυστημάτων, την αποδοτική χρήση ενέργειας και υλικών και την προσαρμογή στην κλιματική αλλαγή. Η οικονομική διάσταση αφορά την παραγωγικότητα, το λειτουργικό κόστος, την ικανότητα προσέλκυσης φορτίων, την αξιοπιστία υπηρεσιών και τη μακροχρόνια βιωσιμότητα των επενδύσεων. Η κοινωνική διάσταση περιλαμβάνει την υγεία και την ασφάλεια των εργαζομένων, τη δημόσια υγεία, την απασχόληση, την ποιότητα ζωής και την ουσιαστική συμμετοχή των ενδιαφερόμενων μερών (Elkington, 1997). Οι τρεις αυτές διαστάσεις της βιωσιμότητας αλληλεπιδρούν και δημιουργούν τόσο συνέργειες όσο και συμβιβασμούς. Για παράδειγμα, η βελτιστοποίηση των λιμενικών διαδικασιών μπορεί να μειώσει ταυτόχρονα χρόνο αναμονής, κατανάλωση ενέργειας και εκπομπές. Αντίθετα, η εγκατάσταση OPS, αποθήκευσης ή ανανεώσιμων πηγών απαιτεί κεφάλαιο, χώρο και τεχνική εξειδίκευση. Η επιλογή μιας ενεργειακής λύσης δεν πρέπει να βασίζεται μόνο στη μέση ετήσια εξοικονόμηση. Πρέπει να εξετάζει τη συμπεριφορά σε αιχμές, τον βαθμό χρησιμοποίησης, τις επιπτώσεις στο δίκτυο, την αβεβαιότητα της μελλοντικής ζήτησης και την κατανομή ωφελειών και κόστους μεταξύ φορέων. Η πρόβλεψη φορτίου συνδέει τις τρεις διαστάσεις, επειδή μειώνει την αβεβαιότητα και επιτρέπει μια πιο ρεαλιστική τεχνικοοικονομική και περιβαλλοντική αξιολόγηση. Η προσέγγιση αυτή ευθυγραμμίζεται με την Ατζέντα 2030 και ειδικότερα με τους Στόχους 7, 9, 11, 12 και 13 για καθαρή ενέργεια, ανθεκτικές υποδομές, βιώσιμες πόλεις, υπεύθυνη παραγωγή και δράση για το κλίμα (United Nations, 2015). Η αναφορά στους Στόχους Βιώσιμης Ανάπτυξης έχει αξία μόνο όταν μετατρέπεται σε μετρήσιμους δείκτες, χρονοδιαγράμματα και διαδικασίες λογοδοσίας. Διαφορετικά, κινδυνεύει να παραμείνει γενική δήλωση προθέσεων χωρίς λειτουργική επίδραση.

1.3.3. Συστήματα περιβαλλοντικής διαχείρισης και εργαλεία διακυβέρνησης

Η θεσμική ενσωμάτωση της βιωσιμότητας απαιτεί οργανωμένες διαδικασίες και όχι μεμονωμένα έργα. Το πρότυπο ISO 14001:2026 παρέχει το γενικό πλαίσιο για τον σχεδιασμό, την εφαρμογή, την αξιολόγηση και τη συνεχή βελτίωση ενός συστήματος περιβαλλοντικής διαχείρισης. Στον λιμενικό τομέα, το Port Environmental Review System

(PERS) της EcoPorts εξειδικεύει τις αρχές αυτές στις λειτουργίες και στις περιβαλλοντικές ευθύνες των λιμένων. Τα συστήματα αυτά βοηθούν στον εντοπισμό σημαντικών περιβαλλοντικών επιπτώσεων, στον καθορισμό στόχων, στην παρακολούθηση συμμόρφωσης και στην τεκμηρίωση διορθωτικών ενεργειών (EcoPorts, n.d.; International Organization for Standardization, 2026). Οι λιμενικές αρχές διαθέτουν επίσης εργαλεία πολιτικής και συμβατικής διακυβέρνησης: περιβαλλοντικά διαφοροποιημένα τέλη, όρους παραχώρησης, απαιτήσεις υπομετρήσεων, κίνητρα χρήσης καθαρών τεχνολογιών και υποχρεώσεις δημοσιοποίησης. Η αποτελεσματικότητα αυτών των εργαλείων εξαρτάται από το εύρος αρμοδιοτήτων της λιμενικής αρχής και τη δομή ιδιοκτησίας των υποδομών (Acciaro et al., 2014; Lam & Notteboom, 2014). Όταν η αρχή δεν ελέγχει άμεσα τα φορτία, μπορεί να επηρεάσει τη συμπεριφορά μέσω τιμολογίων, δεδομένων και συμβατικών απαιτήσεων. Αυτό έχει άμεση επίπτωση τόσο στην ανάπτυξη όσο και στην αξιοποίηση ενός μοντέλου πρόβλεψης, επειδή καθορίζει ποια δεδομένα μπορούν να συλλεχθούν και ποια ηλεκτρικά φορτία μπορούν να επηρεαστούν μέσω διαχειριστικών παρεμβάσεων.

1.3.4. Δείκτες επίδοσης, συγκριτική αξιολόγηση (benchmarking) και συνεχής βελτίωση

Η βιωσιμότητα πρέπει να μεταφράζεται σε σύστημα δεικτών που συνδέει στόχους, λειτουργίες και αποτελέσματα. Ενδεικτικοί δείκτες είναι η συνολική και ειδική κατανάλωση ενέργειας, η μέγιστη ισχύς, ο συντελεστής φορτίου, οι εκπομπές ανά τόνο φορτίου ή επιβάτη, το ποσοστό ηλεκτροκίνητου εξοπλισμού, η διείσδυση ΑΠΕ, η χρήση OPS και η συχνότητα υπερβάσεων περιβαλλοντικών ορίων. Οι ετήσιες εκθέσεις ESPO/EcoPorts καταγράφουν την εξέλιξη των περιβαλλοντικών προτεραιοτήτων των ευρωπαϊκών λιμένων και ενισχύουν τη συγκριτική αξιολόγηση και την ανταλλαγή πρακτικών (European Sea Ports Organisation, 2025). Οι δείκτες πρέπει να ερμηνεύονται προσεκτικά. Μια μείωση της κατανάλωσης ανά τόνο φορτίου μπορεί να συνυπάρχει με αύξηση της συνολικής κατανάλωσης λόγω ανάπτυξης του λιμένα. Αντίστοιχα, η αύξηση της ηλεκτρικής ζήτησης μπορεί να αποτελεί θετική εξέλιξη όταν αντικαθιστά πετρέλαιο σε πλοία και εξοπλισμό. Γι' αυτό απαιτείται διάκριση μεταξύ απόλυτων και σχετικών μεγεθών, μεταξύ τελικής ενέργειας και πρωτογενούς ή ανθρακικής επίπτωσης, καθώς και μεταξύ κανονικής λειτουργίας και ακραίων αιχμών. Η πρόβλεψη προσθέτει μελλοντική διάσταση στους δείκτες και επιτρέπει την έγκαιρη ανίχνευση αποκλίσεων από στόχους.

1.4. Ενεργειακή μετάβαση και έξυπνη διαχείριση ηλεκτρικής ενέργειας στους λιμένες

1.4.1. Σύνθεση και δυναμική της ηλεκτρικής κατανάλωσης

Η ηλεκτρική κατανάλωση ενός λιμένα προκύπτει από κτίρια, φωτισμό, συστήματα θέρμανσης, αερισμού και κλιματισμού (HVAC), αντλίες, αποθήκες, ψυκτικά εμπορευματοκιβώτια, γερανογέφυρες, ταινιόδρομους, εργαστήρια, συστήματα ασφάλειας και πλήθος βοηθητικών φορτίων. Το μέγεθος και ο χρονισμός κάθε συνιστώσας εξαρτώνται από τον τύπο λιμένα. Σε τερματικούς σταθμούς εμπορευματοκιβωτίων κυριαρχούν γερανογέφυρες και ψυκτικά εμπορευματοκιβώτια (reefers), σε επιβατικούς λιμένες κτίρια και εποχικότητα, ενώ σε λιμένες χύδην φορτίου κυριαρχούν αντλίες, μεταφορικές ταινίες και εξειδικευμένος βιομηχανικός εξοπλισμός (Bakar et al., 2021; Iris & Lam, 2019). Η ζήτηση διαμορφώνεται από την αλληλεπίδραση επιχειρησιακών και περιβαλλοντικών μεταβλητών. Ο αριθμός πλοίων, οι χρόνοι ελλιμενισμού, οι κινήσεις φορτίου, η αξιοποίηση γερανών, η πληρότητα ψυκτικών θέσεων, οι βάρδιες και οι αφίξεις φορτηγών οχημάτων

επηρεάζουν τη λειτουργική συνιστώσα. Θερμοκρασία, υγρασία, ηλιακή ακτινοβολία και διάρκεια ημέρας επηρεάζουν κτιριακά, ψυκτικά και φωτιστικά φορτία. Η ταυτόχρονη λειτουργία πολλών καταναλωτών υψηλής ισχύος δημιουργεί αιχμές που μπορεί να έχουν μικρή διάρκεια αλλά δυσανάλογη σημασία για ηλεκτρικές υποδομές, συμβατική ισχύ και χρεώσεις ζήτησης. Συνεπώς, η μέση ημερήσια ή μηνιαία κατανάλωση δεν αρκεί για τον ενεργειακό σχεδιασμό.

1.4.2. Εξηλεκτρισμός, ηλεκτροδότηση από ξηράς (OPS) και νέα ευέλικτα φορτία

Ο εξηλεκτρισμός μεταφέρει ενεργειακές υπηρεσίες από πετρέλαιο και φυσικό αέριο προς το ηλεκτρικό σύστημα. Η πιο χαρακτηριστική εφαρμογή είναι η ηλεκτροδότηση από ξηράς (Onshore Power Supply - OPS), μέσω της οποίας τα ελλιμενισμένα πλοία απενεργοποιούν τις βοηθητικές μηχανές και τροφοδοτούνται από την ξηρά. Ανάλογα με τον τύπο πλοίου, οι απαιτήσεις ισχύος μπορεί να κυμαίνονται από εκατοντάδες kW έως αρκετά MW. Η ταυτόχρονη εξυπηρέτηση πολλών πλοίων δημιουργεί μεγάλα, χρονικά εξαρτώμενα φορτία, των οποίων η έναρξη και η διάρκεια εξαρτώνται από το πρόγραμμα αφίξεων, τη θέση ελλιμενισμού και την επιχειρησιακή διαθεσιμότητα (Abu Bakar et al., 2023; Sadiq et al., 2021). Παράλληλα, η ηλεκτροκίνηση γερανογεφυρών, οχημάτων και λοιπού λιμενικού εξοπλισμού μεταφέρει στο ηλεκτρικό σύστημα του λιμένα ενεργειακές ανάγκες που παλαιότερα καλυπτόταν από υγρά καύσιμα. Η φόρτιση του ηλεκτροκίνητου εξοπλισμού είναι εν μέρει ευέλικτη: μπορεί να μετακινηθεί χρονικά, αλλά υπόκειται σε περιορισμούς κατάστασης φόρτισης, επόμενης βάρδιας και διαθεσιμότητας φορτιστών. Συνεπώς, η ευελιξία δεν πρέπει να θεωρείται δεδομένη, αλλά να ποσοτικοποιείται ανά κατηγορία φορτίου και να ενσωματώνεται σε μοντέλα ενεργειακής διαχείρισης. Η πρόβλεψη παρέχει την εκτίμηση του αναμενόμενου φορτίου, πάνω στην οποία μπορεί να υπολογιστεί πόση χρονική μετατόπιση φορτίων είναι εφικτή χωρίς να διακυβεύεται η επιχειρησιακή λειτουργία ή η αξιοπιστία του ηλεκτρικού συστήματος.

1.4.3. Ανανεώσιμες πηγές ενέργειας (ΑΠΕ), αποθήκευση, μικροδίκτυα (microgrids) και συστήματα ενεργειακής διαχείρισης

Οι λιμενικές περιοχές προσφέρουν δυνατότητες αξιοποίησης φωτοβολταϊκών σε στέγες αποθηκών, σκιάστρα και ανεκμετάλλευτες επιφάνειες, ενώ ορισμένες θέσεις διαθέτουν αξιόλογο αιολικό ή θαλάσσιο δυναμικό. Η αξιοποίηση ανανεώσιμων πηγών ενέργειας (ΑΠΕ) μειώνει την εξάρτηση από το ηλεκτρικό δίκτυο και μπορεί να βελτιώσει το ανθρακικό αποτύπωμα του OPS, αλλά η μεταβλητότητα παραγωγής που χαρακτηρίζει τις ΑΠΕ αυξάνει την ανάγκη για πρόβλεψη και συντονισμό. Τα συστήματα αποθήκευσης μπορούν να απορροφούν πλεονάζουσα παραγωγή, να περιορίζουν αιχμές φορτίου, να παρέχουν εφεδρεία και συμβάλλουν στη διατήρηση της ποιότητας ισχύος. Η τεχνικοοικονομική τους αξία εξαρτάται από το πραγματικό προφίλ φορτίου, τις τιμές ενέργειας, τη συχνότητα αιχμών και το επιτρεπτό βάθος εκφόρτισης (Cholidis et al., 2025; Sifakis & Tsoutsos, 2021). Το μικροδίκτυο οργανώνει την παραγωγή, την αποθήκευση και τα φορτία ως συντονισμένο ενεργειακό σύστημα, το οποίο μπορεί να λειτουργεί διασυνδεδεμένο και, υπό κατάλληλες προϋποθέσεις, νησιδοποιημένο. Τα σύγχρονα Συστήματα Διαχείρισης Ενέργειας (EMS - Energy Management Systems) βελτιστοποιούν την κατανομή ισχύος, τη φόρτιση και αποφόρτιση των συστημάτων αποθήκευσης, την απόκριση ζήτησης και την προμήθεια ηλεκτρικής ενέργειας. Η βιβλιογραφία για μικροδίκτυα λιμένων υπογραμμίζει ότι η μεγάλης κλίμακας ηλεκτροδότηση και η ενσωμάτωση ΑΠΕ απαιτούν πιο ενεργό έλεγχο από αυτόν που μπορεί να παρέχει ένα συμβατικό παθητικό δίκτυο (Bakar et al., 2021; Sadiq et al., 2021). Η αποτελεσματικότητα

των αποφάσεων του EMS περιορίζεται, όμως, από την ποιότητα των προβλέψεων φορτίου και παραγωγής που χρησιμοποιεί.

1.4.4. Από την παρακολούθηση στη βραχυπρόθεσμη πρόβλεψη φορτίου

Η συνεχής παρακολούθηση μέσω έξυπνων μετρητών και SCADA παρέχει εικόνα της τρέχουσας κατάστασης, αλλά δεν παρέχει πληροφορία από μόνη της για τη μελλοντική εξέλιξη. Σε ένα δυναμικό λιμενικό περιβάλλον, η αντίδραση μετά την εμφάνιση μιας αιχμής μπορεί να είναι καθυστερημένη: το σύστημα αποθήκευσης μπορεί να μην έχει επαρκή φόρτιση, η αγορά ενέργειας να έχει κλείσει ή η ταυτόχρονη σύνδεση φορτίων να έχει ήδη υπερβεί λειτουργικά όρια. Η βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου μετατρέπει τη λειτουργία από αντιδραστική σε προληπτική και υποστηρίζει ενδοημερήσιο και προημερήσιο προγραμματισμό. Η πρόβλεψη σε λιμένες είναι δυσκολότερη από μια τυπική κτιριακή εφαρμογή, επειδή συνδυάζει περιοδικά φορτία με γεγονότα που καθορίζονται από επιχειρησιακά προγράμματα. Ιστορικό φορτίο και μετεωρολογικές μεταβλητές παραμένουν αναγκαία, αλλά συχνά δεν αρκούν. Πληροφορίες για αφίξεις πλοίων, κατανομή θέσεων ελλιμενισμού, κινήσεις φορτίου, χρήση γερανών, αριθμό ψυκτικών εμπορευματοκιβωτίων και προγράμματα φόρτισης μπορούν να εξηγήσουν αιχμές που διαφορετικά εμφανίζονται ως τυχαίες. Η ενσωμάτωση αυτών των πηγών δημιουργεί προκλήσεις χρονικού συγχρονισμού, ποιότητας, διαθεσιμότητας και εμπιστευτικότητας δεδομένων, αλλά αυξάνει σημαντικά την επιχειρησιακή ερμηνευσιμότητα. Σε αυτό το πλαίσιο μετάβασης η πρόβλεψη δεν αποτελεί απομονωμένο πρόβλημα αλγοριθμικής ακρίβειας, αλλά αντιμετωπίζεται συστημικά ως θεμελιώδης λειτουργία ενός βιώσιμου και έξυπνου λιμένα. Ένα μοντέλο πρόβλεψης που εφαρμόζεται σε σύγχρονο λιμενικό περιβάλλον καλείται να είναι λειτουργικό σε πραγματικές επιχειρησιακές συνθήκες, προβλέποντας με επάρκεια τη συνήθη ζήτηση, αποτυπώνοντας με αξιοπιστία τις περιόδους αιχμής, αξιοποιώντας μόνο πληροφορία πραγματικά διαθέσιμη κατά τον χρόνο πρόβλεψης και παράγοντας αποτελέσματα που μπορούν να συνδεθούν με αποφάσεις ενεργειακής διαχείρισης.

1.5. Κανονιστικό και στρατηγικό πλαίσιο της λιμενικής ηλεκτροδότησης

1.5.1. Διεθνής ναυτιλιακή απανθρακοποίηση

Η αυξανόμενη σημασία της πρόβλεψης λιμενικών φορτίων συνδέεται άμεσα με τη διεθνή πολιτική απανθρακοποίησης της ναυτιλίας. Η Στρατηγική του Διεθνούς Ναυτιλιακού Οργανισμού του 2023 θέτει ως συνολική κατεύθυνση την επίτευξη καθαρών μηδενικών εκπομπών αερίων του θερμοκηπίου από τη διεθνή ναυτιλία έως ή περίπου το 2050. Περιλαμβάνει ενδεικτικά σημεία ελέγχου με μείωση των συνολικών ετήσιων εκπομπών κατά τουλάχιστον 20%, με επιδίωξη 30%, έως το 2030 και κατά τουλάχιστον 70%, με επιδίωξη 80%, έως το 2040 σε σχέση με το 2008. Παράλληλα, προβλέπει μείωση της μέσης έντασης άνθρακα κατά τουλάχιστον 40% έως το 2030 και μερίδιο τουλάχιστον 5%, με επιδίωξη 10%, για τεχνολογίες, καύσιμα ή πηγές ενέργειας μηδενικών ή σχεδόν μηδενικών εκπομπών (International Maritime Organization, 2023). Οι στόχοι αυτοί δεν αφορούν μόνο τα καύσιμα πρόωσης, αλλά προωθούν τον εξηλεκτρισμό των λιμενικών δραστηριοτήτων, μεταβάλλοντας σημαντικά τις απαιτήσεις των λιμενικών ηλεκτρικών συστημάτων ως προς τη χρήση και την προέλευση της ηλεκτρικής ενέργειας, καθώς και τη διασύνδεση μεταξύ πλοίου, λιμένα και δικτύου. Η ηλεκτροδότηση από ξηρά (OPS) αντικαθιστά τη λειτουργία των βοηθητικών μηχανών και μπορεί να μηδενίσει τις τοπικές εκπομπές καυσαερίων στο σημείο χρήσης, όμως το συνολικό κλιματικό όφελος εξαρτάται από το ανθρακικό αποτύπωμα της ηλεκτρικής ενέργειας, τις απώλειες και την πραγματική χρήση της

υποδομής. Υπό το πρίσμα αυτό, η πρόβλεψη της ηλεκτρικής ζήτησης αποκτά μείζονα σημασία και συνδέεται όχι μόνο με την ποσότητα της απαιτούμενης ενέργειας, αλλά και με το χρονικό προφίλ του φορτίου, καθώς αυτό καθορίζει ποιες μονάδες παραγωγής και ποιοι πόροι του ηλεκτρικού δικτύου ενεργοποιούνται σε κάθε χρονική στιγμή.

1.5.2. Ευρωπαϊκό πλαίσιο AFIR και FuelEU Maritime

Στην Ευρωπαϊκή Ένωση, ο Κανονισμός (ΕΕ) 2023/1804 για την ανάπτυξη υποδομών εναλλακτικών καυσίμων (AFIR) δημιουργεί συγκεκριμένες υποχρεώσεις για την παροχή ηλεκτρικής ενέργειας από την ξηρά (European Parliament & Council of the European Union, 2023a). Τα κράτη μέλη οφείλουν να εξασφαλίσουν έως τις 31 Δεκεμβρίου 2029 ότι οι λιμένες του κεντρικού και εκτεταμένου διευρωπαϊκού δικτύου μεταφορών που υπερβαίνουν καθορισμένα κατώφλια προσεγγίσεων θα μπορούν να παρέχουν OPS τουλάχιστον στο 90% των επιλέξιμων προσεγγίσεων πλοίων μεταφοράς εμπορευματοκιβωτίων και επιβατηγών πλοίων άνω των 5.000 μονάδων ολικής χωρητικότητας (Gross Tonnage, GT). Το κριτήριο είναι λειτουργικό και όχι απλώς κατασκευαστικό: η ηλεκτρική υποδομή του λιμένα πρέπει να καλύπτει το πραγματικό πρότυπο προσεγγίσεων. Ο Κανονισμός (ΕΕ) 2023/1805 FuelEU Maritime συμπληρώνει την προσέγγιση από την πλευρά του πλοίου (European Parliament & Council of the European Union, 2023b). Από την 1η Ιανουαρίου 2030, τα πλοία μεταφοράς εμπορευματοκιβωτίων και τα επιβατηγά πλοία που εμπίπτουν στο πεδίο εφαρμογής και προσεγγίζουν καλυπτόμενο λιμένα οφείλουν, υπό τις προβλεπόμενες εξαιρέσεις, να συνδέονται με OPS και να τη χρησιμοποιούν για το σύνολο της ηλεκτρικής τους ζήτησης κατά τον ελλιμενισμό (European Parliament & Council of the European Union, 2023b). Η συνδυασμένη εφαρμογή των δύο κανονισμών δημιουργεί ταυτόχρονα υποχρέωση προσφοράς και ζήτησης, περιορίζοντας την αβεβαιότητα ως προς τη μελλοντική διείσδυση της τεχνολογίας αλλά αυξάνοντας την ανάγκη ακριβούς σχεδιασμού ισχύος. Το AFIR παραπέμπει σε διεθνή πρότυπα, όπως τα IEC/IEEE 80005-1 και IEC 62613, τα οποία καθορίζουν τις τεχνικές προδιαγραφές για τις συνδέσεις υψηλής τάσης και τον σχετικό εξοπλισμό που απαιτείται για την ηλεκτροδότηση πλοίων από ξηρά (OPS). Η τυποποίηση αυτή μειώνει τα προβλήματα διαλειτουργικότητας, χωρίς όμως να εξαλείφει τις τοπικές διαφορές ως προς την τάση, τη συχνότητα, τη διάταξη θέσεων πρόσδεσης, το μήκος των καλωδίων και τη διαμόρφωση του ηλεκτρικού συστήματος κάθε λιμένα. Ο σχεδιασμός εγκαταστάσεων OPS πρέπει να λαμβάνει υπόψη παραμέτρους όπως η πιθανή ταυτόχρονη τροφοδότηση πολλών πλοίων, οι απαιτήσεις ισχύος και η αξιοπιστία της τοπικής σύνδεσης. Τα ιδιαίτερα χωροταξικά και λειτουργικά χαρακτηριστικά μικρών και μεσαίων λιμένων, όπως οι πολλές μικρές θέσεις πρόσδεσης και η ανάγκη για ξεχωριστές μονάδες ή μεγαλύτερα μήκη καλωδίων, μπορούν να αυξήσουν σημαντικά το κόστος υλοποίησης, όπως έχει αναδειχθεί στην περίπτωση του Aberdeen (Innes & Monios, 2018). Ιδιαίτερη σημασία για τη χώρα μας έχει η πρόβλεψη του AFIR για νησιωτικά και απομονωμένα συστήματα, όπου θεσπίζεται εξαίρεση για λιμένες σε νησιά που δεν συνδέονται απευθείας με το ηπειρωτικό ηλεκτρικό δίκτυο έως ότου ολοκληρωθεί η σύνδεση ή υπάρχει επαρκής τοπική παραγωγική ικανότητα από μη ορυκτές πηγές. Η διάταξη αναγνωρίζει ότι η εγκατάσταση OPS χωρίς επαρκές σύστημα ηλεκτρικής ισχύος μπορεί να μεταφέρει το πρόβλημα από το πλοίο στο τοπικό δίκτυο. Για τέτοιες περιπτώσεις, η αξιόπιστη πρόβλεψη της ηλεκτρικής ζήτησης αποτελεί βασικό εργαλείο για τον ορθολογικό σχεδιασμό και την αξιολόγηση επενδύσεων σε υποδομές ηλεκτροδότησης.

1.5.3. Περιβαλλοντικά, οικονομικά και δικτυακά κίνητρα

Η περιβαλλοντική αξία της OPS προκύπτει κυρίως από τη μείωση των τοπικών εκπομπών οξειδίων του αζώτου, οξειδίων του θείου, σωματιδίων και θορύβου σε περιοχές όπου λιμένες και αστικός ιστός συνυπάρχουν. Οι Styhre et al. (2017), με περιπτώσεις από τέσσερις ηπείρους, έδειξαν ότι η παραμονή στο λιμάνι μπορεί να αποτελεί σημαντικό μέρος των εκπομπών ενός ταξιδιού. Οι Winkel et al. (2016) ποσοτικοποίησαν το ευρωπαϊκό δυναμικό shore-side electricity και ανέδειξαν ταυτόχρονα περιβαλλοντικά οφέλη και εμπόδια εφαρμογής. Οι Ballini & Bozzo (2015) προσέγγισαν την τεχνολογία μέσω κοινωνικοοικονομικής αποτίμησης των εξωτερικών επιπτώσεων υγείας. Η Zis (2019) επισήμανε ότι η οικονομική βιωσιμότητα εξαρτάται από τιμές καυσίμων και ηλεκτρικής ενέργειας, επίπεδο χρήσης, κανονιστικές απαιτήσεις και κατανομή του κόστους μεταξύ λιμένα και πλοιοκτήτη. Από τη σκοπιά του δικτύου, η πρόκληση δεν είναι η ετήσια κατανάλωση αλλά η χωρική και χρονική συγκέντρωση της ισχύος. Ένας λιμένας μπορεί να αντιπροσωπεύει μικρό ποσοστό της συνολικής ετήσιας κατανάλωσης μιας περιφέρειας, αλλά να απαιτεί πολύ υψηλή ισχύ σε λίγες θέσεις και συγκεκριμένες ώρες. Η ταυτόχρονη σύνδεση πλοίων, γερανών και φορτιστών μπορεί να υπερβεί τη συμβατική ισχύ ή να απαιτήσει ενίσχυση υποσταθμών και γραμμών. Η πρόβλεψη της ηλεκτρικής ζήτησης επιτρέπει να διακριθεί αν οι αιχμές φορτίου είναι συστηματικές, προγραμματίσιμες ή σπάνιες, διευκολύνοντας την επιλογή της καταλληλότερης στρατηγικής αντιμετώπισης, όπως η ανακατανομή φορτίων, η αποθήκευση ενέργειας ή η διαχείριση της φόρτισης, αντί της αποκλειστικής υπερδιαστασιολόγησης. Το κανονιστικό πλαίσιο μετατρέπει επομένως την πρόβλεψη σε βασικό εργαλείο συμμόρφωσης και επενδυτικού σχεδιασμού. Η εκτίμηση της μελλοντικής ζήτησης καθορίζει την απαιτούμενη ισχύ εγκαταστάσεων OPS, το πλήθος ταυτόχρονων συνδέσεων, τις ανάγκες εφεδρείας και τη χρονική κατανομή της ενέργειας. Ο ορίζοντας της πρόβλεψης συνδέεται άμεσα με το επιδιωκόμενο πεδίο εφαρμογής, καθώς διαφορετικές χρονικές κλίμακες εξυπηρετούν διαφορετικές επιχειρησιακές και σχεδιαστικές ανάγκες. Βραχυπρόθεσμα, σε λειτουργικό επίπεδο, οι προβλέψεις υποστηρίζουν την προμήθεια ηλεκτρικής ενέργειας και τη διαχείριση των αιχμών φορτίου. Μακροπρόθεσμα, σε στρατηγικό επίπεδο, οι προβλέψεις με ορίζοντα πολλών ετών υποστηρίζουν αποφάσεις σχετικά με τον σχεδιασμό, την ανάπτυξη υποδομών και τις επενδύσεις.

1.5.4. Συνέπειες της ηλεκτροδότησης για τον ενεργειακό σχεδιασμό

Η κανονιστική ώθηση προς την ηλεκτροδότηση των πλοίων από ξηρά (OPS) και την ηλεκτροκίνηση δεν συνεπάγεται μόνο αύξηση της ετήσιας κατανάλωσης ηλεκτρικής ενέργειας, αλλά και μεταβολή της μορφής της καμπύλης φορτίου. Για τον διαχειριστή δικτύου και τη λιμενική αρχή, το κρίσιμο μέγεθος δεν είναι αποκλειστικά οι MWh που θα καταναλωθούν σε ένα έτος, αλλά η ταυτόχρονη ισχύς, η διάρκεια των υψηλών φορτίσεων, οι ρυθμοί ανόδου και καθόδου του φορτίου και η χρονική σύμπτωση με το υπόλοιπο τοπικό ηλεκτρικό σύστημα. Δύο λιμένες με ίδια ετήσια κατανάλωση μπορούν να απαιτούν εντελώς διαφορετική ισχύ σύνδεσης, εάν ο ένας εμφανίζει ομαλή καμπύλη φορτίου και ο άλλος σύντομες, επαναλαμβανόμενες αιχμές λόγω ταυτόχρονων προσεγγίσεων πλοίων. Η διάκριση αυτή εξηγεί γιατί η απλή προβολή ετήσιων τάσεων δεν επαρκεί για τον επιχειρησιακό και τεχνικό σχεδιασμό. Η βιβλιογραφία επισημαίνει ότι η τεχνική και οικονομική βιωσιμότητα των εγκαταστάσεων OPS εξαρτάται σε σημαντικό βαθμό από τη δομή του λιμένα, τη χρήση των εγκαταστάσεων και τα χαρακτηριστικά της ηλεκτρικής ζήτησης (Ballini & Bozzo, 2015; Innes & Monios, 2018; Winkel et al., 2016; Zis, 2019).

Η εγκατάσταση OPS δημιουργεί στενή αλληλεξάρτηση μεταξύ του προγράμματος αφίξεων και αναχωρήσεων των πλοίων, της διαθεσιμότητας των θέσεων ελλιμενισμού και της λειτουργίας του ηλεκτρικού συστήματος του λιμένα. Μεταβολές στον χρόνο άφιξης των πλοίων ή στη θέση ελλιμενισμού τους μπορούν να μεταβάλουν σημαντικά τη χρονική κατανομή του ηλεκτρικού φορτίου και, κατά συνέπεια, τις απαιτήσεις ισχύος του λιμένα. Για τον λόγο αυτό, οι βραχυπρόθεσμες προβλέψεις επικαιροποιούνται επιχειρησιακά καθώς γίνονται διαθέσιμα νέα δεδομένα σχετικά με τις αφίξεις, τις αναχωρήσεις και τις πραγματικές συνδέσεις των πλοίων, επιτρέποντας τη συνεχή αναθεώρηση των εκτιμήσεων φορτίου.

Ο ενεργειακός σχεδιασμός πρέπει να διαχωρίζει την εγκατεστημένη ισχύ από την πραγματική αξιοποίησή της. Η ονομαστική ισχύς ενός σταθμού OPS αποτελεί τεχνικό ανώτατο όριο, ενώ η πραγματική ζήτηση εξαρτάται από τον τύπο και τη συχνότητα των προσεγγίσεων, τα χαρακτηριστικά των πλοίων και τις επιχειρησιακές συνθήκες. Η αξιόπιστη πρόβλεψη του ηλεκτρικού φορτίου υποστηρίζει το σταδιακό σχεδιασμό και την ανάπτυξη των ηλεκτρικών υποδομών, επιτρέποντας την τεχνική και οικονομική αξιολόγηση εναλλακτικών λύσεων. Αν οι αιχμές φορτίου εμφανίζονται μόνο για λίγες ώρες τον χρόνο, μπορεί να είναι οικονομικότερη η αξιοποίηση λύσεων όπως η αποθήκευση ενέργειας ή η μετατόπιση φορτίου, αντί της άμεσης υπερδιαστασιολόγησης του δικτύου. Αντίθετα, όταν οι υψηλές φορτίσεις είναι συχνές και μεγάλης διάρκειας, απαιτείται μόνιμη ενίσχυση των ηλεκτρικών υποδομών. Με τον τρόπο αυτό, ακόμη και οι βραχυπρόθεσμες προβλέψεις ηλεκτρικού φορτίου παρέχουν πολύτιμη πληροφορία για τον επιχειρησιακό σχεδιασμό και τον μακροπρόθεσμο προγραμματισμό επενδύσεων στις ηλεκτρικές υποδομές του λιμένα.

1.6. Αντικείμενο και ευρύτερο πλαίσιο

1.6.1. Οι λιμένες ως σύνθετα ενεργειακά και επιχειρησιακά συστήματα

Οι λιμένες αποτελούν κρίσιμους κόμβους των παγκόσμιων εφοδιαστικών αλυσίδων, αλλά η λειτουργία τους δεν περιορίζεται στη μεταφόρτωση εμπορευμάτων ή στην εξυπηρέτηση επιβατών. Σε μια σύγχρονη λιμενική ζώνη συνυπάρχουν θαλάσσιες μεταφορές, χερσαία εφοδιαστική, βιομηχανικές και ναυπηγοεπισκευαστικές δραστηριότητες, κτίρια, αποθήκες, ψυκτικές εγκαταστάσεις, συστήματα ασφάλειας, δίκτυα φωτισμού και υποδομές παροχής ενέργειας. Το ενεργειακό προφίλ προκύπτει από την αλληλεπίδραση αυτών των επιμέρους λειτουργιών και, συνεπώς, ο λιμένας πρέπει να αντιμετωπίζεται ως σύνθετο κοινωνικοτεχνικό σύστημα και όχι ως ένας ενιαίος καταναλωτής με σταθερή καμπύλη φορτίου. Η προσέγγιση αυτή συνάδει με τη βιβλιογραφία της ενεργειακής διαχείρισης λιμένων, η οποία μετατοπίζει τον ρόλο των λιμενικών αρχών από τη διαχείριση λιμενικής περιουσίας και υποδομών προς τον συντονισμό ενεργειακών ροών, επενδύσεων και εμπλεκόμενων φορέων (Acciario et al., 2014; Iris & Lam, 2019). Η πολυπλοκότητα των λιμενικών ενεργειακών συστημάτων απαιτεί τον σαφή προσδιορισμό του αντικειμένου της πρόβλεψης, καθώς τα χαρακτηριστικά του εξεταζόμενου συστήματος, το επίπεδο ανάλυσης και η διαθεσιμότητα των δεδομένων επηρεάζουν τόσο τη διαμόρφωση του προβλήματος όσο και την ερμηνεία των αποτελεσμάτων. Η πρόβλεψη μπορεί να αφορά είτε τη συνολική ηλεκτρική κατανάλωση ενός λιμένα είτε επιμέρους κατηγορίες φορτίων που απαντώνται στο λιμενικό περιβάλλον. Μια μέτρηση στο σημείο σύνδεσης με το δίκτυο επιτρέπει την αποτύπωση και την πρόβλεψη της συνολικής ζήτησης, αλλά δεν καθιστά δυνατή την αποτίμηση της συνεισφοράς των επιμέρους καταναλώσεων ή την αναγνώριση των φορτίων που διαθέτουν δυνατότητα ευέλικτης διαχείρισης. Αντίθετα, η ανάλυση επιμέρους φορτίων

διευκολύνει την κατανόηση της συμπεριφοράς διαφορετικών κατηγοριών κατανάλωσης και την αξιολόγηση της ευελιξίας τους, αυξάνει όμως την πολυπλοκότητα συλλογής και ενοποίησης των δεδομένων.

1.6.2. Ετερογένεια φορτίων και λιμενικών τύπων

Το προφίλ ηλεκτρικού φορτίου ενός λιμένα αποτελεί τη συνισταμένη επιμέρους ηλεκτρικών φορτίων με διαφορετικό μέγεθος, φυσική προέλευση και χρονική συμπεριφορά, όπως φαίνεται και στο Σχήμα 1. Η σύνθεση αυτών των φορτίων καθορίζεται από τις δραστηριότητες που αναπτύσσονται σε κάθε λιμένα και τους κυρίαρχους επιμέρους καταναλωτές, με αποτέλεσμα να μην υπάρχει ένα καθολικό «τυπικό» προφίλ ηλεκτρικού φορτίου. Οι εμπορευματικοί λιμένες εμφανίζουν έντονη συσχέτιση της κατανάλωσης με τις κινήσεις φορτίου, τη λειτουργία γερανών και γερανογεφύρων, την αποθήκευση και το πλήθος ψυκτικών εμπορευματοκιβωτίων. Οι επιβατικοί λιμένες, συμπεριλαμβανομένων των λιμένων κρουαζιέρας, επηρεάζονται περισσότερο από την εποχικότητα, τα προγράμματα αφίξεων και αναχωρήσεων, την τουριστική ζήτηση και τα μεγάλα φορτία ξενοδοχειακών υπηρεσιών των πλοίων. Αντίστοιχα, οι λιμένες χύδην φορτίου χαρακτηρίζονται από τη λειτουργία ταινιοδρόμων, αντλιών, φορτωτών και εγκαταστάσεων επεξεργασίας, ενώ οι ναυπηγοεπισκευαστικές ζώνες περιλαμβάνουν ενεργοβόρες βιομηχανικές διεργασίες, όπως ηλεκτροσυγκολλήσεις, συμπιεστές και βαρέα μηχανήματα. Οι μικροί νησιωτικοί λιμένες, συχνά εξυπηρετούνται από ασθενέστερα ηλεκτρικά δίκτυα και εμφανίζουν εντονότερη εποχικότητα, γεγονός που περιορίζει την ικανότητά τους να απορροφούν απότομες αυξήσεις του φορτίου. Συνεπώς, η μεταφερσιμότητα ενός μοντέλου πρόβλεψης μεταξύ διαφορετικών λιμένων είναι περιορισμένη χωρίς κατάλληλη προσαρμογή των χαρακτηριστικών εισόδου και επανεκπαίδευση.

Πέρα από τις διαφορές μεταξύ λιμένων, σημαντική ετερογένεια παρουσιάζουν και οι ίδιοι οι επιμέρους ηλεκτρικοί καταναλωτές ως προς το μέγεθος, τη χρονική συμπεριφορά και τον βαθμό προβλεψιμότητας του φορτίου τους όπως φαίνεται στον Πίνακα 2.

Κύριες συνιστώσες της ηλεκτρικής ζήτησης σε λιμενικές εγκαταστάσεις



Σχήμα 1. Κύριες συνιστώσες της ηλεκτρικής ζήτησης σε λιμενικές εγκαταστάσεις

Η ηλεκτροδότηση πλοίων από την ξηρά (Onshore Power Supply – OPS) δεν προσθέτει ένα σταθερό φορτίο, αλλά εισάγει γεγονότα μεγάλης ισχύος, των οποίων η έναρξη, η διάρκεια και το μέγεθος εξαρτώνται από το πρόγραμμα ελλιμενισμού, τον τύπο του πλοίου, τις ξενοδοχειακές ανάγκες, την εποχή, τη διαθεσιμότητα συμβατού εξοπλισμού και το ποσοστό χρήσης της υποδομής. Η ταυτόχρονη σύνδεση πολλών πλοίων μπορεί να δημιουργήσει αιχμές συγκρίσιμες ή και μεγαλύτερες από το υφιστάμενο χερσαίο φορτίο. Αντίστοιχα, η ηλεκτροκίνηση οχημάτων και εξοπλισμού διακίνησης μεταφέρει ενεργειακή ζήτηση από τα υγρά καύσιμα στο ηλεκτρικό δίκτυο και εισάγει φορτία φόρτισης που είναι δυνητικά ελεγχόμενα, αλλά εξαρτώνται από τις βάρδιες, τους κύκλους εργασίας και τους επιχειρησιακούς περιορισμούς. Αντίθετα, οι ψυκτικοί καταναλωτές, όπως τα reefer containers και οι ψυχόμενες αποθήκες, δημιουργούν σχετικά συνεχές φορτίο, το οποίο επηρεάζεται κυρίως από τον αριθμό των μονάδων, τις ρυθμίσεις θερμοκρασίας, τη θερμοκρασία περιβάλλοντος, την ηλιακή ακτινοβολία και τη διάρκεια παραμονής των φορτίων. Τα κτιριακά φορτία εμφανίζουν έντονη ημερήσια και εβδομαδιαία περιοδικότητα, ενώ ο εξωτερικός φωτισμός ακολουθεί κυρίως τον κύκλο ημέρας-νύχτας και την ένταση της επιχειρησιακής δραστηριότητας.

Πίνακας 2. Ενδεικτικές συνιστώσες φορτίου και προσδιοριστικοί παράγοντες.

Συνιστώσα	Τυπική συμπεριφορά	Κύριοι προσδιοριστικοί παράγοντες	Χρήσιμα δεδομένα
Γερανοί STS/RTG/RMG	Υψηλές, βραχείες αιχμές και αναγεννητική λειτουργία	Αριθμός κινήσεων, βάρος φορτίου, πρόγραμμα γερανών, αριθμός ενεργών μηχανημάτων	TOS, PLC/SCADA, μετρητές υποσταθμών
Reefer containers	Σχετικά συνεχές φορτίο με κύκλους συμπίεστών	Πλήθος reefers, θερμοκρασία περιβάλλοντος, set-points, ανοίγματα θυρών	TOS, αισθητήρες reefer, μετεωρολογικά δεδομένα
OPS/cold ironing	Μεγάλα βηματικά φορτία κατά τον ελλιμενισμό	Τύπος πλοίου, ώρα άφιξης, διάρκεια παραμονής, ποσοστό σύνδεσης, απαιτήσεις πλοίου	AIS, port-call database, berth plan, μετρητές OPS
Κτίρια και φωτισμός	Ομαλή ημερήσια/εβδομαδιαία εποχικότητα	Ωράριο, θερμοκρασία, υγρασία, εποχή, πληρότητα	BMS, μετρητές, καιρός, ημερολόγιο
Ηλεκτρικά οχήματα/AGVs	Συσσωρευμένες ανάγκες φόρτισης και ευελιξία	Κύκλοι εργασίας, SOC, διαθεσιμότητα φορτιστών, βάρδιες	Fleet management, charger logs
Ηλεκτρόλυση/νέα φορτία	Υψηλή ισχύς, δυνητικά προγραμματιζόμενη	Τιμή ενέργειας, στόχος παραγωγής, διαθεσιμότητα ΑΠΕ	EMS, αγορά ενέργειας, παραγωγή ΑΠΕ

Συνεπώς, η συνολική καμπύλη φορτίου ενός λιμένα αποτελεί τη συνισταμένη ετερόκλητων ηλεκτρικών φορτίων, άλλων σχεδόν σταθερών, άλλων περιοδικών και άλλων εξαρτώμενων από επιχειρησιακά γεγονότα. Η συνύπαρξη αυτών των διαφορετικών προτύπων κατανάλωσης αυξάνει την πολυπλοκότητα της μοντελοποίησης της ζήτησης και, κατ' επέκταση, της βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου.

1.6.3. Από τον παθητικό καταναλωτή στον ενεργό ενεργειακό κόμβο

Η ενεργειακή μετάβαση μετασχηματίζει τους λιμένες από παθητικούς καταναλωτές ηλεκτρικής ενέργειας σε ενεργούς ενεργειακούς κόμβους. Η ενσωμάτωση ανανεώσιμων πηγών ενέργειας, συστημάτων αποθήκευσης, υποδομών ηλεκτροδότησης από ξηρά (OPS) και φόρτισης ηλεκτρικών οχημάτων και η υιοθέτηση τεχνολογιών διαχείρισης ζήτησης δημιουργούν ένα ολοένα πιο σύνθετο ενεργειακό οικοσύστημα, στο οποίο η κατανάλωση, η τοπική παραγωγή και η αποθήκευση ηλεκτρικής ενέργειας αλληλεπιδρούν δυναμικά. Μελέτες έχουν δείξει ότι ο συνδυασμένος σχεδιασμός ενεργειακής διαχείρισης και λιμενικών λειτουργιών μπορεί να μειώσει τόσο το λειτουργικό κόστος όσο και τις εκπομπές αερίων του θερμοκηπίου, ενώ οι αρχιτεκτονικές λιμενικών μικροδικτύων ενσωματώνουν πλέον την πρόβλεψη φορτίου και ανανεώσιμης παραγωγής στις διαδικασίες λήψης αποφάσεων (Gennitsaris & Kanellos, 2019; Iris & Lam, 2021; Zhang et al., 2022).

Σε αυτό το περιβάλλον, η διαχείριση της ηλεκτρικής ενέργειας δεν περιορίζεται πλέον στην κάλυψη της ζήτησης, αλλά περιλαμβάνει αποφάσεις σχετικά με την κατανομή της διαθέσιμης ισχύος, το συντονισμό λειτουργίας των συστημάτων αποθήκευσης, την αξιοποίηση της τοπικής παραγωγής, τον προγραμματισμό της προμήθειας ηλεκτρικής ενέργειας και το συντονισμό εύελκτων φορτίων. Η ποιότητα των αποφάσεων αυτών εξαρτάται σε μεγάλο βαθμό από την αξιοπιστία της πρόβλεψης του ηλεκτρικού φορτίου, καθώς η εμπειρική ή ανακριβής εκτίμηση της μελλοντικής ζήτησης μπορεί να οδηγήσει σε υπερβολική αγορά ενέργειας, ενεργοποίηση ακριβών εφεδρειών, παραβίαση περιορισμών ισχύος, αναποτελεσματική λειτουργία των συστημάτων αποθήκευσης ή αδυναμία αξιοποίησης της διαθέσιμης ανανεώσιμης παραγωγής. Αντίθετα, η αξιόπιστη πρόβλεψη επιτρέπει οικονομικότερη λειτουργία, αποτελεσματικότερη αξιοποίηση των ενεργειακών υποδομών και περιορισμό των περιβαλλοντικών επιπτώσεων (Hong & Fan, 2016). Κατά συνέπεια, στους σύγχρονους λιμένες, η πρόβλεψη ηλεκτρικού φορτίου μετατρέπεται από εργαλείο εκτίμησης της μελλοντικής ζήτησης σε βασικό μηχανισμό υποστήριξης της ενεργειακής και επιχειρησιακής λήψης αποφάσεων.

1.7. Η ενεργειακή ζήτηση ως πρόβλημα πρόβλεψης

1.7.1. Μεταβλητή-στόχος, χρονική ανάλυση και ορίζοντας

Η πρόβλεψη ενεργειακής ζήτησης αφορά την εκτίμηση μίας ή περισσότερων μελλοντικών τιμών του ηλεκτρικού φορτίου με βάση την πληροφορία που είναι διαθέσιμη κατά τον χρόνο έκδοσης της πρόβλεψης. Η επιλογή της μεταβλητής-στόχου πρέπει να είναι συμβατή με τον επιδιωκόμενο σκοπό της πρόβλεψης και τη χρήση των αποτελεσμάτων της. Ο χρονικός ορίζοντας καθορίζει το σύνολο των διαθέσιμων χαρακτηριστικών που μπορούν να χρησιμοποιηθούν κατά την πρόβλεψη. Για βραχυπρόθεσμες προβλέψεις αξιοποιούνται συνήθως πρόσφατες υστερήσεις της χρονοσειράς, ημερολογιακά χαρακτηριστικά, λειτουργικές μεταβλητές και οι τοπικά και χρονικά αντίστοιχες μετεωρολογικές προβλέψεις, ενώ σε μεγαλύτερους χρονικούς ορίζοντες αυξάνεται η αβεβαιότητα των εξωγενών μεταβλητών και ενδέχεται να απαιτείται η εξέταση εναλλακτικών σεναρίων.

Η πρόβλεψη μπορεί να είναι σημειακή (point forecasting), όπου παράγεται μία μοναδική εκτιμώμενη τιμή, ή πιθανοτική (probabilistic forecasting), όπου εκτιμάται η αβεβαιότητα της πρόβλεψης μέσω εκατοστημορίων (quantiles), κατανομών πιθανότητας ή διαστημάτων πρόβλεψης. Οι σημειακές προβλέψεις έχουν το πλεονέκτημα ότι είναι ευκολότερες στην ερμηνεία και αποτελούν τη συνηθέστερη βάση για τη συγκριτική αξιολόγηση μοντέλων. Από την άλλη πλευρά, σε εφαρμογές όπου η αβεβαιότητα των προβλέψεων επηρεάζει τη λήψη επιχειρησιακών αποφάσεων, οι πιθανοτικές προβλέψεις παρέχουν πρόσθετη πληροφορία, εκτιμώντας το εύρος της αβεβαιότητας μέσω κατανομών πιθανότητας, εκατοστημορίων ή διαστημάτων πρόβλεψης (Gneiting & Katzfuss, 2014; Hong & Fan, 2016).

1.7.2. Χρονική δομή, μη στασιμότητα και σπάνια συμβάντα

Τα λιμενικά φορτία συνδυάζουν περιοδικότητα και γεγονότα. Τα κτίρια, ο φωτισμός και οι βάρδιες δημιουργούν ημερήσια και εβδομαδιαία πρότυπα. Η τουριστική κίνηση και οι μετεωρολογικές συνθήκες δημιουργούν εποχικότητα. Αντίθετα, οι αφίξεις πλοίων, η ταυτόχρονη λειτουργία γερανών, οι βλάβες και οι έκτακτες εργασίες προκαλούν απότομες μεταβολές. Η συνολική σειρά μπορεί να εμφανίζει υψηλή αυτοσυσχέτιση στις συνήθεις περιόδους και χαμηλή προβλεψιμότητα στα επιχειρησιακά συμβάντα. Για αυτό η αξιολόγηση αποκλειστικά μέσω συνολικών δεικτών σφάλματος μπορεί να αποκρύψει τις χρονικές περιόδους που είναι επιχειρησιακά σημαντικότερες. Η μη στασιμότητα αποτελεί κεντρικό ζήτημα. Η εγκατάσταση νέου γερανού, η έναρξη λειτουργίας OPS, η αλλαγή τιμολογίου, η επέκταση ωραρίου ή η ηλεκτροκίνηση στόλου μεταβάλλουν τη σχέση μεταξύ χαρακτηριστικών και ζήτησης. Το concept drift μπορεί να είναι απότομο, όπως μετά από σύνδεση νέου μεγάλου φορτίου, ή σταδιακό, όπως η αύξηση της χρήσης OPS. Ένα μοντέλο που εκπαιδεύτηκε σε ιστορική περίοδο πριν από τη μεταβολή μπορεί να εμφανίζει συστηματική μεροληψία, η οποία σε επίπεδο εφαρμογής μπορεί να αντιμετωπιστεί με παρακολούθηση υπολοίπων, επανεκπαίδευση και, όπου απαιτείται, ειδικούς δείκτες καθεστώτος (regime indicators). Οι ακραίες τιμές (outliers) αποτελούν συχνό χαρακτηριστικό των χρονοσειρών ηλεκτρικού φορτίου και απαιτούν προσεκτική αξιολόγηση πριν από οποιαδήποτε επεξεργασία. Μία απότομη αιχμή φορτίου μπορεί να οφείλεται είτε σε σφάλμα μέτρησης είτε να αντιστοιχεί σε πραγματικό επιχειρησιακό γεγονός, όπως η ταυτόχρονη σύνδεση δύο πλοίων στο σύστημα ηλεκτροδότησης. Η μηχανική ανίχνευση και απομάκρυνση των ακραίων τιμών μπορεί να βελτιώσει τεχνητά τους συνολικούς δείκτες σφάλματος, υποβαθμίζοντας όμως την ικανότητα του μοντέλου να προβλέπει τις κρίσιμες περιόδους πραγματικού ενδιαφέροντος. Για τον λόγο αυτό, η διάκριση μεταξύ αληθινών ακραίων γεγονότων και σφαλμάτων μέτρησης απαιτεί συνδυασμό στατιστικών κριτηρίων και γνώσης της φυσικής λειτουργίας του συστήματος που μελετάται.

1.7.3. Πολυπηγικά δεδομένα και πραγματική διαθεσιμότητα πληροφορίας

Η πρόβλεψη του ηλεκτρικού φορτίου σε λιμενικά περιβάλλοντα αποτελεί κατεξοχήν πρόβλημα ενοποίησης ετερογενών πηγών δεδομένων. Οι μετρήσεις ηλεκτρικής ενέργειας προέρχονται συνήθως από συστήματα SCADA, έξυπνους μετρητές ή λογαριασμούς ηλεκτρικής ενέργειας. Τα επιχειρησιακά δεδομένα αντλούνται από Terminal Operating Systems (TOS), Port Community Systems (PCS), προγράμματα λειτουργίας γερανών, βάρδιες προσωπικού και αρχεία συντήρησης. Τα ναυτιλιακά δεδομένα περιλαμβάνουν προγραμματισμένες αφίξεις, πραγματικό χρόνο άφιξης (Actual Time of Arrival – ATA), κατηγορία και μέγεθος πλοίου, διάρκεια παραμονής, καθώς και δεδομένα του Συστήματος Αυτόματης Αναγνώρισης Πλοίων (Automatic Identification System – AIS). Οι

μετεωρολογικές μεταβλητές προέρχονται είτε από τοπικούς αισθητήρες είτε από υπηρεσίες πρόγνωσης καιρού. Η χρονική ευθυγράμμιση των διαφορετικών πηγών, οι αποκλίσεις στις ζώνες ώρας και οι μεταγενέστερες διορθώσεις των επιχειρησιακών αρχείων αποτελούν συχνές πηγές σφαλμάτων κατά την ανάπτυξη μοντέλων πρόβλεψης. Κατά την επιχειρησιακή εφαρμογή ενός συστήματος πρόβλεψης, κάθε χαρακτηριστικό εισόδου πρέπει να είναι διαθέσιμο *ex ante*, δηλαδή κατά τη χρονική στιγμή έκδοσης της πρόβλεψης. Η χρήση πληροφορίας που καθίσταται διαθέσιμη μεταγενέστερα, η χρήση του πραγματικού χρόνου άφιξης ενός πλοίου ή της παρατηρηθείσας θερμοκρασίας σε πρόβλεψη επόμενης μέρας, οδηγεί σε διαρροή πληροφορίας (*data leakage*) και μπορεί να οδηγήσει σε υπερεκτίμηση της πραγματικής απόδοσης του μοντέλου. Αντίθετα, σε αναδρομικές (*ex post*) συγκριτικές μελέτες, χρησιμοποιούνται συχνά παρατηρηθείσες μετεωρολογικές μεταβλητές προκειμένου να αξιολογηθεί η εγγενής προγνωστική ικανότητα των μοντέλων υπό κοινές συνθήκες εισόδου. Παρότι η βιβλιογραφία αναδεικνύει τη σημασία επιχειρησιακών μεταβλητών, όπως οι αφίξεις πλοίων, ο προγραμματισμός γερανών, οι δείκτες διακίνησης φορτίου και λοιποί λειτουργικοί δείκτες λιμενικής δραστηριότητας (Do Carmo et al., 2026; Micallef et al., 2025; Kim et al., 2023), η διαθεσιμότητα τέτοιων δεδομένων παραμένει περιορισμένη στις περισσότερες πραγματικές εφαρμογές. Ως αποτέλεσμα, πολλές μελέτες πρόβλεψης ηλεκτρικού φορτίου βασίζονται κυρίως σε ιστορικές μετρήσεις φορτίου, ημερολογιακές μεταβλητές και μετεωρολογικά δεδομένα, τα οποία αποτελούν τις πλέον ευρέως διαθέσιμες και τυποποιημένες πηγές πληροφορίας για την ανάπτυξη και αξιολόγηση μοντέλων STLF. Η επιλογή των χαρακτηριστικών εισόδου αποτελεί συνεπώς συμβιβασμό μεταξύ της θεωρητικά βέλτιστης αναπαράστασης της λειτουργίας του συστήματος και της πρακτικής διαθεσιμότητας αξιόπιστων δεδομένων. Σε κάθε περίπτωση η ποιότητα, η πληροφοριακή επάρκεια και η αντιπροσωπευτικότητα των χαρακτηριστικών εισόδου αποτελούν, μαζί με την επιλογή του κατάλληλου μοντέλου και την παραμετροποίησή του, βασικούς διαμορφωτικούς παράγοντες της προγνωστικής απόδοσης και συμβάλλουν στη βελτίωση της ακρίβειας των μοντέλων πρόβλεψης, ανεξάρτητα από την αλγοριθμική τους πολυπλοκότητα.

1.7.4. Επιχειρησιακές χρήσεις της πρόβλεψης

Η αξία μιας πρόβλεψης δεν καθορίζεται μόνο από τη συνολική ακρίβειά της, αλλά και από την επιχειρησιακή χρήση για την οποία προορίζεται. Στον βραχυπρόθεσμο επιχειρησιακό προγραμματισμό, σημασία έχουν η σωστή αποτύπωση της αναμενόμενης εξέλιξης του φορτίου και η αποφυγή συστηματικής μεροληψίας, ενώ στη διαχείριση αιχμών η μέγιστη τιμή του φορτίου, η χρονική στιγμή εμφάνισής της και η πιθανότητα υπέρβασης προκαθορισμένων ορίων. Για τη λειτουργία συστημάτων αποθήκευσης ενδιαφέρουν κυρίως η εξέλιξη του φορτίου και η αβεβαιότητα της πρόβλεψης σε κάθε χρονικό βήμα, ενώ στον σχεδιασμό ενεργειακών υποδομών μεγαλύτερη σημασία έχουν τα ακραία σενάρια και οι μακροπρόθεσμες μεταβολές της ζήτησης. Από επιχειρησιακή σκοπιά, το «βέλτιστο» μοντέλο δεν είναι κατ' ανάγκην εκείνο που επιτυγχάνει τη μικρότερη τιμή ενός γενικού δείκτη σφάλματος, αλλά εκείνο που υποστηρίζει αποτελεσματικότερα τη συγκεκριμένη επιχειρησιακή απόφαση.

Η αποτελεσματική αξιοποίηση των προβλέψεων εξαρτάται επίσης από το επίπεδο χωρικής ανάλυσης των δεδομένων. Η πρόβλεψη του συνολικού ηλεκτρικού φορτίου ενός λιμένα είναι κατάλληλη για τον συνολικό ενεργειακό προγραμματισμό και τη διαχείριση της σύνδεσης με το ηλεκτρικό δίκτυο, ενώ η πρόβλεψη επιμέρους λειτουργικών μονάδων ή υπομετρητών παρέχει λεπτομερέστερη πληροφόρηση και υποστηρίζει στοχευμένες παρεμβάσεις διαχείρισης. Η επιλογή του κατάλληλου επιπέδου ανάλυσης εξαρτάται από τους επιχειρησιακούς στόχους της εφαρμογής και τη διαθεσιμότητα αξιόπιστων δεδομένων.

1.7.5. Ταξινόμηση του προβλήματος και επίπεδα δυσκολίας

Η πρόβλεψη ενεργειακής ζήτησης μπορεί να ταξινομηθεί με βάση τον χρονικό ορίζοντα, τη χρονική ανάλυση, τη μορφή της εξόδου και τη διαθεσιμότητα εξωγενών μεταβλητών. Όσον αφορά το χρονικό ορίζοντα, η πολύ βραχυπρόθεσμη πρόβλεψη καλύπτει χρονικό διάστημα έως περίπου μια ώρα και βασίζεται κυρίως στην πρόσφατη δυναμική του φορτίου και στην τρέχουσα λειτουργική κατάσταση. Η βραχυπρόθεσμη πρόβλεψη, συνήθως από μια ώρα έως λίγες ημέρες, συνδυάζει ιστορικές μετρήσεις φορτίου, ημερολογιακά χαρακτηριστικά, προγνώσεις καιρού και, όπου είναι διαθέσιμες, επιχειρησιακές πληροφορίες. Η μεσοπρόθεσμη πρόβλεψη καλύπτει χρονικό διάστημα εβδομάδων ή μηνών και χρησιμοποιείται για τον προγραμματισμό πόρων και συντήρησης, ενώ η μακροπρόθεσμη πρόβλεψη υποστηρίζει επενδυτικές αποφάσεις και βασίζεται περισσότερο σε σενάρια εξέλιξης παρά στη βραχυχρόνια δυναμική των χρονοσειρών.

Ένα δεύτερο κριτήριο ταξινόμησης αφορά τη μορφή της πρόβλεψης, η οποία μπορεί να είναι σημειακή ή πιθανοτική. Η σημειακή πρόβλεψη παρέχει μία αναμενόμενη τιμή για κάθε χρονικό βήμα, ενώ η πιθανοτική πρόβλεψη αποδίδει ποσοστημόρια, διαστήματα πρόβλεψης ή πλήρη κατανομή πιθανότητας, επιτρέποντας την ποσοτικοποίηση της αβεβαιότητας και τη λήψη αποφάσεων με βάση το επιθυμητό επίπεδο κινδύνου. Οι Hong και Fan (2016) επισημαίνουν ότι η αξιολόγησή της πρέπει να λαμβάνει υπόψη τόσο την αξιοπιστία όσο και την οξύτητα των διαστημάτων πρόβλεψης, καθώς ένα υπερβολικά ευρύ διάστημα μπορεί να παρουσιάζει υψηλή κάλυψη αλλά περιορισμένη πρακτική αξία.

Τρίτο κριτήριο αποτελεί η στρατηγική πολυβηματικής πρόβλεψης. Στην αναδρομική (recursive) στρατηγική, ένα μοντέλο ενός βήματος εφαρμόζεται επαναληπτικά και οι προηγούμενες προβλέψεις χρησιμοποιούνται ως είσοδοι για τα επόμενα χρονικά βήματα. Η προσέγγιση αυτή είναι υπολογιστικά αποδοτική, αλλά είναι επιρρεπής σε συσσωρευση σφάλματος. Στην άμεση (direct) στρατηγική εκπαιδεύεται διαφορετικό μοντέλο για κάθε βήμα πρόβλεψης, μειώνοντας τη διάδοση του σφάλματος με αυξημένο όμως υπολογιστικό κόστος. Στην προσέγγιση πολλαπλής εξόδου (multi-output), ένα ενιαίο μοντέλο προβλέπει ταυτόχρονα ολόκληρο τον ορίζοντα πρόβλεψης, αξιοποιώντας τις συσχετίσεις μεταξύ των μελλοντικών χρονικών βημάτων. Η καταλληλότερη στρατηγική εξαρτάται από τον χρονικό ορίζοντα, το μέγεθος και τη διαθεσιμότητα δεδομένων και την αρχιτεκτονική του μοντέλου. Τέταρτο κριτήριο είναι το επίπεδο συγκέντρωσης της πρόβλεψης. Η πρόβλεψη μπορεί να αφορά το συνολικό φορτίο ενός συστήματος ή επιμέρους λειτουργικές μονάδες του. Η ανάλυση σε λεπτομερέστερο επίπεδο επιτρέπει την αξιοποίηση εξειδικευμένων πληροφοριών για κάθε υποσύστημα, απαιτεί όμως μεγαλύτερη διαθεσιμότητα και συνέπεια δεδομένων. Όταν πραγματοποιούνται προβλέψεις σε πολλαπλά επίπεδα, μπορούν να εφαρμοστούν τεχνικές συμφιλίωσης προβλέψεων (forecast reconciliation), ώστε να διασφαλίζεται η συνέπεια μεταξύ των προβλέψεων στα διαφορετικά επίπεδα συγκέντρωσης.

Το επίπεδο δυσκολίας του προβλήματος αυξάνεται όταν η διαδικασία παρουσιάζει μεταβολή της υποκείμενης σχέσης μεταξύ των χαρακτηριστικών εισόδων και της μεταβλητής στόχου (concept drift), φαινόμενο που συχνά συνοδεύει μη στάσιμες χρονοσειρές (Gama et al., 2014). Η ηλεκτροδότηση νέου εξοπλισμού, η εγκατάσταση φωτοβολταϊκών συστημάτων, η εφαρμογή συστημάτων ηλεκτροδότησης πλοίων από την ξηρά (OPS) ή άλλες μεταβολές στη λειτουργία ενός λιμένα μπορούν να αλλάξουν τη συμπεριφορά του φορτίου και να μειώσουν την ακρίβεια ενός μοντέλου που είχε εκπαιδευτεί σε προηγούμενες συνθήκες. Για τον λόγο αυτό απαιτείται περιοδική αξιολόγηση της απόδοσης και, όταν κρίνεται αναγκαίο, επανεκπαίδευση του μοντέλου.

1.8. Διατύπωση του ερευνητικού προβλήματος

1.8.1. Αποσύνθεση του λιμενικού φορτίου

Το συνολικό ηλεκτρικό φορτίο ενός λιμένα μπορεί να θεωρηθεί ως το άθροισμα επιμέρους λειτουργικών συνιστωσών. Η ακόλουθη σχέση δεν προϋποθέτει ότι κάθε συνιστώσα μετράται ανεξάρτητα, αλλά αποτελεί εννοιολογική αποσύνθεση που διευκολύνει την κατανόηση των μηχανισμών διαμόρφωσης του φορτίου, την επιλογή των κατάλληλων χαρακτηριστικών εισόδου και την ερμηνεία των σφαλμάτων πρόβλεψης:

$$P_t^{\text{port}} = P_t^{\text{base}} + P_t^{\text{cargo}} + P_t^{\text{reefer}} + P_t^{\text{OPS}} + P_t^{\text{mobility}} + P_t^{\text{aux}}$$

όπου P_t^{base} αντιστοιχεί στο φορτίο βάσης των μόνιμων εγκαταστάσεων και των κτιρίων, P_t^{cargo} στο φορτίο του εξοπλισμού διακίνησης φορτίων, P_t^{reefer} στο φορτίο των ψυκτικών εμπορευματοκιβωτίων, P_t^{OPS} στην ηλεκτροδότηση ελλιμενισμένων πλοίων από την ξηρά (Onshore Power Supply), P_t^{mobility} στα συστήματα φόρτισης και στον ηλεκτροκίνητο εξοπλισμό, ενώ P_t^{aux} περιλαμβάνει λοιπές βοηθητικές καταναλώσεις, όπως αντλίες, φωτισμό, εργαστήρια και υποστηρικτικές εγκαταστάσεις. Η εννοιολογική αυτή αποσύνθεση αναδεικνύει ότι διαφορετικοί παράγοντες επηρεάζουν διαφορετικές συνιστώσες του φορτίου. Για παράδειγμα, η θερμοκρασία επηρεάζει κυρίως τα φορτία κλιματισμού και ψύξης, ενώ το πρόγραμμα αφίξεων και παραμονής πλοίων επηρεάζει κυρίως το φορτίο του OPS και, έμμεσα, τη λειτουργία του εξοπλισμού διακίνησης. Στην πράξη, όταν οι μετρήσεις είναι διαθέσιμες ως χρονοσειρά ισχύος (kW) με σταθερό χρονικό βήμα (h), η καταναλισκόμενη ηλεκτρική ενέργεια (kWh) προκύπτει από τη χρονική ολοκλήρωση της ισχύος. Όταν το ενδιαφέρον εστιάζεται στην ακριβέστερη περιγραφή των αιχμών φορτίου, χρησιμοποιούνται συχνά ο συντελεστής φορτίου (load factor) και ο λόγος αιχμής προς μέση τιμή (peak-to-average ratio):

$$LF = \frac{\bar{P}}{P_{\max}}, \quad PAR = \frac{P_{\max}}{\bar{P}}$$

Υψηλές τιμές του load factor υποδηλώνουν ομοιόμορφη αξιοποίηση της εγκατεστημένης ισχύος, ενώ υψηλές τιμές του peak-to-average ratio υποδηλώνουν εντονότερες αιχμές φορτίου.

1.8.2. Συνάρτηση πρόβλεψης και σύνολο πληροφορίας

Στην πρόβλεψη ηλεκτρικού φορτίου, στόχος είναι η εκτίμηση της μελλοντικής τιμής της ζήτησης ηλεκτρικής ισχύος για έναν συγκεκριμένο χρονικό ορίζοντα πρόβλεψης, αξιοποιώντας αποκλειστικά τις πληροφορίες που είναι διαθέσιμες κατά τον χρόνο έκδοσης της πρόβλεψης. Έστω y_t η πραγματική ζήτηση ηλεκτρικής ισχύος στο χρονικό βήμα t . Για χρονικό ορίζοντα πρόβλεψης h , η σημειακή πρόβλεψη ορίζεται ως συνάρτηση των διαθέσιμων πληροφοριών μέχρι τον χρόνο t :

$$\hat{y}_{t+h|t} = f_{\theta}(\mathbf{X}_t)$$

όπου η παράμετρος θ περιλαμβάνει τους συντελεστές ή τα βάρη του μοντέλου και το X_t αναπαριστά το διαθέσιμο σύνολο πληροφορίας. Στο πρόβλημα πρόβλεψης ηλεκτρικού φορτίου λιμένα, το σύνολο αυτό μπορεί να εκφραστεί ως:

$$\mathbf{X}_t = \{y_t, y_{t-1}, \dots, y_{t-L+1}, \mathbf{c}_t, \mathbf{w}_{t:t+H}, \mathbf{o}_{t:t+H}\}$$

όπου οι πρώτοι όροι αντιστοιχούν στο ιστορικό φορτίο και στις υστερήσεις του, $\mathbf{c}_t$ στις ημερολογιακές μεταβλητές, $\mathbf{w}$ στις διαθέσιμες μετεωρολογικές προβλέψεις και $\mathbf{o}$ στις διαθέσιμες επιχειρησιακές πληροφορίες, όπως προγράμματα αφίξεων ή λειτουργίας. Η

σημειογραφία $t: t + H$ δεν υποδηλώνει γνώση μελλοντικών τιμών της μεταβλητής-στόχου, αλλά αναφέρεται αποκλειστικά σε εξωγενείς πληροφορίες που είναι ήδη διαθέσιμες κατά τον χρόνο t , διασφαλίζοντας την αποφυγή διαρροής πληροφορίας (data leakage).

1.8.3. Εκπαίδευση και τακτικοποίηση μοντέλων πρόβλεψης

Η εκπαίδευση ενός μοντέλου πρόβλεψης μπορεί να διατυπωθεί γενικά ως πρόβλημα ελαχιστοποίησης μιας συνάρτησης απώλειας, ενδεχομένως με την προσθήκη όρου τακτικοποίησης που περιορίζει την πολυπλοκότητα του μοντέλου και βελτιώνει τη δυνατότητα γενίκευσης:

$$\theta_{\text{opt}} = \underset{\theta}{\operatorname{argmin}} \frac{1}{N} \sum_{i=1}^N \mathcal{L}(y_i, f_{\theta}(\mathbf{X}_i)) + \lambda \Omega(\theta)$$

όπου η συνάρτηση απώλειας $\mathcal{L}$ εκφράζει το σφάλμα πρόβλεψης, η συνάρτηση $\Omega(\theta)$ αποτελεί όρο τακτικοποίησης που περιορίζει την πολυπλοκότητα του μοντέλου και η παράμετρος λ ελέγχει τον συμβιβασμό μεταξύ προσαρμογής στα δεδομένα εκπαίδευσης και ικανότητας γενίκευσης σε νέα δεδομένα. Η μορφή της τακτικοποίησης εξαρτάται από την οικογένεια του μοντέλου: στα γραμμικά μοντέλα εφαρμόζεται συνήθως στους συντελεστές, ενώ στα δένδρικά και στα νευρωνικά μοντέλα υλοποιείται μέσω διαφορετικών μηχανισμών περιορισμού της πολυπλοκότητας. (Goodfellow et al., 2016)

Σε αντίθεση με τα κλασικά προβλήματα βελτιστοποίησης, στόχος στην πρόβλεψη δεν είναι η επίτευξη της μικρότερης δυνατής τιμής της συνάρτησης απώλειας στα δεδομένα εκπαίδευσης, αλλά η ανάπτυξη μοντέλων που διατηρούν υψηλή ακρίβεια σε νέα, μη παρατηρημένα δεδομένα. Η ιδιότητα αυτή είναι γνωστή ως ικανότητα γενίκευσης (generalization) και αποτελεί θεμελιώδη προϋπόθεση για την επιχειρησιακή αξιοπιστία ενός συστήματος πρόβλεψης.

Η ικανότητα γενίκευσης μπορεί να υπονομευθεί από τη χρήση πληροφοριών που δεν είναι πραγματικά διαθέσιμες κατά τον χρόνο έκδοσης της πρόβλεψης. Η χρήση πραγματοποιηθεισών μελλοντικών μετρήσεων, στατιστικών που έχουν υπολογιστεί με δεδομένα του συνόλου ελέγχου ή άλλων πληροφοριών που δεν θα ήταν επιχειρησιακά διαθέσιμες οδηγεί σε διαρροή πληροφορίας (data leakage), προκαλώντας τεχνητή υπερεκτίμηση της απόδοσης των μοντέλων και μη ρεαλιστική εκτίμηση της ικανότητας γενίκευσής τους.

Σε εφαρμογές πρόβλεψης όπου οι αιχμές φορτίου έχουν εξέχουσα επιχειρησιακή σημασία, η βιβλιογραφία έχει προτείνει σταθμισμένες συναρτήσεις απώλειας (weighted loss functions), οι οποίες αποδίδουν μεγαλύτερο βάρος στις παρατηρήσεις υψηλού φορτίου. Οι προσεγγίσεις αυτές στοχεύουν στη βελτίωση της πρόβλεψης των αιχμών, ενδέχεται όμως να μειώσουν την ακρίβεια στις συνήθεις συνθήκες λειτουργίας και εφαρμόζονται όταν οι επιχειρησιακές απαιτήσεις δικαιολογούν αυτή την αντιστάθμιση.

1.8.4. Πιθανοτική πρόβλεψη και αβεβαιότητα

Η κλασική σημειακή πρόβλεψη (point forecasting) παρέχει μία μοναδική εκτίμηση της μελλοντικής τιμής του φορτίου. Ωστόσο, στις σύγχρονες εφαρμογές βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου αυξάνεται το ενδιαφέρον για πιθανοτικές προσεγγίσεις (probabilistic forecasting), οι οποίες ποσοτικοποιούν την αβεβαιότητα της πρόβλεψης. Αντί μίας μόνο εκτίμησης, το μοντέλο παρέχει ένα διάστημα ή μία κατανομή πιθανότητας, επιτρέποντας την εκτίμηση του κινδύνου και τη λήψη περισσότερο τεκμηριωμένων επιχειρησιακών αποφάσεων. (Gneiting & Katzfuss, 2014)

Σε μία απλή μορφή πιθανοτικής πρόβλεψης ζητείται ένα κάτω και άνω όριο που να καλύπτει την πραγματική τιμή με προκαθορισμένη πιθανότητα:

$$\Pr(L_{t+h|t} \leq y_{t+h} \leq U_{t+h|t}) \approx 1 - \alpha$$

Ένα αξιόπιστο διάστημα πρόβλεψης πρέπει να είναι καλά βαθμονομημένο (well-calibrated), ώστε η εμπειρική πιθανότητα κάλυψης να προσεγγίζει το επιθυμητό επίπεδο εμπιστοσύνης, ενώ παράλληλα να παραμένει όσο το δυνατόν στενότερο. Υπερβολικά ευρεία διαστήματα μπορεί να επιτυγχάνουν υψηλή κάλυψη, αλλά μειώνουν την πρακτική χρησιμότητα της πρόβλεψης. Σε εφαρμογές όπως η λειτουργία λιμένων, η αβεβαιότητα αναμένεται να αυξάνεται κατά περιόδους έντονης επιχειρησιακής δραστηριότητας ή μεταβαλλόμενων εξωτερικών συνθηκών.

1.9. Μεθοδολογικό πλαίσιο ανάπτυξης συστημάτων πρόβλεψης ηλεκτρικού φορτίου

Η ανάπτυξη συστημάτων πρόβλεψης ηλεκτρικού φορτίου (Electricity Load Forecasting – ELF) ακολουθεί συνήθως μία διαδοχική μεθοδολογία, η οποία περιλαμβάνει τον καθορισμό του προβλήματος πρόβλεψης, τη συλλογή και προεπεξεργασία των δεδομένων, την επιλογή και κατασκευή χαρακτηριστικών, την ανάπτυξη και εκπαίδευση των μοντέλων, την επικύρωση και αξιολόγηση της απόδοσής τους, καθώς και την ερμηνεία των αποτελεσμάτων.

Αρχικά, καθορίζονται ο χρονικός ορίζοντας πρόβλεψης, η χρονική ανάλυση των δεδομένων και το πεδίο εφαρμογής, καθώς οι παράγοντες αυτοί επηρεάζουν τόσο την επιλογή των δεδομένων όσο και την καταλληλότητα των αλγορίθμων που θα χρησιμοποιηθούν.

Στη συνέχεια πραγματοποιείται η συλλογή και ενοποίηση των διαθέσιμων χρονοσειρών, οι οποίες συνήθως περιλαμβάνουν ιστορικές μετρήσεις ηλεκτρικού φορτίου, μετεωρολογικές μεταβλητές, ημερολογιακές πληροφορίες και λειτουργικά χαρακτηριστικά, ανάλογα με τη διαθεσιμότητά τους. Ακολουθεί έλεγχος της ποιότητας των δεδομένων μέσω διαδικασιών όπως η διαχείριση ελλিপών τιμών, η αντιμετώπιση ακραίων παρατηρήσεων, η χρονική ευθυγράμμιση των διαφορετικών πηγών και η διασφάλιση της συνέχειας των χρονοσειρών. Σημασία δίνεται επίσης στη δημιουργία κατάλληλων χαρακτηριστικών (feature engineering), καθώς η απόδοση των μοντέλων εξαρτάται σε μεγάλο βαθμό από την ποιότητα της αναπαράστασης των δεδομένων. Η διαδικασία αυτή μπορεί να περιλαμβάνει την αξιοποίηση ιστορικών τιμών φορτίου, χρονικών μεταβλητών, μετεωρολογικών παραμέτρων, καθώς και κατάλληλων κωδικοποιήσεων χρονικών και κατηγορικών χαρακτηριστικών, με στόχο την αποτελεσματικότερη αναπαράσταση των χρονικών, περιοδικών και εποχικών προτύπων της κατανάλωσης ηλεκτρικής ενέργειας.


Ακολουθεί η ανάπτυξη και εκπαίδευση διαφορετικών μοντέλων πρόβλεψης, τα οποία μπορεί να προέρχονται από στατιστικές προσεγγίσεις, αλγορίθμους μηχανικής μάθησης ή αρχιτεκτονικές βαθιάς μάθησης. Η διαδικασία περιλαμβάνει την επιλογή κατάλληλων υπερπαραμέτρων, τη βελτιστοποίηση της απόδοσης των μοντέλων και την αποφυγή υπερπροσαρμογής μέσω διαδικασιών χρονικής επικύρωσης που διατηρούν τη χρονική ακολουθία των δεδομένων και αποτρέπουν τη διαρροή πληροφορίας (data leakage).

Η τελική αξιολόγηση πραγματοποιείται σε ανεξάρτητα δεδομένα που δεν χρησιμοποιήθηκαν κατά την ανάπτυξη των μοντέλων, με χρήση κατάλληλων δεικτών αξιολόγησης της προγνωστικής απόδοσης, ώστε να επιτευχθεί αντικειμενική σύγκριση της προγνωστικής τους ικανότητας.

Τέλος, η ανάλυση των αποτελεσμάτων δεν περιορίζεται μόνο στη σύγκριση της προγνωστικής ακρίβειας, αλλά επεκτείνεται και στην ερμηνεία της συμπεριφοράς των

μοντέλων, στην αξιολόγηση της συμβολής των επιμέρους χαρακτηριστικών, καθώς και στην εκτίμηση της καταλληλότητας τους για πραγματικές εφαρμογές διαχείρισης ενεργειακών συστημάτων.

Ενδεικτική ροή ανάπτυξης μοντέλου πρόβλεψης ενεργειακής ζήτησης



Σχήμα 2. Ενδεικτική ροή ανάπτυξης, επικύρωσης και αξιοποίησης του μοντέλου πρόβλεψης.

1.10. Σκοπός και επιμέρους στόχοι

Σκοπός της παρούσας εργασίας είναι η ανάπτυξη και αξιολόγηση ενός συστηματικού πλαισίου βραχυπρόθεσμης πρόβλεψης της ωριαίας ηλεκτρικής ζήτησης σε λιμενικές εγκαταστάσεις με τη χρήση τεχνικών μηχανικής μάθησης. Το προτεινόμενο πλαίσιο καλύπτει όλα τα βασικά στάδια της διαδικασίας πρόβλεψης, από τον ορισμό του προβλήματος και την προεπεξεργασία των δεδομένων έως την ανάπτυξη, εκπαίδευση και συγκριτική αξιολόγηση διαφορετικών μοντέλων σύμφωνα με τις αρχές της αναπαραγωγιμότητας και της ορθής αξιολόγησης χρονοσειρών. Η βιβλιογραφία δείχνει ότι η σχετική απόδοση εξαρτάται από το μέγεθος του συνόλου δεδομένων, τη χρονική ανάλυση, την ποιότητα των επιχειρησιακών δεδομένων και το πρωτόκολλο αξιολόγησης (Akhtar et al., 2023; Guo et al., 2021; Hou et al., 2022). Παράλληλα, επιδιώκεται η διερεύνηση της καταλληλότητας των εξεταζόμενων προσεγγίσεων για εφαρμογές βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου σε πραγματικές λιμενικές ενεργειακές υποδομές.

Η εργασία δεν προϋποθέτει την υπεροχή κάποιας συγκεκριμένης οικογένειας μοντέλων, αλλά υιοθετεί συγκριτική προσέγγιση μεταξύ γραμμικών, δενδρικών και νευρωνικών μεθόδων. Η σχετική απόδοση των μοντέλων αξιολογείται υπό κοινές συνθήκες εκπαίδευσης και ελέγχου, ώστε η επιλογή τους να βασίζεται στην πραγματική προγνωστική τους ικανότητα και όχι στην πολυπλοκότητα της αρχιτεκτονικής τους.

Οι επιμέρους στόχοι της εργασίας είναι οι ακόλουθοι:

- Να οριστούν με σαφήνεια η μεταβλητή-στόχος, η χρονική ανάλυση, ο ορίζοντας πρόβλεψης και το πρωτόκολλο αξιολόγησης. Να αποτυπωθούν οι βασικοί παράγοντες που επηρεάζουν τη μεταβολή του ηλεκτρικού φορτίου, συμπεριλαμβανομένων χρονικών, μετεωρολογικών και, εφόσον είναι διαθέσιμες, επιχειρησιακών μεταβλητών.
- Να αξιολογηθεί η ποιότητα, η πληρότητα και η χρονική συνέπεια των διαθέσιμων δεδομένων και να εφαρμοστεί κατάλληλη διαδικασία καθαρισμού και προεπεξεργασίας.
- Να κατασκευαστούν χαρακτηριστικά βασισμένα στο ιστορικό φορτίο και στις διαθέσιμες εξωγενείς μεταβλητές με στόχο τη βελτίωση της προγνωστικής ικανότητας των μοντέλων. Να αναπτυχθούν μοντέλα μηχανικής μάθησης (Γραμμική Παλινδρόμηση, Random Forest, XGBoost και LSTM) υπό ενιαίο πλαίσιο εκπαίδευσης και αξιολόγησης, λαμβάνοντας υπόψη τις ιδιαίτερες απαιτήσεις και τα χαρακτηριστικά κάθε μοντέλου.
- Να εφαρμοστούν διαδικασίες εκπαίδευσης και επικύρωσης κατάλληλες για χρονοσειρές, αποφεύγοντας τη διαρροή πληροφορίας από το μέλλον προς το παρελθόν.
- Να διερευνηθεί πειραματικά η επίδραση της επιλογής χαρακτηριστικών, της αρχιτεκτονικής και των υπερπαραμέτρων στην προγνωστική απόδοση των μοντέλων.
- Να αξιολογηθεί και να συγκριθεί η προγνωστική ικανότητα των εξεταζόμενων μοντέλων με τη χρήση καθιερωμένων δεικτών αξιολόγησης.
- Να ερμηνευθεί η συμβολή των επιμέρους χαρακτηριστικών στην προγνωστική απόδοση των τελικών μοντέλων μέσω τεχνικών ερμηνείας χαρακτηριστικών, όπως η ανάλυση σημαντικότητας μέσω τυχαίας αναδιάταξης (permutation importance), όπου αυτή είναι εφαρμόσιμη.
- Να εξαχθούν συμπεράσματα σχετικά με την καταλληλότητα των εξεταζόμενων μεθόδων για εφαρμογές βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου σε λιμενικές εγκαταστάσεις.

1.11. Ερευνητικά ερωτήματα

1. Ποιο από τα εξεταζόμενα μοντέλα (Γραμμική Παλινδρόμηση, Random Forest, XGBoost ή LSTM) επιτυγχάνει την υψηλότερη προγνωστική απόδοση για βραχυπρόθεσμη πρόβλεψη της ωριαίας ηλεκτρικής ζήτησης του λιμένα;
2. Παρέχουν οι διαθέσιμες μετεωρολογικές και ημερολογιακές μεταβλητές πρόσθετη πληροφορία για την πρόβλεψη του ηλεκτρικού φορτίου;
3. Ποια χαρακτηριστικά παρουσιάζουν τη μεγαλύτερη συμβολή στην πρόβλεψη του ηλεκτρικού φορτίου σύμφωνα με τις εφαρμοζόμενες τεχνικές ερμηνείας;
4. Είναι οι τεχνικές βαθιάς μάθησης σε θέση να υπερέχουν των κλασικών μοντέλων μηχανικής μάθησης στο συγκεκριμένο σύνολο δεδομένων;

1.12. Αναμενόμενη συμβολή της εργασίας

Η παρούσα εργασία επιδιώκει να συμβάλει στην εφαρμογή τεχνικών μηχανικής μάθησης για τη βραχυπρόθεσμη πρόβλεψη της ηλεκτρικής ζήτησης σε λιμενικές εγκαταστάσεις, έναν τομέα στον οποίο η διαθέσιμη βιβλιογραφία παραμένει περιορισμένη σε σύγκριση με άλλες εφαρμογές πρόβλεψης ηλεκτρικού φορτίου. Η ιδιαιτερότητα του λιμενικού περιβάλλοντος, το οποίο παρουσιάζει σύνθετα πρότυπα ηλεκτρικής ζήτησης, καθιστά αναγκαία την αξιολόγηση των μοντέλων σε πραγματικά δεδομένα κατανάλωσης από λιμενικές εγκαταστάσεις.

Σε μεθοδολογικό επίπεδο, η εργασία προτείνει ένα συνεκτικό πλαίσιο ανάπτυξης και συγκριτικής αξιολόγησης μοντέλων βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου. Το πλαίσιο περιλαμβάνει την προεπεξεργασία των δεδομένων, την κατασκευή κατάλληλων χαρακτηριστικών, την ανάπτυξη μοντέλων Γραμμικής Παλινδρόμησης, Random Forest, XGBoost και LSTM, καθώς και την αξιολόγησή τους με διαδικασίες κατάλληλες για χρονοσειρές, ώστε να διασφαλίζεται η μεθοδολογικά συνεπής σύγκριση της προγνωστικής τους απόδοσης και η αποφυγή διαρροής πληροφορίας.

Η κύρια επιστημονική συμβολή της εργασίας έγκειται στη συγκριτική αξιολόγηση κλασικών μοντέλων μηχανικής μάθησης και μοντέλου βαθιάς μάθησης για την πρόβλεψη της ωριαίας ηλεκτρικής ζήτησης του Νοτίου Λιμένα Πατρών, καθώς και στη διερεύνηση της συμβολής των επιμέρους χαρακτηριστικών στην προγνωστική διαδικασία μέσω τεχνικών ερμηνείας χαρακτηριστικών.

Σε πρακτικό επίπεδο, τα αποτελέσματα της εργασίας μπορούν να υποστηρίξουν τη λήψη αποφάσεων που σχετίζονται με τη διαχείριση της ηλεκτρικής ενέργειας στις λιμενικές εγκαταστάσεις, παρέχοντας τεκμηριωμένη αξιολόγηση των εξεταζόμενων προσεγγίσεων πρόβλεψης και αναδεικνύοντας τη συμβολή των σημαντικότερων χαρακτηριστικών στη διαμόρφωση των προβλέψεων. Παράλληλα, η εργασία αναδεικνύει τις δυνατότητες αλλά και τους περιορισμούς της εφαρμογής τεχνικών μηχανικής μάθησης σε πραγματικά λιμενικά δεδομένα, παρέχοντας χρήσιμη βάση για μελλοντική έρευνα και περαιτέρω ανάπτυξη αντίστοιχων εφαρμογών.

1.13. Δομή της διπλωματικής εργασίας

Η παρούσα διπλωματική εργασία οργανώνεται σε έξι κεφάλαια. Το Κεφάλαιο 1 εισάγει το αντικείμενο της έρευνας, παρουσιάζει το πλαίσιο του προβλήματος, τεκμηριώνει τη σημασία της βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου στους λιμένες και διατυπώνει τον σκοπό, τους στόχους και τα ερευνητικά ερωτήματα της εργασίας. Το Κεφάλαιο 2 παρουσιάζει το θεωρητικό υπόβαθρο και την ανασκόπηση της σχετικής βιβλιογραφίας, καλύπτοντας τις βασικές έννοιες της πρόβλεψης ηλεκτρικού φορτίου, τους παράγοντες που επηρεάζουν τη ζήτηση, τις κυριότερες μεθοδολογικές προσεγγίσεις και τα ευρήματα της σύγχρονης ερευνητικής δραστηριότητας.

Το Κεφάλαιο 3 περιγράφει την περίπτωση μελέτης, τα χρησιμοποιούμενα δεδομένα, τη διαδικασία προεπεξεργασίας και τη διερευνητική ανάλυση των δεδομένων. Το Κεφάλαιο 4 παρουσιάζει τη μεθοδολογία που ακολουθήθηκε για την ανάπτυξη, την εκπαίδευση και την αξιολόγηση των μοντέλων πρόβλεψης. Στο Κεφάλαιο 5 παρουσιάζονται τα πειραματικά αποτελέσματα, η συγκριτική αξιολόγηση της απόδοσης των εξεταζόμενων μοντέλων, η ερμηνεία των ευρημάτων και η σύγκρισή τους με τα αντίστοιχα ευρήματα της διεθνούς βιβλιογραφίας. Τέλος, το Κεφάλαιο 6 συνοψίζει τα βασικά συμπεράσματα της έρευνας,

αναδεικνύει τους περιορισμούς της μελέτης και διατυπώνει προτάσεις για μελλοντική έρευνα.

2. ΚΕΦΑΛΑΙΟ 2 — ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ ΚΑΙ ΜΕΘΟΔΟΛΟΓΙΕΣ ΠΡΟΒΛΕΨΗΣ

2.1. Η έννοια και χαρακτηριστικά της χρονοσειράς

2.1.1. Η έννοια της χρονοσειράς

Μια χρονοσειρά ορίζεται ως ένα σύνολο παρατηρήσεων $\{y_t\}$, όπου κάθε παρατήρηση καταγράφεται σε μια συγκεκριμένη χρονική στιγμή t .

Στην περίπτωση των χρονοσειρών διακριτού χρόνου, οι χρονικές στιγμές ανήκουν σε ένα διακριτό σύνολο, συνήθως ισαπέχον, όπως όταν οι μετρήσεις πραγματοποιούνται ανά ώρα, ημέρα ή μήνα. Αντίθετα, στις χρονοσειρές συνεχούς χρόνου οι παρατηρήσεις θεωρητικά ορίζονται για κάθε χρονική στιγμή εντός ενός συνεχούς χρονικού διαστήματος. Οι χρονοσειρές μπορούν επίσης να διακριθούν σε ντετερμινιστικές και στοχαστικές. Στις ντετερμινιστικές χρονοσειρές η εξέλιξη των παρατηρήσεων περιγράφεται πλήρως από μία καθορισμένη μαθηματική σχέση, χωρίς την παρουσία τυχαίας μεταβλητότητας. Αντίθετα, στις στοχαστικές χρονοσειρές οι παρατηρήσεις επηρεάζονται από τυχαίους παράγοντες, με αποτέλεσμα η μελλοντική εξέλιξη της χρονοσειράς να μην μπορεί να προβλεφθεί με απόλυτη βεβαιότητα (Brockwell & Davis, 2016). Στην πράξη, οι περισσότερες πραγματικές χρονοσειρές — και ειδικότερα το ηλεκτρικό φορτίο — μοντελοποιούνται ως στοχαστικές χρονοσειρές διακριτού χρόνου.

2.1.2. Αποσύνθεση της χρονοσειράς σε συνιστώσες

Η αποσύνθεση (decomposition) αποτελεί βασική τεχνική ανάλυσης χρονοσειρών, καθώς διαχωρίζει μια χρονοσειρά στις επιμέρους συνιστώσες που διαμορφώνουν τη συνολική της συμπεριφορά. Οι κυριότερες συνιστώσες είναι το επίπεδο (level), η τάση (trend), η εποχικότητα (seasonality), οι κυκλικές μεταβολές (cyclical variation) και η υπολειμματική ή τυχαία συνιστώσα (residual). Η ανάλυση των συνιστωσών αυτών διευκολύνει την κατανόηση της δομής μιας χρονοσειράς και την επιλογή κατάλληλων μεθόδων πρόβλεψης (Hyndman & Athanasopoulos, 2021).

Η αποσύνθεση μπορεί να πραγματοποιηθεί με προσθετικό ή πολλαπλασιαστικό μοντέλο, ανάλογα με το αν η εποχική διακύμανση παραμένει σταθερή ή μεταβάλλεται ανάλογα με το επίπεδο της χρονοσειράς:

Προσθετικό μοντέλο:

$$y_t = T_t + S_t + R_t$$

Πολλαπλασιαστικό μοντέλο:

$$y_t = T_t \times S_t \times R_t$$

Όπου T_t : η συνιστώσα της τάσης (Trend), S_t : η εποχική συνιστώσα (Seasonality), R_t : η υπολειμματική ή τυχαία συνιστώσα (Residual/Random).

Μία από τις πλέον διαδεδομένες σύγχρονες μεθόδους αποσύνθεσης είναι η STL (Seasonal-Trend Decomposition using LOESS), η οποία βασίζεται σε τοπική παλινδρόμηση (LOESS)

και παρουσιάζει αυξημένη ανθεκτικότητα σε ακραίες τιμές και μεταβαλλόμενα εποχικά πρότυπα (Cleveland et al., 1990). Για χρονοσειρές με πολλαπλές εποχικότητες, όπως οι ωριαίες ενεργειακές χρονοσειρές, έχει προταθεί η επέκταση MSTL, η οποία διατηρεί τα πλεονεκτήματα της STL ενώ υποστηρίζει την ταυτόχρονη μοντελοποίηση πολλαπλών εποχικών κύκλων (Bandara et al., 2025).

Παρότι τα σύγχρονα μοντέλα μηχανικής μάθησης και βαθιάς μάθησης μπορούν να μάθουν απευθείας τα χαρακτηριστικά μιας χρονοσειράς, η αποσύνθεση εξακολουθεί να χρησιμοποιείται τόσο ως εργαλείο διερευνητικής ανάλυσης όσο και ως στάδιο προεπεξεργασίας σε υβριδικά μοντέλα, όπου διαφορετικές συνιστώσες προβλέπονται από εξειδικευμένους αλγορίθμους πριν συνδυαστούν στην τελική πρόβλεψη (Zhang, 2003; Ma et al., 2025).

2.1.3. Σημασία της πρόβλεψης ηλεκτρικού φορτίου

Η πρόβλεψη ηλεκτρικού φορτίου (Electricity Load Forecasting – ELF) αποτελεί επιμέρους αντικείμενο της ευρύτερης ενεργειακής πρόβλεψης (Energy Forecasting – EF) και αναφέρεται στη διαδικασία εκτίμησης της μελλοντικής ζήτησης ηλεκτρικής ενέργειας σε διαφορετικούς χρονικούς ορίζοντες και τομείς κατανάλωσης. Στο πλαίσιο της ενεργειακής πρόβλεψης, η ELF συμβάλλει στην εκτίμηση των μελλοντικών τάσεων κατανάλωσης, παραγωγής και διανομής ηλεκτρικής ενέργειας, υποστηρίζοντας τον σχεδιασμό και τη λειτουργία των ενεργειακών συστημάτων (Mystakidis et al., 2024; Hong & Fan, 2016). Η ακριβής πρόβλεψη της ζήτησης ηλεκτρικής ενέργειας αποτελεί θεμελιώδη προϋπόθεση για την ασφαλή, αξιόπιστη και αποδοτική λειτουργία των σύγχρονων συστημάτων ηλεκτρικής ενέργειας. Η διατήρηση της ισορροπίας μεταξύ παραγωγής και ζήτησης, η ενίσχυση της αξιοπιστίας και της ευστάθειας του δικτύου, καθώς και η αποτελεσματική αξιοποίηση των διαθέσιμων ενεργειακών πόρων εξαρτώνται σε σημαντικό βαθμό από την ακρίβεια των προβλέψεων (Misiurek et al., 2025; Klyuev et al., 2022).

Η πρόβλεψη ηλεκτρικού φορτίου υποστηρίζει ένα ευρύ φάσμα επιχειρησιακών και στρατηγικών αποφάσεων, όπως ο προγραμματισμός παραγωγής, ο προγραμματισμός λειτουργίας μονάδων παραγωγής (unit commitment), η οικονομική κατανομή φορτίου (economic dispatch), η διαχείριση ενεργειακών πόρων, ο σχεδιασμός δικτύων, ο προγραμματισμός προμήθειας καυσίμων, η λειτουργία συστημάτων αποθήκευσης ενέργειας και η ενσωμάτωση ανανεώσιμων πηγών ενέργειας (Chandrasekaran & Paramasivan, 2025; Hong & Fan, 2016).

Η σημασία της πρόβλεψης ηλεκτρικού φορτίου έχει ενισχυθεί περαιτέρω με την ανάπτυξη των έξυπνων δικτύων, των αποκεντρωμένων ενεργειακών πόρων και της αυξανόμενης διείσδυσης ανανεώσιμων πηγών ενέργειας. Οι εξελίξεις αυτές αυξάνουν την πολυπλοκότητα της λειτουργίας των ενεργειακών συστημάτων και καθιστούν τις αξιόπιστες προβλέψεις απαραίτητες για τη διαχείριση της ζήτησης, τη διατήρηση της ευστάθειας του δικτύου και τη βέλτιστη αξιοποίηση των διαθέσιμων ενεργειακών πόρων (Mystakidis et al., 2024; Hasan et al., 2025).

Η ακρίβεια των προβλέψεων επηρεάζει άμεσα τόσο την επιχειρησιακή αξιοπιστία όσο και το οικονομικό κόστος λειτουργίας των ενεργειακών συστημάτων. Η υποεκτίμηση της ζήτησης μπορεί να οδηγήσει σε ανεπαρκή κάλυψη του φορτίου και στην ανάγκη ενεργοποίησης δαπανηρών εφεδρικών μηχανισμών, ενώ η υπερεκτίμηση συνεπάγεται πλεονάζουσα παραγωγή, αναποτελεσματική αξιοποίηση των διαθέσιμων πόρων και αυξημένο λειτουργικό κόστος (Bou Nassif et al., 2021; Candela Esclapez et al., 2022; Misiurek et al., 2025).

Συνεπώς, η πρόβλεψη ηλεκτρικού φορτίου δεν αποτελεί απλώς διαδικασία εκτίμησης της μελλοντικής ζήτησης, αλλά βασικό εργαλείο υποστήριξης αποφάσεων για τον σχεδιασμό,

τη λειτουργία και τη βελτιστοποίηση των σύγχρονων ενεργειακών συστημάτων. Η σημασία της είναι ιδιαίτερα εμφανής στο λιμενικό περιβάλλον, όπου η κατανάλωση ηλεκτρικής ενέργειας επηρεάζεται από την αλληλεπίδραση πολλαπλών και ετερογενών δραστηριοτήτων, όπως οι λιμενικές εγκαταστάσεις, ο εξοπλισμός φορτοεκφόρτωσης και οι νέες εφαρμογές εξηλεκτρισμού, συμπεριλαμβανομένης της ηλεκτροδότησης πλοίων από την ξηρά (Onshore Power Supply – OPS). Για τον λόγο αυτό, η ανάπτυξη αξιόπιστων μοντέλων βραχυπρόθεσμης πρόβλεψης αποτελεί σημαντικό εργαλείο για την αποδοτικότερη διαχείριση της ενέργειας και την υποστήριξη της ενεργειακής μετάβασης των σύγχρονων λιμένων (Acciaro et al., 2014; Molavi et al., 2019).

2.1.4. Χρονικοί ορίζοντες πρόβλεψης (forecasting horizons)

Η πρόβλεψη ηλεκτρικού φορτίου διακρίνεται συνήθως σε τέσσερις βασικές κατηγορίες ανάλογα με τον χρονικό ορίζοντα πρόβλεψης (forecasting horizon): την πολύ βραχυπρόθεσμη (Very Short-Term Load Forecasting – VSTLF), τη βραχυπρόθεσμη (Short-Term Load Forecasting – STLF), τη μεσοπρόθεσμη (Medium-Term Load Forecasting – MTLF) και τη μακροπρόθεσμη πρόβλεψη (Long-Term Load Forecasting – LTLF). Παρότι παρατηρούνται μικρές διαφοροποιήσεις στα ακριβή χρονικά όρια μεταξύ διαφορετικών μελετών, υπάρχει ευρεία συμφωνία ότι κάθε κατηγορία εξυπηρετεί διαφορετικούς επιχειρησιακούς και σχεδιαστικούς στόχους. Ως εκ τούτου, ο χρονικός ορίζοντας πρόβλεψης επιλέγεται ανάλογα με τον σκοπό της πρόβλεψης και καθορίζει τις διαθέσιμες εξωγενείς μεταβλητές, τη μορφή της εξόδου και, σε σημαντικό βαθμό, την καταλληλότητα των χρησιμοποιούμενων μεθόδων πρόβλεψης (Chandrasekaran & Paramasivan, 2025; Mystakidis et al., 2024; Nti et al., 2020).

Η πολύ βραχυπρόθεσμη πρόβλεψη (VSTLF) αφορά συνήθως χρονικούς ορίζοντες από λίγα λεπτά έως περίπου μία ώρα και χρησιμοποιείται κυρίως για λειτουργίες πραγματικού χρόνου, όπως η συνεχής παρακολούθηση του ηλεκτρικού συστήματος, ο έλεγχος λειτουργίας σε πραγματικό χρόνο και η άμεση εξισορρόπηση παραγωγής και ζήτησης (Chandrasekaran & Paramasivan, 2025; Mystakidis et al., 2024; Nti et al., 2020).

Η βραχυπρόθεσμη πρόβλεψη (STLF) συνήθως καλύπτει χρονικούς ορίζοντες από μία ώρα έως μερικές ημέρες ή και μία εβδομάδα. Αποτελεί τον σημαντικότερο χρονικό ορίζοντα για την καθημερινή λειτουργία των συστημάτων ηλεκτρικής ενέργειας, καθώς υποστηρίζει τον βραχυπρόθεσμο επιχειρησιακό σχεδιασμό και τη λήψη λειτουργικών αποφάσεων, με τον προγραμματισμό λειτουργίας των μονάδων παραγωγής (Unit dispatching), τη διαχείριση της ζήτησης (Demand Response), την εξισορρόπηση των διαθέσιμων ενεργειακών πόρων (Resource Balancing), τον προγραμματισμό της προμήθειας ηλεκτρικής ενέργειας (Energy Purchasing) και τη συνολική ενεργειακή διαχείριση (Energy management) (Azeem et al., 2021; Chandrasekaran & Paramasivan, 2025; Nti et al., 2020). Παράλληλα, η βελτίωση της ακρίβειας των προβλέψεων συμβάλλει στη μείωση του λειτουργικού κόστους και του επιχειρησιακού κινδύνου, στη βελτίωση του προγραμματισμού και στην ενίσχυση της αξιοπιστίας των ενεργειακών συστημάτων (Azeem et al., 2021; Dong et al., 2025). Επιπλέον, η STLF είναι καίριας σημασίας για τον ενεργειακό σχεδιασμό περιφερειακών ενεργειακών συστημάτων, μικροδικτύων (microgrids), μεγάλων καταναλωτών ηλεκτρικής ενέργειας, εγκαταστάσεων υποδομών και βιομηχανικών μονάδων (Misiurek et al., 2025). Η μεσοπρόθεσμη πρόβλεψη εκτείνεται συνήθως από μερικές εβδομάδες έως περίπου ένα έτος και χρησιμοποιείται κυρίως για τον προγραμματισμό συντήρησης, τον προγραμματισμό καυσίμων, την πρόβλεψη εποχικής ζήτησης, και γενικά τον επιχειρησιακό και οικονομικό σχεδιασμό των συστημάτων ηλεκτρικής ενέργειας (Azeem et al., 2021;

Chandrasekaran & Paramasivan, 2025; Nti et al., 2020). Αντίστοιχα, η μακροπρόθεσμη πρόβλεψη αφορά χρονικούς ορίζοντες μεγαλύτερους του ενός έτους και χρησιμοποιείται για στρατηγικές αποφάσεις, όπως ο σχεδιασμός νέων μονάδων παραγωγής, η ανάπτυξη δικτύων μεταφοράς και διανομής, οι επενδύσεις σε ενεργειακές υποδομές και ο μακροχρόνιος ενεργειακός σχεδιασμός (Chandrasekaran & Paramasivan, 2025; Misiurek et al., 2025; Nti et al., 2020). Επιπλέον, οι ακριβείς μακροπρόθεσμες προβλέψεις διαδραματίζουν καθοριστικό ρόλο στον σχεδιασμό αποτελεσματικών περιβαλλοντικών στρατηγικών όπως η βιομηχανική απανθρακοποίηση (decarbonization), η συμμόρφωση με αυστηρά όρια εκπομπών αερίων ρύπων και η ενσωμάτωση ανανεώσιμων πηγών ενέργειας (Ahmad et al., 2020; Klyuev et al., 2022; Misiurek et al., 2025). Στον Πίνακα 3 δίνεται η σύνδεση του χρονικού ορίζοντα πρόβλεψης, των διεργασιών που η πρόβλεψη εξυπηρετεί και των συνήθων μεταβλητών εισόδου που χρησιμοποιούνται στην πρόβλεψη.

Πίνακας 3. Χρονικοί ορίζοντες πρόβλεψης ηλεκτρικού φορτίου και αντιπροσωπευτικές εφαρμογές και συνήθεις μεταβλητές εισόδου.

Χρονικός ορίζοντας	Ενδεικτική διάρκεια	Ενδεικτικές εφαρμογές	Τυπικές μεταβλητές
Πολύ βραχυπρόθεσμος (VSTLF)	Λεπτά έως ~1 ώρα	Λειτουργία σε πραγματικό χρόνο, εξισορρόπηση φορτίου, διαχείριση συστημάτων αποθήκευσης ενέργειας	Πρόσφατες τιμές φορτίου, μετρήσεις πραγματικού χρόνου (real-time), κατάσταση εξοπλισμού
Βραχυπρόθεσμος (STLF)	1 ώρα έως 7 ημέρες	Προγραμματισμός λειτουργίας μονάδων παραγωγής (Unit Commitment), απόκριση ζήτησης (Demand Response), ενεργειακή διαχείριση, προμήθεια ηλεκτρικής ενέργειας (day-ahead), λειτουργία συστημάτων ηλεκτροδότησης πλοίων από την ξηρά (OPS) και προγραμματισμός λειτουργίας λιμένα	Ιστορικό φορτίο, ημερολογιακές μεταβλητές, πρόγνωση καιρού, λειτουργικά δεδομένα (όπου είναι διαθέσιμα, π.χ. αφίξεις πλοίων)
Μεσοπρόθεσμος (MTLF)	Εβδομάδες έως 1 έτος	Προγραμματισμός συντήρησης, προμήθεια ενέργειας, κατάρτιση προϋπολογισμού	Εποχικότητα, ιστορική ζήτηση, επιχειρησιακοί δείκτες
Μακροπρόθεσμος (LTLF)	>1 έτος	Σχεδιασμός ενεργειακών υποδομών, ανάπτυξη δικτύου, επενδύσεις και εξηλεκτρισμός λιμένων	Δημογραφικά και οικονομικά στοιχεία, σενάρια ανάπτυξης, ενεργειακή πολιτική, ρυθμός εξηλεκτρισμού, προβλέψεις διακίνησης φορτίου

Η παρούσα εργασία εντάσσεται στην κατηγορία της βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου, καθώς εξετάζει την πρόβλεψη της ζήτησης ηλεκτρικής ενέργειας μία

ώρα μπροστά (one-hour-ahead forecasting). Ο συγκεκριμένος χρονικός ορίζοντας είναι σημαντικός για τη λειτουργική διαχείριση ενεργειακών συστημάτων και υποδομών, καθώς υποστηρίζει την έγκαιρη λήψη αποφάσεων σχετικά με τη διαχείριση του φορτίου, των διαθέσιμων ενεργειακών πόρων και της λειτουργίας κρίσιμων εγκαταστάσεων, όπως οι λιμένες.

Συγκεκριμένα, η βραχυχρόνια πρόβλεψη ηλεκτρικού φορτίου (Short-Term Load Forecasting – STLF) στοχεύει στην πρόβλεψη της ζήτησης ηλεκτρικής ενέργειας για ένα μελλοντικό χρονικό διάστημα που κυμαίνεται από λίγες ώρες έως και αρκετές ημέρες. Τα δεδομένα εισόδου ενός μοντέλου STLF περιλαμβάνουν ιστορικά δεδομένα φορτίου (historical load data), καθώς και εξωτερικούς παράγοντες που επηρεάζουν τη ζήτηση (influencing factors), με στόχο την εκμάθηση ενός συνόλου συναρτήσεων αντιστοίχισης (set of mapping functions) μεταξύ των δεδομένων εισόδου και της μεταβλητής εξόδου (Dong et al., 2025).

Αν y_t παριστά τη ζήτηση ηλεκτρικού φορτίου τη χρονική στιγμή t , ο στόχος της STLF είναι η πρόβλεψη της ζήτησης για έναν μελλοντικό χρονικό ορίζοντα h ωρών, η οποία συμβολίζεται ως $\hat{y}_{t+h}$. Γενικά, το πρόβλημα της πρόβλεψης μπορεί να διατυπωθεί ως:

$$\hat{y}_{t+h} = f(y_t, y_{t-1}, \dots, y_{t-n+1}, X_t),$$

όπου $\hat{y}_{t+h}$ είναι το προβλεπόμενο φορτίο τη χρονική στιγμή $t + h$, η f αναπαριστά το μοντέλο πρόβλεψης (στατιστικό, μηχανικής μάθησης ή βαθιάς μάθησης), τα $y_t, y_{t-1}, \dots, y_{t-n+1}$ αποτελούν τις ιστορικές παρατηρήσεις φορτίου για τις προηγούμενες n χρονικές περιόδους, και το X_t περιλαμβάνει τις εξωτερικές μεταβλητές (όπως μετεωρολογικά δεδομένα (weather data), πληροφορίες ημερολογίου (calendar information) κ.ά.) τη χρονική στιγμή t .

2.2. Παράγοντες που επηρεάζουν το ηλεκτρικό φορτίο

Η κατανάλωση ηλεκτρικής ενέργειας επηρεάζεται από ένα ευρύ σύνολο παραγόντων, οι οποίοι παρουσιάζονται στην ακόλουθη ενότητα. Στη βιβλιογραφία οι παράγοντες αυτοί ταξινομούνται συνήθως σε τέσσερις βασικές κατηγορίες: ιστορικές μεταβλητές φορτίου, μετεωρολογικές μεταβλητές, ημερολογιακές μεταβλητές και κοινωνικοοικονομικούς ή συμπεριφορικούς παράγοντες. Η επιλογή των κατάλληλων μεταβλητών εισόδου αποτελεί κρίσιμο στάδιο κατά την ανάπτυξη μοντέλων πρόβλεψης, καθώς επηρεάζει σημαντικά την ακρίβεια και τη δυνατότητα γενίκευσης των μοντέλων. Συνολικά, δεν υπάρχει ένα ενιαίο σύνολο μεταβλητών που να είναι κατάλληλο για όλες τις εφαρμογές πρόβλεψης ηλεκτρικού φορτίου και η επιλογή των εκάστοτε χαρακτηριστικών εξαρτάται από τον χρονικό ορίζοντα πρόβλεψης, το είδος του καταναλωτή, τη διαθεσιμότητα των δεδομένων και τα ιδιαίτερα χαρακτηριστικά του εξεταζόμενου συστήματος. Σε εφαρμογές βραχυπρόθεσμης πρόβλεψης, οι ιστορικές τιμές φορτίου, οι μετεωρολογικές συνθήκες και οι ημερολογιακές μεταβλητές αποτελούν τις κυριότερες κατηγορίες εισόδων που χρησιμοποιούνται στη διεθνή βιβλιογραφία.

2.2.1. Ιστορικά δεδομένα φορτίου

Οι ιστορικές τιμές του ηλεκτρικού φορτίου αποτελούν μία από τις θεμελιώδεις πηγές πληροφορίας για την πρόβλεψη της μελλοντικής ζήτησης ηλεκτρικής ενέργειας. Η διεθνής βιβλιογραφία συγκλίνει ότι η μελλοντική εξέλιξη του φορτίου παρουσιάζει ισχυρή αυτοσυσχέτιση (autocorrelation) και χρονική εξάρτηση από τις προηγούμενες τιμές του,

καθώς η κατανάλωση ηλεκτρικής ενέργειας ακολουθεί επαναλαμβανόμενα ημερήσια, εβδομαδιαία και εποχικά πρότυπα που αντανακλούν τη λειτουργία των ανθρώπινων, εμπορικών και βιομηχανικών δραστηριοτήτων. Κατά συνέπεια, το ιστορικό φορτίο αποτελεί έναν από τους σημαντικότερους προγνωστικούς παράγοντες στα μοντέλα βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου. Για τον λόγο αυτό, οι ιστορικές χρονοσειρές αποτελούν μία από τις σημαντικότερες κατηγορίες μεταβλητών εισόδου στα μοντέλα βραχυπρόθεσμης πρόβλεψης (Azeem et al., 2021; Mystakidis et al., 2024; Dong et al., 2025).

Η ιστορική πληροφορία κατανάλωσης ηλεκτρικής ενέργειας μπορεί να ενσωματωθεί στα μοντέλα είτε μέσω ρητά καθορισμένων χρονικών υστερήσεων (lag variables), όπως το φορτίο της προηγούμενης ώρας, της προηγούμενης ημέρας ή της αντίστοιχης ώρας της προηγούμενης εβδομάδας, είτε μέσω παραγόμενων στατιστικών χαρακτηριστικών, όπως κυλιόμενοι μέσοι όροι και κυλιόμενες τυπικές αποκλίσεις, είτε μέσω διαδοχικών παρατηρήσεων της χρονοσειράς σε ακολουθιακή μορφή, ανάλογα με την επιλεγμένη μεθοδολογία πρόβλεψης. Οι προηγούμενες αυτές παρατηρήσεις επιτρέπουν στα μοντέλα να αξιοποιούν τις χρονικές εξαρτήσεις και τα επαναλαμβανόμενα πρότυπα της χρονοσειράς, ανεξάρτητα από τον τρόπο με τον οποίο αναπαρίστανται στα δεδομένα εισόδου (Mystakidis et al., 2024; Azeem et al., 2021).

2.2.2. Μετεωρολογικές μεταβλητές

Οι μετεωρολογικές συνθήκες αποτελούν μία από τις συνηθέστερα χρησιμοποιούμενες κατηγορίες μεταβλητών στην πρόβλεψη ηλεκτρικού φορτίου. Οι μεταβλητές που χρησιμοποιούνται συχνότερα περιλαμβάνουν τη θερμοκρασία αέρα, τη σχετική υγρασία, την ηλιακή ακτινοβολία, την ταχύτητα και τη διεύθυνση του ανέμου, τη νεφοκάλυψη και τα κατακρημνίσματα. Η επίδρασή τους σχετίζεται κυρίως με τη λειτουργία συστημάτων θέρμανσης, ψύξης και κλιματισμού, γεγονός που επηρεάζει άμεσα τη ζήτηση ηλεκτρικής ενέργειας (Azeem et al., 2021; Mystakidis et al., 2024). Στο λιμενικό περιβάλλον, οι μετεωρολογικές συνθήκες μπορούν επίσης να επηρεάσουν τη λειτουργία υπαίθριου εξοπλισμού, τις ψυκτικές εγκαταστάσεις (reefers) και ορισμένες επιχειρησιακές δραστηριότητες, συμβάλλοντας περαιτέρω στη διαμόρφωση του ηλεκτρικού φορτίου. Σύμφωνα με τις διαθέσιμες ανασκοπήσεις, οι μετεωρολογικές μεταβλητές συγκαταλέγονται στις σημαντικότερες κατηγορίες μεταβλητών εισόδου σε μοντέλα πρόβλεψης, ενώ η ενσωμάτωσή τους συμβάλλει ιδιαίτερα στη βελτίωση της πρόβλεψης κατά τις περιόδους έντονων μεταβολών του φορτίου και στην ακριβέστερη εκτίμηση των αιχμών ζήτησης (Nti et al., 2020; Azeem et al., 2021; Hong & Fan, 2016). Βέβαια, η συμβολή των μετεωρολογικών μεταβλητών στην ακρίβεια της πρόβλεψης εξαρτάται από τα χαρακτηριστικά του υπό μελέτη συστήματος, καθώς η σχέση μεταξύ καιρικών συνθηκών και ηλεκτρικού φορτίου διαφοροποιείται ανάλογα με τον τύπο των καταναλωτών, τις κλιματικές συνθήκες και τα τοπικά χαρακτηριστικά της περιοχής (Azeem et al., 2021; Nti et al., 2020; Hong et al., 2016; Ahmad et al., 2020). Επιπλέον, η σχέση μεταξύ ορισμένων μετεωρολογικών μεταβλητών, κυρίως της θερμοκρασίας, και του ηλεκτρικού φορτίου είναι συχνά μη γραμμική, γεγονός που ευνοεί τη χρήση ευέλικτων μοντέλων μηχανικής μάθησης και βαθιάς μάθησης.

2.2.3. Ημερολογιακές μεταβλητές

Εκτός από τις ιστορικές και τις μετεωρολογικές πληροφορίες, σημαντική θέση στην πρόβλεψη ηλεκτρικού φορτίου κατέχουν οι ημερολογιακές μεταβλητές. Η ώρα της ημέρας, η ημέρα της εβδομάδας, ο μήνας, η εποχή, οι αργίες και άλλες ειδικές ημερομηνίες

χρησιμοποιούνται ευρέως για την περιγραφή της χρονικής περιοδικότητας της κατανάλωσης ηλεκτρικής ενέργειας. Οι μεταβλητές αυτές επιτρέπουν στα μοντέλα να αποτυπώνουν ημερήσια, εβδομαδιαία και εποχικά πρότυπα ζήτησης, τα οποία αντανakλούν τον περιοδικό χαρακτήρα των ανθρώπινων, εμπορικών και παραγωγικών δραστηριοτήτων. Η διάκριση μεταξύ εργάσιμων ημερών, Σαββατοκύριακων, αργιών και άλλων ειδικών ημερών είναι σημαντική, καθώς τα αντίστοιχα προφίλ φορτίου συχνά αποκλίνουν από τα συνήθη ημερήσια και εβδομαδιαία πρότυπα κατανάλωσης, γεγονός που απαιτεί την κατάλληλη αναπαράσταση των χαρακτηριστικών αυτών στα μοντέλα πρόβλεψης. Οι ημερολογιακές μεταβλητές μπορούν να αναπαρασταθούν μέσω κατηγορικών κωδικοποιήσεων, όπως η one-hot κωδικοποίηση, ενώ οι μεταβλητές με εγγενή περιοδικότητα, όπως η ώρα της ημέρας και η ημέρα της εβδομάδας, μπορούν επίσης να κωδικοποιηθούν με κυκλικό τρόπο. Σε κάθε περίπτωση, η αξιοποίηση των ημερολογιακών χαρακτηριστικών στα μοντέλα πρόβλεψης μπορεί να συμβάλει στη βελτίωση της ακρίβειας των προβλέψεων, ιδίως σε περιόδους μη τυπικής λειτουργίας (Azeem et al., 2021; Mystakidis et al., 2024; Chandrasekaran & Paramasivan, 2025).

2.2.4. Κοινωνικοοικονομικοί, συμπεριφορικοί και άλλοι παράγοντες

Στη διεθνή βιβλιογραφία συναντώνται επίσης μεταβλητές που σχετίζονται με κοινωνικοοικονομικούς, λειτουργικούς και συμπεριφορικούς παράγοντες, όπως οι τιμές ηλεκτρικής ενέργειας, οι δείκτες οικονομικής και βιομηχανικής ανάπτυξης, τα χαρακτηριστικά των κτιρίων και η συμπεριφορά των καταναλωτών. Η χρήση των μεταβλητών αυτών εξαρτάται σε μεγάλο βαθμό από τον χρονικό ορίζοντα και το πεδίο εφαρμογής της πρόβλεψης. Οι κοινωνικοοικονομικοί δείκτες αξιοποιούνται κυρίως σε εφαρμογές μεσοπρόθεσμης και μακροπρόθεσμης πρόβλεψης, ενώ χαρακτηριστικά κτιρίων και συμπεριφοράς καταναλωτών χρησιμοποιούνται συχνότερα σε προβλήματα πρόβλεψης σε επίπεδο κτιρίου ή νοικοκυριού. Αντίθετα, στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου οι ιστορικές τιμές φορτίου, οι μετεωρολογικές συνθήκες και οι ημερολογιακές μεταβλητές εξακολουθούν να αποτελούν τις κυριότερες κατηγορίες μεταβλητών εισόδου, ενώ η αξιοποίηση πρόσθετων χαρακτηριστικών εξαρτάται από τη διαθεσιμότητα των δεδομένων και τα ιδιαίτερα χαρακτηριστικά του υπό μελέτη συστήματος (Mystakidis et al., 2024; Azeem et al., 2021; Chandrasekaran & Paramasivan, 2025).

2.2.5. Επιχειρησιακά και ναυτιλιακά δεδομένα

Στις εφαρμογές πρόβλεψης ηλεκτρικού φορτίου σε λιμένες, ιδιαίτερη σημασία έχουν τα επιχειρησιακά και ναυτιλιακά δεδομένα, τα οποία διαφοροποιούν ουσιαστικά το πρόβλημα από τη γενική πρόβλεψη ηλεκτρικού φορτίου. Μεταβλητές όπως οι προγραμματισμένες αφίξεις και αναχωρήσεις πλοίων, οι ώρες ελλιμενισμού, ο αριθμός και ο τύπος των πλοίων, η αναμενόμενη ζήτηση ηλεκτροδότησης από την ξηρά (OPS), η λειτουργία γερανών, η διακίνηση εμπορευματοκιβωτίων (TEU), ο αριθμός των ψυκτικών εμπορευματοκιβωτίων (reefers), οι βάρδιες και η διαθεσιμότητα εξοπλισμού μπορούν να συμβάλουν σημαντικά στη βελτίωση της ακρίβειας των προβλέψεων, όταν είναι διαθέσιμα. Επιπλέον, δεδομένα από το Σύστημα Αυτόματης Αναγνώρισης Πλοίων (AIS) μπορούν να αξιοποιηθούν για την εκτίμηση των χρόνων άφιξης και της αναμενόμενης λιμενικής δραστηριότητας. Η σχετική βιβλιογραφία καταδεικνύει ότι η ενσωμάτωση τέτοιων επιχειρησιακών πληροφοριών μπορεί να βελτιώσει σημαντικά την απόδοση των μοντέλων πρόβλεψης σε λιμενικά περιβάλλοντα (Kim et al., 2023; Micallef et al., 2025; Do Carmo et al., 2026).

2.3. Μέθοδοι πρόβλεψης χρονοσειρών ηλεκτρικού φορτίου

Η πρόβλεψη ηλεκτρικού φορτίου βασίστηκε για πολλές δεκαετίες κυρίως σε στατιστικές μεθόδους, όπως τα μοντέλα παλινδρόμησης, τα αυτοπαλίνδρομα μοντέλα και οι τεχνικές εκθετικής εξομάλυνσης. Παρότι οι μέθοδοι αυτές παρουσιάζουν ικανοποιητική απόδοση σε σχετικά απλά προβλήματα, η αποτελεσματικότητά τους περιορίζεται όταν η ζήτηση χαρακτηρίζεται από έντονες μη γραμμικότητες και σύνθετες αλληλεπιδράσεις μεταξύ πολλών παραγόντων.

Η ανάπτυξη της μηχανικής μάθησης επέτρεψε τη μάθηση σύνθετων προτύπων απευθείας από τα δεδομένα, χωρίς την ανάγκη αυστηρών υποθέσεων για τη μορφή των σχέσεων μεταξύ των μεταβλητών. Για τον λόγο αυτό, οι αλγόριθμοι μηχανικής μάθησης έχουν καθιερωθεί ως βασικές μέθοδοι στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου, παρουσιάζοντας αυξημένη προγνωστική ακρίβεια σε προβλήματα με έντονη μη γραμμικότητα.

Οι συνηθέστερες προσεγγίσεις περιλαμβάνουν γραμμικά μοντέλα παλινδρόμησης, μεθόδους βασισμένες σε δέντρα αποφάσεων και τεχνικές συνόλων (ensemble methods), καθώς και τεχνητά νευρωνικά δίκτυα. Στις επόμενες ενότητες παρουσιάζονται συνοπτικά οι βασικότεροι αλγόριθμοι μηχανικής μάθησης που χρησιμοποιούνται στην πρόβλεψη ηλεκτρικού φορτίου, με έμφαση στη Γραμμική Παλινδρόμηση, το Random Forest, το XGBoost και τα δίκτυα LSTM.

2.3.1. Κλασικές Στατιστικές Μέθοδοι

Οι κλασικές μέθοδοι πρόβλεψης χρονοσειρών περιλαμβάνουν τις τεχνικές εκθετικής εξομάλυνσης (Exponential Smoothing – ETS), όπως οι μέθοδοι Holt και Holt–Winters, καθώς και τα αυτοπαλίνδρομα μοντέλα AR, MA, ARMA, ARIMA και SARIMA. Οι μέθοδοι εκθετικής εξομάλυνσης βασίζονται στην εκτίμηση της στάθμης, της τάσης και της εποχικότητας της χρονοσειράς, ενώ τα αυτοπαλίνδρομα μοντέλα αξιοποιούν τη χρονική εξάρτηση των ιστορικών παρατηρήσεων και, στην περίπτωση των ARIMA/SARIMA, τη διαφοροποίηση για την αντιμετώπιση μη στάσιμων χρονοσειρών (Hyndman & Athanasopoulos, 2021). Οι προσεγγίσεις αυτές είναι απλές, ερμηνεύσιμες και παρουσιάζουν καλή απόδοση σε γραμμικά προβλήματα βραχυπρόθεσμης πρόβλεψης. Ωστόσο, η αποτελεσματικότητά τους περιορίζεται όταν τα δεδομένα εμφανίζουν έντονη μη γραμμικότητα, πολύπλοκες χρονικές εξαρτήσεις ή υψηλή μεταβλητότητα, γεγονός που έχει οδηγήσει στην ευρεία υιοθέτηση μεθόδων μηχανικής μάθησης και βαθιάς μάθησης στην πρόβλεψη ηλεκτρικού φορτίου (Hyndman & Athanasopoulos, 2021; Ugbehe et al., 2025).

2.3.1.1. Naïve και εποχικές γραμμές βάσης

Οι απλές μέθοδοι πρόβλεψης (naïve forecasting) χρησιμοποιούνται ευρέως ως γραμμές βάσης (baseline models) για την αξιολόγηση της πραγματικής συνεισφοράς πιο σύνθετων αλγορίθμων. Η βασική αρχή τους είναι ότι η μελλοντική τιμή προσεγγίζεται είτε από την πιο πρόσφατη διαθέσιμη παρατήρηση είτε από την αντίστοιχη χρονική στιγμή ενός προηγούμενου εποχικού κύκλου. Παρότι οι μέθοδοι αυτές διαθέτουν περιορισμένη προγνωστική ικανότητα, αποτελούν αυστηρά σημεία αναφοράς, καθώς ένα σύνθετο μοντέλο οφείλει να επιτυγχάνει σταθερά καλύτερη απόδοση ώστε να δικαιολογείται η αυξημένη πολυπλοκότητά του (Hyndman & Athanasopoulos, 2021).

Η εποχική Naïve πρόβλεψη (Seasonal Naïve) ορίζεται ως:

$$\hat{y}_{t+h|t} = y_{t+h-m}$$

όπου m είναι η εποχική περίοδος της χρονοσειράς.

Για ωριαία δεδομένα ηλεκτρικού φορτίου χρησιμοποιούνται συχνά $m = 24$, που αντιστοιχεί στην ίδια ώρα της προηγούμενης ημέρας, και $m = 168$, που αντιστοιχεί στην ίδια ώρα της προηγούμενης εβδομάδας. Η βιβλιογραφία αξιοποιεί συστηματικά τις *naïve* προσεγγίσεις ως benchmarks, ακόμη και όταν η τελική σύγκριση αφορά προηγμένους αλγόριθμους μηχανικής μάθησης και βαθιάς μάθησης (Hyndman & Athanasopoulos, 2021; Micallef et al., 2025).

2.3.1.2. Εκθετική εξομάλυνση

Οι μέθοδοι εκθετικής εξομάλυνσης (Exponential Smoothing – ETS) βασίζονται στην ιδέα ότι οι πιο πρόσφατες παρατηρήσεις περιέχουν περισσότερη πληροφορία για το μέλλον και, επομένως, λαμβάνουν μεγαλύτερο βάρος κατά την πρόβλεψη. Οι επεκτάσεις Holt και Holt–Winters επιτρέπουν τη μοντελοποίηση τάσης και εποχικότητας αντίστοιχα, διατηρώντας παράλληλα χαμηλή υπολογιστική πολυπλοκότητα και υψηλή ερμηνευσιμότητα. Τα μοντέλα ETS παραμένουν ιδιαίτερα ανταγωνιστικά σε πολλές εφαρμογές χρονοσειρών και χρησιμοποιούνται συχνά ως ισχυρές στατιστικές γραμμές βάσης, ιδίως όταν οι χρονοσειρές παρουσιάζουν σχετικά σταθερή συμπεριφορά (Hyndman & Athanasopoulos, 2021).

2.3.1.3. ARIMA, SARIMA και SARIMAX

Τα μοντέλα ARIMA (Autoregressive Integrated Moving Average) αποτελούν μία από τις πλέον καθιερωμένες οικογένειες στατιστικών μοντέλων για την πρόβλεψη χρονοσειρών και χρησιμοποιούνται εκτενώς ως σημεία αναφοράς στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου (Hyndman & Athanasopoulos, 2021). Η βασική τους ιδέα είναι ότι οι μελλοντικές τιμές μιας χρονοσειράς μπορούν να περιγραφούν ως γραμμικός συνδυασμός προηγούμενων παρατηρήσεων και προηγούμενων τυχαίων σφαλμάτων, ενώ η εφαρμογή διαφοροποίησης (differencing) επιτρέπει τη μοντελοποίηση μη στάσιμων χρονοσειρών μέσω της απομάκρυνσης της τάσης.

Για χρονοσειρές με έντονη εποχικότητα χρησιμοποιείται η επέκταση SARIMA (Seasonal ARIMA), η οποία εισάγει επιπλέον εποχικούς αυτοπαλίνδρομους και κινητούς όρους, καθώς και εποχική διαφοροποίηση. Όταν απαιτείται η αξιοποίηση εξωγενών μεταβλητών, όπως μετεωρολογικών ή λειτουργικών χαρακτηριστικών, χρησιμοποιείται το SARIMAX, το οποίο επεκτείνει το SARIMA ενσωματώνοντας μεταβλητές εισόδου πέραν της ίδιας της χρονοσειράς. Η γενική μορφή του μοντέλου εκφράζεται ως:

$$\Phi_P(B^m) \phi_p(B) (1 - B)^d (1 - B^m)^D y_t = \Theta_Q(B^m) \theta_q(B) \varepsilon_t + \beta^T x_t$$

όπου B είναι ο τελεστής οπισθοδρόμησης (backshift operator) και $\Phi_P(B^m)$ και $\phi_p(B)$ είναι, αντίστοιχα, τα εποχικά και μη εποχικά αυτοπαλίνδρομα πολυώνυμα, ενώ $\Theta_Q(B^m)$ και $\theta_q(B)$ είναι τα αντίστοιχα πολυώνυμα κινητού μέσου. Οι παράμετροι p, d, q αποτελούν τις μη εποχικές τάξεις του μοντέλου και οι P, D, Q τις αντίστοιχες εποχικές τάξεις με περίοδο m , ενώ ε_t είναι ο στοχαστικός όρος σφάλματος, x_t το διάνυσμα των εξωγενών μεταβλητών και β το αντίστοιχο διάνυσμα συντελεστών.

Παρά τη διαχρονική τους αξία, τα μοντέλα της οικογένειας ARIMA βασίζονται στη γραμμική περιγραφή των σχέσεων μεταξύ των μεταβλητών και προϋποθέτουν ότι η χρονική σειρά μπορεί να καταστεί στάσιμη μέσω διαφοροποίησης. Ως αποτέλεσμα, η ικανότητά τους να αποτυπώνουν πολύπλοκες μη γραμμικές αλληλεπιδράσεις και απότομες μεταβολές του ηλεκτρικού φορτίου είναι περιορισμένη. Για τον λόγο αυτό, στις σύγχρονες εφαρμογές βραχυπρόθεσμης πρόβλεψης χρησιμοποιούνται κυρίως ως ισχυρά στατιστικά σημεία

αναφοράς ή σε συνδυασμό με πιο ευέλικτες μεθόδους μηχανικής μάθησης και βαθιάς μάθησης (Hong & Fan, 2016; Hyndman & Athanasopoulos, 2021; Mystakidis et al., 2024).

2.3.2. Μέθοδοι Μηχανικής Μάθησης

Η μηχανική μάθηση (Machine Learning – ML) αποτελεί υποπεδίο της τεχνητής νοημοσύνης, το οποίο ασχολείται με την ανάπτυξη αλγορίθμων που επιτρέπουν στα υπολογιστικά συστήματα να μαθαίνουν από δεδομένα και να βελτιώνουν την απόδοσή τους σε συγκεκριμένες εργασίες χωρίς να έχουν προγραμματιστεί ρητά για κάθε πιθανή περίπτωση. Ο όρος εισήχθη από τον Arthur Samuel, ο οποίος περιέγραψε τη μηχανική μάθηση ως το πεδίο που δίνει στους υπολογιστές «τη δυνατότητα να μαθαίνουν χωρίς να έχουν προγραμματιστεί ρητά» (Samuel, 1959).

Έναν από τους πλέον καθιερωμένους τυπικούς ορισμούς διατύπωσε ο Mitchell (1997), σύμφωνα με τον οποίο ένα πρόγραμμα υπολογιστή θεωρείται ότι μαθαίνει από εμπειρία E ως προς μία κλάση εργασιών T και ένα μέτρο απόδοσης P , εφόσον η απόδοσή του στις εργασίες της κλάσης T , όπως αυτή μετράται από το P , βελτιώνεται με την αύξηση της εμπειρίας E . Ο ορισμός αυτός υπογραμμίζει ότι η μάθηση μπορεί να αξιολογηθεί αντικειμενικά ως μετρήσιμη βελτίωση της απόδοσης ενός συστήματος μέσω της εμπειρίας και εξακολουθεί να αποτελεί το εννοιολογικό θεμέλιο της σύγχρονης μηχανικής μάθησης. Σύγχρονα εγχειρίδια προσεγγίζουν τη μηχανική μάθηση ως τη διαδικασία ανάπτυξης μοντέλων που μαθαίνουν πρότυπα απευθείας από τα δεδομένα και βελτιστοποιούν την απόδοσή τους ως προς μία αντικειμενική συνάρτηση, με στόχο την αξιόπιστη γενίκευση σε νέα, άγνωστα δεδομένα (Géron, 2019; Alpaydm, 2020). Σε αντίθεση με πολλές κλασικές στατιστικές μεθόδους, οι αλγόριθμοι μηχανικής μάθησης δεν απαιτούν την εκ των προτέρων διατύπωση ενός συγκεκριμένου λειτουργικού μοντέλου για τις σχέσεις μεταξύ των μεταβλητών, αλλά τις προσεγγίζουν απευθείας από τα διαθέσιμα δεδομένα. Η ιδιότητα αυτή τους επιτρέπει να αποτυπώνουν πολύπλοκες και μη γραμμικές αλληλεπιδράσεις μεταξύ μεγάλου αριθμού χαρακτηριστικών, γεγονός που έχει οδηγήσει στην ευρεία υιοθέτησή τους στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου, όπου η ζήτηση επηρεάζεται ταυτόχρονα από ιστορικές τιμές φορτίου, μετεωρολογικές συνθήκες, ημερολογιακές μεταβλητές και επιχειρησιακούς παράγοντες (Hong & Fan, 2016; Mystakidis et al., 2024; Ugbehe et al., 2025).

Η πρόβλεψη ηλεκτρικού φορτίου διατυπώνεται συνήθως ως πρόβλημα επιβλεπόμενης μάθησης (supervised learning), στο οποίο ο αλγόριθμος εκπαιδεύεται χρησιμοποιώντας ζεύγη δεδομένων εισόδου και γνωστών τιμών εξόδου. Οι μεταβλητές εισόδου, οι οποίες στη βιβλιογραφία αναφέρονται ως χαρακτηριστικά (features), μπορεί να περιλαμβάνουν ιστορικές τιμές φορτίου, μετεωρολογικές μεταβλητές, ημερολογιακές πληροφορίες και άλλους εξωγενείς παράγοντες, ενώ η μεταβλητή εξόδου (target variable) αντιστοιχεί στη μελλοντική τιμή του ηλεκτρικού φορτίου που πρόκειται να προβλεφθεί.

Δεδομένου ότι η μεταβλητή στόχος είναι συνεχής αριθμητική ποσότητα, η βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου αποτελεί πρόβλημα παλινδρόμησης (regression) και όχι ταξινόμησης. Κατά τη διαδικασία εκπαίδευσης, ο αλγόριθμος προσαρμόζει τις παραμέτρους του ώστε να μάθει τη σχέση μεταξύ των χαρακτηριστικών και της μεταβλητής στόχου, ελαχιστοποιώντας το σφάλμα πρόβλεψης στο σύνολο εκπαίδευσης. Το εκπαιδευμένο μοντέλο χρησιμοποιείται στη συνέχεια για την παραγωγή προβλέψεων σε νέα δεδομένα που δεν είχαν χρησιμοποιηθεί κατά την εκπαίδευση, με σκοπό την αξιόπιστη γενίκευση της γνώσης που απέκτησε.

Άλλα παραδείγματα μηχανικής μάθησης περιλαμβάνουν τη μη επιβλεπόμενη (unsupervised), την ημι-επιβλεπόμενη (semi-supervised) και την ενισχυτική μάθηση (reinforcement learning). Ωστόσο, η βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου

διατυπώνεται στη συντριπτική πλειονότητα των εφαρμογών ως πρόβλημα επιβλεπόμενης παλινδρόμησης, γεγονός που αποτελεί και το αντικείμενο της παρούσας εργασίας (Géron, 2019; Alpaydin, 2020).

2.3.2.1. Γραμμική Παλινδρόμηση (Linear Regression)

Η γραμμική παλινδρόμηση (Linear Regression) αποτελεί μία από τις θεμελιώδεις μεθόδους επιβλεπόμενης μάθησης για προβλήματα παλινδρόμησης και χρησιμοποιείται ευρέως τόσο ως μοντέλο πρόβλεψης όσο και ως σημείο αναφοράς (baseline model) για την αξιολόγηση πιο σύνθετων αλγορίθμων. Στόχος της είναι η μοντελοποίηση της σχέσης μεταξύ μίας συνεχούς μεταβλητής στόχου και ενός συνόλου μεταβλητών εισόδου, υποθέτοντας ότι η σχέση αυτή μπορεί να προσεγγιστεί από μία γραμμική συνάρτηση (Hyndman & Athanasopoulos, 2021; Géron, 2019).

Η γενική μορφή του μοντέλου πολλαπλής γραμμικής παλινδρόμησης δίνεται από:

$$\hat{y}_t = \beta_0 + \sum_{j=1}^p \beta_j x_{t,j}$$

όπου $\hat{y}_t$ είναι η προβλεπόμενη τιμή της μεταβλητής στόχου, β_0 η σταθερά του μοντέλου, β_j οι συντελεστές παλινδρόμησης των μεταβλητών εισόδου και $x_{t,j}$ οι αντίστοιχες μεταβλητές εισόδου.

Οι συντελεστές του μοντέλου εκφράζουν τη μεταβολή της προβλεπόμενης τιμής για μοναδιαία μεταβολή της αντίστοιχης μεταβλητής εισόδου, υπό την προϋπόθεση ότι οι υπόλοιπες μεταβλητές παραμένουν σταθερές. Η ιδιότητα αυτή καθιστά τη γραμμική παλινδρόμηση ιδιαίτερα ερμηνεύσιμη σε σύγκριση με πιο σύνθετα μοντέλα μηχανικής μάθησης (James et al., 2021; Hyndman & Athanasopoulos, 2021).

Στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου, η γραμμική παλινδρόμηση χρησιμοποιεί συνήθως ως χαρακτηριστικά ιστορικές τιμές φορτίου, μεταβλητές χρονικής υστέρησης (lag features), ημερολογιακές πληροφορίες και μετεωρολογικές μεταβλητές, επιτρέποντας την αξιοποίηση τόσο της χρονικής εξάρτησης όσο και εξωγενών παραγόντων που επηρεάζουν τη ζήτηση ηλεκτρικής ενέργειας (Mystakidis et al., 2024; Misiurek et al., 2025). Παρά την απλότητά της, εξακολουθεί να χρησιμοποιείται ευρέως στη βιβλιογραφία, καθώς χαρακτηρίζεται από χαμηλό υπολογιστικό κόστος, υψηλή ερμηνευσιμότητα και σταθερή απόδοση σε προβλήματα όπου οι σχέσεις μεταξύ των μεταβλητών είναι κυρίως γραμμικές.

Επεκτάσεις της κλασικής γραμμικής παλινδρόμησης αποτελούν οι μέθοδοι Ridge και Lasso, οι οποίες εισάγουν όρους κανονικοποίησης (regularization) για τον περιορισμό της πολυσυγγραμμικότητας και της υπερπροσαρμογής σε προβλήματα με μεγάλο αριθμό ή ισχυρά συσχετισμένα χαρακτηριστικά. Η Ridge συρρικνώνει τους συντελεστές χωρίς να τους μηδενίζει, ενώ η Lasso μπορεί επιπλέον να πραγματοποιήσει αυτόματη επιλογή χαρακτηριστικών μηδενίζοντας ορισμένους συντελεστές (James et al., 2021; Géron, 2019).

Η Γραμμική Παλινδρόμηση αποτελεί μία από τις απλούστερες και περισσότερο ερμηνεύσιμες μεθόδους πρόβλεψης, με χαμηλό υπολογιστικό κόστος και εύκολη υλοποίηση. Λόγω της διαφάνειας του μοντέλου και της δυνατότητας άμεσης ερμηνείας της επίδρασης κάθε μεταβλητής εισόδου, χρησιμοποιείται συχνά ως μοντέλο αναφοράς (baseline) για τη σύγκριση πιο σύνθετων αλγορίθμων (Cordeiro-Costas et al., 2023). Παρά τα πλεονεκτήματά της, η γραμμική παλινδρόμηση βασίζεται στην υπόθεση ότι η σχέση μεταξύ των μεταβλητών μπορεί να περιγραφεί επαρκώς από γραμμικό μοντέλο. Ως αποτέλεσμα, η απόδοσή της περιορίζεται όταν η συμπεριφορά του ηλεκτρικού φορτίου

επηρεάζεται από έντονες μη γραμμικές αλληλεπιδράσεις ή πολύπλοκες χρονικές εξαρτήσεις, όπου αλγόριθμοι όπως τα Random Forest, XGBoost και τα δίκτυα LSTM παρουσιάζουν συνήθως υψηλότερη προγνωστική ακρίβεια (Hong & Fan, 2016; Mystakidis et al., 2024; Ugbehe et al., 2025).

2.3.2.2. Support Vector Machines

Η Παλινδρόμηση Διανυσμάτων Υποστήριξης (Support Vector Regression – SVR) αποτελεί επέκταση των Μηχανών Διανυσμάτων Υποστήριξης (Support Vector Machines – SVM) για προβλήματα παλινδρόμησης και ανήκει στις επιβλεπόμενες μεθόδους μηχανικής μάθησης. Η βασική της αρχή είναι η εκτίμηση μιας συνάρτησης παλινδρόμησης με ελεγχόμενη πολυπλοκότητα, επιτρέποντας μικρές αποκλίσεις από τις πραγματικές τιμές μέσω της συνάρτησης απώλειας ϵ -insensitive loss. Για την αντιμετώπιση μη γραμμικών σχέσεων χρησιμοποιούνται συναρτήσεις πυρήνα (kernel functions), με συνηθέστερη την Radial Basis Function (RBF) (Cortes & Vapnik, 1995; Smola & Schölkopf, 2004).

Η διαδικασία εκπαίδευσης της SVR διατυπώνεται ως πρόβλημα βελτιστοποίησης:

$$\min_{\mathbf{w}, b, \xi, \zeta} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N (\xi_i + \zeta_i)$$

όπου $\mathbf{w}$ είναι το διάνυσμα βαρών, b ο όρος μετατόπισης, οι μεταβλητές χαλάρωσης ξ και ζ επιτρέπουν αποκλίσεις πέραν του περιθωρίου ϵ , ενώ η παράμετρος C ελέγχει τον συμβιβασμό μεταξύ της πολυπλοκότητας του μοντέλου και του σφάλματος εκπαίδευσης (Smola & Schölkopf, 2004).

Πλεονεκτήματα της μεθόδου είναι η δυνατότητα μοντελοποίησης τόσο γραμμικών όσο και μη γραμμικών σχέσεων μέσω κατάλληλων συναρτήσεων πυρήνα, η υψηλή ικανότητα γενίκευσης, η ανθεκτικότητα στις ακραίες τιμές και η αποτελεσματική διαχείριση προβλημάτων με μεγάλο αριθμό χαρακτηριστικών. Επιπλέον, η χρήση παραμέτρων κανονικοποίησης συμβάλλει στον έλεγχο της πολυπλοκότητας του μοντέλου και στη βελτίωση της γενίκευσης (Cordeiro-Costas et al., 2023).

Ωστόσο, η απόδοση της SVR εξαρτάται σημαντικά από την επιλογή της συνάρτησης πυρήνα και τη ρύθμιση των υπερπαραμέτρων C , ϵ και γ , ενώ απαιτείται κατάλληλη κανονικοποίηση των χαρακτηριστικών εισόδου. Επιπλέον, το υπολογιστικό κόστος εκπαίδευσης αυξάνεται σημαντικά σε μεγάλα σύνολα δεδομένων (Cortes & Vapnik, 1995; Smola & Schölkopf, 2004).

2.3.2.3. Αλγόριθμος k-Πλησιέστερων Γειτόνων (k-NNs)

Ο αλγόριθμος k-Πλησιέστερων Γειτόνων (k-Nearest Neighbours – k-NN) αποτελεί επιβλεπόμενη, μη παραμετρική και βασισμένη σε περιπτώσεις μέθοδο μηχανικής μάθησης. Για την πρόβλεψη μιας νέας παρατήρησης, εντοπίζονται τα k πλησιέστερα δείγματα του συνόλου εκπαίδευσης με βάση μια προκαθορισμένη μετρική απόστασης. Στα προβλήματα παλινδρόμησης, η προβλεπόμενη τιμή προκύπτει συνήθως από τον μέσο όρο των τιμών-στόχων των γειτονικών παρατηρήσεων, ενώ στα προβλήματα ταξινόμησης χρησιμοποιείται πλειοψηφική ψηφοφορία. Η επιλογή του k , της μετρικής απόστασης και της κλιμάκωσης των χαρακτηριστικών επηρεάζει άμεσα την απόδοση του μοντέλου, καθώς καθορίζει τη σχέση μεταξύ μεροληψίας και διακύμανσης. Βασικά πλεονεκτήματα της μεθόδου αποτελούν η απλότητα, η εύκολη υλοποίηση και η απουσία σύνθετης διαδικασίας εκπαίδευσης. Ωστόσο, απαιτεί την αποθήκευση των δεδομένων εκπαίδευσης και τον υπολογισμό αποστάσεων κατά την πρόβλεψη, γεγονός που μπορεί να αυξήσει σημαντικά το υπολογιστικό κόστος σε μεγάλα σύνολα δεδομένων. Επιπλέον, η απόδοσή της επηρεάζεται αρνητικά από την υψηλή διαστασιμότητα και από την ύπαρξη χαρακτηριστικών με διαφορετικές κλίμακες, γεγονός που καθιστά αναγκαία την κατάλληλη

προεπεξεργασία των δεδομένων (Mitchell, 1997; Hastie et al., 2009; Goodfellow et al., 2016; Ugbehe et al., 2025). Στην πρόβλεψη ηλεκτρικού φορτίου, ο k-NN έχει χρησιμοποιηθεί σε εφαρμογές βραχυπρόθεσμης και πολύ βραχυπρόθεσμης πρόβλεψης, συχνά ως απλό μοντέλο αναφοράς για τη σύγκριση πιο σύνθετων μεθόδων μηχανικής και βαθιάς μάθησης (Nti et al., 2020; Misiurek et al., 2025; Azeem et al., 2021).

2.3.2.4. Δέντρα Απόφασης (Decision Trees)

Τα δέντρα απόφασης (Decision Trees) αποτελούν μη παραμετρικά μοντέλα μηχανικής μάθησης τα οποία υλοποιούνται μέσω μιας δομής δεδομένων τύπου δέντρου. Η κατασκευή τους βασίζεται στον επαναληπτικό διαχωρισμό των δεδομένων εισόδου μέσω της εφαρμογής μιας ιεραρχικής ακολουθίας κανόνων απόφασης. Κάθε εσωτερικός κόμβος απόφασης (internal decision node) στο δέντρο αντιστοιχεί σε ένα κριτήριο διαχωρισμού βασισμένο σε μία από τις μεταβλητές εισόδου, ενώ η διαδικασία καταλήγει σε φύλλα, όπου κάθε φύλλο περιέχει την τελική πρόβλεψη της μεταβλητής-στόχου. Στην περίπτωση των δέντρων ταξινόμησης (classification trees), κάθε φύλλο αποδίδει την προβλεπόμενη κατηγορία της μεταβλητής-στόχου, συνήθως βάσει της πλειοψηφίας των παρατηρήσεων που καταλήγουν σε αυτό, ενώ στα δέντρα παλινδρόμησης (regression trees) κάθε φύλλο (terminal node, leaf) περιέχει μια σταθερή αριθμητική πρόβλεψη, η οποία ισούται συνήθως με τη μέση τιμή της μεταβλητής-στόχου των αντίστοιχων παρατηρήσεων (Alpaydin, 2020; Hastie et al., 2009).

Ωστόσο, τα μεμονωμένα δέντρα απόφασης παρουσιάζουν υψηλή διακύμανση και είναι ευαίσθητα σε μικρές μεταβολές των δεδομένων εκπαίδευσης, γεγονός που μπορεί να οδηγήσει σε υπερπροσαρμογή. Η αντιμετώπιση των περιορισμών αυτών αποτέλεσε το βασικό κίνητρο για την ανάπτυξη μεθόδων συνόλων, όπως τα Random Forests και το Gradient Boosting (Hastie et al., 2009; Géron, 2019)

2.3.2.5. Random Forests

Τα τυχαία δάση (Random Forests) αποτελούν μια μέθοδο μηχανικής μάθησης που ανήκει στην κατηγορία των μεθόδων συνόλων (ensemble methods) και ειδικότερα στις μεθόδους bagging. Στα Random Forests συνδυάζονται πολλαπλά δέντρα απόφασης, στα οποία εισάγονται διαφορετικές πηγές τυχαιότητας κατά την εκπαίδευση. Η τελική έξοδος προκύπτει μέσω πλειοψηφικής ψηφοφορίας στην ταξινόμηση και μέσω του μέσου όρου των επιμέρους προβλέψεων στην παλινδρόμηση.

Κάθε δέντρο απόφασης εντός του τυχαίου δάσους εκπαιδεύεται σε ένα διαφορετικό υποσύνολο των δεδομένων εκπαίδευσης, το οποίο προκύπτει μέσω τυχαίας δειγματοληψίας με επανάθεση (bootstrap sampling). Επιπλέον, εντός κάθε δέντρου απόφασης, για κάθε διαχωρισμό κόμβου επιλέγεται τυχαία ένα υποσύνολο των χαρακτηριστικών. Οι δύο αυτές διαδικασίες διαφοροποιούν τα επιμέρους δέντρα και μειώνουν τη μεταξύ τους συσχέτιση. Ως αποτέλεσμα, ο μέσος όρος των προβλέψεών τους παρουσιάζει χαμηλότερη διακύμανση και μεγαλύτερη σταθερότητα από την πρόβλεψη ενός μεμονωμένου δέντρου απόφασης. Η καθιερωμένη υλοποίηση της μεθόδου συνδυάζει bootstrap sampling και τυχαία επιλογή χαρακτηριστικών σε κάθε διαχωρισμό κόμβου (Breiman, 2001). Σύμφωνα με τον Breiman (2001), το σφάλμα γενίκευσης ενός Random Forest επηρεάζεται από δύο βασικούς παράγοντες: την προβλεπτική ισχύ των επιμέρους δέντρων και τη μεταξύ τους συσχέτιση. Η απόδοση βελτιώνεται όταν τα δέντρα παραμένουν επαρκώς ακριβή, αλλά τα σφάλματά τους δεν είναι έντονα συσχετισμένα. Καθώς αυξάνεται ο αριθμός των δέντρων, το σφάλμα γενίκευσης συγκλίνει σε μια οριακή τιμή, επομένως η απλή προσθήκη δέντρων δεν οδηγεί συνήθως σε υπερπροσαρμογή (Hastie et al., 2009; Géron, 2019).

Στην περίπτωση της παλινδρόμησης, η τελική πρόβλεψη του Random Forest ισούται με τον μέσο όρο των προβλέψεων των B επιμέρους δέντρων:

$$\hat{y}(\mathbf{x}) = \frac{1}{B} \sum_{b=1}^B T_b(\mathbf{x})$$

όπου $T_b(\mathbf{x})$ είναι η πρόβλεψη του b -οστού δέντρου για το διάνυσμα εισόδου $\mathbf{x}$.

Στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου, τα Random Forests μπορούν να αποτυπώσουν μη γραμμικές σχέσεις και αλληλεπιδράσεις μεταξύ ιστορικών τιμών φορτίου, ημερολογιακών δεικτών, μετεωρολογικών συνθηκών και επιχειρησιακών μεταβλητών. Παράλληλα, δεν απαιτούν κανονικοποίηση των αριθμητικών χαρακτηριστικών και μπορούν να χρησιμοποιήσουν μεταβλητές διαφορετικής κλίμακας. Συνοπτικά τα πλεονεκτήματα της μεθόδου είναι η δυνατότητα μοντελοποίησης πολύπλοκων μη γραμμικών σχέσεων, η ανθεκτικότητα στον θόρυβο και στις ακραίες τιμές των δεδομένων, καθώς και η υψηλή ικανότητα γενίκευσης μέσω του συνδυασμού πολλαπλών δέντρων αποφάσεων. Επιπλέον, μπορεί να διαχειριστεί αποτελεσματικά μεγάλα σύνολα δεδομένων (Cordeiro-Costas et al., 2023).

Βασικός περιορισμός των Random Forests στην πρόβλεψη φορτίου είναι η περιορισμένη ικανότητα εξωπαρεμβολής πέρα από το εύρος των τιμών που περιλαμβάνονται στα δεδομένα εκπαίδευσης. Επειδή οι προβλέψεις των δέντρων βασίζονται στις μέσες τιμές των παρατηρήσεων που καταλήγουν στα φύλλα τους, το μοντέλο δυσκολεύεται να προβλέψει τιμές σημαντικά υψηλότερες ή χαμηλότερες από εκείνες που έχουν ήδη παρατηρηθεί. Επιπλέον, ο μέσος όρος πολλών δέντρων μπορεί να οδηγήσει σε εξομάλυνση ακραίων αιχμών του φορτίου.

Η σημαντικότητα των χαρακτηριστικών που βασίζεται στη συνολική μείωση της ανομοιογένειας των κόμβων μπορεί να είναι μεροληπτική υπέρ μεταβλητών με πολλές πιθανές τιμές διαχωρισμού. Επιπλέον, όταν οι μεταβλητές εισόδου παρουσιάζουν έντονη συσχέτιση, η αποδιδόμενη σημαντικότητα ενδέχεται να κατανέμεται μεταξύ τους, δυσχεραίνοντας την ερμηνεία της συμβολής κάθε χαρακτηριστικού.

2.3.2.6. Gradient Boosting Μέθοδοι

Το Gradient Boosting (Friedman, 2001) αποτελεί μια μέθοδο συνόλου, στην οποία κατασκευάζεται ένα σταδιακό προσθετικό μοντέλο (stage-wise additive model) μέσω του διαδοχικού συνδυασμού ασθενών μοντέλων πρόβλεψης (weak learners), το οποίο προοδευτικά βελτιώνει την προβλεπτική του ικανότητα μέσω της επαναληπτικής διόρθωσης των σφαλμάτων. Στην προσέγγιση αυτή η δημιουργία του συνόλου μοντέλων είναι σταδιακή, με κάθε προστιθέμενο μοντέλο να εκπαιδεύεται ώστε να διορθώνει τα σφάλματα του ήδη υπάρχοντος συνόλου. Πιο τυπικά, η διαδικασία αυτή μπορεί να θεωρηθεί ως πρόβλημα βελτιστοποίησης, όπου σε κάθε βήμα ελαχιστοποιείται μια συνάρτηση απώλειας (loss function) μέσω της προσαρμογής του νέου μοντέλου στην αρνητική κλίση (negative gradient) της συνάρτησης απώλειας ως προς τις τρέχουσες προβλέψεις. Έτσι, το Gradient Boosting μπορεί να περιγραφεί ως μια επαναληπτική διαδικασία μάθησης που κατασκευάζει το τελικό μοντέλο ως άθροισμα διαδοχικών επιμέρους μοντέλων, επιτυγχάνοντας προοδευτική βελτίωση της απόδοσης. (Hastie et al., 2009; Friedman, 2001)

Μαθηματικά μπορεί να περιγραφεί από τη σχέση:

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

όπου $F_{m-1}(x)$ είναι το ensemble μοντέλο της προηγούμενης επανάληψης, $h_m(x)$ το νέο ασθενές μοντέλο (συνήθως δέντρο απόφασης) που προσαρμόζεται στα αρνητικά gradients της συνάρτησης απώλειας, ρ_m ο συντελεστής βήματος και η ο συντελεστής εκμάθησης (learning rate), ο οποίος καθορίζει τη συνεισφορά κάθε νέου μοντέλου στην τελική πρόβλεψη. Μικρότερες τιμές του η οδηγούν συνήθως σε βελτιωμένη γενίκευση, απαιτώντας όμως μεγαλύτερο αριθμό δέντρων.

Το XGBoost (Chen & Guestrin, 2016) αποτελεί μια βελτιστοποιημένη και υπολογιστικά αποδοτικότερη υλοποίηση του Gradient Boosting, η οποία ενσωματώνει κανονικοποίηση (regularization) στη διαδικασία βελτιστοποίησης, εισάγοντας όρους ποινής στη συνάρτηση στόχου για τον έλεγχο της πολυπλοκότητας του μοντέλου. Η διαδικασία εκπαίδευσης αξιοποιεί τόσο την πρώτη όσο και τη δεύτερη παράγωγο της συνάρτησης απώλειας, επιτρέποντας ακριβέστερη και πιο σταθερή προσαρμογή του μοντέλου. Επιπλέον, κατά την κατασκευή των δέντρων εφαρμόζεται μηχανισμός κλαδέματος (pruning), μέσω του οποίου διατηρούνται μόνο οι διαχωρισμοί που συμβάλλουν ουσιαστικά στη μείωση του σφάλματος. Τέλος, ο αλγόριθμος ενσωματώνει βελτιστοποιήσεις σε επίπεδο υλοποίησης, οι οποίες ενισχύουν την υπολογιστική αποδοτικότητα και καθιστούν τη μέθοδο κατάλληλη για μεγάλης κλίμακας προβλήματα. Συνοψίζοντας, η ενσωμάτωση τεχνικών κανονικοποίησης και αποδοτικής βελτιστοποίησης καθιστά το XGBoost ικανό να επιτυγχάνει υψηλή προγνωστική απόδοση με παράλληλο έλεγχο της πολυπλοκότητας. Επιπλέον, η ευελιξία στη ρύθμιση των υπερπαραμέτρων επιτρέπει την προσαρμογή του μοντέλου σε διαφορετικά προβλήματα πρόβλεψης. (Cordeiro-Costas et al., 2023) Άλλες δημοφιλείς υλοποιήσεις του Gradient Boosting περιλαμβάνουν το LightGBM (Ke et al., 2017) και το CatBoost (Prokhorenkova et al., 2019). Το LightGBM βασίζεται σε τεχνικές που επιταχύνουν τη διαδικασία εκπαίδευσης και μειώνουν τις απαιτήσεις σε μνήμη, καθιστώντας το κατάλληλο για προβλήματα μεγάλης κλίμακας, ενώ το CatBoost σχεδιάστηκε για την αποτελεσματική διαχείριση κατηγορικών μεταβλητών και τη μείωση της μεροληψίας κατά την εκπαίδευση (Ke et al., 2017; Prokhorenkova et al., 2019). Οι αλγόριθμοι αυτοί, μαζί με το XGBoost, συγκαταλέγονται πλέον στις πλέον διαδεδομένες υλοποιήσεις του Gradient Boosting και έχουν χρησιμοποιηθεί εκτενώς σε εφαρμογές πρόβλεψης ενέργειας και ηλεκτρικού φορτίου, λόγω της υψηλής προγνωστικής τους απόδοσης και της υπολογιστικής τους αποδοτικότητας (Klyuev et al., 2022; Mystakidis et al., 2024).

2.3.2.7. Μοντέλα Ασαφούς Λογικής (Fuzzy logic)

Η Ασαφής Λογική (Fuzzy Logic) αποτελεί προσέγγιση υπολογιστικής νοημοσύνης που επεκτείνει τη δυαδική λογική, επιτρέποντας σε ένα στοιχείο να ανήκει σε ένα σύνολο με βαθμό συμμετοχής μεταξύ 0 και 1 αντί της απόλυτης συμμετοχής ή μη συμμετοχής. Η προσέγγιση αυτή βασίζεται στη χρήση ασαφών συνόλων (fuzzy sets), συναρτήσεων συμμετοχής (membership functions) και γλωσσικών κανόνων της μορφής IF-THEN, μέσω των οποίων μπορούν να μοντελοποιηθούν πολύπλοκες και μη γραμμικές σχέσεις καθώς και να ενσωματωθεί η γνώση ειδικών στο μοντέλο. Βασικά πλεονεκτήματα της ασαφούς λογικής αποτελούν η αποτελεσματική διαχείριση αβεβαιότητας και ασάφειας, καθώς και η δυνατότητα ενσωμάτωσης εμπειρικής γνώσης. Ωστόσο, η απόδοσή της εξαρτάται σε σημαντικό βαθμό από τον σχεδιασμό των συναρτήσεων συμμετοχής και της βάσης κανόνων, γεγονός που δυσχεραίνει την εφαρμογή της σε προβλήματα μεγάλης κλίμακας. Στη βιβλιογραφία της πρόβλεψης ηλεκτρικού φορτίου, η ασαφής λογική έχει εφαρμοστεί τόσο ως αυτόνομη μέθοδος όσο και σε υβριδικά μοντέλα σε συνδυασμό με τεχνητά

νευρωνικά δίκτυα και άλλες τεχνικές μηχανικής μάθησης (Azeem et al., 2021; Misiurek et al., 2025; Nti et al., 2020).

Η Ασαφής Λογική επιτρέπει τη μοντελοποίηση προβλημάτων που χαρακτηρίζονται από αβεβαιότητα και ασαφείς σχέσεις, ενώ προσφέρει υψηλή ερμηνευσιμότητα μέσω κανόνων τύπου IF–THEN. Παρ' όλα αυτά, η απόδοσή της εξαρτάται από τον κατάλληλο σχεδιασμό των κανόνων και των συναρτήσεων συμμετοχής και, ως αυτόνομη μέθοδος, συχνά υστερεί έναντι νεότερων υβριδικών και βαθιών μοντέλων (Ugbehe et al., 2025).

2.3.3. Μέθοδοι Βαθιάς Μάθησης

Η ραγδαία αύξηση της διαθεσιμότητας δεδομένων από έξυπνους μετρητές, αισθητήρες και συστήματα παρακολούθησης, σε συνδυασμό με την αυξανόμενη πολυπλοκότητα των σύγχρονων ηλεκτρικών δικτύων, ανέδειξε τους περιορισμούς των παραδοσιακών στατιστικών και κλασικών μεθόδων μηχανικής μάθησης στην πρόβλεψη ηλεκτρικού φορτίου. Ως αποτέλεσμα, η έρευνα στράφηκε ολοένα και περισσότερο προς τις τεχνικές βαθιάς μάθησης (Deep Learning – DL), οι οποίες διαθέτουν αυξημένη ικανότητα εκμάθησης πολύπλοκων μη γραμμικών σχέσεων και εξαγωγής ιεραρχικών χαρακτηριστικών απευθείας από τα δεδομένα (Mystakidis et al., 2024; Chandrasekaran & Paramasivan, 2025).

Σε αντίθεση με τις παραδοσιακές προσεγγίσεις, τα μοντέλα βαθιάς μάθησης μπορούν να αξιοποιήσουν αποτελεσματικά μεγάλους όγκους δεδομένων και να προσαρμοστούν σε σύνθετα πρότυπα κατανάλωσης, χωρίς να απαιτείται εκτεταμένη χειροκίνητη κατασκευή χαρακτηριστικών (feature engineering). Για τον λόγο αυτό, η χρήση τους στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου έχει αυξηθεί σημαντικά τα τελευταία χρόνια, ιδιαίτερα σε εφαρμογές που περιλαμβάνουν υψηλή μεταβλητότητα, έντονη μη γραμμικότητα και μεγάλες χρονικές ακολουθίες (Nti et al., 2020; Mystakidis et al., 2024). Η εξέλιξη των αρχιτεκτονικών βαθιάς μάθησης ακολούθησε μία διαδοχική πορεία βελτίωσης. Τα αρχικά τεχνητά νευρωνικά δίκτυα (Artificial Neural Networks - ANN) αποτέλεσαν τη βάση για την ανάπτυξη πιο εξειδικευμένων αρχιτεκτονικών, όπως τα αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Networks – RNN), τα οποία σχεδιάστηκαν για την επεξεργασία ακολουθιακών δεδομένων. Στη συνέχεια αναπτύχθηκαν οι αρχιτεκτονικές Long Short-Term Memory (LSTM) και Gated Recurrent Unit (GRU), με στόχο την αποτελεσματικότερη μοντελοποίηση μακροχρόνιων χρονικών εξαρτήσεων. Πιο πρόσφατα, η βιβλιογραφία παρουσιάζει αυξανόμενο ενδιαφέρον για υβριδικά μοντέλα, όπως οι συνδυασμοί CNN–LSTM και οι μηχανισμοί προσοχής (Attention), καθώς και για αρχιτεκτονικές βασισμένες στους Transformers, οι οποίες αξιοποιούν την παράλληλη επεξεργασία των ακολουθιών και εμφανίζουν ιδιαίτερα υψηλή προγνωστική ικανότητα σε μεγάλα σύνολα δεδομένων (Mystakidis et al., 2024; Misiurek et al., 2025; Chandrasekaran & Paramasivan, 2025).

Παρά τη σημαντική πρόοδο που έχει σημειωθεί, η βιβλιογραφία επισημαίνει ότι τα μοντέλα βαθιάς μάθησης συνοδεύονται από αυξημένες απαιτήσεις σε υπολογιστικούς πόρους και δεδομένα εκπαίδευσης, ενώ παράλληλα χαρακτηρίζονται από περιορισμένη ερμηνευσιμότητα σε σύγκριση με απλούστερες προσεγγίσεις μηχανικής μάθησης. Για τον λόγο αυτό, η επιλογή της κατάλληλης αρχιτεκτονικής εξαρτάται τόσο από τα χαρακτηριστικά του προβλήματος όσο και από τη διαθεσιμότητα δεδομένων και υπολογιστικών πόρων (Mystakidis et al., 2024; Misiurek et al., 2025).

2.3.3.1. Τεχνητά Νευρωνικά Δίκτυα

Τα Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks – ANNs) εμπνεύστηκαν εννοιολογικά από τη δομή και τη λειτουργία των νευρικών κυττάρων (νευρώνων, neurons) του ανθρώπινου εγκεφάλου. Ένας βιολογικός νευρώνας λαμβάνει ηλεκτρικά ή χημικά ερεθίσματα, μέσω των δενδριτών του, από γειτονικούς του νευρώνες με τους οποίους είναι διασυνδεδεμένος, επεξεργάζεται την πληροφορία στο κυτταρικό σώμα του και μεταδίδει σήματα (νευρικές ώσεις) μέσω του νευράξονα του προς άλλους διασυνδεδεμένους νευρώνες. Σημαντικό χαρακτηριστικό της βιολογικής λειτουργίας των νευρώνων αποτελεί το γεγονός ότι ο νευρώνας ενεργοποιείται μόνο όταν το συνολικό εισερχόμενο ερέθισμα υπερβεί μια συγκεκριμένη οριακή τιμή ενεργοποίησης (κατώφλι ενεργοποίησης, threshold). Παρότι η λειτουργία ενός μεμονωμένου νευρώνα είναι σχετικά απλή, η διασύνδεση δισεκατομμυρίων νευρώνων οδηγεί στην εμφάνιση πολύπλοκων συμπεριφορών και γνωστικών λειτουργιών μέσω αναδυόμενων ιδιοτήτων (emergent properties), οι οποίες απορρέουν από τη συλλογική λειτουργία των νευρώνων ως δίκτυο (Haykin, 2011; Urry et al., 2021).

Με στόχο την μαθηματική και υπολογιστική προσομοίωση της λειτουργίας των βιολογικών νευρώνων αναπτύχθηκαν απλοποιημένα υπολογιστικά μοντέλα, οι τεχνητοί νευρώνες (artificial neurons), οι οποίοι αποτελούν τη βασική δομική και λειτουργική μονάδα των Τεχνητών Νευρωνικών Δικτύων. Ένας τεχνητός νευρώνας λαμβάνει πολλαπλές εισόδους, καθεμία από τις οποίες συνδέεται με ένα αντίστοιχο βάρος (weight), το οποίο εκφράζει τη σχετική σημασία της εισόδου στη συνολική απόκριση του νευρώνα. Στη συνέχεια, ο νευρώνας υπολογίζει ένα σταθμισμένο άθροισμα των εισόδων και προσθέτει έναν όρο πόλωσης (bias), ο οποίος λειτουργεί ως σταθερός προσαρμοστικός όρος. Ο όρος αυτός επιτρέπει την αύξηση ή τη μείωση της συνολικής εισόδου της συνάρτησης ενεργοποίησης, ανάλογα με το πρόσημό του, επηρεάζοντας κατ' επέκταση τη συμπεριφορά και την ενεργοποίηση του νευρώνα και αυξάνοντας την ευελιξία του μοντέλου. Παρότι τα πρώτα μοντέλα τεχνητών νευρώνων βασίζονταν στη λογική κατωφλίου (threshold logic), σύμφωνα με την οποία ο νευρώνας ενεργοποιούνταν για να παράγει έξοδο μόνο όταν η συνολική διέγερση υπερέβαινε μια οριακή τιμή, όπως συμβαίνει και στους βιολογικούς νευρώνες (McCulloch & Pitts, 1943), στα σύγχρονα νευρωνικά δίκτυα η έξοδος παράγεται μέσω της εφαρμογής μίας συνάρτησης ενεργοποίησης (activation function) στο σταθμισμένο άθροισμα των εισόδων και του όρου πόλωσης (Bishop, 2016; Goodfellow et al., 2016; Haykin, 2011) και μπορεί να παρασταθεί ως εξής:

$$u_k = \sum_{j=1}^m w_{kj} x_j$$
$$y_k = \phi(u_k + b_k)$$

όπου x_j είναι τα σήματα εισόδου (input signals), w_{kj} τα αντίστοιχα βάρη σύνδεσης (synaptic weights) του νευρώνα, b_k όρος πόλωσης (bias), $\phi(\cdot)$ η συνάρτηση ενεργοποίησης και y_k η τελική έξοδος του νευρώνα. Σε εναλλακτική, μαθηματικά ισοδύναμη διατύπωση, ο όρος πόλωσης μπορεί να θεωρηθεί ως μία επιπλέον σταθερή είσοδος με τιμή $x_0 = 1$ και αντίστοιχο βάρος σύνδεσης $w_{k0} = b_k$ (Haykin, 2011).

2.3.3.2. Τεχνητά νευρωνικά δίκτυα προώθησης προς τα εμπρός (FeedForward Neural Networks)

Τα Τεχνητά Νευρωνικά Δίκτυα (ANNs) είναι συστήματα παράλληλα διασυνδεδεμένων τεχνητών νευρώνων, οι οποίοι συνεργάζονται για την επεξεργασία και μάθηση σύνθετων προτύπων από τα δεδομένα. Η γνώση που αποκτά το δίκτυο κατά την εκπαίδευση του, αποθηκεύεται στα βάρη σύνδεσης μεταξύ των νευρώνων, τα οποία προσαρμόζονται δυναμικά κατά την διαδικασία αυτή (Haykin, 2011). Κάθε επίπεδο ενός νευρωνικού δικτύου μπορεί να θεωρηθεί ως στάδιο παράλληλης επεξεργασίας, στο οποίο πολλοί νευρώνες επεξεργάζονται ταυτόχρονα τις εξόδους του προηγούμενου επιπέδου μέσω διαφορετικών βαρών σύνδεσης και συναρτήσεων ενεργοποίησης.

Μία από τις βασικότερες κατηγορίες αρχιτεκτονικών νευρωνικών δικτύων αποτελούν τα δίκτυα προώθησης προς τα εμπρός (Feedforward Neural Networks – FNNs). Στα δίκτυα αυτά, η πληροφορία μεταδίδεται μονοκατευθυντικά από το επίπεδο εισόδου προς τα επόμενα επίπεδα επεξεργασίας και τελικά προς το επίπεδο εξόδου, χωρίς την ύπαρξη κυκλικών ή αναδρομικών συνδέσεων. Η αρχιτεκτονική αυτή χαρακτηρίζεται από την απουσία μηχανισμού ανάδρασης (feedback), γεγονός που διαφοροποιεί τα δίκτυα προώθησης προς τα εμπρός από τα αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Networks – RNNs) (Goodfellow et al., 2016).

Ένα τυπικό νευρωνικό δίκτυο προώθησης προς τα εμπρός αποτελείται συνήθως από τρία βασικά είδη επιπέδων, όπου κάθε επίπεδο αποτελείται από ένα σύνολο νευρώνων: το επίπεδο εισόδου (input layer), ένα ή περισσότερα κρυφά επίπεδα (hidden layers) και το επίπεδο εξόδου (output layer). Στο επίπεδο εισόδου, οι νευρώνες λαμβάνουν τα δεδομένα του προβλήματος και τα προωθούν προς τα επόμενα επίπεδα χωρίς ουσιαστική επεξεργασία. Η κύρια υπολογιστική διαδικασία του δικτύου πραγματοποιείται στα κρυφά επίπεδα, όπου οι νευρώνες τους εφαρμόζουν διαδοχικούς μη γραμμικούς μετασχηματισμούς στα δεδομένα εισόδου. Τέλος, το επίπεδο εξόδου παράγει την τελική έξοδο του μοντέλου που αντιστοιχεί σε κάποια πρόβλεψη ή ταξινόμηση, ανάλογα με τη φύση του εξεταζόμενου προβλήματος. Όταν κάθε νευρώνας ενός επιπέδου συνδέεται με όλους τους νευρώνες του προηγούμενου επιπέδου, το επίπεδο στο οποίο ανήκει χαρακτηρίζεται ως πλήρως συνδεδεμένο επίπεδο (fully connected ή dense layer), ενώ αν ορισμένες από τις συνδέσεις αυτές απουσιάζουν, το δίκτυο χαρακτηρίζεται ως μερικώς συνδεδεμένο (partially connected layer) (Goodfellow et al., 2016; Haykin, 2011).

Από μαθηματικής σκοπιάς ένα νευρωνικό δίκτυο προώθησης προς τα εμπρός μπορεί να θεωρηθεί ως μια ακολουθία διαδοχικών συναρτησιακών μετασχηματισμών, μέσω των οποίων τα δεδομένα εισόδου x σταδιακά μετατρέπονται στην τελική έξοδο του μοντέλου y , όπου κάθε συνάρτηση ($f_1, f_2, f_3 \dots$) αντιστοιχεί σε ένα επίπεδο επεξεργασίας του δικτύου (Goodfellow et al., 2016):

$$y = f_3(f_2(f_1(x)))$$

Η διαδοχική σύνθεση πολλαπλών κρυφών επιπέδων αποτελεί τη βασική αρχή της Βαθιάς Μάθησης (Deep Learning), στην οποία χρησιμοποιούνται βαθιά νευρωνικά δίκτυα (Deep Neural Networks - DNNs), με το βάθος του δικτύου να αντιστοιχεί στο πλήθος των διαδοχικών επιπέδων επεξεργασίας. Τα δίκτυα αυτά επιτρέπουν την εκμάθηση ιεραρχικών αναπαραστάσεων αυξανόμενης πολυπλοκότητας και αφαίρεσης σε σύγκριση με τα ρηχά νευρωνικά δίκτυα (shallow neural networks).

Τα Πολυεπίπεδα Perceptrons (Multilayer Perceptrons – MLPs) αποτελούν την πλέον χαρακτηριστική αρχιτεκτονική feedforward νευρωνικών δικτύων και μία από τις θεμελιώδεις αρχιτεκτονικές της βαθιάς μάθησης. Σε αντίθεση με το απλό perceptron, το

οποίο χρησιμοποιεί συναρτήσεις κατωφλίου, τα σύγχρονα MLPs χρησιμοποιούν συνεχείς και διαφορίσιμες μη γραμμικές συναρτήσεις ενεργοποίησης, γεγονός που επιτρέπει την εκπαίδευσή τους μέσω αλγορίθμων βελτιστοποίησης βασισμένων στη μέθοδο της οπισθοδιάδοσης του σφάλματος (backpropagation). Η συνάρτηση ενεργοποίησης είναι υπεύθυνη για την εισαγωγή μη γραμμικότητας στο μοντέλο, επιτρέποντας στα νευρωνικά δίκτυα να προσεγγίζουν σύνθετες μη γραμμικές σχέσεις μεταξύ εισόδων και εξόδων. Ανάλογα με την αρχιτεκτονική του δικτύου, μπορούν να χρησιμοποιηθούν διαφορετικές συναρτήσεις ενεργοποίησης, όπως η σιγμοειδής (sigmoid), η υπερβολική εφαπτομένη (hyperbolic tangent - tanh) και η Rectified Linear Unit (ReLU). Ωστόσο, σε προβλήματα παλινδρόμησης χρησιμοποιείται συχνά γραμμική συνάρτηση ενεργοποίησης (η ταυτοτική) στο επίπεδο εξόδου, ώστε το μοντέλο να μπορεί να παράγει συνεχείς αριθμητικές τιμές (Goodfellow et al., 2016; Haykin, 2011; Géron, 2019; Bishop, 2016).

Πολλές αρχιτεκτονικές νευρωνικών δικτύων έχουν αναπτυχθεί για την αντιμετώπιση εξειδικευμένων προβλημάτων. Ενώ τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks – CNNs) χρησιμοποιούνται κυρίως στην επεξεργασία εικόνας, τα Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks – RNNs) αποτελούν επέκταση των δικτύων προώθησης προς τα εμπρός (Feedforward Neural Networks – FNNs), σχεδιασμένη για την επεξεργασία ακολουθιακών δεδομένων και χρονοσειρών (Goodfellow et al., 2016). Παρά την αποτελεσματικότητά τους σε προβλήματα παλινδρόμησης και ταξινόμησης, τα πολυεπίπεδα perceptrons (MLPs) επεξεργάζονται κάθε παρατήρηση ανεξάρτητα και δεν διαθέτουν μηχανισμό μνήμης για τη μοντελοποίηση χρονικών εξαρτήσεων. Για τον λόγο αυτό, για την επεξεργασία ακολουθιακών δεδομένων αναπτύχθηκαν οι αρχιτεκτονικές αναδρομικών νευρωνικών δικτύων, οι οποίες παρουσιάζονται στη συνέχεια

2.3.3.3. Αναδρομικά Νευρωνικά Δίκτυα (RNN)

Τα αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Networks – RNNs) αποτελούν οικογένεια νευρωνικών δικτύων σχεδιασμένων για την επεξεργασία ακολουθιακών δεδομένων (sequential data) της μορφής $x^{(1)}, x^{(2)}, \dots, x^{(t)}$ όπως οι λεκτικές ακολουθίες και οι χρονοσειρές (Goodfellow et al., 2016) όπου η χρονική σειρά και οι εξαρτήσεις μεταξύ των παρατηρήσεων επηρεάζουν σημαντικά τη συμπεριφορά του συστήματος.

Η βασική αρχή λειτουργίας των RNNs είναι η επαναληπτική επεξεργασία των δεδομένων μέσω μιας εσωτερικής κατάστασης (hidden state), η οποία μεταφέρει πληροφορία από προηγούμενα χρονικά βήματα στα επόμενα. Η κατάσταση αυτή ενημερώνεται επαναληπτικά σύμφωνα με τη σχέση:

$$h^{(t)} = f(h^{(t-1)}, x^{(t)}; \theta)$$

όπου $x^{(t)}$ είναι η είσοδος στη χρονική στιγμή t , $h^{(t-1)}$ η προηγούμενη κρυφή κατάσταση και θ το σύνολο των κοινών παραμέτρων του δικτύου. Κατά την εκπαίδευση, το RNN μαθαίνει να χρησιμοποιεί την κρυφή κατάσταση ως μία δυναμική αναπαράσταση της προηγούμενης ακολουθίας εισόδων, μέσω της οποίας πληροφορία από προηγούμενα χρονικά βήματα μεταφέρεται και επηρεάζει, εκτός από την τρέχουσα έξοδο, και την επεξεργασία των επόμενων παρατηρήσεων (Goodfellow et al., 2016).

Η βασική παραδοχή της αρχιτεκτονικής των RNN είναι ότι οι χρονικές εξαρτήσεις μιας ακολουθίας μπορούν να περιγραφούν μέσω του ίδιου μηχανισμού ενημέρωσης της κρυφής κατάστασης σε κάθε χρονικό βήμα. Αυτό υλοποιείται με την επαναληπτική εφαρμογή της ίδιας συνάρτησης μετάβασης και του ίδιου συνόλου παραμέτρων (parameter sharing) σε ολόκληρη την ακολουθία. Ο διαμοιρασμός παραμέτρων αποτελεί θεμελιώδες

χαρακτηριστικό των RNNs, καθώς επιτρέπει στο δίκτυο να μαθαίνει έναν ενιαίο κανόνα ενημέρωσης της εσωτερικής του κατάστασης, ο οποίος συνδυάζει την πληροφορία από προηγούμενα χρονικά βήματα με τις νέες εισόδους. Παράλληλα, καθιστά δυνατή την εφαρμογή του ίδιου μοντέλου σε ακολουθίες διαφορετικού μήκους χωρίς να απαιτείται διαφορετικό σύνολο παραμέτρων για κάθε χρονική στιγμή, μειώνοντας σημαντικά τον αριθμό των παραμέτρων, επιτρέποντας την εκπαίδευση του μοντέλου με λιγότερα παραδείγματα εκπαίδευσης και ενισχύοντας την ικανότητα γενίκευσης μέσω της εκμάθησης κοινών χρονικών προτύπων που εμφανίζονται σε διαφορετικές θέσεις της ακολουθίας (Géron, 2019; Goodfellow et al., 2016).

Ενώ τα πολυεπίπεδα perceptrons εκπαιδεύονται συνήθως με τη μέθοδο της οπισθοδιάδοσης του σφάλματος (backpropagation of error), μέσω της οποίας ενημερώνονται οι παράμετροι του δικτύου, στα αναδρομικά νευρωνικά δίκτυα εφαρμόζεται η παραλλαγή Backpropagation Through Time (BPTT), η οποία προσαρμόζει τη συμβατική οπισθοδιάδοση σε δεδομένα ακολουθιών. Για τον σκοπό αυτό, το αναδρομικό δίκτυο «ξεδιπλώνεται» κατά μήκος του χρόνου, μετατρέποντας την αναδρομική δομή σε μια ακολουθία διαδοχικών χρονικών βημάτων. Στη συνέχεια, οι κλίσεις της συνάρτησης απώλειας διαδίδονται προς τα πίσω κατά μήκος της χρονικής ακολουθίας, ενημερώνοντας τις κοινές παραμέτρους του δικτύου σε όλα τα χρονικά βήματα (Goodfellow et al., 2016; Géron, 2019).

Ωστόσο, η αποτελεσματική εκπαίδευση των συμβατικών RNNs (vanilla RNNs) περιορίζεται από το Πρόβλημα της Εξαφάνισης των Κλίσεων (Vanishing Gradient Problem). Το φαινόμενο αυτό εμφανίζεται όταν οι κλίσεις μειώνονται προοδευτικά καθώς διαδίδονται προς τα πίσω στα προηγούμενα χρονικά βήματα. Ως αποτέλεσμα, οι παράμετροι που σχετίζονται με παλαιότερες πληροφορίες λαμβάνουν ελάχιστο σήμα μάθησης, γεγονός που δυσχεραίνει την εκμάθηση μακροπρόθεσμων εξαρτήσεων (long-term dependencies). Η δυσκολία αυτή μελετήθηκε θεωρητικά από τους Bengio et al. (1994), οι οποίοι έδειξαν ότι τα αναδρομικά δίκτυα που εκπαιδεύονται με μεθόδους βασισμένες στην κλίση αντιμετωπίζουν θεμελιώδεις περιορισμούς όταν απαιτείται η διατήρηση πληροφοριών για μεγάλα χρονικά διαστήματα. Παράλληλα, μπορεί να εμφανιστεί και το αντίθετο φαινόμενο της έκρηξης των κλίσεων (Exploding Gradient Problem), κατά το οποίο οι κλίσεις αυξάνονται υπερβολικά και καθιστούν την εκπαίδευση ασταθή (Bengio et al., 1994; Goodfellow et al., 2016; Géron, 2019; Haykin, 2011).

Οι περιορισμοί αυτοί αποτέλεσαν βασικό κίνητρο για την ανάπτυξη βελτιωμένων αναδρομικών αρχιτεκτονικών. Ειδικότερα, τα δίκτυα Long Short-Term Memory (LSTM) σχεδιάστηκαν ώστε να διευκολύνουν τη διατήρηση πληροφορίας και τη ροή των κλίσεων σε μεγάλους χρονικούς ορίζοντες, αντιμετωπίζοντας ένα από τα σημαντικότερα μειονεκτήματα των συμβατικών RNNs (Goodfellow et al., 2016).

2.3.3.4. Δίκτυα Μακράς Βραχυπρόθεσμης Μνήμης (LSTM)

Τα δίκτυα Long Short-Term Memory (LSTM) αποτελούν εξειδικευμένη αρχιτεκτονική αναδρομικών νευρωνικών δικτύων (Recurrent Neural Networks – RNNs), η οποία αναπτύχθηκε από τους Hochreiter και Schmidhuber (1997) με στόχο την αντιμετώπιση των περιορισμών των συμβατικών RNNs κατά την εκμάθηση μακροπρόθεσμων χρονικών εξαρτήσεων. Ειδικότερα, η ανάπτυξη των LSTM υπαγορεύθηκε από το πρόβλημα της εξαφάνισης των κλίσεων (Vanishing Gradient Problem), το οποίο δυσχεραίνει τη διάδοση του σήματος μάθησης σε μεγάλες χρονικές ακολουθίες και περιορίζει την ικανότητα των συμβατικών RNNs να αξιοποιούν πληροφορία που προέρχεται από απομακρυσμένα χρονικά βήματα (Goodfellow et al., 2016; Chollet, 2018).

Σε αντίθεση με τα συμβατικά αναδρομικά δίκτυα, τα LSTM εισάγουν μία επιπλέον κατάσταση μνήμης, γνωστή ως κατάσταση κυψέλης (cell state), η οποία λειτουργεί παράλληλα με την κρυφή κατάσταση (hidden state). Η κατάσταση κυψέλης αποτελεί τον βασικό μηχανισμό διατήρησης της πληροφορίας σε μεγάλους χρονικούς ορίζοντες, ενώ η κρυφή κατάσταση χρησιμοποιείται κυρίως για την παραγωγή της εξόδου και τη μεταφορά βραχυπρόθεσμης πληροφορίας μεταξύ διαδοχικών χρονικών βημάτων. Με τον τρόπο αυτό, η πληροφορία μπορεί να διατηρείται και να μεταφέρεται αποτελεσματικότερα κατά μήκος της ακολουθίας, μειώνοντας την απώλεια σημαντικών χρονικών εξαρτήσεων (Géron, 2019; Chollet, 2018).

Η λειτουργία του LSTM βασίζεται σε έναν μηχανισμό πυλών (gating mechanism), μέσω του οποίου ελέγχεται δυναμικά η ροή της πληροφορίας μέσα στο δίκτυο. Οι πύλες χρησιμοποιούν κυρίως τη σιγμοειδή συνάρτηση ενεργοποίησης (sigmoid), ώστε να παράγουν τιμές μεταξύ 0 και 1, οι οποίες καθορίζουν ποιο ποσοστό της διαθέσιμης πληροφορίας θα διατηρηθεί, θα ενημερωθεί ή θα χρησιμοποιηθεί για την παραγωγή της εξόδου. Παράλληλα, η συνάρτηση υπερβολικής εφαπτομένης (tanh) χρησιμοποιείται για τη δημιουργία των νέων υπονήφιας τιμών της κατάστασης κυψέλης και για τον υπολογισμό της τελικής κρυφής κατάστασης (Goodfellow et al., 2016).

Η πρώτη από τις βασικές πύλες του LSTM είναι η πύλη λήθης (Forget Gate), η οποία καθορίζει ποια πληροφορία από την προηγούμενη κατάσταση κυψέλης θα διατηρηθεί και ποια θα απορριφθεί. Στη συνέχεια, η πύλη εισόδου (Input Gate) επιλέγει ποια νέα πληροφορία από την τρέχουσα είσοδο και την προηγούμενη κρυφή κατάσταση θα ενσωματωθεί στην κατάσταση κυψέλης, ενημερώνοντας την και, κατ' επέκταση, τη μακροπρόθεσμη μνήμη του μοντέλου. Τέλος, η πύλη εξόδου (Output Gate) καθορίζει ποιο μέρος της ενημερωμένης κατάστασης κυψέλης θα χρησιμοποιηθεί για την παραγωγή της νέας κρυφής κατάστασης, η οποία αποτελεί τόσο την έξοδο του δικτύου για το συγκεκριμένο χρονικό βήμα όσο και την είσοδο προς το επόμενο (Goodfellow et al., 2016; Géron, 2019).

Η λειτουργία μιας κυψέλης LSTM περιγράφεται με μαθηματικό τρόπο από ένα σύνολο εξισώσεων που καθορίζουν τον τρόπο με τον οποίο ενημερώνεται η κατάσταση κυψέλης και παράγεται η νέα κρυφή κατάσταση σε κάθε χρονικό βήμα. Αρχικά, η τρέχουσα είσοδος x_t και η προηγούμενη κρυφή κατάσταση h_{t-1} χρησιμοποιούνται για τον υπολογισμό των τριών πυλών του μοντέλου μέσω της σιγμοειδούς συνάρτησης ενεργοποίησης:

Για την πύλη εισόδου: $i_t = \sigma(W_{xi}^T x_t + W_{hi}^T h_{t-1} + b_i),$

Για την πύλη λήθης: $f_t = \sigma(W_{xf}^T x_t + W_{hf}^T h_{t-1} + b_f),$

Για την πύλη εξόδου: $o_t = \sigma(W_{xo}^T x_t + W_{ho}^T h_{t-1} + b_o)$

Παράλληλα, υπολογίζεται η υπονήφια τιμή της κατάστασης κυψέλης (Candidate Cell State), η οποία περιέχει τη νέα πληροφορία που μπορεί να ενσωματωθεί στη μακροπρόθεσμη μνήμη του δικτύου:

$$g_t = \tanh(W_{xg}^T x_t + W_{hg}^T h_{t-1} + b_g),$$

Η κατάσταση κυψέλης ενημερώνεται συνδυάζοντας την πληροφορία που διατηρείται μέσω της πύλης λήθης με τη νέα πληροφορία που επιλέγεται από την πύλη εισόδου, όπου το σύμβολο $\odot$ δηλώνει στοιχειομετρικό (Hadamard) πολλαπλασιασμό:

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t,$$

Τέλος, η πύλη εξόδου καθορίζει ποιο μέρος της ενημερωμένης κατάστασης κυψέλης θα χρησιμοποιηθεί για την παραγωγή της νέας κρυφής κατάστασης,

$$h_t = o_t \odot \tanh(c_t).$$

Στις παραπάνω εξισώσεις, οι πίνακες W αντιστοιχούν στα βάρη που συνδέουν την τρέχουσα είσοδο και την προηγούμενη κρυφή κατάσταση με κάθε πύλη, τα b αποτελούν τους αντίστοιχους όρους μετατόπισης (biases), η συνάρτηση $\sigma(\cdot)$ είναι η σιγμοειδής (sigmoid) συνάρτηση ενεργοποίησης και η $\tanh(\cdot)$ η συνάρτηση υπερβολικής εφαπτομένης. Οι πύλες χρησιμοποιούν τη σιγμοειδή συνάρτηση ώστε να παράγουν τιμές στο διάστημα $[0, 1]$, οι οποίες λειτουργούν ως συντελεστές που ελέγχουν τη ροή της πληροφορίας. Τιμές κοντά στο 0 περιορίζουν σημαντικά τη διέλευση της πληροφορίας από την πύλη, ενώ τιμές κοντά στο 1 επιτρέπουν τη σχεδόν πλήρη διατήρησή της και τη μετάδοσή της, ρυθμίζοντας δυναμικά τη ροή της πληροφορίας μέσα στο δίκτυο. Η συνάρτηση υπερβολικής εφαπτομένης $\tanh$ χρησιμοποιείται τόσο για τον υπολογισμό της υποψήφιας κατάστασης κυψέλης g_t , ώστε να δημιουργούνται νέες υποψήφιας τιμές που μπορούν να ενσωματωθούν στην κατάσταση κυψέλης, όσο και για την παραγωγή της νέας κρυφής κατάστασης h_t . Οι δείκτες i , f , o και g αναφέρονται αντίστοιχα στην πύλη εισόδου, την πύλη λήθης, την πύλη εξόδου και την υποψήφια κατάσταση κυψέλης (Géron, 2019; Goodfellow et al., 2016).

Η σημαντικότερη καινοτομία της αρχιτεκτονικής LSTM είναι η εισαγωγή αυτοβρόχων (self-loops) στην κατάσταση κυψέλης, οι οποίοι δημιουργούν διαδρομές μέσω των οποίων οι κλίσεις μπορούν να διαδοθούν αποτελεσματικότερα κατά την εκπαίδευση. Η σχεδίαση αυτή διευκολύνει τη ροή των κλίσεων σε μεγάλες χρονικές ακολουθίες, επιτρέποντας στο δίκτυο να μαθαίνει αποτελεσματικότερα μακροπρόθεσμες χρονικές εξαρτήσεις και να μετριάξει το πρόβλημα της εξαφάνισης των κλίσεων σε σύγκριση με τα συμβατικά RNNs (Goodfellow et al., 2016). Οι ιδιότητες αυτές έχουν οδηγήσει στην ευρεία εφαρμογή των LSTM σε πλήθος προβλημάτων ακολουθιακής μοντελοποίησης, όπου οι τρέχουσες τιμές επηρεάζονται από γεγονότα που έχουν συμβεί αρκετά βήματα νωρίτερα, όπως η αναγνώριση ομιλίας, η μηχανική μετάφραση, η επεξεργασία φυσικής γλώσσας και η πρόβλεψη χρονοσειρών, συμπεριλαμβανομένης και της εφαρμογής τους σε προβλήματα πρόβλεψης ηλεκτρικού φορτίου. Στον τομέα της πρόβλεψης ηλεκτρικού φορτίου, τα LSTM αποτελούν μία από τις πλέον διαδεδομένες αρχιτεκτονικές βαθιάς μάθησης, καθώς έχουν χρησιμοποιηθεί εκτενώς στη βιβλιογραφία και παρουσιάζουν υψηλή προγνωστική ακρίβεια σε προβλήματα βραχυπρόθεσμης πρόβλεψης (Goodfellow et al., 2016; Nti et al., 2020; Mystakidis et al., 2024). Πλεονεκτήματα των LSTM είναι η ικανότητα μοντελοποίησης τόσο βραχυπρόθεσμων όσο και μακροπρόθεσμων χρονικών εξαρτήσεων, η αποτελεσματική διατήρηση σημαντικής πληροφορίας από προηγούμενες χρονικές στιγμές και η καταλληλότητά τους για την πρόβλεψη πολύπλοκων χρονικών προτύπων σε δεδομένα χρονοσειρών (Cordeiro-Costas et al., 2023).

Παρά τα σημαντικά πλεονεκτήματά τους, τα LSTM παρουσιάζουν μεγαλύτερη αρχιτεκτονική πολυπλοκότητα και διαθέτουν περισσότερες παραμέτρους σε σύγκριση με τα συμβατικά RNNs, γεγονός που αυξάνει τις απαιτήσεις σε υπολογιστικούς πόρους και χρόνο εκπαίδευσης. Επιπλέον, η απόδοσή τους εξαρτάται σε σημαντικό βαθμό από την κατάλληλη επιλογή των υπερπαραμέτρων και της αρχιτεκτονικής του δικτύου, ενώ σε ορισμένες εφαρμογές απλούστερες παραλλαγές των gated RNNs, όπως τα δίκτυα GRU, μπορούν να επιτύχουν παρόμοια προγνωστική απόδοση με μικρότερο υπολογιστικό κόστος (Chollet, 2018; Géron, 2019).

2.3.3.5. Δίκτυα Πυλών Επαναφοράς (GRU)

Τα Δίκτυα Πυλών Επαναφοράς (Gated Recurrent Units – GRUs) αποτελούν απλουστευμένη παραλλαγή των δικτύων Long Short-Term Memory (LSTM), η οποία αναπτύχθηκε για την αντιμετώπιση των ίδιων περιορισμών των συμβατικών αναδρομικών

νευρωνικών δικτύων (RNNs), κυρίως του προβλήματος της εξαφάνισης των κλίσεων κατά την εκπαίδευση μεγάλων ακολουθιών. Όπως και τα LSTM, τα GRUs ανήκουν στην κατηγορία των gated recurrent networks, δημιουργώντας διαδρομές μέσω των οποίων οι κλίσεις μπορούν να διαδοθούν αποτελεσματικότερα σε μεγάλα χρονικά διαστήματα (Goodfellow et al., 2016).

Σε αντίθεση με τα LSTM, τα GRUs δεν διαθέτουν ξεχωριστή κατάσταση κυψέλης (cell state), αλλά συγχωνεύουν τη μακροπρόθεσμη και τη βραχυπρόθεσμη πληροφορία σε μία ενιαία κρυφή κατάσταση (hidden state). Η λειτουργία τους βασίζεται σε δύο μόνο πύλες, την πύλη ενημέρωσης (update gate) και την πύλη επαναφοράς (reset gate), γεγονός που οδηγεί σε απλούστερη αρχιτεκτονική και μικρότερο αριθμό παραμέτρων σε σύγκριση με τα LSTM. Ως αποτέλεσμα, τα GRUs είναι γενικά λιγότερο υπολογιστικά απαιτητικά, ενώ σε πολλές εφαρμογές παρουσιάζουν συγκρίσιμη προγνωστική απόδοση με τα LSTM. Ωστόσο, η υπάρχουσα βιβλιογραφία δεν καταλήγει ότι κάποια από τις δύο αρχιτεκτονικές υπερέχει σταθερά έναντι της άλλης, καθώς η απόδοσή τους εξαρτάται από τα χαρακτηριστικά του εκάστοτε προβλήματος και των διαθέσιμων δεδομένων (Goodfellow et al., 2016; Géron, 2019; Chollet, 2018). Παρά τη μικρότερη αρχιτεκτονική τους πολυπλοκότητα, τα GRUs αποτελούν μία από τις πλέον διαδεδομένες αρχιτεκτονικές βαθιάς μάθησης στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου, ενώ αρκετές μελέτες αναφέρουν προγνωστική απόδοση συγκρίσιμη με εκείνη των δικτύων LSTM, με χαμηλότερες υπολογιστικές απαιτήσεις σε ορισμένες εφαρμογές (Chandrasekaran & Paramasivan, 2025; Moustakidis et al., 2024; Misiurek et al., 2025).

2.3.3.6. Συνελικτικά νευρωνικά δίκτυα (CNN)

Τα συνελικτικά νευρωνικά δίκτυα (Convolutional Neural Networks – CNNs) αποτελούν εξειδικευμένη κατηγορία νευρωνικών δικτύων που αναπτύχθηκαν για την επεξεργασία δεδομένων με δομή πλέγματος (grid-like topology), όπως οι εικόνες και οι χρονοσειρές. Στην περίπτωση των χρονοσειρών, τα δεδομένα μπορούν να θεωρηθούν ως μονοδιάστατο πλέγμα διαδοχικών χρονικών παρατηρήσεων. Τα CNNs βασίζονται στη μαθηματική πράξη της συνέλιξης (convolution), κατά την οποία μικρά φίλτρα (kernels) εφαρμόζονται διαδοχικά πάνω στα δεδομένα με στόχο την εξαγωγή τοπικών χαρακτηριστικών και χρονικών προτύπων. Η αρχιτεκτονική αυτή αξιοποιεί την τοπική συνδεσιμότητα (local connectivity) και τον διαμοιρασμό παραμέτρων (parameter sharing), επιτρέποντας την αποτελεσματική εκμάθηση τοπικών χρονικών εξαρτήσεων με σημαντικά μικρότερο αριθμό παραμέτρων σε σύγκριση με τα πλήρως συνδεδεμένα νευρωνικά δίκτυα (Goodfellow et al., 2016; Géron, 2019).

Μετά από ένα ή περισσότερα συνελικτικά επίπεδα εφαρμόζονται συχνά επίπεδα συγκέντρωσης (pooling layers), τα οποία συνοψίζουν τις τοπικές πληροφορίες των παραγόμενων χαρτών χαρακτηριστικών (feature maps), μειώνοντας τη διάσταση των δεδομένων και τις υπολογιστικές απαιτήσεις του δικτύου (Goodfellow et al., 2016; Géron, 2019). Τα μονοδιάστατα CNNs έχουν χρησιμοποιηθεί επιτυχώς σε προβλήματα επεξεργασίας ακολουθιακών δεδομένων και πρόβλεψης χρονοσειρών, καθώς μπορούν να λειτουργήσουν ως αποδοτική εναλλακτική ή συμπληρωματική προσέγγιση των αναδρομικών νευρωνικών δικτύων για την εκμάθηση τοπικών χρονικών προτύπων (Chollet, 2018). Πλεονεκτήματα της μεθόδου είναι η αποτελεσματική εξαγωγή χαρακτηριστικών από χρονοσειρές, η δυνατότητα μοντελοποίησης χρονικών εξαρτήσεων σε διαφορετικές χρονικές κλίμακες και η ανθεκτικότητα στον θόρυβο μέσω του φιλτραρίσματος μη χρήσιμων προτύπων. Επιπλέον, μπορεί να επεξεργαστεί ακολουθίες

μεταβλητού μήκους και να διευκολύνει την κατανόηση των προτύπων που συμβάλλουν στις προβλέψεις της κατανάλωσης ηλεκτρικής ενέργειας (Cordeiro-Costas et al., 2023).

2.3.4. Σύγχρονες και υβριδικές μέθοδοι και μέθοδοι συνόλων

2.3.4.1. Μοντέλα βασισμένα σε Transformers

Τα τελευταία χρόνια, οι αρχιτεκτονικές Transformer έχουν αναδειχθεί ως μία από τις σημαντικότερες εξελίξεις στον χώρο της βαθιάς μάθησης. Σε αντίθεση με τα αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Networks - RNNs), τα οποία επεξεργάζονται τις χρονικές ακολουθίες διαδοχικά, οι Transformers βασίζονται στον μηχανισμό self-attention, ο οποίος επιτρέπει την ταυτόχρονη επεξεργασία όλων των στοιχείων μιας ακολουθίας. Η προσέγγιση αυτή διευκολύνει την αποτελεσματική εκμάθηση τόσο βραχυπρόθεσμων όσο και μακροπρόθεσμων εξαρτήσεων μεταξύ των δεδομένων, ενώ παράλληλα επιτρέπει την παραλληλοποίηση της διαδικασίας εκπαίδευσης, μειώνοντας σημαντικά τον χρόνο εκπαίδευσης σε μεγάλα σύνολα δεδομένων (Vaswani et al., 2017; Misiurek et al., 2025). Ο βασικός μηχανισμός attention περιγράφεται από τη σχέση:

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

όπου τα Queries (Q), Keys (K) και Values (V) αποτελούν διαφορετικές αναπαραστάσεις των δεδομένων εισόδου, μέσω των οποίων υπολογίζεται η σχετική σημασία κάθε στοιχείου της ακολουθίας. Η διαίρεση με διαίρεση με $\sqrt{d_k}$ περιορίζει την εμφάνιση πολύ μεγάλων τιμών πριν από την εφαρμογή της συνάρτησης softmax, συμβάλλοντας στη σταθερότητα της εκπαίδευσης (Vaswani et al., 2017).

Μία από τις σημαντικότερες εξειδικευμένες αρχιτεκτονικές Transformer για εφαρμογές πρόβλεψης χρονοσειρών είναι το Temporal Fusion Transformer (TFT). Η αρχιτεκτονική αυτή συνδυάζει μηχανισμούς attention με Gated Residual Networks, μηχανισμούς επιλογής μεταβλητών (Variable Selection Networks) και δυνατότητα πιθανοτικής πρόβλεψης πολλαπλών χρονικών οριζόντων (multi-horizon forecasting), επιτρέποντας παράλληλα την ερμηνεία της σχετικής συμβολής των μεταβλητών στις παραγόμενες προβλέψεις (Lim et al., 2021).

Οι αρχιτεκτονικές Transformer εφαρμόζονται ολοένα και συχνότερα σε προβλήματα πρόβλεψης ενεργειακής ζήτησης, όπως η πρόβλεψη ηλεκτρικού φορτίου σε επίπεδο πόλης, η διαχείριση της ζήτησης φόρτισης ηλεκτρικών οχημάτων και άλλες σύνθετες εφαρμογές ενεργειακών συστημάτων, όπου η ύπαρξη μεγάλων όγκων δεδομένων επιτρέπει την αξιοποίηση των πλεονεκτημάτων τους (Misiurek et al., 2025; Chandrasekaran & Paramasivan, 2025).

Παρά τη σημαντική ερευνητική τους δυναμική, οι Transformers απαιτούν συνήθως μεγαλύτερους όγκους δεδομένων και αυξημένους υπολογιστικούς πόρους σε σύγκριση με απλούστερες αρχιτεκτονικές, όπως τα αναδρομικά νευρωνικά δίκτυα ή τα παραδοσιακά μοντέλα μηχανικής μάθησης. Επιπλέον, η αποτελεσματική εκπαίδευσή τους προϋποθέτει κατάλληλη κανονικοποίηση (regularization) και προσεκτική επιλογή των υπερπαραμέτρων, ώστε να περιορίζεται ο κίνδυνος υπερεκπαίδευσης (Lim et al., 2021; Misiurek et al., 2025). Ωστόσο, η συνεχώς αυξανόμενη διαθεσιμότητα δεδομένων από έξυπνα δίκτυα, έξυπνους μετρητές και προηγμένες υποδομές μέτρησης αναμένεται να ενισχύσει περαιτέρω τη χρήση των αρχιτεκτονικών αυτών στις εφαρμογές πρόβλεψης ηλεκτρικού φορτίου (Mystakidis et al., 2024; Misiurek et al., 2025).

Τέλος, παρότι οι μηχανισμοί attention μπορούν να παρέχουν χρήσιμες ενδείξεις σχετικά με τα χρονικά σημεία ή τις μεταβλητές στις οποίες εστιάζει το μοντέλο κατά την παραγωγή των προβλέψεων, οι τιμές των attention weights δεν πρέπει να ερμηνεύονται αυτόματα ως

ένδειξη αιτιώδους σχέσης ή πραγματικής σημασίας των μεταβλητών, αλλά ως εργαλείο υποστήριξης της ερμηνείας του μοντέλου (Lim et al., 2021).

2.3.4.2. Μέθοδοι Συνόλων (Ensemble Methods)

Οι μέθοδοι συνόλων (ensemble methods) βασίζονται στον συνδυασμό πολλαπλών επιμέρους μοντέλων πρόβλεψης (predictors), με στόχο τη δημιουργία ενός τελικού μοντέλου με μεγαλύτερη προγνωστική ακρίβεια από οποιοδήποτε επιμέρους μοντέλο. Η βασική ιδέα είναι ότι διαφορετικά μοντέλα ενδέχεται να παρουσιάζουν διαφορετικά σφάλματα πρόβλεψης· επομένως, ο κατάλληλος συνδυασμός των επιμέρους προβλέψεων τους μπορεί να μειώσει τη διακύμανση, τη μεροληψία ή και τα δύο, οδηγώντας σε βελτιωμένη ικανότητα γενίκευσης και υψηλότερη προγνωστική ακρίβεια (Géron, 2019; Bishop, 2016).

2.3.4.2.1. Bagging & Pasting

Οι μέθοδοι bagging και pasting αποτελούν μεθόδους συνόλου που βασίζονται στην εκπαίδευση πολλαπλών ίδιων μοντέλων σε διαφορετικά υποσύνολα των δεδομένων εκπαίδευσης. Στην περίπτωση του bagging (bootstrap aggregating), η δειγματοληψία πραγματοποιείται με επανάθεση, ενώ στο pasting χωρίς επανάθεση. Μετά την εκπαίδευση, οι προβλέψεις των επιμέρους μοντέλων συνδυάζονται μέσω πλειοψηφικής ψήφου στα προβλήματα ταξινόμησης ή μέσω υπολογισμού του μέσου όρου των προβλέψεων στα προβλήματα παλινδρόμησης. Η διαδικασία αυτή οδηγεί σε μείωση της διακύμανσης του τελικού μοντέλου και βελτίωση της σταθερότητας των προβλέψεων σε σχέση με ένα μεμονωμένο μοντέλο. Για παράδειγμα, τα Random Forests που παρουσιάζονται στην ενότητα 2.3.2.5 υλοποιούνται μέσω της εκπαίδευσης πολλαπλών δέντρων απόφασης σε διαφορετικά τυχαία υποσύνολα των δεδομένων εκπαίδευσης και συνεπώς θεωρούνται λιγότερο επιρρεπή στην υπερπροσαρμογή σε σχέση με ένα μεμονωμένο δέντρο απόφασης. (Bishop, 2016; Géron, 2019; Hastie et al., 2009)

2.3.4.2.2. Boosting

Το boosting αποτελεί μέθοδο συνόλου κατά την οποία πολλαπλά ασθενή μοντέλα πρόβλεψης (weak learners) εκπαιδεύονται διαδοχικά, με κάθε νέο μοντέλο να εστιάζει στη διόρθωση των σφαλμάτων των προηγούμενων. Με τον τρόπο αυτό, το τελικό μοντέλο βελτιώνεται σταδιακά, μειώνοντας το συνολικό σφάλμα πρόβλεψης. Η προσέγγιση αυτή οδηγεί στη δημιουργία ισχυρών προβλεπτικών μοντέλων και αποτελεί τη βάση σύγχρονων αλγορίθμων, όπως το Gradient Boosting και το XGBoost που αναλύονται στην ενότητα 2.3.2.6. (Bishop, 2016; Géron, 2019)

2.3.4.2.3. Stacking

Το stacking αποτελεί μέθοδο συνόλου κατά την οποία οι προβλέψεις πολλαπλών βασικών μοντέλων χρησιμοποιούνται ως είσοδοι σε ένα μετα-μοντέλο (meta-model), το οποίο μαθαίνει να συνδυάζει τις επιμέρους προβλέψεις και να παράγει την τελική εκτίμηση. (Alpaydm, 2020; Géron, 2019)

2.3.4.3. Υβριδικά Συστήματα Πρόβλεψης

Η αυξανόμενη πολυπλοκότητα των προβλημάτων βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου έχει ενισχύσει το ενδιαφέρον για υβριδικές μεθόδους, οι οποίες συνδυάζουν διαφορετικούς τύπους μοντέλων ή τεχνικών, όπως στατιστικές μεθόδους, αλγορίθμους

μηχανικής μάθησης και αρχιτεκτονικές βαθιάς μάθησης, με στόχο την αξιοποίηση των συμπληρωματικών πλεονεκτημάτων κάθε προσέγγισης. Η βασική τους φιλοσοφία είναι ότι διαφορετικά μοντέλα μπορούν να αναλάβουν διαφορετικά στάδια της επεξεργασίας των δεδομένων, με αποτέλεσμα ο συνδυασμός τους να επιτυγχάνει συχνά υψηλότερη προγνωστική απόδοση από ό,τι κάθε μοντέλο μεμονωμένα (Azeem et al., 2021; Mystakidis et al., 2024).

Χαρακτηριστικό παράδειγμα υβριδικής προσέγγισης στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου αποτελούν οι αρχιτεκτονικές CNN–LSTM, στις οποίες τα συνελκτικά νευρωνικά δίκτυα (Convolutional Neural Networks – CNN) χρησιμοποιούνται για την εξαγωγή τοπικών χαρακτηριστικών και χρονικών προτύπων από τις χρονοσειρές, ενώ τα δίκτυα Long Short-Term Memory (LSTM) αναλαμβάνουν τη μοντελοποίηση των χρονικών εξαρτήσεων. Με τον τρόπο αυτό επιτυγχάνεται αποτελεσματικότερη αναπαράσταση τόσο των τοπικών προτύπων όσο και των μακροχρόνιων χρονικών εξαρτήσεων των δεδομένων. Πρόσφατες ανασκοπήσεις αναφέρουν ότι ο συνδυασμός διαφορετικών αρχιτεκτονικών μπορεί να ενισχύσει την ικανότητα γενίκευσης και να οδηγήσει σε υψηλότερη προγνωστική ακρίβεια σε σύγκριση με μεμονωμένα μοντέλα (Mystakidis et al., 2024; Misiurek et al., 2025; Tefera et al., 2025).

Παρά τα πλεονεκτήματά τους, οι υβριδικές αρχιτεκτονικές συνοδεύονται συχνά από αυξημένη υπολογιστική πολυπλοκότητα, μεγαλύτερο αριθμό υπερπαραμέτρων και υψηλότερες απαιτήσεις σε χρόνο εκπαίδευσης και υπολογιστικούς πόρους. Επιπλέον, η αυξημένη πολυπλοκότητα των αρχιτεκτονικών αυτών μπορεί να δυσχεράνει τόσο τη διαδικασία βελτιστοποίησης όσο και την ερμηνεία του τρόπου με τον οποίο παράγονται οι προβλέψεις, περιορίζοντας την ερμηνευσιμότητα των μοντέλων (Mystakidis et al., 2024; Misiurek et al., 2025).

2.4. Πιθανοτική πρόβλεψη και αβεβαιότητα

Στις περισσότερες εφαρμογές πρόβλεψης ηλεκτρικού φορτίου, τα μοντέλα παράγουν σημειακές προβλέψεις (point forecasts), δηλαδή μία μοναδική εκτίμηση της μελλοντικής τιμής του φορτίου. Ωστόσο, στην πράξη η μελλοντική ζήτηση επηρεάζεται από αβεβαιότητες που σχετίζονται με τις καιρικές συνθήκες, τις ανθρώπινες δραστηριότητες, τη λειτουργία των ενεργειακών συστημάτων και άλλους εξωγενείς παράγοντες. Για τον λόγο αυτό, τα τελευταία χρόνια έχει αυξηθεί το ερευνητικό ενδιαφέρον για την πιθανοτική πρόβλεψη (probabilistic forecasting), η οποία εκτιμά όχι μόνο την αναμενόμενη τιμή αλλά και την αβεβαιότητα που τη συνοδεύει (Hong & Fan, 2016).

Η πιθανοτική πρόβλεψη μπορεί να υλοποιηθεί με διάφορες προσεγγίσεις, όπως η ποσοστιαία παλινδρόμηση (quantile regression), τα σύνολα μοντέλων (ensembles), η Gaussian Process Regression (GPR) και εξειδικευμένες αρχιτεκτονικές βαθιάς μάθησης που παράγουν διαστήματα πρόβλεψης ή πολλαπλά ποσοστημόρια (quantiles). Στο πεδίο της πρόβλεψης ηλεκτρικού φορτίου λιμένων, αξίζει να αναφερθεί η GPR καθώς έχει εφαρμοστεί επιτυχώς, παρουσιάζοντας ανταγωνιστική προγνωστική απόδοση έναντι καθιερωμένων μεθόδων μηχανικής μάθησης σε μεσαίου μεγέθους σύνολα δεδομένων (Micallef et al., 2025). Η GPR αποτελεί μία μη παραμετρική πιθανοτική μέθοδο, η οποία παρέχει τόσο τη σημειακή πρόβλεψη όσο και εκτίμηση της αβεβαιότητάς της μέσω της προβλεπτικής κατανομής, ενώ η απόδοσή της εξαρτάται σε μεγάλο βαθμό από την επιλογή της συνάρτησης πυρήνα (kernel). Παρά τη μεγάλη ευελιξία της, η υπολογιστική πολυπλοκότητά της περιορίζει την εφαρμογή της σε πολύ μεγάλα σύνολα δεδομένων (Rasmussen & Williams, 2006). Η αξιολόγηση τέτοιων μοντέλων βασίζεται σε δείκτες όπως το Pinball Loss και η κάλυψη (coverage) των διαστημάτων πρόβλεψης, οι οποίοι

συμπληρώνουν τους κλασικούς δείκτες σφάλματος που χρησιμοποιούνται στις σημειακές προβλέψεις (Gneiting & Raftery, 2007; Hong & Fan, 2016).

2.5. Θεμελιώδεις Αρχές Εκπαίδευσης Αλγορίθμων Μηχανικής Μάθησης

Στην επιβλεπόμενη μάθηση, ένας αλγόριθμος μηχανικής μάθησης επιδιώκει να εκμάθει μια συνάρτηση, η οποία αντιστοιχίζει τα δεδομένα εισόδου στις επιθυμητές εξόδους, με στόχο την ελαχιστοποίηση του μέσου σφάλματος πρόβλεψης στο σύνολο των δεδομένων εκπαίδευσης (Qin, 2020). Πιο τυπικά, η διαδικασία μάθησης μπορεί να διατυπωθεί ως πρόβλημα βελτιστοποίησης της μορφής:

$$\min_{f \in \mathcal{F}} \frac{1}{|D|} \sum_{(x,y) \in D} l(f(x), y)$$

όπου D είναι το σύνολο εκπαίδευσης, $\mathcal{F}$ ο χώρος των πιθανών συναρτήσεων ή μοντέλων που μπορεί να επιλέξει ο αλγόριθμος, και $l(f(x), y)$ η συνάρτηση απώλειας (loss function), η οποία ποσοτικοποιεί τη διαφορά μεταξύ της πραγματικής τιμής y και της πρόβλεψης $\hat{y} = f(x)$ του μοντέλου. Η διαδικασία μάθησης απαιτεί επίσης έναν αλγόριθμο βελτιστοποίησης (optimizer), ο οποίος χρησιμοποιείται για την επίλυση του προβλήματος ελαχιστοποίησης της συνάρτησης απώλειας μέσω της προσαρμογής των παραμέτρων του μοντέλου.

2.5.1. Συνάρτηση Απώλειας και Πρόβλημα Βελτιστοποίησης

Η συνάρτηση απώλειας αποτυπώνει αριθμητικά την απόκλιση μεταξύ των προβλέψεων του μοντέλου και των πραγματικών τιμών. Η συνάρτηση απώλειας εξαρτάται από το είδος του προβλήματος που προσεγγίζεται και του μοντέλου που χρησιμοποιείται. Στα προβλήματα παλινδρόμησης χρησιμοποιείται συχνά το μέσο τετραγωνικό σφάλμα (Mean Squared Error – MSE), ενώ σε προβλήματα ταξινόμησης εφαρμόζονται συναρτήσεις όπως η λογαριθμική απώλεια (log-loss) ή η hinge loss στις μηχανές διανυσμάτων υποστήριξης (support vector machines - SVMs) (Goodfellow et al., 2016; Géron, 2019).

Για την ελαχιστοποίηση της συνάρτησης απώλειας έχουν αναπτυχθεί διαφορετικοί αλγόριθμοι βελτιστοποίησης, ανάλογα με τη φύση του μοντέλου και του προβλήματος. Στα νευρωνικά δίκτυα χρησιμοποιούνται ευρέως παραλλαγές της στοχαστικής κατάβασης κλίσης (stochastic gradient descent), όπως οι Adam και AdaGrad, ενώ σε μεθόδους ενίσχυσης δέντρων, όπως το XGBoost, εφαρμόζονται εξειδικευμένες διαδικασίες επαναληπτικής βελτιστοποίησης.

2.5.2. Οπισθοδιάδοση Σφάλματος και Κατάβαση Κλίσης κατά την εκπαίδευση νευρωνικών δικτύων (Backpropagation of Error & Gradient Descent)

2.5.2.1. Οπισθοδιάδοση του Σφάλματος (Backpropagation of error)

Η εκπαίδευση ενός τεχνητού νευρωνικού δικτύου βασίζεται στην επαναλαμβανόμενη εκτέλεση δύο διαδοχικών φάσεων: του ευθέως περάσματος (forward pass) και του οπίσθιου περάσματος (backward pass). Σύμφωνα με τους Goodfellow et al. (2016) και Géron (2019), η οπισθοδιάδοση του σφάλματος (backpropagation) αποτελεί τον αλγόριθμο που επιτρέπει τον αποδοτικό υπολογισμό των κλίσεων της συνάρτησης απώλειας ως προς τις εκπαιδευσιμες παραμέτρους του δικτύου και αποτελεί τη θεμελιώδη διαδικασία εκπαίδευσης των σύγχρονων νευρωνικών δικτύων.

Κατά το ευθύ πέρασμα (forward pass), τα δεδομένα εισόδου διαδίδονται διαδοχικά μέσω των επιπέδων του δικτύου μέχρι την παραγωγή της τελικής πρόβλεψης. Στη συνέχεια, η πρόβλεψη συγκρίνεται με την πραγματική τιμή-στόχο μέσω μιας συνάρτησης απώλειας, η οποία ποσοτικοποιεί την απόκλιση μεταξύ της προβλεπόμενης τιμής και της πραγματικής τιμής στόχου (target). Η συνάρτηση αυτή λειτουργεί ως το μέτρο αξιολόγησης της απόδοσης του δικτύου για το συγκεκριμένο δείγμα ή ομάδα δειγμάτων (batch). Ο υπολογισμός της απώλειας είναι κρίσιμος, καθώς η τιμή αυτή αποτελεί την αφετηρία για τον προσδιορισμό των απαραίτητων διορθώσεων στις παραμέτρους του μοντέλου (Géron, 2019; Goodfellow et al., 2016).

Το οπίσθιο πέρασμα αποτελεί την ουσία του αλγορίθμου οπισθοδιάδοσης. Σε αυτή τη φάση, η πληροφορία του σφάλματος διαδίδεται αντίστροφα, από την έξοδο προς τα προηγούμενα επίπεδα του δικτύου. Η διαδικασία αυτή βασίζεται στον κανόνα της αλυσίδας (chain rule) του διαφορικού λογισμού (Goodfellow et al., 2016) και επιτρέπει τον υπολογισμό των μερικών παραγώγων της συνάρτησης απώλειας ως προς κάθε ενδιαμέση μεταβλητή και τελικά ως προς τα βάρη και τις πολώσεις κάθε επιπέδου, επιτρέποντας τον προσδιορισμό της συμβολής κάθε παραμέτρου στο συνολικό σφάλμα. Κατά την οπισθοδιάδοση υπολογίζεται η κλίση (gradient), η οποία είναι ένα διάνυσμα που υποδεικνύει την κατεύθυνση στην οποία η συνάρτηση απώλειας παρουσιάζει τη μέγιστη αύξηση (Géron, 2019).

Είναι σημαντικό να σημειωθεί ότι η οπισθοδιάδοση δεν τροποποιεί άμεσα τις παραμέτρους του μοντέλου. Ο ρόλος της περιορίζεται στον υπολογισμό των κλίσεων της συνάρτησης απώλειας. Η προσαρμογή των βαρών πραγματοποιείται στη συνέχεια από τον αλγόριθμο βελτιστοποίησης (optimizer), ο οποίος χρησιμοποιεί τις υπολογισμένες από την οπισθοδιάδοση κλίσεις και εφαρμόζει έναν κανόνα για την ενημέρωση των παραμέτρων ώστε να μειωθεί η τιμή της απώλειας σύμφωνα με τη μέθοδο βελτιστοποίησης που έχει επιλεγεί, με τη βασικότερη προσέγγιση να αποτελεί τη μέθοδο της κατάβασης κλίσης (Gradient Descent), η οποία παρουσιάζεται στην επόμενη ενότητα. Επομένως, η συνάρτηση απώλειας, οι κλίσεις και ο αλγόριθμος βελτιστοποίησης αποτελούν διακριτές αλλά αλληλένδετες συνιστώσες της διαδικασίας εκπαίδευσης (Géron, 2019).

Η οπισθοδιάδοση καθιστά εφικτή την εφαρμογή της μεθόδου της κλίσης σε πολυεπίπεδα νευρωνικά δίκτυα με μεγάλο αριθμό παραμέτρων. Στην περίπτωση των επαναλαμβανόμενων νευρωνικών δικτύων (Recurrent Neural Networks – RNNs), η ίδια βασική αρχή επεκτείνεται μέσω της Οπισθοδιάδοσης μέσω του Χρόνου (Backpropagation Through Time – BPTT), κατά την οποία οι κλίσεις υπολογίζονται κατά μήκος των διαδοχικών χρονικών βημάτων μιας ακολουθίας (Goodfellow et al., 2016).

2.5.2.2. Μέθοδος της Κατάβασης Κλίσης (Gradient Descent)

Η στρατηγική που χρησιμοποιείται για την εύρεση του ελαχίστου της συνάρτησης κόστους βασίζεται στην έννοια της κλίσης (gradient). Η κλίση της συνάρτησης κόστους ως προς τις παραμέτρους του μοντέλου συμβολίζεται ως

$$\nabla_{\theta} J(\theta)$$

και αποτελεί διάνυσμα που περιλαμβάνει τις μερικές παραγώγους της συνάρτησης κόστους ως προς κάθε παράμετρο του μοντέλου. Η κλίση υποδεικνύει την κατεύθυνση της ταχύτερης τοπικής αύξησης της συνάρτησης κόστους στο τρέχον σημείο των παραμέτρων. Κατά συνέπεια, η μεταβολή των παραμέτρων προς την αντίθετη κατεύθυνση, δηλαδή προς την αρνητική κλίση, υποδεικνύει την κατεύθυνση της ταχύτερης τοπικής μείωσης της συνάρτησης κόστους. Η πραγματική μεταβολή της συνάρτησης κόστους εξαρτάται παράλληλα και από τον επιλεγμένο ρυθμό μάθησης (Goodfellow et al., 2016; Géron, 2019).

Αφού υπολογιστούν οι κλίσεις μέσω της οπισθοδιάδοσης, οι παράμετροι του μοντέλου ενημερώνονται επαναληπτικά σύμφωνα με τη μέθοδο της κατάβασης κλίσης. Ο μηχανισμός ενημέρωσης των παραμέτρων υλοποιείται επαναληπτικά σύμφωνα με τη σχέση:

$$\theta^{(t+1)} = \theta^{(t)} - \eta \nabla_{\theta} J(\theta^{(t)})$$

όπου:

- $\theta^{(t)}$ είναι το διάνυσμα των παραμέτρων κατά την επανάληψη t ,
- $\theta^{(t+1)}$ είναι οι ενημερωμένες παράμετροι μετά την επόμενη επανάληψη,
- η είναι ο ρυθμός μάθησης (learning rate),
- $\nabla_{\theta} J(\theta^{(t)})$ είναι η κλίση της συνάρτησης κόστους ως προς τις παραμέτρους του μοντέλου.

Ο ρυθμός μάθησης αποτελεί μία από τις σημαντικότερες υπερπαραμέτρους της διαδικασίας εκπαίδευσης, καθώς καθορίζει το μέγεθος της μεταβολής των παραμέτρων σε κάθε επανάληψη. Υπερβολικά υψηλές τιμές μπορεί να προκαλέσουν αστάθεια ή ακόμη και απόκλιση της διαδικασίας βελτιστοποίησης, ενώ πολύ μικρές τιμές οδηγούν σε αργή σύγκλιση και αυξημένο χρόνο εκπαίδευσης (Goodfellow et al., 2016; Géron, 2019).

Ανάλογα με τον αριθμό των δειγμάτων που χρησιμοποιούνται για την εκτίμηση της κλίσης, διακρίνονται τρεις βασικές παραλλαγές. Στην Κατάβαση Κλίσης Πλήρους Παρτίδας (Batch Gradient Descent), η κλίση υπολογίζεται χρησιμοποιώντας ολόκληρο το σύνολο εκπαίδευσης. Στη Στοχαστική Κατάβαση Κλίσης (Stochastic Gradient Descent – SGD), η ενημέρωση πραγματοποιείται με βάση ένα μόνο δείγμα, ενώ στην Κατάβαση Κλίσης Μικρής Παρτίδας (Mini-batch Gradient Descent) χρησιμοποιείται ένα υποσύνολο των δεδομένων. Η τελευταία προσέγγιση αποτελεί τη συνηθέστερη πρακτική στην εκπαίδευση σύγχρονων νευρωνικών δικτύων, καθώς συνδυάζει υπολογιστική αποδοτικότητα και σχετικά σταθερές εκτιμήσεις της κλίσης (Goodfellow et al., 2016; Géron, 2019).

Παρότι η Στοχαστική Μέθοδος Κλίσης αποτελεί τη θεμελιώδη προσέγγιση εκπαίδευσης των νευρωνικών δικτύων, στην πράξη χρησιμοποιούνται συχνά πιο εξελιγμένοι αλγόριθμοι βελτιστοποίησης που ενσωματώνουν πρόσθετους μηχανισμούς για ταχύτερη και σταθερότερη σύγκλιση. Ένας από τους πλέον διαδεδομένους αλγορίθμους αυτής της κατηγορίας είναι ο Adam (Adaptive Moment Estimation).

2.5.2.3. Ο αλγόριθμος βελτιστοποίησης Adam (Adaptive Moment Estimation)

Η Στοχαστική Κατάβαση Κλίσης (Stochastic Gradient Descent – SGD) αποτελεί θεμελιώδη προσέγγιση για την εκπαίδευση νευρωνικών δικτύων. Ωστόσο, η χρήση κοινού ρυθμού μάθησης για όλες τις παραμέτρους και η ευαισθησία της μεθόδου στην επιλογή του μπορούν να οδηγήσουν σε αργή σύγκλιση ή ταλαντώσεις κατά τη διαδικασία βελτιστοποίησης (Goodfellow et al., 2016; Géron, 2019).

Ο Adam (Adaptive Moment Estimation), ο οποίος προτάθηκε από τους Kingma και Ba (2014), συνδυάζει την ορμή (momentum) με προσαρμοστικούς ρυθμούς μάθησης. Ειδικότερα, διατηρεί εκθετικά σταθμισμένους κινητούς μέσους όρους των κλίσεων και των τετραγώνων τους, οι οποίοι αντιστοιχούν σε εκτιμήσεις της πρώτης και της μη κεντραρισμένης δεύτερης ροπής. Παράλληλα, εφαρμόζει διόρθωση μεροληψίας κατά τα πρώτα στάδια της εκπαίδευσης, επειδή οι εκτιμήσεις αυτές αρχικοποιούνται στο μηδέν (Kingma & Ba, 2014; Goodfellow et al., 2016).

Με τους παραπάνω μηχανισμούς, ο Adam προσαρμόζει το μέγεθος της ενημέρωσης χωριστά για κάθε παράμετρο και συχνά επιτυγχάνει ταχύτερη και σταθερότερη σύγκλιση, με μικρότερη ανάγκη συντονισμού του αρχικού ρυθμού μάθησης σε σύγκριση με την απλή

SGD. Για τον λόγο αυτό αποτελεί έναν από τους πλέον διαδεδομένους αλγορίθμους βελτιστοποίησης στη βαθιά μάθηση και χρησιμοποιείται ευρέως στην εκπαίδευση αναδρομικών νευρωνικών δικτύων και μοντέλων χρονοσειρών (Goodfellow et al., 2016; Géron, 2019).

2.5.3. Γενίκευση, Υπερπροσαρμογή και Υποπροσαρμογή

Αυτό που διαφοροποιεί ένα πρόβλημα μηχανικής μάθησης από ένα απλό πρόβλημα μαθηματικής βελτιστοποίησης, είναι το γεγονός ότι η απόδοση ενός μοντέλου δεν αξιολογείται μόνο βάσει της ικανότητάς του να προσαρμόζεται στα δεδομένα εκπαίδευσης, αλλά κυρίως βάσει της ικανότητάς του να γενικεύει σε νέα, μη παρατηρημένα δεδομένα (Goodfellow et al., 2016; Qin, 2020). Η απόδοση του μοντέλου στα δεδομένα εκπαίδευσης αποτυπώνεται μέσω του σφάλματος εκπαίδευσης (training error), ενώ η απόδοσή του σε νέα δεδομένα μέσω του σφάλματος γενίκευσης ή σφάλματος ελέγχου (generalization/test error). Δύο βασικά προβλήματα που σχετίζονται με την ικανότητα γενίκευσης είναι η υπερπροσαρμογή (overfitting) και η υποπροσαρμογή (underfitting).

Η υποπροσαρμογή εμφανίζεται όταν το μοντέλο δεν είναι αρκετά σύνθετο ώστε να συλλάβει τις υποκείμενες σχέσεις των δεδομένων, ενώ η υπερπροσαρμογή εμφανίζεται όταν το μοντέλο προσαρμόζεται υπερβολικά καλά στα δεδομένα εκπαίδευσης, «απομνημονεύοντας» ακόμη και τον θόρυβο ή τις τυχαίες διακυμάνσεις τους, γεγονός που περιορίζει την ικανότητα γενίκευσης.

Για την αντιμετώπιση της υπερπροσαρμογής εφαρμόζονται τεχνικές κανονικοποίησης (regularization), οι οποίες αποσκοπούν στον περιορισμό της πολυπλοκότητας των μοντέλων και στη βελτίωση της ικανότητας γενίκευσης, μειώνοντας τον κίνδυνο υπερπροσαρμογής. Οι τεχνικές αυτές μπορούν να εφαρμοστούν με διαφορετικούς τρόπους, όπως μέσω επιβολής όρων ποινής στις παραμέτρους του μοντέλου, όπως η L1 και L2 κανονικοποίηση στη γραμμική παλινδρόμηση και τα νευρωνικά δίκτυα, μέσω περιορισμών στην διαδικασία εκπαίδευσης, όπως η τεχνικές dropout και early stopping στα νευρωνικά δίκτυα, ή μέσω τεχνικών δειγματοληψίας και συνδυασμού μοντέλων, όπως η δειγματοληψία bootstrap και οι μέθοδοι συνόλων στα τυχαία δάση δέντρων αποφάσεων.

2.5.4. Πρωτόκολλα εκπαίδευσης και χρονικά ορθή επικύρωση

Η αξιολόγηση μοντέλων πρόβλεψης χρονοσειρών διαφέρει ουσιαστικά από την αξιολόγηση συμβατικών προβλημάτων μηχανικής μάθησης, καθώς οι παρατηρήσεις παρουσιάζουν χρονική εξάρτηση και δεν είναι ανεξάρτητες μεταξύ τους. Για τον λόγο αυτό, η τυχαία διάσπαση των δεδομένων σε σύνολα εκπαίδευσης και ελέγχου δεν είναι κατάλληλη, επειδή μπορεί να επιτρέψει στο μοντέλο να εκπαιδευτεί με πληροφορία που, από χρονικής άποψης, ανήκει στο μέλλον σε σχέση με τις παρατηρήσεις που καλείται να προβλέψει. Το φαινόμενο αυτό οδηγεί σε αισιόδοξες εκτιμήσεις της απόδοσης και δεν αντανακλά τις πραγματικές συνθήκες λειτουργίας ενός συστήματος πρόβλεψης (Tashman, 2000; Bergmeir & Benítez, 2012).

Η πλέον απλή και ευρέως χρησιμοποιούμενη προσέγγιση είναι η χρονολογική διάσπαση (holdout), κατά την οποία οι παλαιότερες παρατηρήσεις χρησιμοποιούνται για εκπαίδευση και οι νεότερες αποκλειστικά για αξιολόγηση. Η προσέγγιση αυτή προσομοιώνει ρεαλιστικά τη λειτουργία ενός συστήματος πρόβλεψης, αφού κάθε πρόβλεψη βασίζεται μόνο σε πληροφορία διαθέσιμη μέχρι τη συγκεκριμένη χρονική στιγμή. Ωστόσο, η αξιολόγηση βασίζεται σε μία μόνο χρονική περίοδο και ενδέχεται να επηρεαστεί από ασυνήθιστα γεγονότα ή μεταβολές της ζήτησης που δεν είναι αντιπροσωπευτικές του συνόλου των δεδομένων.

Για τον λόγο αυτό, στη βιβλιογραφία προτείνεται η χρήση επαναλαμβανόμενης χρονικής επικύρωσης (rolling-origin evaluation ή walk-forward validation), κατά την οποία το μοντέλο επανεκπαιδεύεται διαδοχικά καθώς γίνονται διαθέσιμες νέες παρατηρήσεις και αξιολογείται σε πολλαπλά χρονικά παράθυρα (Tashman, 2000). Η διαδικασία αυτή μπορεί να υλοποιηθεί είτε με expanding window, όπου το σύνολο εκπαίδευσης αυξάνεται προοδευτικά διατηρώντας όλες τις προηγούμενες παρατηρήσεις, είτε με rolling window, όπου χρησιμοποιείται σταθερού μεγέθους παράθυρο που μετακινείται διαχρονικά. Η πρώτη στρατηγική είναι κατάλληλη όταν θεωρείται ότι οι παλαιότερες παρατηρήσεις εξακολουθούν να περιέχουν χρήσιμη πληροφορία, ενώ η δεύτερη προτιμάται όταν αναμένονται σημαντικές μεταβολές στη στατιστική συμπεριφορά της χρονοσειράς (concept drift).

Η διαδικασία επιλογής υπερπαραμέτρων πρέπει επίσης να ακολουθεί τη χρονική διάταξη των δεδομένων. Οι υπερπαραμέτροι ενός μοντέλου δεν πρέπει να επιλέγονται χρησιμοποιώντας το τελικό σύνολο ελέγχου, καθώς αυτό οδηγεί σε μεροληπτική εκτίμηση της πραγματικής ικανότητας γενίκευσης. Αντίθετα, η βελτιστοποίηση πραγματοποιείται σε ανεξάρτητο σύνολο επικύρωσης (validation set), το οποίο προηγείται χρονικά του test set. Σε εφαρμογές υψηλών απαιτήσεων προτείνεται η χρήση nested time-series validation, όπου η εξωτερική διαδικασία χρησιμοποιείται για την εκτίμηση της γενίκευσης και η εσωτερική για τη ρύθμιση των υπερπαραμέτρων (Bergmeir & Benítez, 2012). Ωστόσο, σε εφαρμογές με περιορισμένο πλήθος διαθέσιμων δεδομένων, όπως συμβαίνει συχνά σε ενεργειακά δεδομένα μεμονωμένων λιμένων, ένα αυστηρά χρονολογικό train-validation-test split ή ένα expanding-window backtesting αποτελεί επιστημονικά αποδεκτή εναλλακτική, εφόσον η διαδικασία τεκμηριώνεται με σαφήνεια.

Σε περίπτωση επαναλαμβανόμενης χρονικής επικύρωσης με K διαδοχικά χρονικά παράθυρα, η συνολική επίδοση του μοντέλου εκτιμάται ως ο μέσος όρος της συνάρτησης απώλειας στα επιμέρους σύνολα ελέγχου:

$$\hat{R}_{CV} = \frac{1}{K} \sum_{k=1}^K \frac{1}{n_k} \sum_{t \in T_k} L(y_t, \hat{y}_{t|D_k})$$

όπου το D_k συμβολίζει το σύνολο εκπαίδευσης που περιλαμβάνει αποκλειστικά παρατηρήσεις προγενέστερες του αντίστοιχου συνόλου ελέγχου T_k , ενώ n_k είναι ο αριθμός των παρατηρήσεων του συγκεκριμένου χρονικού παραθύρου. Η ίδια διαδικασία εκπαίδευσης και αξιολόγησης πρέπει να εφαρμόζεται σε όλα τα μοντέλα που συγκρίνονται, ώστε οι διαφορές στην απόδοση να αποδίδονται αποκλειστικά στα χαρακτηριστικά των αλγορίθμων και όχι σε διαφορετικά πρωτόκολλα επικύρωσης.

Η διατήρηση της χρονικής ακεραιότητας σε όλα τα στάδια της εκπαίδευσης αποτελεί βασική προϋπόθεση για την αξιόπιστη αξιολόγηση μοντέλων πρόβλεψης φορτίου. Η χρήση κατάλληλων πρωτοκόλλων επικύρωσης περιορίζει τον κίνδυνο διαρροής πληροφορίας (data leakage), παρέχει ρεαλιστικότερη εκτίμηση της ικανότητας γενίκευσης και επιτρέπει την αντικειμενική σύγκριση διαφορετικών μεθόδων πρόβλεψης υπό κοινές συνθήκες αξιολόγησης.

2.6. Μετρικές αξιολόγησης μοντέλων πρόβλεψης

Για την αξιολόγηση και τη σύγκριση αλγορίθμων πρόβλεψης ενέργειας χρησιμοποιούνται διάφορες μετρικές. Καμία μετρική αξιολόγησης δεν μπορεί να αποτυπώσει από μόνη της όλες τις διαστάσεις της προγνωστικής απόδοσης ενός μοντέλου. Για τον λόγο αυτό, η αξιολόγηση των μοντέλων βασίζεται συνήθως στον συνδυασμό πολλαπλών δεικτών, οι οποίοι αναδεικνύουν διαφορετικές πτυχές του σφάλματος (Hyndman & Koehler, 2006). Η επιλογή των κατάλληλων μετρικών είναι κρίσιμη για την αξιόπιστη εκτίμηση της απόδοσης

ενός μοντέλου και δεν θα πρέπει να παραβλέπεται, καθώς οι μετρικές αξιολόγησης δεν αποτυπώνουν όλες με τον ίδιο τρόπο την προβλεπτική ακρίβεια ούτε τη διακύμανση των σφαλμάτων. Επιπλέον, οι συνήθεις μετρικές, αν και παρέχουν χρήσιμες ενδείξεις για την ποιότητα των προβλέψεων, ενδέχεται να μην καλύπτουν πλήρως τις απαιτήσεις εφαρμογών πρόβλεψης ενέργειας. Για τον λόγο αυτό, η επιλογή τους θα πρέπει να ευθυγραμμίζεται με τους στόχους και τους περιορισμούς της εκάστοτε εφαρμογής, λαμβάνοντας υπόψη τις επιπτώσεις των σφαλμάτων πρόβλεψης, όπως οι οικονομικές και λειτουργικές συνέπειες. Οι συνηθέστερες μετρικές που χρησιμοποιούνται στην πρόβλεψη ενέργειας, μαζί με τους μαθηματικούς ορισμούς και τα βασικά χαρακτηριστικά τους είναι οι παρακάτω (Mystakidis et al., 2024):

2.6.1. Συντελεστής Προσδιορισμού (Coefficient of determination - R²)

Ο συντελεστής προσδιορισμού, γνωστός ως R-squared ή R², εκφράζει τη σύγκριση της διακύμανσης του σφάλματος με τη διακύμανση των δεδομένων που πρόκειται να μοντελοποιηθούν. Καθώς εκφράζει το ποσοστό της διακύμανσης των δεδομένων που εξηγείται από το μοντέλο πρόβλεψης, σε αντίθεση με τις μετρικές που βασίζονται στο σφάλμα, όσο μεγαλύτερη είναι η τιμή του R² τόσο καλύτερη θεωρείται η προσαρμογή του μοντέλου.

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} = 1 - \frac{\sum (y_i - f_i)^2}{\sum (y_i - \bar{y})^2}$$

όπου SS_{res} είναι το άθροισμα των τετραγώνων των σφαλμάτων, SS_{tot} το συνολικό άθροισμα τετραγώνων που είναι ενδεικτικό της διακύμανσης των δεδομένων, y_i η πραγματική τιμή, $\bar{y}$ ο μέσος όρος των πραγματικών τιμών και f_i η προβλεπόμενη τιμή.

2.6.2. Μέσο Απόλυτο Σφάλμα (Mean Absolute Error, MAE)

Το Μέσο Απόλυτο Σφάλμα (MAE) αποτελεί μία απλή και ευρέως χρησιμοποιούμενη μετρική αξιολόγησης, η οποία υπολογίζεται ως ο μέσος όρος των απόλυτων διαφορών μεταξύ πραγματικών και προβλεπόμενων τιμών, οπότε όσο μικρότερο είναι, τόσο καλύτερη θεωρείται η προσαρμογή του μοντέλου. Σε αντίθεση με άλλες μετρικές, αποδίδει ίσο βάρος σε όλα τα σφάλματα και ορίζεται ως:

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

όπου y_i είναι η πραγματική τιμή, f_i η προβλεπόμενη τιμή και N το πλήθος των παρατηρήσεων.

2.6.3. Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error, MSE)

Το Μέσο Τετραγωνικό Σφάλμα (MSE) αξιολογεί την ποιότητα προσαρμογής ενός μοντέλου υπολογίζοντας τη μέση τιμή των τετραγωνικών διαφορών μεταξύ των πραγματικών και των προβλεπόμενων τιμών. Η ύψωση στο τετράγωνο εξαλείφει τα αρνητικά πρόσημα και αποδίδει μεγαλύτερο βάρος στα μεγαλύτερα σφάλματα. Όσο μικρότερη είναι η τιμή του MSE, τόσο καλύτερη θεωρείται η πρόβλεψη.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - f_i)^2$$

όπου y_i είναι η πραγματική τιμή, f_i η προβλεπόμενη τιμή και N το πλήθος των παρατηρήσεων.

2.6.4. Ρίζα Μέσου Τετραγωνικού Σφάλματος (Root Mean Squared Error - RMSE)

Η Ρίζα του Μέσου Τετραγωνικού Σφάλματος (RMSE) αποτελεί τη τετραγωνική ρίζα του MSE και εκφράζει τη μέση τετραγωνική απόκλιση μεταξύ πραγματικών και προβλεπόμενων τιμών. Σε αντίθεση με το MSE, το RMSE μετράται στις ίδιες μονάδες με το υπό μελέτη μέγεθος, γεγονός που το καθιστά ευρύτερα χρησιμοποιούμενο. Επιπλέον, αποδίδει μεγαλύτερο βάρος στα μεγαλύτερα σφάλματα, καθώς η επίδραση ενός σφάλματος στο συνολικό αποτέλεσμα είναι ανάλογη του τετραγώνου του και όχι του μεγέθους του.

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

όπου y_i είναι η πραγματική τιμή, f_i η προβλεπόμενη τιμή και N το πλήθος των παρατηρήσεων.

2.6.5. Συντελεστής Μεταβλητότητας του RMSE (Coefficient of Variation of Root Mean Squared Error - CVRMSE)

Ο Συντελεστής Μεταβλητότητας της Ρίζας Μέσου Τετραγωνικού Σφάλματος (CVRMSE) προκύπτει από την κανονικοποίηση του RMSE ως προς τη μέση τιμή των παρατηρήσεων, εκφράζοντας το συνολικό σφάλμα σε ποσοστιαία μορφή. Όπως και το RMSE, αποδίδει μεγαλύτερο βάρος στα μεγαλύτερα σφάλματα, καθώς η επίδραση ενός μεμονωμένου σφάλματος στο συνολικό αποτέλεσμα είναι ανάλογη του τετραγώνου του.

$$CVRMSE(\%) = \frac{RMSE}{\bar{y}} * 100 = \frac{\sqrt{\sum (y_i - f_i)^2 / N}}{\sum y_i / N} * 100$$

όπου y_i είναι η πραγματική τιμή, f_i η προβλεπόμενη τιμή και N το πλήθος των παρατηρήσεων. Ένα σημαντικό πλεονέκτημα του CVRMSE είναι ότι η κανονικοποίηση του RMSE ως προς τη μέση τιμή των παρατηρήσεων επιτρέπει την έκφραση του σφάλματος σε σχετικούς όρους, ως αδιάστατου δείκτη ανεξάρτητου από την κλίμακα των δεδομένων. Με τον τρόπο αυτό, το CVRMSE διευκολύνει τη σύγκριση της απόδοσης μοντέλων μεταξύ διαφορετικών συστημάτων ή μελετών, όπου τα επίπεδα φορτίου ενδέχεται να διαφέρουν σημαντικά.

2.6.6. Κανονικοποιημένη Ρίζα Μέσου Τετραγωνικού Σφάλματος (Normalised Root Mean Squared Error - NRMSE)

Η Κανονικοποιημένη Ρίζα Μέσου Τετραγωνικού Σφάλματος αποτελεί κανονικοποιημένη μορφή του RMSE, η οποία επιτρέπει συγκριτική αξιολόγηση της αποτελεσματικότητας του μοντέλου και συνήθως εκφράζεται σε ποσοστιαία μορφή. Μικρότερες τιμές NRMSE

υποδηλώνουν ακριβέστερη προσαρμογή του μοντέλου στα πραγματικά δεδομένα. Ένας τρόπος υπολογισμού του είναι κανονικοποιημένο ως προς το εύρος των τιμών $y_{\max} - y_{\min}$:

$$NRMSE(\%) = \frac{RMSE}{y_{\max} - y_{\min}} * 100$$

2.6.7. Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (MAPE)

Το Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (MAPE) αποτελεί ευρέως χρησιμοποιούμενη μετρική ακρίβειας, καθώς εκφράζει το σφάλμα σε ποσοστιαία μορφή. Υπολογίζεται ως ο μέσος όρος των απόλυτων ποσοστιαίων διαφορών μεταξύ πραγματικών και προβλεπόμενων τιμών. Ωστόσο, παρουσιάζει μειονέκτημα όταν οι πραγματικές τιμές είναι μηδενικές ή πολύ μικρές, οδηγώντας σε άπειρες ή ιδιαίτερα μεγάλες τιμές.

$$MAPE(\%) = \frac{100}{N} \sum_{i=1}^N \left| \frac{y_i - f_i}{y_i} \right|$$

όπου y_i είναι η πραγματική τιμή, f_i η προβλεπόμενη τιμή και N το πλήθος των παρατηρήσεων.

2.6.8. Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (sMAPE)

Το Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (symmetric Mean Absolute Percentage Error – sMAPE) αποτελεί παραλλαγή του MAPE και υπολογίζει το μέσο ποσοστιαίο σφάλμα κανονικοποιώντας την απόλυτη διαφορά μεταξύ της πραγματικής και της προβλεπόμενης τιμής ως προς το μέσο όρο των απόλυτων τιμών τους. Ωστόσο, παρουσιάζει μειονέκτημα όταν οι πραγματικές τιμές είναι μηδενικές ή πολύ μικρές, οδηγώντας σε άπειρες ή ιδιαίτερα μεγάλες τιμές.

$$sMAPE(\%) = \frac{100}{N} \sum_{i=1}^N \frac{2|y_i - f_i|}{|y_i| + |f_i|}$$

όπου y_i είναι η πραγματική τιμή, f_i η προβλεπόμενη τιμή και N το πλήθος των παρατηρήσεων.

Η χρήση των απόλυτων τιμών στον παρονομαστή περιορίζει την ασυμμετρία που παρουσιάζει το MAPE μεταξύ υπερεκτίμησης και υποεκτίμησης, ενώ η τιμή του δείκτη εκφράζεται ως ποσοστό (Hyndman & Athanassopoulos, 2021).

2.6.9. Μέσο Απόλυτο Κλιμακωμένο Σφάλμα (Mean Absolute Scaled Error – MASE)

Το Μέσο Απόλυτο Κλιμακωμένο Σφάλμα (Mean Absolute Scaled Error – MASE) αποτελεί μετρική αξιολόγησης που προτάθηκε από τους Hyndman και Koehler (2006) για την αντιμετώπιση περιορισμών του MAPE και άλλων σχετικών δεικτών. Το MASE κανονικοποιεί το Μέσο Απόλυτο Σφάλμα ως προς το σφάλμα μιας απλής πρόβλεψης

αναφοράς (naïve benchmark), επιτρέποντας τη σύγκριση της προγνωστικής απόδοσης μεταξύ διαφορετικών χρονοσειρών και εφαρμογών.

$$MASE = \frac{\frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|}{\frac{1}{T-m} \sum_{t=m+1}^T |y_t - y_{t-m}|}$$

όπου m είναι η περίοδος εποχικότητας, T το συνολικό πλήθος παρατηρήσεων και ο παρονομαστής αντιστοιχεί στο μέσο απόλυτο σφάλμα του εποχικού μοντέλου αναφοράς (seasonal naïve forecast). Τιμές $MASE < 1$ υποδηλώνουν ότι το μοντέλο παρουσιάζει καλύτερη προγνωστική απόδοση από το αντίστοιχο μοντέλο αναφοράς (Hyndman & Koehler, 2006; Hyndman & Athanasopoulos, 2021).

Συνοψίζοντας, ο πίνακας 4 δείχνει τα πλεονεκτήματα και τους περιορισμούς των συνηθέστερα χρησιμοποιούμενων μετρικών.

Πίνακας 4. Πλεονεκτήματα και περιορισμοί βασικών δεικτών.

Δείκτης	Πλεονέκτημα	Περιορισμός	Συνιστώμενη χρήση
MAE	Άμεση ερμηνεία στην ίδια μονάδα	Δεν τονίζει ιδιαίτερα μεγάλες αποκλίσεις	Κύριος δείκτης γενικής ακρίβειας
RMSE	Τιμωρεί έντονα μεγάλα σφάλματα	Ευαίσθητος σε outliers	Αιχμές και λειτουργική ασφάλεια
MAPE	Εύκολη ποσοστιαία επικοινωνία	Ασταθής κοντά στο μηδέν, ασύμμετρος	Μόνο όταν το φορτίο δεν πλησιάζει το μηδέν
sMAPE	Περιορίζει μέρος της ασυμμετρίας	Παραμένει δύσκολο στην ερμηνεία	Συμπληρωματικός σχετικός δείκτης
MASE	Σύγκριση με naïve και μεταξύ κλιμάκων	Απαιτεί σωστό ορισμό εποχικού naïve	Κύριος δείκτης συγκρισιμότητας

2.6.10. Συμπληρωματικοί και ειδικοί δείκτες αξιολόγησης

Εκτός από τις βασικές μετρικές προγνωστικής ακρίβειας, στην αξιολόγηση μοντέλων πρόβλεψης χρησιμοποιούνται και συμπληρωματικοί ή εξειδικευμένοι σε επίπεδο εφαρμογής δείκτες, οι οποίοι αποτυπώνουν την υπολογιστική αποδοτικότητα ή συγκεκριμένες λειτουργικές διαστάσεις της πρόβλεψης.

Ο Χρόνος Εκτέλεσης (Execution Time – ET) εκφράζει τον χρόνο που απαιτείται για την εκπαίδευση και την παραγωγή προβλέψεων από ένα μοντέλο και αναφέρεται συνήθως σε δευτερόλεπτα. Παρότι αποτελεί σημαντική παράμετρο για την πρακτική εφαρμογή ενός μοντέλου, δεν αποτελεί άμεσο δείκτη προγνωστικής ακρίβειας. Επιπλέον, εξαρτάται σε μεγάλο βαθμό από τους διαθέσιμους υπολογιστικούς πόρους, το λογισμικό και τις λεπτομέρειες υλοποίησης, γεγονός που περιορίζει την άμεση σύγκρισή του μεταξύ διαφορετικών μελετών. Για τον λόγο αυτό, αντιμετωπίζεται ως συμπληρωματική μετρική αξιολόγησης.

Σε εφαρμογές ενεργειακού σχεδιασμού χρησιμοποιούνται επίσης δείκτες που εστιάζουν στην ακρίβεια πρόβλεψης των αιχμών φορτίου, όπως το Σφάλμα Αιχμής (Peak Error). Ο δείκτης αυτός εκφράζει την απόκλιση μεταξύ της πραγματικής και της προβλεπόμενης μέγιστης τιμής φορτίου και είναι χρήσιμος όταν η εκτίμηση της μέγιστης ζήτησης επηρεάζει τον προγραμματισμό λειτουργίας, τη διαστασιολόγηση του εξοπλισμού ή το κόστος ισχύος.

Επιπλέον, οι δείκτες ενεργειακής μεροληψίας (energy bias) εξετάζουν κατά πόσο ένα μοντέλο υπερεκτιμά ή υποεκτιμά συστηματικά τη συνολική κατανάλωση ενέργειας σε συγκεκριμένο χρονικό διάστημα, όπως μία ημέρα. Το Daily Energy Bias εστιάζει επομένως στη συνολική ημερήσια ενεργειακή ισορροπία των προβλέψεων και όχι αποκλειστικά στην ακρίβεια κάθε επιμέρους χρονικής στιγμής.

2.7. Βιβλιογραφική ανασκόπηση εφαρμογών ELF σε λιμένες

Η βιβλιογραφία που αφορά ειδικά την πρόβλεψη της ηλεκτρικής ζήτησης σε λιμένες παραμένει περιορισμένη σε σύγκριση με το ευρύτερο πεδίο της βραχυπρόθεσμης πρόβλεψης φορτίου. Οι διαθέσιμες μελέτες εξετάζουν διαφορετικές μονάδες ανάλυσης, από μεμονωμένο εξοπλισμό έως ολόκληρους τερματικούς σταθμούς και λιμενικά μικροδίκτυα, ενώ διαφέρουν επίσης ως προς τη χρονική ανάλυση, τον ορίζοντα πρόβλεψης και τον επιχειρησιακό σκοπό. Για τον λόγο αυτό, η εξέλιξη του πεδίου περιγράφεται πληρέστερα ως σταδιακή διεύρυνση του αντικειμένου πρόβλεψης και των διαθέσιμων δεδομένων παρά ως άμεση σύγκριση αλγορίθμων.

Οι πρώτες άμεσα συναφείς μελέτες επικεντρώθηκαν στην κατανάλωση συγκεκριμένου λιμενικού εξοπλισμού, κυρίως ηλεκτροκίνητων γερανών RTG. Οι Alasali et al. (2018) συνέκριναν στατιστικές προσεγγίσεις και τεχνητά νευρωνικά δίκτυα για day-ahead πρόβλεψη του φορτίου δύο γερανών στον λιμένα Felixstowe. Εκτός από το ιστορικό φορτίο, εξέτασαν επιχειρησιακές μεταβλητές, όπως ο αριθμός κινήσεων των γερανών και το βάρος των εμπορευματοκιβωτίων, δείχνοντας ότι η διαθεσιμότητα κατάλληλων λειτουργικών πληροφοριών μπορεί να βελτιώσει την πρόβλεψη. Σε επόμενη εργασία, οι Alasali et al. (2019) συνέδεσαν τις προβλέψεις φορτίου με τον έλεγχο συστήματος αποθήκευσης ενέργειας για μείωση των αιχμών. Οι μελέτες αυτές δείχνουν ότι η χρήση επιχειρησιακών δεδομένων και η σύνδεση της πρόβλεψης με την ενεργειακή διαχείριση εμφανίζονται ήδη στην πρώιμη βιβλιογραφία, αλλά σε επίπεδο μεμονωμένου εξοπλισμού.

Από το 2021, το ενδιαφέρον επεκτάθηκε προς τη συνολική ζήτηση τερματικών σταθμών. Οι Alikhani et al. (2021) ανέπτυξαν πλαίσιο για τον τερματικό σταθμό εμπορευματοκιβωτίων του λιμένα Gävle, το οποίο περιλάμβανε πρόβλεψη του βασικού φορτίου με feed-forward ANN, εκτίμηση της μέγιστης ταυτόχρονης ζήτησης και διαμόρφωση day-ahead καμπυλών φορτίου με βάση τις προγραμματισμένες λειτουργίες. Για την πρόβλεψη του βασικού φορτίου χρησιμοποιήθηκαν ωριαίες μετρήσεις της περιόδου 2018–2020, χρονικά χαρακτηριστικά και υστερημένες τιμές φορτίου, ενώ το ANN κατέγραψε MAPE 16,04% στο έτος ελέγχου. Η day-ahead καμπύλη δεν προέκυψε αποκλειστικά από το ANN, αλλά από τον συνδυασμό της πρόβλεψης βάσης με πληροφορίες για αφίξεις πλοίων, χειρισμό εμπορευματοκιβωτίων, ώρες λειτουργίας εξοπλισμού και μελλοντικές υποδομές. Η μελέτη αντιπροσωπεύει επομένως τη μετάβαση από την πρόβλεψη επιμέρους φορτίων προς ένα πλαίσιο συνολικού ενεργειακού σχεδιασμού τερματικού σταθμού.

Η σύνδεση της πρόβλεψης με την ενεργειακή διαχείριση συνεχίστηκε από τους Gopalakrishnan et al. (2022), οι οποίοι συνδύασαν πρόβλεψη ηλεκτρικού φορτίου και φωτοβολταϊκής παραγωγής με σύστημα ενεργειακής διαχείρισης για peak shaving και παροχή υπηρεσιών προς το δίκτυο στον λιμένα Gävle. Η έμφαση αυτής της κατεύθυνσης δεν βρίσκεται μόνο στην ελαχιστοποίηση του σφάλματος πρόβλεψης, αλλά στη χρησιμοποίηση των προβλέψεων για τον προγραμματισμό αποθήκευσης, τη μείωση των αιχμών και τη διαχείριση του ενεργειακού κόστους.

Παράλληλα, η βιβλιογραφία άρχισε να καλύπτει διαφορετικές χρονικές κλίμακες. Οι Kim et al. (2023) χρησιμοποίησαν πολυμεταβλητό LSTM για τη μακροπρόθεσμη προβολή της ηλεκτρικής κατανάλωσης του Busan New Port έως το 2040, με εισόδους το ιστορικό κατανάλωσης και τον όγκο διακίνησης εμπορευματοκιβωτίων. Η εργασία αυτή αφορά κυρίως τον σχεδιασμό ενεργειακών υποδομών και όχι τη λειτουργική βραχυπρόθεσμη πρόβλεψη. Η παρουσία τόσο μακροπρόθεσμων όσο και day-ahead εφαρμογών δείχνει ότι ο όρος «πρόβλεψη λιμενικού φορτίου» καλύπτει διαφορετικά προβλήματα, τα οποία δεν πρέπει να συγκρίνονται μόνο βάσει των αναφερόμενων μετρικών σφάλματος.

Από το 2023 και μετά, ενισχύθηκε η τάση προς πολυσταδιακές και υβριδικές αρχιτεκτονικές. Οι Cao et al. (2023) πρότειναν το SP2LSTM, το οποίο συνδυάζει Singular Spectrum Analysis, παράλληλα LSTM και BiLSTM και τοπική διόρθωση μέσω CNN σε πλαίσιο patch learning. Η μέθοδος αξιολογήθηκε σε ωριαία δεδομένα φορτίου υποσταθμού λιμενικής περιοχής και απέδωσε χαμηλότερα σφάλματα από τα SVR, Random Forest, GBDT και N-BEATS στο συγκεκριμένο σύνολο δεδομένων. Η εργασία βασίστηκε στην ιστορική χρονοσειρά φορτίου και όχι σε επιχειρησιακές ή μετεωρολογικές μεταβλητές, επομένως η βελτίωση προήλθε κυρίως από την αποσύνθεση του σήματος και τη διόρθωση περιοχών με υψηλό τοπικό σφάλμα.

Οι Chen et al. (2024) ακολούθησαν επίσης υβριδική προσέγγιση, αλλά συνδύασαν την αποσύνθεση της χρονοσειράς με πολυμεταβλητή είσοδο. Το μοντέλο VMD–TCN–LSTM χρησιμοποίησε Variational Mode Decomposition για τον περιορισμό της μεταβλητότητας, TCN για την εξαγωγή χρονικών χαρακτηριστικών και LSTM για τη μοντελοποίηση εξαρτήσεων μεγαλύτερης διάρκειας. Εκτός από το ιστορικό φορτίο, ενσωματώθηκαν μετεωρολογικά και χρονικά χαρακτηριστικά, όπως η θερμοκρασία, η ταχύτητα ανέμου, το τρίμηνο και η ώρα. Στη συγκεκριμένη περίπτωση μελέτης, το προτεινόμενο μοντέλο υπερείχε των GRU, LSTM, XGBoost και VMD–LSTM, καταγράφοντας $R^2=0,94$, MAPE 2,36% και MSE 3,59. Οι ίδιοι οι συγγραφείς αναγνωρίζουν ότι η διάρκεια του διαθέσιμου δείγματος και η εφαρμογή σε έναν παράκτιο κινεζικό λιμένα περιορίζουν τη δυνατότητα γενίκευσης σε άλλους τύπους λιμένων.

Στην ίδια ευρύτερη κατεύθυνση εντάσσονται οι Song et al. (2024) και Ma et al. (2025). Οι Song et al. (2024) συνδύασαν TPA-LSTM, MQ-RNN και Deep Factors σε ensemble πλαίσιο και ανέφεραν MAPE 6,23% και 7,94% σε δύο πραγματικά λιμενικά σύνολα δεδομένων. Οι Ma et al. (2025) ανέπτυξαν πολυσταδιακή μέθοδο που συνδυάζει αποσύνθεση VMD, εντοπισμό διαθρωτικών μεταβολών και δίκτυα Bi-GRU και LSTM για φορτίο λιμενικού υποσταθμού. Οι εργασίες αυτές δείχνουν αυξανόμενη έμφαση στην αποσύνθεση μη στάσιμων χρονοσειρών και στον συνδυασμό πολλών επιμέρους μοντέλων. Δεν τεκμηριώνουν όμως από μόνες τους ότι η μεγαλύτερη αρχιτεκτονική πολυπλοκότητα αποτελεί γενικά την καταλληλότερη επιλογή, καθώς οι συγκρίσεις πραγματοποιούνται σε διαφορετικά datasets και με διαφορετικά πρωτόκολλα αξιολόγησης.

Μια διαφορετική κατεύθυνση εκπροσωπείται από τους Micallef et al. (2025), οι οποίοι συνέκριναν Random Forest, Least-Squares Boosting, Gaussian Process Regression, Γραμμική Παλινδρόμηση και naïve πρόβλεψη σε πραγματικά δεδομένα λιμενικού μικροδικτύου. Το Random Forest με expanding-window εκπαίδευση κατέγραψε την καλύτερη απόδοση, με RMSE 1,1848 MW και MAPE 7,2483%. Η μελέτη δείχνει ότι συμβατικές μέθοδοι μηχανικής μάθησης μπορούν να παραμένουν ανταγωνιστικές, όταν αξιολογούνται με κατάλληλο χρονικό σχήμα εκπαίδευσης και συγκρίνονται με απλές γραμμές βάσης. Παράλληλα, η ανάλυση έδειξε ότι ένας σταθμισμένος δείκτης προσεγγίσεων πλοίων συνέβαλε στην πρόβλεψη, συνδέοντας το φορτίο του μικροδικτύου με τη λιμενική δραστηριότητα.

Η ενσωμάτωση επιχειρησιακών δεδομένων αναπτύχθηκε περαιτέρω στις εργασίες των Tang et al. (2025) και Do Carmo et al. (2026). Οι Tang et al. (2025) μοντελοποίησαν τα φορτία γερανών, εξοπλισμού διακίνησης και shore power με βάση αφίζεις πλοίων και προγραμματισμένες εργασίες, χρησιμοποιώντας τα αποτελέσματα για τον προγραμματισμό κατανομής ενεργειακών πόρων της επόμενης ημέρας. Η εργασία τους αποτελεί κυρίως λειτουργικό μοντέλο ενός ολοκληρωμένου λιμενικού ενεργειακού συστήματος και όχι συμβατικό benchmark μηχανικής μάθησης. Οι Do Carmo et al. (2026), αντίθετα, εξέτασαν άμεσα την προστιθέμενη αξία επιχειρησιακών μεταβλητών σε μοντέλα LSTM για τον λιμένα Sines. Η προσθήκη λεπτομερών δεδομένων δραστηριότητας γερανών μείωσε το αναφερόμενο MAPE από 10,55% σε 3,59% σε σχέση με το βασικό μοντέλο ιστορικού φορτίου και ημερολογιακών χαρακτηριστικών, αν και η άνιση χρονική διαθεσιμότητα των datasets περιορίζει την αυστηρή σύγκριση των δύο αποτελεσμάτων.

Συνολικά, η βιβλιογραφία δείχνει μετάβαση από την πρόβλεψη φορτίου επιμέρους λιμενικού εξοπλισμού προς τη μοντελοποίηση της συνολικής ζήτησης τερματικών σταθμών, λιμένων και μικροδικτύων. Οι διαθέσιμες μελέτες διαφέρουν ως προς το αντικείμενο πρόβλεψης, τη χρονική ανάλυση, τον χρονικό ορίζοντα, τις μεταβλητές εισόδου, τις γραμμές βάσης και τις διαδικασίες επικύρωσης, γεγονός που δυσχεραίνει την εξαγωγή γενικεύσιμων συμπερασμάτων. Επιπλέον, η απουσία κοινού ανοικτού συνόλου δεδομένων περιορίζει τόσο την αναπαραγωγικότητα όσο και την άμεση σύγκριση των προτεινόμενων μεθόδων. Συνολικά, η βιβλιογραφία δεν παρέχει ακόμη σαφή συναίνεση ότι μία οικογένεια μοντέλων είναι καθολικά βέλτιστη. Επομένως, η αξιολόγηση και η επιλογή ενός μοντέλου θα πρέπει να εξετάζονται σε συνάρτηση με το πρωτόκολλο χρονικής επικύρωσης, τη διαθεσιμότητα επιχειρησιακών και εξωγενών μεταβλητών, καθώς και τον επιδιωκόμενο σκοπό της πρόβλεψης.

2.8. Ερευνητικά κενά

Η ανασκόπηση της διεθνούς βιβλιογραφίας ανέδειξε ότι, παρά τη σημαντική πρόοδο που έχει επιτευχθεί στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου, εξακολουθούν να υφίστανται σημαντικά ερευνητικά κενά, ιδιαίτερα στις εφαρμογές που αφορούν λιμενικές εγκαταστάσεις.

Αρχικά, παρατηρείται έλλειψη ανοικτών και τυποποιημένων συνόλων δεδομένων που να συνδυάζουν ενεργειακά, επιχειρησιακά και μετεωρολογικά χαρακτηριστικά. Η περιορισμένη διαθεσιμότητα τέτοιων δεδομένων δυσχεραίνει την αναπαραγωγή των αποτελεσμάτων και την αντικειμενική σύγκριση διαφορετικών μεθόδων πρόβλεψης.

Παράλληλα, η αξιοποίηση επιχειρησιακών δεδομένων, όπως πληροφορίες σχετικά με τις αφίζεις πλοίων ή τη λειτουργία του λιμενικού εξοπλισμού, εξαρτάται σε μεγάλο βαθμό από τη διαθεσιμότητά τους. Ως αποτέλεσμα, πολλές μελέτες βασίζονται κυρίως σε ιστορικά δεδομένα φορτίου και μετεωρολογικές μεταβλητές, χωρίς να ενσωματώνουν πληροφορίες που περιγράφουν άμεσα τη λειτουργία του λιμένα.

Επιπλέον, η αξιολόγηση των μοντέλων επικεντρώνεται συνήθως σε συνολικούς δείκτες σφάλματος, όπως οι MAE, RMSE και MAPE, ενώ η απόδοσή τους κατά τη διάρκεια περιόδων αιχμής ή άλλων σπάνιων γεγονότων εξετάζεται σε μικρότερο βαθμό. Αντίστοιχα, οι περισσότερες εφαρμογές περιορίζονται σε σημειακές προβλέψεις, με περιορισμένη αξιοποίηση πιθανοτικών προσεγγίσεων και εκτίμησης της αβεβαιότητας των προβλέψεων. Ένα ακόμη ζήτημα αφορά την προσαρμοστικότητα των μοντέλων σε μεταβολές των χαρακτηριστικών του συστήματος, όπως η ηλεκτροκίνηση, η εγκατάσταση συστημάτων Onshore Power Supply (OPS) ή άλλες αλλαγές στη λειτουργία των λιμενικών

εγκαταστάσεων, οι οποίες ενδέχεται να μεταβάλλουν σημαντικά τα πρότυπα κατανάλωσης ηλεκτρικής ενέργειας.

Παράλληλα, η βιβλιογραφία περιλαμβάνει σχετικά περιορισμένο αριθμό μελετών που συγκρίνουν απλά και ερμηνεύσιμα μοντέλα με περισσότερο σύνθετες μεθόδους μηχανικής και βαθιάς μάθησης, χρησιμοποιώντας κοινά δεδομένα και ενιαία διαδικασία αξιολόγησης. Επιπλέον, η σύνδεση της πρόβλεψης φορτίου με πραγματικές εφαρμογές ενεργειακής διαχείρισης, καθώς και η διερεύνηση της μεταφερσιμότητας μοντέλων μεταξύ διαφορετικών τύπων λιμένων, αποτελούν πεδία που δεν έχουν ακόμη μελετηθεί επαρκώς. Όπως επισημαίνουν οι Carrillo-Galvez et al. (2025), σημαντικό μέρος των παραπάνω περιορισμών συνδέεται με τη διαθεσιμότητα και την ποιότητα των δεδομένων. Το ζήτημα δεν αφορά αποκλειστικά την ανάπτυξη νέων αλγορίθμων, αλλά και την πρόσβαση σε αξιόπιστα και ολοκληρωμένα δεδομένα, τα οποία συχνά προέρχονται από διαφορετικούς φορείς και δεν είναι εύκολα διαθέσιμα για ερευνητική αξιοποίηση. Επιλεγμένες μελέτες της πρόσφατης βιβλιογραφίας συνοψίζονται στον Πίνακα 5.

Πίνακας 5. Επιλεγμένες μελέτες πρόβλεψης ή μοντελοποίησης λιμενικής ηλεκτρικής ζήτησης.

Μελέτη	Περίπτωση/ δεδομένα	Μέθοδος	Κύριο εύρημα	Κύριος περιορισμός
Gopalakrishnan et al., 2022	Port of Gävle, πραγματικό φορτίο και PV	ANN forecasting + EMS για peak shaving	Σύνδεση πρόβλεψης με peak shaving και υπηρεσίες δικτύου	Μελέτη συγκεκριμένου τερματικού και περιορισμένο εύρος σεναρίων
Kim et al., 2023	Busan New Port, 10 έτη μηνιαίων δεδομένων και throughput	LSTM μακροπρόθεσμης πρόβλεψης	Πρόβλεψη αύξησης κατανάλωσης 4,9% ετησίως έως 2040	Μηνιαία ανάλυση, κατάλληλη για υποδομές αλλά όχι λειτουργικό dispatch
Sarantakos et al., 2023	Port of Tyne, ψηφιοποίηση ενεργειακών διεργασιών	Ψηφιακή μοντελοποίηση/σενάρια φορτίου	Ανάδειξη ψηφιακών δεδομένων στο σχεδιασμό της απανθρακοποίησης	Περισσότερο πλαίσιο ψηφιοποίησης παρά συγκριτικό benchmark ML
Song et al., 2024	Δύο πραγματικά λιμενικά datasets	TPA-LSTM, MQ-RNN, Deep Factors και ensemble	MAPE 6,23% και 7,94%	Υψηλή πολυπλοκότητα και περιορισμένη μεταφερσιμότητα
Ma et al., 2025	Μεταβλητό φορτίο μεγάλου λιμένα	VMD-ICSS, Bi-GRU και hybrid LSTM	Βελτίωση σε μη σταθερές και δομικά μεταβαλλόμενες σειρές	Περιορισμένη χρήση επιχειρησιακών εξωγενών μεταβλητών
Micallef et al., 2025	Πραγματικά δεδομένα port microgrid	RF, LSBoost, GPR, linear και naïve	RF expanding window: RMSE 1,18 MW, MAPE 7,25%	Τα δεδομένα δεν είναι διαθέσιμα δημόσια

Μελέτη	Περίπτωση/ δεδομένα	Μέθοδος	Κύριο εύρημα	Κύριος περιορισμός
Tang et al., 2025	Integrated port energy system	Load model βάσει αφίξεων και handling tasks + dispatch	Η λειτουργική μοντελοποίηση υποστηρίζει οικονομικότερο dispatch	Δεν αποτελεί καθαρό data-driven benchmark πρόβλεψης
Do Carmo et al., 2026	Port of Sines, smart meters, vessel calls, crane scheduling	Day-ahead LSTM	MAPE 10,55% → 3,59% με επιχειρησιακά δεδομένα	Εξάρτηση από πρόσβαση σε αξιόπιστα scheduling data

2.9. Σύνδεση της βιβλιογραφίας με την παρούσα εργασία

Η ανάλυση της βιβλιογραφίας αποτέλεσε τη βάση για τον σχεδιασμό της μεθοδολογίας που ακολουθείται στην παρούσα διπλωματική εργασία. Τα ευρήματα των προηγούμενων μελετών υποδεικνύουν ότι δεν υπάρχει ένας αλγόριθμος που να υπερέχει συστηματικά σε όλες τις εφαρμογές βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου. Η απόδοση κάθε μοντέλου εξαρτάται από τα χαρακτηριστικά του προβλήματος, τη διαθεσιμότητα και την ποιότητα των δεδομένων, την επιλογή των μεταβλητών εισόδου και το πρωτόκολλο αξιολόγησης που εφαρμόζεται (Guo et al., 2021; Hou et al., 2022; Akhtar et al., 2023).

Με βάση τα παραπάνω, η παρούσα εργασία υιοθετεί μία συγκριτική προσέγγιση, στην οποία αξιολογούνται διαφορετικές κατηγορίες μοντέλων μηχανικής μάθησης και βαθιάς μάθησης στο ίδιο σύνολο δεδομένων και υπό κοινές συνθήκες εκπαίδευσης και αξιολόγησης. Συγκεκριμένα, εξετάζονται ένα γραμμικό μοντέλο παλινδρόμησης (Linear Regression), δύο δένδροειδείς μέθοδοι συνόλου (Random Forest και XGBoost) και ένα μοντέλο βαθιάς μάθησης τύπου Long Short-Term Memory (LSTM). Η επιλογή αυτή επιτρέπει τη σύγκριση μοντέλων διαφορετικής πολυπλοκότητας και διαφορετικών μηχανισμών μάθησης, παρέχοντας μια ολοκληρωμένη εικόνα της καταλληλότητας τους για το συγκεκριμένο πρόβλημα.

Παράλληλα, η σχεδίαση της μεθοδολογίας δίνει ιδιαίτερη έμφαση στη χρήση χρονικά ορθής διαδικασίας εκπαίδευσης και αξιολόγησης, ώστε να αποφεύγεται η διαρροή πληροφορίας από το μέλλον προς το παρελθόν και να εξασφαλίζεται ότι όλα τα μοντέλα συγκρίνονται υπό ισοδύναμες συνθήκες. Επιπλέον, αξιοποιούνται τόσο ιστορικές τιμές φορτίου όσο και ημερολογιακές και μετεωρολογικές μεταβλητές, σύμφωνα με τα ευρήματα της βιβλιογραφίας σχετικά με τους σημαντικότερους παράγοντες που επηρεάζουν τη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου. Τέλος, η αξιολόγηση των μοντέλων δεν περιορίζεται μόνο στην προγνωστική τους ακρίβεια, αλλά περιλαμβάνει και ανάλυση της σχετικής συμβολής των χαρακτηριστικών εισόδου μέσω τεχνικών ερμηνευσιμότητας, με σκοπό τη διερεύνηση των παραγόντων που επηρεάζουν περισσότερο τις παραγόμενες προβλέψεις.

Με τον τρόπο αυτό, η παρούσα εργασία επιδιώκει να αξιολογήσει τη σχετική απόδοση διαφορετικών προσεγγίσεων πρόβλεψης βραχυπρόθεσμου ηλεκτρικού φορτίου σε πραγματικά δεδομένα κατανάλωσης του Λιμένα Πατρών, εφαρμόζοντας ενιαία διαδικασία προεπεξεργασίας, εκπαίδευσης, αξιολόγησης και ερμηνείας των αποτελεσμάτων. Η

προσέγγιση αυτή επιτρέπει τόσο τη σύγκριση της προγνωστικής ικανότητας των εξεταζόμενων μοντέλων όσο και τη διερεύνηση της επίδρασης των επιμέρους χαρακτηριστικών στις παραγόμενες προβλέψεις.

2.10. Σύγχρονες ερευνητικές προκλήσεις

Παρά τη σημαντική πρόοδο που έχει σημειωθεί στην εφαρμογή μοντέλων βαθιάς μάθησης για τη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου, εξακολουθούν να υπάρχουν σημαντικές ερευνητικές προκλήσεις. Πρώτον, η ποιότητα και η πληρότητα των δεδομένων παραμένουν καθοριστικοί παράγοντες για την αξιοπιστία των προβλέψεων. Τα μοντέλα βαθιάς μάθησης είναι ευαίσθητα σε ελλιπή, θορυβώδη ή ανακριβή δεδομένα, γεγονός που καθιστά απαραίτητη την κατάλληλη προεπεξεργασία και τον έλεγχο ποιότητας πριν από την εκπαίδευση των μοντέλων (Mystakidis et al., 2024; Mustaqeem et al., 2021).

Δεύτερον, η αυξανόμενη πολυπλοκότητα των σύγχρονων αρχιτεκτονικών και η «black-box» φύση πολλών μοντέλων βαθιάς μάθησης δημιουργούν σημαντικά ζητήματα ερμηνευσιμότητας. Η περιορισμένη δυνατότητα κατανόησης του τρόπου με τον οποίο παράγονται οι προβλέψεις αποτελεί σημαντικό ζήτημα σε εφαρμογές του ενεργειακού τομέα, όπου οι προβλέψεις χρησιμοποιούνται για τη λήψη των κρίσιμων επιχειρησιακών αποφάσεων, όπως ο προγραμματισμός παραγωγής και η διαχείριση του ηλεκτρικού φορτίου (Hong & Fan, 2016; Mystakidis et al., 2024). Για την αντιμετώπιση του περιορισμού αυτού, η πρόσφατη βιβλιογραφία αναδεικνύει την Εξηγήσιμη Τεχνητή Νοημοσύνη (Explainable Artificial Intelligence – XAI) ως μία από τις ερευνητικές κατευθύνσεις που μπορούν να ενισχύσουν τη διαφάνεια και την ερμηνευσιμότητα των μοντέλων πρόβλεψης (Chandrasekaran & Paramasivan, 2025; Misiurek et al., 2025).

Τρίτον, παραμένει ανοιχτό το ζήτημα της γενίκευσης των μοντέλων μεταξύ διαφορετικών εφαρμογών και τύπων καταναλωτών. Ένα μοντέλο που παρουσιάζει υψηλή απόδοση σε οικιακά δεδομένα ή σε κτιριακές εφαρμογές δεν είναι απαραίτητο ότι θα διατηρήσει την ίδια απόδοση σε βιομηχανικά και εμπορικά περιβάλλοντα ή εγκαταστάσεις υποδομών, καθώς τα πρότυπα κατανάλωσης και οι παράγοντες που επηρεάζουν τη ζήτηση μπορεί να διαφέρουν σημαντικά. Για τον λόγο αυτό, η πρόσφατη βιβλιογραφία επισημαίνει την ανάγκη για περισσότερες εφαρμογές σε διαφορετικά επιχειρησιακά περιβάλλοντα και για συγκριτικές αξιολογήσεις που λαμβάνουν υπόψη τα ιδιαίτερα χαρακτηριστικά κάθε συστήματος (Azeem et al., 2021; Misiurek et al., 2025).


Συνολικά, η σύγχρονη έρευνα στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου επικεντρώνεται όχι μόνο στη βελτίωση της προγνωστικής ακρίβειας, αλλά και στην ανάπτυξη μοντέλων που είναι περισσότερο αξιόπιστα, ερμηνεύσιμα και ικανά να γενικεύουν σε διαφορετικά επιχειρησιακά περιβάλλοντα. Επομένως, η επιλογή της κατάλληλης μεθόδου πρόβλεψης δεν θα πρέπει να βασίζεται αποκλειστικά στην προγνωστική απόδοση, αλλά να λαμβάνει επίσης υπόψη την ποιότητα των διαθέσιμων δεδομένων, την υπολογιστική πολυπλοκότητα, τη δυνατότητα ερμηνείας και τις απαιτήσεις της εκάστοτε εφαρμογής.

3. ΚΕΦΑΛΑΙΟ 3 – Περιγραφή δεδομένων και διερευνητική ανάλυση

3.1. Περιγραφή περίπτωσης μελέτης

3.1.1. Ο Λιμένας Πατρών ως αντικείμενο μελέτης

Ως περίπτωση μελέτης εξετάζεται ο Λιμένας Πατρών, ένας από τους σημαντικότερους λιμένες της χώρας και η σημαντικότερη θαλάσσια πύλη της Δυτικής Ελλάδας προς τη Δυτική Ευρώπη. Ο λιμένας βρίσκεται στον Πατραϊκό Κόλπο, εντός του αστικού ιστού της πόλης των Πατρών, και λόγω της στρατηγικής γεωγραφικής του θέσης διαδραματίζει καθοριστικό ρόλο στις θαλάσσιες μεταφορές, συνδέοντας την Ελλάδα με σημαντικούς λιμένες της Ιταλίας, όπως η Ανκόνα, το Μπάρι και το Μπρίντιζι, και του ευρωπαϊκού δικτύου μεταφορών μέσω τακτικών επιβατικών και εμπορευματικών δρομολογίων.



Εικόνα 1. Δορυφορική απεικόνιση του Λιμένα Πατρών. Διακρίνονται οι κύριες θαλάσσιες συνδέσεις του λιμένα προς την Ιταλία και τα νησιά του Ιονίου (Google Maps)

Ο Οργανισμός Λιμένος Πατρών χαρακτηρίζει τον λιμένα ως διατροφικό κόμβο της εφοδιαστικής αλυσίδας, γεγονός που αντικατοπτρίζει τον πολυλειτουργικό του χαρακτήρα (Ένωση Λιμένων Ελλάδος, 2024; Οργανισμός Λιμένος Πάτρας, 2023). Ο λιμένας εξυπηρετεί επιβατικές μεταφορές, εμπορευματική διακίνηση, μεταφορά οχημάτων και φορτηγών μέσω υπηρεσιών Ro-Ro (Roll-on/Roll-off), διακίνηση ασυνόδευτων ρυμουλκούμενων (trailers), καθώς και εμπορευματοκιβωτίων (containers). Η συνύπαρξη των δραστηριοτήτων αυτών δημιουργεί ένα σύνθετο επιχειρησιακό περιβάλλον το οποίο απαιτεί την ταυτόχρονη εξυπηρέτηση διαφορετικών λειτουργιών και επιχειρησιακών αναγκών.

Οι λιμενικές εγκαταστάσεις διακρίνονται στον Βόρειο (παλιό) και στον Νότιο (νέο) Λιμένα, με τον δεύτερο να αποτελεί τη σύγχρονη κύρια πύλη επιβατικών και εμπορευματικών μεταφορών. Διαθέτει σύγχρονες λιμενικές και ηλεκτρομηχανολογικές υποδομές, επιβατικούς σταθμούς, εγκαταστάσεις εξυπηρέτησης φορτίων και οχημάτων, καθώς και δίκτυα ηλεκτροδότησης και λοιπές υποστηρικτικές εγκαταστάσεις που υποστηρίζουν τις ανάγκες της σύγχρονης ναυτιλίας και του διεθνούς εμπορίου.


Ο λιμένας λειτουργεί σε συνεχή βάση (24 ώρες ημερησίως και 365 ημέρες ετησίως), εξυπηρετώντας επιβατικές και εμπορευματικές δραστηριότητες καθ' όλη τη διάρκεια του έτους. Ως αποτέλεσμα, η κατανάλωση ηλεκτρικής ενέργειας δεν περιορίζεται στις ώρες ή τους μήνες αιχμής της λιμενικής λειτουργίας, αλλά επηρεάζεται από το ευρύ φάσμα λειτουργιών και υπηρεσιών, δημιουργώντας σύνθετα πρότυπα ενεργειακής ζήτησης.

Η λειτουργία του λιμένα, σύμφωνα με τον Οργανισμό Λιμένος Πατρών, διέπεται από πολιτικές περιβαλλοντικής διαχείρισης που συμμορφώνονται με το πρότυπο ISO 14001:2015, ενώ παράλληλα προωθούνται δράσεις για την ανάπτυξη βιώσιμων υποδομών, τη μείωση του περιβαλλοντικού αποτυπώματος και την αξιοποίηση καθαρών μορφών ενέργειας. Η κατεύθυνση αυτή συμβαδίζει με τη διεθνή τάση μετάβασης προς έξυπνα και βιώσιμα λιμάνια (Smart & Sustainable Ports), στα οποία η αξιοποίηση δεδομένων και προηγμένων αναλυτικών μεθόδων αποτελεί βασικό εργαλείο βελτιστοποίησης της λειτουργίας τους.

Υπό το πρίσμα αυτό, ο Λιμένας Πατρών αποτελεί κατάλληλη περίπτωση μελέτης για την εφαρμογή μεθόδων βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου, καθώς η συνύπαρξη επιβατικών και εμπορευματικών δραστηριοτήτων, σε συνδυασμό με τη συνεχή λειτουργία του, δημιουργεί ένα πολύπλοκο και δυναμικό πρότυπο κατανάλωσης ηλεκτρικής ενέργειας. Η κατανόηση και η πρόβλεψη της ενεργειακής συμπεριφοράς του μπορούν να συμβάλουν στη βελτιστοποίηση της ενεργειακής διαχείρισης και στην αποτελεσματικότερη λειτουργία των λιμενικών εγκαταστάσεων.

3.1.2. Επιβατική κίνηση στον Λιμένα Πατρών την περίοδο 2021-2025

Σύμφωνα με στατιστικά στοιχεία λιμενικής δραστηριότητας της Ελληνικής Στατιστικής Αρχής (ΕΛΣΤΑΤ), η τριμηνιαία εξέλιξη της επιβατικής κίνησης στον Λιμένα Πατρών για την περίοδο 2021–2025 παρουσιάζεται στο Σχήμα 3 (Ελληνική Στατιστική Αρχή, 2025), όπου η συνολική επιβατική κίνηση υπολογίστηκε ως το άθροισμα διακινούμενων (επιβιβαζόμενων και αποβιβαζόμενων) επιβατών εσωτερικού και εξωτερικού. Τα τριμηνιαία στοιχεία της ΕΛΣΤΑΤ χρησιμοποιήθηκαν αποκλειστικά για την περιγραφική αποτύπωση του λειτουργικού προφίλ και της εποχικότητας του λιμένα. Δεν ενσωματώθηκαν ως είσοδοι στα μοντέλα, καθώς η χρονική τους ανάλυση δεν παρείχε ουσιαστική πληροφορία για τις ωριαίες μεταβολές της κατανάλωσης.



Σχήμα 3. Τριμηνιαία επιβατική κίνηση λιμένα Πατρών 2021-2025

Η επιβατική κίνηση παρουσιάζει εμφανή εποχικότητα, με σημαντική αύξηση της συνολικής επιβατικής κίνησης κατά το τρίτο τρίμηνο (Q3) κάθε έτους και αισθητά χαμηλότερες τιμές κατά το πρώτο τρίμηνο (Q1). Η εποχική αυτή συμπεριφορά συνδέεται με την αυξημένη τουριστική δραστηριότητα και τη μεγαλύτερη ζήτηση ακτοπλοϊκών και διεθνών συνδέσεων κατά τους θερινούς μήνες, γεγονός που αποτελεί χαρακτηριστικό των ελληνικών λιμένων με έντονη επιβατική κίνηση.


Όσον αφορά τις διακυμάνσεις μεταξύ των ετών, οι υψηλές τιμές της επιβατικής κίνησης που παρατηρούνται κατά την περίοδο 2022-2023 ενδέχεται να σχετίζονται με τη μεταπανδημική ανάκαμψη του τουρισμού και των διεθνών μετακινήσεων μετά τη σταδιακή άρση των περιοριστικών μέτρων για την COVID-19 στην Ελλάδα και την Ευρώπη (UNECE, 2022). Επομένως, οι διαφορές μεταξύ των πρώτων ετών της εξεταζόμενης περιόδου και των επόμενων δεν θα πρέπει να ερμηνεύονται αποκλειστικά ως ένδειξη μακροχρόνιας τάσης, αλλά και ως πιθανό αποτέλεσμα της αποκατάστασης της ταξιδιωτικής δραστηριότητας μετά την πανδημία.

Στο διάγραμμα φαίνεται επίσης ότι το μεγαλύτερο μέρος της συνολικής επιβατικής κίνησης του λιμένα κατέχει διαχρονικά η διεθνής επιβατική κίνηση, καθώς σε όλα τα τρίμηνα της μελετώμενης περιόδου, οι επιβάτες εξωτερικού υπερβαίνουν κατά πολύ τους επιβάτες εσωτερικού. Το γεγονός αυτό επιβεβαιώνει τον κομβικό ρόλο που έχει ο Λιμένας Πατρών ως διεθνής πύλη σύνδεσης της Ελλάδας με την Ιταλία και γενικότερα τη Δυτική Ευρώπη.

Η έντονη εποχικότητα της επιβατικής κίνησης υποδηλώνει την ύπαρξη υποκείμενου εποχικού προτύπου, στοιχείο που πρέπει να ληφθεί υπόψη κατά την ανάπτυξη και αξιολόγηση μοντέλων βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου, καθώς αναμένεται να επηρεάζεται αντίστοιχα και η συνολική λειτουργική δραστηριότητα του λιμένα. Κατ' επέκταση, η ζήτηση ηλεκτρικής ενέργειας ενδέχεται να παρουσιάζει αντίστοιχες εποχικές διακυμάνσεις και, ως εκ τούτου, καθίσταται αναγκαία η χρήση μοντέλων που μπορούν να συλλάβουν τόσο τις βραχυχρόνιες όσο και τις εποχικές μεταβολές της εξεταζόμενης χρονοσειράς.

3.1.3. Εμπορευματική κίνηση στον Λιμένα Πατρών την περίοδο 2021-2025

Σύμφωνα με στατιστικά στοιχεία λιμενικής δραστηριότητας της ΕΛΣΤΑΤ, η τριμηνιαία εξέλιξη της εμπορευματικής κίνησης στον Λιμένα Πατρών για την περίοδο 2021–2025 παρουσιάζεται στο διάγραμμα του Σχήματος 4 (Ελληνική Στατιστική Αρχή, 2025), όπου η συνολική διακίνηση εμπορευμάτων υπολογίστηκε ως το άθροισμα του μικτού βάρους των διακινούμενων (φορτωθέντων και εκφορτωθέντων) εμπορευμάτων εσωτερικού και εξωτερικού.



Σχήμα 4. Τριμηνιαία διακίνηση εμπορευμάτων στον Λιμένα Πατρών 2021-2025

Σε αντίθεση με την επιβατική κίνηση, η εμπορευματική κίνηση χαρακτηρίζεται από σχετικά σταθερά επίπεδα κατά τη διάρκεια της εξεταζόμενης περιόδου, παρότι παρατηρούνται περιορισμένες διακυμάνσεις μεταξύ των τριμήνων. Όπως φαίνεται και στο διάγραμμα, παρόλο που υπάρχει μια μικρή υποχώρηση κατά την περίοδο 2022–2023 ακολουθούμενη από μια ήπια ανάκαμψη κατά τα επόμενα έτη, οι συνολικές ποσότητες διακινούμενων εμπορευμάτων κυμαίνονται σε συγκρίσιμα επίπεδα χωρίς να διακρίνεται ένα σαφές επαναλαμβανόμενο εποχικό πρότυπο.

Από το διάγραμμα προκύπτει επίσης ότι το μεγαλύτερο μέρος της συνολικής εμπορευματικής κίνησης αντιστοιχεί διαχρονικά στη διεθνή διακίνηση εμπορευμάτων, καθώς το μικτό βάρος των διακινούμενων εμπορευμάτων εξωτερικού υπερβαίνει σημαντικά το αντίστοιχο των διακινούμενων εμπορευμάτων εσωτερικού σε όλα τα τρίμηνα της μελετώμενης περιόδου. Η παρατήρηση αυτή επιβεβαιώνει τον διεθνή διαμετακομιστικό χαρακτήρα του Λιμένα Πατρών και τον ρόλο του ως βασικής πύλης θαλάσσιας σύνδεσης της Ελλάδας με την Ιταλία και τη Δυτική Ευρώπη.

3.2. Ενεργειακά δεδομένα

Τα ωριαία δεδομένα κατανάλωσης παραχωρήθηκαν για τις ανάγκες της έρευνας από τον Οργανισμό Λιμένος Πατρών και αφορούν μετρητικά δεδομένα καμπύλης ενεργού ενέργειας για τον Νότιο Λιμένα Πατρών για την περίοδο από 01/01/2021 01:00 έως 01/11/2025 00:00. Η χρονοσειρά αποτελείται από 42.360 ωριαίες παρατηρήσεις κατανάλωσης ηλεκτρικής ενέργειας (kWh), οι οποίες χρησιμοποιήθηκαν ως μεταβλητή στόχος για την ανάπτυξη των μοντέλων πρόβλεψης.

3.3. Μετεωρολογικά δεδομένα

Τα μετεωρολογικά δεδομένα για την περιοχή του Νοτίου Λιμένα Πατρών (38.2267314° N, 21.7218917° E) αντλήθηκαν μέσω του API της πλατφόρμας Open-Meteo (Zippenfenig, 2024). Συλλέχθηκαν ωριαίες χρονοσειρές θερμοκρασίας, σχετικής υγρασίας, κατακρημνισμάτων, ταχύτητας και διεύθυνσης ανέμου, νεφοκάλυψης και ηλιακής

ακτινοβολίας που καλύπτουν την ίδια χρονική περίοδο με τα δεδομένα κατανάλωσης ηλεκτρικής ενέργειας.

3.4. Διερευνητική ανάλυση δεδομένων

3.4.1. Χρονική εξέλιξη της κατανάλωσης ηλεκτρικής ενέργειας


Το Σχήμα 5 παρουσιάζει τη χρονική εξέλιξη της ωριαίας κατανάλωσης ηλεκτρικής ενέργειας στο λιμάνι της Πάτρας για την μελετώμενη περίοδο 2021–2025. Παρατηρείται έντονη μεταβλητότητα με συχνές αιχμές κατανάλωσης και περιστασιακές απότομες μειώσεις, καθώς και εμφανής εποχικότητα, με υψηλότερα επίπεδα κατανάλωσης κατά τα έτη 2021–2022 και σχετική σταθεροποίηση κατά τα επόμενα έτη. Επιπλέον, διακρίνονται μεμονωμένες ακραίες τιμές, οι οποίες ενδέχεται να σχετίζονται με επιχειρησιακές μεταβολές του λιμένα ή τεχνικές ανωμαλίες. Απότομες πτώσεις της κατανάλωσης ενδέχεται να σχετίζονται με χρονικές ιδιαιτερότητες των καταγραφών ή μεμονωμένες ανωμαλίες των δεδομένων. Συνολικά, η χρονοσειρά χαρακτηρίζεται από έντονη χρονική μεταβλητότητα, εποχικότητα και παρουσία μη κανονικών γεγονότων, στοιχεία που εντείνουν την πολυπλοκότητα του προβλήματος πρόβλεψης φορτίου.



Σχήμα 5. Ωριαία κατανάλωση ηλεκτρικής ενέργειας λιμένα Πάτρας 2021-2025

3.4.2. Ημερήσια, εβδομαδιαία και εποχικά πρότυπα κατανάλωσης


Το μέσο ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας στο λιμάνι της Πάτρας για την περίοδο 2021–2025 παρουσιάζεται στο Σχήμα 6, όπου αποτυπώνεται η ενδοημερήσια μεταβλητότητα της ζήτησης. Εντός του 24ώρου παρατηρείται, όπως είναι αναμενόμενο, μείωση της κατανάλωσης από τις νυχτερινές έως τις πρώτες πρωινές ώρες, ενώ εμφανίζεται μια δευτερεύουσα αιχμή περί τις 08:00 η οποία πιθανόν σχετίζεται με την έναρξη της ημερήσιας δραστηριότητας. Στη συνέχεια, η ζήτηση αυξάνεται σταδιακά κατά τη διάρκεια της ημέρας και κορυφώνεται τις βραδινές ώρες, γεγονός που ενδέχεται να συνδέεται με την εντατικοποίηση της λιμενικής δραστηριότητας και τη λειτουργία των συστημάτων φωτισμού. Η μεγαλύτερη διασπορά των τιμών παρατηρείται κατά τις ώρες αιχμής, υποδηλώνοντας αυξημένη μεταβλητότητα στη ζήτηση τις περιόδους υψηλής κατανάλωσης. Συνολικά, το ημερήσιο προφίλ καταδεικνύει την παρουσία επαναλαμβανόμενων ενδοημερήσιων προτύπων και της αντίστοιχης χρονικής εξάρτησης της χρονοσειράς.



Σχήμα 6. Μέσο ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας λιμένα Πάτρας 2021-2025

Στα Σχήματα 7 και 8 παρουσιάζεται η κατανομή της κατανάλωσης ηλεκτρικής ενέργειας στο λιμάνι της Πάτρας για την περίοδο 2021–2025 ανά ημέρα της εβδομάδας και ανά μήνα αντίστοιχα, μέσω διαγραμμάτων κουτιού (boxplots). Τα διαγράμματα αυτά αποτυπώνουν βασικά στατιστικά χαρακτηριστικά της κατανομής των δεδομένων, όπως η διάμεσος, η διασπορά και οι ακραίες τιμές, επιτρέποντας τη συγκριτική αξιολόγηση της συμπεριφοράς της ζήτησης σε διαφορετικές χρονικές κλίμακες.


Διάγραμμα κουτιού (boxplot) κατανάλωσης ηλεκτρικής ενέργειας λιμένας Πάτρας ανά ημέρα εβδομάδας (2021-2025)



Σχήμα 7. Διάγραμμα κουτιού (boxplot) κατανάλωσης ηλεκτρικής ενέργειας λιμένα Πάτρας ανά ημέρα της εβδομάδας.


Στην κατανάλωση ηλεκτρικής ενέργειας ανά ημέρα της εβδομάδας (Σχήμα 7) παρατηρούνται παρόμοιες τιμές της διαμέσου και σημαντική επικάλυψη των κατανομών

μεταξύ των ημερών, γεγονός που υποδηλώνει ότι η κατανάλωση δεν διαφοροποιείται σημαντικά μεταξύ των ημερών της εβδομάδας. Οι ελαφρώς χαμηλότερες τιμές που εμφανίζονται τις Κυριακές ενδέχεται να σχετίζονται με μειωμένη λιμενική δραστηριότητα σε σχέση με τις εργάσιμες ημέρες. Παράλληλα, η παρουσία ακραίων τιμών σε όλες τις ημέρες της εβδομάδας δείχνει ότι περίοδοι υψηλής κατανάλωσης μπορούν να εμφανιστούν ανεξαρτήτως ημέρας. Εν κατακλείδι, η ημέρα της εβδομάδας φαίνεται να συνδέεται με ήπιες διαφοροποιήσεις της κατανάλωσης, χωρίς όμως να αναδεικνύεται ως ο κυρίαρχος παράγοντας των παρατηρούμενων διακυμάνσεων.



Σχήμα 8. Διάγραμμα κουτιού (boxplot) κατανάλωσης ηλεκτρικής ενέργειας λιμένα Πάτρας ανά μήνα του έτους.

Η κατανάλωση ηλεκτρικής ενέργειας ανά μήνα (Σχήμα 8), παρουσιάζει εντονότερες διαφοροποιήσεις τόσο στη διάμεσο όσο και στη διασπορά, υποδηλώνοντας την παρουσία εποχικότητας. Υψηλότερες τιμές καταγράφονται κατά τους θερινούς και χειμερινούς μήνες, γεγονός που ενδέχεται να σχετίζεται με αυξημένες ανάγκες θέρμανσης και κλιματισμού, ενώ χαμηλότερα επίπεδα εμφανίζονται κυρίως κατά την άνοιξη. Η παρουσία εποχικότητας επιβεβαιώνεται και στο Σχήμα 9, όπου παρουσιάζεται η χρονοσειρά της μέσης μηνιαίας κατανάλωσης ηλεκτρικής ενέργειας στο λιμάνι της Πάτρας για την μελετώμενη περίοδο 2021-2025. Συγκριτικά με την επίδραση της ημέρας της εβδομάδας, η μηνιαία διαφοροποίηση εμφανίζεται εντονότερη, αντανakλώντας την παρουσία εποχικών προτύπων στη χρονοσειρά.



Σχήμα 9. Μέση μηνιαία κατανάλωση ηλεκτρικής ενέργειας λιμένα Πάτρας 2021–2025

Ο θερμικός χάρτης του Σχήματος 10 παρουσιάζει τη μέση ωριαία κατανάλωση ηλεκτρικής ενέργειας ανά μήνα στο λιμάνι της Πάτρας για την περίοδο 2021–2025. Το διάγραμμα επιβεβαιώνει τα προαναφερθέντα χρονικά πρότυπα και αναδεικνύει τη συνδυασμένη επίδραση της εποχικότητας και της ενδοημερήσιας μεταβολής στη διαμόρφωση της ζήτησης ηλεκτρικής ενέργειας.




Σχήμα 10. Μέση ωριαία κατανάλωση ηλεκτρικής ενέργειας ανά μήνα στο λιμάνι της Πάτρας 2021–2025

3.4.3. Κατανομή της κατανάλωσης και ανάλυση αιχμών φορτίου


Η κατανομή της κατανάλωσης ηλεκτρικής ενέργειας στο λιμάνι της Πάτρας για την περίοδο 2021–2025 (Σχήμα 11) αναδεικνύει ότι η πλειονότητα των τιμών συγκεντρώνεται σε μεσαία επίπεδα κατανάλωσης, ενώ εμφανίζονται λιγότερες αλλά σημαντικά υψηλότερες τιμές στις


περιοχές υψηλού φορτίου. Η μορφή της κατανομής υποδηλώνει την παρουσία περιστασιακών αιχμών κατανάλωσης, οι οποίες συμβάλλουν στην αυξημένη μεταβλητότητα της χρονοσειράς. Η ιδιότητα αυτή ενδέχεται να επηρεάσει την απόδοση των μοντέλων πρόβλεψης, καθώς οι ακραίες τιμές και οι περίοδοι υψηλού φορτίου παρουσιάζουν συνήθως μεγαλύτερη δυσκολία πρόβλεψης σε σχέση με τις συχνότερες τιμές κατανάλωσης.



Σχήμα 11. Κατανομή κατανάλωσης ηλεκτρικής ενέργειας λιμένα Πάτρας 2021-2025

Στο Σχήμα 12 παρουσιάζεται η ανάλυση των αιχμών κατανάλωσης ηλεκτρικής ενέργειας στο λιμάνι της Πάτρας, όπου ως αιχμές θεωρήθηκαν οι τιμές που υπερβαίνουν το 95^ο εκατοστημόριο της κατανομής, ώστε να εντοπιστούν οι περίοδοι ασυνήθιστα υψηλής κατανάλωσης χωρίς να περιορίζεται η ανάλυση μόνο σε μεμονωμένες ακραίες τιμές. Οι αιχμές εμφανίζονται κυρίως κατά τις βραδινές ώρες, με μέγιστη συχνότητα γύρω στις 21:00–22:00, ενώ παρατηρείται μικρότερη συγκέντρωση και κατά τις πρωινές ώρες. Ως προς την ημέρα της εβδομάδας, δεν προκύπτουν σημαντικές διαφοροποιήσεις, ενώ σε ορισμένες περιόδους του έτους παρατηρείται αυξημένη συχνότητα υψηλών φορτίων. Συνολικά, η χρονική κατανομή των αιχμών υποδηλώνει ότι τα ακραία φορτία ακολουθούν επαναλαμβανόμενα χρονικά πρότυπα και δεν εμφανίζονται τυχαία στη χρονοσειρά.





Σχήμα 13. Διορθογράμματα αυτοσυσχέτισης της κατανάλωσης ηλεκτρικής ενέργειας στο λιμάνι της Πάτρας για την περίοδο 2021–2025 για 0–175 υστερήσεις (άνω) και 0–48 υστερήσεις για εστίαση στην ημερήσια περιοδικότητα (κάτω).

Συνολικά, η διερευνητική ανάλυση ανέδειξε ότι η κατανάλωση ηλεκτρικής ενέργειας στο λιμάνι της Πάτρας χαρακτηρίζεται από έντονη χρονική εξάρτηση, εποχικότητα, επαναλαμβανόμενα ενδοημερήσια πρότυπα και παρουσία περιόδων αυξημένου φορτίου. Η ημερήσια περιοδικότητα εμφανίζεται ως το κυρίαρχο χαρακτηριστικό της χρονοσειράς, ενώ εποχικές και ημερολογιακές μεταβολές φαίνεται επίσης να συμβάλλουν στη διαμόρφωση της ζήτησης ηλεκτρικής ενέργειας. Τα ευρήματα αυτά αξιοποιήθηκαν στη φάση ανάπτυξης των μοντέλων πρόβλεψης, υποστηρίζοντας την επιλογή μεταβλητών χρονικής υστέρησης καθώς και ημερολογιακών μεταβλητών για την ημέρα της εβδομάδας και τον μήνα του έτους, με σκοπό την αποτύπωση της χρονικής δυναμικής της ζήτησης.

4. Κεφάλαιο 4 — Μεθοδολογία

4.1. Συνολικό πλαίσιο πρόβλεψης

Στο παρόν κεφάλαιο περιγράφεται η μεθοδολογία που ακολουθήθηκε για την ανάπτυξη και αξιολόγηση των μοντέλων βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου. Παρουσιάζονται τα στάδια προεπεξεργασίας και μηχανικής χαρακτηριστικών των δεδομένων, το υπολογιστικό περιβάλλον υλοποίησης, οι μέθοδοι εκπαίδευσης και βελτιστοποίησης των μοντέλων, καθώς και οι μετρικές που χρησιμοποιήθηκαν για την αξιολόγηση της απόδοσής τους.

4.1.1. Περιβάλλον υλοποίησης και λογισμικό

Η ανάπτυξη και εκπαίδευση των μοντέλων πραγματοποιήθηκε στη γλώσσα προγραμματισμού Python, με χρήση των βιβλιοθηκών pandas για τη διαχείριση δεδομένων (McKinney, 2010), NumPy για αριθμητικούς υπολογισμούς (Harris et al., 2020), scikit-learn για την ανάπτυξη μοντέλων μηχανικής μάθησης (Pedregosa et al., 2011), XGBoost για την υλοποίηση μοντέλων gradient boosting (Chen & Guestrin, 2016) και matplotlib για την οπτικοποίηση δεδομένων (Hunter, 2007), ενώ για την ανάπτυξη των μοντέλων LSTM έγινε χρήση της βιβλιοθήκης TensorFlow/Keras (TensorFlow Developers, 2021).

Τα μοντέλα γραμμικής παλινδρόμησης, Random Forest και XGBoost υλοποιήθηκαν σε περιβάλλον Python έκδοσης 3.14.2, ενώ για την ανάπτυξη και εκπαίδευση των μοντέλων LSTM χρησιμοποιήθηκε ξεχωριστό υπολογιστικό περιβάλλον Python έκδοσης 3.10.11 με χρήση της βιβλιοθήκης TensorFlow/Keras, λόγω των αυξημένων υπολογιστικών απαιτήσεων των μοντέλων βαθιάς μάθησης και απαιτήσεων συμβατότητας του πλαισίου TensorFlow.

4.2. Προεπεξεργασία δεδομένων

Πριν από την ανάπτυξη των μοντέλων πρόβλεψης πραγματοποιήθηκε διαδικασία προεπεξεργασίας των δεδομένων με στόχο τη διασφάλιση της ποιότητας, της χρονολογικής συνέπειας και της καταλληλότητας της χρονοσειράς για εφαρμογές πρόβλεψης φορτίου. Η διαδικασία περιλάμβανε ελέγχους εγκυρότητας των δεδομένων, διαχείριση ανωμαλιών και μηδενικών τιμών, καθώς και χρονολογικό διαχωρισμό των δεδομένων σε σύνολα εκπαίδευσης και ελέγχου.

4.2.1. Έλεγχος δεδομένων και χρονολογική συνέπεια

Πριν από την ανάπτυξη των μοντέλων πραγματοποιήθηκε έλεγχος εγκυρότητας και χρονολογικής συνέπειας των δεδομένων, ώστε να διασφαλιστεί η καταλληλότητά τους για εφαρμογές πρόβλεψης χρονοσειρών. Αρχικά, οι χρονικές σημάνσεις μετατράπηκαν σε μορφή ημερομηνίας και ώρας (datetime format), ενώ τα δεδομένα ταξινομήθηκαν χρονολογικά κατά αύξουσα σειρά. Στη συνέχεια πραγματοποιήθηκε έλεγχος για τυχόν διπλότυπες χρονικές εγγραφές, καθώς και για ασυνέχειες στο ωριαίο χρονικό βήμα της χρονοσειράς, ώστε να διασφαλιστεί η ύπαρξη συνεχούς χρονικής ακολουθίας στα δεδομένα.

Επιπλέον, εξετάστηκε η ύπαρξη ελλিপών τιμών τόσο στη μεταβλητή κατανάλωσης όσο και στις μετεωρολογικές μεταβλητές. Δεν εντοπίστηκαν κενά ή χρονικές ασυνέχειες στα

προαναφερθέντα δεδομένα, γεγονός που επέτρεψε τη διατήρηση της αρχικής μορφής της χρονοσειράς χωρίς την ανάγκη τεχνικών συμπλήρωσης ή παρεμβολής δεδομένων.

4.2.2. Διαχείριση μηδενικών τιμών και ανωμαλιών

Κατά την προεπεξεργασία των δεδομένων εντοπίστηκαν 12 μηδενικές ή εξαιρετικά χαμηλές τιμές κατανάλωσης σε σύνολο 42.360 ωριαίων παρατηρήσεων, οι οποίες αντιστοιχούσαν σε ποσοστό μικρότερο του 0.03% του συνόλου των δεδομένων. Μέρος των τιμών αυτών συνδεόταν με μεταβάσεις θερινής και χειμερινής ώρας (Daylight Saving Time – DST), κατά τις οποίες εμφανίζονται χρονικές ιδιαιτερότητες στη χρονοσειρά λόγω αλλαγής του ωριαίου χρονικού βήματος. Οι αποκλίσεις αυτές μπορούν να αποδοθούν πιθανότατα στον τρόπο καταγραφής και χρονοσήμανσης των μετρήσεων από το σύστημα παρακολούθησης και δεν αντανakλούν απαραίτητα πραγματικές μεταβολές της κατανάλωσης ηλεκτρικής ενέργειας. Επιπλέον, παρατηρήθηκαν μεμονωμένες σύντομες περιόδους μηδενικής κατανάλωσης, οι οποίες επίσης ενδέχεται να σχετίζονται με μεμονωμένες επιχειρησιακές ή καταγραφικές ανωμαλίες.

Δεδομένου του εξαιρετικά μικρού ποσοστού εμφάνισης των τιμών αυτών και της περιορισμένης επίδρασής τους στη συνολική κατανομή της χρονοσειράς, οι παρατηρήσεις διατηρήθηκαν χωρίς εφαρμογή τεχνικών συμπλήρωσης ή παρεμβολής δεδομένων. Ωστόσο, η παρουσία μηδενικών ή πολύ μικρών τιμών ελήφθη υπόψη κατά την επιλογή των μετρικών αξιολόγησης, καθώς δείκτες όπως το Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (Mean Absolute Percentage Error – MAPE) εμφανίζουν αστάθεια όταν πραγματοποιείται διαίρεση με τιμές που προσεγγίζουν το μηδέν, οδηγώντας σε παραπλανητικά μεγάλες τιμές του δείκτη.

4.2.3. Χρονολογικός διαχωρισμός εκπαίδευσης–ελέγχου

Για την ανάπτυξη και αξιολόγηση των μοντέλων πρόβλεψης εφαρμόστηκε χρονολογικός διαχωρισμός των δεδομένων σε σύνολα εκπαίδευσης και ελέγχου (train–test split), διατηρώντας τη φυσική χρονική ακολουθία της χρονοσειράς. Δεδομένου ότι η διαθέσιμη χρονοσειρά υπολειπόταν κατά περίπου δύο μήνες των πέντε πλήρων ημερολογιακών ετών, επιλέχθηκε χρονολογικός διαχωρισμός 80/20 αντί διαχωρισμού βάσει ακέραιων ετών. Συγκεκριμένα, το πρώτο 80% των παρατηρήσεων χρησιμοποιήθηκε για την εκπαίδευση των μοντέλων, ενώ το τελευταίο 20% χρησιμοποιήθηκε αποκλειστικά για την τελική αξιολόγηση της προγνωστικής τους ικανότητας σε μελλοντικά μη παρατηρημένα δεδομένα. Με τον τρόπο αυτό διατηρήθηκε η χρονική σειρά των παρατηρήσεων, ενώ εξασφαλίστηκε επαρκές μέγεθος τόσο για την εκπαίδευση όσο και για την τελική αξιολόγηση των μοντέλων.

Μετά τον διαχωρισμό των δεδομένων δημιουργήθηκαν ξεχωριστά για τα σύνολα εκπαίδευσης και ελέγχου οι μεταβλητές χρονικής υστέρησης, διαδικασία που οδήγησε στην εισαγωγή κενών τιμών (NaN) στην αρχή κάθε συνόλου. Για τον λόγο αυτό αφαιρέθηκαν οι πρώτες 168 ωριαίες παρατηρήσεις από τα σύνολα εκπαίδευσης και ελέγχου, αριθμός που αντιστοιχούσε σε πολύ μικρό ποσοστό του συνολικού πλήθους των δεδομένων χωρίς ουσιαστική επιρροή στη διαδικασία εκπαίδευσης και αξιολόγησης των μοντέλων.

4.3. Μηχανική χαρακτηριστικών (Feature Engineering)

Στο πλαίσιο της ανάπτυξης των μοντέλων πρόβλεψης πραγματοποιήθηκε διαδικασία μηχανικής χαρακτηριστικών (feature engineering) με σκοπό την αποτύπωση της χρονικής δυναμικής και των εξωτερικών παραγόντων που επηρεάζουν τη ζήτηση ηλεκτρικής ενέργειας. Οι μεταβλητές που χρησιμοποιήθηκαν προέκυψαν τόσο από τα ευρήματα της

διερευνητικής ανάλυσης δεδομένων όσο και από τη σχετική βιβλιογραφία πρόβλεψης φορτίου, και περιλάμβαναν μεταβλητές χρονικής υστέρησης, μετεωρολογικές μεταβλητές, ημερολογιακές μεταβλητές και μεταβλητές χρονικής τάσης.

4.3.1. Μεταβλητές χρονικής υστέρησης

Για την αποτύπωση της χρονικής εξάρτησης της χρονοσειράς δημιουργήθηκαν μεταβλητές χρονικής υστέρησης (lag features), οι οποίες χρησιμοποιούν προηγούμενες τιμές της κατανάλωσης ηλεκτρικής ενέργειας ως μεταβλητές εισόδου στα μοντέλα πρόβλεψης. Η επιλογή των χρονικών υστερήσεων βασίστηκε τόσο στα ευρήματα της διερευνητικής ανάλυσης δεδομένων όσο και στην ανάλυση αυτοσυσχέτισης της χρονοσειράς, όπου παρατηρήθηκε έντονη ημερήσια περιοδικότητα και ισχυρή αυτοσυσχέτιση σε χρονικές υστερήσεις που αποτελούσαν πολλαπλάσια των 24 ωρών.

Συγκεκριμένα, χρησιμοποιήθηκαν οι μεταβλητές υστέρησης μίας ώρας (lag1), εικοσιτεσσάρων ωρών (lag24) και εκατόν εξήντα οκτώ ωρών (lag168). Η μεταβλητή lag1 επιτρέπει την αποτύπωση της βραχυχρόνιας εξάρτησης μεταξύ διαδοχικών ωριαίων παρατηρήσεων, η μεταβλητή lag24 αποτυπώνει την ημερήσια επαναληπτικότητα της κατανάλωσης, ενώ η μεταβλητή lag168 χρησιμοποιήθηκε για την αναπαράσταση πιθανών εβδομαδιαίων προτύπων στη χρονοσειρά.

4.3.2. Μετεωρολογικές μεταβλητές

Για την αποτύπωση της επίδρασης των καιρικών συνθηκών στη ζήτηση ηλεκτρικής ενέργειας χρησιμοποιήθηκαν οι μετεωρολογικές μεταβλητές θερμοκρασίας, σχετικής υγρασίας, κατακρημνισμάτων, ταχύτητας ανέμου, διεύθυνσης ανέμου, νεφοκάλυψης και ηλιακής ακτινοβολίας, στις αντίστοιχες μονάδες μέτρησης που παρέχονταν από τη βάση δεδομένων Open-Meteo (Zippenfenig, 2024), όπως παρουσιάζονται στον Πίνακα 6. Οι μεταβλητές αυτές χρησιμοποιούνται συχνά σε εφαρμογές πρόβλεψης φορτίου, καθώς επηρεάζουν άμεσα ή έμμεσα τη λειτουργία συστημάτων θέρμανσης, ψύξης και φωτισμού, καθώς και γενικότερα την ενεργειακή συμπεριφορά εγκαταστάσεων και υποδομών.

Τα αντίστοιχα ωριαία μετεωρολογικά δεδομένα για τη μελετώμενη χρονική περίοδο αντλήθηκαν μέσω του API του Open-Meteo (Zippenfenig, 2024) για την τοποθεσία του Νοτίου Λιμένα Πατρών (γεωγραφικές συντεταγμένες 38.2267314° N, 21.7218917° E). Για λόγους που σχετίζονταν με τη μη διαθεσιμότητα ομοιογενούς συνόλου μετεωρολογικών προβλέψεων για ολόκληρη την περίοδο μελέτης, χρησιμοποιήθηκαν οι ιστορικές παρατηρήσεις των παραπάνω μεταβλητών από το Historical Weather API του Open-Meteo και όχι προγνώσεις καιρού. Η επιλογή αυτή εξασφάλισε χρονικά συνεπή δεδομένα για όλο το εξεταζόμενο διάστημα και επέτρεψε την αξιολόγηση των μοντέλων πρόβλεψης φορτίου χωρίς την πρόσθετη επίδραση του σφάλματος μιας μετεωρολογικής πρόγνωσης. Κατά συνέπεια, η αξιολόγηση έχει ex post χαρακτήρα ως προς τις μετεωρολογικές εισόδους, γεγονός που εξετάζεται αναλυτικότερα στους περιορισμούς της μελέτης.

Πίνακας 6. Μετεωρολογικές μεταβλητές που χρησιμοποιήθηκαν

Μεταβλητή	Περιγραφή	Χρονική αναφορά	Μονάδα μέτρησης
temperature_2m	Θερμοκρασία αέρα στα 2 m από το έδαφος	Στιγμιαία τιμή	°C
relative_humidity_2m	Σχετική υγρασία στα 2 m από το έδαφος	Στιγμιαία τιμή	%
Precipitation	Συνολικό ύψος κατακρημνισμάτων	Άθροισμα προηγούμενης ώρας	mm
wind_speed_10m	Ταχύτητα ανέμου στα 10 m από το έδαφος	Στιγμιαία τιμή	km/h
wind_direction_10m	Διεύθυνση ανέμου στα 10 m από το έδαφος	Στιγμιαία τιμή	-
cloud_cover	Συνολική νεφοκάλυψη	Στιγμιαία τιμή	%
shortwave_radiation	Ηλιακή ακτινοβολία μικρού μήκους κύματος	Μέση τιμή προηγούμενης ώρας	W/m ²

4.3.3. Μεταβλητή χρονικής τάσης

Για την αποτύπωση πιθανών μακροχρόνιων μεταβολών στη χρονοσειρά δημιουργήθηκε μεταβλητή χρονικής τάσης (trend). Η μεταβλητή αυτή αντιστοιχεί σε έναν αύξοντα αριθμητικό δείκτη, ο οποίος αυξάνεται κατά μία μονάδα για κάθε διαδοχική ωριαία παρατήρηση.

Η εισαγωγή της μεταβλητής τάσης αποσκοπεί στην αναπαράσταση μακροπρόθεσμων σταδιακών μεταβολών στο επίπεδο της κατανάλωσης ηλεκτρικής ενέργειας πέρα από τις βραχυχρόνιες και περιοδικές εξαρτήσεις που αποτυπώνονται μέσω των μεταβλητών χρονικής υστέρησης. Οι εν λόγω μεταβολές ενδέχεται να σχετίζονται με αλλαγές στη λειτουργία του λιμένα, στη συνολική ζήτηση ή σε άλλους μακροχρόνιους παράγοντες κατά τη διάρκεια της μελετώμενης περιόδου 2021-2025.

4.3.4. Ημερολογιακές μεταβλητές

Η διερευνητική ανάλυση δεδομένων έδειξε ότι υπήρχαν κάποιες διαφοροποιήσεις της κατανάλωσης ως προς την ημέρα της εβδομάδας και τον μήνα, περιέχοντας δυνητικά χρήσιμη πληροφορία για την πρόβλεψη του φορτίου. Έτσι, στο πλαίσιο της μηχανικής χαρακτηριστικών χρησιμοποιήθηκαν ημερολογιακές μεταβλητές, με στόχο την αποτύπωση πιθανών εβδομαδιαίων και μηνιαίων προτύπων στη χρονοσειρά κατανάλωσης ηλεκτρικής ενέργειας. Η συμπερίληψη των μεταβλητών αυτών επιτρέπει στα μοντέλα να λαμβάνουν υπόψη συστηματικές μεταβολές που σχετίζονται με συγκεκριμένες ημέρες της εβδομάδας, μήνες ή περιόδους του έτους, οι οποίες ενδέχεται να επηρεάζουν τη λειτουργία και την ενεργειακή κατανάλωση του λιμένα.

Συγκεκριμένα, εφαρμόστηκε δυαδική κωδικοποίηση κατηγορικών μεταβλητών (one-hot encoding) για την ημέρα της εβδομάδας και τον μήνα. Για την αποφυγή πολυσυγγραμμικότητας μια ημέρα της εβδομάδας και ένας μήνας, εν προκειμένω η Δευτέρα και ο Ιανουάριος αντίστοιχα, χρησιμοποιήθηκαν ως κατηγορίες αναφοράς και δεν συμπεριλήφθηκαν στο τελικό σύνολο χαρακτηριστικών. Συνεπώς, οι συντελεστές των

υπόλοιπων ημερών και μηνών ερμηνεύονται ως αποκλίσεις σε σχέση με τις αντίστοιχες κατηγορίες αναφοράς.

4.4. Κλιμάκωση δεδομένων

Για τη βελτίωση της διαδικασίας εκπαίδευσης εφαρμόστηκε, όπου κρίθηκε απαραίτητο, διαδικασία κλιμάκωσης των δεδομένων πριν από την εκπαίδευση των μοντέλων, ώστε οι μεταβλητές εισόδου να βρίσκονται σε συγκρίσιμη αριθμητική κλίμακα. Η επιλογή της μεθόδου κλιμάκωσης διαφοροποιήθηκε ανάλογα με τα χαρακτηριστικά και τις απαιτήσεις κάθε αλγορίθμου. Σε όλες τις περιπτώσεις όπου εφαρμόστηκε κλιμάκωση, οι μετασχηματισμοί κλιμάκωσης προσαρμόστηκαν αποκλειστικά στα δεδομένα εκπαίδευσης και στη συνέχεια εφαρμόστηκαν στα δεδομένα ελέγχου, ώστε να αποφεύγεται η διαρροή πληροφορίας (data leakage) από το σύνολο ελέγχου προς το σύνολο εκπαίδευσης.

Για τα μοντέλα Random Forest και XGBoost δεν εφαρμόστηκε κλιμάκωση των δεδομένων, καθώς τα μοντέλα που βασίζονται σε δέντρα απόφασης βασίζονται σε διαδοχικούς διαχωρισμούς των χαρακτηριστικών και συνεπώς η απόδοσή τους δεν επηρεάζεται ουσιωδώς από την κλίμακα των μεταβλητών εισόδου.

4.4.1. Τυποποίηση (standardization)

Για το μοντέλο γραμμικής παλινδρόμησης χρησιμοποιήθηκε διαδικασία τυποποίησης (standardization), μέσω της οποίας κάθε μεταβλητή εισόδου μετασχηματίστηκε ώστε να παρουσιάζει μέση τιμή ίση με μηδέν και μοναδιαία τυπική απόκλιση (Géron, 2019), ως εξής:

$$z = \frac{x - \mu}{\sigma}$$

όπου x και z είναι αντίστοιχα η αρχική και η τυποποιημένη τιμή της μεταβλητής, μ η μέση τιμή και σ η τυπική απόκλιση της μεταβλητής στο σύνολο εκπαίδευσης.

Η κλιμάκωση εφαρμόστηκε αποκλειστικά στις μεταβλητές εισόδου, ενώ η μεταβλητή στόχος διατηρήθηκε στις αρχικές μονάδες μέτρησης (kWh), ώστε οι προβλέψεις και οι μετρικές αξιολόγησης να παραμένουν άμεσα ερμηνεύσιμες.

4.4.2. Κανονικοποίηση (Normalization)

Για τα μοντέλα LSTM χρησιμοποιήθηκε διαδικασία κανονικοποίησης (normalization), κατά την οποία οι μεταβλητές μετασχηματίστηκαν στο διάστημα $[0, 1]$, σύμφωνα με τη σχέση (Géron, 2019):

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}}$$

όπου x και x' είναι αντίστοιχα η αρχική και η κανονικοποιημένη τιμή της μεταβλητής, ενώ x_{min} και x_{max} αντιστοιχούν η ελάχιστη και η μέγιστη τιμή της μεταβλητής στο σύνολο εκπαίδευσης.

Η μέθοδος αυτή επιλέχθηκε λόγω της αυξημένης ευαισθησίας των νευρωνικών δικτύων στην κλίμακα των δεδομένων εισόδου. Στα μοντέλα LSTM η κανονικοποίηση εφαρμόστηκε τόσο στις μεταβλητές εισόδου όσο και στη μεταβλητή στόχο. Μετά την ολοκλήρωση της διαδικασίας πρόβλεψης πραγματοποιήθηκε αντίστροφος μετασχηματισμός (inverse transformation) των προβλέψεων, ώστε οι τελικές τιμές και οι

μετρικές αξιολόγησης να εκφράζονται στις αρχικές μονάδες μέτρησης της κατανάλωσης ηλεκτρικής ενέργειας (kWh).

4.5. Ανάπτυξη μοντέλων πρόβλεψης

Στο πλαίσιο της παρούσας εργασίας αναπτύχθηκαν και αξιολογήθηκαν διαφορετικές κατηγορίες μοντέλων βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου, με στόχο τη σύγκριση της απόδοσής τους στο ίδιο πρόβλημα πρόβλεψης μίας ώρας μπροστά. Τα μοντέλα που εξετάστηκαν περιλάμβαναν κλασικά μοντέλα μηχανικής μάθησης και νευρωνικά δίκτυα βαθιάς μάθησης, ώστε να αξιολογηθεί η ικανότητά τους να αποτυπώνουν τη χρονική δυναμική και τη μεταβλητότητα της κατανάλωσης ηλεκτρικής ενέργειας.

Οι μεταβλητές και η αναπαράσταση των εισόδων προσαρμόστηκαν στη δομή κάθε οικογένειας μοντέλων, όπως περιγράφεται στις αντίστοιχες υποενότητες. Στα μοντέλα Γραμμικής Παλινδρόμησης, Random Forest και XGBoost χρησιμοποιήθηκαν οι μεταβλητές χρονικής υστέρησης, οι μετεωρολογικές μεταβλητές, η μεταβλητή χρονικής τάσης και οι ημερολογιακές μεταβλητές που περιεγράφηκαν στις Ενότητες 4.3.1 έως 4.3.4. Στα μοντέλα LSTM οι είσοδοι οργανώθηκαν σε χρονικές ακολουθίες και διαφοροποιήθηκαν ανάλογα με τη διαμόρφωση: τα μονομεταβλητά μοντέλα χρησιμοποίησαν μόνο την ιστορική κατανάλωση, ενώ τα πολυμεταβλητά συνδύασαν την ιστορική κατανάλωση με μετεωρολογικές και χρονικές μεταβλητές. Για την αξιολόγηση εφαρμόστηκε κοινός αρχικός χρονολογικός διαχωρισμός 80/20, με επιμέρους διαφοροποιήσεις στον αριθμό των τελικών δειγμάτων λόγω των χρονικών υστερήσεων και των διαφορετικών μηκών ιστορικού παραθύρου. Η απόδοση όλων των μοντέλων αξιολογήθηκε με τις κοινές μετρικές που παρουσιάζονται στην Ενότητα 4.6.1.

4.5.1. Μοντέλο Γραμμικής Παλινδρόμησης

Το μοντέλο γραμμικής παλινδρόμησης χρησιμοποιήθηκε ως βασικό μοντέλο αναφοράς (benchmark model) για αποτύπωση της σχέσης μεταξύ της κατανάλωσης ηλεκτρικής ενέργειας και των μεταβλητών εισόδου, καθώς παρέχει μία απλή και ερμηνεύσιμη βάση σύγκρισης για την αξιολόγηση της απόδοσης των πιο σύνθετων μοντέλων μηχανικής μάθησης και βαθιάς μάθησης.

Η υλοποίηση του μοντέλου γραμμικής παλινδρόμησης έγινε με χρήση της κλάσης LinearRegression της βιβλιοθήκης scikit-learn. Πριν από την εκπαίδευση του μοντέλου εφαρμόστηκε τυποποίηση των μεταβλητών εισόδου με τη μέθοδο StandardScaler της ίδιας βιβλιοθήκης, ενώ η μεταβλητή στόχος διατηρήθηκε στην αρχική της κλίμακα (kWh), ώστε οι προβλέψεις του μοντέλου και οι μετρικές αξιολόγησης που βασίζονται στις πραγματικές τιμές κατανάλωσης να υπολογίζονται απευθείας στις αρχικές μονάδες μέτρησης (kWh). Εξαιτίας της διαδικασίας τυποποίησης, οι συντελεστές της γραμμικής παλινδρόμησης δεν εκφράζουν άμεσα μεταβολές στις αρχικές μονάδες μέτρησης των μεταβλητών, αλλά μπορούν να χρησιμοποιηθούν συγκριτικά για την αξιολόγηση της σχετικής συμβολής των χαρακτηριστικών στην πρόβλεψη του φορτίου.

4.5.2. Μοντέλο τυχαίου δάσους (Random Forest)

Για την ανάπτυξη του μοντέλου Random Forest χρησιμοποιήθηκε η κλάση RandomForestRegressor της βιβλιοθήκης scikit-learn. Το μοντέλο επιλέχθηκε λόγω της ικανότητάς του να αποτυπώνει μη γραμμικές σχέσεις και αλληλεπιδράσεις μεταξύ των

μεταβλητών εισόδου, καθώς και λόγω της ανθεκτικότητάς του σε θόρυβο και υπερπροσαρμογή μέσω της διαδικασίας συνάθροισης πολλαπλών δέντρων απόφασης.

Η εκπαίδευση του μοντέλου πραγματοποιήθηκε στα μη κλιμακωμένα δεδομένα εισόδου, καθώς τα μοντέλα που βασίζονται σε δέντρα απόφασης θεωρούνται γενικά μη ευαίσθητα στην κλίμακα των μεταβλητών και δεν απαιτούν διαδικασία κανονικοποίησης ή τυποποίησης των χαρακτηριστικών εισόδου.

Για τη βελτιστοποίηση των υπερπαραμέτρων εφαρμόστηκε διαδικασία αναζήτησης πλέγματος υπερπαραμέτρων (GridSearchCV) με χρήση διασταυρούμενης επικύρωσης χρονοσειρών (TimeSeriesSplit) αποκλειστικά στο σύνολο εκπαίδευσης. Οι υπερπαραμέτροι που διερευνήθηκαν περιλάμβαναν τον αριθμό των δέντρων ($n_estimators$), το μέγιστο βάθος των δέντρων (max_depth), τον ελάχιστο αριθμό δειγμάτων για διάσπαση κόμβου ($min_samples_split$) και τον ελάχιστο αριθμό δειγμάτων ανά φύλλο ($min_samples_leaf$). Η αξιολόγηση των διαφορετικών συνδυασμών και η επιλογή των βέλτιστων υπερπαραμέτρων πραγματοποιήθηκαν με βάση τη μετρική της ρίζας του μέσου τετραγωνικού σφάλματος (RMSE). Τα εύρη τιμών των υπερπαραμέτρων επιλέχθηκαν με βάση συνήθειες πρακτικές βελτιστοποίησης μοντέλων δέντρων απόφασης και προκαταρκτικές δοκιμές.

Η διαδικασία βελτιστοποίησης πραγματοποιήθηκε σε δύο στάδια, περιλαμβάνοντας αρχική διερεύνηση ευρύτερων περιοχών τιμών των υπερπαραμέτρων (coarse grid search) και στη συνέχεια λεπτομερέστερη αναζήτηση (fine grid search) σε περιοχές τιμών που παρουσίασαν την καλύτερη απόδοση. Κατά τη διαδικασία βελτιστοποίησης, μεταξύ ισοδύναμων διαμορφώσεων υπερπαραμέτρων προτιμήθηκαν εκείνες που περιόριζαν την πολυπλοκότητα των επιμέρους δέντρων, με στόχο τη βελτίωση της ικανότητας γενίκευσης και τον περιορισμό της υπερπροσαρμογής. Η διαδικασία βελτιστοποίησης οδήγησε σε τελικό μοντέλο με 400 δέντρα ($n_estimators=400$), μέγιστο βάθος δέντρων 12 ($max_depth=12$), τουλάχιστον 6 δείγματα ανά φύλλο ($min_samples_leaf=6$) και ελάχιστο πλήθος δειγμάτων για τη διάσπαση κόμβου 5 ($min_samples_split=5$).

Μετά την ολοκλήρωση της διαδικασίας βελτιστοποίησης, το τελικό μοντέλο με τις βέλτιστες υπερπαραμέτρους εκπαιδεύτηκε εκ νέου στο πλήρες σύνολο εκπαίδευσης και στη συνέχεια αξιολογήθηκε στο ανεξάρτητο σύνολο ελέγχου.

4.5.3. Μοντέλο XGBoost

Για την ανάπτυξη του μοντέλου XGBoost χρησιμοποιήθηκε η κλάση XGBRegressor της βιβλιοθήκης XGBoost. Η εκπαίδευση πραγματοποιήθηκε στα μη κλιμακωμένα δεδομένα εισόδου, ακολουθώντας αντίστοιχη διαδικασία βελτιστοποίησης υπερπαραμέτρων με εκείνη που εφαρμόστηκε στο μοντέλο Random Forest, μέσω αναζήτησης πλέγματος υπερπαραμέτρων και διασταυρούμενης επικύρωσης χρονοσειρών.

Οι υπερπαραμέτροι που διερευνήθηκαν περιλάμβαναν τον αριθμό δέντρων ($n_estimators$), το μέγιστο βάθος των δέντρων (max_depth), τον ρυθμό εκμάθησης ($learning_rate$) και το ποσοστό δειγμάτων ($subsample$) και χαρακτηριστικών ($colsample_bytree$) που χρησιμοποιούνταν σε κάθε επανάληψη εκπαίδευσης. Τα εύρη τιμών των υπερπαραμέτρων επιλέχθηκαν με βάση συνήθειες πρακτικές βελτιστοποίησης μοντέλων XGBoost και προκαταρκτικές δοκιμές.

Η διαδικασία βελτιστοποίησης οδήγησε σε τελικό μοντέλο με 180 δέντρα ($n_estimators=180$), μέγιστο βάθος των δέντρων 5 ($max_depth=5$), ρυθμό εκμάθησης 0,05 ($learning_rate=0,05$) και ποσοστό δειγμάτων ($subsample=0,8$) και χαρακτηριστικών ($colsample_bytree=0,8$) αμφότερα 0,8.

Μετά την ολοκλήρωση της διαδικασίας βελτιστοποίησης, το τελικό μοντέλο εκπαιδεύτηκε εκ νέου στο πλήρες σύνολο εκπαίδευσης και έπειτα αξιολογήθηκε στο ανεξάρτητο σύνολο ελέγχου.

4.5.4. Ανάπτυξη των μοντέλων LSTM

Πέραν των κλασικών μοντέλων μηχανικής μάθησης που παρουσιάστηκαν στις προηγούμενες ενότητες, αναπτύχθηκε και ένα μοντέλο Long Short-Term Memory (LSTM) με σκοπό τη διερεύνηση της δυνατότητας των επαναλαμβανόμενων νευρωνικών δικτύων να μοντελοποιήσουν τις χρονικές εξαρτήσεις της χρονοσειράς και να βελτιώσουν την πρόβλεψη του ηλεκτρικού φορτίου μίας ώρας μπροστά (one-hour-ahead forecasting). Η ανάπτυξη του μοντέλου περιλάμβανε τον σχεδιασμό της αναπαράστασης των δεδομένων εισόδου, την επιλογή του ιστορικού χρονικού παραθύρου, τη διερεύνηση διαφορετικών συνόλων μεταβλητών εισόδου, τον καθορισμό της αρχιτεκτονικής του δικτύου καθώς και τη βελτιστοποίηση των υπερπαραμέτρων εκπαίδευσης. Οι επιμέρους αυτές διαδικασίες παρουσιάζονται στις επόμενες ενότητες, ενώ η τελική διαμόρφωση του μοντέλου προέκυψε από τη συγκριτική αξιολόγηση των εξεταζόμενων επιλογών.

4.5.4.1. Διαμόρφωση του συνόλου δεδομένων επιβλεπόμενης μάθησης

Πριν από την ανάπτυξη και αξιολόγηση των μοντέλων, το σύνολο δεδομένων διαχωρίστηκε χρονολογικά σε σύνολο εκπαίδευσης (80%) και ανεξάρτητο σύνολο ελέγχου (20%), χωρίς τυχαία αναδιάταξη των παρατηρήσεων, ώστε να διατηρηθεί η χρονική συνέχεια της χρονοσειράς. Το σύνολο εκπαίδευσης χρησιμοποιήθηκε για την αξιολόγηση των υποψήφιων διαμορφώσεων και την ανάπτυξη του τελικού μοντέλου, ενώ το σύνολο ελέγχου χρησιμοποιήθηκε αποκλειστικά για την τελική αξιολόγηση της προγνωστικής επίδοσης, ώστε να εξασφαλιστεί αντικειμενική εκτίμηση της δυνατότητας γενίκευσης του μοντέλου σε μη χρησιμοποιημένα δεδομένα.

Πριν από τη δημιουργία των ακολουθιών εισόδου, οι μεταβλητές κανονικοποιήθηκαν με τη μέθοδο κανονικοποίησης Min-Max (Min-Max Scaling), ώστε οι τιμές τους να μετασχηματιστούν στο διάστημα $[0,1]$. Η κανονικοποίηση πραγματοποιήθηκε χρησιμοποιώντας αποκλειστικά τα δεδομένα του συνόλου εκπαίδευσης, ενώ οι ίδιες παράμετροι μετασχηματισμού εφαρμόστηκαν στη συνέχεια στο σύνολο ελέγχου, αποφεύγοντας τη διαρροή πληροφορίας από τα δεδομένα αξιολόγησης προς τη διαδικασία εκπαίδευσης.

Στη συνέχεια, η κανονικοποιημένη χρονοσειρά μετασχηματίστηκε σε σύνολο δεδομένων επιβλεπόμενης μάθησης μέσω της μεθόδου του μετακινούμενου χρονικού παραθύρου (sliding window). Συγκεκριμένα, διαδοχικές παρατηρήσεις ομαδοποιήθηκαν σε ακολουθίες εισόδου, ενώ ως μεταβλητή-στόχος ορίστηκε η κατανάλωση ηλεκτρικής ενέργειας της αμέσως επόμενης ώρας. Έτσι, κάθε δείγμα αποτελούνταν από μία ιστορική ακολουθία εισόδου και την αντίστοιχη τιμή στόχο της επόμενης χρονικής στιγμής. Με τον τρόπο αυτό δημιουργήθηκε το σύνολο δειγμάτων που χρησιμοποιήθηκε για την εκπαίδευση και αξιολόγηση του δικτύου. Η επιλογή του μήκους του ιστορικού παραθύρου αντιμετωπίστηκε ως μεθοδολογική παράμετρος και διερευνήθηκε στη συνέχεια μέσω συγκριτικής αξιολόγησης, όπως περιγράφεται στην ενότητα 4.5.4.3.

4.5.4.2. Διαδικασία εκπαίδευσης και αξιολόγησης των υποψήφιων μοντέλων

Η αξιολόγηση όλων των υποψήφιων διαμορφώσεων του μοντέλου πραγματοποιήθηκε με διαδικασία διαδοχικής χρονικής επικύρωσης τύπου Rolling Origin (Rolling Origin Validation), χρησιμοποιώντας επεκτεινόμενο σύνολο εκπαίδευσης (expanding window). Στη διαδικασία αυτή, η χρονική προέλευση της πρόβλεψης μετατοπιζόταν διαδοχικά προς τα εμπρός, ενώ το σύνολο εκπαίδευσης εμπλουτιζόταν κάθε φορά με τις νέες διαθέσιμες ιστορικές παρατηρήσεις. Με τον τρόπο αυτό, κάθε πρόβλεψη βασιζόταν, ως προς το ηλεκτρικό φορτίο, αποκλειστικά σε ιστορικές παρατηρήσεις που θα ήταν διαθέσιμες έως τη συγκεκριμένη χρονική στιγμή. Έτσι, το μοντέλο αξιολογήθηκε σε πολλαπλά χρονικά σημεία υπό συνθήκες που, ως προς τη διαθεσιμότητα της ιστορικής πληροφορίας φορτίου, προσομοιώνουν τη μελλοντική επιχειρησιακή εφαρμογή ενός συστήματος βραχυπρόθεσμης πρόβλεψης. Οι παρατηρηθείσες μετεωρολογικές μεταβλητές χρησιμοποιήθηκαν σε πλαίσιο εκ των υστέρων (ex post) αξιολόγησης, όπως αναλύεται στους περιορισμούς της μελέτης.

Η ίδια διαδικασία εκπαίδευσης και αξιολόγησης εφαρμόστηκε σε όλες τις υποψήφιες διαμορφώσεις του μοντέλου, συμπεριλαμβανομένης της επιλογής του ιστορικού χρονικού παραθύρου, των μεταβλητών εισόδου, καθώς και της αρχιτεκτονικής και των υπερπαραμέτρων του δικτύου. Με τον τρόπο αυτό, όλες οι εναλλακτικές προσεγγίσεις αξιολογήθηκαν υπό το ίδιο πειραματικό πρωτόκολλο και η τελική επιλογή βασίστηκε αποκλειστικά στην προγνωστική τους επίδοση.

4.5.4.3. Επιλογή του ιστορικού χρονικού παραθύρου

Η επιλογή του ιστορικού χρονικού παραθύρου επηρεάζει άμεσα την πληροφορία που αξιοποιεί το μοντέλο, καθώς καθορίζει το πλήθος των προηγούμενων παρατηρήσεων που είναι διαθέσιμες στο δίκτυο για την πρόβλεψη της επόμενης χρονικής στιγμής. Για τον λόγο αυτό, το μήκος του παραθύρου αντιμετωπίστηκε ως μεθοδολογική παράμετρος προς διερεύνηση και όχι ως προκαθορισμένη επιλογή.

Η διερευνητική ανάλυση των δεδομένων και ειδικότερα η συνάρτηση αυτοσυσχέτισης (Autocorrelation Function – ACF) ανέδειξαν έντονη ημερήσια περιοδικότητα, με ισχυρή συσχέτιση σε υστέρηση 24 ωρών. Η παρατήρηση αυτή υποδηλώνει ότι η πληροφορία του προηγούμενου ημερήσιου κύκλου θα μπορούσε να αποτελέσει επαρκές ιστορικό πλαίσιο για την πρόβλεψη του φορτίου της επόμενης ώρας. Παράλληλα, εξετάστηκε και η χρήση ιστορικού παραθύρου 168 ωρών (εβδομάδας), με σκοπό να διερευνηθεί εάν η παροχή μεγαλύτερου χρονικού ιστορικού θα επέτρεπε στο δίκτυο να αξιοποιήσει πρόσθετες χρονικές εξαρτήσεις που δεν αποτυπώνονται σε ένα ημερήσιο παράθυρο.

Κατά συνέπεια, αναπτύχθηκαν δύο εναλλακτικές διαμορφώσεις του μοντέλου με ιστορικά παράθυρα 24 και 168 ωρών αντίστοιχα, για τις οποίες ακολουθήθηκε η ίδια διαδικασία εκπαίδευσης και αξιολόγησης. Η συγκριτική αξιολόγηση της προγνωστικής τους επίδοσης οδήγησε στην επιλογή του χρονικού παραθύρου των 24 ωρών, με τα αντίστοιχα αποτελέσματα να παρουσιάζονται στο Κεφάλαιο 5.

4.5.4.4. Επιλογή των μεταβλητών εισόδου

Η αρχική διαμόρφωση του μοντέλου βασίστηκε σε πολυμεταβλητή αναπαράσταση των δεδομένων εισόδου, αξιοποιώντας τόσο τις ιστορικές τιμές του ηλεκτρικού φορτίου όσο και τις διαθέσιμες μετεωρολογικές και ημερολογιακές μεταβλητές. Η επιλογή αυτή

ευθυγραμμίζεται με τη συνήθη πρακτική της βιβλιογραφίας και επιτρέπει την αξιοποίηση πιθανών εξωγενών παραγόντων που επηρεάζουν τη ζήτηση ηλεκτρικής ενέργειας. Παρότι η χρήση εξωγενών μεταβλητών αποτελεί συνήθη πρακτική στη βιβλιογραφία της βραχυπρόθεσμης πρόβλεψης φορτίου, αρκετές μελέτες έχουν δείξει ότι όταν η χρονοσειρά παρουσιάζει έντονη αυτοσυσχέτιση και σαφή ημερήσια περιοδικότητα, τα δίκτυα LSTM μπορούν να εξάγουν το μεγαλύτερο μέρος της προγνωστικής πληροφορίας από τις ίδιες τις ιστορικές τιμές του φορτίου. Η διερευνητική ανάλυση της παρούσας εργασίας έδειξε επίσης ισχυρή αυτοσυσχέτιση σε υστέρηση 24 ωρών, γεγονός που οδήγησε στη διερεύνηση του κατά πόσο οι πρόσθετες μεταβλητές συνέβαλλαν ουσιαστικά στην προγνωστική επίδοση. Η παρατήρηση αυτή οδήγησε στη διερεύνηση της υπόθεσης ότι ένα δίκτυο LSTM, το οποίο έχει σχεδιαστεί για την εκμάθηση χρονικών εξαρτήσεων από διαδοχικές παρατηρήσεις, θα μπορούσε να επιτύχει υψηλή προγνωστική επίδοση χρησιμοποιώντας αποκλειστικά ιστορικές τιμές φορτίου στο συγκεκριμένο σύνολο δεδομένων.

Για τον λόγο αυτό, πέραν της πολυμεταβλητής εκδοχής, αναπτύχθηκε και αξιολογήθηκε μία μονομεταβλητή εκδοχή του μοντέλου. Για κάθε συνδυασμό τύπου εισόδου και μήκους ιστορικού παραθύρου εφαρμόστηκε το ίδιο πειραματικό πρωτόκολλο και το ίδιο πλέγμα υποψήφιων υπερπαραμέτρων. Ωστόσο, η επιλογή των βέλτιστων υπερπαραμέτρων πραγματοποιήθηκε χωριστά για κάθε διαμόρφωση μέσω της διαδικασίας χρονικής διασταυρωμένης επικύρωσης. Επομένως, η σύγκριση αφορά την απόδοση των αντίστοιχων βελτιστοποιημένων διαμορφώσεων.

Στην πολυμεταβλητή διαμόρφωση, κάθε χρονικό παράθυρο εισόδου περιλάμβανε τις ιστορικές τιμές του ηλεκτρικού φορτίου, τις διαθέσιμες μετεωρολογικές μεταβλητές, τη μεταβλητή χρονικής τάσης, την ώρα της ημέρας, τη δυαδική ένδειξη Σαββατοκύριακου και τις κατηγορικές μεταβλητές της ημέρας της εβδομάδας και του μήνα. Η ώρα της ημέρας παρείχε ένα σταθερό σημείο αναφοράς για τη θέση κάθε παρατήρησης στον ημερήσιο κύκλο των επικαλυπτόμενων ακολουθιών, ενώ η ένδειξη Σαββατοκύριακου παρείχε άμεση διάκριση μεταξύ εργάσιμων ημερών και Σαββατοκύριακου. Αντίθετα, στη μονομεταβλητή διαμόρφωση χρησιμοποιήθηκαν αποκλειστικά οι ιστορικές τιμές του ηλεκτρικού φορτίου. Η τελική επιλογή της βέλτιστης διαμόρφωσης πραγματοποιήθηκε βάσει της χαμηλότερης μέσης τιμής του RMSE στους πέντε διαδοχικούς διαχωρισμούς της χρονικής διασταυρωμένης επικύρωσης. Τα αποτελέσματα της σύγκρισης παρουσιάζονται αναλυτικά στο Κεφάλαιο 5.

4.5.4.5. Οριστικοποίηση της αρχιτεκτονικής του δικτύου και βελτιστοποίηση των υπερπαραμέτρων

Μετά τον καθορισμό του ιστορικού χρονικού παραθύρου και των μεταβλητών εισόδου, ακολούθησε η οριστικοποίηση της αρχιτεκτονικής του δικτύου και των υπερπαραμέτρων εκπαίδευσης. Δεδομένου ότι η προγνωστική επίδοση ενός μοντέλου LSTM εξαρτάται τόσο από τη δομή του δικτύου όσο και από τη διαδικασία εκπαίδευσής του, οι δύο αυτές παράμετροι διερευνήθηκαν συνδυαστικά.

Στο πλαίσιο αυτό αξιολογήθηκαν εναλλακτικές διαμορφώσεις της αρχιτεκτονικής του δικτύου, μεταβάλλοντας τον αριθμό των μονάδων του επιπέδου LSTM και το ποσοστό dropout. Παράλληλα, διερευνήθηκαν διαφορετικοί συνδυασμοί βασικών υπερπαραμέτρων εκπαίδευσης, όπως ο ρυθμός μάθησης (learning rate) και το μέγεθος της παρτίδας εκπαίδευσης (batch size), ενώ οι υπόλοιπες υπερπαραμέτροι της διαδικασίας εκπαίδευσης διατηρήθηκαν σταθερές, ώστε να απομονωθεί η επίδραση των εξεταζόμενων υπερπαραμέτρων στην προγνωστική επίδοση του μοντέλου.

Η εκπαίδευση όλων των υποψήφιων μοντέλων πραγματοποιήθηκε με χρήση του αλγορίθμου βελτιστοποίησης Adam, ο οποίος αποτελεί μία από τις πλέον διαδεδομένες και αποτελεσματικές μεθόδους εκπαίδευσης βαθιών νευρωνικών δικτύων και χρησιμοποιείται εκτενώς στη σύγχρονη βιβλιογραφία της βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου (Dong et al., 2025). Ως συνάρτηση απώλειας χρησιμοποιήθηκε το Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error – MSE), κατάλληλο για προβλήματα παλινδρόμησης συνεχών μεταβλητών. Για τον περιορισμό της υπερπροσαρμογής (overfitting) στα δεδομένα εκπαίδευσης εφαρμόστηκε μηχανισμός πρόωρης διακοπής της εκπαίδευσης (Early Stopping), με επαναφορά των βέλτιστων βαρών του δικτύου, ώστε η διαδικασία εκπαίδευσης να διακόπτεται όταν δεν παρατηρούνταν περαιτέρω βελτίωση της προγνωστικής επίδοσης στο σύνολο επικύρωσης.

Η τελική διαμόρφωση του μοντέλου προέκυψε από τη συγκριτική αξιολόγηση των εξεταζόμενων συνδυασμών και παρουσιάζεται σε επόμενη ενότητα, ενώ τα αντίστοιχα αποτελέσματα παρουσιάζονται στο Κεφάλαιο 5.

Όλες οι υποψήφιες διαμορφώσεις εκπαιδεύτηκαν και αξιολογήθηκαν σύμφωνα με τη διαδικασία χρονικής επικύρωσης τύπου Rolling Origin που περιεγράφηκε στην ενότητα 4.5.4.2. Η τελική επιλογή βασίστηκε στη συγκριτική αξιολόγηση της μέσης τιμής του δείκτη RMSE στις επιμέρους επαναλήψεις της διαδικασίας, καθώς ο δείκτης αυτός χρησιμοποιήθηκε ως κύριο κριτήριο επιλογής του βέλτιστου μοντέλου. Η τελική διαμόρφωση παρουσιάζεται στην επόμενη ενότητα, ενώ τα αποτελέσματα της συγκριτικής αξιολόγησης παρουσιάζονται στο Κεφάλαιο 5.

4.5.4.6. Τελική διαμόρφωση και εκπαίδευση του μοντέλου

Με βάση τη συγκριτική αξιολόγηση των προηγούμενων ενοτήτων, η τελική διαμόρφωση του μοντέλου προέκυψε από τη διαδοχική διαδικασία βελτιστοποίησης. Ειδικότερα, επιλέχθηκε ιστορικό χρονικό παράθυρο 24 ωρών και μονομεταβλητή αναπαράσταση των δεδομένων εισόδου, όπως προέκυψε από τις συγκριτικές αξιολογήσεις που παρουσιάζονται στο κεφάλαιο 5. Τα χαρακτηριστικά της τελικής αρχιτεκτονικής του δικτύου και οι αντίστοιχες υπερπαράμετροι εκπαίδευσης μετά τη βελτιστοποίηση παρουσιάζονται στον Πίνακα 7.

Πίνακας 7. Χαρακτηριστικά βέλτιστου μονομεταβλητού μοντέλου LSTM με ιστορικό παράθυρο 24 ωρών

Παράμετρος	Περιγραφή	Τελική τιμή
Μονάδες επιπέδου LSTM (LSTM units)	Αριθμός μονάδων μνήμης του επιπέδου LSTM που καθορίζει την υπολογιστική ικανότητα του δικτύου.	128
Ποσοστό dropout (Dropout)	Ποσοστό μονάδων που απενεργοποιούνται προσωρινά κατά την εκπαίδευση για τον περιορισμό της υπερπροσαρμογής.	0,10
Αλγόριθμος βελτιστοποίησης (Optimizer)	Αλγόριθμος ενημέρωσης των βαρών του δικτύου κατά την εκπαίδευση.	Adam

Συνάρτηση απώλειας (Loss function)	Μέτρο του σφάλματος που ελαχιστοποιείται κατά τη διαδικασία εκπαίδευσης.	MSE
Ρυθμός μάθησης (Learning rate)	Μέγεθος του βήματος με το οποίο ενημερώνονται τα βάρη του δικτύου.	0,0005
Μέγεθος παρτίδας εκπαίδευσης (Batch size)	Πλήθος δειγμάτων που χρησιμοποιούνται σε κάθε ενημέρωση των βαρών.	32
Διαχωρισμοί χρονικής επικύρωσης	Πλήθος διαδοχικών χρονικών διαχωρισμών σε σύνολα εκπαίδευσης και επικύρωσης	5
Μέγιστος αριθμός εποχών ανά διαχωρισμό επικύρωσης (Maximum epochs)	Ανώτατος αριθμός πλήρων διελεύσεων από το σύνολο εκπαίδευσης.	100
Πρόωρη διακοπή κατά την επικύρωση (Early Stopping)	Μηχανισμός διακοπής της εκπαίδευσης όταν δεν παρατηρείται περαιτέρω βελτίωση στο σύνολο επικύρωσης.	Ναι
Υπομονή κατά την επικύρωση (Patience)	Αριθμός εποχών αναμονής πριν την ενεργοποίηση του μηχανισμού Early Stopping.	10
Τυχαία αναδιάταξη	Αναδιάταξη των ακολουθιών εκπαίδευσης πριν από κάθε εποχή.	Όχι
Κριτήριο επιλογής μοντέλου (Model selection criterion)	Δείκτης που χρησιμοποιήθηκε για τη σύγκριση και επιλογή της βέλτιστης διαμόρφωσης.	Μέση τιμή RMSE στους πέντε διαχωρισμούς χρονικής επικύρωσης

Κατά τη διαδικασία χρονικής διασταυρωμένης επικύρωσης, τα υποψήφια μοντέλα εκπαιδεύτηκαν για έως 100 εποχές με εφαρμογή πρόωρης διακοπής και υπομονή 10 εποχών. Για κάθε διαχωρισμό καταγράφηκε η εποχή στην οποία επιτεύχθηκε η χαμηλότερη τιμή RMSE στο σύνολο επικύρωσης. Μετά την επιλογή της βέλτιστης διαμόρφωσης, το τελικό μοντέλο επανεκπαιδεύτηκε στο πλήρες σύνολο εκπαίδευσης, χωρίς τυχαία αναδιάταξη των ακολουθιών και για αριθμό εποχών ίσο με τη διάμεσο των αντίστοιχων βέλτιστων εποχών. Στο στάδιο αυτό δεν εφαρμόστηκε πρόωρη διακοπή, καθώς δεν χρησιμοποιήθηκε ξεχωριστό σύνολο επικύρωσης. Το ανεξάρτητο σύνολο ελέγχου χρησιμοποιήθηκε αποκλειστικά για την τελική αξιολόγηση της προγνωστικής επίδοσης.

4.6. Μετρικές σφάλματος και διαγνωστική αξιολόγηση των μοντέλων

4.6.1. Αριθμητικές μετρικές αξιολόγησης

Προκειμένου να αξιολογηθεί η απόδοση των μοντέλων υπολογίστηκαν ως μετρικές ο συντελεστής προσδιορισμού (R^2), το μέσο απόλυτο σφάλμα (MAE), η ρίζα του μέσου τετραγωνικού σφάλματος (RMSE), το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE), το συμμετρικό μέσο απόλυτο ποσοστιαίο σφάλμα (sMAPE) και ο συντελεστής μεταβλητότητας της ρίζας του μέσου τετραγωνικού σφάλματος (CV(RMSE)). Η RMSE προτιμήθηκε από την MSE καθώς περιέχει ουσιαστικά την ίδια πληροφορία, ενώ επιπλέον εκφράζεται στις ίδιες μονάδες μέτρησης με τη μεταβλητή στόχο (kWh).

Για τη συγκριτική αξιολόγηση των μοντέλων και τη συζήτηση των αποτελεσμάτων επιλέχθηκαν ως μετρικές τα R^2 , RMSE, MAE, sMAPE και CV(RMSE). Η μετρική sMAPE χρησιμοποιήθηκε αντί της MAPE, καθώς η παρουσία πολύ μικρών ή μηδενικών τιμών φορτίου στο σύνολο δεδομένων μπορεί να οδηγήσει σε ασταθείς, μη αντιπροσωπευτικές τιμές της τελευταίας. Τέλος, το CV(RMSE) χρησιμοποιήθηκε ως κανονικοποιημένο μέτρο σφάλματος που απαντάται ευρέως στη βιβλιογραφία ενεργειακών προβλέψεων.

4.6.2. Διαγνωστική αξιολόγηση μοντέλων

Πέραν των αριθμητικών μετρικών απόδοσης, πραγματοποιήθηκε και διαγνωστική αξιολόγηση των μοντέλων μέσω της ανάλυσης των σφαλμάτων πρόβλεψης ή υπολοίπων (residuals), τα οποία ορίζονται ως η διαφορά μεταξύ της πραγματικής και της προβλεπόμενης τιμής (Hyndman & Athanasopoulos, 2021):

$$e_t = y_t - \hat{y}_t$$

Η ανάλυση των υπολοίπων χρησιμοποιήθηκε συμπληρωματικά για την αξιολόγηση της συμπεριφοράς των μοντέλων και περιλάμβανε τη μελέτη της χρονικής εξέλιξης των σφαλμάτων πρόβλεψης, της συσχέτισης μεταξύ πραγματικών και προβλεπόμενων τιμών καθώς και της συνάρτησης αυτοσυσχέτισης (ACF), με στόχο τον εντοπισμό πιθανών συστηματικών σφαλμάτων ή υπολειπόμενων χρονικών εξαρτήσεων.

5. ΚΕΦΑΛΑΙΟ 5 — ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΣΥΖΗΤΗΣΗ

Στο παρόν κεφάλαιο παρουσιάζονται και συζητούνται τα αποτελέσματα των μοντέλων πρόβλεψης που αναπτύχθηκαν στο πλαίσιο της εργασίας. Για κάθε μοντέλο παρατίθενται οι μετρικές απόδοσης, οι γραφικές απεικονίσεις των προβλέψεων και η ανάλυση των υπολοίπων, ενώ ακολουθεί ερμηνεία των αποτελεσμάτων και συζήτηση των βασικών ευρημάτων.

5.1. Αποτελέσματα Γραμμικής Παλινδρόμησης

Η Γραμμική Παλινδρόμηση χρησιμοποιήθηκε ως βασικό μοντέλο αναφοράς (benchmark model) για την αξιολόγηση της απόδοσης των πιο σύνθετων μοντέλων μηχανικής μάθησης και βαθιάς μάθησης. Το μοντέλο εκπαιδεύτηκε στα τυποποιημένα δεδομένα εισόδου και αξιολογήθηκε στο ανεξάρτητο σύνολο ελέγχου.

5.1.1. Μετρικές απόδοσης

Τα αποτελέσματα, τα οποία συνοψίζονται στον πίνακα 8, έδειξαν ότι το μοντέλο γραμμικής παλινδρόμησης πέτυχε ικανοποιητική προγνωστική απόδοση με συντελεστή προσδιορισμού $R^2=0.884$ στο σύνολο ελέγχου και $RMSE = 18,83$ kWh. Η σχετικά μικρή διαφορά της απόδοσης βάσει των τιμών R^2 στα σύνολα εκπαίδευσης και ελέγχου υποδηλώνει καλή ικανότητα γενίκευσης του μοντέλου.


Πίνακας 8. Μετρικές απόδοσης μοντέλου γραμμικής παλινδρόμησης

Μοντέλο	R^2 train	R^2 test	MAE	RMSE	sMAPE	CV(RMSE)
Γραμμική παλινδρόμηση	0,920	0,884	13,44	18,83	6,42	8,68

Παρά τον απλό γραμμικό χαρακτήρα του μοντέλου, τα αποτελέσματα υποδεικνύουν ότι σημαντικό μέρος της μεταβλητότητας του ηλεκτρικού φορτίου μπορεί να εξηγηθεί μέσω γραμμικών σχέσεων μεταξύ της κατανάλωσης και των μεταβλητών εισόδου.

5.1.2. Πραγματικές και προβλεπόμενες τιμές χρονοσειράς


Στο Σχήμα 14, στο οποίο παρουσιάζονται οι πραγματικές και οι προβλεπόμενες τιμές φορτίου για το μοντέλο γραμμικής παλινδρόμησης στο σύνολο ελέγχου, φαίνεται ότι το μοντέλο αναπαράγει ικανοποιητικά τη γενική δυναμική της χρονοσειράς, αποτυπώνοντας τόσο τον ημερήσιο κύκλο όσο και τις μακροχρόνιες διακυμάνσεις της κατανάλωσης κατά τη διάρκεια της περιόδου αξιολόγησης.



Σχήμα 14: Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου στο σύνολο ελέγχου για το μοντέλο γραμμικής παλινδρόμησης


Για την καλύτερη οπτικοποίηση της προσαρμογής του μοντέλου, στο διάγραμμα του Σχήματος 15 παρουσιάζονται ενδεικτικά οι πρώτες δέκα ημέρες του συνόλου ελέγχου, όπου διαπιστώνεται ότι το μοντέλο αναπαράγει με σχετική ακρίβεια τη χρονική θέση και το μέγεθος των περισσότερων ημερήσιων αιχμών και ελαχίστων τιμών. Ωστόσο, σε ορισμένες

περιπτώσεις παρατηρείται τάση εξομάλυνσης των ακραίων τιμών, καθώς ορισμένες από τις υψηλότερες αιχμές υποεκτιμώνται ενώ ορισμένες από τις χαμηλότερες τιμές υπερεκτιμώνται, υποδηλώνοντας ότι μέρος της μεταβλητότητας του φορτίου, ιδιαίτερα κατά τη διάρκεια απότομων μεταβολών και ακραίων τιμών, δεν περιγράφεται πλήρως από το μοντέλο.



Σχήμα 15. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου για τις 10 πρώτες ημέρες του συνόλου ελέγχου στο μοντέλο γραμμικής παλινδρόμησης


Το διάγραμμα του Σχήματος 16 παρουσιάζει τη συσχέτιση μεταξύ των πραγματικών και των προβλεπόμενων τιμών φορτίου για το μοντέλο γραμμικής παλινδρόμησης. Παρατηρείται ότι η πλειονότητα των σημείων συγκεντρώνεται κοντά στη γραμμή ταύτισης πραγματικών και προβλεπόμενων τιμών, γεγονός που επιβεβαιώνει την ικανοποιητική προσαρμογή του μοντέλου και είναι συνεπές με την υψηλή τιμή του συντελεστή προσδιορισμού ($R^2 = 0,884$). Παράλληλα, παρατηρούνται ορισμένες αποκλίσεις από τη γραμμή ταύτισης πραγματικών και προβλεπόμενων τιμών, οι οποίες αντιστοιχούν σε περιπτώσεις αυξημένου σφάλματος πρόβλεψης και είναι συνεπείς με τις αποκλίσεις που παρατηρήθηκαν στα προηγούμενα διαγράμματα της χρονοσειράς.



Σχήμα 16. Συσχέτιση μεταξύ πραγματικών και προβλεπόμενων τιμών φορτίου στο σύνολο ελέγχου για το μοντέλο γραμμικής παλινδρόμησης


5.1.3. Χρονική συμπεριφορά των υπολοίπων

Το διάγραμμα του Σχήματος 17 παρουσιάζει τα υπόλοιπα του μοντέλου γραμμικής παλινδρόμησης στο σύνολο ελέγχου. Παρατηρείται ότι τα υπόλοιπα κατανέμονται γενικά γύρω από το μηδέν χωρίς εμφανή μακροχρόνια τάση ή συστηματική μετατόπιση, υποδηλώνοντας ότι το μοντέλο δεν παρουσιάζει εμφανή συστηματική τάση υπερεκτίμησης ή υποεκτίμησης του φορτίου. Ορισμένες μεμονωμένες ακραίες αποκλίσεις αντιστοιχούν σε χρονικές στιγμές αυξημένου σφάλματος πρόβλεψης και πιθανόν να σχετίζονται με απότομες μεταβολές ή ασυνήθιστες τιμές φορτίου που αποκλίνουν από τα κυρίαρχα πρότυπα που έχει μάθει το μοντέλο.



Σχήμα 17. Υπόλοιπα του μοντέλου γραμμικής παλινδρόμησης στο σύνολο ελέγχου.

Το διάγραμμα του Σχήματος 18 παρουσιάζει τη συνάρτηση αυτοσυσχέτισης (Autocorrelation Function – ACF) των υπολοίπων του μοντέλου γραμμικής παλινδρόμησης. Παρατηρούνται κορυφές στις χρονικές υστερήσεις των 24, 48, 72 και 168 ωρών οι οποίες υπερβαίνουν εμφανώς τα όρια εμπιστοσύνης του διαγράμματος, υποδηλώνοντας την ύπαρξη υπολειπόμενης ημερήσιας και εβδομαδιαίας περιοδικότητας στα σφάλματα πρόβλεψης. Συνεπώς, παρά την ικανοποιητική συνολική απόδοση του μοντέλου, φαίνεται ότι μέρος των χρονικών εξαρτήσεων της χρονοσειράς παραμένει αποτυπωμένο στα υπόλοιπα.



Σχήμα 18. Συνάρτηση αυτοσυσχέτισης (ACF) των υπολοίπων του μοντέλου γραμμικής παλινδρόμησης.

5.1.4. Συντελεστές μοντέλου

Ο Πίνακας 9 παρουσιάζει τους συντελεστές του μοντέλου της γραμμικής παλινδρόμησης ταξινομημένους κατά φθίνουσα απόλυτη τιμή. Δεδομένου ότι οι μεταβλητές εισόδου είχαν προηγουμένως τυποποιηθεί, οι συντελεστές μπορούν να ερμηνευτούν συγκριτικά ως προς τη σχετική συμβολή κάθε χαρακτηριστικού στην πρόβλεψη του φορτίου. Οι κατηγορίες αναφοράς είναι η Δευτέρα για την ημέρα της εβδομάδας και ο Ιανουάριος για τον μήνα.

Πίνακας 9. Συντελεστές του μοντέλου γραμμικής παλινδρόμησης.

Μεταβλητή	Περιγραφή	Συντελεστής
lag24	Χρονική υστέρηση 24 ωρών (ημέρας)	32.6501064
lag1	Χρονική υστέρηση 1 ώρας	25.71328425
lag168	Χρονική υστέρηση 168 ωρών (εβδομάδας)	21.58815876
day_of_week_5	Σάββατο	-6.239204664
day_of_week_6	Κυριακή	-6.187816169
day_of_week_2	Τετάρτη	-4.989445404
day_of_week_1	Τρίτη	-4.85771987
day_of_week_4	Παρασκευή	-3.849636223
day_of_week_3	Πέμπτη	-3.281253658
month_9	Σεπτέμβριος	-2.230959525
month_8	Αύγουστος	-1.983598735
month_2	Φεβρουάριος	-1.53339472
month_10	Οκτώβριος	-1.524494727
month_7	Ιούλιος	-1.327127321
relative_humidity_2m	Σχετική υγρασία στα 2m από το έδαφος	-1.049620617
month_4	Απρίλιος	-1.045427484
month_3	Μάρτιος	-0.87769821

temperature_2m	Θερμοκρασία αέρα στα 2m από το έδαφος	0.763151434
precipitation	Συνολικό ύψος κατακρημνησμάτων	0.530068244
month_5	Μάιος	-0.471697294
month_12	Δεκέμβριος	-0.361450398
shortwave_radiation	Ηλιακή ακτινοβολία μικρού μήκους κύματος	0.224401777
month_6	Ιούνιος	0.176432806
wind_direction_10m	Διεύθυνση ανέμου στα 10 m από το έδαφος	0.176136062
Trend	Μεταβλητή χρονικής τάσης	0.155190025
cloud_cover	Συνολική νεφοκάλυψη	-0.107204866
month_11	Νοέμβριος	0.098704713
wind_speed_10m	Ταχύτητα ανέμου στα 10 m από το έδαφος	0.018142746

Παρατηρείται ότι οι σημαντικότεροι συντελεστές αντιστοιχούν στις χρονικές υστερήσεις lag24, lag1 και lag168 που αποτυπώνουν τη χρονική αυτοσυσχέτιση της χρονοσειράς σε ωριαίο, ημερήσιο και εβδομαδιαίο επίπεδο αντίστοιχα. Η υστέρηση lag24 παρουσιάζει τη μεγαλύτερη σχετική συνεισφορά στο μοντέλο, υποδηλώνοντας ότι η κατανάλωση της αντίστοιχης ώρας της προηγούμενης ημέρας αποτελεί τη σημαντικότερη πηγή πληροφορίας για την πρόβλεψη του τρέχοντος φορτίου, το οποίο είναι συνεπές με την έντονη ημερήσια περιοδικότητα που παρατηρήθηκε κατά τη διερευνητική ανάλυση δεδομένων.

Μετά τις μεταβλητές χρονικής υστέρησης ακολουθούν οι μεταβλητές της ημέρας της εβδομάδας, με τις μεγαλύτερες αρνητικές τιμές συντελεστών να αντιστοιχούν στο Σάββατο και την Κυριακή. Οι αρνητικοί συντελεστές υποδηλώνουν χαμηλότερα επίπεδα κατανάλωσης σε σχέση με τη Δευτέρα, η οποία χρησιμοποιήθηκε ως κατηγορία αναφοράς, γεγονός που υποδηλώνει την ύπαρξη διαφοροποιήσεων στη λειτουργία του λιμένα μεταξύ εργασιμων ημερών και Σαββατοκύριακου.

Οι μεταβλητές του μήνα εμφανίζουν συγκριτικά μικρότερη συνεισφορά στο μοντέλο, ωστόσο οι περισσότεροι συντελεστές είναι αρνητικοί ως προς τον Ιανουάριο, γεγονός που υποδηλώνει χαμηλότερα επίπεδα κατανάλωσης κατά τους αντίστοιχους μήνες σε σχέση με τον μήνα αναφοράς.

Τέλος, οι μετεωρολογικές μεταβλητές παρουσιάζουν τη μικρότερη σχετική συνεισφορά σε σύγκριση με τις μεταβλητές χρονικής υστέρησης και τις ημερολογιακές μεταβλητές. Μεταξύ αυτών, η σχετική υγρασία και η θερμοκρασία εμφανίζουν τους μεγαλύτερους συντελεστές κατά απόλυτη τιμή, ενώ η βροχόπτωση, η ηλιακή ακτινοβολία, η νεφοκάλυψη και τα χαρακτηριστικά του ανέμου παρουσιάζουν περιορισμένη επίδραση στο τελικό μοντέλο.

5.2. Αποτελέσματα μοντέλου τυχαίου δάσους (Random Forest)

5.2.1. Μετρικές απόδοσης

Ο Πίνακας 10 παρουσιάζει τις μετρικές απόδοσης του μοντέλου Random Forest στο σύνολο ελέγχου. Το μοντέλο πέτυχε συντελεστή προσδιορισμού $R^2 = 0,901$ και ρίζα μέσου τετραγωνικού σφάλματος $RMSE = 17,40$ kWh, παρουσιάζοντας υψηλή ακρίβεια πρόβλεψης. Η σχετικά μικρή διαφορά μεταξύ των τιμών R^2 στο σύνολο εκπαίδευσης και


στο σύνολο ελέγχου υποδηλώνει περιορισμένο βαθμό υπερπροσαρμογής και ικανοποιητική ικανότητα γενίκευσης.

Πίνακας 10. Μετρικές απόδοσης μοντέλου Random Forest

Μοντέλο	R^2_{train}	R^2_{test}	MAE	RMSE	sMAPE	CV(RMSE)
Random Forest	0,970	0,901	11,47	17,40	5,53	8,02


5.2.2. Πραγματικές και προβλεπόμενες τιμές χρονοσειράς

Το διάγραμμα του Σχήματος 19 παρουσιάζει τη σύγκριση των πραγματικών και των προβλεπόμενων τιμών φορτίου για το μοντέλο Random Forest στο σύνολο ελέγχου και συνάδει με τις υψηλές τιμές του συντελεστή προσδιορισμού και τις χαμηλές τιμές σφάλματος που παρουσιάστηκαν προηγουμένως. Παρατηρείται ότι το μοντέλο αναπαράγει ικανοποιητικά τη συνολική χρονική εξέλιξη της κατανάλωσης ηλεκτρικής ενέργειας, ακολουθώντας τόσο τις βραχυχρόνιες διακυμάνσεις όσο και τις ευρύτερες μεταβολές του φορτίου κατά τη διάρκεια της εξεταζόμενης περιόδου. Οι σημαντικότερες αποκλίσεις εμφανίζονται κυρίως σε μεμονωμένες ακραίες τιμές και απότομες μεταβολές του φορτίου, οι οποίες δεν αναπαράγονται πλήρως από το μοντέλο.




Σχήμα 19. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου στο σύνολο ελέγχου για το μοντέλο τυχαίου δάσους

Το διάγραμμα του Σχήματος 20 παρουσιάζει ενδεικτικά τη σύγκριση των πραγματικών και των προβλεπόμενων τιμών φορτίου για το μοντέλο Random Forest κατά τις δέκα πρώτες ημέρες του συνόλου ελέγχου. Παρατηρείται ότι το μοντέλο αναπαράγει με υψηλή ακρίβεια τη βραχυχρόνια δυναμική της χρονοσειράς, ακολουθώντας στενά τόσο το ημερήσιο πρότυπο μεταβολής του φορτίου όσο και τις διαδοχικές εναλλαγές μεταξύ περιόδων υψηλής και χαμηλής κατανάλωσης. Οι αποκλίσεις μεταξύ πραγματικών και προβλεπόμενων τιμών παραμένουν γενικά περιορισμένες και εντοπίζονται κυρίως σε ορισμένες απότομες μεταβολές του φορτίου.



Σχήμα 20. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου για τις 10 πρώτες ημέρες του συνόλου ελέγχου στο μοντέλο τυχαίου δάσους (Random Forest)


Το διάγραμμα του Σχήματος 21 παρουσιάζει τη συσχέτιση μεταξύ των πραγματικών και των προβλεπόμενων τιμών φορτίου για το μοντέλο Random Forest στο σύνολο ελέγχου. Η πλειονότητα των σημείων φαίνεται να συγκεντρώνεται κοντά στη γραμμή ταύτισης πραγματικών και προβλεπόμενων τιμών, υποδηλώνοντας υψηλό βαθμό συμφωνίας μεταξύ των προβλέψεων του μοντέλου και των πραγματικών μετρήσεων. Οι μεγαλύτερες αποκλίσεις και, κατά συνέπεια, τα μεγαλύτερα σφάλματα πρόβλεψης εμφανίζονται κυρίως σε ακραίες τιμές φορτίου, όπου παρατηρείται αυξημένη διασπορά των σημείων γύρω από τη γραμμή αναφοράς.



Σχήμα 21. Συσχέτιση μεταξύ πραγματικών και προβλεπόμενων τιμών φορτίου στο σύνολο ελέγχου για το μοντέλο τυχαίου δάσους (Random Forest).


5.2.3. Χρονική συμπεριφορά των υπολοίπων

Το διάγραμμα του Σχήματος 22 παρουσιάζει τα υπόλοιπα του μοντέλου Random Forest στο σύνολο ελέγχου. Τα περισσότερα υπόλοιπα είναι κατανομημένα κοντά στο μηδέν, ενώ οι μεγαλύτερες αποκλίσεις εμφανίζονται σποραδικά κυρίως σε μεμονωμένες χρονικές στιγμές. Παρατηρούνται επίσης ορισμένες περιόδους αυξημένης διασποράς των υπολοίπων, οι οποίες υποδηλώνουν ότι το μοντέλο αντιμετώπισε μεγαλύτερη δυσκολία πρόβλεψης κατά τα αντίστοιχα χρονικά διαστήματα.



Σχήμα 22. Υπόλοιπα του μοντέλου τυχαίου δάσους (Random Forest) στο σύνολο ελέγχου.

Το διάγραμμα του Σχήματος 23 παρουσιάζει τη συνάρτηση αυτοσυσχέτισης (ACF) των υπολοίπων του μοντέλου Random Forest. Παρατηρείται ότι οι περισσότερες τιμές αυτοσυσχέτισης παραμένουν σχετικά κοντά στο μηδέν, γεγονός που υποδηλώνει ότι το μοντέλο έχει αποτυπώσει σημαντικό μέρος της χρονικής εξάρτησης της χρονοσειράς. Ωστόσο, διακρίνονται ορισμένες θετικές κορυφές κυρίως σε πολλαπλάσια των 24 ωρών, υποδηλώνοντας την ύπαρξη περιορισμένων υπολειπόμενων ημερήσιων και εβδομαδιαίων προτύπων τα οποία δεν έχουν αποτυπωθεί πλήρως από το μοντέλο.



Σχήμα 23. Συνάρτηση αυτοσυσχέτισης (ACF) των υπολοίπων του μοντέλου τυχαίου δάσους (Random Forest).

5.2.4. Σημαντικότητα χαρακτηριστικών

Ο Πίνακας 11 παρουσιάζει τη σημαντικότητα των χαρακτηριστικών (feature importance) που υπολογίστηκε από το μοντέλο Random Forest κατά φθίνουσα σειρά σημαντικότητας. Η σημαντικότητα υπολογίστηκε μέσω της ενσωματωμένης μεθόδου που βασίζεται στη μείωση της ανομοιογένειας (impurity-based feature importance) του RandomForestRegressor και αντιστοιχεί στην κανονικοποιημένη συνολική μείωση του κριτηρίου διαχωρισμού βάσει τετραγωνικού σφάλματος που αποδίδεται σε κάθε χαρακτηριστικό στο σύνολο των δέντρων (Mean Decrease in Impurity – MDI). Οι τιμές σημαντικότητας εκφράζουν τη σχετική συμβολή κάθε μεταβλητής στη διαδικασία λήψης αποφάσεων του μοντέλου και δεν παρέχουν πληροφορία σχετικά με την κατεύθυνση της επίδρασής της στο φορτίο.

Πίνακας 11. Σημαντικότητα χαρακτηριστικών του μοντέλου τυχαίου δάσους (Random Forest).

Χαρακτηριστικό	Περιγραφή	Σημαντικότητα
lag24	Χρονική υστέρηση 24 ωρών (ημέρας)	0,703640056
lag1	Χρονική υστέρηση 1 ώρας	0,194768873
lag168	Χρονική υστέρηση 168 ωρών (εβδομάδας)	0,075261544
shortwave_radiation	Ηλιακή ακτινοβολία μικρού μήκους κύματος	0,009887215
trend	Μεταβλητή χρονικής τάσης	0,005752839

temperature_2m	Θερμοκρασία αέρα στα 2m από το έδαφος	0,003335674
wind_speed_10m	Ταχύτητα ανέμου στα 10 m από το έδαφος	0,00151461
wind_direction_10m	Διεύθυνση ανέμου στα 10 m από το έδαφος	0,001489235
relative_humidity_2m	Σχετική υγρασία στα 2m από το έδαφος	0,001135603
cloud_cover	Συνολική νεφοκάλυψη	0,000988496
day_of_week_6	Κυριακή	0,000293013
day_of_week_5	Σάββατο	0,000275554
month_11	Νοέμβριος	0,00018992
month_9	Σεπτέμβριος	0,000147329
month_8	Αύγουστος	0,000137954
precipitation	Συνολικό ύψος κατακρημνησμάτων	0,000134325
day_of_week_3	Πέμπτη	0,000123506
day_of_week_1	Τρίτη	0,000122916
month_4	Απρίλιος	0,000122501
day_of_week_2	Τετάρτη	0,000122356
month_6	Ιούνιος	0,000110656
month_5	Μάιος	0,000100609
day_of_week_4	Παρασκευή	8,16041E-05
month_10	Οκτώβριος	7,32174E-05
month_3	Μάρτιος	5,5089E-05
month_7	Ιούλιος	4,7353E-05
month_2	Φεβρουάριος	4,61916E-05
month_12	Δεκέμβριος	4,17588E-05

Παρατηρείται ότι οι μεταβλητές χρονικής υστέρησης κυριαρχούν στη διαδικασία πρόβλεψης, με την υστέρηση μίας ημέρας (lag24) να παρουσιάζει τη μεγαλύτερη σημαντικότητα, ακολουθούμενη από την υστέρηση μίας ώρας (lag1) και την υστέρηση μίας εβδομάδας (lag168). Το αποτέλεσμα αυτό υποδηλώνει ότι η πρόσφατη ιστορική συμπεριφορά του φορτίου αποτελεί τη σημαντικότερη πηγή προγνωστικής πληροφορίας για το μοντέλο.

Εφόσον το μεγαλύτερο μέρος της προγνωστικής πληροφορίας περιέχεται στις μεταβλητές χρονικής υστέρησης η επιπλέον συνεισφορά των υπόλοιπων μεταβλητών καθίσταται συγκριτικά μικρότερη. Μεταξύ των μεταβλητών αυτών, η ηλιακή ακτινοβολία μικρού μήκους κύματος (shortwave radiation), η μεταβλητή τάσης (trend) και η θερμοκρασία παρουσιάζουν τη μεγαλύτερη σχετική συμβολή, ενώ οι ημερολογιακές και οι μετεωρολογικές μεταβλητές που απομένουν συνεισφέρουν σε μικρότερο βαθμό στη διαδικασία πρόβλεψης.

5.3. Αποτελέσματα XGBoost

5.3.1. Μετρικές απόδοσης

Ο Πίνακας 12 παρουσιάζει τις μετρικές απόδοσης του μοντέλου XGBoost στα σύνολα εκπαίδευσης και ελέγχου. Το μοντέλο πέτυχε συντελεστή προσδιορισμού R^2 ίσο με 0,956 στο σύνολο εκπαίδευσης και 0,900 στο σύνολο ελέγχου, υποδεικνύοντας υψηλή ικανότητα ερμηνείας της διακύμανσης του φορτίου και καλή γενίκευση σε μη παρατηρημένα δεδομένα. Παράλληλα, η τιμή του RMSE διαμορφώθηκε στις 17,47 kWh, γεγονός που


υποδηλώνει υψηλή ακρίβεια πρόβλεψης. Η σχετικά μικρή διαφορά μεταξύ των τιμών R^2 εκπαίδευσης και ελέγχου δεν φανερώνει έντονα φαινόμενα υπερπροσαρμογής.

Πίνακας 12. Μετρικές απόδοσης μοντέλου XGBoost

Μοντέλο	R^2_{train}	R^2_{test}	MAE	RMSE	sMAPE	CV(RMSE)
XGBoost	0,956	0,900	11,89	17,47	5,70	8,05

5.3.2. Πραγματικές και προβλεπόμενες τιμές χρονοσειράς


Το διάγραμμα του Σχήματος 24 παρουσιάζει τη σύγκριση των πραγματικών και των προβλεπόμενων τιμών φορτίου για το μοντέλο XGBoost στο σύνολο ελέγχου. Παρατηρείται ότι το μοντέλο ακολουθεί στενά τη συνολική χρονική εξέλιξη της κατανάλωσης ηλεκτρικής ενέργειας, αποτυπώνοντας τόσο τις βραχυχρόνιες διακυμάνσεις όσο και τις μεταβολές του γενικού επιπέδου του φορτίου κατά τη διάρκεια της εξεταζόμενης περιόδου. Οι σημαντικότερες αποκλίσεις εμφανίζονται κυρίως σε μεμονωμένες ακραίες τιμές και απότομες μεταβολές του φορτίου, οι οποίες παραμένουν δυσκολότερο να προβλεφθούν με ακρίβεια.



Σχήμα 24. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου στο σύνολο ελέγχου για το μοντέλο XGBoost


Το διάγραμμα του Σχήματος 25 παρουσιάζει ενδεικτικά τη σύγκριση των πραγματικών και των προβλεπόμενων τιμών φορτίου για το μοντέλο XGBoost κατά τις δέκα πρώτες ημέρες του συνόλου ελέγχου. Διαπιστώνεται ότι οι προβλέψεις του μοντέλου ακολουθούν στενά τη χρονική εξέλιξη του φορτίου, αναπαράγοντας με συνέπεια τις επαναλαμβανόμενες ημερήσιες διακυμάνσεις της κατανάλωσης. Παράλληλα, το μοντέλο αποτυπώνει αποτελεσματικά τις μεταβάσεις μεταξύ διαφορετικών επιπέδων φορτίου, ενώ οι

σημαντικότερες αποκλίσεις εμφανίζονται κυρίως σε ορισμένες απότομες μεταβολές και τοπικές αιχμές της χρονοσειράς.



Σχήμα 25. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου για τις 10 πρώτες ημέρες του συνόλου ελέγχου στο μοντέλο XGBoost


Το διάγραμμα του Σχήματος 26 παρουσιάζει τη συσχέτιση μεταξύ των πραγματικών και των προβλεπόμενων τιμών φορτίου για το μοντέλο XGBoost στο σύνολο ελέγχου. Παρατηρείται ότι τα σημεία ακολουθούν σε μεγάλο βαθμό τη γραμμή ταύτισης πραγματικών και προβλεπόμενων τιμών, γεγονός που καταδεικνύει την ικανότητα του μοντέλου να προσεγγίζει με ακρίβεια τις πραγματικές τιμές του φορτίου. Οι μεγαλύτερες αποκλίσεις εντοπίζονται κυρίως σε ακραίες τιμές φορτίου, αντανακλώντας αυξημένα σφάλματα πρόβλεψης σε αυτές.



Σχήμα 26. Συσχέτιση μεταξύ πραγματικών και προβλεπόμενων τιμών φορτίου στο σύνολο ελέγχου για το μοντέλο XGBoost


5.3.3. Χρονική συμπεριφορά των υπολοίπων

Το διάγραμμα του Σχήματος 27 παρουσιάζει τα υπόλοιπα του μοντέλου XGBoost στο σύνολο ελέγχου. Παρατηρείται ότι τα σφάλματα πρόβλεψης εναλλάσσονται μεταξύ θετικών και αρνητικών τιμών χωρίς να διαμορφώνονται παρατεταμένες περιόδους συστηματικής απόκλισης. Οι σημαντικότερες αποκλίσεις εμφανίζονται κυρίως σε μεμονωμένες χρονικές στιγμές, ενώ τοπικά παρατηρούνται περίοδοι αυξημένης μεταβλητότητας των υπολοίπων.



Σχήμα 27. Υπόλοιπα του μοντέλου XGBoost στο σύνολο ελέγχου.

Το διάγραμμα του Σχήματος 28 παρουσιάζει τη συνάρτηση αυτοσυσχέτισης (ACF) των υπολοίπων του μοντέλου XGBoost. Παρατηρείται ότι οι περισσότερες τιμές αυτοσυσχέτισης παραμένουν κοντά στο μηδέν, γεγονός που υποδηλώνει ότι το μοντέλο έχει αποτυπώσει σημαντικό μέρος της χρονικής εξάρτησης της χρονοσειράς. Ωστόσο, εμφανίζονται διακριτές θετικές κορυφές σε χρονικές υστερήσεις που αντιστοιχούν σε πολλαπλάσια των 24 ωρών, υποδηλώνοντας την ύπαρξη υπολειπόμενων ημερήσιων και εβδομαδιαίων προτύπων τα οποία δεν έχουν αποτυπωθεί πλήρως από το μοντέλο.



Σχήμα 28. Συνάρτηση αυτοσυσχέτισης (ACF) των υπολοίπων για το μοντέλο XGBoost

5.3.4. Σημαντικότητα χαρακτηριστικών

Ο Πίνακας 13 παρουσιάζει τη σημαντικότητα των χαρακτηριστικών (feature importance) που υπολογίστηκε από το μοντέλο XGBoost κατά φθίνουσα σειρά σημαντικότητας. Η σημαντικότητα προέκυψε από την ιδιότητα `feature_importances_` του `XGBRegressor` και, καθώς δεν ορίστηκε διαφορετικός τύπος σημαντικότητας, αντιστοιχεί στη σημαντικότητα βάσει κέρδους (gain-based importance). Κάθε τιμή εκφράζει την κανονικοποιημένη μέση βελτίωση της αντικειμενικής συνάρτησης που επιτεύχθηκε από τους διαχωρισμούς στους οποίους χρησιμοποιήθηκε το αντίστοιχο χαρακτηριστικό. Οι τιμές σημαντικότητας εκφράζουν τη σχετική συμβολή κάθε μεταβλητής στη διαδικασία της πρόβλεψης και δεν παρέχουν πληροφορία σχετικά με την κατεύθυνση της επίδρασής της στο φορτίο.

Πίνακας 13. Σημαντικότητα χαρακτηριστικών του μοντέλου XGBoost.

Χαρακτηριστικό	Περιγραφή	Σημαντικότητα
lag24	Χρονική υστέρηση 24 ωρών (ημέρας)	0,451523185
lag168	Χρονική υστέρηση 168 ωρών (εβδομάδας)	0,3122361
lag1	Χρονική υστέρηση 1 ώρας	0,138210595
shortwave_radiation	Ηλιακή ακτινοβολία μικρού μήκους κύματος	0,013510562
temperature_2m	Θερμοκρασία αέρα στα 2m από το έδαφος	0,008796001
day_of_week_5	Σάββατο	0,006196195
day_of_week_6	Κυριακή	0,005707206
trend	Μεταβλητή χρονικής τάσης	0,004754993
month_6	Ιούνιος	0,004395994

month_11	Νοέμβριος	0,004377593
day_of_week_1	Τρίτη	0,003909515
month_8	Αύγουστος	0,003714943
day_of_week_2	Τετάρτη	0,003693219
day_of_week_4	Παρασκευή	0,003684237
wind_direction_10m	Διεύθυνση ανέμου στα 10 m από το έδαφος	0,003537398
month_2	Φεβρουάριος	0,003469836
month_9	Σεπτέμβριος	0,003438693
month_12	Δεκέμβριος	0,002937617
month_4	Απρίλιος	0,002904354
month_10	Οκτώβριος	0,00286074
day_of_week_3	Πέμπτη	0,002806614
month_7	Ιούλιος	0,002254968
wind_speed_10m	Ταχύτητα ανέμου στα 10 m από το έδαφος	0,002007526
cloud_cover	Συνολική νεφοκάλυψη	0,001984891
month_5	Μάιος	0,001949035
relative_humidity_2m	Σχετική υγρασία στα 2m από το έδαφος	0,001868265
precipitation	Συνολικό ύψος κατακρημνησμάτων	0,001794312
month_3	Μάρτιος	0,001475361

Η ανάλυση δείχνει ότι το μοντέλο αντλεί το μεγαλύτερο μέρος της προγνωστικής πληροφορίας από τις μεταβλητές χρονικής υστέρησης. Ειδικότερα, η υστέρηση μίας ημέρας (lag24) παρουσιάζει τη μεγαλύτερη σημαντικότητα, ακολουθούμενη από την υστέρηση μίας εβδομάδας (lag168) και την υστέρηση μίας ώρας (lag1). Το εύρημα αυτό υποδηλώνει ότι τόσο τα ημερήσια όσο και τα εβδομαδιαία πρότυπα της χρονοσειράς διαδραματίζουν καθοριστικό ρόλο στη διαδικασία πρόβλεψης.

Οι υπόλοιπες μεταβλητές εμφανίζουν αισθητά χαμηλότερες τιμές σημαντικότητας. Μεταξύ αυτών, η ηλιακή ακτινοβολία μικρού μήκους κύματος (shortwave radiation) και η θερμοκρασία αναδεικνύονται ως οι σημαντικότερες εξωγενείς μεταβλητές, ενώ οι ημερολογιακές και οι λοιπές μετεωρολογικές μεταβλητές παρουσιάζουν περιορισμένη συμβολή στη διαμόρφωση των προβλέψεων του μοντέλου.

5.4. Αποτελέσματα LSTM

5.4.1. Μετρικές απόδοσης

Προκειμένου να διερευνηθεί η επίδραση του μήκους του χρονικού παραθύρου και της χρήσης εξωγενών μεταβλητών στην απόδοση των δικτύων LSTM, αξιολογήθηκαν τέσσερις διαφορετικές διαμορφώσεις μοντέλων: (α) μονομεταβλητό μοντέλο με παράθυρο 24 ωρών, (β) μονομεταβλητό μοντέλο με παράθυρο 168 ωρών, (γ) πολυμεταβλητό μοντέλο με παράθυρο 24 ωρών και (δ) πολυμεταβλητό μοντέλο με παράθυρο 168 ωρών.

Για κάθε μία από τις τέσσερις διαμορφώσεις πραγματοποιήθηκε διαδικασία χρονοσειριακής διασταυρωμένης επικύρωσης (TimeSeriesSplit cross-validation) στο σύνολο εκπαίδευσης με σκοπό την επιλογή του βέλτιστου συνδυασμού υπερπαραμέτρων. Οι υπερπαραμέτροι που διερευνήθηκαν περιλάμβαναν τον αριθμό μονάδων LSTM, το ποσοστό απενεργοποίησης νευρώνων (dropout), τον ρυθμό μάθησης (learning rate) του αλγορίθμου βελτιστοποίησης Adam και το μέγεθος παρτίδας (batch size). Στη συνέχεια, κάθε

διαμόρφωση επανεκπαιδεύτηκε στο πλήρες σύνολο εκπαίδευσης χρησιμοποιώντας τις επιλεγμένες υπερπαραμέτρους και αξιολογήθηκε στο ανεξάρτητο σύνολο ελέγχου.

Ο Πίνακας 14 παρουσιάζει τους βέλτιστους συνδυασμούς υπερπαραμέτρων που προέκυψαν από τη διαδικασία χρονοσειριακής διασταυρωμένης επικύρωσης για καθεμία από τις τέσσερις διαμορφώσεις LSTM. Παρατηρείται ότι τα περισσότερα μοντέλα συγκλίνουν σε σχετικά χαμηλές τιμές ρυθμού μάθησης (0.0005), ενώ το πολυμεταβλητό μοντέλο με παράθυρο 168 ωρών απαιτούσε ελαφρώς υψηλότερο ρυθμό μάθησης (0.001). Το βέλτιστο μοντέλο ήταν το μονομεταβλητό μοντέλο με παράθυρο 24 ωρών, το οποίο χρησιμοποίησε τον μεγαλύτερο αριθμό μονάδων LSTM (128), γεγονός που πιθανόν υποδηλώνει ότι η αυξημένη αναπαραστατική ικανότητα του δικτύου σχετίζεται με τη βελτιωμένη προγνωστική του επίδοση.

Πίνακας 14. Βέλτιστες υπερπαραμέτροι των μοντέλων LSTM

Διαμόρφωση	Παράθυρο (ώρες)	Μονάδες LSTM	Ποσοστό απενεργοποίησης νευρώνων (Dropout)	Μέγεθος παρτίδας (Batch Size)	Ρυθμός μάθησης (Learning rate)
Μονομεταβλητό LSTM	24	128	0.10	32	0,0005
Μονομεταβλητό LSTM	168	64	0.20	32	0,0005
Πολυμεταβλητό LSTM	24	64	0.10	32	0,0005
Πολυμεταβλητό LSTM	168	32	0.10	32	0,0010

5.4.2. Αποτελέσματα διασταυρωμένης επικύρωσης

Τα αποτελέσματα της χρονοσειριακής διασταυρωμένης επικύρωσης παρουσιάζονται στον Πίνακα 15. Η καλύτερη επίδοση επιτεύχθηκε από το μονομεταβλητό μοντέλο LSTM με παράθυρο εισόδου 24 ωρών, το οποίο κατέγραψε μέση τιμή RMSE ίση με 24,57, μέση τιμή MAE ίση με 17,03 και συντελεστή προσδιορισμού R^2 ίσο με 0,848. Η αύξηση του μήκους του παραθύρου σε 168 ώρες οδήγησε σε αισθητή επιδείνωση της απόδοσης, καθώς το αντίστοιχο μονομεταβλητό μοντέλο παρουσίασε RMSE ίσο με 31,29 και R^2 ίσο με 0,759. Παρόμοια εικόνα παρατηρήθηκε και στα πολυμεταβλητά μοντέλα, τα οποία εμφάνισαν υψηλότερες τιμές σφάλματος και χαμηλότερες τιμές R^2 σε σχέση με τα αντίστοιχα μονομεταβλητά μοντέλα.

Πίνακας 15. Αποτελέσματα διασταυρωμένης επικύρωσης

Διαμόρφωση	Παράθυρο (ώρες)	CV MAE	CV RMSE	CV R^2
Μονομεταβλητό LSTM	24	17,03	24,57	0,848
Μονομεταβλητό LSTM	168	23,37	31,29	0,759
Πολυμεταβλητό LSTM	24	26,89	35,59	0,673
Πολυμεταβλητό LSTM	168	27,23	35,69	0,670

Τα αποτελέσματα της διασταυρωμένης επικύρωσης υποδηλώνουν ότι τόσο η αύξηση του χρονικού παραθύρου όσο και η προσθήκη εξωγενών μεταβλητών δεν οδήγησαν σε βελτίωση της προγνωστικής ικανότητας των δικτύων LSTM για το συγκεκριμένο πρόβλημα πρόβλεψης.

5.4.3. Τελική αξιολόγηση στο σύνολο ελέγχου

Μετά την επιλογή των βέλτιστων υπερπαραμέτρων, τα μοντέλα επανεκπαιδεύτηκαν στο πλήρες σύνολο εκπαίδευσης και αξιολογήθηκαν στο ανεξάρτητο σύνολο ελέγχου. Τα αποτελέσματα παρουσιάζονται στον Πίνακα 16.

Πίνακας 16. Τελική αξιολόγηση των μοντέλων LSTM στο σύνολο ελέγχου


Διαμόρφωση	Παράθυρο (ώρες)	MAE	RMSE	CV(RMSE) (%)	sMAPE (%)	R ²
Μονομεταβλητό LSTM	24	13,64	19,63	9,05	6,56	0,873
Πολυμεταβλητό LSTM	24	16,20	22,75	10,49	7,77	0,829
Πολυμεταβλητό LSTM	168	17,43	24,61	11,35	8,27	0,800
Μονομεταβλητό LSTM	168	18,98	26,27	12,11	8,69	0,772

Το καλύτερο συνολικά αποτέλεσμα επιτεύχθηκε από το μονομεταβλητό μοντέλο LSTM με παράθυρο εισόδου 24 ωρών, το οποίο κατέγραψε MAE ίσο με 13,64, RMSE ίσο με 19,63, CV(RMSE) ίσο με 9,05%, sMAPE ίσο με 6,56% και συντελεστή προσδιορισμού R² ίσο με 0,873.

Η κατάταξη των μοντέλων στο σύνολο ελέγχου ήταν συνεπής με τα αποτελέσματα της διασταυρωμένης επικύρωσης, καθώς επιβεβαιώθηκε ότι η χρήση παραθύρου 24 ωρών υπερείχε σταθερά έναντι του παραθύρου 168 ωρών. Ωστόσο, για το παράθυρο των 168 ωρών η πολυμεταβλητή διαμόρφωση πέτυχε χαμηλότερα σφάλματα και υψηλότερη τιμή R² σε σχέση με το αντίστοιχο μονομεταβλητό μοντέλο. Καθώς καμία από τις πολυμεταβλητές διαμορφώσεις δεν κατάφερε να ξεπεράσει την επίδοση του μονομεταβλητού μοντέλου με παράθυρο εισόδου 24 ωρών, το τελευταίο επιλέχθηκε ως η βέλτιστη διαμόρφωση μεταξύ όλων των εξεταζόμενων αρχιτεκτονικών LSTM και χρησιμοποιείται στη συνέχεια για τη σύγκριση με τα υπόλοιπα μοντέλα της μελέτης.

5.4.4. Πραγματικές και προβλεπόμενες τιμές χρονοσειράς

Το διάγραμμα του Σχήματος 29 παρουσιάζει τη σύγκριση των πραγματικών και των προβλεπόμενων τιμών ηλεκτρικού φορτίου για το σύνολο ελέγχου για το βέλτιστο μονομεταβλητό μοντέλο LSTM με παράθυρο εισόδου 24 ωρών. Παρατηρείται ότι το μοντέλο αναπαράγει με ικανοποιητική ακρίβεια τη συνολική δυναμική της χρονοσειράς, ακολουθώντας τόσο τις βραχυχρόνιες διακυμάνσεις όσο και τις μακροχρόνιες μεταβολές του επιπέδου κατανάλωσης κατά τη διάρκεια της περιόδου αξιολόγησης.




Σχήμα 29. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου στο σύνολο ελέγχου για το βέλτιστο μοντέλο LSTM

Οι προβλέψεις εμφανίζουν υψηλό βαθμό συμφωνίας με τις πραγματικές τιμές σε όλο το εύρος του συνόλου ελέγχου, γεγονός που είναι συνεπές με τις υψηλές τιμές του συντελεστή προσδιορισμού ($R^2 = 0,873$) και τις χαμηλές τιμές σφάλματος που παρουσιάστηκαν προηγουμένως. Επιπλέον, δεν παρατηρείται συστηματική απόκλιση των προβλέψεων από τις πραγματικές τιμές σε συγκεκριμένες χρονικές περιόδους, γεγονός που υποδηλώνει ικανοποιητική ικανότητα γενίκευσης του μοντέλου.

Οι σημαντικότερες αποκλίσεις εντοπίζονται κυρίως σε μεμονωμένες ακραίες τιμές και σε απότομες μεταβολές του φορτίου, όπου το μοντέλο τείνει να εξομαλύνει τις κορυφές και τις βυθίσεις της χρονοσειράς. Παρά τις αποκλίσεις αυτές, η συνολική συμπεριφορά του μοντέλου καταδεικνύει ότι οι προβλέψεις παραμένουν αρκετά κοντά στις πραγματικές τιμές καθ' όλη τη διάρκεια της εξεταζόμενης περιόδου.

Για την καλύτερη οπτική αξιολόγηση της προσαρμογής του βέλτιστου μονομεταβλητού μοντέλου LSTM με παράθυρο εισόδου 24 ωρών, το διάγραμμα του Σχήματος 30 παρουσιάζει τις πραγματικές και τις προβλεπόμενες τιμές φορτίου για τις δέκα πρώτες ημέρες του συνόλου ελέγχου.




Σχήμα 30. Χρονοσειρές πραγματικού και προβλεπόμενου φορτίου για τις 10 πρώτες ημέρες του συνόλου ελέγχου στο βέλτιστο μοντέλο LSTM

Παρατηρείται ότι το μοντέλο αναπαράγει με μεγάλη ακρίβεια τον ημερήσιο κύκλο κατανάλωσης, ακολουθώντας τόσο τη χρονική θέση όσο και το γενικό μέγεθος των περισσότερων κορυφών και ελαχίστων τιμών της χρονοσειράς. Οι προβλέψεις ακολουθούν στενά τις διαδοχικές εναλλαγές μεταξύ περιόδων υψηλής και χαμηλής κατανάλωσης, γεγονός που υποδηλώνει ότι το δίκτυο έχει αποτυπώσει αποτελεσματικά τα βραχυχρόνια πρότυπα του φορτίου.

Οι μεγαλύτερες αποκλίσεις εμφανίζονται κυρίως σε ορισμένες απότομες μεταβολές και τοπικές αιχμές φορτίου, όπου το μοντέλο παρουσιάζει τάση εξομάλυνσης των ακραίων τιμών. Παρά ταύτα, η χρονική εξέλιξη των προβλέψεων παραμένει ιδιαίτερα κοντά στην πραγματική χρονοσειρά, επιβεβαιώνοντας την ικανότητα του μοντέλου να αναπαράγει με συνέπεια τη βραχυχρόνια δυναμική του ηλεκτρικού φορτίου.

Το διάγραμμα του Σχήματος 31 παρουσιάζει τη συσχέτιση μεταξύ των πραγματικών και των προβλεπόμενων τιμών φορτίου για το επιλεγμένο μονομεταβλητό μοντέλο LSTM με παράθυρο εισόδου 24 ωρών στο σύνολο ελέγχου. Παρατηρείται ότι η πλειονότητα των σημείων συγκεντρώνεται κοντά στη γραμμή ταύτισης πραγματικών και προβλεπόμενων τιμών, γεγονός που υποδηλώνει αρκετά μεγάλο βαθμό συμφωνίας μεταξύ προβλέψεων και πραγματικών μετρήσεων. Η σχετικά περιορισμένη διασπορά γύρω από τη διαγώνιο επιβεβαιώνει την ικανοποιητική προγνωστική ικανότητα του μοντέλου και είναι συνεπής με την υψηλή τιμή του συντελεστή προσδιορισμού ($R^2 = 0,873$). Ωστόσο, παρατηρούνται ορισμένες μεγαλύτερες αποκλίσεις τόσο σε χαμηλές όσο και σε υψηλές τιμές φορτίου, οι οποίες αντιστοιχούν σε περιπτώσεις αυξημένου σφάλματος πρόβλεψης. Οι αποκλίσεις αυτές υποδηλώνουν ότι, παρά τη συνολικά καλή προσαρμογή του μοντέλου, ορισμένες ακραίες ή ασυνήθιστες παρατηρήσεις δεν αποτυπώνονται πλήρως από τις προβλέψεις.




Σχήμα 31. Συσχέτιση μεταξύ πραγματικών και προβλεπόμενων τιμών φορτίου στο σύνολο ελέγχου για το βέλτιστο μοντέλο LSTM

5.4.5. Χρονική συμπεριφορά των υπολοίπων


Το διάγραμμα του Σχήματος 32 παρουσιάζει τη χρονική εξέλιξη των υπολοίπων του επιλεγμένου μοντέλου LSTM στο σύνολο ελέγχου. Παρατηρείται ότι τα σφάλματα πρόβλεψης κατανέμονται γύρω από τη μηδενική γραμμή και εναλλάσσονται μεταξύ θετικών και αρνητικών τιμών χωρίς εμφανή συστηματική τάση υπερεκτίμησης ή υποεκτίμησης του φορτίου. Οι μεγαλύτερες αποκλίσεις εμφανίζονται σε περιορισμένο αριθμό χρονικών στιγμών και αντιστοιχούν σε μεμονωμένα επεισόδια αυξημένου σφάλματος πρόβλεψης. Παράλληλα, διακρίνονται ορισμένες περιόδους αυξημένης διασποράς των υπολοίπων, χωρίς όμως να παρατηρούνται παρατεταμένα χρονικά διαστήματα συστηματικής απόκλισης από τη μηδενική γραμμή. Η συμπεριφορά αυτή

υποδηλώνει ότι το μοντέλο αποτυπώνει ικανοποιητικά τη γενική δυναμική της χρονοσειράς, ενώ οι μεγαλύτερες αποκλίσεις περιορίζονται κυρίως σε μεμονωμένες ακραίες παρατηρήσεις.



Σχήμα 32. Υπόλοιπα του βέλτιστου μοντέλου LSTM στο σύνολο ελέγχου.

Το διάγραμμα του Σχήματος 33 παρουσιάζει τη συνάρτηση αυτοσυσχέτισης (ACF) των υπολοίπων του βέλτιστου μοντέλου LSTM. Παρατηρείται ότι οι περισσότερες τιμές αυτοσυσχέτισης κινούνται σε σχετικά χαμηλά επίπεδα, γεγονός που υποδηλώνει ότι σημαντικό μέρος της χρονικής εξάρτησης της χρονοσειράς έχει αποτυπωθεί από το μοντέλο. Ωστόσο, εμφανίζονται διακριτές θετικές κορυφές σε χρονικές υστερήσεις που αντιστοιχούν περίπου σε πολλαπλάσια των 24 ωρών, ενώ παρατηρείται και μία πιο ομαλή κυματοειδής διακύμανση της αυτοσυσχέτισης μεταξύ των κορυφών αυτών. Το εύρημα αυτό υποδηλώνει ότι μέρος της περιοδικής δομής της χρονοσειράς εξακολουθεί να παραμένει στα σφάλματα πρόβλεψης και δεν έχει αποτυπωθεί πλήρως από το μοντέλο.




Σχήμα 33. Συνάρτηση αυτοσυσχέτισης (ACF) των υπολοίπων του βέλτιστου μοντέλου LSTM.

Συνολικά, η ανάλυση των διαγνωστικών διαγραμμάτων επιβεβαιώνει τα συμπεράσματα που προέκυψαν από τις μετρικές αξιολόγησης. Το μονομεταβλητό μοντέλο LSTM με παράθυρο εισόδου 24 ωρών παρουσίασε την καλύτερη προσαρμογή στα δεδομένα του συνόλου ελέγχου, αναπαράγοντας με ικανοποιητική ακρίβεια τη δυναμική του ηλεκτρικού φορτίου. Ωστόσο, η παρουσία υπολειπόμενης αυτοσυσχέτισης σε συγκεκριμένες χρονικές υστερήσεις υποδηλώνει ότι εξακολουθεί να υπάρχει χρονική πληροφορία η οποία δεν αξιοποιήθηκε πλήρως από το μοντέλο.


5.4.6. Επίδραση των εξωγενών μεταβλητών στα πολυμεταβλητά μοντέλα LSTM

Προκειμένου να διερευνηθεί η συμβολή των επιμέρους μεταβλητών στις προβλέψεις των πολυμεταβλητών μοντέλων LSTM, εφαρμόστηκε ανάλυση σημασίας χαρακτηριστικών με τη μέθοδο εκτίμησης της σημαντικότητας χαρακτηριστικών μέσω τυχαίας αναδιάταξης (permutation importance). Η μέθοδος αυτή εκτιμά τη σημασία κάθε μεταβλητής με βάση την αύξηση του σφάλματος πρόβλεψης που προκαλείται όταν οι τιμές της αναδιατάσσονται τυχαία, διατηρώντας σταθερές τις υπόλοιπες μεταβλητές. Για κάθε χαρακτηριστικό πραγματοποιήθηκαν τρεις τυχαίες αναδιατάξεις στο σύνολο ελέγχου και ως μέτρο σημαντικότητας χρησιμοποιήθηκε η μέση αύξηση του RMSE σε σχέση με την αρχική απόδοση του μοντέλου.

Τα διαγράμματα των Σχημάτων 34 και 35 παρουσιάζουν τα αποτελέσματα της ανάλυσης για τα πολυμεταβλητά μοντέλα με παράθυρο εισόδου 24 και 168 ωρών αντίστοιχα.



Σχήμα 34. Σημασία χαρακτηριστικών (permutation importance) για το πολυμεταβλητό μοντέλο LSTM με παράθυρο εισόδου 24 ωρών.



Σχήμα 35. Σημασία χαρακτηριστικών (permutation importance) για το πολυμεταβλητό μοντέλο LSTM με παράθυρο εισόδου 168 ωρών.

Από τα αποτελέσματα προκύπτει ότι η μεταβλητή της ιστορικής κατανάλωσης ηλεκτρικής ενέργειας (Ενέργεια) αποτελεί μακράν τον σημαντικότερο παράγοντα για την πρόβλεψη του φορτίου και στις δύο διαμορφώσεις. Η τυχαία αναδιάταξη της συγκεκριμένης μεταβλητής οδηγεί στη μεγαλύτερη αύξηση του σφάλματος πρόβλεψης, γεγονός που υποδηλώνει ότι το μοντέλο βασίζεται κυρίως στις πληροφορίες που περιέχονται στις προηγούμενες τιμές του φορτίου.

Μετά την ιστορική κατανάλωση, οι σημαντικότερες μεταβλητές είναι η ηλιακή ακτινοβολία (shortwave radiation) και η ώρα της ημέρας (hour), οι οποίες παρουσιάζουν αισθητά υψηλότερη σημασία σε σχέση με τις υπόλοιπες εξωγενείς μεταβλητές. Η διαπίστωση αυτή είναι συμβατή με τη γνωστή ημερήσια περιοδικότητα της ζήτησης ηλεκτρικής ενέργειας, καθώς και με την επίδραση των συνθηκών φωτισμού και των ανθρώπινων δραστηριοτήτων στη διαμόρφωση του φορτίου.

Αντίθετα, οι περισσότερες μετεωρολογικές μεταβλητές, όπως η σχετική υγρασία, η ταχύτητα και η διεύθυνση του ανέμου, καθώς και τα κατακρημνίσματα, παρουσίασαν ιδιαίτερα χαμηλή συμβολή στην προγνωστική ικανότητα των μοντέλων. Παρόμοια εικόνα παρατηρείται και για τις περισσότερες ημερολογιακές μεταβλητές, των οποίων η σημασία παραμένει περιορισμένη συγκριτικά με την ιστορική πληροφορία του φορτίου.

Τέλος, παρατηρείται ότι οι επικρατέστερες μεταβλητές παραμένουν οι ίδιες μεταξύ των παραθύρων εισόδου 24 και 168 ωρών, με την ιστορική κατανάλωση ηλεκτρικής ενέργειας να αποτελεί τη σημαντικότερη πηγή πληροφορίας, ακολουθούμενη από την ηλιακή ακτινοβολία και την ώρα της ημέρας. Παρότι παρατηρούνται διαφοροποιήσεις στις

επιμέρους τιμές σημασίας των χαρακτηριστικών, η γενική εικόνα παραμένει παρόμοια μεταξύ των δύο διαμορφώσεων.

Το εύρημα αυτό υποδηλώνει ότι η αύξηση του μήκους του ιστορικού παραθύρου δεν μεταβάλλει ουσιωδώς τις σημαντικότερες πηγές πληροφορίας που αξιοποιεί το μοντέλο κατά την πρόβλεψη του φορτίου.

5.5. Συγκριτική Αξιολόγηση Μοντέλων

5.5.1. Σύγκριση προγνωστικής επίδοσης

Τα αποτελέσματα του Πίνακα 17 στον οποίο συνοψίζονται οι προγνωστικές επιδόσεις των βέλτιστων διαμορφώσεων των εξεταζόμενων μοντέλων δείχνουν ότι το μοντέλο Random Forest πέτυχε την υψηλότερη συνολική προγνωστική ακρίβεια, καταγράφοντας τις χαμηλότερες τιμές MAE, RMSE, sMAPE και CV(RMSE), καθώς και την υψηλότερη τιμή του συντελεστή προσδιορισμού R^2 . Πολύ κοντά ακολούθησε το μοντέλο XGBoost, με τις διαφορές μεταξύ των δύο μοντέλων να είναι περιορισμένες.

Πίνακας 17. Σύγκριση προγνωστικής επίδοσης των μοντέλων

Μοντέλο	R^2_{test}	MAE	RMSE	sMAPE	CV(RMSE)
Random Forest	0,901	11,47	17,40	5,53	8,02
XGBoost	0,900	11,89	17,47	5,70	8,05
Γραμμικής παλινδρόμησης	0,884	13,44	18,83	6,42	8,68
Μονομεταβλητό LSTM με παράθυρο 24 ωρών	0,873	13,64	19,63	6,56	9,05

Η γραμμική παλινδρόμηση παρουσίασε ικανοποιητική απόδοση παρά τη σχετικά απλή δομή της. Η χρήση χρονικών υστερήσεων (lag features) και εξωγενών μεταβλητών επέτρεψε στο μοντέλο να αποτυπώσει σημαντικό μέρος της μεταβλητότητας του φορτίου, επιτυγχάνοντας τιμή R^2 ίση με 0,884 και σφάλματα πρόβλεψης συγκρίσιμα με εκείνα των πιο σύνθετων μοντέλων. Αξιοσημείωτο είναι ότι η γραμμική παλινδρόμηση, παρά την απλότητα της δομής της, πέτυχε επίδοση συγκρίσιμη με εκείνη του βέλτιστου μοντέλου LSTM. Το εύρημα αυτό υποδηλώνει ότι σημαντικό μέρος της πληροφορίας που απαιτείται για τη βραχυπρόθεσμη πρόβλεψη του ηλεκτρικού φορτίου μπορεί να περιγραφεί μέσω σχετικά απλών σχέσεων μεταξύ των μεταβλητών εισόδου και της μεταβλητής στόχου.

Το βέλτιστο μοντέλο LSTM ήταν το μονομεταβλητό μοντέλο με παράθυρο εισόδου 24 ωρών, το οποίο κατέγραψε R^2 ίσο με 0,873 και RMSE ίσο με 19,63. Παρότι η επίδοσή του ήταν ελαφρώς χαμηλότερη από εκείνη των μοντέλων Random Forest και XGBoost, παρέμεινε ανταγωνιστική και επιβεβαίωσε την ικανότητα των αναδρομικών νευρωνικών δικτύων να αξιοποιούν τη χρονική πληροφορία της χρονοσειράς. Ωστόσο, η πολυμεταβλητή εκδοχή του LSTM δεν οδήγησε σε βελτίωση της προγνωστικής ακρίβειας, γεγονός που υποδηλώνει ότι οι πρόσθετες μετεωρολογικές και ημερολογιακές μεταβλητές παρείχαν περιορισμένη νέα πληροφορία πέραν αυτής που περιέχεται ήδη στις ιστορικές τιμές του φορτίου.

Συνολικά, τα αποτελέσματα δείχνουν ότι όλες οι εξεταζόμενες μέθοδοι πέτυχαν υψηλή ακρίβεια πρόβλεψης, με τις μεγαλύτερες διαφορές να παρατηρούνται μεταξύ των δένδρων απόφασης και των υπολοίπων προσεγγίσεων. Η υπεροχή των Random Forest και XGBoost υποδηλώνει ότι οι μη γραμμικές σχέσεις που χαρακτηρίζουν τη χρονοσειρά του ηλεκτρικού

φορτίου μπορούν να αποτυπωθούν αποτελεσματικά από μοντέλα βασισμένα σε δένδρα αποφάσεων.

5.5.2. Επίδραση της χρονικής πληροφορίας

Τα αποτελέσματα όλων των μοντέλων υποδεικνύουν ότι η ιστορική πληροφορία του φορτίου αποτελεί τον σημαντικότερο παράγοντα για την επιτυχή πρόβλεψη της ζήτησης ηλεκτρικής ενέργειας. Η υψηλή σημασία των χρονικών υστερήσεων στα μοντέλα γραμμικής παλινδρόμησης, Random Forest και XGBoost, καθώς και η υπεροχή του μονομεταβλητού μοντέλου LSTM έναντι των πολυμεταβλητών διαμορφώσεων, καταδεικνύουν ότι οι πρόσφατες τιμές του φορτίου περιέχουν το μεγαλύτερο μέρος της χρήσιμης πληροφορίας για τον χρονικό ορίζοντα πρόβλεψης της μίας ώρας.

Η ανάλυση της σημασίας των χρονικών υστερήσεων στα μοντέλα μηχανικής μάθησης καταδεικνύει μια συνεπή και δομικά σημαντική ιεράρχηση της χρονικής πληροφορίας της χρονοσειράς. Συγκεκριμένα, η χρονική υστέρηση 24 ωρών (lag24) αναδεικνύεται σταθερά ως το σημαντικότερο χαρακτηριστικό, ακολουθούμενη από τη βραχυπρόθεσμη υστέρηση μίας ώρας (lag1) και, σε μικρότερο βαθμό, την εβδομαδιαία υστέρηση (lag168). Το αποτέλεσμα αυτό υποδηλώνει ότι η ημερήσια περιοδικότητα αποτελεί τη βασική δομική συνιστώσα της χρονοσειράς, ενώ οι πιο βραχυπρόθεσμες και εβδομαδιαίες εξαρτήσεις λειτουργούν συμπληρωματικά στην πρόβλεψη της ζήτησης.

Η συνέπεια της παραπάνω ιεράρχησης μεταξύ διαφορετικών αλγορίθμων μηχανικής μάθησης ενισχύει το συμπέρασμα ότι η πληροφορία για την πρόβλεψη εμπεριέχεται κυρίως στους ημερήσιους κύκλους κατανάλωσης. Το παραπάνω μοτίβο συνάδει επίσης με τα ευρήματα της διερευνητικής ανάλυσης δεδομένων (EDA), όπου οι διαφορές μεταξύ εργάσιμων ημερών και Σαββατοκύριακου εμφανίζονται περιορισμένες, γεγονός που υποδηλώνει ότι οι ημερολογιακές επιδράσεις έχουν δευτερεύον ρόλο σε σχέση με την έντονη ημερήσια περιοδικότητα της χρονοσειράς.

Ιδιαίτερο ενδιαφέρον παρουσιάζει το γεγονός ότι το μοντέλο γραμμικής παλινδρόμησης πέτυχε ελαφρώς καλύτερη επίδοση από το βέλτιστο μοντέλο LSTM. Μία πιθανή ερμηνεία είναι ότι η χρήση των ρητών χρονικών υστερήσεων lag1, lag24 και lag168 επέτρεψε στο γραμμικό μοντέλο να αξιοποιήσει άμεσα τις σημαντικότερες χρονικές εξαρτήσεις της χρονοσειράς, ενώ το LSTM έπρεπε να ανακαλύψει και να αναπαραστήσει τα πρότυπα αυτά αποκλειστικά από τις ακολουθίες εισόδου μέσω της διαδικασίας εκπαίδευσης.

Η ερμηνεία αυτή ενισχύεται και από την ανάλυση αυτοσυσχέτισης των υπολοίπων του μοντέλου LSTM. Όπως και στα υπόλοιπα μοντέλα, παρατηρούνται διακριτές κορυφές σε χρονικές υστερήσεις που αντιστοιχούν σε πολλαπλάσια των 24 ωρών, γεγονός που υποδηλώνει ότι μέρος της ημερήσιας περιοδικότητας παραμένει στα σφάλματα πρόβλεψης. Ωστόσο, σε αντίθεση με τα υπόλοιπα μοντέλα, η συνάρτηση αυτοσυσχέτισης των υπολοίπων του LSTM παρουσιάζει εντονότερη ταλαντωτική συμπεριφορά μεταξύ των διαδοχικών κορυφών, υποδηλώνοντας την ύπαρξη υπολειπόμενων χρονικών δομών που δεν έχουν αποτυπωθεί πλήρως από το μοντέλο. Το εύρημα αυτό ενδέχεται να εξηγεί εν μέρει τη χαμηλότερη προγνωστική επίδοση του LSTM σε σχέση με τα μοντέλα που αξιοποίησαν ρητές χρονικές υστερήσεις. Επιπλέον, η σύγκριση μεταξύ διαφορετικών μηκών ιστορικού παραθύρου στο LSTM δείχνει συστηματική υπεροχή του παραθύρου των 24 ωρών έναντι της διαμόρφωσης των 168 ωρών. Το γεγονός αυτό ενισχύει την παρατήρηση ότι η κρίσιμη πληροφορία για τη βραχυπρόθεσμη πρόβλεψη εντοπίζεται κυρίως στον ημερήσιο κύκλο, ενώ η επέκταση του ιστορικού ορίζοντα δεν προσφέρει ουσιαστική βελτίωση της προγνωστικής ικανότητας.

Συνολικά, τα αποτελέσματα όλων των προσεγγίσεων συγκλίνουν στο ότι η βραχυπρόθεσμη δυναμική της χρονοσειράς κυριαρχείται από ισχυρή ημερήσια περιοδικότητα, η οποία αποτελεί τον κύριο άξονα εξηγητικής και προγνωστικής πληροφορίας ανεξαρτήτως αλγοριθμικής αρχιτεκτονικής.

5.5.3. Επίδραση των εξωγενών μεταβλητών

Η σύγκριση μεταξύ μονομεταβλητών και πολυμεταβλητών διαμορφώσεων των μοντέλων LSTM έδειξε ότι η ενσωμάτωση εξωγενών μεταβλητών δεν οδήγησε σε συστηματική βελτίωση της προγνωστικής επίδοσης των μοντέλων. Στην περίπτωση των LSTM, το βέλτιστο αποτέλεσμα επιτεύχθηκε από το μονομεταβλητό μοντέλο με παράθυρο εισόδου 24 ωρών. Η επίδραση των εξωγενών μεταβλητών δεν ήταν ομοιόμορφη μεταξύ των διαφορετικών διαμορφώσεων, καθώς για παράθυρο 168 ωρών παρατηρήθηκε βελτίωση της προγνωστικής επίδοσης σε σχέση με το αντίστοιχο μονομεταβλητό μοντέλο, ενώ για παράθυρο 24 ωρών η επίδοση υποβαθμίστηκε. Παρά τη διαφοροποίηση αυτή, καμία από τις πολυμεταβλητές διαμορφώσεις δεν κατάφερε να ξεπεράσει την επίδοση του μονομεταβλητού μοντέλου των 24 ωρών. Το εύρημα αυτό υποδηλώνει ότι η συμβολή των εξωγενών μεταβλητών εξαρτάται από τη διαμόρφωση του μοντέλου και δεν μεταφράζεται απαραίτητα σε βελτίωση της προγνωστικής επίδοσης.

Η ανάλυση της σημασίας των χαρακτηριστικών των πολυμεταβλητών μοντέλων LSTM με permutation importance παρέχει επιπλέον πληροφορίες σχετικά με τον τρόπο με τον οποίο το δίκτυο αξιοποίησε τις διαθέσιμες εισόδους. Παρά τις διαφοροποιήσεις στις επιμέρους τιμές σημασίας των χαρακτηριστικών, η μεταβλητή της ιστορικής κατανάλωσης ηλεκτρικής ενέργειας αναδείχθηκε και στις δύο πολυμεταβλητές διαμορφώσεις ως η σημαντικότερη πηγή πληροφορίας, παρουσιάζοντας σημαντικά υψηλότερη συμβολή σε σχέση με όλες τις υπόλοιπες μεταβλητές. Μεταξύ των εξωγενών χαρακτηριστικών, η ηλιακή ακτινοβολία (shortwave radiation) και η ώρα της ημέρας (hour) κατέγραψαν τις υψηλότερες τιμές σημασίας, ενώ οι υπόλοιπες μετεωρολογικές και ημερολογιακές μεταβλητές παρουσίασαν αισθητά μικρότερη συμβολή. Το εύρημα αυτό πιθανόν υποδηλώνει ότι οι μεταβολές της ζήτησης σχετίζονται περισσότερο με παράγοντες που αποτυπώνουν τον ημερήσιο κύκλο λειτουργίας του λιμένα και τις συνθήκες φωτισμού, παρά με βραχυχρόνιες μεταβολές των λοιπών μετεωρολογικών συνθηκών.

Η εικόνα που προκύπτει από τα μοντέλα LSTM είναι συνεπής με τα αποτελέσματα των μοντέλων γραμμικής παλινδρόμησης, Random Forest και XGBoost. Στα μοντέλα αυτά, οι χρονικές υστερήσεις του φορτίου αναδείχθηκαν σταθερά ως η κυρίαρχη πηγή πληροφορίας για την πρόβλεψη της ζήτησης ηλεκτρικής ενέργειας, με συνεπή ιεράρχηση των χαρακτηριστικών lag24, lag1 και lag168 ως προς τη σχετική τους σημασία. Παράλληλα, μεταξύ των εξωγενών μεταβλητών, η ηλιακή ακτινοβολία (shortwave radiation) εμφανίστηκε σταθερά ως το σημαντικότερο χαρακτηριστικό, ενώ η θερμοκρασία κατέλαβε δευτερεύοντα αλλά σαφώς διακριτό ρόλο.

Αντίθετα, μεταβλητές όπως η σχετική υγρασία, τα κατακρημνίσματα, η νεφοκάλυψη και τα χαρακτηριστικά του ανέμου παρουσίασαν περιορισμένη συμβολή στην προγνωστική διαδικασία. Παρόμοια εικόνα παρατηρήθηκε και για τις περισσότερες ημερολογιακές μεταβλητές, των οποίων η σημασία ήταν σημαντικά χαμηλότερη σε σύγκριση με εκείνη των ιστορικών χαρακτηριστικών του φορτίου.

Η συνέπεια των παραπάνω ευρημάτων μεταξύ διαφορετικών αλγοριθμικών προσεγγίσεων ενισχύει την αξιοπιστία του συμπεράσματος ότι η κύρια πληροφορία για τη βραχυπρόθεσμη πρόβλεψη φορτίου περιέχεται ήδη στη χρονοσειρά της κατανάλωσης, ενώ οι εξωγενείς μεταβλητές λειτουργούν κυρίως συμπληρωματικά. Το αποτέλεσμα αυτό πιθανόν

υποδηλώνει ότι οι επιδράσεις των μετεωρολογικών και ημερολογιακών παραγόντων αποτυπώνονται σε σημαντικό βαθμό έμμεσα στις ιστορικές τιμές του φορτίου, περιορίζοντας το πρόσθετο πληροφοριακό όφελος από την άμεση ενσωμάτωσή τους στα μοντέλα πρόβλεψης.

5.5.4. Ερμηνεία της επίδοσης των μοντέλων

Το μοντέλο Random Forest πέτυχε την καλύτερη συνολική επίδοση, γεγονός που πιθανόν οφείλεται στην ικανότητά του να αποτυπώνει μη γραμμικές σχέσεις μεταξύ των χαρακτηριστικών χωρίς να απαιτεί ιδιαίτερα μεγάλο όγκο δεδομένων εκπαίδευσης. Η υψηλή σημασία των χρονικών υστερήσεων υποδηλώνει ότι η κύρια πληροφορία για την πρόβλεψη του φορτίου ήταν ήδη διαθέσιμη στα χαρακτηριστικά εισόδου, επιτρέποντας στο μοντέλο να αξιοποιήσει αποτελεσματικά τις συσχετίσεις αυτές μέσω της δομής των δένδρων αποφάσεων.

Η πολύ μικρή διαφορά μεταξύ Random Forest και XGBoost υποδηλώνει ότι το πρόβλημα πρόβλεψης χαρακτηρίζεται από ισχυρό πληροφοριακό σήμα, το οποίο μπορεί να αποτυπωθεί αποτελεσματικά και από τις δύο μεθόδους. Υπό αυτές τις συνθήκες, το πλεονέκτημα της διαδοχικής διόρθωσης σφαλμάτων που προσφέρει το XGBoost φαίνεται να είναι περιορισμένο.

Η ανταγωνιστική επίδοση της γραμμικής παλινδρόμησης υποδηλώνει ότι σημαντικό μέρος της πληροφορίας που απαιτείται για τη βραχυπρόθεσμη πρόβλεψη του φορτίου μπορεί να περιγραφεί μέσω σχετικά απλών σχέσεων μεταξύ των μεταβλητών εισόδου και της μεταβλητής στόχου. Η χρήση των χρονικών υστερήσεων επέτρεψε στο μοντέλο να αξιοποιήσει άμεσα τη σημαντικότερη διαθέσιμη πληροφορία, περιορίζοντας το πλεονέκτημα που θα μπορούσαν να προσφέρουν πιο σύνθετες προσεγγίσεις.

Παρότι τα δίκτυα LSTM έχουν σχεδιαστεί για την εκμάθηση σύνθετων χρονικών εξαρτήσεων, τα αποτελέσματα της παρούσας μελέτης υποδηλώνουν ότι η συγκεκριμένη χρονοσειρά χαρακτηρίζεται κυρίως από έντονη ημερήσια περιοδικότητα και ισχυρή αυτοσυσχέτιση μικρού βάθους. Υπό αυτές τις συνθήκες, το πρόσθετο επίπεδο πολυπλοκότητας του LSTM δεν μεταφράστηκε σε αντίστοιχη βελτίωση της προγνωστικής επίδοσης. Η ύπαρξη υπολειπόμενης χρονικής δομής στα σφάλματα πρόβλεψης, όπως προέκυψε από την ανάλυση αυτοσυσχέτισης των υπολοίπων, υποδηλώνει ότι το μοντέλο δεν αξιοποίησε πλήρως τη διαθέσιμη χρονική πληροφορία.

Ως προς την ερμηνευσιμότητα, η γραμμική παλινδρόμηση αποτελεί την πλέον διαφανή προσέγγιση, καθώς η επίδραση κάθε χαρακτηριστικού μπορεί να εκτιμηθεί άμεσα μέσω των συντελεστών του μοντέλου. Παρότι η τυποποίηση των μεταβλητών περιορίζει την άμεση ερμηνεία των συντελεστών σε φυσικές μονάδες, εξακολουθεί να επιτρέπει τη σύγκριση της σχετικής επίδρασης των χαρακτηριστικών και την κατανόηση της κατεύθυνσης της σχέσης τους με το φορτίο. Τα μοντέλα Random Forest και XGBoost παρουσιάζουν χαμηλότερη αλλά ικανοποιητική ερμηνευσιμότητα, καθώς η ανάλυση σημασίας χαρακτηριστικών επιτρέπει την αναγνώριση των σημαντικότερων μεταβλητών που συμβάλλουν στις προβλέψεις. Αντίθετα, τα δίκτυα LSTM χαρακτηρίζονται από περιορισμένη ερμηνευσιμότητα λόγω της σύνθετης εσωτερικής τους δομής και της κατανεμημένης αναπαράστασης της πληροφορίας στους νευρώνες και τις καταστάσεις μνήμης. Παρόλα αυτά, η εφαρμογή της μεθόδου permutation importance επέτρεψε την εξαγωγή χρήσιμων συμπερασμάτων σχετικά με τη σχετική σημασία των μεταβλητών εισόδου, βελτιώνοντας σε κάποιο βαθμό τη δυνατότητα ερμηνείας της συμπεριφοράς του μοντέλου.

Ως προς την πολυπλοκότητα και το υπολογιστικό κόστος, οι εξεταζόμενες μέθοδοι παρουσιάζουν σημαντικές διαφοροποιήσεις. Η γραμμική παλινδρόμηση αποτελεί την απλούστερη προσέγγιση τόσο ως προς τη δομή του μοντέλου όσο και ως προς τη διαδικασία εκπαίδευσης, απαιτώντας περιορισμένους υπολογιστικούς πόρους και μικρό χρόνο εκτέλεσης. Τα μοντέλα Random Forest και XGBoost χαρακτηρίζονται από μεγαλύτερη πολυπλοκότητα, καθώς βασίζονται στη δημιουργία συνόλων δένδρων αποφάσεων και στην αξιοποίηση μη γραμμικών σχέσεων μεταξύ των μεταβλητών. Παρόλα αυτά, η διαδικασία εκπαίδευσής τους παρέμεινε πρακτικά διαχειρίσιμη στο πλαίσιο της παρούσας εργασίας. Αντίθετα, τα μοντέλα LSTM παρουσίασαν τη μεγαλύτερη πολυπλοκότητα, καθώς απαιτούν την εκπαίδευση μεγάλου αριθμού παραμέτρων μέσω επαναληπτικών διαδικασιών βελτιστοποίησης. Επιπλέον, η διερεύνηση διαφορετικών αρχιτεκτονικών, μηκών ιστορικού παραθύρου και υπερπαραμέτρων αύξησε σημαντικά το συνολικό υπολογιστικό κόστος της ανάπτυξης των μοντέλων. Παρά την αυξημένη αυτή πολυπλοκότητα, τα μοντέλα LSTM δεν κατέγραψαν ανώτερη προγνωστική επίδοση σε σχέση με τις μεθόδους που βασίζονται σε δένδρα αποφάσεων, ενώ ακόμη και η γραμμική παλινδρόμηση παρέμεινε ιδιαίτερα ανταγωνιστική.

Συνολικά, τα αποτελέσματα δείχνουν ότι η αύξηση της πολυπλοκότητας του μοντέλου δεν οδηγεί απαραίτητα σε αντίστοιχη βελτίωση της προγνωστικής ακρίβειας καθώς για το συγκεκριμένο πρόβλημα πρόβλεψης φορτίου, οι απλούστερες ή μετρίως σύνθετες προσεγγίσεις αξιοποίησαν αποτελεσματικότερα τη διαθέσιμη πληροφορία. Παρά το γεγονός ότι τα μοντέλα βαθιάς μάθησης διαθέτουν μεγαλύτερη αναπαραστατική ικανότητα, οι μέθοδοι που βασίζονται σε δένδρα αποφάσεων απέδωσαν καλύτερα στο συγκεκριμένο πρόβλημα. Παράλληλα, η πολύ καλή επίδοση της γραμμικής παλινδρόμησης υπογραμμίζει ότι η κατάλληλη επιλογή χαρακτηριστικών μπορεί να αντισταθμίσει σε σημαντικό βαθμό την απλότητα του μοντέλου. Τα ευρήματα αυτά υποστηρίζουν ότι η φύση της χρονοσειράς και η ποιότητα των χαρακτηριστικών εισόδου είναι συχνά σημαντικότερες από την πολυπλοκότητα του ίδιου του αλγορίθμου.

Μεταξύ των εξεταζόμενων προσεγγίσεων, το Random Forest παρουσίασε την καλύτερη συνολική ισορροπία μεταξύ προγνωστικής ακρίβειας, ερμηνευσιμότητας και υπολογιστικής αποδοτικότητας. Συνεπώς, για το συγκεκριμένο πρόβλημα βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου, τα αποτελέσματα υποδεικνύουν ότι η αξιοποίηση κατάλληλων χρονικών χαρακτηριστικών και η επιλογή μοντέλων μέτριας πολυπλοκότητας αποτελούν αποτελεσματικότερη στρατηγική από την υιοθέτηση ολοένα και πιο σύνθετων αρχιτεκτονικών.

5.6. Συζήτηση και σύνδεση με τη βιβλιογραφία

5.6.1. Επισκόπηση των κύριων ευρημάτων

Η παρούσα εργασία διερεύνησε την απόδοση τεσσάρων προσεγγίσεων πρόβλεψης της βραχυπρόθεσμης ζήτησης ηλεκτρικής ενέργειας μίας ώρας μπροστά (one-hour-ahead Short-Term Load Forecasting), της Γραμμικής Παλινδρόμησης (Linear Regression), του Random Forest, του Extreme Gradient Boosting (XGBoost) και του Long Short-Term Memory (LSTM), αξιοποιώντας πραγματικά δεδομένα ηλεκτρικής κατανάλωσης του Νότιου Λιμένα Πατρών. Όλα τα μοντέλα αναπτύχθηκαν και αξιολογήθηκαν στο ίδιο πειραματικό πλαίσιο, με κοινό σύνολο δεδομένων και μεθοδολογία προεπεξεργασίας και αξιολόγησης προσαρμοσμένη στις απαιτήσεις κάθε αλγορίθμου.

Τα αποτελέσματα ανέδειξαν σαφείς διαφοροποιήσεις ως προς την αποτελεσματικότητα των εξεταζόμενων προσεγγίσεων. Οι μέθοδοι μηχανικής μάθησης που βασίζονται σε δένδρα αποφάσεων παρουσίασαν συνολικά την υψηλότερη προγνωστική ακρίβεια, ενώ η Γραμμική Παλινδρόμηση παρέμεινε ανταγωνιστική παρά την απλότητά της. Αντίθετα, τα εξεταζόμενα μοντέλα LSTM δεν κατόρθωσαν να υπερέχουν των βέλτιστων μοντέλων μηχανικής μάθησης. Παράλληλα, η ανάλυση της σημασίας των χαρακτηριστικών ανέδειξε τον κυρίαρχο ρόλο της ιστορικής κατανάλωσης ηλεκτρικής ενέργειας, με την ημερήσια περιοδικότητα του φορτίου να αποτελεί το σημαντικότερο χρονικό πρότυπο, ενώ οι μετεωρολογικές μεταβλητές συνέβαλαν κυρίως συμπληρωματικά στη βελτίωση της προγνωστικής απόδοσης.

5.6.2. Προγνωστική απόδοση και οικογένεια μοντέλων

Ένα από τα σημαντικότερα ευρήματα της παρούσας μελέτης ήταν ότι τα μοντέλα μηχανικής μάθησης που βασίζονται σε δένδρα αποφάσεων, και ιδιαίτερα το Random Forest και το XGBoost, παρουσίασαν την υψηλότερη προγνωστική απόδοση, ενώ το βέλτιστο μοντέλο LSTM δεν κατόρθωσε να υπερέχει των αποδοτικότερων δενδρικών (tree-based) προσεγγίσεων. Το εύρημα αυτό συμφωνεί με μέρος της πρόσφατης βιβλιογραφίας για τη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου, η οποία όμως δεν συγκλίνει στην ύπαρξη ενός καθολικά υπέρτερου αλγορίθμου, καθώς η σχετική απόδοση των διαφορετικών προσεγγίσεων επηρεάζεται από τα χαρακτηριστικά του προβλήματος πρόβλεψης, το διαθέσιμο σύνολο δεδομένων και τη μεθοδολογία ανάπτυξης των μοντέλων.

Η σύγκριση με προηγούμενες μελέτες ξεκινά από εργασίες που εξετάζουν εφαρμογές σε λιμενικά ενεργειακά συστήματα, λόγω της άμεσης συνάφειάς τους με την παρούσα περίπτωση μελέτης, και στη συνέχεια επεκτείνεται σε ευρύτερες εφαρμογές βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου. Η προσέγγιση αυτή επιτρέπει να εξεταστεί κατά πόσο η υπεροχή των μοντέλων που βασίζονται σε δένδρα αποφάσεων αποτελεί ιδιαιτερότητα των λιμενικών υποδομών ή αν παρατηρείται με συνέπεια και σε διαφορετικά περιβάλλοντα, όπως εθνικά συστήματα ηλεκτρικής ενέργειας, βιομηχανικές εγκαταστάσεις και κτιριακά φορτία.

Η ανώτερη προγνωστική επίδοση του μοντέλου Random Forest που παρατηρήθηκε στην παρούσα μελέτη για το Νότιο Λιμένα Πατρών είναι σύμφωνη με τα αποτελέσματα των Micallef et al. (2025), οι οποίοι επίσης ανέδειξαν το Random Forest ως το ακριβέστερο μοντέλο μεταξύ εκείνων που αξιολογήθηκαν για την πρόβλεψη της ζήτησης ηλεκτρικής ενέργειας μίας ημέρας μπροστά (day-ahead) σε λιμενικό μικροδίκτυο. Οι συγγραφείς απέδωσαν την υπεροχή αυτή στην ικανότητα του Random Forest να αποτυπώνει πολύπλοκες μη γραμμικές αλληλεπιδράσεις μεταξύ των μεταβλητών εισόδου, διατηρώντας παράλληλα υψηλή ανθεκτικότητα στην υπερπροσαρμογή, λόγω της φύσης του ως μεθόδου ensemble learning. Παρότι η μελέτη των Micallef et al. (2025) αφορούσε διαφορετικό ορίζοντα πρόβλεψης και περιλάμβανε πρόσθετες επιχειρησιακές μεταβλητές ειδικές για λιμενικά μικροδίκτυα, και οι δύο μελέτες βασίστηκαν στον συνδυασμό ιστορικών δεδομένων φορτίου με εξωγενείς μεταβλητές, όπως μετεωρολογικά και ημερολογιακά χαρακτηριστικά. Το γεγονός ότι και στη μελέτη των Micallef et al. (2025) το Random Forest αναδείχθηκε ως το ακριβέστερο μοντέλο ενισχύει την αξιοπιστία του ως προσέγγισης για εφαρμογές βραχυπρόθεσμης πρόβλεψης ηλεκτρικής ζήτησης σε λιμενικά περιβάλλοντα.

Πέρα όμως από τις εφαρμογές σε λιμενικά ενεργειακά συστήματα, αντίστοιχα συμπεράσματα έχουν αναφερθεί και σε ένα ευρύ φάσμα εφαρμογών βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου, υποδηλώνοντας ότι η υψηλή προγνωστική απόδοση των μοντέλων που βασίζονται σε δένδρα αποφάσεων έχει παρατηρηθεί και σε διαφορετικά λειτουργικά περιβάλλοντα.

Οι Abumohsen et al. (2023) διερεύνησαν τη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου (STLF) χρησιμοποιώντας πραγματικά δεδομένα κατανάλωσης από δίκτυο διανομής ηλεκτρικής ενέργειας στην Παλαιστίνη. Σε συμφωνία με την παρούσα εργασία, το μοντέλο Random Forest κατέγραψε την υψηλότερη προγνωστική ακρίβεια μεταξύ των εξεταζόμενων μοντέλων μηχανικής μάθησης ($R^2 = 0,877$). Ωστόσο, στη μελέτη των Abumohsen et al. η απόδοση της γραμμικής παλινδρόμησης ($R^2 = 0,637$) ήταν σημαντικά χαμηλότερη από εκείνη των μοντέλων Random Forest και XGBoost ($R^2 = 0,811$), ενώ στην παρούσα εργασία παρέμεινε ιδιαίτερα ανταγωνιστική, παρουσιάζοντας επίδοση συγκρίσιμη με εκείνη του βέλτιστου μοντέλου LSTM. Η διαφορά αυτή ενδέχεται να οφείλεται στο γεγονός ότι, παρότι οι συγγραφείς εντόπισαν μέσω της διερευνητικής ανάλυσης σαφή ημερήσια και εβδομαδιαία περιοδικότητα, δεν αναφέρεται να αξιοποιήσαν ρητές χρονικές υστερήσεις του φορτίου ως χαρακτηριστικά εισόδου. Αντίθετα, στην παρούσα μελέτη η χρονική πληροφορία ενσωματώθηκε μέσω των μεταβλητών χρονικής υστέρησης lag1, lag24 και lag168, οι οποίες αναδείχθηκαν ως οι σημαντικότεροι προγνωστικοί παράγοντες. Οι Gökçe και Duman (2022) διερεύνησαν τη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου χρησιμοποιώντας ωριαία δεδομένα κατανάλωσης ηλεκτρικής ενέργειας από την Τουρκία και συγκρίνοντας τα μοντέλα Linear Regression, Random Forest και XGBoost σε ένα πειραματικό πλαίσιο αντίστοιχο με εκείνο της παρούσας μελέτης, αξιοποιώντας χαρακτηριστικά χρονικής υστέρησης, μετεωρολογικές και ημερολογιακές μεταβλητές. Σε συμφωνία με τα ευρήματα της παρούσας εργασίας, τα μοντέλα που βασίζονται σε δένδρα αποφάσεων παρουσίασαν την υψηλότερη προγνωστική ακρίβεια, με το Random Forest και το XGBoost να εμφανίζουν πολύ παρόμοια απόδοση και την πρωτιά να εναλλάσσεται ανάλογα με τη μετρική αξιολόγησης, ενώ η Γραμμική Παλινδρόμηση κατέγραψε σταθερά τη χαμηλότερη προγνωστική ακρίβεια μεταξύ των τριών μοντέλων.

Παρόμοια ευρήματα αναφέρονται από τον Tümsel (2025), ο οποίος συνέκρινε τα μοντέλα XGBoost, Random Forest και LSTM για την πρόβλεψη της ημερήσιας κατανάλωσης ηλεκτρικής ενέργειας στην Τουρκία και διαπίστωσε ότι οι μέθοδοι που βασίζονται σε δένδρα αποφάσεων παρουσίασαν υψηλότερη προγνωστική ακρίβεια από το μοντέλο LSTM, με το XGBoost να επιτυγχάνει την καλύτερη συνολική επίδοση. Οι συγγραφείς συνέδεσαν την υπεροχή αυτή με την αποτελεσματική αξιοποίηση των δομημένων δεδομένων και της διαδικασίας μηχανικής χαρακτηριστικών, ενώ το Random Forest αξιολογήθηκε από τους συγγραφείς ως αξιόπιστη προσέγγιση για την αποτύπωση μη γραμμικών σχέσεων στα δεδομένα.

Οι Ibrahim et al. (2022), εξετάζοντας την ωριαία πρόβλεψη ηλεκτρικής ζήτησης στο εθνικό σύστημα ηλεκτρικής ενέργειας του Παναμά, διαπίστωσαν ότι το Random Forest και το XGBoost παρουσίασαν ιδιαίτερα ανταγωνιστική απόδοση, με το Random Forest να επιτυγχάνει ελαφρώς χαμηλότερα σφάλματα από το XGBoost. Παράλληλα, όπως και στην παρούσα μελέτη, η ανάλυση σημαντικότητας χαρακτηριστικών ανέδειξε το ιστορικό φορτίο της προηγούμενης εβδομάδας και της προηγούμενης ημέρας ως τους σημαντικότερους προγνωστικούς παράγοντες, ενώ η θερμοκρασία είχε μικρότερη συμβολή. Πέρα όμως από την καταγραφή της συγκριτικής υπεροχής των μοντέλων που βασίζονται σε δένδρα αποφάσεων, αρκετές μελέτες επιχείρησαν να διερευνήσουν τους λόγους για τους οποίους οι προσεγγίσεις αυτές εμφανίζουν σταθερά υψηλή προγνωστική απόδοση σε διαφορετικά σύνολα δεδομένων και εφαρμογές.

Ο Dudek (2022) πραγματοποίησε μία εκτενή διερεύνηση της εφαρμογής του Random Forest στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου, χρησιμοποιώντας ωριαία δεδομένα από τέσσερα ευρωπαϊκά συστήματα ηλεκτρικής ενέργειας και συγκρίνοντάς το με ένα ευρύ φάσμα μοντέλων στατιστικής, μηχανικής μάθησης και βαθιάς μάθησης, συμπεριλαμβανομένων υβριδικών αρχιτεκτονικών. Το Random Forest κατέγραψε την

υψηλότερη προγνωστική ακρίβεια στις τρεις από τις τέσσερις περιπτώσεις, ενώ στο τέταρτο σύνολο δεδομένων κατετάγη τρίτο, μετά τα μοντέλα RandNN και SVM, επιβεβαιώνοντας την υψηλή αποτελεσματικότητά του στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου. Ο συγγραφέας απέδωσε την υπεροχή του μοντέλου κυρίως στην ειδική προεπεξεργασία και αναπαράσταση της χρονοσειράς, τονίζοντας ότι η κατάλληλη αναπαράσταση της ιστορικής πληροφορίας αποτελεί καθοριστικό παράγοντα για την προγνωστική απόδοση. Η ανάλυση σημαντικότητας χαρακτηριστικών ανέδειξε ως σημαντικότερο προγνωστικό παράγοντα την κατανάλωση της ίδιας ώρας της προηγούμενης ημέρας (lag24), εύρημα που βρίσκεται σε συμφωνία με την παρούσα μελέτη, όπου οι μεταβλητές χρονικής υστέρησης και ιδιαίτερα η ημερήσια περιοδικότητα αποτέλεσαν τους σημαντικότερους παράγοντες πρόβλεψης.

Οι Ribeiro et al. (2022) διερεύνησαν τη βραχυπρόθεσμη και πολύ βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου σε κτίριο αποθήκης, χρησιμοποιώντας ωριαία δεδομένα κατανάλωσης και συγκρίνοντας μοντέλα μηχανικής μάθησης και βαθιάς μάθησης, μεταξύ των οποίων και τα Random Forest, XGBoost, LSTM και GRU. Ως είσοδος χρησιμοποιήθηκε αποκλειστικά ένα ιστορικό παράθυρο 48 διαδοχικών ωριαίων τιμών φορτίου, χωρίς αξιοποίηση μετεωρολογικών ή άλλων εξωγενών μεταβλητών. Τα μοντέλα XGBoost και Random Forest, με μικρές μεταξύ τους διαφορές, κατέγραψαν τις υψηλότερες επιδόσεις, υπερέχοντας των μοντέλων βαθιάς μάθησης, εύρημα που συμφωνεί με τη γενική εικόνα που προέκυψε και στην παρούσα μελέτη, όπου τα δύο μοντέλα βασισμένα σε δέντρα αποφάσεων παρουσίασαν επίσης την καλύτερη προγνωστική απόδοση. Οι συγγραφείς αποδίδουν την υπεροχή του XGBoost τόσο στην καταλληλότητα του για δεδομένα πινακοποιημένης μορφής (tabular data) όσο και στο γεγονός ότι τα μοντέλα βαθιάς μάθησης απαιτούν σημαντικά μεγαλύτερη υπολογιστική προσπάθεια και εκτεταμένο συντονισμό υπερπαραμέτρων, χωρίς αυτό να συνεπάγεται απαραίτητα υψηλότερη ακρίβεια. Το εύρημα αυτό ενισχύει την παρατήρηση της παρούσας μελέτης ότι η αυξημένη αλγοριθμική πολυπλοκότητα δεν οδηγεί κατ' ανάγκη σε βελτιωμένη προγνωστική απόδοση.

Τα ευρήματα αυτά ενισχύονται από τη μελέτη των Shwartz-Ziv και Armon (2022), οι οποίοι αξιολόγησαν την απόδοση σύγχρονων μοντέλων βαθιάς μάθησης και μεθόδων βασισμένων σε δέντρα σε έντεκα ετερογενή σύνολα δεδομένων πινακοποιημένης μορφής (tabular data). Οι συγγραφείς διαπίστωσαν ότι το XGBoost υπερείχε γενικά των εξεταζόμενων μοντέλων βαθιάς μάθησης, ιδιαίτερα σε σύνολα δεδομένων που δεν είχαν χρησιμοποιηθεί στις αρχικές μελέτες ανάπτυξής τους, γεγονός που υποδηλώνει καλύτερη ικανότητα γενίκευσης. Παράλληλα, έδειξαν ότι τα μοντέλα βαθιάς μάθησης απαιτούσαν σημαντικά μεγαλύτερη προσπάθεια συντονισμού υπερπαραμέτρων και υψηλότερο υπολογιστικό κόστος, χωρίς η αυξημένη αυτή πολυπλοκότητα να μεταφράζεται απαραίτητα σε υψηλότερη προγνωστική απόδοση. Οι συγγραφείς υποστηρίζουν ότι, κατά την αξιολόγηση μοντέλων για πραγματικές εφαρμογές, θα πρέπει να συνεκτιμώνται όχι μόνο η ακρίβεια πρόβλεψης, αλλά και η ευκολία βελτιστοποίησης, το υπολογιστικό κόστος και η δυνατότητα γενίκευσης σε νέα σύνολα δεδομένων. Η παρατήρηση αυτή συνάδει με τα ευρήματα της παρούσας μελέτης, όπου τα μοντέλα βασισμένα σε δέντρα παρείχαν υψηλότερη προγνωστική ακρίβεια από το LSTM, παρά τη μικρότερη πολυπλοκότητα και τις χαμηλότερες απαιτήσεις παραμετροποίησης.

Με αφετηρία την υψηλή απόδοση των μοντέλων που βασίζονται σε δέντρα αποφάσεων, αρκετές πρόσφατες μελέτες δεν περιορίζονται πλέον στη συγκριτική αξιολόγηση διαφορετικών αλγορίθμων, αλλά διερευνούν τρόπους περαιτέρω ενίσχυσης της προγνωστικής τους ικανότητας μέσω υβριδικών και συνδυαστικών προσεγγίσεων.

Συναφή ευρήματα αναφέρθηκαν από τους Wang et al. (2021), οι οποίοι διερεύνησαν το πρόβλημα της βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου (STLF) σε μεμονωμένους βιομηχανικούς καταναλωτές ηλεκτρικής ενέργειας, αξιολογώντας την απόδοση

διαφορετικών μοντέλων σε δύο ανεξάρτητα πραγματικά σύνολα δεδομένων, προερχόμενα από βιομηχανικό καταναλωτή στην Κίνα και από τη δημόσια βάση δεδομένων Irish Smart Metering Electricity Customer Behaviour Trials. Μεταξύ των μεμονωμένων μοντέλων που αξιολογήθηκαν (SVR, ELM, LSTM, CNN, GBDT και XGBoost), το XGBoost παρουσίασε το χαμηλότερο προγνωστικό σφάλμα, ενώ παράλληλα απαίτησε κατά πολύ μικρότερο υπολογιστικό χρόνο σε σύγκριση με το LSTM. Οι συγγραφείς έδειξαν επίσης ότι η ενσωμάτωση του XGBoost σε υβριδικές αρχιτεκτονικές βασισμένες σε αποσύνθεση χρονοσειρών (EMD-XGBoost, SVM-D-XGBoost και το προτεινόμενο υβριδικό μοντέλο) οδήγησε σε περαιτέρω βελτίωση της ακρίβειας των προβλέψεων, με αντίτιμο όμως το κατά πολύ αυξημένο υπολογιστικό κόστος.

Οι Salakapuri και Pavan Kumar (2025) διερεύνησαν τη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου χρησιμοποιώντας πραγματικά ωριαία δεδομένα από την πλατφόρμα ENTSO-E για είκοσι ευρωπαϊκές χώρες κατά την περίοδο 2018–2024. Οι συγγραφείς αξιολόγησαν αρχικά δέκα μεμονωμένα μοντέλα μηχανικής και βαθιάς μάθησης και διαπίστωσαν ότι τα μοντέλα βασισμένα σε δέντρα αποφάσεων (Extra Trees, Random Forest και XGBoost) αποτελούσαν τις αποδοτικότερες προσεγγίσεις ήδη από την αρχική αξιολόγηση. Μετά την ενσωμάτωση χαρακτηριστικών χρονικής υστέρησης και την εφαρμογή πενταπλής διασταυρούμενης επικύρωσης, όλα τα μοντέλα παρουσίασαν ουσιαστική βελτίωση της προγνωστικής τους απόδοσης και μείωση των σφαλμάτων, όμως τα μοντέλα βασισμένα σε δέντρα αποφάσεων διατήρησαν την υπεροχή τους, με το Extra Trees να καταλαμβάνει την πρώτη θέση, ακολουθούμενο κατά σειρά από τα Random Forest και XGBoost τα οποία είχαν παραπλήσια απόδοση. Παρότι το LSTM παρουσίασε αισθητή βελτίωση μετά την αναθεωρημένη πειραματική διαδικασία, παρέμεινε χαμηλότερα από τα κορυφαία μοντέλα βασισμένα σε δέντρα αποφάσεων, ενώ η Γραμμική Παλινδρόμηση διατήρησε ανταγωνιστική απόδοση παρά την απλούστερη δομή της. Με βάση τα αποτελέσματα της μελέτης, η αυξημένη αρχιτεκτονική πολυπλοκότητα δεν συνεπάγεται κατ' ανάγκην υψηλότερη προγνωστική ακρίβεια. Ωστόσο, η ερμηνεία της βελτίωσης δεν μπορεί να αποδοθεί ξεκάθαρα στα χαρακτηριστικά υστέρησης ή την διασταυρούμενη επικύρωση, καθώς αυτά εισήχθησαν ταυτόχρονα στη δεύτερη πειραματική διαμόρφωση, χωρίς να αξιολογείται η επίδραση κάθε παρέμβασης ξεχωριστά. Σε δεύτερο στάδιο, οι συγγραφείς συνδύασαν τις προβλέψεις των πέντε αποδοτικότερων βασικών μοντέλων μέσω ενός πλαισίου μετα-μάθησης (stacking), το οποίο ενίσχυσε την προβλεπτική απόδοση σε σχέση με αυτή των μεμονωμένων μοντέλων, όπου το Random Forest ως μετα-εκτιμητής πέτυχε τη μεγαλύτερη βελτίωση της προγνωστικής ακρίβειας μεταξύ των εξεταζόμενων μετά-μοντέλων.

Παρά τη συχνή αναφορά υψηλής προγνωστικής απόδοσης των μοντέλων που βασίζονται σε δέντρα αποφάσεων, η βιβλιογραφία δεν είναι απολύτως ομόφωνη. Υπό διαφορετικές συνθήκες δεδομένων και εναλλακτικές αρχιτεκτονικές μοντέλων έχουν αναφερθεί και αποτελέσματα που ευνοούν τις προσεγγίσεις βαθιάς μάθησης.

Σε αντίθεση με τα ευρήματα της παρούσας μελέτης, ο Zheng (2026), μελετώντας την ωριαία πρόβλεψη ηλεκτρικού φορτίου σε περιφερειακό δίκτυο ηλεκτρικής ενέργειας, διαπίστωσε ότι το μοντέλο LSTM υπερείχε σημαντικά των μοντέλων Random Forest, Gradient Boosting, Extra Trees και SVR στην ωριαία βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου. Ο συγγραφέας απέδωσε την υψηλότερη προγνωστική επίδοση του LSTM στην ικανότητά του να μαθαίνει μακροχρόνιες χρονικές εξαρτήσεις και σύνθετα διαδοχικά πρότυπα της χρονοσειράς. Παράλληλα, η ανάλυση SHAP (Lundberg & Lee, 2017) ανέδειξε το ιστορικό ηλεκτρικό φορτίο ως τον σημαντικότερο παράγοντα πρόβλεψης, επιβεβαιώνοντας τη θεμελιώδη σημασία της προηγούμενης κατανάλωσης στην πρόβλεψη της μελλοντικής ζήτησης. Η διαφοροποίηση των αποτελεσμάτων σε σχέση με την παρούσα

έρευνα ενδέχεται να οφείλεται σε διαφορές στη δομή του συνόλου δεδομένων, στην αναπαράσταση των χρονικών πληροφοριών, στην επιλογή των χαρακτηριστικών και στη διαμόρφωση των μοντέλων, γεγονός που υποδηλώνει ότι η σχετική απόδοση των αλγορίθμων εξαρτάται σε σημαντικό βαθμό από το εκάστοτε πρόβλημα πρόβλεψης.

Οι Gu και Zhao (2026), μελετώντας την ωριαία πρόβλεψη ηλεκτρικού φορτίου σε μονάδα παραγωγής χάλυβα, συνέκριναν τα μοντέλα XGBoost, LSTM και Bidirectional Long Short-Term Memory (BiLSTM) χρησιμοποιώντας κοινό πειραματικό πρωτόκολλο, με χρονολογικό διαχωρισμό των δεδομένων και ιστορικό παράθυρο εισόδου 24 ωρών. Τα αποτελέσματα έδειξαν ότι τα μοντέλα βαθιάς μάθησης που βασίζονται σε επαναλαμβανόμενα νευρωνικά δίκτυα (LSTM και BiLSTM) υπερείχαν του XGBoost, με το BiLSTM να επιτυγχάνει τη συνολικά υψηλότερη προγνωστική ακρίβεια. Οι συγγραφείς απέδωσαν την ανώτερη επίδοση του BiLSTM στην ικανότητά του να συλλαμβάνει αποτελεσματικότερα τις χρονικές εξαρτήσεις μέσω της αμφίδρομης επεξεργασίας της ακολουθίας εισόδου. Τα ευρήματα αυτά υποδηλώνουν ότι η προγνωστική απόδοση των επαναλαμβανόμενων νευρωνικών δικτύων εξαρτάται σε μεγάλο βαθμό από την αρχιτεκτονική τους. Η σύγχρονη έρευνα έχει πλέον στραφεί στην ανάπτυξη περισσότερο εξειδικευμένων υβριδικών αρχιτεκτονικών που επιχειρούν να αντιμετωπίσουν τους περιορισμούς των συμβατικών μοντέλων LSTM.

Οι Song et al. (2026), μελετώντας τη βραχυπρόθεσμη πρόβλεψη φορτίου σε έξυπνο λιμενικό ενεργειακό σύστημα, πρότειναν ένα μοντέλο FeatureGating-BiLSTM ενισχυμένο με μηχανισμούς DualAttention, με στόχο την αποτελεσματικότερη αξιοποίηση των εισόδων και τη βελτίωση της πρόβλεψης σε συνθήκες υψηλής μεταβλητότητας. Οι συγγραφείς έδειξαν ότι η συνδυασμένη χρήση δυναμικής στάθμισης χαρακτηριστικών και μηχανισμών προσοχής οδήγησε σε καλύτερη προγνωστική επίδοση σε σχέση με απλούστερες αρχιτεκτονικές βαθιάς μάθησης, αναδεικνύοντας τη σύγχρονη τάση προς ολοένα πιο εξειδικευμένα υβριδικά μοντέλα για εφαρμογές STLF.

5.6.3. Ο ρόλος της ιστορικής πληροφορίας και της μηχανικής χαρακτηριστικών

Πέρα από τη συγκριτική αξιολόγηση των αλγορίθμων, ιδιαίτερο ενδιαφέρον παρουσιάζει η διερεύνηση των παραγόντων που συνέβαλαν στην προγνωστική τους απόδοση. Στην παρούσα μελέτη, οι μεταβλητές χρονικής υστέρησης (lag1, lag24 και lag168) αναδείχθηκαν ως οι σημαντικότεροι προγνωστικοί παράγοντες στα περισσότερα μοντέλα, ενώ οι μετεωρολογικές μεταβλητές λειτούργησαν κυρίως συμπληρωματικά. Το εύρημα αυτό αναδεικνύει τη σημασία της κατάλληλης μηχανικής χαρακτηριστικών και της αξιοποίησης της ιστορικής πληροφορίας, ζητήματα που έχουν απασχολήσει εκτενώς τη σχετική βιβλιογραφία.

Η σημασία της μηχανικής χαρακτηριστικών αναγνωρίζεται ευρέως ως καθοριστικός παράγοντας για την προγνωστική απόδοση των μοντέλων, καθώς επηρεάζει τον τρόπο με τον οποίο η διαθέσιμη πληροφορία μετατρέπεται σε χρήσιμα χαρακτηριστικά εισόδου. Οι Xing και Kaheh (2026) υποστήριξαν ότι η διαδικασία προεπεξεργασίας και η αναπαράσταση των δεδομένων αποτελούν καθοριστικούς παράγοντες της προγνωστικής απόδοσης και ότι η σύγκριση διαφορετικών αρχιτεκτονικών μπορεί να είναι παραπλανητική όταν εφαρμόζεται κοινή διαδικασία προεπεξεργασίας σε μοντέλα με διαφορετικές απαιτήσεις εισόδου. Στο πλαίσιο ενός αυστηρά ελεγχόμενου πειραματικού σχεδιασμού, όπου όλα τα μοντέλα αξιολογήθηκαν αρχικά με την ίδια πινακοποιημένη (tabular) αναπαράσταση των δεδομένων, τα δένδροειδή μοντέλα (LightGBM και Random Forest) παρουσίασαν χαμηλότερα σφάλματα πρόβλεψης από τα μοντέλα βαθιάς μάθησης. Ωστόσο, όταν για το LSTM εφαρμόστηκε διαδικασία προεπεξεργασίας συμβατή με τη σειριακή φύση της αρχιτεκτονικής του, η προγνωστική του απόδοση βελτιώθηκε σημαντικά, γεγονός

που οδήγησε τους συγγραφείς στο συμπέρασμα ότι η προεπεξεργασία αποτελεί παράγοντα πρώτης τάξης για την απόδοση των μοντέλων βαθιάς μάθησης και ότι η αξιολόγηση διαφορετικών αρχιτεκτονικών προϋποθέτει αναπαράσταση των δεδομένων συμβατή με τον τρόπο λειτουργίας κάθε μοντέλου. Οι συγγραφείς διαπίστωσαν επίσης ότι τα χαρακτηριστικά που βασίζονται στην ιστορική ζήτηση είχαν τη μεγαλύτερη συμβολή στην ακρίβεια των προβλέψεων, ενώ οι μετεωρολογικές μεταβλητές λειτουργούσαν κυρίως συμπληρωματικά, ενισχύοντας αλλά όχι αντικαθιστώντας το ισχυρό αυτοπαλίνδρομο σήμα της ζήτησης. Τα ευρήματα αυτά παρέχουν μία εύλογη ερμηνεία για τα αποτελέσματα της παρούσας έρευνας, στην οποία τα δένδροειδή μοντέλα υπερείχαν του LSTM, ενώ η ιστορική κατανάλωση ηλεκτρικής ενέργειας αναδείχθηκε ως ο σημαντικότερος προγνωστικός παράγοντας.

Στο πλαίσιο αυτό, ιδιαίτερη σημασία αποδίδεται στην αναπαράσταση της ιστορικής πληροφορίας, καθώς αρκετές μελέτες έχουν δείξει ότι η επιλογή και η δομή των χρονικών χαρακτηριστικών επηρεάζουν ουσιαστικά την προγνωστική ικανότητα των μοντέλων. Ο Dudek (2022) έδειξε ότι η ειδική προεπεξεργασία και αναπαράσταση της χρονοσειράς συνέβαλαν καθοριστικά στην υψηλή προγνωστική απόδοση του μοντέλου τους, ενώ η ανάλυση σημαντικότητας χαρακτηριστικών ανέδειξε την κατανάλωση της ίδιας ώρας της προηγούμενης ημέρας (lag24) ως τον σημαντικότερο προγνωστικό παράγοντα. Το εύρημα αυτό υποστηρίζει ότι η αποτελεσματική αναπαράσταση της ιστορικής πληροφορίας αποτελεί κρίσιμο στοιχείο της προγνωστικής διαδικασίας, ανεξάρτητα από την πολυπλοκότητα του χρησιμοποιούμενου μοντέλου. Η κυρίαρχη σημασία της ιστορικής κατανάλωσης επιβεβαιώνεται και από μελέτες που αξιολόγησαν άμεσα τη σχετική συμβολή των χαρακτηριστικών εισόδου. Οι Ibrahim et al. (2022) διαπίστωσαν ότι οι σημαντικότεροι προγνωστικοί παράγοντες ήταν το ιστορικό φορτίο της προηγούμενης ημέρας και της προηγούμενης εβδομάδας, ενώ η θερμοκρασία παρουσίασε σαφώς μικρότερη συμβολή. Αντίστοιχα, παρότι ο Zheng (2026) κατέληξε σε διαφορετικά συμπεράσματα ως προς το αποδοτικότερο μοντέλο πρόβλεψης, η ανάλυση SHAP ανέδειξε επίσης το ιστορικό ηλεκτρικό φορτίο ως τον σημαντικότερο παράγοντα πρόβλεψης, γεγονός που υποδηλώνει ότι η σημασία της προηγούμενης κατανάλωσης παραμένει σταθερή ακόμη και όταν διαφοροποιείται η αρχιτεκτονική του μοντέλου.

Πέρα όμως από την αναγνώριση της σημασίας της ιστορικής πληροφορίας, η πρόσφατη βιβλιογραφία έχει εξετάσει και τον βαθμό στον οποίο η συστηματική μηχανική χαρακτηριστικών μπορεί να βελτιώσει συνολικά την απόδοση διαφορετικών αλγορίθμων πρόβλεψης. Οι Salakapuri και Pavan Kumar (2025) παρατήρησαν ότι η ενσωμάτωση χαρακτηριστικών χρονικής υστέρησης σε συνδυασμό με την αναθεωρημένη πειραματική διαδικασία οδήγησε σε ουσιαστική βελτίωση της προγνωστικής απόδοσης όλων των εξεταζόμενων μοντέλων, γεγονός που υπογραμμίζει τη σημασία της κατάλληλης προεπεξεργασίας και της μηχανικής χαρακτηριστικών, ανεξάρτητα από τον χρησιμοποιούμενο αλγόριθμο. Ωστόσο, οι συγγραφείς επισημαίνουν ότι η επίδραση των χαρακτηριστικών χρονικής υστέρησης δεν μπορεί να απομονωθεί πλήρως, καθώς εφαρμόστηκαν ταυτόχρονα με τη διασταυρούμενη επικύρωση.

Συνολικά, τα ευρήματα της παρούσας μελέτης βρίσκονται σε συμφωνία με την εικόνα που προκύπτει από τη διεθνή βιβλιογραφία, αναδεικνύοντας τη θεμελιώδη σημασία της ιστορικής πληροφορίας και της κατάλληλης μηχανικής χαρακτηριστικών στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου. Το εύρημα αυτό ενισχύει την άποψη ότι η κατάλληλη επιλογή χαρακτηριστικών χρονικής υστέρησης μπορεί, σε ορισμένες περιπτώσεις, να είναι εξίσου σημαντική με την επιλογή του ίδιου του αλγορίθμου πρόβλεψης. Υπό το πρίσμα αυτό, η ανταγωνιστική απόδοση ακόμη και της Γραμμικής Παλινδρόμησης στην παρούσα μελέτη μπορεί να αποδοθεί, τουλάχιστον εν μέρει, στη

συστηματική επιλογή χαρακτηριστικών χρονικής υστέρησης που βασίστηκε στην ανάλυση αυτοσυσχέτισης (ACF), η οποία συνέβαλε στην αποτελεσματική αναπαράσταση της χρονικής εξάρτησης της χρονοσειράς.

5.6.4. Ερμηνεία των ευρημάτων και πρακτικές προεκτάσεις

Η επιτυχία ενός μοντέλου δεν εξαρτάται αποκλειστικά από την πολυπλοκότητα της αρχιτεκτονικής του, αλλά από την αλληλεπίδραση μεταξύ των χαρακτηριστικών του προβλήματος, της αναπαράστασης των δεδομένων και της εφαρμοζόμενης μηχανικής χαρακτηριστικών (Xing & Kaheh, 2026). Η υψηλή απόδοση των δένδροειδών μοντέλων μπορεί να αποδοθεί στην ικανότητά τους να αξιοποιούν αποτελεσματικά την πινακοποιημένη αναπαράσταση των δεδομένων και να μοντελοποιούν μη γραμμικές σχέσεις μεταξύ των μεταβλητών χωρίς εκτεταμένες παραδοχές για τη μορφή τους. Παράλληλα, η αξιοποίηση των χαρακτηριστικών χρονικής υστέρησης επέτρεψε την αποτελεσματική αναπαράσταση της χρονικής εξάρτησης του φορτίου, παρέχοντας στα μοντέλα το σημαντικότερο μέρος της προγνωστικής πληροφορίας.

Η ανταγωνιστική απόδοση της Γραμμικής Παλινδρόμησης αποτελεί επίσης αξιοσημείωτο εύρημα της παρούσας μελέτης. Παρότι πρόκειται για ένα απλό γραμμικό μοντέλο, η συστηματική επιλογή χαρακτηριστικών χρονικής υστέρησης μέσω της ανάλυσης αυτοσυσχέτισης (ACF) φαίνεται ότι επέτρεψε την αποτελεσματική αξιοποίηση της ισχυρής χρονικής εξάρτησης της χρονοσειράς. Το αποτέλεσμα αυτό υποδηλώνει ότι, σε προβλήματα βραχυπρόθεσμης πρόβλεψης όπου η πληροφορία του πρόσφατου ιστορικού φορτίου είναι ιδιαίτερα ισχυρή, η κατάλληλη μηχανική χαρακτηριστικών μπορεί να αντισταθμίσει, σε σημαντικό βαθμό, την απλότητα του αλγορίθμου (Xing & Kaheh, 2026; Salakapuri & Pavankumar, 2025).

Αντίθετα, καμία από τις διαμορφώσεις του μοντέλου LSTM που αξιολογήθηκαν στην παρούσα μελέτη δεν κατάφερε να υπερέχει των δένδροειδών μοντέλων. Το εύρημα αυτό ενδέχεται να σχετίζεται με τον περιορισμένο όγκο των διαθέσιμων δεδομένων, τον βραχύ χρονικό ορίζοντα πρόβλεψης και το γεγονός ότι η αρχιτεκτονική του LSTM κλήθηκε να εξάγει τις χρονικές εξαρτήσεις αποκλειστικά από τις ακολουθίες εισόδου, χωρίς την ενσωμάτωση ρητών χαρακτηριστικών χρονικής υστέρησης, όπως εφαρμόστηκε στα μοντέλα που βασίζονται σε πινακοποιημένα δεδομένα. Αν και πρόσφατες μελέτες έχουν δείξει ότι ο συνδυασμός αρχιτεκτονικών βαθιάς μάθησης με χαρακτηριστικά χρονικής υστέρησης μπορεί να οδηγήσει σε περαιτέρω βελτίωση της προγνωστικής απόδοσης (Salakapuri & Pavankumar, 2025), η συγκεκριμένη προσέγγιση δεν αποτέλεσε αντικείμενο της παρούσας έρευνας. Υπό τις συνθήκες αυτές, τα πλεονεκτήματα των βαθιών νευρωνικών δικτύων ενδέχεται να μην αξιοποιούνται πλήρως (Xing & Kaheh, 2026).

Οι παραπάνω διαπιστώσεις έχουν σημαντικές πρακτικές προεκτάσεις για εφαρμογές διαχείρισης ενέργειας σε λιμενικές εγκαταστάσεις και γενικότερα σε υποδομές με αντίστοιχα χαρακτηριστικά κατανάλωσης. Τα αποτελέσματα της παρούσας μελέτης υποδεικνύουν ότι τα δένδροειδή μοντέλα αποτελούν μία ισορροπημένη επιλογή, συνδυάζοντας υψηλή προγνωστική ακρίβεια, σχετικά χαμηλό υπολογιστικό κόστος και ικανοποιητικό βαθμό ερμηνευσιμότητας. Παράλληλα, η ανταγωνιστική επίδοση της Γραμμικής Παλινδρόμησης δείχνει ότι, σε προβλήματα όπου η χρονική εξάρτηση αποτυπώνεται αποτελεσματικά μέσω κατάλληλης μηχανικής χαρακτηριστικών, ακόμη και ένα απλό και ιδιαίτερα ερμηνεύσιμο μοντέλο μπορεί να αποτελέσει αξιόπιστη επιλογή. Η δυνατότητα ακριβούς πρόβλεψης του ηλεκτρικού φορτίου μπορεί να υποστηρίξει τον αποτελεσματικότερο ενεργειακό προγραμματισμό, τη βελτιστοποίηση της λειτουργίας των εγκαταστάσεων και την ορθολογικότερη αξιοποίηση των διαθέσιμων ενεργειακών πόρων.

6. ΚΕΦΑΛΑΙΟ 6 - ΣΥΜΠΕΡΑΣΜΑΤΑ

6.1. Σύνοψη της έρευνας

Η παρούσα διπλωματική εργασία διερεύνησε την εφαρμογή μεθόδων μηχανικής και βαθιάς μάθησης στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου του Νοτίου Λιμένα Πατρών. Η πρόβλεψη της ηλεκτρικής ζήτησης αποκτά αυξανόμενη σημασία για τις σύγχρονες λιμενικές εγκαταστάσεις, καθώς ο εξηλεκτρισμός του εξοπλισμού, η ανάπτυξη υποδομών ηλεκτροδότησης πλοίων από την ξηρά, η ενσωμάτωση ανανεώσιμων πηγών ενέργειας και η χρήση συστημάτων αποθήκευσης αυξάνουν τόσο το μέγεθος όσο και τη μεταβλητότητα των ηλεκτρικών φορτίων. Στο πλαίσιο αυτό, η αξιόπιστη βραχυπρόθεσμη πρόβλεψη μπορεί να αποτελέσει βασική είσοδο για τον ενεργειακό προγραμματισμό, τη διαχείριση της ζήτησης και τη λειτουργία μελλοντικών συστημάτων ενεργειακής διαχείρισης.

Ως περίπτωση μελέτης επιλέχθηκε ο Νότιος Λιμένας Πατρών, ο οποίος λειτουργεί σε συνεχή βάση και εξυπηρετεί διαφορετικές επιβατικές και εμπορευματικές δραστηριότητες. Η ανάλυση βασίστηκε σε πραγματικά ωριαία δεδομένα κατανάλωσης ηλεκτρικής ενέργειας που παραχωρήθηκαν από τον Οργανισμό Λιμένος Πατρών και καλύπτουν την περίοδο από την 1η Ιανουαρίου 2021 έως την 1η Νοεμβρίου 2025. Η διαθέσιμη χρονοσειρά περιλάμβανε 42.360 ωριαίες παρατηρήσεις, οι οποίες συνδυάστηκαν με μετεωρολογικά δεδομένα της περιοχής και ημερολογιακές μεταβλητές.

Το πρόβλημα διατυπώθηκε ως πρόβλεψη του ηλεκτρικού φορτίου μίας ώρας μπροστά. Για τον σκοπό αυτό αναπτύχθηκαν και συγκρίθηκαν τέσσερις αντιπροσωπευτικές προσεγγίσεις: η Γραμμική Παλινδρόμηση, το Random Forest, το XGBoost και το LSTM. Για τα κλασικά μοντέλα μηχανικής μάθησης, στα οποία χρησιμοποιήθηκαν δεδομένα πινακοποιημένης μορφής, κατασκευάστηκαν χαρακτηριστικά που περιλάμβαναν ιστορικές τιμές φορτίου σε χρονικές υστερήσεις μίας ώρας, μίας ημέρας και μίας εβδομάδας, μετεωρολογικές μεταβλητές, ημερολογιακά χαρακτηριστικά και μεταβλητή χρονικής τάσης. Η ενσωμάτωση των χρονικών υστερήσεων επέτρεψε στα μοντέλα να αξιοποιήσουν τη βραχυχρόνια, ημερήσια και εβδομαδιαία εξάρτηση της χρονοσειράς.

Για το μοντέλο LSTM ακολουθήθηκε διαφορετική αναπαράσταση των δεδομένων όπου η χρονοσειρά μετασχηματίστηκε σε ακολουθίες εισόδου μέσω κυλιόμενου χρονικού παραθύρου. Εξετάστηκαν ιστορικά παράθυρα 24 και 168 ωρών, καθώς και μονομεταβλητές και πολυμεταβλητές διαμορφώσεις. Από τη συγκριτική αξιολόγηση προέκυψε ως καταλληλότερη η μονομεταβλητή διαμόρφωση με ιστορικό παράθυρο 24 ωρών. Η αρχιτεκτονική και οι υπερπαραμέτροι του δικτύου βελτιστοποιήθηκαν μέσω χρονικά ορθής διαδικασίας επικύρωσης.

Σε όλα τα στάδια διατηρήθηκε η χρονολογική σειρά των παρατηρήσεων, ώστε να αποφεύγεται η διαρροή πληροφορίας από μελλοντικές προς παρελθοντικές χρονικές περιόδους. Τα δεδομένα διαχωρίστηκαν χρονολογικά σε σύνολα εκπαίδευσης και ελέγχου, ενώ οι διαδικασίες επιλογής διαμόρφωσης και υπερπαραμέτρων πραγματοποιήθηκαν με τεχνικές επικύρωσης κατάλληλες για χρονοσειρές. Η κοινή αυτή πειραματική λογική επέτρεψε τη συγκριτική αξιολόγηση των εξεταζόμενων αλγορίθμων υπό ενιαίο πρωτόκολλο αξιολόγησης.

6.2. Βασικά συμπεράσματα

Τα αποτελέσματα της μελέτης ανέδειξαν ότι τα μοντέλα μηχανικής μάθησης που βασίζονται σε δένδρα αποφάσεων παρουσίασαν την υψηλότερη συνολική προγνωστική απόδοση. Το Random Forest και το XGBoost κατέγραψαν τα χαμηλότερα σφάλματα μεταξύ των εξεταζόμενων προσεγγίσεων, επιβεβαιώνοντας την καταλληλότητα των δενδροειδών μοντέλων για σύνολα δεδομένων πινακοποιημένης μορφής που συνδυάζουν ιστορικές, μετεωρολογικές και ημερολογιακές μεταβλητές.

Το δεύτερο βασικό συμπέρασμα αφορά τον καθοριστικό ρόλο της ιστορικής πληροφορίας. Οι μεταβλητές χρονικής υστέρησης αποτέλεσαν τους σημαντικότερους προγνωστικούς παράγοντες, με την ημερήσια περιοδικότητα της κατανάλωσης να εμφανίζει ιδιαίτερα ισχυρή συμβολή. Το εύρημα αυτό είναι συνεπές τόσο με τη διερευνητική ανάλυση και τη συνάρτηση αυτοσυσχέτισης όσο και με τα αποτελέσματα της ανάλυσης σημαντικότητας χαρακτηριστικών. Κατά συνέπεια, η κατάλληλη αναπαράσταση της χρονικής δομής της χρονοσειράς αποτέλεσε σημαντικότερο παράγοντα από την απλή αύξηση της πολυπλοκότητας του αλγορίθμου.

Οι μετεωρολογικές και ημερολογιακές μεταβλητές συνέβαλαν συμπληρωματικά στην πρόβλεψη, χωρίς να υπερβαίνουν σε σημασία την πρόσφατη ιστορική κατανάλωση. Η παρατήρηση αυτή δεν σημαίνει ότι οι συγκεκριμένες μεταβλητές είναι περιττές, αλλά ότι, για τον χρονικό ορίζοντα μίας ώρας και για το συγκεκριμένο προφίλ φορτίου, μεγάλο μέρος της αναγκαίας πληροφορίας περιέχεται ήδη στις προηγούμενες τιμές της χρονοσειράς. Η σχετική συνεισφορά των εξωγενών μεταβλητών ενδέχεται να διαφοροποιείται σε μεγαλύτερους χρονικούς ορίζοντες, σε άλλους τύπους λιμένων ή σε περιόδους έντονων μεταβολών των περιβαλλοντικών και λειτουργικών συνθηκών.

Σημαντική ήταν και η ανταγωνιστική απόδοση της Γραμμικής Παλινδρόμησης που χρησιμοποιήθηκε ως μοντέλο αναφοράς. Παρά την απλότητα και τους περιορισμούς της ως προς την αποτύπωση μη γραμμικών σχέσεων, το μοντέλο αξιοποίησε αποτελεσματικά τις ρητά κατασκευασμένες μεταβλητές χρονικής υστέρησης και παρείχε ιδιαίτερα ικανοποιητική προγνωστική απόδοση. Το αποτέλεσμα αυτό καταδεικνύει ότι ένα απλούστερο και περισσότερο ερμηνεύσιμο μοντέλο μπορεί να παραμένει ανταγωνιστικό όταν η διαδικασία μηχανικής χαρακτηριστικών αποτυπώνει κατάλληλα τη δομή του προβλήματος.

Παρότι τα LSTM έχουν σχεδιαστεί για την εκμάθηση χρονικών εξαρτήσεων και μπορούν να αξιοποιούν απευθείας ακολουθίες παρατηρήσεων, η μεγαλύτερη αρχιτεκτονική τους πολυπλοκότητα δεν συνοδεύτηκε από αντίστοιχη βελτίωση της προγνωστικής ακρίβειας. Η επιλογή της μονομεταβλητής διαμόρφωσης με ιστορικό παράθυρο 24 ωρών ανέδειξε ότι, για το συγκεκριμένο σύνολο δεδομένων και τον χρονικό ορίζοντα μίας ώρας, η ημερήσια περιοδικότητα περιείχε την πλέον χρήσιμη πληροφορία για την πρόβλεψη. Παρά τη συστηματική διερεύνηση διαφορετικών διαμορφώσεων και υπερπαραμέτρων, το LSTM παρέμεινε χαμηλότερα σε απόδοση από τα κορυφαία δενδροειδή μοντέλα.

Συνολικά, τα ευρήματα δείχνουν ότι δεν υπάρχει ένας αλγόριθμος που να μπορεί να θεωρηθεί εκ των προτέρων καταλληλότερος για κάθε εφαρμογή βραχυπρόθεσμης πρόβλεψης φορτίου. Η επιλογή του μοντέλου πρέπει να βασίζεται στα χαρακτηριστικά του συνόλου δεδομένων, στον χρονικό ορίζοντα, στη μορφή αναπαράστασης της χρονικής πληροφορίας και στις απαιτήσεις της εφαρμογής. Για το συγκεκριμένο πρόβλημα, η αποτελεσματική μηχανική χαρακτηριστικών σε συνδυασμό με δενδροειδή μοντέλα παρείχε καλύτερα αποτελέσματα από μια περισσότερο σύνθετη ακολουθιακή αρχιτεκτονική. Επομένως, η επιτυχία ενός συστήματος πρόβλεψης δεν εξαρτάται αποκλειστικά από την

επιλογή του αλγορίθμου, αλλά από τον συνδυασμό της ποιότητας των δεδομένων, της κατάλληλης αναπαράστασής τους και του ορθού σχεδιασμού της διαδικασίας εκπαίδευσης και αξιολόγησης.

6.3. Παραδοχές και περιορισμοί της μελέτης

Η ερμηνεία των αποτελεσμάτων βασίζεται σε ορισμένες μεθοδολογικές παραδοχές. Αρχικά, θεωρήθηκε ότι οι ιστορικές μετρήσεις αποτυπώνουν με επαρκή ακρίβεια την πραγματική κατανάλωση ηλεκτρικής ενέργειας του Νοτίου Λιμένα Πατρών κατά την εξεταζόμενη περίοδο. Θεωρήθηκε επίσης ότι, μετά την προεπεξεργασία, τον έλεγχο ποιότητας και τον χρονικό συγχρονισμό των διαφορετικών πηγών, τα δεδομένα ήταν κατάλληλα για την ανάπτυξη και αξιολόγηση των μοντέλων. Επιπλέον, η μεθοδολογία προϋποθέτει ότι οι σχέσεις μεταξύ της ιστορικής κατανάλωσης, των μετεωρολογικών και ημερολογιακών μεταβλητών και του μελλοντικού φορτίου παρέμειναν επαρκώς σταθερές κατά την περίοδο μελέτης, ώστε τα μοντέλα να μπορούν να γενικεύσουν σε μεταγενέστερες μη παρατηρημένες περιόδους.

Η μελέτη αφορά μία συγκεκριμένη λιμενική εγκατάσταση και ένα συγκεκριμένο χρονικό διάστημα. Τα πρότυπα κατανάλωσης του Νοτίου Λιμένα Πατρών διαμορφώνονται από τα ιδιαίτερα λειτουργικά, γεωγραφικά και κλιματικά χαρακτηριστικά του. Ως εκ τούτου, η σχετική κατάταξη των αλγορίθμων δεν θα πρέπει να γενικεύεται άμεσα σε άλλους λιμένες χωρίς προηγούμενη αξιολόγηση σε διαφορετικά προφίλ φορτίου και επιχειρησιακά περιβάλλοντα.

Ένας επιπλέον περιορισμός είναι ότι η εργασία επικεντρώθηκε αποκλειστικά στην πρόβλεψη μίας ώρας μπροστά. Ο συγκεκριμένος ορίζοντας είναι κατάλληλος για βραχυπρόθεσμες λειτουργικές εφαρμογές, ωστόσο τα συμπεράσματα δεν μπορούν να επεκταθούν χωρίς πρόσθετη διερεύνηση σε πολυβηματικές ή προ-ημερήσιες προβλέψεις, στις οποίες η αβεβαιότητα αυξάνεται και η συνεισφορά των εξωγενών μεταβλητών ενδέχεται να διαφοροποιείται.

Η παρούσα μελέτη υιοθέτησε πλαίσιο εκ των υστέρων (ex post) αξιολόγησης, χρησιμοποιώντας παρατηρηθείσες μετεωρολογικές μεταβλητές ως επεξηγηματικές εισόδους. Η επιλογή αυτή οφείλεται στη μη διαθεσιμότητα ομοιογενούς συνόλου αρχειοθετημένων μετεωρολογικών προγνώσεων για ολόκληρη την περίοδο μελέτης και με σταθερό ορίζοντα πρόγνωσης μίας ώρας για κάθε χρονική στιγμή. Για τη διατήρηση κοινής και χρονικά συνεπούς πηγής δεδομένων χρησιμοποιήθηκαν οι ιστορικές καιρικές συνθήκες από το Historical Weather API του Open-Meteo. Με τον τρόπο αυτό, η αξιολόγηση εστίασε στην προγνωστική ικανότητα των μοντέλων φορτίου, χωρίς να ενσωματώνει το πρόσθετο σφάλμα μιας μετεωρολογικής πρόγνωσης. Ωστόσο, η αναφερόμενη ακρίβεια δεν αντιστοιχεί πλήρως στην απόδοση που θα αναμενόταν σε πραγματικό εκ των προτέρων επιχειρησιακό περιβάλλον, όπου θα ήταν διαθέσιμες ex ante μετεωρολογικές προβλέψεις και όχι οι ιστορικές καιρικές συνθήκες. Σε μια επιχειρησιακή εφαρμογή, οι ιστορικές τιμές θα πρέπει να αντικατασταθούν από τις μετεωρολογικές προγνώσεις που είναι διαθέσιμες κατά τον χρόνο έκδοσης της πρόβλεψης και η συνολική απόδοση να αξιολογηθεί εκ νέου. Επιπλέον, τα δεδομένα αντλήθηκαν από την πλατφόρμα Open-Meteo και όχι από μετεωρολογικό σταθμό εγκατεστημένο εντός του λιμένα, με αποτέλεσμα να μην είναι δυνατό να αποκλειστούν τοπικές μικροκλιματικές διαφοροποιήσεις.

Τα διαθέσιμα χαρακτηριστικά δεν περιλάμβαναν αναλυτικές επιχειρησιακές μεταβλητές, όπως αρίξεις και αναχωρήσεις πλοίων, πληρότητα θέσεων ελλιμενισμού, προγράμματα γερανογεφυρών, διακίνηση φορτίων ή αριθμό ψυκτικών εμπορευματοκιβωτίων. Δεν ήταν επίσης διαθέσιμα δεδομένα λειτουργίας ή κατανάλωσης που να σχετίζονται με την

ηλεκτροδότηση πλοίων από την ξηρά (OPS) και, κατά συνέπεια, τέτοιες μεταβλητές δεν ενσωματώθηκαν στα μοντέλα. Η έλλειψη αυτών των δεδομένων περιορίζει την ικανότητα των μοντέλων να ερμηνεύουν αιφνίδιες μεταβολές της ζήτησης που συνδέονται με συγκεκριμένα λειτουργικά γεγονότα.

Η συγκριτική ανάλυση περιορίστηκε σε τέσσερις αντιπροσωπευτικές προσεγγίσεις. Επομένως, η εργασία δεν υποστηρίζει ότι τα εξεταζόμενα μοντέλα αποτελούν τις καθολικά βέλτιστες επιλογές. Παρότι η Γραμμική Παλινδρόμηση χρησιμοποιήθηκε ως μοντέλο αναφοράς, δεν συμπεριλήφθηκε απλό ή εποχικό μοντέλο αφελούς πρόβλεψης ως πρόσθετη γραμμή βάσης. Η συμπερίληψή του θα επέτρεπε την άμεση σύγκριση με την εμμόνη και την επανάληψη των ημερήσιων ή εβδομαδιαίων προτύπων. Παράλληλα, η βελτιστοποίηση των υπερπαραμέτρων πραγματοποιήθηκε εντός πρακτικά διαχειρίσιμων χώρων αναζήτησης. Εκτενέστερες διαδικασίες βελτιστοποίησης θα μπορούσαν να οδηγήσουν σε διαφοροποιήσεις της απόδοσης, χωρίς όμως να είναι βέβαιο ότι θα μεταβάλλουν τα κύρια συγκριτικά συμπεράσματα. Παρότι εφαρμόστηκε κοινός αρχικός χρονολογικός διαχωρισμός 80/20, ο διαφορετικός τρόπος κατασκευής των χρονικών υστερήσεων και των ακολουθιών οδήγησε σε διαφορά 168 ωριαίων παρατηρήσεων μεταξύ των τελικών συνόλων ελέγχου. Οι διαμορφώσεις LSTM βελτιστοποιήθηκαν επίσης χωριστά· συνεπώς, η σύγκριση αφορά τις αντίστοιχες βελτιστοποιημένες τελικές διαμορφώσεις.

Επιπλέον, όσον αφορά τα μοντέλα βαθιάς μάθησης, η παρούσα εργασία επικεντρώθηκε αποκλειστικά στην αρχιτεκτονική LSTM. Παρότι αξιολογήθηκαν διαφορετικές διαμορφώσεις του συγκεκριμένου δικτύου, δεν εξετάστηκαν νεότερες αρχιτεκτονικές, όπως GRU, Temporal Convolutional Networks (TCN) ή Transformer-based προσεγγίσεις, ούτε υβριδικά σχήματα που συνδυάζουν διαφορετικές οικογένειες μοντέλων. Συνεπώς, τα συμπεράσματα που αφορούν τη συγκριτική επίδοση των μοντέλων βαθιάς μάθησης περιορίζονται στην εξεταζόμενη αρχιτεκτονική LSTM.

Τέλος, η εργασία αξιολόγησε την ακρίβεια πρόβλεψης και δεν ενσωμάτωσε τα μοντέλα σε πραγματικό σύστημα ενεργειακής διαχείρισης. Δεν εξετάστηκαν η βελτιστοποίηση της λειτουργίας συστημάτων αποθήκευσης, η απόκριση ζήτησης, η μείωση αιχμών, η αγορά ηλεκτρικής ενέργειας ή η διαστασιολόγηση υποδομών OPS. Κατά συνέπεια, τα λειτουργικά και οικονομικά οφέλη που θα μπορούσαν να προκύψουν από τη βελτίωση της ακρίβειας δεν ποσοτικοποιήθηκαν.

6.4. Προτάσεις για μελλοντική έρευνα

Μία από τις σημαντικότερες κατευθύνσεις μελλοντικής έρευνας είναι η ενσωμάτωση λειτουργικών δεδομένων του λιμένα. Μεταβλητές όπως οι προγραμματισμένες αφίξεις πλοίων, η διάρκεια ελλιμενισμού, η χρήση γερανογεφυρών, η διακίνηση φορτίων, η πληρότητα των υποδομών και η μελλοντική χρήση OPS μπορούν να παρέχουν πληροφορία που δεν περιέχεται στο ιστορικό φορτίο ή στα μετεωρολογικά δεδομένα. Η συγκριτική αξιολόγηση μοντέλων με και χωρίς τις μεταβλητές αυτές θα επέτρεπε την ποσοτικοποίηση της προστιθέμενης προγνωστικής τους αξίας.

Παράλληλα, η μεθοδολογία θα μπορούσε να επεκταθεί σε μεγαλύτερους χρονικούς ορίζοντες, όπως πρόβλεψη έξι, δώδεκα ή είκοσι τεσσάρων ωρών, καθώς και σε πλήρη προ-ημερήσια πρόβλεψη. Η ανάπτυξη πολυβηματικών μοντέλων θα επέτρεπε τη διερεύνηση της συσσώρευσης του σφάλματος και της μεταβολής της σχετικής απόδοσης των αλγορίθμων όσο αυξάνεται ο χρονικός ορίζοντας.

Ενδιαφέρον παρουσιάζει ως επέκταση και η μετάβαση από τη σημειακή στην πιθανοτική πρόβλεψη. Η εκτίμηση διαστημάτων πρόβλεψης ή διαφορετικών ποσοστημορίων θα επέτρεπε την ποσοτικοποίηση της αβεβαιότητας, η οποία είναι σημαντική σε περιόδους

απότομων μεταβολών της λιμενικής δραστηριότητας. Η πληροφορία αυτή θα μπορούσε να αξιοποιηθεί σε αποφάσεις σχετικά με τη λειτουργία συστημάτων αποθήκευσης, την προμήθεια ενέργειας και την αντιμετώπιση πιθανών αιχμών ζήτησης.

Μελλοντικές μελέτες θα μπορούσαν επίσης να εξετάσουν πρόσθετες αρχιτεκτονικές βαθιάς μάθησης, μοντέλα βασισμένα σε μηχανισμούς προσοχής και Transformers, καθώς και υβριδικά ή συνδυαστικά σχήματα. Η αξιολόγηση των προσεγγίσεων αυτών θα πρέπει να πραγματοποιείται υπό το ίδιο χρονικά ορθό πρωτόκολλο και να λαμβάνει υπόψη όχι μόνο την ακρίβεια, αλλά και τις απαιτήσεις σε δεδομένα, υπολογιστικούς πόρους, βελτιστοποίηση και ερμηνευσιμότητα.

Η εξωτερική εγκυρότητα της μεθοδολογίας θα μπορούσε να διερευνηθεί μέσω εφαρμογής σε περισσότερους λιμένες με διαφορετικά χαρακτηριστικά. Η σύγκριση επιβατικών, εμπορευματικών και μικτών λιμένων θα επέτρεπε να διαπιστωθεί ποια συμπεράσματα είναι γενικεύσιμα και ποια εξαρτώνται από τη σύνθεση των επιμέρους φορτίων και τη λειτουργική δομή κάθε εγκατάστασης.

Τέλος, η μελλοντική έρευνα θα μπορούσε να συνδέσει άμεσα την πρόβλεψη με τη λήψη ενεργειακών αποφάσεων. Η ενσωμάτωση των μοντέλων σε Σύστημα Διαχείρισης Ενέργειας θα επέτρεπε την αξιολόγηση εφαρμογών όπως η φόρτιση και εκφόρτιση συστημάτων αποθήκευσης, η χρονική μετατόπιση ευέλικτων φορτίων, η μείωση αιχμών και ο συντονισμός ΑΠΕ και OPS. Στο πλαίσιο αυτό θα μπορούσε να πραγματοποιηθεί και οικονομική αξιολόγηση, ώστε να διερευνηθεί σε ποιο βαθμό η βελτίωση της προγνωστικής ακρίβειας μεταφράζεται σε μείωση του λειτουργικού κόστους ή σε βελτίωση της αξιοπιστίας του ενεργειακού συστήματος. Παράλληλα, η εφαρμογή διαδικασιών περιοδικής επανεκπαίδευσης και παρακολούθησης της μεταβολής των προτύπων κατανάλωσης θα ήταν απαραίτητη για τη διατήρηση της απόδοσης των μοντέλων σε ένα λιμενικό περιβάλλον που εξελίσσεται διαρκώς.

Συμπερασματικά, η παρούσα εργασία ανέπτυξε και αξιολόγησε ένα συνεκτικό πλαίσιο βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου για τον Νότιο Λιμένα Πατρών, βασισμένο σε πραγματικά δεδομένα και σε χρονικά ορθή πειραματική διαδικασία. Τα αποτελέσματα κατέδειξαν ότι τα δένδροειδή μοντέλα, σε συνδυασμό με κατάλληλα χαρακτηριστικά χρονικής υστέρησης, συνιστούν αποτελεσματική επιλογή για το συγκεκριμένο πρόβλημα. Παράλληλα, η ανταγωνιστική απόδοση της Γραμμικής Παλινδρόμησης και η χαμηλότερη επίδοση του LSTM επιβεβαίωσαν ότι η αυξημένη πολυπλοκότητα δεν συνεπάγεται κατ' ανάγκη υψηλότερη προγνωστική ακρίβεια. Η εργασία παρέχει, επομένως, μια τεκμηριωμένη βάση για την περαιτέρω ανάπτυξη και μελλοντική επιχειρησιακή αξιοποίηση συστημάτων πρόβλεψης ηλεκτρικής ζήτησης σε λιμενικές εγκαταστάσεις.

Βιβλιογραφία

Abu Bakar, N. N., Bazmohammadi, N., Vasquez, J. C., & Guerrero, J. M. (2023).

Electrification of onshore power systems in maritime transportation towards decarbonization of ports: A review of the cold ironing technology. *Renewable and Sustainable Energy Reviews*, 178, 113243.

<https://doi.org/10.1016/j.rser.2023.113243>

Abumohsen, M., Owda, A. Y., & Owda, M. (2023). *Electrical load forecasting based on random forest, XGBoost, and linear regression algorithms*. 2023 International Conference on Information Technology (ICIT), 25–31.

<https://doi.org/10.1109/ICIT58056.2023.10225968>

Acciaro, M., Ghiara, H., & Cusano, M. I. (2014). Energy management in seaports: A new role for port authorities. *Energy Policy*, 71, 4–12.

<https://doi.org/10.1016/j.enpol.2014.04.013>

Ahmad, T., Zhang, H., & Yan, B. (2020). A review on renewable energy and electricity requirement forecasting models for smart grid and buildings. *Sustainable Cities and Society*, 55, 102052. <https://doi.org/10.1016/j.scs.2020.102052>

Akhtar, S., Shahzad, S., Zaheer, A., Ullah, H. S., Kilic, H., Gono, R., Jasiński, M., & Leonowicz, Z. (2023). Short-term load forecasting models: A review of challenges, progress, and the road ahead. *Energies*, 16(10), 4060.

<https://doi.org/10.3390/en16104060>

Alasali, F., Haben, S., Becerra, V., & Holderbaum, W. (2018). Day-ahead industrial load forecasting for electric RTG cranes. *Journal of Modern Power Systems and Clean Energy*, 6(2), 223–234. <https://doi.org/10.1007/s40565-018-0394-4>

- Alasali, F., Haben, S., & Holderbaum, W. (2019). Stochastic optimal energy management system for RTG cranes network using genetic algorithm and ensemble forecasts. *Journal of Energy Storage*, 24, 100759. <https://doi.org/10.1016/j.est.2019.100759>
- Alikhani, P., Tjernberg, L. B., Astner, L., & Donnerstal, P. (2021). Forecasting the Electrical Demand at the Port of Gävle Container Terminal. *2021 IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe)*, 1–6. <https://doi.org/10.1109/ISGTEurope52324.2021.9640170>
- Alpaydin, E. (2020). *Introduction to machine learning (4th ed.)*. MIT Press.
- Azeem, A., Ismail, I., Jameel, S. M., & Harindran, V. R. (2021). Electrical load forecasting models for different generation modalities: A review. *IEEE Access*, 9, 142239–142263. <https://doi.org/10.1109/ACCESS.2021.3120731>
- Bailey, D., & Solomon, G. (2004). *Pollution prevention at ports: Clearing the air*. *Environmental Impact Assessment Review*, 24(7–8), 749–774. <https://doi.org/10.1016/j.eiar.2004.06.005>
- Bakar, N. N. A., Guerrero, J. M., Vasquez, J. C., Bazmohammadi, N., Yu, Y., Abusorrah, A., & Al-Turki, Y. A. (2021). A review of the conceptualization and operational management of seaport microgrids on the shore and seaside. *Energies*, 14(23), 7941. <https://doi.org/10.3390/en14237941>
- Ballini, F., & Bozzo, R. (2015). Air pollution from ships in ports: The socio-economic benefit of cold-ironing technology. *Research in Transportation Business & Management*, 17, 92–98. <https://doi.org/10.1016/j.rtbm.2015.10.007>
- Bandara, K., Hyndman, R. J., & Bergmeir, C. (2025). MSTL: A seasonal-trend decomposition algorithm for time series with multiple seasonal patterns. *International Journal of Operational Research*, 52(1), 79–98. <https://doi.org/10.1504/IJOR.2025.143957>

- Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157–166. <https://doi.org/10.1109/72.279181>
- Bergmeir, C., & Benítez, J. M. (2012). On the use of cross-validation for time series predictor evaluation. *Information Sciences*, 191, 192–213. <https://doi.org/10.1016/j.ins.2011.12.028>
- Bishop, C. M. (2016). *Pattern recognition and machine learning*. Springer.
- Bou Nassif, A., Soudan, B., Azzeh, M., Attili, I., & Almulla, O. (2021). Artificial Intelligence and Statistical Techniques in Short-Term Load Forecasting: A Review. *International Review on Modelling and Simulations (IREMOS)*, 14(6), 408. <https://doi.org/10.15866/iremos.v14i6.21328>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/a:1010933404324>
- Brockwell, P. J., & Davis, R. A. (2016). *Introduction to time series and forecasting*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-29854-2>
- Candela Esclapez, A., López García, M., Valero Verdú, S., & Senabre Blanes, C. (2022). Automatic Selection of Temperature Variables for Short-Term Load Forecasting. *Sustainability*, 14(20), 13339. <https://doi.org/10.3390/su142013339>
- Cao, J., Chen, Y., Cao, X., Wang, Q., Wang, B., Du, J., & Wen, Z. (2023). SP2LSTM: A patch learning-based electrical load forecasting for container terminal. *Neural Computing and Applications*, 35(30), 22651–22669. <https://doi.org/10.1007/s00521-023-08878-2>
- Carrillo-Galvez, A., Carmo, F. do, Soares, T., Mourão, Z., Ponomarev, I., Araújo, J., & Bandeira, E. (2025). Electricity demand forecasting in green ports: Modelling and

- future research directions. *Transport Policy*, 171, 1012–1024.
<https://doi.org/10.1016/j.tranpol.2025.07.013>
- Chandrasekaran, R., & Paramasivan, S. K. (2025). Advances in deep learning techniques for short-term energy load forecasting applications: A review. *Archives of Computational Methods in Engineering*, 32(2), 663–692.
<https://doi.org/10.1007/s11831-024-10155-x>
- Chen, T., & Guestrin, C. (2016). *XGBoost: A scalable tree boosting system*. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chen, G., Ma, X., & Wei, L. (2024). Multifeature-Based Variational Mode Decomposition–Temporal Convolutional Network–Long Short-Term Memory for Short-Term Forecasting of the Load of Port Power Systems. *Sustainability*, 16(13), 5321. <https://doi.org/10.3390/su16135321>
- Cholidis, D., Sifakis, N., Chachalis, A., Savvakis, N., & Arampatzis, G. (2025). Energy transition framework for nearly zero-energy ports: HRES planning, storage integration, and implementation roadmap. *Sustainability*, 17(13), 5971. <https://doi.org/10.3390/su17135971>
- Chollet, F. (2018). *Deep learning with Python*. Manning Publications Co.
- Cleveland, R. B., Cleveland, W. S., McRae, J. E., Terpenning, I., & others. (1990). STL: A seasonal-trend decomposition procedure based on loess. *J. off. Stat*, 6(1), 3–73.
- Cordeiro-Costas, M., Villanueva, D., Eguía-Oller, P., Martínez-Comesaña, M., & Ramos, S. (2023). Load Forecasting with Machine Learning and Deep Learning Methods. *Applied Sciences*, 13(13), 7933. <https://doi.org/10.3390/app13137933>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/bf00994018>

- Do Carmo, F., Carrillo-Galvez, A., Soares, T., Dias, B. H., & Silva, B. (2026). Day-ahead electricity demand forecasting in an electrified seaport using crane scheduling. *Smart Grids and Sustainable Energy*, 11(2). <https://doi.org/10.1007/s40866-026-00350-z>
- Dong, Q., Huang, R., Cui, C., Towey, D., Zhou, L., Tian, J., & Wang, J. (2025). Short-term electricity-load forecasting by deep learning: A comprehensive survey. *Engineering Applications of Artificial Intelligence*, 154, 110980. <https://doi.org/10.1016/j.engappai.2025.110980>
- Dudek, G. (2022). A comprehensive study of random forest for short-term load forecasting. *Energies*, 15(20), 7547. <https://doi.org/10.3390/en15207547>
- EcoPorts. (n.d.). *Port environmental review system (PERS)*. European Sea Ports Organisation. <https://www.ecoports.com/pers>
- Elkington, J. (1997). *Cannibals with forks: The triple bottom line of 21st century business*. Capstone Publishing.
- European Parliament & Council of the European Union. (2023a). *Regulation (EU) 2023/1804 of the European Parliament and of the Council of 13 September 2023 on the Deployment of Alternative Fuels Infrastructure, and Repealing Directive 2014/94/EU*. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32023R1804>
- European Parliament & Council of the European Union. (2023b). *Regulation (EU) 2023/1805 of the European Parliament and of the Council of 13 September 2023 on the Use of Renewable and Low-Carbon Fuels in Maritime Transport, and Amending Directive 2009/16/EC*. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32023R1805>

- European Sea Ports Organisation. (2025). *ESPO environmental report 2025*. European Sea Ports Organisation. <https://www.espo.be/publications/espo-environmental-report-2025>
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5). <https://doi.org/10.1214/aos/1013203451>
- Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., & Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Computing Surveys*, 46(4), 1–37. <https://doi.org/10.1145/2523813>
- Gennitsaris, S. G., & Kanellos, F. D. (2019). Emission-aware and cost-effective distributed demand response system for extensively electrified large ports. *IEEE Transactions on Power Systems*, 34(6), 4341–4351. <https://doi.org/10.1109/tpwrs.2019.2919949>
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems (2nd ed.)*. O'Reilly.
- Gneiting, T., & Raftery, A. E. (2007). Strictly Proper Scoring Rules, Prediction, and Estimation. *Journal of the American Statistical Association*, 102(477), 359–378. <https://doi.org/10.1198/016214506000001437>
- Gneiting, T., & Katzfuss, M. (2014). Probabilistic forecasting. *Annual Review of Statistics and Its Application*, 1(1), 125–151. <https://doi.org/10.1146/annurev-statistics-062713-085831>
- Gökçe, M. M., & Duman, E. (2022). *Performance comparison of simple regression, random forest, and XGBoost algorithms for forecasting electricity demand*. 2022 3rd International Informatics and Software Engineering Conference (IISEC), 1–6. <https://doi.org/10.1109/IISEC56263.2022.9998213>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

- Gopalakrishnan, P., Alikhani, P., Shafique, H., Tjernberg, L. B., Hallinder, J., Engström, A., & He, Y. (2022). *Peak demand shaving based on solar and load forecasting at Port of Gävle*. In 2022 17th International Conference on Probabilistic Methods Applied to Power Systems (PMAPS). IEEE.
<https://doi.org/10.1109/PMAPS53380.2022.9810648>
- Gu, F., & Zhao, Y. (2026). Comparative evaluation of several models for forecasting hourly electricity use in a steel plant. *Scientific Reports*, 16(1), 13123.
<https://doi.org/10.1038/s41598-026-43868-z>
- Guo, W., Che, L., Shahidepour, M., & Wan, X. (2021). Machine-Learning based methods in short-term load forecasting. *The Electricity Journal*, 34(1), 106884.
<https://doi.org/10.1016/j.tej.2020.106884>
- Hall, P. V. (2007). Governance, development, and change in port regions. *International Journal of Urban and Regional Research*, 31(2), 431–447.
<https://doi.org/10.1111/j.1468-2427.2007.00724.x>
- Harris, C. R., Millman, K. J., Van Der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N. J., Kern, R., Picus, M., Hoyer, S., Van Kerkwijk, M. H., Brett, M., Haldane, A., Del Río, J. F., Wiebe, M., Peterson, P., ... Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585(7825), 357–362. <https://doi.org/10.1038/s41586-020-2649-2>
- Hasan, M., Mifta, Z., Papiya, S. J., Roy, P., Dey, P., Salsabil, N. A., Chowdhury, N.-U.-R., & Farrok, O. (2025). A state-of-the-art comparative review of load forecasting methods: Characteristics, perspectives, and applications. *Energy Conversion and Management: X*, 26, 100922. <https://doi.org/10.1016/j.ecmx.2025.100922>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning*. Springer New York. <https://doi.org/10.1007/978-0-387-84858-7>

- Haykin, S. (2011). *Neural networks and learning machines* (3rd ed.).
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hong, T., & Fan, S. (2016). Probabilistic electric load forecasting: A tutorial review. *International Journal of Forecasting*, 32(3), 914–938. <https://doi.org/10.1016/j.ijforecast.2015.11.011>
- Hou, H., Liu, C., Wang, Q., Wu, X., Tang, J., Shi, Y., & Xie, C. (2022). Review of load forecasting based on artificial intelligence methodologies, models, and challenges. *Electric Power Systems Research*, 210, 108067. <https://doi.org/10.1016/j.epsr.2022.108067>
- Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(3), 90–95. <https://doi.org/10.1109/MCSE.2007.55>
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts. <https://OTexts.com/fpp3>
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Ibrahim, B., Rabelo, L., Gutierrez-Franco, E., & Clavijo-Buritica, N. (2022). Machine learning for short-term load forecasting in smart grids. *Energies*, 15(21), 8079. <https://doi.org/10.3390/en15218079>
- Innes, A., & Monios, J. (2018). Identifying the unique challenges of installing cold ironing at small and medium ports – The case of Aberdeen. *Transportation Research Part D: Transport and Environment*, 62, 298–313. <https://doi.org/10.1016/j.trd.2018.02.004>

- International Maritime Organization. (2023). *2023 IMO strategy on reduction of GHG emissions from ships (Resolution MEPC.377(80))*.
<https://wwwcdn.imo.org/localresources/en/OurWork/Environment/Documents/annex/2023%20IMO%20Strategy%20on%20Reduction%20of%20GHG%20Emissions%20from%20Ships.pdf>
- International Organization for Standardization. (2026). *ISO 14001:2026: Environmental management systems—Requirements with guidance for use (4th ed.)*.
<https://www.iso.org/standard/14001>
- Iris, Ç., & Lam, J. S. L. (2019). A review of energy efficiency in ports: Operational strategies, technologies and energy management systems. *Renewable and Sustainable Energy Reviews*, 112, 170–182.
<https://doi.org/10.1016/j.rser.2019.04.069>
- Iris, Ç., & Lam, J. S. L. (2021). Optimal energy management and operations planning in seaports with smart grid while harnessing renewable energy under uncertainty. *Omega*, 103, 102445. <https://doi.org/10.1016/j.omega.2021.102445>
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An Introduction to Statistical Learning: With Applications in R*. Springer US. <https://doi.org/10.1007/978-1-0716-1418-1>
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017, December). LightGBM: A Highly Efficient Gradient Boosting Decision Tree. *Advances in Neural Information Processing Systems*, 30, 3146–3154.
- Kim, G., Lee, G., An, S., & Lee, J. (2023). Forecasting future electric power consumption in Busan New Port using a deep learning model. *The Asian Journal of Shipping and Logistics*, 39(2), 78–93. <https://doi.org/10.1016/j.ajsl.2023.04.001>

- Kingma, D. P., & Ba, J. (2014). *Adam: A Method for Stochastic Optimization* (Version 9). arXiv. <https://doi.org/10.48550/ARXIV.1412.6980>
- Klyuev, R. V., Morgoev, I. D., Morgoeva, A. D., Gavrina, O. A., Martyshev, N. V., Efremkov, E. A., & Mengxu, Q. (2022). Methods of forecasting electric energy consumption: A literature review. *Energies*, 15(23), 8919. <https://doi.org/10.3390/en15238919>
- Lam, J. S. L., & Notteboom, T. (2014). The greening of ports: A comparison of port management tools used by leading ports in Asia and Europe. *Transport Reviews*, 34(2), 169–189. <https://doi.org/10.1080/01441647.2014.891162>
- Lim, B., Arik, S. Ö., Loeff, N., & Pfister, T. (2021). Temporal fusion transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, 37(4), 1748–1764. <https://doi.org/10.1016/j.ijforecast.2021.03.012>
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30.
- Ma, K., Nie, X., Yang, J., Zha, L., Li, G., & Li, H. (2025). A power load forecasting method in port based on VMD-ICSS-hybrid neural network. *Applied Energy*, 377, 124246. <https://doi.org/10.1016/j.apenergy.2024.124246>
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>
- McKinney, W. (2010). *Data structures for statistical computing in Python*. In S. van der Walt & J. Millman (Eds.), *Proceedings of the 9th Python in Science Conference* (pp. 56–61). <https://doi.org/10.25080/Majora-92bf1922-00a>
- Micallef, A., Apap, M., Licari, J., Spiteri Staines, C., & Xiao, Z. (2025). A comparative framework for evaluating machine learning models in forecasting electricity

- demand for port microgrids. *Energy and AI*, 20, 100494.
<https://doi.org/10.1016/j.egyai.2025.100494>
- Misiurek, K., Olkusi, T., & Zyśk, J. (2025). Review of methods and models for forecasting electricity consumption. *Energies*, 18(15), 4032.
<https://doi.org/10.3390/en18154032>
- Mitchell, T. M. (1997). *Machine learning (Nachdr.)*. McGraw-Hill.
- Molavi, A., Lim, G. J., & Race, B. (2019). A framework for building a smart port and smart port index. *International Journal of Sustainable Transportation*, 14(9), 686–700. <https://doi.org/10.1080/15568318.2019.1610919>
- Mustaqeem, Ishaq, M., & Kwon, S. (2021). Short-Term Energy Forecasting Framework Using an Ensemble Deep Learning Approach. *IEEE Access*, 9, 94262–94271.
<https://doi.org/10.1109/ACCESS.2021.3093053>
- Mystakidis, A., Koukaras, P., Tsalikidis, N., Ioannidis, D., & Tjortjis, C. (2024). Energy forecasting: A comprehensive review of techniques and technologies. *Energies*, 17(7), 1662. <https://doi.org/10.3390/en17071662>
- Notteboom, T. E., & Rodrigue, J.-P. (2005). Port regionalization: Towards a new phase in port development. *Maritime Policy & Management*, 32(3), 297–313.
<https://doi.org/10.1080/03088830500139885>
- Nti, I. K., Teimeh, M., Nyarko-Boateng, O., & Adekoya, A. F. (2020). Electricity load forecasting: A systematic review. *Journal of Electrical Systems and Information Technology*, 7(1), Article 13. <https://doi.org/10.1186/s43067-020-00021-8>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn:

- Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., & Gulin, A. (2019). *CatBoost: Unbiased boosting with categorical features* (arXiv:1706.09516). arXiv. <https://doi.org/10.48550/arXiv.1706.09516>
- Qin, T. (2020). Machine Learning Basics. In T. Qin, *Dual Learning* (pp. 11–23). Springer Singapore. https://doi.org/10.1007/978-981-15-8884-6_2
- Rasmussen, C. E., & Williams, C. K. I. (2006). *Gaussian Processes for Machine Learning*. The MIT Press. <https://doi.org/10.7551/mitpress/3206.001.0001>
- Ribeiro, A. M. N. C., Do Carmo, P. R. X., Endo, P. T., Rosati, P., & Lynn, T. (2022). Short- and very short-term firm-level load forecasting for warehouses: A comparison of machine learning and deep learning models. *Energies*, 15(3), 750. <https://doi.org/10.3390/en15030750>
- Sadiq, M., Ali, S. W., Terriche, Y., Mutarraf, M. U., Hassan, M. A., Hamid, K., Ali, Z., Sze, J. Y., Su, C.-L., & Guerrero, J. M. (2021). Future greener seaports: A review of new infrastructure, challenges, and energy efficiency measures. *IEEE Access*, 9, 75568–75587. <https://doi.org/10.1109/access.2021.3081430>
- Salakapuri, R., & Pavankumar, T. (2025). A meta-learning framework with temporal feature integration for electricity load forecasting. *Energy Informatics*, 8(1), 112. <https://doi.org/10.1186/s42162-025-00572-y>
- Samuel, A. L. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, 3(3), 210–229. <https://doi.org/10.1147/rd.33.0210>
- Sarantakos, I., Bowkett, A., Allahham, A., Sayfutdinov, T., Murphy, A., Pazouki, K., Mangan, J., Liu, G., Chang, E., Bougioukou, E., & Patsios, H. (2023).

- Digitalization for port decarbonization: Decarbonization of key energy processes at the Port of Tyne. *IEEE Electrification Magazine*, 11(1), 61–72.
<https://doi.org/10.1109/mele.2022.3233114>
- Shen, J., Gao, W., Lu, J., Li, F., & Feng, X. (2025). Sources, calculation methods, and reduction strategies for GHG emissions at ports: Current status and future trends. *Frontiers in Marine Science*, 12. <https://doi.org/10.3389/fmars.2025.1542255>
- Shwartz-Ziv, R., & Armon, A. (2022). Tabular data: Deep learning is not all you need. *Information Fusion*, 81, 84–90. <https://doi.org/10.1016/j.inffus.2021.11.011>
- Sifakis, N., & Tsoutsos, T. (2021). Planning zero-emissions ports through the nearly zero energy port concept. *Journal of Cleaner Production*, 286, 125448.
<https://doi.org/10.1016/j.jclepro.2020.125448>
- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199–222.
<https://doi.org/10.1023/B:STCO.0000035301.49549.88>
- Song, P., Zhu, H., & Yang, Q. (2026). Short-term high-volatility power load forecasting in smart port energy systems using FeatureGating-BiLSTM enhanced by DualAttention mechanisms. *Energy Conversion and Management*, 348, 120664.
<https://doi.org/10.1016/j.enconman.2025.120664>
- Song, W., Cao, X., Jiang, H., Li, Z., & Gao, R. (2024). Two-stage combined model for short-term electricity forecasting in ports. *Information*, 15(11), 715.
<https://doi.org/10.3390/info15110715>
- Styhre, L., Winnes, H., Black, J., Lee, J., & Le-Griffin, H. (2017). Greenhouse gas emissions from ships in ports – Case studies in four continents. *Transportation Research Part D: Transport and Environment*, 54, 212–224.
<https://doi.org/10.1016/j.trd.2017.04.033>

- Tang, R., Ning, S., Ren, Z., Li, X., & Zhang, Y. (2025). Novel load forecasting and optimal dispatching methods considering demand response for integrated port energy system. *Journal of Marine Science and Engineering*, 13(3), 421.
<https://doi.org/10.3390/jmse13030421>
- Tashman, L. J. (2000). Out-of-sample tests of forecasting accuracy: An analysis and review. *International Journal of Forecasting*, 16(4), 437–450.
[https://doi.org/10.1016/s0169-2070\(00\)00065-0](https://doi.org/10.1016/s0169-2070(00)00065-0)
- Tefera, E., Kekeba, K., Ravindra Babu, B., & Martínez Ballesteros, M. del M. (2025). Nonlinear Ensemble Deep Learning Model for Energy Consumption Prediction with Bayesian Optimization. *Communications on Applied Nonlinear Analysis*, 32(1), 155–172. <https://doi.org/10.52783/cana.v32.1628>
- TensorFlow Developers. (2021). *TensorFlow (Version v2.x) [Computer software]*. Zenodo. <https://doi.org/10.5281/ZENODO.4724125>
- Tümse, S. (2025). LSTM, XGBoost and random forest models in forecasting current and future electricity consumption in Türkiye. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(4), 2139–2148.
<https://doi.org/10.17780/ksujes.1785928>
- Ugbehe, P. O., Diemuodeke, O. E., & Aikhuele, D. O. (2025). Electricity demand forecasting methodologies and applications: A review. *Sustainable Energy Research*, 12(1), 19. <https://doi.org/10.1186/s40807-025-00149-z>
- UNECE. (2022). *Greece—Observatory on Border Crossings Status due to COVID-19—UNECE Wiki*. <https://wiki.unece.org/spaces/CTRBSBC/pages/101548439/Greece>
- United Nations Conference on Trade and Development. (2024). *Review of maritime transport 2024: Navigating maritime chokepoints*. United Nations.

United Nations. (2015). *Transforming our world: The 2030 Agenda for Sustainable*

Development. United Nations.

Urry, L. A., Cain, M. L., Wasserman, S. A., Minorsky, P. V., & Orr, R. B. (2021).

Campbell Biology (12th ed.). Pearson.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., &

Polosukhin, I. (2017). *Attention Is All You Need* (Version 7). arXiv.

<https://doi.org/10.48550/ARXIV.1706.03762>

Viana, M., Hammingh, P., Colette, A., Querol, X., Degraeuwe, B., de Vlieger, I., & van

Aardenne, J. (2014). Impact of maritime transport emissions on coastal air quality in Europe. *Atmospheric Environment*, 90, 96–105.

<https://doi.org/10.1016/j.atmosenv.2014.03.046>

Wang, L., & Li, Y. (2023). *Estimation methods and reduction strategies of port carbon emissions—What literatures say? Marine Pollution Bulletin*, 195, 115451.

<https://doi.org/10.1016/j.marpolbul.2023.115451>

Wang, Y., Sun, S., Chen, X., Zeng, X., Kong, Y., Chen, J., Guo, Y., & Wang, T. (2021).

Short-term load forecasting of industrial customers based on SVM and XGBoost. *International Journal of Electrical Power & Energy Systems*, 129, 106830.

<https://doi.org/10.1016/j.ijepes.2021.106830>

Winkel, R., Weddige, U., Johnsen, D., Hoen, V., & Papaefthimiou, S. (2016). Shore-side electricity in Europe: Potential and environmental benefits. *Energy Policy*, 88,

584–593. <https://doi.org/10.1016/j.enpol.2015.07.013>

Xing, L., & Kaheh, Z. (2026). Fair benchmarking in short-term load forecasting. *Artificial*

Intelligence for Engineering, 2(1), 53–66. <https://doi.org/10.1049/aie2.70011>

- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)
- Zhang, Y., Liang, C., Shi, J., Lim, G., & Wu, Y. (2022). Optimal port microgrid scheduling incorporating onshore power supply and berth allocation under uncertainty. *Applied Energy*, 313, 118856. <https://doi.org/10.1016/j.apenergy.2022.118856>
- Zheng, Y. (2026). Performance assessment of LSTM networks for short-term load forecasting based on temporal feature engineering. *Informatica*, 50(9). <https://doi.org/10.31449/inf.v50i9.9317>
- Zippenfenig, P. (2024). *Open-Meteo.com Weather API (Version 1.4.0) [Computer software]*. Zenodo. <https://doi.org/10.5281/ZENODO.7970649>
- Zis, T. P. V. (2019). Prospects of cold ironing as an emissions reduction option. *Transportation Research Part A: Policy and Practice*, 119, 82–95. <https://doi.org/10.1016/j.tra.2018.11.003>
- Ένωση Λιμένων Ελλάδος. (2024, July 30). *Οργανισμός Λιμένος Πατρών—Ο.Λ.ΠΑ.* - Ένωση Λιμένων Ελλάδος (Ε.ΛΙΜ.Ε). <https://elime.gr/limania/organismos-limenos-patron-o-l-pa/>
- Ελληνική Στατιστική Αρχή. (2025). *Επιβατική και Εμπορευματική Κίνηση στη Ναυτιλία* (αρ. Επιβατών / οχημάτων, εμπορεύματα). Ελληνική Στατιστική Αρχή (ΕΛΣΤΑΤ). <https://www.statistics.gr/el/statistics/-/publication/SMA06/->
- Οργανισμός Λιμένος Πάτρας. (2023, December 1). *Οργανισμός Λιμένος Πάτρας Α.Ε.* - Ο.Λ.ΠΑ. Α.Ε. Οργανισμός Λιμένος Πάτρας. <https://patrasport.gr/>

Υπεύθυνη Δήλωση Συγγραφέα:

Δηλώνω ρητά ότι, σύμφωνα με το άρθρο 8 του Ν.1599/1986, η παρούσα εργασία αποτελεί αποκλειστικά προϊόν προσωπικής μου εργασίας, δεν προσβάλλει κάθε μορφής δικαιώματα διανοητικής ιδιοκτησίας, προσωπικότητας και προσωπικών δεδομένων τρίτων, δεν περιέχει έργα/εισφορές τρίτων για τα οποία απαιτείται άδεια των δημιουργών/δικαιούχων και δεν είναι προϊόν μερικής ή ολικής αντιγραφής, οι πηγές δε που χρησιμοποιήθηκαν περιορίζονται στις βιβλιογραφικές αναφορές και μόνον και πληρούν τους κανόνες της επιστημονικής παράθεσης.