



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

ΠΡΟΒΛΕΨΗ ΤΙΜΩΝ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ ΕΥΡΩΠΑΪΚΩΝ ΑΓΟΡΩΝ ΕΞΙΣΟΡΡΟΠΗΣΗΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Γρηγόριος Δ. Οικονόμου

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

Επόπτευση: Χριστόφορος Μένος-Αικατερινιάδης, Υποψήφιος Διδάκτορας Ε.Μ.Π.

Αθήνα, Ιούνιος 2025



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

ΠΡΟΒΛΕΨΗ ΤΙΜΩΝ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ ΕΥΡΩΠΑΪΚΩΝ ΑΓΟΡΩΝ ΕΙΣΟΡΡΟΠΗΣΗΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Γρηγόριος Δ. Οικονόμου

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

Επόπτευση: Χριστόφορος Μένος-Αικατερινιάδης, Υποψήφιος Διδάκτορας Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 27^η Ιουνίου 2025

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

.....
Βασίλειος Νικολαΐδης
Επικ. Καθηγητής Ε.Μ.Π.

.....
Γεώργιος Τσεκούρας
Αναπλ. Καθηγητής Πα.Δ.Α.

Αθήνα, Ιούνιος 2025

.....
Γρηγόριος Δ. Οικονόμου

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

Copyright © Γρηγόριος Οικονόμου, 2025.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

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

ΠΕΡΙΛΗΨΗ

Η αυξανόμενη συμμετοχή των ανανεώσιμων πηγών ενέργειας στα ηλεκτρικά δίκτυα της Ευρώπης έχει ενισχύσει τη μεταβλητότητα στην παραγωγή, καθιστώντας δυσκολότερη τη διατήρηση της ισορροπίας μεταξύ προσφοράς και ζήτησης. Στο πλαίσιο αυτό, η Αγορά Εξισορρόπησης αναλαμβάνει καθοριστικό ρόλο, με την πρόβλεψη των τιμών της να αποτελεί κρίσιμο εργαλείο για τη σταθερή και αποδοτική λειτουργία του ενεργειακού συστήματος.

Η παρούσα εργασία αναπτύσσει και εφαρμόζει ένα κοινό μεθοδολογικό πλαίσιο για τη βραχυπρόθεσμη πρόβλεψη τιμών Εξισορρόπησης σε τρεις ευρωπαϊκές χώρες με διαφορετικά λειτουργικά χαρακτηριστικά: Ιρλανδία, Ισπανία και Βέλγιο. Η ανάλυση βασίζεται σε δεδομένα υψηλής χρονικής ανάλυσης που προέρχονται από την ευρωπαϊκή πλατφόρμα ENTSO-E και περιλαμβάνουν, μεταξύ άλλων, προβλέψεις ζήτησης, παραγωγής και διασυννοριακών ροών. Η μεθοδολογία που ακολουθείται περιλαμβάνει την εφαρμογή τεσσάρων μοντέλων πρόβλεψης: ενός στατιστικού μοντέλου χρονοσειρών (ARIMA), ενός γραμμικού αυτοπαλίνδρομου μοντέλου με κανονικοποίηση τύπου LASSO (LEAR), ενός αλγορίθμου μηχανικής μάθησης βασισμένου σε δέντρα απόφασης (XGBoost) και ενός απλού μοντέλου αναφοράς (Naïve). Η σύγκριση των μοντέλων πραγματοποιείται μηνιαία και για διαφορετικά βάρη ιστορικού παραθύρου, με χρήση καθιερωμένων δεικτών σφάλματος (MAE, RMSE, sMAPE).

Η εργασία προσφέρει χρήσιμες συγκρίσεις για την απόδοση διαφορετικών τεχνικών πρόβλεψης και συμβάλλει στην κατανόηση των ιδιαίτερων προκλήσεων που παρουσιάζει η πρόβλεψη τιμών Εξισορρόπησης σε διαφορετικά ευρωπαϊκά περιβάλλοντα. Τα ευρήματα της μελέτης μπορούν να αξιοποιηθούν από Διαχειριστές Συστημάτων Μεταφοράς (TSOs) και φορείς της αγοράς για την βελτίωση των στρατηγικών πρόβλεψης και την λήψη τεκμηριωμένων αποφάσεων στο πλαίσιο της αγοράς Εξισορρόπησης.

ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ

Πρόβλεψη τιμών Εξισορρόπησης, Αγορές Εξισορρόπησης, Χρονοσειρές, ARIMA, LEAR, XGBoost, ENTSO-E, παράθυρο εκπαίδευσης, Ιρλανδία, Ισπανία, Βέλγιο

ABSTRACT

The increasing penetration of renewable energy sources into Europe's electricity networks has amplified production variability, making it more challenging to maintain the real-time balance between supply and demand. In this context, the Balancing Market plays a critical role, and accurate price forecasting emerges as a key tool for the stable and efficient operation of power systems.

This Diploma Thesis develops and implements a unified methodological framework for short-term balancing price forecasting across three European countries with distinct operational characteristics: Ireland, Spain, and Belgium. The analysis relies on high-resolution data from the ENTSO-E platform, including both historical and forecasted variables, such as demand, generation (conventional and renewable), net cross-border flows, and the balancing price itself. The forecasting methodology involves the application of four models: a statistical time series model (ARIMA), a linear autoregressive model with LASSO regularization (LEAR), a machine learning model based on decision trees (XGBoost), and a simple baseline model (Naive). Model comparison is conducted on a monthly basis and across different input window sizes, using established performance metrics (MAE, RMSE, sMAPE).

The study provides valuable comparisons regarding the performance of different forecasting techniques and contributes to understanding the specific challenges of balancing price prediction across diverse European market settings. The findings can be leveraged by Transmission System Operators and market participants to enhance forecasting strategies and support informed decision-making in the Balancing Market.

KEY WORDS

Balancing Price Forecasting, Balancing Markets, Time Series, ARIMA, LEAR, XGBoost, ENTSO-E, training window, Ireland, Spain, Belgium

ΕΥΧΑΡΙΣΤΙΕΣ

Η παρούσα διπλωματική εργασία εκπονήθηκε κατά το ακαδημαϊκό έτος 2024–2025 υπό την επίβλεψη του κ. Παύλου Γεωργιλάκη, καθηγητή της σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Ε.Μ.Π., στον οποίο οφείλω ιδιαίτερες ευχαριστίες για την ανάθεσή της, δίνοντάς μου την ευκαιρία να ασχοληθώ με ένα τόσο ενδιαφέρον και δημιουργικό θέμα. Επίσης, θα ήθελα να ευχαριστήσω θερμά τον υποψήφιο διδάκτορα Χριστόφορο Μένο-Αικατερινιάδη για την πολύτιμη καθοδήγηση, την αδιάλειπτη υποστήριξη και τη συνεχή διαθεσιμότητά του σε όλα τα στάδια της εργασίας. Η συμβολή του υπήρξε καθοριστική τόσο στην κατανόηση της μεθοδολογίας όσο και στην επιτυχή υλοποίηση της μελέτης. Θα ήθελα, τέλος, να εκφράσω την ευγνωμοσύνη μου στην οικογένειά μου για τη στήριξή της καθ' όλη τη διάρκεια των σπουδών μου, καθώς και σε φίλους και συναδέλφους που με στήριζαν με την παρουσία και τη συμπαράστασή τους.

ΠΕΡΙΕΧΟΜΕΝΑ

ΚΕΦΑΛΑΙΟ 1:	ΕΙΣΑΓΩΓΗ	1
1.1	Σκοπός και αντικείμενο της εργασίας	1
1.2	Δομή της εργασίας	1
ΚΕΦΑΛΑΙΟ 2:	ΟΙ ΑΓΟΡΕΣ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ ΚΑΙ Η ΑΓΟΡΑ ΕΞΙΣΟΡΡΟΠΗΣΗΣ ΣΤΗΝ ΕΥΡΩΠΗ	3
2.1	Εισαγωγή	3
2.2	Βασικές κατηγορίες αγορών ηλεκτρικής ενέργειας	4
2.2.1	Αγορά Επόμενης Ημέρας	4
2.2.2	Ενδοημερήσια Αγορά	5
2.2.3	Αγορά Εξισορρόπησης	5
2.3	Δομή και λειτουργία της αγοράς εξισορρόπησης σε ευρωπαϊκές χώρες	6
2.3.1	Ιρλανδία	6
2.3.2	Ισπανία	7
2.3.3	Βέλγιο	8
2.4	Χαρακτηριστικά και προκλήσεις πρόβλεψης των τιμών στην αγορά εξισορρόπησης	8
ΚΕΦΑΛΑΙΟ 3:	ΔΕΔΟΜΕΝΑ ΚΑΙ ΠΡΟΕΠΕΞΕΡΓΑΣΙΑ	11
3.1	Εισαγωγή	11
3.2	Μεθοδολογία πρόβλεψης και αξιολόγησης	11
3.3	Πηγές και προεπεξεργασία δεδομένων	13
3.4	Μεταβλητές εισόδου και στόχος πρόβλεψης	16
3.5	Δομή συνόλων εκπαίδευσης και αξιολόγησης	17
ΚΕΦΑΛΑΙΟ 4:	ΜΟΝΤΕΛΑ ΠΡΟΒΛΕΨΗΣ ΚΑΙ ΜΕΘΟΔΟΛΟΓΙΑ	21
4.1	Εισαγωγή	21
4.2	Μοντέλα πρόβλεψης	22
4.2.1	Μοντέλο ARIMA	22
4.2.2	Μοντέλο LEAR	26
4.2.3	Μοντέλο XGBoost	29
4.3	Δείκτες αξιολόγησης	34

ΚΕΦΑΛΑΙΟ 5:	ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΣΥΓΚΡΙΤΙΚΗ	37
	ΑΞΙΟΛΟΓΗΣΗ	
5.1	Εισαγωγή	37
5.2	Διερεύνηση απόδοσης ανά μηνά και χρονικό παράθυρο εκπαίδευσης	38
5.2.1	Ιρλανδία	38
5.2.2	Ισπανία	45
5.2.3	Βέλγιο	52
5.3	Συγκριτική αξιολόγηση	58
5.3.1	Βέλτιστοι συνδυασμοί μοντελοποίησης ανά χώρα	59
5.3.2	Σύγκριση αποτελεσμάτων για τη αγορά της Ιρλανδίας με τη βιβλιογραφία	67
ΚΕΦΑΛΑΙΟ 6:	ΣΥΜΠΕΡΑΣΜΑΤΑ	71
6.1	Σύνοψη της εργασίας και των αποτελεσμάτων της	71
6.2	Περιορισμοί και δυσκολίες	73
6.3	Μελλοντικές κατευθύνσεις	74
ΚΕΦΑΛΑΙΟ 7:	ΒΙΒΛΙΟΓΡΑΦΙΑ	77

ΕΙΣΑΓΩΓΗ

1.1 ΣΚΟΠΟΣ ΚΑΙ ΑΝΤΙΚΕΙΜΕΝΟ ΤΗΣ ΕΡΓΑΣΙΑΣ

Η ολοένα αυξανόμενη διείσδυση στοχαστικών ανανεώσιμων πηγών ενέργειας (όπως η αιολική και η ηλιακή) στα ευρωπαϊκά ηλεκτρικά δίκτυα επιδρά σημαντικά στη διακύμανση της παραγωγής και καθιστά πιο απαιτητική τη διατήρηση της ισορροπίας σε πραγματικό χρόνο. Η Αγορά Εξισορρόπησης αποτελεί το τελικό στάδιο της χονδρεμπορικής αγοράς ηλεκτρικής ενέργειας και καλείται να καλύψει αποκλίσεις μεταξύ προβλεπόμενης και πραγματικής παραγωγής και ζήτησης, διασφαλίζοντας την επιχειρησιακή ευστάθεια του συστήματος. Η δυνατότητα πρόβλεψης των τιμών αυτής της αγοράς αποτελεί χρήσιμο εργαλείο τόσο για τους Διαχειριστές Συστημάτων Μεταφοράς, όσο και για τους συμμετέχοντες στην αγορά.

Αντικείμενο της παρούσας διπλωματικής εργασίας είναι η ανάπτυξη ενός ενιαίου πλαισίου βραχυπρόθεσμης πρόβλεψης τιμών Εξισορρόπησης για τρεις ευρωπαϊκές χώρες που διαθέτουν διαφορετικά ρυθμιστικά και λειτουργικά χαρακτηριστικά: Ιρλανδία, Ισπανία και Βέλγιο. Η πρόβλεψη βασίζεται σε δεδομένα με χρονική ανάλυση 30 λεπτών, τα οποία συλλέγονται από την πλατφόρμα ENTSO-E, και περιλαμβάνουν τόσο ιστορικές, όσο και προβλεπόμενες μεταβλητές, όπως η τιμή Εξισορρόπησης, η ζήτηση, η παραγωγή (συμβατική και από ΑΠΕ) και οι καθαρές διασυνοριακές ροές ισχύος. Για την υλοποίηση του στόχου, εφαρμόζονται τέσσερα μοντέλα πρόβλεψης: ένα στατιστικό μοντέλο χρονοσειρών (ARIMA), ένα γραμμικό μοντέλο αυτοπαλινδρόμησης με κανονικοποίηση τύπου l_1 (L1) (LEAR), ένα μοντέλο μηχανικής μάθησης (XGBoost), καθώς και ένα απλό υπόδειγμα βάσης (Naïve).

Κύριος σκοπός της εργασίας είναι η συστηματική αξιολόγηση και σύγκριση των τεχνικών πρόβλεψης σε διαφορετικά πειραματικά σενάρια, όπως η χρονική περίοδος πρόβλεψης και το μέγεθος του ιστορικού παραθύρου εισόδου. Μέσω της ανάλυσης των αποτελεσμάτων για κάθε χώρα, διερευνάται η επίδραση του ρυθμιστικού και λειτουργικού πλαισίου στην απόδοση των μοντέλων και εντοπίζονται μεθοδολογικές προσεγγίσεις που προσφέρουν καλύτερη ακρίβεια και συνέπεια στην πρόβλεψη των τιμών Εξισορρόπησης.

1.2 ΔΟΜΗ ΤΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα διπλωματική εργασία οργανώνεται σε επτά κεφάλαια:

- ✓ Στο **Κεφάλαιο 2** παρουσιάζεται το θεσμικό και λειτουργικό πλαίσιο των ευρωπαϊκών αγορών ηλεκτρικής ενέργειας, με έμφαση στην Αγορά Εξισορρόπησης ως βασικό εργαλείο διατήρησης της ισορροπίας μεταξύ προσφοράς και ζήτησης σε πραγματικό χρόνο. Αρχικά περιγράφονται

συνοπτικά τα είδη αγορών που απαρτίζουν την ενιαία αγορά ενέργειας, ενώ στη συνέχεια αναλύονται οι βασικές λειτουργίες της Αγοράς Εξισορρόπησης και παρουσιάζονται οι ιδιαιτερότητες της σε τρεις ευρωπαϊκές χώρες: Ιρλανδία, Ισπανία και Βέλγιο.

- ✓ Στο **Κεφάλαιο 3** παρουσιάζεται η μεθοδολογική προσέγγιση που ακολουθήθηκε για τη συγκρότηση του συνόλου δεδομένων και την προετοιμασία των εισόδων προς τα μοντέλα πρόβλεψης. Αρχικά περιγράφονται οι πηγές των δεδομένων και τα βασικά βήματα προεπεξεργασίας των δεδομένων. Στη συνέχεια, αναλύεται η διαδικασία διαμόρφωσης των χαρακτηριστικών εισόδου, η επιλογή του στόχου πρόβλεψης και η οργάνωση της διαδικασίας εκπαίδευσης και αξιολόγησης των μοντέλων.
- ✓ Στο **Κεφάλαιο 4** αναλύονται τα μοντέλα πρόβλεψης που εφαρμόστηκαν στο πλαίσιο της παρούσας διπλωματικής εργασίας: ARIMA, LEAR, XGBoost και Naive. Παρουσιάζονται οι θεωρητικές αρχές κάθε μεθόδου, η διαδικασία εκπαίδευσης και εφαρμογής των μοντέλων, καθώς και η επιλογή κατάλληλων παραμέτρων και δεικτών αξιολόγησης της απόδοσης.
- ✓ Στο **Κεφάλαιο 5** παρουσιάζονται τα αποτελέσματα εφαρμογής των μοντέλων πρόβλεψης για τις τρεις υπό μελέτη χώρες. Αξιολογείται η απόδοσή τους σε διαφορετικά πειραματικά σενάρια, με χρήση δεικτών σφάλματος. Επιπλέον, πραγματοποιείται συγκριτική αποτίμηση των αποτελεσμάτων, με αναφορά σε ευρήματα της σχετικής βιβλιογραφίας.
- ✓ Στο **Κεφάλαιο 6** συνοψίζονται τα βασικά ευρήματα της εργασίας, καταγράφονται οι περιορισμοί που αντιμετωπίστηκαν κατά την υλοποίηση, και προτείνονται κατευθύνσεις για μελλοντική έρευνα και βελτίωση.
- ✓ Στο **Κεφάλαιο 7** παρατίθεται η βιβλιογραφία που χρησιμοποιήθηκε σε όλη την έκταση της διπλωματικής εργασίας.


ΟΙ ΑΓΟΡΕΣ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ ΚΑΙ Η ΑΓΟΡΑ ΕΞΙΣΟΡΡΟΠΗΣΗΣ ΣΤΗΝ ΕΥΡΩΠΗ

2.1 ΕΙΣΑΓΩΓΗ

Η ηλεκτρική ενέργεια αποτελεί βασικό αγαθό για τη λειτουργία των σύγχρονων κοινωνιών και οικονομιών. Η ανάπτυξη ανταγωνιστικών αγορών ηλεκτρικής ενέργειας στην Ευρώπη τις τελευταίες δεκαετίες αποσκοπεί στη βελτιστοποίηση της κατανομής πόρων, την ενίσχυση της αποδοτικότητας και τη μείωση του κόστους για τους καταναλωτές. Στο πλαίσιο αυτό, έχουν διαμορφωθεί πολυεπίπεδες αγορές που καλύπτουν τόσο τον προγραμματισμό της παραγωγής και της κατανάλωσης, όπως η Αγορά Επόμενης Ημέρας και η Ενδοημερήσια Αγορά, όσο και την εξισορρόπηση της παραγωγής και της ζήτησης σε πραγματικό χρόνο μέσω της Αγοράς Εξισορρόπησης, καθεμία με τα δικά της χαρακτηριστικά και χρονικούς ορίζοντες. Η διασύνδεση και η διαδοχή μεταξύ των αγορών αυτών αποτυπώνεται συνοπτικά στο Σχήμα 2.1 [1].

Μεταξύ αυτών των επιμέρους αγορών, η Αγορά Εξισορρόπησης διαδραματίζει κρίσιμο ρόλο στη διατήρηση της ευστάθειας του συστήματος. Η μετάβαση προς ένα αποκεντρωμένο και δυναμικό ενεργειακό σύστημα, με αυξανόμενη διείσδυση ανανεώσιμων πηγών ενέργειας, εντείνει την ανάγκη για μηχανισμούς που διασφαλίζουν την ευστάθεια και την αξιοπιστία του δικτύου. Σε αυτό το πλαίσιο, η Αγορά Εξισορρόπησης ενεργοποιείται για να διορθώσει αποκλίσεις μεταξύ προβλεπόμενης και πραγματικής παραγωγής ή κατανάλωσης. Η υψηλή μεταβλητότητα και μη προβλεψιμότητα των ΑΠΕ καθιστά την αγορά εξισορρόπησης ιδιαίτερα ευαίσθητη σε χρονικές ασυμφωνίες και αποκλίσεις, εντείνοντας τις απαιτήσεις για αξιόπιστα προβλεπτικά μοντέλα [2].

Υπό αυτό το πρίσμα, η κατανόηση της δομής των μηχανισμών και των ιδιαιτεροτήτων κάθε επιμέρους αγοράς είναι απαραίτητη τόσο για την ανάλυση της λειτουργίας τους όσο και για την ανάπτυξη εργαλείων πρόβλεψης. Το παρόν κεφάλαιο στοχεύει να θεμελιώσει θεωρητικά την παρούσα διπλωματική εργασία, παρουσιάζοντας το πλαίσιο λειτουργίας των ευρωπαϊκών αγορών ηλεκτρικής ενέργειας με έμφαση στην Αγορά Εξισορρόπησης. Παράλληλα, αναλύονται οι ιδιαιτερότητες των αγορών σε τρεις επιλεγμένες χώρες (Ιρλανδία, Ισπανία, Βέλγιο), στις οποίες βασίστηκε η πειραματική ανάλυση της παρούσας διπλωματικής εργασίας.



Σχήμα 2.1 : Σχηματική απεικόνιση της δομής των ευρωπαϊκών αγορών ηλεκτρικής ενέργειας [6]

2.2 ΒΑΣΙΚΕΣ ΚΑΤΗΓΟΡΙΕΣ ΑΓΟΡΩΝ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ

Η χονδρεμπορική αγορά ηλεκτρικής ενέργειας στην Ευρώπη δομείται σε τρία βασικά επίπεδα, τα οποία διαφοροποιούνται βάσει του χρονικού ορίζοντα και του ρόλου τους στην εξασφάλιση της ισορροπίας μεταξύ προσφοράς και ζήτησης. Συγκεκριμένα, οι κύριες αγορές είναι:

- Αγορά Επόμενης Ημέρας
- Ενδοημερήσια Αγορά
- Αγορά Εξισορρόπησης

Κάθε μία από τις παραπάνω αγορές χαρακτηρίζεται από διαφορετικά χρονικά πλαίσια, τύπους συμμετεχόντων και μεθόδους διαμόρφωσης τιμών. Οι ιδιαιτερότητες τους παρουσιάζονται αναλυτικά στις επόμενες υποενότητες.

2.2.1 Αγορά Επόμενης Ημέρας

Η Αγορά Επόμενης Ημέρας αποτελεί το βασικό στάδιο χρονικού προγραμματισμού της ηλεκτροπαραγωγής στα περισσότερα ευρωπαϊκά ενεργειακά συστήματα. Σε αυτό το πλαίσιο, οι παραγωγοί και οι προμηθευτές υποβάλλουν προσφορές και δηλώσεις ζήτησης για την κάλυψη του φορτίου της επόμενης ημέρας, με στόχο την επίτευξη ισορροπίας μεταξύ προσφοράς και ζήτησης βάσει του κόστους και της διαθεσιμότητας των μονάδων παραγωγής [3]. Η εξισορρόπηση αυτή επιτυγχάνεται μέσω του αλγορίθμου EUPHEMIA (Pan-European Hybrid Electricity Market Integration Algorithm), ο οποίος εφαρμόζεται από το 2014 στο πλαίσιο της ευρωπαϊκής σύζευξης αγορών. Ο αλγόριθμος λαμβάνει υπόψη τεχνικούς περιορισμούς, όπως τα όρια μεταφοράς στις διασυνδέσεις μεταξύ των χωρών, και υπολογίζει τη συνοριακή οριακή τιμή συστήματος για κάθε χρονική περίοδο. Η προκύπτουσα τιμή εκκαθάρισης επηρεάζει τόσο την εγχώρια παραγωγή, όσο και τις διασυνοριακές ροές ενέργειας [4].

Η Αγορά Επόμενης Ημέρας λειτουργεί σε καθημερινή βάση, με δημοπρασία που διεξάγεται στις 11:00 (UTC), και καλύπτει το 24ωρο της επόμενης ημέρας σε ωριαία χρονικά διαστήματα. Οι συμμετέχοντες υποβάλλουν δεσμευτικές προσφορές πώλησης ή αγοράς για κάθε ώρα της ημέρας, λαμβάνοντας υπόψη προβλέψεις φορτίου, διαθεσιμότητα μονάδων και άλλες τεχνικές ή αγοραίες παραμέτρους [3]. Μεταξύ των βασικών συμμετεχόντων συγκαταλέγονται παραγωγοί, προμηθευτές, μεγάλοι καταναλωτές και εταιρείες εμπορίας ενέργειας. Σε πολλές χώρες, η συμμετοχή μεγάλων παραγωγών είναι υποχρεωτική, προκειμένου να διασφαλίζεται η διαφάνεια και να περιορίζονται φαινόμενα στρατηγικής χειραγώγησης προσφορών.

Η Αγορά Επόμενης Ημέρας εμφανίζει συγκριτικά υψηλότερη προβλεψιμότητα σε σχέση με τις ενδοημερήσιες ή τις αγορές εξισορρόπησης, κυρίως λόγω της χρονικής απόστασης από την παράδοση και της επάρκειας ιστορικών δεδομένων. Ωστόσο, η αυξανόμενη διείσδυση ανανεώσιμων πηγών ενέργειας έχει περιορίσει την ακρίβεια των προβλέψεων, αναδεικνύοντας την ανάγκη για πιο εξελιγμένα μοντέλα πρόβλεψης τιμών [5]. Πρόσφατες ερευνητικές προσεγγίσεις εστιάζουν σε μοντέλα που αξιοποιούν τη χρονική δυναμική των δεδομένων και τις συσχετίσεις με γειτονικές αγορές. Ενδεικτικά, έχει καταγραφεί υψηλή απόδοση από μοντέλα επαναληπτικών νευρωνικών δικτύων, όπως η Μονάδα Αναδρομικής Πύλης (GRU) και τα Δίκτυα Μακράς Βραχύχρονης Μνήμης (LSTM), αλλά και από μοντέλα χαμηλότερης υπολογιστικής πολυπλοκότητας, όπως το Αυτοπαλίνδρομο Μοντέλο με τη μέθοδο LASSO (LEAR), ειδικά σε αγορές υψηλής μεταβλητότητας, όπως η σκανδιναβική και η τουρκική [6].

2.2.2 Ενδοημερήσια Αγορά

Η Ενδοημερήσια Αγορά λειτουργεί ως ενδιάμεσο στάδιο μεταξύ της Αγοράς Επόμενης Ημέρας και της Αγοράς Εξισορρόπησης. Η κύρια λειτουργία της είναι η διόρθωση αποκλίσεων μεταξύ προβλέψεων και πραγματικής παραγωγής ή κατανάλωσης, καθώς επιτρέπει στους συμμετέχοντες να προσαρμόζουν τις προσφορές και τις δηλώσεις τους εντός της ίδιας ημέρας, καθώς πλησιάζει η ώρα παράδοσης της ενέργειας [3].

Σε αντίθεση με τη Αγορά της Επόμενης Μέρας που διενεργείται μία φορά την ημέρα, η Ενδοημερήσια Αγορά λειτουργεί συνεχώς σε σχεδόν πραγματικό χρόνο. Οι συναλλαγές πραγματοποιούνται ανά διακριτά χρονικά βήματα, συνήθως 15 ή 60 λεπτών, έως και λίγες ώρες πριν από την παράδοση. Οι συμμετέχοντες υποβάλλουν δεσμευτικές προσφορές πώλησης ή αγοράς για κάθε χρονικό διάστημα, βασιζόμενοι σε επικαιροποιημένα δεδομένα παραγωγής και φορτίου. Η διασυννοριακή ενοποίηση της αγοράς επιτυγχάνεται μέσω της πλατφόρμας XBID, η οποία επιτρέπει συναλλαγές με σειρά προτεραιότητας, χωρίς εκκαθάριση τιμών [4].

Η σημασία της Ενδοημερήσιας Αγοράς έχει αυξηθεί τα τελευταία έτη, καθώς η ακριβέστερη πρόβλεψη κοντά στην ώρα παράδοσης ενισχύει την αποδοτική ενσωμάτωση των ανανεώσιμων πηγών ενέργειας. Πολλές ευρωπαϊκές χώρες αξιοποιούν αυτοματοποιημένα εργαλεία για τη διαχείριση των προσφορών και της συμμετοχής στην αγορά με συνεχείς επικαιροποιήσεις προσφορών και φορτίου. Η διεθνής βιβλιογραφία καταγράφει την ερευνητική πρόοδο σε μοντέλα πρόβλεψης που αξιοποιούν στοχαστικές τεχνικές, δεδομένα ανανεώσιμων πηγών ενέργειας και φορτίου, και προτείνει επέκταση των εφαρμογών σε ευρωπαϊκές αγορές πέραν της Γερμανίας, με στόχο την ενίσχυση της διαφάνειας και τον περιορισμό καταχρηστικών πρακτικών [5].

2.2.3 Αγορά Εξισορρόπησης

Η Αγορά Εξισορρόπησης αποτελεί το τελικό στάδιο της χονδρεμπορικής αγοράς ηλεκτρικής ενέργειας και διασφαλίζει την πραγματική εξισορρόπηση μεταξύ παραγωγής και κατανάλωσης σε σχεδόν πραγματικό χρόνο, συνήθως από 15 λεπτά έως λίγες ώρες πριν την παράδοση. Σε αντίθεση με τις προηγούμενες αγορές, οι οποίες βασίζονται σε προβλέψεις, η Αγορά Εξισορρόπησης λειτουργεί σε επιχειρησιακό επίπεδο, με παρεμβάσεις του Διαχειριστή του Συστήματος Μεταφοράς Ηλεκτρικής Ενέργειας για τη διόρθωση αποκλίσεων και τη διατήρηση της ευστάθειας του συστήματος [5].

Η δομή και η λειτουργία της Αγοράς Εξισορρόπησης διαφέρει σημαντικά από χώρα σε χώρα. Ανάλογα με το θεσμικό και τεχνικό πλαίσιο, εφαρμόζονται διαφορετικοί κανόνες αποδοχής εντολών, επιλογής μονάδων και υπολογισμού τιμών, οι οποίοι επηρεάζονται από παράγοντες όπως η διείσδυση ανανεώσιμων πηγών ενέργειας, η τεχνολογική ωριμότητα και η αρχιτεκτονική της αγοράς. Η αυξημένη μεταβλητότητα, η χαμηλή συσχέτιση με προγενέστερες προβλέψεις και οι τεχνικές ιδιαιτερότητες κάθε συστήματος καθιστούν την πρόβλεψη τιμών εξισορρόπησης μία από τις πλέον σύνθετες προκλήσεις. Η σε βάθος κατανόηση των εθνικών προσεγγίσεων αποτελεί αντικείμενο της Ενότητας 2.3 [5].

Οι Διαχειριστές Συστημάτων εφαρμόζουν επιμέρους διαδικασίες τιμολόγησης, υιοθετώντας πολιτικές όπως ο αποκλεισμός εντολών, ο καθορισμός ελάχιστων ορίων για την ενεργοποίηση προσφορών και η αποδοχή μόνο ενεργειακών παρεμβάσεων. Σε αρκετά συστήματα εισάγονται επιπλέον ρυθμίσεις για την αποφυγή ακραίων τιμών ή την αντιμετώπιση αποκλίσεων υψηλής επικινδυνότητας. Οι μηχανισμοί αυτοί επηρεάζουν άμεσα την τελική τιμολόγηση και η κατανόησή τους είναι ουσιώδης για την ανάπτυξη αξιόπιστων μοντέλων πρόβλεψης και τη διαχείριση του κινδύνου αποκλίσεων σε περιβάλλοντα υψηλής αβεβαιότητας [5].

Τέλος, η Αγορά Εξισορρόπησης στην Ευρώπη βρίσκεται σε φάση θεσμικής μεταρρύθμισης, με στόχο την εναρμόνιση των κανόνων και τη βελτίωση της αποδοτικότητας. Πολλαπλές μεθοδολογίες πρόβλεψης τιμών έχουν αξιολογηθεί υπό συνθήκες υψηλής μεταβλητότητας, αναδεικνύοντας την ανάγκη συνδυαστικής αξιοποίησης τεχνικών, στατιστικών και υπολογιστικών εργαλείων [6].

2.3 ΔΟΜΗ ΚΑΙ ΛΕΙΤΟΥΡΓΙΑ ΤΗΣ ΑΓΟΡΑΣ ΕΞΙΣΟΡΡΟΠΗΣΗΣ ΣΕ ΕΥΡΩΠΑΪΚΕΣ ΧΩΡΕΣ

Η Αγορά Εξισορρόπησης παρουσιάζει σημαντικές διαφοροποιήσεις μεταξύ των ευρωπαϊκών χωρών, τόσο στον σχεδιασμό, όσο και στην εφαρμογή των μηχανισμών αποδοχής εντολών και υπολογισμού τιμών. Η κατανόηση αυτών των διαφορών είναι κρίσιμη για την αξιολόγηση της αποδοτικότητας κάθε εθνικού συστήματος, καθώς και για την επιλογή κατάλληλων μεθοδολογιών πρόβλεψης. Στην παρούσα υποενότητα παρουσιάζονται ενδεικτικά τρία παραδείγματα εθνικών αγορών, συγκεκριμένα της Ιρλανδίας, της Ισπανίας και του Βελγίου, που χαρακτηρίζονται από διαφορετικά τεχνικά, ρυθμιστικά και επιχειρησιακά χαρακτηριστικά.

2.3.1 Ιρλανδία

Η Ιρλανδική αγορά εξισορρόπησης εντάσσεται στην Ενιαία Αγορά Ηλεκτρικής Ενέργειας (SEM), η οποία καλύπτει τόσο την Ιρλανδία όσο και τη Βόρεια Ιρλανδία. Το σύστημα αυτό παρουσιάζει σημαντικές ιδιαιτερότητες σε τεχνικό και ρυθμιστικό επίπεδο, καθιστώντας την πρόβλεψη των τιμών εξισορρόπησης ιδιαίτερα απαιτητική [6].

Η λειτουργία της αγοράς βασίζεται σε εντολές διάρκειας πέντε λεπτών, ενώ η εκκαθάριση των τιμών πραγματοποιείται ανά ημίωρο. Ο Διαχειριστής του Συστήματος (EirGrid) εφαρμόζει σύνθετους μηχανισμούς εκκαθάρισης που περιλαμβάνουν φίλτρα όπως το κατώφλι ελάχιστης αποδοχής (DMAT) και μηχανισμούς απομόνωσης ακραίων τιμών. Εντολές που δεν σχετίζονται με ενεργειακές

ανάγκες, π.χ. λόγω περιορισμών δικτύου, εξαιρούνται από την τιμολόγηση, γεγονός που εντείνει την ασυμμετρία μεταξύ προσφοράς και εκκαθάρισης. Πρόσθετη πρόκληση αποτελεί η υψηλή διείσδυση ανανεώσιμων πηγών ενέργειας, ιδίως αιολικής, η οποία αυξάνει τη μεταβλητότητα και οδηγεί σε συχνές αποκλίσεις μεταξύ προγραμματισμένης και πραγματικής παραγωγής. Το κανονιστικό πλαίσιο της Ιρλανδικής αγοράς εξισορρόπησης προσθέτει πολυπλοκότητα, μέσω κανόνων για την αποζημίωση αποκλίσεων, τη διαχείριση αποθεμάτων και τη χρήση ιστορικών δεδομένων στον υπολογισμό των τιμών ανισορροπίας. Ιδιαίτερα σημαντικός είναι ο νησιωτικός χαρακτήρας του Ιρλανδικού συστήματος, με περιορισμένες διασυνδέσεις, κυρίως με το Ηνωμένο Βασίλειο μέσω της διασυνδετικής γραμμής Moyle, γεγονός που περιορίζει τη δυνατότητα διασυνοριακής εξισορρόπησης. Αυτό διαφοροποιεί τη δομή της αγοράς σε σχέση με ηπειρωτικά κράτη που συμμετέχουν σε κοινές ευρωπαϊκές πλατφόρμες, όπως το TERRE και το MARI [6].

Η Ιρλανδική αγορά χαρακτηρίζεται από έντονη μεταβλητότητα τιμών, η οποία αποδίδεται στο μικρό μέγεθος του συστήματος, τη μεγάλη συμμετοχή ανανεώσιμων πηγών ενέργειας και την κανονιστική πολυπλοκότητα. Η πρόβλεψη τιμών έχει αποτελέσει αντικείμενο εκτεταμένης έρευνας. Έχουν εντοπιστεί ενδείξεις περιορισμένης προβλεψιμότητας, ιδίως μέσω μοντέλων που λαμβάνουν υπόψη εναλλαγές μεταξύ καταστάσεων λειτουργίας, την επίδραση των ανανεώσιμων πηγών ενέργειας και τους κανονιστικούς περιορισμούς. Τα μοντέλα αυτά, τα οποία ενσωματώνουν δείκτες μεταβλητότητας και δυναμικές παραμέτρους, επιτυγχάνουν καλύτερες επιδόσεις σε περιόδους έντονων αποκλίσεων. Ωστόσο, η ακρίβεια τους παραμένει περιορισμένη υπό ακραίες συνθήκες, αναδεικνύοντας την ανάγκη για περαιτέρω εξειδικευμένα εργαλεία πρόβλεψης [6].

2.3.2 Ισπανία

Η διαχείριση της Ισπανικής αγοράς εξισορρόπησης ασκείται από τον εθνικό Διαχειριστή του Συστήματος Μεταφοράς, ο οποίος είναι υπεύθυνος για τον επιχειρησιακό συντονισμό και τη λειτουργία των σχετικών μηχανισμών. Το μοντέλο λειτουργίας βασίζεται στην παροχή τριών βασικών υπηρεσιών εξισορρόπησης: πρωτογενούς, δευτερογενούς και τριτογενούς ελέγχου. Οι υπηρεσίες αυτές καλύπτουν ένα ευρύ φάσμα δράσεων, από την αυτόματη απόκριση σε αποκλίσεις συχνότητας έως και τη χειροκίνητη ενεργοποίηση διαθέσιμων πόρων σε περιπτώσεις σημαντικών ανισορροπιών [5].

Η Ισπανία συμμετέχει ενεργά στις ευρωπαϊκές πλατφόρμες για τον συντονισμό των αποθεμάτων δευτερογενούς και τριτογενούς ελέγχου, ενισχύοντας τη συνεργασία με τα υπόλοιπα κράτη-μέλη, σε συμμόρφωση με το ευρωπαϊκό ρυθμιστικό πλαίσιο για την εξισορρόπηση, όπως ορίζεται στον Κανονισμό (ΕΕ) 2017/2195. Στο πλαίσιο αυτό, η λειτουργία της αγοράς ακολουθεί αυστηρά καθορισμένα χρονικά πλαίσια, με τις τιμές ανισορροπίας να υπολογίζονται ανά 15 λεπτά, βάσει της διαφοράς μεταξύ προγραμματισμένης και πραγματικής παραγωγής ή κατανάλωσης. Για τον τριτογενή έλεγχο, οι συμμετέχοντες υποβάλλουν προσφορές έως και 45 λεπτά πριν την ώρα παράδοσης, ενώ η ενεργοποίηση και η τιμολόγηση πραγματοποιούνται λίγο πριν και κατά τη διάρκεια του χρονικού διαστήματος εξισορρόπησης. Η υφιστάμενη τεχνική υποδομή του Διαχειριστή υποστηρίζει πλήρως την ομαλή λειτουργία της αγοράς, σε συμμόρφωση με το ευρωπαϊκό κανονιστικό πλαίσιο [5],[8].

Παρότι η αγορά είναι θεσμικά εναρμονισμένη με τις ευρωπαϊκές οδηγίες, η λειτουργία της επηρεάζεται έντονα από τα δομικά χαρακτηριστικά του ισπανικού συστήματος. Η χαμηλή διασυνδεσιμότητα με το ευρωπαϊκό δίκτυο, που αντιστοιχεί μόλις στο 3% της εγκατεστημένης ισχύος, περιορίζει τις δυνατότητες διασυνοριακής εξισορρόπησης, αυξάνοντας την πολυπλοκότητα της διαχείρισης σε εθνικό επίπεδο. Επιπλέον, η Ισπανία καταγράφει υψηλή διείσδυση ανανεώσιμων

πηγών ενέργειας, με ποσοστά που ξεπέρασαν το 56% του ενεργειακού μείγματος το 2024. Η ασυνεχής και μη προβλέψιμη φύση της παραγωγής από ανανεώσιμες πηγές ενέργειας, σε συνδυασμό με την περιορισμένη δυνατότητα αποθήκευσης και την περιορισμένη ικανότητα ανταπόκρισης του συστήματος σε απότομες μεταβολές λειτουργίας, δημιουργούν προκλήσεις ως προς τη σταθερότητα και την ακρίβεια πρόβλεψης των τιμών εξισορρόπησης [3],[7].

Για την ενίσχυση της ευστάθειας του συστήματος, έχουν τεθεί συγκεκριμένοι στόχοι αύξησης της αποθηκευτικής ικανότητας, με την Ισπανία να προβλέπει την εγκατάσταση 22,5 GW έως το 2030, κυρίως μέσω συστημάτων αποθήκευσης ενέργειας με συσσωρευτές. Παράλληλα, προωθούνται τεχνολογίες έξυπνων δικτύων και τεχνητής αδράνειας, οι οποίες ενισχύουν την επιχειρησιακή σταθερότητα και ενσωματώνονται σταδιακά στη λειτουργία της αγοράς εξισορρόπησης, με στόχο τη μείωση των επιπτώσεων που προκαλούνται από τις απότομες και απρόβλεπτες διακυμάνσεις στην παραγωγή από ανανεώσιμες πηγές ενέργειας [9],[10].

2.3.3 Βέλγιο

Η αγορά εξισορρόπησης στο Βέλγιο εποπτεύεται από τον Διαχειριστή του Συστήματος Μεταφοράς, ο οποίος είναι αρμόδιος για τη διατήρηση της ισορροπίας μεταξύ προσφοράς και ζήτησης σε πραγματικό χρόνο. Το πλαίσιο λειτουργίας βασίζεται στην αρχή της καθαρής ρύθμισης, όπου οι συμμετέχοντες καλούνται να προσφέρουν ισχύ εξισορρόπησης μέσω εντολών ενεργοποίησης, οι οποίες διακρίνονται σύμφωνα με το επίπεδο ελέγχου σε πρωτογενή, δευτερογενή και τριτογενή – κατά τρόπο ανάλογο με τη δομή της Ισπανικής αγοράς εξισορρόπησης [5].

Η αποτελεσματικότητα της Βελγικής αγοράς ενισχύεται από τη συμμετοχή σε ευρωπαϊκές πλατφόρμες διασυννοριακού συντονισμού, στο πλαίσιο της ευρύτερης εναρμόνισης των αγορών εξισορρόπησης. Η υψηλή διασυνδεσιμότητα με γειτονικά κράτη, όπως η Γαλλία, η Ολλανδία και η Γερμανία, επιτρέπει τη βελτιστοποίηση της εξισορρόπησης μέσω κοινών διακρατικών μηχανισμών και συμβάλλει στη μείωση του κόστους. Επιπλέον, η αγορά χαρακτηρίζεται από υψηλό επίπεδο διαφάνειας, καθώς δημοσιεύονται σε πραγματικό χρόνο δεδομένα σχετικά με τις ενεργοποιήσεις, τις προσφορές και τις τιμές, διευκολύνοντας την παρακολούθηση και την ανάλυση [5]. Οι τιμές ανισορροπίας υπολογίζονται ανά δεκαπεντάλεπτο και διαμορφώνονται από τη ζήτηση για εξισορρόπηση, τη διαθεσιμότητα των μονάδων και τις τιμές των προσφορών. Επιπλέον, εφαρμόζονται ρυθμιστικοί μηχανισμοί, όπως κατώτατα όρια ενεργοποίησης και φίλτρα αποδοχής, με σκοπό τη διασφάλιση της εύρυθμης λειτουργίας της αγοράς [5].

Αν και το ποσοστό συμμετοχής των ανανεώσιμων πηγών ενέργειας στο ενεργειακό μείγμα του Βελγίου είναι χαμηλότερο από άλλες ευρωπαϊκές χώρες, η αυξανόμενη διείσδυση τους εντείνει την αβεβαιότητα στην παραγωγή. Έτσι, η χρήση αξιόπιστων μοντέλων πρόβλεψης αποκτά αυξανόμενη σημασία. Οι διακυμάνσεις στην παραγωγή, σε συνδυασμό με τις μεταβαλλόμενες ανάγκες του συστήματος, καθιστούν την πρόβλεψη των τιμών εξισορρόπησης κρίσιμο εργαλείο για την επιχειρησιακή σταθερότητα [2]. Σε αυτό το πλαίσιο, έχουν προταθεί στοχαστικά μοντέλα που βασίζονται στην ανάλυση των καθαρών ποσοτήτων εξισορρόπησης, δηλαδή των μεταβολών στην απαιτούμενη ενέργεια που χρειάζεται ώστε να εξασφαλιστεί η ισορροπία μεταξύ παραγωγής και ζήτησης. Οι μέθοδοι αυτές επιτυγχάνουν μεγαλύτερη ακρίβεια από τις κλασικές τεχνικές, ιδιαίτερα σε συνθήκες υψηλής μεταβλητότητας, και προσφέρουν ουσιαστική υποστήριξη στην κατανόηση και πρόβλεψη της συμπεριφοράς της αγοράς [6].

2.4 ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΚΑΙ ΠΡΟΚΛΗΣΕΙΣ ΠΡΟΒΛΕΨΗΣ ΤΩΝ ΤΙΜΩΝ ΣΤΗΝ ΑΓΟΡΑ ΕΞΙΣΟΡΡΟΠΗΣΗΣ

Η ανάλυση των αγορών εξισορρόπησης σε διαφορετικές ευρωπαϊκές χώρες αναδεικνύει τόσο τις διαφοροποιήσεις στον σχεδιασμό και τη λειτουργία, όσο και μια σειρά από κοινές προκλήσεις. Παρά τις διαφορές στη γεωγραφική θέση, στο ποσοστό διείσδυσης ανανεώσιμων πηγών ενέργειας ή στον βαθμό διασύνδεσης με γειτονικά συστήματα, παρατηρούνται επαναλαμβανόμενα μοτίβα σε τεχνικό, κανονιστικό και επιχειρησιακό επίπεδο. Η προώθηση της ενοποίησης των εθνικών αγορών σε ευρωπαϊκές πλατφόρμες και η αυξανόμενη πολυπλοκότητα των σύγχρονων δικτύων διαμορφώνουν ένα ιδιαίτερα απαιτητικό περιβάλλον, στο οποίο η αξιόπιστη διαχείριση και πρόβλεψη των τιμών εξισορρόπησης καθίσταται καθοριστική [11]. Οι αγορές εξισορρόπησης βασίζονται σε πολυεπίπεδους μηχανισμούς ελέγχου και λειτουργούν σε χρονικά διαστήματα που κυμαίνονται από λίγα έως 30 λεπτά πριν την παράδοση. Εφαρμόζονται διαφοροποιημένα σχήματα αποζημίωσης και μηχανισμοί εκκαθάρισης ανά χώρα, ενώ οι τιμές εξισορρόπησης διαμορφώνονται με βάση τη ζήτηση, τις προσφορές και τις ρυθμιστικές παραμέτρους. Η συμμετοχή σε κοινές ευρωπαϊκές πλατφόρμες ενισχύει τη διασυννοιακή συνεργασία και την εναρμόνιση των κανόνων, με τη διαλειτουργικότητα και την ευθυγράμμιση των εθνικών συστημάτων να συνιστούν θεμελιώδεις παράγοντες για την ασφάλεια εφοδιασμού και τη συστημική σταθερότητα [11].

Παρά τις προσπάθειες σύγκλισης, οι αγορές εξισορρόπησης αντιμετωπίζουν παρόμοιες δυσχέρειες, κυρίως σε σχέση με την πρόβλεψη των τιμών. Η αυξημένη διείσδυση των ανανεώσιμων πηγών ενέργειας εντείνει τη μεταβλητότητα και περιορίζει την προβλεψιμότητα σε επιχειρησιακό χρόνο, επιβαρύνοντας τη διαδικασία τιμολόγησης. Χώρες με περιορισμένες διασυνδέσεις, όπως η Ιρλανδία και η Ισπανία, εξαρτώνται σε μεγαλύτερο βαθμό από εσωτερικούς μηχανισμούς εξισορρόπησης, ενώ οι διαφορές στα ρυθμιστικά πλαίσια δυσχεραίνουν την ανάπτυξη ενιαίων μεθοδολογιών. Ταυτόχρονα, οι απαιτήσεις για δεδομένα υψηλής χρονικής ανάλυσης και η ανάγκη διαχείρισης της αβεβαιότητας καθιστούν απαραίτητη τη χρήση προηγμένων προσεγγίσεων. Η περιορισμένη αποτελεσματικότητα των γραμμικών μοντέλων έχει οδηγήσει στην υιοθέτηση στοχαστικών, μη γραμμικών και υβριδικών μοντέλων, προσαρμοσμένων στις ιδιαιτερότητες κάθε αγοράς [12]. Ωστόσο, η αξιοπιστία αυτών των προσεγγίσεων εξαρτάται σε μεγάλο βαθμό από την ποιότητα και τη διαθεσιμότητα των απαιτούμενων δεδομένων. Σε αρκετές περιπτώσεις, οι πληροφορίες που αφορούν τις τιμές εξισορρόπησης, τις εντολές ενεργοποίησης ή τα διαθέσιμα αποθέματα δεν είναι συστηματικά δημοσιευμένες, παρουσιάζουν καθυστερήσεις ή διαφέρουν ως προς τη μορφή και τη συχνότητα καταγραφής μεταξύ των χωρών. Οι ασυνέπειες αυτές δυσκολεύουν τη δημιουργία ενοποιημένων και συγκρίσιμων βάσεων δεδομένων, περιορίζοντας τη δυνατότητα γενίκευσης των συμπερασμάτων που προκύπτουν από τα εκάστοτε μοντέλα πρόβλεψης.

Η αντιμετώπιση των παραπάνω προκλήσεων απαιτεί την υιοθέτηση κατάλληλων μεθοδολογικών προσεγγίσεων και την αξιοποίηση ποιοτικών δεδομένων. Στο Κεφάλαιο 3 παρουσιάζεται το σύνολο των δεδομένων που χρησιμοποιήθηκε στην παρούσα διπλωματική εργασία, η διαδικασία προεπεξεργασίας τους, καθώς και η μεθοδολογία που ακολουθήθηκε για την εκπαίδευση και αξιολόγηση των προβλεπτικών μοντέλων.

ΔΕΔΟΜΕΝΑ ΚΑΙ ΠΡΟΕΠΕΞΕΡΓΑΣΙΑ

3.1 ΕΙΣΑΓΩΓΗ


Η πρόβλεψη των τιμών εξισορρόπησης αποτελεί κρίσιμο εργαλείο για τη διαχείριση των ηλεκτρικών συστημάτων, ιδιαίτερα σε συνθήκες υψηλής μεταβλητότητας που απορρέουν από την αυξημένη διείσδυση μεταβλητών ανανεώσιμων πηγών ενέργειας. Η ανάγκη για βραχυπρόθεσμη ακρίβεια, ταχύτητα απόκρισης και διαχείριση της αβεβαιότητας καθιστούν την εξισορρόπηση ένα από τα πλέον απαιτητικά πεδία πρόβλεψης στο πλαίσιο των αγορών ηλεκτρικής ενέργειας [2],[12]. Όπως αναδείχθηκε στο Κεφάλαιο 2, οι ευρωπαϊκές αγορές εξισορρόπησης χαρακτηρίζονται από διαφοροποιήσεις σε τεχνικό και ρυθμιστικό επίπεδο, γεγονός που περιπλέκει την εφαρμογή καθολικών προσεγγίσεων πρόβλεψης. Η ανάπτυξη αξιόπιστων μεθοδολογιών προϋποθέτει την κατανόηση των τοπικών ιδιοτήτων, καθώς και τη διασφάλιση της συνέπειας, της πληρότητας και της ποιότητας των απαιτούμενων δεδομένων. Η συχνά περιορισμένη διαθεσιμότητα, η χρονική υστέρηση ή η ετερογένεια στη μορφή και τη συχνότητα των δεδομένων ανά χώρα επιβάλλουν συγκεκριμένες ενέργειες ελέγχου ποιότητας και διόρθωσης, συγχρονισμού και επιλογής μεταβλητών για τον σχηματισμό κατάλληλων συνόλων εισόδου [5],[11].

Το παρόν κεφάλαιο παρουσιάζει τη μεθοδολογική προσέγγιση που ακολουθήθηκε για την πρόβλεψη των τιμών στην αγορά εξισορρόπησης, εστιάζοντας στη διαμόρφωση του πλαισίου πρόβλεψης, την προεπεξεργασία των δεδομένων και τον καθορισμό των χαρακτηριστικών εισόδου. Τα υποκείμενα μαθηματικά ή υπολογιστικά μοντέλα πρόβλεψης αναλύονται σε μεταγενέστερο στάδιο της μελέτης. Αρχικά, το Σχήμα 3.1 παρουσιάζει, με τη χρήση διαγράμματος ροής, τη συνολική προσέγγιση που υιοθετήθηκε για την πρόβλεψη και την αξιολόγηση των αποτελεσμάτων. Στη συνέχεια, περιγράφονται οι πηγές και το περιεχόμενο των δεδομένων, καθώς και τα υποσύνολα που κατασκευάστηκαν με ενιαία μεθοδολογία για όλες τις χώρες ανάλυσης. Ακολουθεί η επιλογή των μεταβλητών εισόδου και η διατύπωση του προβλήματος πρόβλεψης, με βάση τον χρονικό ορίζοντα και το πλήθος των προηγούμενων χρονικών βημάτων που χρησιμοποιούνται για τον υπολογισμό των επόμενων τιμών. Τέλος, παρουσιάζονται τα στάδια καθαρισμού, μετασχηματισμού και χρονικής ευθυγράμμισης των δεδομένων, με στόχο τη δημιουργία ενός συνεκτικού και αξιοποιήσιμου συνόλου εισόδου για τα μοντέλα εκπαίδευσης.

3.2 ΜΕΘΟΔΟΛΟΓΙΑ ΠΡΟΒΛΕΨΗΣ ΚΑΙ ΑΞΙΟΛΟΓΗΣΗΣ

Στην παρούσα ενότητα περιγράφεται η ενιαία ροή εργασιών, που υλοποιήθηκε για την πρόβλεψη των τιμών εξισορρόπησης και την αξιολόγηση της απόδοσης των μοντέλων, και παρουσιάζεται στο Σχήμα 3.1. Αρχικά, αντλούνται τα πρωτογενή δεδομένα από το Ευρωπαϊκό Δίκτυο Διαχειριστών

Συστημάτων Μεταφοράς Ηλεκτρικής Ενέργειας (ENTSO-E), τα οποία στη συνέχεια υποβάλλονται σε προεπεξεργασία [15]. Κατόπιν γίνεται επιλογή των χαρακτηριστικών εισόδου και του στόχου πρόβλεψης, ενώ το πλήρες σύνολο διαχωρίζεται σε μηνιαία υποσύνολα και περαιτέρω σε σύνολα εκπαίδευσης και αξιολόγησης. Εντός κάθε υποσυνόλου σχηματίζονται διαδοχικά ιστορικές χρονοσειρές εισόδου και εξόδου για την εκπαίδευση του μοντέλου και την εξαγωγή προβλέψεων στο σύνολο αξιολόγησης. Τέλος, οι προβλέψεις συγκρίνονται με τις πραγματικές τιμές και η απόδοση μετράται μέσω κατάλληλων δεικτών σφάλματος, εξασφαλίζοντας ενιαία αξιολόγηση και δυνατότητα σύγκρισης των αποτελεσμάτων.



Σχήμα 3.1: Συνοπτικό διάγραμμα ροής της μεθοδολογίας πρόβλεψης και αξιολόγησης

3.3 ΠΗΓΕΣ ΚΑΙ ΠΡΟΕΠΕΡΓΑΣΙΑ ΔΕΔΟΜΕΝΩΝ

Μετά την παρουσίαση της ροής εργασιών στην Ενότητα 3.2, η παρούσα ενότητα εστιάζει στην συλλογή και την αρχική επεξεργασία των δεδομένων πριν από τη διαμόρφωσή τους σε σύνολα εκπαίδευσης και αξιολόγησης. Η άντληση πραγματοποιήθηκε από τον ENTSO-E, το Ευρωπαϊκό Δίκτυο Διαχειριστών Συστημάτων Μεταφοράς Ηλεκτρικής Ενέργειας, που θεσπίστηκε με τον Κανονισμό (ΕΚ) 714/2009 για τη διαλειτουργικότητα και τη διαφάνεια των εθνικών δικτύων μεταφοράς ενέργειας. Η διαδικτυακή πλατφόρμα του ENTSO-E παρέχει πλήρη δεδομένα τιμών ημερήσιας αγοράς και εξισορρόπησης, φορτίων, παραγωγής από θερμικές μονάδες, υδροηλεκτρικά και ΑΠΕ, καθώς και διασυνοριακών ροών, σύμφωνα με τον Κανονισμό (ΕΕ) 2019/943 για τη διασφάλιση ποιότητας και επικαιροποίησης [13],[14].

Το αντίστοιχο προγραμματιστικό περιβάλλον (API) παρέχει σε μισάωρα διαστήματα άμεση πρόσβαση σε ιστορικά και τρέχοντα δεδομένα, διασφαλίζοντας συνεχείς ενημερώσεις και ενιαία δομή που επιτρέπει την πλήρη αναπαραγωγή της διαδικασίας εξαγωγής και επεξεργασίας δεδομένων. Αυτή η υποδομή καθιστά τον ENTSO-E την πλέον ενδεδειγμένη πηγή για τη μελέτη βραχυπρόθεσμων προβλέψεων τιμών ενέργειας σε ευρωπαϊκό επίπεδο [15].

Η άντληση των δεδομένων πραγματοποιήθηκε αυτοματοποιημένα για κάθε χώρα, μέσω εντολών προς το διαδικτυακό περιβάλλον του ENTSO-E, αξιοποιώντας την ειδική βιβλιοθήκη EntsoePandasClient. Συλλέχθηκαν χρονοσειρές που περιλαμβάνουν τόσο πραγματικές μετρήσεις, όσο και εκτιμήσεις για κρίσιμες παραμέτρους της λειτουργίας και της αγοράς ηλεκτρικής ενέργειας, οι οποίες είναι απαραίτητες για την περιγραφή της κατάστασης του συστήματος και την πρόβλεψη της τιμής εξισορρόπησης. Οι βασικές μεταβλητές που συγκεντρώθηκαν περιγράφονται συνοπτικά παρακάτω:

- Τιμή εκκαθάρισης επόμενης ημέρας (€/MWh): Ο βασικός δείκτης του βραχυπρόθεσμου κόστους ενέργειας
- Τιμή ηλεκτρικής ενέργειας στη αγορά εξισορρόπησης (€/MWh): Τιμή ηλεκτρικής ενέργειας για τη διόρθωση αποκλίσεων προσφοράς-ζήτησης σε πραγματικό χρόνο
- Πρόβλεψη φορτίου (MW): Προσδιορισμός της αναμενόμενης κατανάλωσης ηλεκτρικής ενέργειας σε κάθε διακριτό χρονικό διάστημα του επόμενου 24ώρου
- Μετρούμενη ζήτηση (MW): Πραγματική κατανάλωση του ηλεκτρικού συστήματος
- Πρόβλεψη συνολικής παραγωγής (MW): Εκτίμηση παραγόμενης ισχύος από όλες τις μονάδες
- Καταγεγραμμένη παραγωγή (MW): Η μετρούμενη ισχύς που παρήχθη στο δίκτυο
- Πρόβλεψη παραγωγής από ΑΠΕ (MW): Εκτίμηση παραγωγής από ΑΠΕ, όπως αιολικά και φωτοβολταϊκά πάρκα
- Καταγεγραμμένη παραγωγή από ΑΠΕ (MW): Πραγματική ισχύς που παρήχθη από ανανεώσιμες πηγές ενέργειας
- Διασυνοριακές ροές (MW): Καθαρές ροές ισχύος μεταξύ γειτονικών χωρών

Πίνακας 3.1 : Διαθεσιμότητα και πληρότητα δεδομένων ENTSO-E ανά έτος και χώρα

Έτος	Χώρα		
	Ιρλανδία	Ισπανία	Βέλγιο
2020	Δεν είναι διαθέσιμα δεδομένα τιμής εξισορρόπησης έως 18/6.	Δεν είναι διαθέσιμα δεδομένα για τις διασυνοριακές ροές έως 11/8.	Πλήρη δεδομένα
2021	Δεν είναι διαθέσιμα δεδομένα τιμής εξισορρόπησης από 12/12 έως 31/12.	Πλήρη δεδομένα	Πλήρη δεδομένα
2022	Διαθέσιμα δεδομένα τιμής εξισορρόπησης από 23/3	Πλήρη δεδομένα	Διαθέσιμα δεδομένα τιμής εξισορρόπησης ανά 30 λεπτά έως 23/5 , ανά 1 ώρα από 23/5 και έπειτα
2023	Διαθέσιμα δεδομένα τιμής εξισορρόπησης από 1/3	Πλήρη δεδομένα	Πλήρη δεδομένα

Στο πλαίσιο της αγοράς εξισορρόπησης διακρίνονται δύο διακριτές κατηγορίες τιμών, ανάλογα με τη φύση της απόκλισης μεταξύ προσφοράς και ζήτησης. Η πρώτη αφορά την τιμή σε περίπτωση έλλειψης ισχύος, η οποία ενεργοποιείται όταν η διαθέσιμη παραγωγή δεν επαρκεί για την κάλυψη της ζήτησης και απαιτείται είτε η επιπλέον ενεργοποίηση μονάδων, είτε η μείωση της κατανάλωσης. Αντίστοιχα, η δεύτερη αφορά την τιμή σε συνθήκες πλεονάσματος ισχύος, όταν δηλαδή η προσφερόμενη ενέργεια υπερβαίνει τη ζήτηση, καθιστώντας αναγκαία είτε τη μείωση της παραγωγής, είτε την απορρόφηση της πλεονάζουσας ισχύος.

Παράλληλα, η λειτουργία των διασυνοριακών διασυνδέσεων θεωρείται κρίσιμη για τη ευστάθεια του συστήματος. Για την Ισπανία παρακολουθούνται οι ροές ισχύος προς την Πορτογαλία και τη Γαλλία, για το Βέλγιο προς την Ολλανδία, τη Γερμανία και το Λουξεμβούργο, ενώ για την Ιρλανδία προς το Ηνωμένο Βασίλειο. Όλα τα δεδομένα για το έτος 2021 εμφάνιζαν πληρότητα άνω του 95% σε σύγκριση με άλλες χρονιές, όπως φαίνεται στον Πίνακα 3.1. Αυτό οδήγησε στην επιλογή του 2021 ως έτους μελέτης της παρούσας διπλωματικής εργασίας. Κατόπιν, όλα τα σύνολα χρονοσειρών υποβλήθηκαν σε κοινή επεξεργασία, η οποία περιλάμβανε:

- Προσαρμογή σε κοινή ζώνη ώρας: Μετατροπή όλων των χρονοσειρών στην τοπική ώρα Δουβλίνου, ώστε να εξασφαλίζεται ενιαίο χρονολογικό πλαίσιο για όλες τις χώρες.

- Καθορισμό κοινής χρονικής συχνότητας δεδομένων: Αναπροσαρμογή όλων των χρονοσειρών ώστε να καταγράφονται σταθερά ανά ημίωρο μέσω αναδειγματολειτουργίας.
- Ομαδοποίηση δεδομένων: Οι τιμές ομαδοποιήθηκαν κατά ημερομηνία, ώρα, λεπτό και μήνα, δημιουργώντας μια συνεκτική δομή για την περαιτέρω ανάλυση.
- Οργάνωση σε ενιαίο πλαίσιο δεδομένων: Όλες οι μεταβλητές εισόδου συγκεντρώθηκαν σε ένα κοινό πίνακα μέσω διαδοχικών ενώσεων, χρησιμοποιώντας κοινά χρονικά κλειδιά (ημερομηνία, ώρα, λεπτό, μήνας). Αυτό εξασφάλισε ότι κάθε χρονικό στιγμιότυπο περιλαμβάνει πλήρες σύνολο πληροφοριών.
- Συμπλήρωση ελλειπόν τιμών: Μετά τη συγχώνευση, τυχούσες απουσίες στις προβλεπόμενες τιμές φορτίου, παραγωγής και ΑΠΕ αναπληρώθηκαν με τις αντίστοιχες πραγματικές τιμές. Για τα υπόλοιπα κενά εφαρμόστηκε γραμμική παρεμβολή, ώστε να διατηρηθεί η συνέχεια των χρονοσειρών.

Η υλοποίηση των παραπάνω βημάτων επιτυγχάνεται μέσω της συνάρτησης `process_data`, η οποία παρουσιάζεται στο Σχήμα 3.2. Η συνάρτηση αυτή εφαρμόζει την απαραίτητη μετατροπή στη σωστή χρονική ζώνη, προσαρμόζει τα δεδομένα σε σταθερή χρονική ανάλυση ημίωρου και οργανώνει τις χρονοσειρές με βάση βασικά χρονικά χαρακτηριστικά (ημερομηνία, ώρα, λεπτό και μήνα). Αντίθετα, η συμπλήρωση των κενών τιμών πραγματοποιείται σε επόμενο στάδιο, κατά τη φάση συγχώνευσης των επιμέρους συνόλων δεδομένων.

```
def process_data(df, new_name):
    if not isinstance(df, pd.DataFrame):
        df = df.to_frame()
    df.index = pd.to_datetime(df.index, utc=True).tz_convert('Europe/Dublin')
    df = df.rename(columns={df.columns[0]: new_name})
    df['Date'] = df.index.date
    df['Hour'] = df.index.hour
    df['Minute'] = df.index.minute # Προσθήκη στήλης για τα λεπτά
    df['Month'] = df.index.month # Προσθήκη στήλης με τον μήνα
    df_final = df.groupby(['Date', 'Hour', 'Minute', 'Month'], as_index=False).mean()
    return df_final
```

Σχήμα 3.2 : Κώδικας σε Python για την προεπεξεργασία των χρονοσειρών, μέσω της συνάρτησης `process_data`

Στη συνέχεια, η δημιουργία του ενιαίου πλαισίου δεδομένων επιτυγχάνεται με τη διαδοχική συγχώνευση των επιμέρους χρονοσειρών, χρησιμοποιώντας ως κοινά κλειδιά τις στήλες ημερομηνίας, ώρας, λεπτού και μήνα. Όπως απεικονίζεται στο Σχήμα 3.3, εφαρμόζεται σειρά ενώσεων μέσω της συνάρτησης `merge`, ώστε να συγκεντρωθούν όλες οι βασικές μεταβλητές (τιμή αγοράς επόμενης ημέρας, φορτίο, προβλέψεις παραγωγής και κατανάλωσης, παραγωγή από ΑΠΕ, διασυννοριακές ροές και τιμές εξισορρόπησης) σε ένα ενιαίο σύνολο, έτοιμο για την επόμενη φάση ανάλυσης.

```

input_data_raw = pd.merge(DAM_prices, actual_load, on=['Date', 'Hour', 'Month'], how='left')
input_data_raw = pd.merge(input_data_raw, forecast_load, on=['Date', 'Hour', 'Month'], how='left')
input_data_raw = pd.merge(input_data_raw, actual_gen_tot, on=['Date', 'Hour', 'Month'], how='left')
input_data_raw = pd.merge(input_data_raw, forecast_generation, on=['Date', 'Hour', 'Month'], how='left')
input_data_raw = pd.merge(input_data_raw, actual_RES, on=['Date', 'Hour', 'Month'], how='left')
input_data_raw = pd.merge(input_data_raw, forecast_RES, on=['Date', 'Hour', 'Month'], how='left')
input_data_raw = pd.merge(input_data_raw, net_flows_dataframe, on=['Date', 'Hour', 'Month'], how='left')
input_data_raw = pd.merge(input_data_raw, bm_prices, on=['Date', 'Hour', 'Month'], how='left') # Merge BM prices

```

Σχήμα 3.3: Κώδικας σε Python για τη συγχώνευση επιμέρους πινάκων δεδομένων μέσω διαδοχικών ενώσεων (merge)

Μετά την ολοκλήρωση αυτής της διαδικασίας, πραγματοποιείται η συμπλήρωση των υπολειπόμενων ελλειπόν τιμών. Πιο συγκεκριμένα, όπως φαίνεται στο Σχήμα 3.4, εφαρμόζεται αντικατάσταση των κενών τιμών στις προβλεπόμενες μεταβλητές με τις αντίστοιχες πραγματικές μετρήσεις, μέσω της εντολής `fillna()`. Στη συνέχεια, για την κάλυψη τυχόντων υπολειπόμενων κενών σε οποιαδήποτε στήλη του πίνακα `inputdata`, εφαρμόζεται γραμμική παρεμβολή με χρήση της μεθόδου `interpolate(method='linear', axis=0)`, διασφαλίζοντας τη συνέχεια και τη χρηστικότητα των χρονοσειρών.

```

input_data = input_data_raw.copy()
input_data['Demand Forecast (MW)'] = input_data['Demand Forecast (MW)'].fillna(input_data['Actual Demand (MW)'])
input_data['Generation Forecast (MW)'] = input_data['Generation Forecast (MW)'].fillna(input_data['Actual Generation (MW)'])
input_data['RES Forecast (MW)'] = input_data['RES Forecast (MW)'].fillna(input_data['Actual RES (MW)'])

input_data = input_data.interpolate(method='linear', axis=0)

```

Σχήμα 3.4: Κώδικας σε Python για τη συμπλήρωση ελλειπόν τιμών με χρήση πραγματικών μετρήσεων και γραμμικής παρεμβολής

Μετά την ολοκλήρωση της προεπεξεργασίας τα δεδομένα είναι έτοιμα για τον καθορισμό των χαρακτηριστικών εισόδου και του στόχου πρόβλεψης. Στην Ενότητα 3.4 αναλύεται η διαδικασία επιλογής των χαρακτηριστικών εισόδου και η διατύπωση του προβλήματος πρόβλεψης.

3.4 ΜΕΤΑΒΛΗΤΕΣ ΕΙΣΟΔΟΥ ΚΑΙ ΣΤΟΧΟΣ ΠΡΟΒΛΕΨΗΣ

Η ακρίβεια των προβλέψεων εξαρτάται από την κατάλληλη διαμόρφωση του στόχου και των μεταβλητών εισόδου. Ως στόχος ορίστηκε η τιμή εξισορρόπησης σε συνθήκη υπερπροσφοράς ισχύος, καθώς αντανακλά το κόστος διάθεσης πλεονάζουσας ενέργειας και είναι εγκαίρως διαθέσιμη μέσω της πλατφόρμας. Τα χαρακτηριστικά εισόδου επιλέχθηκαν με γνώμονα την επιχειρησιακή τους σημασία, την άμεση διαθεσιμότητα τη στιγμή της πρόβλεψης και την ομοιογένεια σε κάθε χώρα μελέτης. Συγκεκριμένα χρησιμοποιήθηκαν:

- Χρονική στιγμή ημέρας (σε λεπτά): Αριθμός λεπτών από την αρχή κάθε ημέρας (0–1439), που επιτρέπει την αξιοποίηση των επαναλαμβανόμενων ημερήσιων μοτίβων ζήτησης (π.χ. τις πρωινές και απογευματινές αιχμές).

- Πρόβλεψη ζήτησης (MW): Εκτίμηση της ζήτησης για κάθε μισάωρο, δημοσιευμένη από τον Διαχειριστή Συστήματος
- Πρόβλεψη συνολικής παραγωγής (MW): Εκτίμηση ισχύος από το σύνολο των μονάδων
- Πρόβλεψη παραγωγής από ΑΠΕ (MW): Εκτίμηση παραγωγής από αιολικά και φωτοβολταϊκά πάρκα
- Διασυνοριακές ροές (MW): Εκτιμημένες καθαρές ροές ισχύος μεταξύ γειτονικών χωρών
- Τιμή εξισορρόπησης λόγω πλεονάσματος ισχύος (MW): Τιμή εξισορρόπησης σε συνθήκη υπερπροσφοράς ισχύος, ως δείκτης πίεσης στην αγορά

Επιπλέον, η επιλογή των συγκεκριμένων μεταβλητών βασίστηκε στην πρακτική διαθεσιμότητά τους τη στιγμή που απαιτείται η εκτέλεση της πρόβλεψης. Όλες οι τιμές πρόβλεψης φορτίου, παραγωγής και διασυνοριακών ροών δημοσιεύονται στον ENTSO-E καθημερινά με ημωριαία ανάλυση, ενώ οι πραγματικές μετρήσεις καθίστανται διαθέσιμες με σχετική καθυστέρηση. Με αυτόν τον τρόπο διασφαλίζεται ότι, κατά την εφαρμογή του μοντέλου, όλα τα δεδομένα εισόδου είναι ήδη γνωστά και προσβάσιμα μέσω της πλατφόρμας, επιτρέποντας μια ακριβή και συνεπή διαδικασία πρόβλεψης.

3.5 ΔΟΜΗ ΣΥΝΟΛΩΝ ΕΚΠΑΙΔΕΥΣΗΣ ΚΑΙ ΑΞΙΟΛΟΓΗΣΗΣ

Μετά την επιλογή των μεταβλητών εισόδου και του στόχου πρόβλεψης, το επόμενο στάδιο αφορά στη διάρθρωση των δεδομένων με τρόπο που να επιτρέπει την αποτελεσματική εκπαίδευση και αξιολόγηση των μοντέλων. Η διαδικασία αυτή περιλαμβάνει την οργάνωση των τιμών σε ιστορικές ακολουθίες σταθερού μήκους, οι οποίες χρησιμοποιούνται τόσο στη φάση εκπαίδευσης, όσο και στην παραγωγή προβλέψεων. Η υλοποίηση της διαδικασίας πραγματοποιείται μέσω της βασικής βοηθητικής συνάρτησης `create_batches`, η οποία παρουσιάζεται στο Σχήμα 3.5.

Η συνάρτηση αυτή δέχεται ως είσοδο τα δεδομένα ενός μήνα και κατασκευάζει διαδοχικά σύνολα εισόδων και στόχου πρόβλεψης, χωρισμένα σε σύνολα εκπαίδευσης και αξιολόγησης βάσει ιστορικών χρονικών διαστημάτων. Απευθύνεται σε πολυμεταβλητά μοντέλα, όπου η είσοδος αποτελείται από πολλαπλές μεταβλητές που σχηματίζουν έναν πίνακα εισόδων για κάθε χρονικό παράθυρο. Στην περίπτωση μονομεταβλητών μοντέλων, η είσοδος για την εκπαίδευση του μοντέλου αντιστοιχεί σε μία μόνο χρονοσειρά τιμών του στόχου πρόβλεψης, η οποία λαμβάνεται από το ιστορικό διάστημα εκπαίδευσης. Σε κάθε περίπτωση, ο σκοπός της συνάρτησης είναι να ευθυγραμμίσει κατάλληλα τα δεδομένα ώστε να τροφοδοτήσουν με συνέπεια τη διαδικασία εκπαίδευσης και τη μετέπειτα παραγωγή προβλέψεων.

Τα δεδομένα κάθε χώρας διαχωρίζονται αρχικά σε σύνολα ανά ημερολογιακό μήνα. Κάθε μηνιαίο υποσύνολο περιλαμβάνει τιμές σε χρονική ανάλυση ανά 30 λεπτά, δηλαδή σε διακριτά χρονικά σημεία με συχνότητα ημώρου. Από το πλήρες αυτό σύνολο, το πρώτο 80% των χρονικών στιγμών χρησιμοποιείται για τη φάση εκπαίδευσης, ενώ το υπόλοιπο 20% χρησιμοποιείται αποκλειστικά για την αξιολόγηση. Για να είναι δυνατή η ενιαία χρονική οργάνωση όλων των μεταβλητών, δημιουργείται μία επιπλέον στήλη `Timestamp`, η οποία ενώνει τις στήλες ημερομηνίας,

ώρας και λεπτού σε μία ενιαία χρονική μεταβλητή. Η υλοποίηση αυτής της διαδικασίας παρουσιάζεται στο Σχήμα 3.6.

```
def create_batches(df_month, window_size):
    total_len = len(df_month)
    train_len = int(total_len * 0.8)

    df_X = df_month[FEATURE_COLS].values
    df_Y = df_month["BM Price (Euros/MWh)"].values
    timestamps = df_month.index

    X_train, Y_train, X_test, Y_test, TS_test, X_train_debug, X_test_debug = [], [], [], [], [], [], []

    for i in range(0, train_len - window_size - FORECAST_HORIZON + 1, FORECAST_HORIZON):
        X_window = df_X[i:i+window_size]
        X_train.append(X_window)
        X_train_debug.append((timestamps[i:i+window_size], X_window))
        Y_train.append(df_Y[i:i+window_size])

    for i in range(train_len - window_size, total_len - window_size - FORECAST_HORIZON + 1, FORECAST_HORIZON):
        X_window = df_X[i:i+window_size]
        X_test.append(X_window)
        X_test_debug.append((timestamps[i:i+window_size], X_window))
        Y_test.append(df_Y[i+window_size:i+window_size+FORECAST_HORIZON])
        TS_test.append(timestamps[i+window_size:i+window_size+FORECAST_HORIZON])

    print(f"✅ Batches: X_train={len(X_train)}, X_test={len(X_test)}")

    print("\n🟢 Χρονικά διαστήματα TRAIN batches:")
    for i, (ts_range, _) in enumerate(X_train_debug):
        print(f"🟢 Batch {i+1}: X = {ts_range[0]} → {ts_range[-1]}")

    print("\n🟠 Χρονικά διαστήματα TEST batches:")
    for i, (ts_range, _) in enumerate(X_test_debug):
        print(f"🟠 Batch {i+1}: X = {ts_range[0]} → {ts_range[-1]}")
        print(f"🟠 Batch {i+1}: Y = {TS_test[i][0]} → {TS_test[i][-1]}")

    return np.array(X_train), np.array(Y_train), np.array(X_test), np.array(Y_test), TS_test, X_train_debug, X_test_debug
```

Σχήμα 3.5: Κώδικας σε Python της συνάρτησης create_batches για τη δημιουργία χρονικών ακολουθιών εισόδου και στόχου

```
df["Timestamp"] = pd.to_datetime(
    df["Date"] + " " + df["Hour"].astype(str).str.zfill(2) + ":" +
    df["Minute"].astype(str).str.zfill(2)
)
df.set_index("Timestamp", inplace=True)
```

Σχήμα 3.6: Κώδικας σε Python για τη δημιουργία της χρονικής μεταβλητής Timestamp και ορισμού της ως δείκτη χρονοσειράς

Για τη διαμόρφωση των συνόλων εκπαίδευσης και αξιολόγησης, εφαρμόζεται μία ενιαία διαδικασία που κατασκευάζει διαδοχικές χρονικές ακολουθίες. Κάθε τέτοια ακολουθία εισόδου αποτελείται από ένα ιστορικό χρονικό διάστημα σταθερού μήκους, το οποίο αντιστοιχεί σε 48, 72, 96, 144 ή 336 ημίωρα, δηλαδή σε μία, μιάμιση, δύο, τρεις ή επτά πλήρεις ημέρες. Για κάθε ιστορική ακολουθία εισόδου, ορίζεται στη συνέχεια και ένα μελλοντικό χρονικό διάστημα πρόβλεψης, που έχει πάντα διάρκεια οκτώ ωρών και αντιστοιχεί σε 16 διαδοχικά ημίωρα. Οι ιστορικές ακολουθίες

εισόδου από το σύνολο εκπαίδευσης αποθηκεύονται στο σύνολο X_{train} , ενώ οι αντίστοιχες τιμές του στόχου αποθηκεύονται στο Y_{train} . Αντίστοιχα, οι ακολουθίες από το σύνολο αξιολόγησης συγκεντρώνονται στα σύνολα X_{test} και Y_{test} . Το X_{train} και το X_{test} περιλαμβάνουν τις ακολουθίες εισόδου, δηλαδή τις μεταβλητές χαρακτηριστικών που έχουν επιλεχθεί, ενώ το Y_{train} και το Y_{test} περιλαμβάνουν τις πραγματικές τιμές της τιμής εξισορρόπησης για κάθε χρονικό διάστημα εκπαίδευσης και πρόβλεψης, αντίστοιχα. Οι προβλεπόμενες τιμές που παράγει το εκπαιδευμένο μοντέλο αποθηκεύονται ξεχωριστά στο σύνολο Y_{pred} , το οποίο δεν προκύπτει κατά τη φάση δημιουργίας των υποσυνόλων εισόδου και εξόδου, αλλά παράγεται μεταγενέστερα στο στάδιο πρόβλεψης. Η διαδικασία πρόβλεψης και η διαχείριση του συνόλου Y_{pred} αναλύονται εκτενώς στο Κεφάλαιο 4.

Πριν την εκπαίδευση του μοντέλου, τα δεδομένα εισόδου μετατρέπονται σε κατάλληλο μονοδιάστατο πίνακα, ώστε να μπορούν να χρησιμοποιηθούν ως πίνακες εισόδου στα αλγοριθμικά μοντέλα. Στη συνέχεια, εφαρμόζεται κανονικοποίηση των τιμών μέσω του μετασχηματισμού `StandardScaler`, ο οποίος μετατρέπει κάθε μεταβλητή ώστε κάθε μεταβλητή να έχει μέσο όρο μηδέν και τυπική απόκλιση ίση με ένα. Η επιλογή αυτού του τύπου κανονικοποίησης αντί για εναλλακτικές, όπως ο μετασχηματισμός `MinMaxScaler`, σχετίζεται με τη φύση των δεδομένων, καθώς η τιμή της ηλεκτρικής ενέργειας στην αγορά εξισορρόπησης μπορεί να λάβει τόσο θετικές όσο και αρνητικές τιμές, γεγονός που καθιστά την κανονικοποίηση σε πεδίο $[0, 1]$ ακατάλληλη. Επισημαίνεται ότι σε περιπτώσεις κατανομών που περιλαμβάνουν μόνο θετικές τιμές, η χρήση του `MinMaxScaler` ενδέχεται να είναι πιο κατάλληλη, καθώς περιορίζει τις τιμές σε συγκεκριμένο διάστημα. Ωστόσο, στο πλαίσιο της παρούσας διπλωματικής εργασίας χρησιμοποιείται ενιαία προσέγγιση με `StandardScaler` για όλα τα δεδομένα, ώστε να διατηρείται κοινό πλαίσιο επεξεργασίας μεταξύ των χωρών. Η κανονικοποίηση των δεδομένων με μετασχηματισμό `StandardScaler` διατηρεί τη συμμετρία των κατανομών και δεν αλλοιώνει τη σημασιολογική σχέση μεταξύ χαμηλών και υψηλών τιμών, καθώς δεν περιορίζει τις τιμές σε συγκεκριμένο διάστημα, αλλά τις καταγράφει ως αποστάσεις από τον μέσο όρο, επιτρέποντας συμμετρική απεικόνιση γύρω από το μηδέν. Ο συγκεκριμένος μετασχηματισμός εφαρμόζεται τόσο στα σύνολα εισόδου X_{train} και X_{test} , όσο και στο σύνολο εξόδου Y_{train} , συμβάλλοντας στη σταθεροποίηση των τιμών και στη βελτίωση της αποδοτικότητας κατά την εκπαίδευση. Η παραπάνω διαδικασία παρουσιάζεται στο Σχήμα 3.7.

```
X_train, Y_train, X_test, Y_test, TS_test, X_train_debug, X_test_debug = create_batches(df_month, window_size)

print(f"X_train shape: {X_train.shape} | Y_train shape: {Y_train.shape}")
print(f"X_test shape: {X_test.shape} | Y_test shape: {Y_test.shape}")

# Scaling
scaler_X = StandardScaler()
scaler_Y = StandardScaler()

X_train_scaled = scaler_X.fit_transform(X_train)
Y_train_scaled = scaler_Y.fit_transform(Y_train)
X_test_scaled = scaler_X.transform(X_test)
```

Σχήμα 3.7: Κώδικας σε Python για τον μετασχηματισμό των δεδομένων μέσω αναδιάταξης των εισόδων σε μορφή πίνακα και κανονικοποίησης με `StandardScaler`

Σε κάθε περίπτωση καταγράφεται επακριβώς η χρονική αντιστοίχιση εισόδου και πρόβλεψης, ώστε να εξασφαλίζεται απόλυτη συνέπεια με το αρχικό σύνολο δεδομένων. Η μετακίνηση από τη μία ακολουθία στην επόμενη γίνεται με βήμα ίσο με το χρονικό διάστημα πρόβλεψης, ώστε οι ακολουθίες να μη συμπίπτουν και να διατηρείται χρονική ανεξαρτησία.

Η συνολική διαδικασία διαχωρισμού, διαμόρφωσης ιστορικών ακολουθιών και προεπεξεργασίας των δεδομένων εφαρμόζεται με τον ίδιο τρόπο για κάθε χώρα και κάθε μήνα, επιτρέποντας την τυποποιημένη εκπαίδευση και αξιολόγηση των μοντέλων. Τα δεδομένα που περιλαμβάνονται σε κάθε χρονική ακολουθία εισόδου προέρχονται από τις μεταβλητές που έχουν αναλυθεί στην Ενότητα 3.4, οι οποίες διατηρούνται κοινές σε όλες τις περιπτώσεις.

Συνοψίζοντας, η παρούσα υποενότητα επικεντρώθηκε αποκλειστικά στη διαμόρφωση των χρονοσειρών και στην προεπεξεργασία των δεδομένων, ανεξάρτητα από το είδος του μοντέλου που τις αξιοποιεί. Η σύνδεση αυτής της διαδικασίας με τα επιμέρους μοντέλα πρόβλεψης, καθώς και ο τρόπος με τον οποίο χρησιμοποιείται κάθε σύνολο δεδομένων κατά την εκπαίδευση και την πρόβλεψη, αναλύεται στο Κεφάλαιο 4.

ΜΟΝΤΕΛΑ ΠΡΟΒΛΕΨΗΣ ΚΑΙ ΜΕΘΟΔΟΛΟΓΙΑ

4.1 ΕΙΣΑΓΩΓΗ

Όπως παρουσιάστηκε στο Κεφάλαιο 3, η διαδικασία διαμόρφωσης και προετοιμασίας των χρονοσειρών αποτελεί το απαραίτητο υπόβαθρο για την εφαρμογή μοντέλων πρόβλεψης. Στο παρόν κεφάλαιο, η ανάλυση εστιάζει πλέον στα ίδια τα μοντέλα πρόβλεψης, τα οποία αξιοποιούν τα δεδομένα εισόδου με σκοπό την εκτίμηση των τιμών εξισορρόπησης σε βραχυπρόθεσμο χρονικό ορίζοντα. Η ανάγκη για ακριβείς και αξιόπιστες προβλέψεις σε αυτή την αγορά είναι ιδιαίτερα επιτακτική, καθώς η πρόβλεψη των τιμών εξισορρόπησης αποτελεί μία από τις σημαντικότερες προκλήσεις στις σύγχρονες αγορές ηλεκτρικής ενέργειας, λόγω της υψηλής μεταβλητότητας, των ακραίων αιχμών και των διακυμάνσεων που προκύπτουν κυρίως από τη διείσδυση των ανανεώσιμων πηγών ενέργειας, την αστάθεια στη ζήτηση και τις διασυνοριακές ροές. Για την αντιμετώπιση αυτών των προκλήσεων, η επιστημονική κοινότητα και οι Διαχειριστές Συστημάτων Μεταφοράς αξιοποιούν πληθώρα μεθόδων πρόβλεψης, από στατιστικά μοντέλα έως σύγχρονους αλγόριθμους μηχανικής μάθησης. Η παρούσα διπλωματική εργασία επικεντρώνεται στη συγκριτική μελέτη τριών μοντέλων πρόβλεψης [2],[6]:

- Μοντέλο Αυτοπαλινδρόμησης Ολοκληρωμένου Κινητού Μέσου Όρου (ARIMA): Αποτελεί ένα από τα πιο διαδεδομένα στατιστικά μοντέλα ανάλυσης χρονοσειρών. Ενσωματώνει μηχανισμούς για την αξιοποίηση της αυτοσυσχέτισης, την αντιμετώπιση της μη στασιμότητας και την εξομάλυνση των τυχαίων διακυμάνσεων, ώστε να προσεγγίζει τη δυναμική των τιμών με ακρίβεια [12],[16].
- Μοντέλο Αυτοπαλινδρόμησης με τη μέθοδο LASSO (LEAR): Βασίζεται στη γραμμική παλινδρόμηση με κανονικοποίηση τύπου L1. Η προσέγγιση αυτή επιτρέπει την επιλογή των σημαντικότερων όρων υστέρησης, περιορίζοντας τον κίνδυνο υπερπροσαρμογής και ενισχύοντας την ερμηνευτική διαφάνεια του μοντέλου, ενώ είναι κατάλληλη για δεδομένα με υψηλή διακύμανση [6].
- Αλγόριθμος Ακραίας Ενίσχυσης Κλίσης (XGBoost): Ανήκει στην κατηγορία των μοντέλων μηχανικής μάθησης που βασίζονται σε δέντρα απόφασης και εφαρμόζει την τεχνική της ενίσχυσης κλίσης (gradient boosting). Χαρακτηρίζεται από υψηλή απόδοση, δυνατότητα ταυτόχρονης επεξεργασίας μεγάλου όγκου δεδομένων, αποτελεσματική κανονικοποίηση για τον περιορισμό της υπερπροσαρμογής και ενσωματωμένη διαχείριση ελλিপών τιμών, καθιστώντας

τον αλγόριθμο XGBoost ιδιαίτερα κατάλληλο για προβλήματα με πολυδιάστατα και δομημένα σύνολα δεδομένων [6],[17].

Η επιλογή των παραπάνω μοντέλων στοχεύει στην κάλυψη ενός ευρέος φάσματος προσεγγίσεων, ξεκινώντας από παραμετρικά και διαφανή στατιστικά μοντέλα, όπως το ARIMA και το LEAR, και φτάνοντας έως πιο ευέλικτους, μη παραμετρικούς αλγορίθμους μηχανικής μάθησης, όπως το XGBoost. Το κάθε μοντέλο διαθέτει ιδιαίτερα χαρακτηριστικά, με διαφορετικό βαθμό πολυπλοκότητας, ευκολίας προσαρμογής και ικανότητας αποτύπωσης της συμπεριφοράς των τιμών εξισορρόπησης.

Στις Ενότητες 4.2 και 4.3 παρουσιάζονται αναλυτικά τόσο τα θεωρητικά θεμέλια και τα βασικά χαρακτηριστικά των τριών μοντέλων πρόβλεψης, όσο και η μεθοδολογία πρόβλεψης που εφαρμόζεται σε κάθε μοντέλο, καθώς και οι δείκτες αξιολόγησης που χρησιμοποιούνται για τη σύγκριση της απόδοσής τους στο πλαίσιο της παρούσας διπλωματικής εργασίας.

4.2 ΜΟΝΤΕΛΑ ΠΡΟΒΛΕΨΗΣ

Η παρούσα ενότητα παρουσιάζει τα τρία μοντέλα πρόβλεψης που εφαρμόζονται στο πλαίσιο της μελέτης. Για κάθε μοντέλο αναλύεται το θεωρητικό υπόβαθρο στο οποίο βασίζεται, περιγράφεται η μαθηματική του διατύπωση και επεξηγείται η μορφή των δεδομένων που χρησιμοποιούνται για την εκπαίδευση και εφαρμογή του. Επιπλέον, παρουσιάζεται ο τρόπος με τον οποίο επιλέγονται οι τιμές των υπερπαραμέτρων και υλοποιείται η διαδικασία εκπαίδευσης βάσει των ιδιαίτερων χαρακτηριστικών κάθε μεθόδου, ενώ στο τέλος περιγράφεται αναλυτικά η μεθοδολογία πρόβλεψης που εφαρμόζεται σε κάθε μοντέλο.

4.2.1 Μοντέλο ARIMA

Το Μοντέλο Αυτοπαλινδρόμησης Ολοκληρωμένου Κινητού Μέσου Όρου (ARIMA) αποτελεί μία από τις πλέον καθιερωμένες και ευρέως χρησιμοποιούμενες μεθόδους στατιστικής πρόβλεψης για μονομεταβλητές χρονοσειρές [18]. Είναι ιδιαίτερα κατάλληλο για περιπτώσεις όπου η δυναμική της υπό μελέτη μεταβλητής αποτυπώνεται κυρίως μέσω της εσωτερικής χρονικής εξάρτησης, χωρίς την ανάγκη ενσωμάτωσης εξωτερικών χαρακτηριστικών. Η μεθοδολογία ARIMA δεν απαιτεί εξωγενείς μεταβλητές, καθώς αξιοποιεί αποκλειστικά τις ίδιες τις παλαιότερες τιμές της χρονοσειράς, και για τον λόγο αυτό χαρακτηρίζεται ως μονομεταβλητό μοντέλο. Η αποτελεσματικότητά του έγκειται στη δυνατότητα σύλληψης τόσο των μακροχρόνιων τάσεων, όσο και των βραχυχρόνιων αποκλίσεων, μέσω του συνδυασμού τριών βασικών συνιστωσών:

- Αυτοπαλινδρόμηση (AR): το παρελθόν της ίδιας της μεταβλητής χρησιμοποιείται για την πρόβλεψη της παρούσας τιμής.
- Ολοκλήρωση (I): εφαρμόζεται διαφοροποίηση, προκειμένου η σειρά να καταστεί στατική και να εξαλειφθεί η τάση ή η εποχικότητα.
- Κινητός μέσος όρος (MA): τα προηγούμενα σφάλματα πρόβλεψης αξιοποιούνται για τη βελτίωση της πρόβλεψης.

Η μαθηματική διατύπωση του μοντέλου ARIMA δίνεται από τις σχέσεις (4.1) και (4.2) [19]:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (4.1)$$

$$Z_t = \nabla^d Y_t \quad (4.2)$$

Οι σχέσεις (4.1) και (4.2) περιγράφουν τη δομή του μοντέλου ARIMA και αποτυπώνει τη σχέση μεταξύ των προβλεπόμενων τιμών, των παλαιότερων παρατηρήσεων της χρονοσειράς και των σφαλμάτων πρόβλεψης. Για την πλήρη κατανόηση της λειτουργίας του μοντέλου, παρατίθεται η ερμηνεία των συμβόλων του μοντέλου:

- Y_t : η αρχική χρονοσειρά
- $\nabla^d Y_t$: η διαφοροποιημένη χρονοσειρά, έπειτα από d πράξεις διαφορίσης
- Z_t : η στατικοποιημένη μορφή της σειράς που τελικά μοντελοποιείται
- ϕ_i : οι συντελεστές της αυτοπαλινδρόμησης, που αποτυπώνουν τη συσχέτιση με προηγούμενες τιμές.
- θ_j : οι συντελεστές του κινητού μέσου όρου, που σχετίζονται με τα προηγούμενα σφάλματα.
- a_t : ο λευκός θόρυβος (στοχαστικό σφάλμα μη προβλέψιμης φύσης)

Οι παράμετροι του μοντέλου (p,d,q) οι οποίες αντιστοιχούν στις τρεις παραπάνω συνιστώσες (AR, I, MA), καθορίζουν:

- p : τον αριθμό όρων αυτοπαλινδρόμησης
- d : τον αριθμό διαφορίσεων που απαιτούνται για τη στασιμότητα.
- q : τον αριθμό όρων κινητού μέσου όρου

Η επιλογή των παραμέτρων (p,d,q) μπορεί να γίνει είτε εμπειρικά μέσω διαγραμμάτων αυτοσυσχέτισης και μερικής αυτοσυσχέτισης, είτε αυτόματα με χρήση στατιστικών κριτηρίων όπως το AIC (Akaike Information Criterion) και το BIC (Bayesian Information Criterion), τα οποία συγκρίνουν την προσαρμογή και την πολυπλοκότητα διαφόρων υποψηφίων μοντέλων [18].

Αφού παρουσιάστηκε το θεωρητικό υπόβαθρο του μοντέλου ARIMA, ακολουθεί η περιγραφή της διαδικασίας εφαρμογής του στο πλαίσιο της παρούσας διπλωματικής εργασίας. Το συγκεκριμένο μοντέλο, ως μονομεταβλητό, αξιοποιεί αποκλειστικά τις ιστορικές τιμές της μεταβλητής που είναι ο στόχος πρόβλεψης, χωρίς τη χρήση εξωτερικών χαρακτηριστικών. Η διαφορά αυτή είναι ουσιώδης σε σχέση με τη λογική δημιουργίας εισόδων που παρουσιάστηκε στην Ενότητα 3.5 μέσω της συνάρτησης `create_batches`, καθώς στο ARIMA δεν πραγματοποιείται διαχωρισμός συνόλων εισόδου και στόχου, αλλά το μοντέλο εκπαιδεύεται άμεσα πάνω στη χρονοσειρά της υπό μελέτη μεταβλητής, χωρίς να εφαρμόζεται κανονικοποίηση. Η χρήση της αρχικής χρονοσειράς θεωρείται επαρκής, καθώς πρόκειται για μονομεταβλητή είσοδο με ομοιογενή κλίμακα τιμών, που δεν απαιτεί περαιτέρω αριθμητική προεπεξεργασία.

Η είσοδος του μοντέλου προκύπτει από τον διαχωρισμό της μηνιαίας χρονοσειράς σε δύο τμήματα, με το 80% των δεδομένων να χρησιμοποιείται για εκπαίδευση και το υπόλοιπο 20% για πρόβλεψη, όπως ορίστηκε στο Κεφάλαιο 3. Ωστόσο, η εφαρμογή της πρώτης πρόβλεψης απαιτεί την ύπαρξη ενός πλήρους ιστορικού παραθύρου σταθερού μήκους, που προηγείται των τιμών τις οποίες πρόκειται να προβλέψουμε. Για τον λόγο αυτό, το σύνολο αξιολόγησης δεν ξεκινά αμέσως μετά τη λήξη του εκπαιδευτικού συνόλου, αλλά μετατοπίζεται προς τα πίσω κατά το μέγεθος του χρονικού παραθύρου. Έτσι διασφαλίζεται ότι, σε κάθε βήμα πρόβλεψης, υπάρχουν επαρκή ιστορικά δεδομένα για να χρησιμοποιηθούν ως είσοδος. Ο τρόπος αυτός διαχωρισμού της χρονοσειράς και προετοιμασίας των συνόλων εκπαίδευσης και αξιολόγησης απεικονίζεται στο Σχήμα 4.1.

```
series = df_month["BM Price (Euros/MWh)"].values
index = df_month.index
train_size = int(len(series) * 0.8)
train_series = series[:train_size]

test_series = series[train_size - window_size:]
test_index = index[train_size - window_size:]
```

Σχήμα 4.1: Κώδικας σε Python για τον διαχωρισμό της ιστορικής χρονοσειράς του στόχου πρόβλεψης για την εκπαίδευση του μοντέλου ARIMA

Στη συνέχεια της διαδικασίας, αφού έχει προσδιοριστεί το σύνολο των δεδομένων εκπαίδευσης, πραγματοποιείται η εκπαίδευση του μοντέλου ARIMA ξεχωριστά για κάθε μήνα, βασισμένη αποκλειστικά στη χρονοσειρά της μεταβλητής του στόχου πρόβλεψης. Οι βέλτιστες τιμές των παραμέτρων επιλέγονται αυτόματα μέσω της συνάρτησης `auto_arima()` της βιβλιοθήκης *pmдарima*, η οποία εφαρμόζει στατιστικά κριτήρια όπως το AIC και το BIC για την αξιολόγηση και επιλογή του καταλληλότερου μοντέλου. Η διαδικασία αυτή υλοποιείται εντός της συνάρτησης `train_arima_model_auto()`, η οποία φαίνεται στο Σχήμα 4.2.

```
def train_arima_model_auto(train_series):
    print(f"\n🔍 Επιλογή παραμέτρων μέσω auto_arima...")
    model = auto_arima(train_series, seasonal=False, stepwise=True,
                       suppress_warnings=True, error_action="ignore")
    print(f"✅ Βέλτιστες παράμετροι: (p,d,q)={model.order}")
    return model
```

Σχήμα 4.2: Κώδικας σε Python για τον καθορισμό των παραμέτρων (p,d,q) του μοντέλου ARIMA μέσω της συνάρτησης `train_arima_model_auto`

Αμέσως μετά την εκπαίδευση, ακολουθεί η διαδικασία πρόβλεψης σε διαδοχικά χρονικά βήματα. Η πρόβλεψη εφαρμόζεται για ορίζοντα 16 χρονικών σημείων, με χρήση ιστορικών παραθύρων σταθερού μήκους (48, 72, 96, 144 ή 336 χρονικών βημάτων), σύμφωνα με τη μεθοδολογία της Ενότητας 3.5.

Για κάθε παράθυρο πρόβλεψης, δημιουργείται ένα παράθυρο εισόδου (`x_input`), το οποίο αποτελείται από τις τιμές του συνόλου `test_series[i:i + window_size]`. Αυτό το παράθυρο τροφοδοτεί το μοντέλο για την παραγωγή προβλέψεων. Παράλληλα, επιλέγεται το αντίστοιχο σύνολο πραγματικών τιμών αξιολόγησης (`y_real`), από το σύνολο `test_series[i + window_size:i + window_size + FORECAST_HORIZON]`, που αντιστοιχεί στις επόμενες 16 χρονικές στιγμές. Οι τιμές αυτές δεν χρησιμοποιούνται ως είσοδος, αλλά ως αντικειμενικός στόχος αξιολόγησης, έναντι του οποίου συγκρίνονται οι προβλέψεις. Μαζί με τα αριθμητικά σύνολα, καταγράφονται και οι αντίστοιχοι χρονοδείκτες εισόδου και στόχου, δηλαδή `x_timestamps` και `y_timestamps`, αντίστοιχα.

Αυτοί εξάγονται από τον δείκτη `test_index`, ώστε κάθε πρόβλεψη να συνοδεύεται από την ακριβή χρονική στιγμή στην οποία αντιστοιχεί. Η πληροφορία αυτή είναι απαραίτητη για την παρουσίαση γραφημάτων και για την τελική αποθήκευση των αποτελεσμάτων.

Η παραπάνω διαδικασία, η οποία απεικονίζεται στο Σχήμα 4.3, υλοποιείται εντός επαναληπτικού βρόχου με μεταβλητή ελέγχου `i`, η οποία μετατοπίζει το παράθυρο εισόδου κατά 16 χρονικά σημεία σε κάθε επανάληψη. Με αυτόν τον τρόπο καλύπτεται ολόκληρο το σύνολο αξιολόγησης χωρίς επικαλύψεις. Κάθε νέα πρόβλεψη που παράγεται αποθηκεύεται στο σύνολο `Y_pred`, ενώ οι αντίστοιχες πραγματικές τιμές καταγράφονται στο σύνολο `Y_true`.

```
for i in range(0, len(test_series) - window_size - FORECAST_HORIZON + 1, FORECAST_HORIZON):
    x_input = test_series[i:i + window_size]
    y_real = test_series[i + window_size:i + window_size + FORECAST_HORIZON]

    x_timestamps = test_index[i:i + window_size]
    y_timestamps = test_index[i + window_size:i + window_size + FORECAST_HORIZON]

    if len(y_timestamps) < FORECAST_HORIZON:
        break
```

Σχήμα 4.3: Κώδικας σε Python για τη δημιουργία παραθύρων εισόδου, στόχου και χρονικών δεικτών για κάθε παρτίδα πρόβλεψης

Αφού προσδιοριστούν οι τιμές εισόδου και οι χρονικές στιγμές για τις οποίες θα παραχθούν προβλέψεις, ακολουθεί η διαδικασία πρόβλεψης, η οποία βασίζεται σε λογική κλειστού βρόχου και απεικονίζεται στο Σχήμα 4.4. Λόγω των περιορισμών της βιβλιοθήκης *pmdarima*, η οποία δεν υποστηρίζει αποθήκευση κατάστασης ή ενημέρωση με νέες παρατηρήσεις, εφαρμόζεται επανεκπαίδευση του μοντέλου σε κάθε χρονικό βήμα. Δηλαδή, για κάθε βήμα πρόβλεψης:

- Το μοντέλο επανεκπαιδεύεται με τις πρόσφατες τιμές της χρονοσειράς (παράθυρο εισόδου).
- Υπολογίζεται η επόμενη τιμή, η οποία προστίθεται στο παράθυρο εισόδου.
- Η διαδικασία επαναλαμβάνεται μέχρι να καλυφθεί ολόκληρος ο ορίζοντας πρόβλεψης.

Η παραπάνω στρατηγική, αν και υπολογιστικά πιο απαιτητική, εξασφαλίζει τη σωστή αυτοπαλινδρομική συμπεριφορά του μοντέλου, καθώς κάθε νέα πρόβλεψη επηρεάζει την επόμενη. Η πρόβλεψη βασίζεται στην έννοια της διαδοχικής επανεκπαίδευσης και όχι στη διατήρηση κατάστασης. Αντίθετα, υλοποιήσεις όπως αυτή της βιβλιοθήκης *statsmodels* υποστηρίζουν τη διατήρηση εσωτερικής κατάστασης, αλλά περιορίζονται στην ευελιξία χρήσης παραθύρων σταθερού μήκους σε περιβάλλοντα με μεγάλο όγκο δεδομένων.

```

input_series = list(x_input)
preds = []
for step in range(FORECAST_HORIZON):
    model_applied = model_fit.fit(input_series[-window_size:])
    next_pred = model_applied.predict(n_periods=1)[0]
    preds.append(next_pred)
    input_series.append(next_pred)

Y_pred.extend(preds)
Y_true.extend(y_real)
timestamps.extend(y_timestamps)
batch_ids.extend([i // FORECAST_HORIZON + 1] * FORECAST_HORIZON)

return Y_true, Y_pred, timestamps, batch_ids

```

Σχήμα 4.4 : Κώδικας σε Python για τη διαδικασία πρόβλεψης με λογική κλειστού βρόχου για κάθε χρονικό βήμα του ορίζοντα πρόβλεψης

Ολοκληρώνοντας τη διαδικασία πρόβλεψης, οι υπολογισμένες τιμές καταγράφονται σε αρχεία αποτελεσμάτων, τα οποία περιλαμβάνουν τόσο τις προβλέψεις όσο και τις αντίστοιχες πραγματικές τιμές και χρονικές στιγμές. Η μεθοδολογία εφαρμόζεται με συνέπεια για όλους τους μήνες και για κάθε διαφορετικό μέγεθος παραθύρου, διασφαλίζοντας ενιαίο και συγκρίσιμο πλαίσιο αξιολόγησης των αποτελεσμάτων.

4.2.2 Μοντέλο LEAR

Το Αυτοπαλίνδρομο Μοντέλο με τη μέθοδο LASSO (LEAR) αποτελεί μία σύγχρονη προσέγγιση πρόβλεψης χρονοσειρών, η οποία βασίζεται στη χρήση γραμμικών μοντέλων εμπλουτισμένων με τεχνικές κανονικοποίησης και επιλογής μεταβλητών. Συγκεκριμένα, χρησιμοποιεί κανονικοποίηση τύπου ℓ_1 (L1), δηλαδή προσθέτει μια ποινή στο άθροισμα των απόλυτων τιμών των συντελεστών του μοντέλου, ενισχύοντας έτσι την απλοποίηση του τελικού μοντέλου, καθώς πολλοί συντελεστές μηδενίζονται και διατηρούνται μόνο εκείνοι που έχουν ουσιαστική συμβολή στην πρόβλεψη. Η ανάγκη για τέτοιου είδους μεθοδολογίες είναι ιδιαίτερα έντονη σε προβλήματα με μεγάλο αριθμό εισόδων και παραμέτρων, όπως η πρόβλεψη τιμών σε αγορές ηλεκτρικής ενέργειας.

Το μοντέλο LEAR περιγράφει τη δυναμική εξέλιξη μιας χρονοσειράς μέσω ενός γραμμικού αυτοπαλίνδρομου μοντέλου, στο οποίο η τιμή σε μία χρονική στιγμή εξαρτάται από προηγούμενες τιμές της ίδιας μεταβλητής. Η μαθηματική μορφή του μοντέλου δίνεται στην Εξίσωση (4.3) [20]:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + Z_t \quad (4.3)$$

όπου X_t είναι η τιμή της χρονοσειράς στη χρονική στιγμή t , οι συντελεστές ϕ_j εκφράζουν τη γραμμική επίδραση των προηγούμενων τιμών και Z_t αντιπροσωπεύει έναν τυχαίο θόρυβο, του οποίου η αναμενόμενη τιμή είναι ίση με το μηδέν. Η Εξίσωση (4.3) αντιστοιχεί στη βασική μορφή ενός γραμμικού αυτοπαλίνδρομου μοντέλου. Στην πράξη, όταν δεν είναι γνωστό ποιοι από τους p υποψήφιους όρους έχουν ουσιαστική συνεισφορά, απαιτείται μία διαδικασία εκτίμησης που ταυτόχρονα εντοπίζει και εκτιμά τους σημαντικούς συντελεστές. Για τον σκοπό αυτό, η εκτίμηση των παραμέτρων γίνεται μέσω της επίλυσης του ακόλουθου προβλήματος ελαχιστοποίησης, το οποίο εκφράζεται από τη σχέση (4.4) [21].

$$\min_{\varphi \in \mathbb{R}^p} \left\{ \frac{1}{2n} \|y - X\varphi\|_2^2 + \alpha \sum_{j=1}^p |\varphi_j| \right\} \quad (4.4)$$

Η πρώτη ποσότητα εκφράζει τη μέση τετραγωνική απόκλιση των προβλέψεων του μοντέλου από τις πραγματικές τιμές. Ο δεύτερος όρος αποτελεί την κανονικοποίηση ℓ_1 (L1), η οποία προσθέτει ποινή ανάλογη του αθροίσματος των απόλυτων τιμών των συντελεστών και ελέγχεται από τον συντελεστή α , ο οποίος καθορίζει το μέγεθος της ποινής, καθώς όσο μεγαλύτερη είναι η τιμή του, τόσο περισσότεροι συντελεστές μηδενίζονται. Η προσθήκη αυτής της ποινής οδηγεί στη μηδενική αποτίμηση πολλών συντελεστών, διατηρώντας μόνο εκείνους που συμβάλλουν ουσιαστικά στην πρόβλεψη. Με αυτόν τον τρόπο, το τελικό μοντέλο γίνεται πιο απλό, πιο ερμηνεύσιμο και λιγότερο επιρρεπές στην υπερπροσαρμογή.

Το μοντέλο LEAR γενικεύεται για περιπτώσεις πρόβλεψης πολλαπλών χρονικών σημείων, αξιοποιώντας τη δυνατότητα πρόβλεψης πολλαπλών εξόδων με επιμέρους μοντέλα, όπως εφαρμόζεται στο πλαίσιο της παρούσας διπλωματικής εργασίας. Η δομή των συνόλων εισόδου και στόχου βασίζεται στη λογική διαδοχικών χρονικών παραθύρων, όπως περιγράφεται στην Ενότητα 3.5.

Η εκπαίδευση του μοντέλου πραγματοποιείται ξεχωριστά για κάθε μήνα και για κάθε μέγεθος παραθύρου, με χρήση του 80% των διαθέσιμων δεδομένων του μήνα. Πριν από την εφαρμογή της διαδικασίας, τα σύνολα εισόδου και στόχου κανονικοποιούνται, ώστε να διασφαλίζεται αριθμητική σταθερότητα και να αποφεύγεται η κυριαρχία μεταβλητών με μεγαλύτερη κλίμακα, όπως αναφέρθηκε και στην Ενότητα 3.5. Ακολούθως, η υπερπαραμέτρος α επιλέγεται με χρήση της συνάρτησης LassoCV από τη βιβλιοθήκη *sklearn.linear_model*, η οποία εφαρμόζει διασταυρούμενη επικύρωση πέντε διαιρέσεων (5-fold cross-validation), δηλαδή χωρίζει το σύνολο εκπαίδευσης σε πέντε ίσα μέρη και, σε κάθε επανάληψη, χρησιμοποιεί τέσσερα από αυτά για εκπαίδευση και το πέμπτο για επικύρωση, ώστε να υπολογιστεί η μέση τιμή του σφάλματος και να επιλεγεί η βέλτιστη τιμή της παραμέτρου α που το ελαχιστοποιεί [22]. Η διαδικασία αυτή αποτυπώνεται στο Σχήμα 4.5, όπου παρουσιάζεται ο προσδιορισμός της βέλτιστης τιμής της παραμέτρου α και η εκπαίδευση του μοντέλου με την εντολή `fit`, βάσει της επιλεγμένης τιμής. Η μοντελοποίηση πραγματοποιείται μέσω της κλάσης `MultiOutputRegressor()` της βιβλιοθήκης *sklearn.multioutput*, η οποία επιτρέπει την ανεξάρτητη εκπαίδευση ενός μοντέλου LEAR για κάθε χρονικό βήμα πρόβλεψης. Αυτός ο διαχωρισμός είναι απαραίτητος, καθώς η μέθοδος LASSO εφαρμόζεται σε προβλήματα μονοδιάστατης εξόδου. Συνεπώς, για την πρόβλεψη 16 χρονικών σημείων, εκπαιδεύονται ισάριθμα γραμμικά μοντέλα, ένα για κάθε χρονική στιγμή [23].

```
lasso_alpha = LassoCV(cv=5).fit(X_train_scaled, Y_train_scaled).alpha_
model = MultiOutputRegressor(Lasso(alpha=lasso_alpha, max_iter=10000))
model.fit(X_train_scaled, Y_train_scaled)
```

Σχήμα 4.5 : Κώδικας σε Python για την επιλογή της τιμής της υπερπαραμέτρου κανονικοποίησης α μέσω της συνάρτησης LassoCV και εκπαίδευση του μοντέλου LEAR με την εντολή `model.fit`

Η πρόβλεψη πραγματοποιείται μέσω μεθοδολογίας κλειστού βρόχου, όπως υλοποιείται στη συνάρτηση `closed_loop_forecast_lear` και αποτυπώνεται στο Σχήμα 4.6. Σε κάθε επανάληψη της

διαδικασίας πρόβλεψης, ως είσοδος χρησιμοποιείται το τελευταίο διαθέσιμο παράθυρο δεδομένων, το οποίο κανονικοποιείται και τροφοδοτείται στο μοντέλο με την εντολή `model.predict()`. Η παραγόμενη πρόβλεψη μετασχηματίζεται πίσω στην αρχική της κλίμακα μέσω της `scaler_Y.inverse_transform()` και ενσωματώνεται στο παράθυρο εισόδου, αντικαθιστώντας την παλαιότερη τιμή. Το νέο παράθυρο, ενημερωμένο με την τελευταία πρόβλεψη, χρησιμοποιείται για την εκτίμηση της επόμενης χρονικής στιγμής. Η διαδικασία αυτή επαναλαμβάνεται διαδοχικά μέχρι να παραχθούν οι συνολικές 16 προβλέψεις, όσες και ο ορίζοντας πρόβλεψης, μέσα στον επαναληπτικό βρόχο της συνάρτησης `closed_loop_forecast_lear`, χρησιμοποιώντας σταθερά το ίδιο εκπαιδευμένο μοντέλο χωρίς ενδιάμεση επανεκπαίδευση.

```
def closed_loop_forecast_lear(model, X_init, df_full, ts_init, scaler_X, scaler_Y):
    current_window = X_init.copy()
    predictions = []
    timestamps = []

    for step in range(FORECAST_HORIZON):
        x_input = current_window.flatten().reshape(1, -1)
        x_scaled = scaler_X.transform(x_input)
        y_scaled = model.predict(x_scaled)
        y_pred = scaler_Y.inverse_transform(np.array(y_scaled).reshape(-1, 1))[0, 0]
        predictions.append(y_pred)

        last_ts = ts_init[-1]
        next_ts = last_ts + pd.Timedelta(minutes=30)

        if next_ts not in df_full.index:
            future_timestamps = df_full.index[df_full.index > next_ts]
            if len(future_timestamps) == 0:
                break
            next_ts = future_timestamps[0]
            print(f"🔍 Παράκαμψη: Χρησιμοποιείται το επόμενο διαθέσιμο timestamp: {next_ts}")

        next_row = df_full.loc[next_ts, FEATURE_COLS].copy()
        next_row["BM Price (Euros/MWh)"] = y_pred
        current_window = np.vstack([current_window[1:], next_row.values])
        ts_init = list(ts_init[1:]) + [next_ts]
        timestamps.append(next_ts)

    return predictions, timestamps
```

Σχήμα 4.6 : Κώδικας σε Python για την υλοποίηση της πρόβλεψης με μεθοδολογία κλειστού βρόχου στη συνάρτηση `closed_loop_forecast_lear`

Η παραπάνω διαδικασία ενσωματώνεται στον βασικό βρόχο αξιολόγησης, όπου για κάθε υποσύνολο του συνόλου ελέγχου εφαρμόζεται διαδοχικά η διαδικασία πρόβλεψης, ξεκινώντας από το τελευταίο διαθέσιμο παράθυρο εισόδου και προχωρώντας στην εκτίμηση των επόμενων 16 χρονικών σημείων. Σε κάθε επανάληψη, οι προβλέψεις που παράγονται προστίθενται στις αντίστοιχες λίστες με τις πραγματικές τιμές, τα χρονικά σημεία και την ένδειξη του αντίστοιχου διαστήματος. Η υλοποίηση αυτής της λογικής παρουσιάζεται στο Σχήμα 4.7, όπου αποτυπώνεται η διαδοχική εφαρμογή του μοντέλου σε όλα τα διαστήματα ελέγχου και η συλλογή των αποτελεσμάτων. Μετά την ολοκλήρωση της διαδικασίας για όλα τα υποσύνολα, τα δεδομένα συγκεντρώνονται και αποθηκεύονται για περαιτέρω ανάλυση και αξιολόγηση. Τα τελικά αποτελέσματα περιλαμβάνουν, για κάθε χρονική

στιγμή, την πραγματική τιμή, την αντίστοιχη πρόβλεψη και την ένδειξη του υποσυνόλου στο οποίο ανήκει.

```
all_predictions, all_true, all_timestamps, all_batches = [], [], [], []

for i, X_init in enumerate(X_test_list):
    ts_init = X_test_debug[i][0]
    preds, ts_forecast = recursive_forecast_lear(model, X_init, df_month, ts_init, scaler_X, scaler_Y)
    if preds is None or ts_forecast is None:
        continue
    all_predictions.extend(preds)
    all_true.extend(Y_test[i])
    all_timestamps.extend(ts_forecast)
    all_batches.extend([i + 1] * FORECAST_HORIZON)

results_dir = f"LEAR_closed_loop_results_2021/{country}/Month_{month_name}"
os.makedirs(results_dir, exist_ok=True)

df_result = pd.DataFrame({
    "Timestamp": all_timestamps,
    "Actual": all_true,
    "Forecast": all_predictions,
    "Batch": all_batches
})
df_result.to_csv(f"{results_dir}/results_window_{window_size}.csv", index=False)
```

Σχήμα 4.7 : Κώδικας σε Python για την επαναληπτική διαδικασία πρόβλεψης για όλα τα χρονικά υποσύνολα ελέγχου για το μοντέλο LEAR

4.2.3 Μοντέλο XGBoost


Ο Αλγόριθμος Ακραίας Ενίσχυσης Κλίσης (XGBoost) αποτελεί μια εξελιγμένη υλοποίηση της μεθόδου βαθμιδωτής ενίσχυσης, σχεδιασμένη για υψηλή ταχύτητα, ακρίβεια και δυνατότητα κλιμάκωσης σε μεγάλα δεδομένα. Ο όρος XGBoost προέρχεται από τον αγγλικό τίτλο *Extreme Gradient Boosting* και παραπέμπει στη βασική αρχή του αλγορίθμου: τη διαδοχική εκπαίδευση μοντέλων παλινδρόμησης, τα οποία συνήθως υλοποιούνται ως δέντρα απόφασης, με σκοπό τη βελτίωση της απόδοσης μέσω διόρθωσης των σφαλμάτων πρόβλεψης των προηγούμενων δέντρων απόφασης [24],[25].

Η αρχιτεκτονική του XGBoost παρουσιάζεται στο Σχήμα 4.8, όπου το αρχικό σύνολο δεδομένων εισέρχεται στον πρώτο εκτιμητή (Tree 1), ο οποίος παράγει μια πρόβλεψη. Η διαφορά μεταξύ των πραγματικών τιμών και των προβλέψεων χρησιμοποιείται ως είσοδος για τον επόμενο εκτιμητή (Tree 2). Η διαδικασία επαναλαμβάνεται μέχρι την εκπαίδευση k εκτιμητών, και η τελική πρόβλεψη προκύπτει από το σταθμισμένο άθροισμα των προβλέψεων όλων των ενδιάμεσων μοντέλων. Το αποτέλεσμα αυτό περιγράφεται μαθηματικά από τη σχέση (4.5) [28]:

$$\hat{y} = \sum_{k=1}^K f_k(X, \theta_k) \quad (4.5)$$

όπου:

- $\hat{y}$: η συνολική πρόβλεψη του μοντέλου
- $f_k(X, \theta_k)$: η πρόβλεψη του k -οστού εκτιμητή
- X : το διάνυσμα εισόδου
- θ_k : το σύνολο των παραμέτρων του k -οστού εκτιμητή
- K : το πλήθος των επιμέρους μοντέλων



Σχήμα 4.8 : Αρχιτεκτονική του Αλγορίθμου XGBoost [28]

Πέρα από τη συνάρτηση πρόβλεψης, το XGBoost βασίζει τη διαδικασία εκπαίδευσής του στη βελτιστοποίηση μιας συνολικής συνάρτησης κόστους, η οποία συνδυάζει την ακρίβεια πρόβλεψης με την πολυπλοκότητα του μοντέλου. Η γενική μορφή της συνάρτησης κόστους περιγράφεται από την Εξίσωση (4.6) [24]:

$$\mathcal{L} = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (4.6)$$

όπου:

- $l(y_i, \hat{y}_i)$: η συνάρτηση απώλειας, η οποία μετρά τη διαφορά μεταξύ της πραγματικής τιμής y_i και της προβλεπόμενης τιμής $\hat{y}_i$.

- $\Omega(f_k)$: ο κανονικοποιητικός όρος, που ελέγχει την πολυπλοκότητα του εκτιμητή f_k , ενσωματώνοντας κριτήρια, όπως το πλήθος των φύλλων ή το άθροισμα των τετραγώνων των βαρών.

Η βαθμιδωτή ενίσχυση αποτελεί τεχνική σύζευξης μοντέλων, στην οποία κάθε νέο μοντέλο επικεντρώνεται στα σφάλματα πρόβλεψης του προηγούμενου. Ο σκοπός είναι η ελαχιστοποίηση της συνάρτησης κόστους (4.6) με χρήση βαθμιδωτής καθόδου, ενώ η συμβολή κάθε νέου εκτιμητή ελέγχεται με κατάλληλο συντελεστή εκμάθησης (*learning rate*), ο οποίος ρυθμίζει το πόσο έντονα επηρεάζει η νέα πρόβλεψη το συνολικό αποτέλεσμα [24],[26]. Βασισμένος σε αυτή την αρχή, ο αλγόριθμος XGBoost ενσωματώνει επιπλέον τεχνικές βελτιστοποίησης που τον καθιστούν πιο αποτελεσματικό και σταθερό σε σχέση με άλλες υλοποιήσεις βαθμιδωτής ενίσχυσης. Οι κυριότερες είναι οι εξής [25]:

- Χρήση συγκεκριμένων μορφών κανονικοποίησης στο πλαίσιο του όρου $\Omega(f_k)$, όπως η τύπου L1 κανονικοποίηση, που βασίζεται στο άθροισμα των απόλυτων τιμών των παραμέτρων και χρησιμοποιείται επίσης στο μοντέλο LEAR που αναλύθηκε στην Υποενότητα 4.2.2, καθώς και η τύπου L2 κανονικοποίηση, που βασίζεται στο άθροισμα των τετραγώνων των τιμών. Οι τεχνικές αυτές συμβάλλουν στη μείωση της υπερπροσαρμογής και στη διατήρηση ενός πιο απλού και γενικεύσιμου μοντέλου.
- Παράλληλη και κατανεμημένη εκπαίδευση, για ταχύτερη διαδικασία εκπαίδευσης σε μεγάλα σύνολα δεδομένων και αξιοποίηση πόρων υπολογιστικής ισχύος.
- Ευέλικτη παραμετροποίηση της συνάρτησης απώλειας, επιτρέποντας την προσαρμογή του μοντέλου σε διαφορετικά προβλήματα πρόβλεψης ή ταξινόμησης.
- Υποστήριξη πολλαπλών τύπων προβλημάτων, όπως ταξινόμηση, παλινδρόμηση και κατάταξη, διευρύνοντας το πεδίο εφαρμογής του αλγορίθμου.

Χάρη στην ευελιξία της αρχιτεκτονικής του, ο αλγόριθμος XGBoost προσαρμόζεται εύκολα σε ποικίλες εφαρμογές και μεγέθη δεδομένων. Η εκπαίδευση πραγματοποιείται διαδοχικά, με δυνατότητα ελέγχου μέσω επικύρωσης ή βάσει προκαθορισμένου πλήθους εκτιμητών, εξασφαλίζοντας υψηλή προσαρμοστικότητα και υπολογιστική αποδοτικότητα. Η χρήση του XGBoost έχει αποδειχθεί ιδιαίτερα αποτελεσματική στην πρόβλεψη της τιμής ηλεκτρικής ενέργειας, χάρη στην ικανότητά του να αποτυπώνει μη γραμμικές σχέσεις και σύνθετα πρότυπα απόδοσης. Πλήθος μελετών έχει καταδείξει την ανωτερότητά του ως προς την ακρίβεια και τη σταθερότητα, καθιστώντας τον αλγόριθμο XGBoost ιδανικό εργαλείο για την ανάλυση αγορών ηλεκτρικής ενέργειας [27].

Η εφαρμογή του μοντέλου XGBoost στην παρούσα διπλωματική εργασία πραγματοποιείται με σκοπό την πρόβλεψη της τιμής ηλεκτρικής ενέργειας στη αγορά εξισορρόπησης για χρονικό ορίζοντα 16 βημάτων των 30 λεπτών. Η διαδικασία εφαρμόζεται σε μηνιαία βάση, χρησιμοποιώντας ιστορικά δεδομένα τα οποία οργανώνονται σε χρονικά παράθυρα εισόδου και αντίστοιχες εξόδους πρόβλεψης, όπως ορίζονται από τη συνάρτηση `create_batches()` που έχει παρουσιαστεί αναλυτικά στην Ενότητα 3.5. Κατά την προετοιμασία των συνόλων χαρακτηριστικών εισόδου και εξόδου, εφαρμόζεται κανονικοποίηση τόσο στα χαρακτηριστικά εισόδου, όσο και στις τιμές στόχου. Κάθε σύνολο εισόδου περιλαμβάνει διαδοχικές χρονικές τιμές για όλα τα διαθέσιμα χαρακτηριστικά και αντιστοιχίζεται με

ένα σύνολο εξόδου που περιέχει τις 16 επόμενες τιμές της τιμής εξισορρόπησης. Αφού ολοκληρωθεί η δημιουργία και επεξεργασία των παραθύρων εισόδου και εξόδου, ακολουθεί η διαδικασία εκπαίδευσης του μοντέλου.

Η εκπαίδευση πραγματοποιείται με χρήση της κλάσης `XGBRegressor`, η οποία ανήκει στη βιβλιοθήκη `xgboost` και υλοποιεί το μοντέλο βαθμιδωτής ενίσχυσης μέσω ακολουθίας δέντρων απόφασης. Οι βασικές υπερπαραμέτροι που καθορίζονται περιλαμβάνουν τον ρυθμό εκμάθησης, το μέγιστο βάθος των δέντρων, το ελάχιστο άθροισμα βάρους ανά κόμβο, τον αριθμό εκτιμητών και το ποσοστό δειγματοληψίας. Στο Σχήμα 4.9 παρουσιάζεται το αντίστοιχο απόσπασμα κώδικα όπου ορίζεται το μοντέλο και εφαρμόζεται η εκπαίδευση. Η διαδικασία αυτή εκτελείται μία φορά για κάθε μήνα και για κάθε μέγεθος παραθύρου στο σύνολο εκπαίδευσης και το μοντέλο που προκύπτει παραμένει σταθερό κατά τη φάση πρόβλεψης. Οι τιμές των υπερπαραμέτρων που παρουσιάζονται στο Σχήμα 4.9 επιλέχθηκαν ύστερα από δοκιμές και αξιολόγηση των αποτελεσμάτων πρόβλεψης, σύμφωνα με όσα αναλύονται στο Κεφάλαιο 5. Σε αντίθεση με το μοντέλο ARIMA, το οποίο επανεκπαιδεύεται σε κάθε διαφορετικό υποσύνολο πρόβλεψης, και το μοντέλο LEAR, το οποίο εκπαιδεύει ξεχωριστά αυτοπαλινδρομικά μοντέλα για κάθε χρονικό βήμα του ορίζοντα πρόβλεψης, το XGBoost χρησιμοποιεί ένα ενιαίο, πολυδιάστατο μοντέλο που εφαρμόζεται διαδοχικά για την παραγωγή όλων των αναλυτικών προβλέψεων.

```
model = XGBRegressor(
    learning_rate=0.05, max_depth=5, min_child_weight=4,
    n_estimators=200, subsample=0.9, objective='reg:squarederror'
)
model.fit(X_train_scaled, Y_train_scaled[:, 0])
```

Σχήμα 4.9 : Κώδικας σε Python για τον ορισμό και την εκπαίδευση του μοντέλου XGBoost

Η πρόβλεψη υλοποιείται με μεθοδολογία κλειστού βρόχου, όπως φαίνεται στο Σχήμα 4.10, μέσω της συνάρτησης `closed_loop_forecast_xgb()`. Σε κάθε βήμα του επαναληπτικού βρόχου, το παράθυρο εισόδου μετατρέπεται σε μονοδιάστατο διάνυσμα, κανονικοποιείται και τροφοδοτεί το εκπαιδευμένο μοντέλο για την παραγωγή της πρόβλεψης. Η τιμή αυτή μετασχηματίζεται εκ νέου στην αρχική της κλίμακα και ενσωματώνεται στο παράθυρο εισόδου, αντικαθιστώντας την παλαιότερη τιμή. Η διαδικασία επαναλαμβάνεται διαδοχικά, με την έξοδο κάθε χρονικού βήματος να αποτελεί είσοδο για το επόμενο, μέχρι να παραχθούν και οι 16 προβλέψεις του χρονικού ορίζοντα πρόβλεψης. Σημαντικό χαρακτηριστικό της προσέγγισης αυτής είναι ότι το ίδιο εκπαιδευμένο μοντέλο εφαρμόζεται σε κάθε χρονικό βήμα, χωρίς να απαιτείται εκ νέου προσαρμογή παραμέτρων.

```

def closed_loop_forecast_xgb(model, X_init, df_full, ts_init, scaler_X, scaler_Y, window_size):
    current_window = X_init.copy()
    predictions = []
    timestamps = []

    for step in range(FORECAST_HORIZON):
        x_input = current_window.flatten().reshape(1, -1)
        x_scaled = scaler_X.transform(x_input)
        y_scaled = model.predict(x_scaled)
        y_pred = scaler_Y.inverse_transform(y_scaled.reshape(-1, 1))[0, 0]
        predictions.append(y_pred)

        last_ts = ts_init[-1]
        next_ts = last_ts + pd.Timedelta(minutes=30)

        if next_ts not in df_full.index:
            future_timestamps = df_full.index[df_full.index > next_ts]
            if len(future_timestamps) == 0:
                print(f"⚠ Δεν βρέθηκε επόμενο timestamp μετά το {next_ts}. Τερματισμός batch.")
                break
            next_ts = future_timestamps[0]
            print(f"📅 Παράκαμψη: Χρησιμοποιείται το επόμενο διαθέσιμο timestamp: {next_ts}")

        next_row = df_full.loc[next_ts, FEATURE_COLS].copy()
        next_row["BM Price (Euros/MWh)"] = y_pred

        current_window = np.vstack([current_window[1:], next_row.values])
        ts_init = list(ts_init[1:]) + [next_ts]
        timestamps.append(next_ts)

    return predictions, timestamps

```

Σχήμα 4.10: Κώδικας σε Python για τη διαδικασία πρόβλεψης XGBoost με μεθοδολογία κλειστού βρόχου μέσω της συνάρτησης `closed_loop_forecast_xgb`

Η παραπάνω διαδικασία ενσωματώνεται στον βασικό βρόχο αξιολόγησης, όπου για κάθε υποσύνολο του συνόλου ελέγχου εφαρμόζεται διαδοχικά η διαδικασία πρόβλεψης, ξεκινώντας από το τελευταίο διαθέσιμο παράθυρο εισόδου και προχωρώντας στην εκτίμηση των επόμενων 16 χρονικών σημείων. Σε κάθε επανάληψη, οι προβλέψεις που παράγονται προστίθενται στις αντίστοιχες λίστες με τις πραγματικές τιμές, τα χρονικά σημεία και την ένδειξη του αντίστοιχου διαστήματος. Η υλοποίηση αυτής της λογικής παρουσιάζεται στο Σχήμα 4.11, όπου αποτυπώνεται η διαδοχική εφαρμογή του μοντέλου σε όλα τα διαστήματα ελέγχου και η συλλογή των αποτελεσμάτων. Μετά την ολοκλήρωση της διαδικασίας για όλα τα χρονικά υποσύνολα, τα αποτελέσματα συγκεντρώνονται και αποθηκεύονται για περαιτέρω ανάλυση και αξιολόγηση. Τα τελικά αποτελέσματα περιλαμβάνουν για κάθε χρονική στιγμή, την πραγματική τιμή του στόχου πρόβλεψης, την αντίστοιχη πρόβλεψη και την ένδειξη του διαστήματος στο οποίο ανήκει.

```

all_predictions = []
all_true = []
all_timestamps = []
all_batches = []

for i, X_init in enumerate(X_test_list):
    ts_init = X_test_debug[i][0]
    preds, ts_forecast = recursive_forecast(model, X_init, df_month, ts_init, scaler_X, scaler_Y, window_size)

    if preds is None or ts_forecast is None:
        continue # Παράλειψε το batch αν το timestamp έλειπε

    all_predictions.extend(preds)
    all_true.extend(Y_test[i])
    all_timestamps.extend(ts_forecast)
    all_batches.extend([i + 1] * FORECAST_HORIZON)

results_dir = f"XGB_recursive_results_2021/{country}/Month_{month_name}"
os.makedirs(results_dir, exist_ok=True)

df_result = pd.DataFrame({
    "Timestamp": all_timestamps,
    "Actual": all_true,
    "Forecast": all_predictions,
    "Batch": all_batches
})
df_result.to_csv(f"{results_dir}/results_window_{window_size}.csv", index=False)

```

Σχήμα 4.11: Κώδικας σε Python για την επαναληπτική διαδικασία πρόβλεψης για όλα τα χρονικά υποσύνολα ελέγχου με χρήση του μοντέλου XGBoost

Με αυτόν τον τρόπο, το XGBoost εφαρμόζεται σε διακριτά χρονικά διαστήματα με σκοπό τη βραχυχρόνια πρόβλεψη της τιμής εξισορρόπησης. Χάρη στη σταθερότητα του μοντέλου και στη δυνατότητα αποδοτικής αξιοποίησης δομημένων ιστορικών δεδομένων, η προσέγγιση αυτή επιτρέπει γρήγορη και ακριβή πρόβλεψη χωρίς ανάγκη επανεκπαίδευσης, ενισχύοντας την αξιοπιστία του μοντέλου στις εφαρμογές της αγοράς ηλεκτρικής ενέργειας.

4.3 ΔΕΙΚΤΕΣ ΑΞΙΟΛΟΓΗΣΗΣ

Η αξιολόγηση της απόδοσης των μοντέλων πρόβλεψης που παρουσιάστηκαν στην Ενότητα 4.2 πραγματοποιείται μέσω της ποσοτικής σύγκρισης μεταξύ των προβλεπόμενων και των πραγματικών τιμών. Για τον σκοπό αυτό χρησιμοποιούνται τυπικοί στατιστικοί δείκτες σφάλματος, οι οποίοι έχουν καθιερωθεί στη βιβλιογραφία ως αξιόπιστα εργαλεία εκτίμησης της ακρίβειας πρόβλεψης και προσφέρουν διαφορετικές οπτικές αξιολόγησης, αλληλοσυμπληρούμενοι ως προς τα πλεονεκτήματά τους:

- **Τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος (RMSE)**

Ο δείκτης RMSE αποτυπώνει τη μέση τετραγωνική απόκλιση μεταξύ των προβλεπόμενων και των πραγματικών τιμών. Δίνει μεγαλύτερη βαρύτητα στα ακραία σφάλματα, καθώς υπολογίζεται το τετράγωνο της διαφοράς για κάθε πρόβλεψη. Στο πλαίσιο της παρούσας διπλωματικής εργασίας, η μονάδα μέτρησης του δείκτη RMSE είναι €/MWh, καθώς αφορά την απόκλιση της προβλεπόμενης

τιμής ηλεκτρικής ενέργειας στη Αγορά Εξισορρόπησης. Ο μαθηματικός τύπος δίνεται από την σχέση (4.7) [29]:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.7)$$

- **Μέσο Απόλυτο Σφάλμα (MAE)**

Ο δείκτης MAE αντιπροσωπεύει τη μέση απόλυτη τιμή των σφαλμάτων μεταξύ των προβλεπόμενων και των πραγματικών τιμών και ερμηνεύεται με τρόπο απλό και άμεσα συγκρίσιμο. Επιπλέον, παρέχει πιο ισορροπημένη αποτίμηση από το RMSE, καθώς δεν δίνει δυσανάλογο βάρος στα μεγάλα σφάλματα. Όπως και το RMSE, εκφράζεται σε €/MWh, καθώς αποτιμά άμεσα τη διαφορά μεταξύ των προβλεπόμενων και των πραγματικών τιμών. Ο υπολογισμός του περιγράφεται από την σχέση (4.8) [29]:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.8)$$

- **Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (sMAPE)**

Ο δείκτης sMAPE προσδιορίζει το σφάλμα πρόβλεψης σε ποσοστιαία μορφή, κανονικοποιώντας τη διαφορά με βάση τον μέσο όρο των πραγματικών και των προβλεπόμενων τιμών. Το χαρακτηριστικό αυτό προσδίδει συμμετρία στην αποτίμηση υπερεκτιμήσεων και υποεκτιμήσεων, ενώ επιτρέπει τη σύγκριση διαφορετικών χρονικών περιόδων ή μεταβλητών με διαφορετική κλίμακα. Η τελική του τιμή εκφράζεται ως ποσοστό επί τοις εκατό (%) και ο μαθηματικός του τύπος περιγράφεται από τη σχέση (4.9) [30]:

$$\text{sMAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{(|y_i| + |\hat{y}_i|)/2} \quad (4.9)$$

Οι παραπάνω μετρικές εφαρμόζονται πάνω στο σύνολο προβλέψεων που προκύπτει από τη λειτουργία κάθε μοντέλου πρόβλεψης, όπως αναλύθηκε στην Ενότητα 4.2. Σε κάθε περίπτωση, συλλέγονται οι πραγματικές και προβλεπόμενες τιμές ανά χρονική στιγμή, για κάθε μήνα και κάθε μέγεθος παραθύρου, και υπολογίζονται οι δείκτες RMSE και MAE με τις συναρτήσεις `mean_squared_error` και `mean_absolute_error` της βιβλιοθήκης *sklearn.metrics*, ενώ ο δείκτης sMAPE υπολογίζεται μέσω της συνάρτησης `sMAPE()` από τη βιβλιοθήκη *epftoolbox.evaluation* σύμφωνα με τον ορισμό της Εξίσωσης (4.9). Με τον τρόπο αυτό, εξάγονται συγκρίσιμα και αναπαραγώγιμα αποτελέσματα για κάθε χρονική στιγμή πρόβλεψης, τα οποία επιτρέπουν την αντικειμενική και τεκμηριωμένη αποτίμηση της απόδοσης των μοντέλων. Η παρουσίαση και ανάλυση των αποτελεσμάτων αυτών, ανά μοντέλο, μήνα, χώρα και εκπαιδευτικό σενάριο, παρατίθεται στο Κεφάλαιο 5, το οποίο επικεντρώνεται στη συγκριτική αξιολόγηση των μοντέλων πρόβλεψης βάσει των παραπάνω δεικτών.

ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΣΥΓΚΡΙΤΙΚΗ ΑΞΙΟΛΟΓΗΣΗ

5.1 ΕΙΣΑΓΩΓΗ

Το παρόν κεφάλαιο επικεντρώνεται στην αξιολόγηση της απόδοσης των τριών υπό μελέτη μοντέλων πρόβλεψης, ARIMA, LEAR και XGBoost, ως προς την ικανότητά τους να προβλέψουν τις τιμές ηλεκτρικής ενέργειας στην Αγορά Εξισορρόπησης. Η αξιολόγηση πραγματοποιείται με βάση τρεις βασικούς δείκτες σφάλματος, οι οποίοι αναλύθηκαν θεωρητικά στην Ενότητα 4.3: το Μέσο Απόλυτο Σφάλμα (MAE), το Μέσο Τετραγωνικό Σφάλμα (RMSE) και το Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (sMAPE). Η παρουσίαση των αποτελεσμάτων οργανώνεται σε δύο βασικούς άξονες: αρχικά εξετάζεται η ακρίβεια πρόβλεψης των μοντέλων με χρήση δεδομένων αποκλειστικά για ένα μήνα, ενώ στη συνέχεια αξιολογείται η συμπεριφορά τους ως προς το μέγεθος του χρονικού παραθύρου εισόδου. Επιπλέον, στο πλαίσιο του κεφαλαίου παρουσιάζεται η συγκριτική αποτίμηση των μοντέλων ανά χώρα, η ανάδειξη των βέλτιστων συνδυασμών μοντελοποίησης ανά περίπτωση, καθώς και η σύγκριση των αποτελεσμάτων πρόβλεψης για την περίπτωση της Ιρλανδίας με ευρήματα από τη σχετική βιβλιογραφία.

Για λόγους σύγκρισης και αποτίμησης της γενικής ικανότητας των υπό μελέτη μεθόδων πρόβλεψης, ως βασικό σημείο αναφοράς χρησιμοποιείται το απλούστερο δυνατό μοντέλο, γνωστό ως *Naive* ή *Persistence*. Το μοντέλο αυτό βασίζεται στην παραδοχή ότι η μελλοντική τιμή της μεταβλητής στόχου μπορεί να εκτιμηθεί αποκλειστικά με βάση την τιμή που είχε καταγραφεί σε συγκεκριμένο παρελθοντικό χρονικό σημείο, χωρίς τη χρήση εξωτερικών χαρακτηριστικών ή την εφαρμογή μαθηματικών μετασχηματισμών. Στο πλαίσιο της παρούσας διπλωματικής εργασίας, η πρόβλεψη κάθε χρονικής στιγμής βασίζεται στη τιμή που παρατηρήθηκε ακριβώς 48 χρονικά βήματα νωρίτερα, δηλαδή την ίδια ώρα της προηγούμενης ημέρας, δεδομένου ότι η χρονοσειρά είναι καταγεγραμμένη σε χρονικά βήματα των 30 λεπτών. Η απλότητα της προσέγγισης αυτής δεν επιτρέπει δυναμική προσαρμογή στις διακυμάνσεις των δεδομένων, ενώ καθιστά την αξιολόγηση ως προς τον δείκτη sMAPE προβληματική, καθώς ενδέχεται να προκύψουν μη ορισμένες ή ακραίες τιμές σφάλματος. Παρά τους περιορισμούς της, η μέθοδος αυτή αποτελεί καθιερωμένο σημείο αναφοράς στη βιβλιογραφία πρόβλεψης τιμών ενέργειας, ιδίως όταν εξετάζεται η αξιοπιστία πιο σύνθετων μοντέλων, και περιγράφεται από τη σχέση (5.1) [18],[35]:

$$\hat{Y}_t = Y_{t-48} \quad (5.1)$$

Στον Πίνακα 5.1 παρουσιάζεται ο μέσος όρος της Τιμής Εξισορρόπησης για κάθε χώρα, κατά το έτος 2021, το οποίο αποτελεί το έτος μελέτης της παρούσας διπλωματικής εργασίας. Όπως διαπιστώνεται, η Ιρλανδία εμφανίζει τη μεγαλύτερη μέση τιμή, γεγονός που καταδεικνύει την έντονη

δυναμική και μεταβλητότητα της αγοράς, όπως παρουσιάστηκε στην Υποενότητα 2.3.1. Αντίθετα, η Ισπανία καταγράφει τη μικρότερη τιμή, υποδηλώνοντας έναν πιο ήπιο και σταθερό χαρακτήρα αγοράς, σύμφωνα με την περιγραφή της Υποενότητας 2.3.2. Η Βελγική αγορά εξισορρόπησης παρουσιάζει επίσης υψηλή μέση τιμή, ελαφρώς χαμηλότερη από εκείνη της Ιρλανδίας, κάτι που συνάδει με τη συμμετοχή της σε διασυννοριακούς μηχανισμούς και την περιοδική εμφάνιση υψηλών αποκλίσεων, όπως αναλύθηκε στην Υποενότητα 2.3.3.

Πίνακας 5.1: Μέση τιμή ηλεκτρικής ενέργειας στην Αγορά Εξισορρόπησης (€/MWh) ανά χώρα για το έτος 2021

Χώρα	Μέση τιμή Εξισορρόπησης (€/MWh)
Ιρλανδία	105.94
Ισπανία	57.89
Βέλγιο	97.69

5.2 ΔΙΕΡΕΥΝΗΣΗ ΑΠΟΔΟΣΗΣ ΑΝΑ ΜΗΝΑ ΚΑΙ ΧΡΟΝΙΚΟ ΠΑΡΑΘΥΡΟ ΕΚΠΑΙΔΕΥΣΗΣ


Η ενότητα αυτή παρουσιάζει αναλυτικά τα αποτελέσματα αξιολόγησης των τριών μοντέλων πρόβλεψης (ARIMA, LEAR και XGBoost), καθώς και του απλούστερου μοντέλου Naïve, για κάθε μία από τις τρεις εξεταζόμενες χώρες. Η παρουσίαση γίνεται σε δύο διαστάσεις: αρχικά ανά μήνα για όλο το έτος μελέτης, ώστε να αναδειχθεί η χρονική συμπεριφορά κάθε μεθόδου, και στη συνέχεια ανά μέγεθος του χρονικού παραθύρου εισόδου, με στόχο την αποτύπωση της ευαισθησίας των μοντέλων σε διαφορετικούς όγκους ιστορικής πληροφορίας. Για κάθε περίπτωση παρατίθενται πίνακες με τις τιμές των δεικτών σφάλματος (MAE, RMSE, sMAPE), καθώς και διαγράμματα που απεικονίζουν τη μεταβολή των τιμών των δεικτών ανά μήνα και μέγεθος παραθύρου, για κάθε μοντέλο πρόβλεψης. Η ερμηνεία των αποτελεσμάτων γίνεται εντός των επιμέρους υποενοτήτων, με στόχο την αναγνώριση πλεονεκτημάτων και αδυναμιών κάθε προσέγγισης ανά αγορά.

5.2.1 Ιρλανδία

Η παρουσίαση των αποτελεσμάτων ξεκινά με την περίπτωση της Ιρλανδικής αγοράς εξισορρόπησης, μιας αγοράς που χαρακτηρίζεται από έντονη μεταβλητότητα και σύνθετες δυναμικές, όπως παρουσιάστηκε στην Υποενότητα 2.3.1. Σημειώνεται ότι για την περίπτωση της Ιρλανδίας, η μηνιαία αξιολόγηση δεν περιλαμβάνει τον Δεκέμβριο λόγω σημαντικής έλλειψης διαθέσιμων δεδομένων, όπως αναλύθηκε στην Ενότητα 3.3. Αρχικά εξετάζεται η επίδοση των τριών βασικών μοντέλων πρόβλεψης (ARIMA, LEAR και XGBoost) και του μοντέλου αναφοράς σε μηνιαία ανάλυση, ώστε να αναδειχθεί η εποχική συμπεριφορά τους κατά τη διάρκεια του 2021.

Πίνακας 5.2: Μηνιαία ανάλυση του δείκτη MAE (€/MWh) για την Ιρλανδία ανά μοντέλο πρόβλεψης

Μήνας	Μέσο Απόλυτο σφάλμα (MAE) €/MWh			
	ARIMA	LEAR	XGB	Naive
1	40.55	40.49	51.43	51.09
2	48.55	42.14	52.58	44.53
3	34.86	37.56	44.91	48.83
4	49.56	49.23	55.47	58.82
5	52.70	53.02	54.32	60.91
6	38.83	48.94	40.23	48.72
7	56.75	70.81	64.12	97.31
8	28.20	38.54	36.13	32.85
9	68.27	488.80	279.75	85.84
10	87.30	78.31	97.92	107.28
11	74.16	73.56	80.28	85.53



Σχήμα 5.1: Διάγραμμα μηνιαίας ανάλυσης του δείκτη MAE (€/MWh) για την Ιρλανδία ανά μοντέλο πρόβλεψης

Από τον Πίνακα 5.2 και το Σχήμα 5.1 προκύπτει ότι το μοντέλο ARIMA καταγράφει τις χαμηλότερες τιμές MAE σε έξι από τους έντεκα μήνες αξιολόγησης, με ιδιαίτερα καλή επίδοση κατά το πρώτο οκτάμηνο. Η μεθοδολογία LEAR σημειώνει τη βέλτιστη απόδοση σε πέντε μήνες, με ανταγωνιστικές τιμές σφάλματος κυρίως στο πρώτο εξάμηνο, αλλά καταγράφει απότομη επιδείνωση της απόδοσης τον Σεπτέμβριο, με τιμή MAE που εκτοξεύεται στα 488.80 €/MWh. Αντίστοιχα, το XGBoost παρουσιάζει γενικά υψηλότερα σφάλματα από τα υπόλοιπα μοντέλα, χωρίς να υπερέχει σε καμία περίοδο, ενώ χαρακτηρίζεται από έντονη αστάθεια. Η πιο ακραία τιμή του XGBoost καταγράφεται επίσης τον Σεπτέμβριο (279.75 €/MWh), γεγονός που επιβεβαιώνει τη δυσκολία πρόβλεψης κατά τη διάρκεια αυτής της περιόδου. Η έντονη επιδείνωση της ακρίβειας τον Σεπτέμβριο αποδίδεται σε

εξωτερικούς ενεργειακούς και λειτουργικούς παράγοντες που επηρέασαν σημαντικά την αγορά, όπως αναλύεται στο τέλος της παρούσας υποενότητας.

Ενδιαφέρον παρουσιάζει το γεγονός ότι το μοντέλο ARIMA επηρεάζεται λιγότερο από όλα τα υπόλοιπα τον Σεπτέμβριο, ενώ και το Naive καταγράφει χαμηλότερο σφάλμα σε σχέση με τις πολυμεταβλητές μεθόδους LEAR και XGBoost. Η συμπεριφορά αυτή ενδέχεται να συνδέεται με τη φύση τους ως μονομεταβλητά μοντέλα, τα οποία βασίζονται αποκλειστικά στην ιστορική εξέλιξη της τιμής εξισορρόπησης και όχι σε εξωτερικά χαρακτηριστικά, όπως η πρόβλεψη παραγωγής από ΑΠΕ ή η ζήτηση. Παρότι το Naive καταγράφει αυξημένο σφάλμα (85.84 €/MWh), η τιμή αυτή είναι σαφώς χαμηλότερη από εκείνες των πολυμεταβλητών μεθόδων, γεγονός που ενισχύει την παρατήρηση ότι, σε περιόδους έντονης αβεβαιότητας, τα ιστορικά μονομεταβλητά μοντέλα μπορεί να επιδεικνύουν μεγαλύτερη ανθεκτικότητα σε ακραίες διακυμάνσεις. Αντίθετα, η εξάρτηση των LEAR και XGBoost από εξωγενείς εισόδους ενδέχεται να καθιστά τα μοντέλα αυτά πιο ευάλωτα σε συνθήκες κρίσης, οδηγώντας σε σημαντική επιδείνωση της απόδοσης. Το εύρημα αυτό αποτελεί κρίσιμο συμπέρασμα για τη στρατηγική επιλογή χαρακτηριστικών εισόδου. Επιπλέον, κατά τον Αύγουστο, το Naive πλησιάζει τις επιδόσεις των πιο εξελιγμένων μεθόδων, γεγονός που υποδηλώνει ότι, σε περιόδους χαμηλής μεταβλητότητας, η απόδοσή του μπορεί να προσεγγίσει εκείνη πιο σύνθετων μεθόδων.

Πίνακας 5.3: Μηνιαία ανάλυση του δείκτη RMSE (€/MWh) για την Ιρλανδία ανά μοντέλο

	Τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) €/MWh			
Μήνας	ARIMA	LEAR	XGB	Naive
1	54.13	53.73	66.18	67.98
2	67.61	57.08	68.28	62.41
3	50.17	52.59	61.44	65.93
4	70.98	65.08	75.42	78.93
5	79.35	69.74	75.92	93.19
6	63.22	76.18	68.05	85.42
7	84.28	100.50	98.13	149.45
8	37.49	49.27	46.05	43.95
9	90.37	807.95	373.74	110.81
10	109.25	100.28	124.78	130.66
11	98.60	94.95	101.12	116.44


Η εικόνα που προκύπτει από τον Πίνακα 5.3 είναι απολύτως ευθυγραμμισμένη με τα συμπεράσματα του δείκτη MAE. Το μοντέλο ARIMA εξακολουθεί να επιτυγχάνει τη χαμηλότερη τιμή RMSE στους περισσότερους μήνες, όπως ενδεικτικά φαίνεται τον Μάρτιο (50.17 €/MWh) και τον Ιούλιο (37.49 €/MWh). Το μοντέλο LEAR παραμένει ανταγωνιστικό σε αρκετές περιόδους, αλλά παρουσιάζει εξαιρετικά μεγάλη απόκλιση τον Σεπτέμβριο, φτάνοντας σε τιμή 807.95 €/MWh. Το XGBoost, αν και εμφανίζει ηπιότερη ακραία τιμή (373.74 €/MWh), παραμένει ασταθές και δεν υπερέχει σε κανέναν μήνα. Το φαινόμενο αυτό αποδίδεται, όπως αναλύεται στο τέλος της υποενότητας, σε εξωτερικούς παράγοντες που φαίνεται να επηρεάζουν δυσμενώς την ακρίβεια των πολυμεταβλητών μοντέλων.

Σε αυτό το πλαίσιο, ενδιαφέρον παρουσιάζει και η σύγκριση με το μοντέλο Naive, το οποίο καταγράφει συστηματικά χαμηλότερη απόδοση συγκριτικά με τις υπόλοιπες μεθόδους σε όλη τη διάρκεια του έτους. Παρόλα αυτά, τον Αύγουστο (43.95 €/MWh) εμφανίζει τιμές που δεν αποκλίνουν σημαντικά από τα πολυμεταβλητά μοντέλα, ενώ παραμένει αισθητά πιο σταθερό από το LEAR και το

XGBoost τον Σεπτέμβριο. Το γεγονός αυτό αναδεικνύει την αξία του ως σημείο σύγκρισης, αλλά και τονίζει τη σημασία της συνετής επιλογής χαρακτηριστικών εισόδου, ειδικά σε περιόδους αυξημένης αστάθειας. Σε αυτό το πλαίσιο, ο δείκτης RMSE, λόγω της ευαισθησίας του σε ακραίες τιμές, καθιστά αναγκαία την προσεκτική ερμηνεία των αποτελεσμάτων, χωρίς ωστόσο να μεταβάλλει ουσιαστικά την κατάταξη των μοντέλων ως προς τη συνολική τους επίδοση.

Πίνακας 5.4: Μηνιαία ανάλυση του δείκτη sMAPE (%) για την Ιρλανδία ανά μοντέλο πρόβλεψης

	Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (sMAPE) %		
Μήνας	ARIMA	LEAR	XGB
1	66.34	67.41	84.66
2	80.23	70.94	88.70
3	82.19	79.42	92.06
4	45.26	48.95	51.10
5	44.42	48.33	55.89
6	32.13	46.98	34.28
7	40.43	50.53	41.34
8	18.51	26.52	24.33
9	39.59	108.27	94.84
10	51.24	46.80	67.92
11	44.43	45.47	49.88



Σχήμα 5.2: Διάγραμμα μηνιαίας ανάλυσης του δείκτη sMAPE (%) για την Ιρλανδία ανά μοντέλο πρόβλεψης


Από τον Πίνακα 5.4 και το Σχήμα 5.2 προκύπτει ότι κατά τη θερινή περίοδο, και ειδικά τον Αύγουστο, όλα τα μοντέλα παρουσιάζουν αισθητά χαμηλότερα ποσοστιαία σφάλματα, γεγονός που ενδέχεται να οφείλεται σε μειωμένη μεταβλητότητα της αγοράς. Τον Σεπτέμβριο η προσέγγιση LEAR εμφανίζει σοβαρή επιδείνωση με sMAPE άνω του 100%, ενώ και οι υπόλοιπες μέθοδοι καταγράφουν αυξημένη μεταβλητότητα. Το μοντέλο XGBoost παρουσιάζει υψηλά ποσοστιαία σφάλματα κατά τους πρώτους μήνες του έτους και τον Σεπτέμβριο (έως και 94.84%), ενώ εμφανίζει μεγαλύτερη σταθερότητα κατά την καλοκαιρινή περίοδο. Η απόδοση του μοντέλου ARIMA είναι υποδεέστερη κατά τους πρώτους τέσσερις μήνες συγκριτικά με τους υπόλοιπους μήνες του έτους. Συνολικά, οι διαφορές μεταξύ των μοντέλων είναι πιο ήπιες, καθώς οι ποσοστιαίες αποκλίσεις κινούνται σε παρόμοια επίπεδα.

Έχοντας αναδείξει τις διαφοροποιήσεις στην απόδοση των μοντέλων πρόβλεψης σε μηνιαία βάση, η ανάλυση επεκτείνεται στη διερεύνηση της επίδρασης του χρονικού παραθύρου εισόδου στην ακρίβεια των προβλέψεων. Εξετάζεται κατά πόσο το μέγεθος του ιστορικού χρονικού διαστήματος που χρησιμοποιείται ως είσοδος επηρεάζει τη συμπεριφορά κάθε προσέγγισης, αναδεικνύοντας ενδεχόμενα πλεονεκτήματα ή αδυναμίες υπό διαφορετικά επίπεδα πληροφορίας.

Από τον Πίνακα 5.5 και το Σχήμα 5.3 διαπιστώνεται ότι η προσέγγιση ARIMA επιτυγχάνει σταθερά τη χαμηλότερη τιμή του δείκτη MAE, με σαφή τάση βελτίωσης καθώς αυξάνεται το χρονικό παράθυρο εισόδου, φτάνοντας σε ελάχιστο σφάλμα 49.34 €/MWh για παράθυρο εκπαίδευσης που αντιστοιχεί σε επτά ημέρες παρελθοντικών τιμών. Η μέθοδος LEAR παρουσιάζει τη βέλτιστη επίδοση στο ιστορικό παράθυρο των 72 ημιώρων (74.34 €/MWh), ωστόσο εμφανίζει σημαντικές διακυμάνσεις σε μικρότερα ή μεγαλύτερα παράθυρα, χωρίς ξεκάθαρη τάση βελτίωσης. Το μοντέλο XGBoost καταγράφει και αυτό τη χαμηλότερη τιμή του στο παράθυρο των 72 ημιώρων (61.19 €/MWh), αλλά συνολικά παρουσιάζει υψηλότερα σφάλματα συγκριτικά με το ARIMA.

Πίνακας 5.5: Ανάλυση του δείκτη MAE (€/MWh) για την Ιρλανδία ανά χρονικό παράθυρο εκπαίδευσης και μοντέλο πρόβλεψης

Μοντέλο	Μέσο Απόλυτο σφάλμα (MAE) €/MWh				
	Χρονικό Παράθυρο Εισόδου (ημίωρα)				
	48	72	96	144	336
ARIMA	55.52	53.29	52.87	52.50	49.34
LEAR	122.14	74.34	90.33	92.08	85.38
XGB	95.25	61.19	79.64	76.94	76.60
Naive	60.14				



Σχήμα 5.3: Διάγραμμα ανάλυσης του δείκτη MAE (€/MWh) για την Ιρλανδία ανά χρονικό παράθυρο εισόδου και μοντέλο πρόβλεψης

Η επίδοση του μοντέλου Naive παραμένει αμετάβλητη σε όλα τα παράθυρα (60.14 €/MWh), γεγονός που δεν οφείλεται σε κάποια εσωτερική σταθερότητα αλλά στη φύση της μεθοδολογίας. Όπως αναλύθηκε στην Ενότητα 5.1, η πρόβλεψη βασίζεται απλώς στην τιμή της προηγούμενης ημέρας, ανεξαρτήτως του ιστορικού παραθύρου εισόδου, με αποτέλεσμα να μην μεταβάλλεται με βάση το παράθυρο εκπαίδευσης. Η σύγκριση δείχνει ότι, παρότι υστερεί έναντι του ARIMA, το Naive υπερέχει σε επιλεγμένες περιπτώσεις του LEAR και του XGBoost. Το εύρημα αυτό υπογραμμίζει την αξία του ως σημείο αναφοράς και αναδεικνύει τους περιορισμούς των πολυμεταβλητών μοντέλων όταν αυτά δεν προσαρμόζονται επαρκώς σε συνθήκες περιορισμένης πληροφορίας.

Πίνακας 5.6: Ανάλυση του δείκτη RMSE (€/MWh) για την Ιρλανδία ως προς το χρονικό παράθυρο εισόδου ανά μοντέλο πρόβλεψης

Μοντέλο	Τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) €/MWh				
	Χρονικό Παράθυρο Εισόδου (ημέωρα)				
	48	72	96	144	336
ARIMA	76.5	74.15	72.91	72.64	69.92
LEAR	183.83	100.73	141.71	146.47	121.51
XGB	132.03	81.74	107.66	103.45	101.97
Naive	83.76				

Από τον Πίνακα 5.6 προκύπτει ότι οι διαφοροποιήσεις στον δείκτη RMSE ακολουθούν την ίδια γενική τάση με τον MAE, επιβεβαιώνοντας τη συνολική υπεροχή του μοντέλου ARIMA. Καθώς αυξάνεται το χρονικό βάθος, η τιμή του RMSE για το μοντέλο ARIMA μειώνεται σταδιακά, με την καλύτερη επίδοση να καταγράφεται στο παράθυρο των 336 ημιώρων (69.92 €/MWh). Οι μέθοδοι LEAR και XGBoost επιτυγχάνουν τη βέλτιστη απόδοσή τους στο παράθυρο των 72 ημιώρων (100.73 και 81.74 €/MWh, αντίστοιχα), ωστόσο υπολείπονται σημαντικά έναντι του ARIMA για όλα τα χρονικά διαστήματα. Στο πλαίσιο αυτό, το μοντέλο Naïve υπερέχει του LEAR και του XGBoost σχεδόν σε όλες τις περιπτώσεις, με μοναδική εξαίρεση το παράθυρο των 72 ημιώρων, όπου το XGBoost αποδίδει καλύτερα. Το εύρημα αυτό αναδεικνύει, έμμεσα, τους περιορισμούς των πολυμεταβλητών μεθόδων όταν εφαρμόζονται υπό συνθήκες περιορισμένης πληροφορίας, όπου η εξάρτησή τους από εξωτερικές μεταβλητές δεν συνοδεύεται από επαρκή προγνωστική ισχύ.

Πίνακας 5.7: Ανάλυση του δείκτη sMAPE (%) για την Ιρλανδία ως προς το χρονικό παράθυρο εισόδου ανά μοντέλο πρόβλεψης

Μοντέλο	Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (sMAPE) %				
	Χρονικό Παράθυρο Εισόδου (ημίωρα)				
	48	72	96	144	336
ARIMA	52.74	49.87	49.98	49.17	45.86
LEAR	60.88	57.65	56.04	58.40	57.77
XGB	61.54	65.28	61.68	61.99	60.87

Από τον Πίνακα 5.7 διαπιστώνεται ότι ο δείκτης sMAPE ακολουθεί την ίδια γενική τάση με τους δείκτες MAE και RMSE, επιβεβαιώνοντας την υπεροχή του μοντέλου ARIMA για μεγαλύτερα παράθυρα εισόδου. Η σειρά κατάταξης των μοντέλων παραμένει σταθερή, χωρίς αξιοσημείωτες διαφοροποιήσεις, γεγονός που περιορίζει την προστιθέμενη αξία του δείκτη στην παρούσα ανάλυση.

Συνοψίζοντας, διαπιστώνεται ότι το μοντέλο ARIMA παρουσιάζει τη σταθερότερη και πιο αξιόπιστη απόδοση στην Ιρλανδική αγορά εξισορρόπησης, τόσο σε μηνιαίο επίπεδο όσο και ως προς το βάθος του χρονικού παραθύρου εισόδου. Η απόδοσή του ενισχύεται σταθερά με την αύξηση των εισόδων, επιτυγχάνοντας τη βέλτιστη ακρίβεια για μεγάλα ιστορικά βάθη (7 ημέρες παρελθοντικών δεδομένων), ιδίως κατά τους θερινούς μήνες. Το μοντέλο XGBoost προσφέρει σταθερή, αν και ελαφρώς υποδεέστερη πρόβλεψη, με καλύτερα αποτελέσματα για χρονικά παράθυρα εισόδου μεσαίου μεγέθους (72 ημίωρα). Η μεθοδολογία LEAR εμφανίζει έντονη αστάθεια, με εξαιρετικά υψηλές αποκλίσεις τον Σεπτέμβριο, όπως καταδεικνύεται από όλους τους δείκτες σφάλματος και ιδιαίτερα από τον MAE, όπου καταγράφεται μέσο απόλυτο σφάλμα ίσο με 488.8 €/MWh, και τον δείκτη sMAPE, όπου καταγράφεται ποσοστιαίο σφάλμα άνω του 100%.

Αξίζει να σημειωθεί ότι η γενικότερη υποβάθμιση της απόδοσης όλων των μοντέλων τον Σεπτέμβριο μπορεί να αποδοθεί σε εξωτερικούς παράγοντες που επηρέασαν την αγορά εξισορρόπησης. Συγκεκριμένα, εκείνη την περίοδο σημειώθηκε σημαντική αστάθεια στις τιμές, λόγω της εκτίναξης των τιμών του φυσικού αερίου και της ταυτόχρονης μείωσης της παραγωγής από ανανεώσιμες πηγές ενέργειας, ιδίως την αιολική, οδηγώντας σε ακραίες τιμές και αυξημένη μεταβλητότητα στην Ιρλανδική αγορά εξισορρόπησης [31]. Παρόλο που όλα τα μοντέλα επηρεάστηκαν αρνητικά, το ARIMA παρουσίασε σαφώς μικρότερη επιδείνωση σε σχέση με τα


πολυμεταβλητά μοντέλα LEAR και XGBoost, ενώ και το Naive διατήρησε αξιοπρεπή επίδοση. Το γεγονός αυτό ενδέχεται να οφείλεται στη φύση των μοντέλων αυτών ως μονομεταβλητές προσεγγίσεις, οι οποίες βασίζονται αποκλειστικά στην ιστορική συμπεριφορά της ίδιας της τιμής εξισορρόπησης και επομένως εμφανίζονται πιο ανθεκτικές σε εξωτερικές διαταραχές. Αξιοσημείωτο είναι ότι οι τιμές του δείκτη MAE για το μοντέλο ARIMA αντιστοιχούν περίπου στο 50% της μέσης τιμής εξισορρόπησης στην Ιρλανδία (105.94 €/MWh, Πίνακας 5.1) κατά τη μηνιαία ανάλυση, και στο 47% στο βέλτιστο χρονικό παράθυρο εισόδου (336 ημίωρα), όπως προκύπτει από την ανάλυση ανά παράθυρο εκπαίδευσης. Το εύρημα αυτό αποτυπώνει τη δυσκολία επίτευξης χαμηλών σφαλμάτων ακόμη και από το βέλτιστο μοντέλο, εξαιτίας της έντονης μεταβλητότητας και της απρόβλεπτης συμπεριφοράς της Ιρλανδικής αγοράς εξισορρόπησης. Συνολικά, τα ευρήματα αυτά υπογραμμίζουν τη σημασία τόσο της εποχικότητας, όσο και της επιλογής κατάλληλου ιστορικού βάθους για τη βελτιστοποίηση των προβλέψεων σε απαιτητικές αγορές, όπως αυτή της Ιρλανδίας.

5.2.2 Ισπανία

Η παρουσίαση των αποτελεσμάτων συνεχίζεται με την περίπτωση της Ισπανικής Αγοράς Εξισορρόπησης, η οποία, όπως παρουσιάστηκε στην Υποενότητα 2.3.2, διακρίνεται από καθορισμένα λειτουργικά πλαίσια, χαμηλή μέση τιμή εξισορρόπησης, όπως παρουσιάζεται στον Πίνακα 5.1, και συγκεκριμένες δομικές ιδιαιτερότητες. Η Ισπανία χαρακτηρίζεται από υψηλή διείσδυση ανανεώσιμων πηγών ενέργειας, περιορισμένη διασυνδεσιμότητα με το υπόλοιπο ευρωπαϊκό δίκτυο και σχετικά ήπια εποχιακή μεταβλητότητα, στοιχεία που επηρεάζουν τη δυναμική και τη σταθερότητα της αγοράς. Αρχικά παρουσιάζεται η μηνιαία ανάλυση της απόδοσης των μοντέλων πρόβλεψης ARIMA, LEAR και XGBoost, με βάση αναφοράς το μοντέλο Naive, για κάθε μήνα του έτους 2021, με στόχο την ανάδειξη της χρονικής συμπεριφοράς τους στην Ισπανική αγορά.

Πίνακας 5.8: Μηνιαία ανάλυση του δείκτη MAE (€/MWh) για την Ισπανία ανά μοντέλο πρόβλεψης

Μήνας	Μέσο Απόλυτο σφάλμα (MAE) €/MWh			
	ARIMA	LEAR	XGB	Naive
1	9.35	14.96	12.60	11.95
2	9.70	22.25	10.12	14.78
3	10.47	13.97	10.72	11.52
4	5.93	7.40	6.64	7.53
5	5.70	14.96	18.64	10.20
6	11.47	12.53	14.58	17.21
7	11.31	20.61	13.84	17.95
8	8.11	24.06	12.36	11.66
9	18.31	30.86	18.65	22.15
10	37.52	126.81	44.57	43.40
11	29.40	39.42	25.01	28.24
12	64.50	108.09	88.27	78.55



Σχήμα 5.4: Διάγραμμα μηνιαίας ανάλυσης του δείκτη MAE (€/MWh) για την Ισπανία ανά μοντέλο πρόβλεψης

Από τον Πίνακα 5.8 και το Σχήμα 5.4 διαπιστώνεται ότι το μοντέλο ARIMA καταγράφει τις χαμηλότερες τιμές MAE στους περισσότερους μήνες, επιδεικνύοντας ιδιαίτερα σταθερή και αξιόπιστη απόδοση, ιδίως κατά το πρώτο οκτάμηνο. Αντίθετα, η μεθοδολογία LEAR χαρακτηρίζεται από έντονη αστάθεια, με εξαιρετικά υψηλά σφάλματα κατά το τελευταίο τρίμηνο, και με αποκορύφωμα τις τιμές του Οκτωβρίου και Δεκεμβρίου (126.81 και 108.09 €/MWh αντίστοιχα). Η διαφορά στη συμπεριφορά των δύο μοντέλων αναδεικνύει τη σημασία της προσαρμοστικότητας σε εποχικές διακυμάνσεις, καθώς, ενώ το ARIMA διατηρεί την ακρίβειά του σε μεταβαλλόμενες συνθήκες, το LEAR αποδίδει μόνο σε περιορισμένα χρονικά διαστήματα. Η γενικευμένη αύξηση των σφαλμάτων τον Δεκέμβριο, που καταγράφεται σε όλα τα μοντέλα, υποδηλώνει την παρουσία εξωγενών συνθηκών που επιδείνωσαν τη δυναμική της αγοράς, οι οποίες θα αναλυθούν στο τέλος της παρούσας υποενότητας.

Όσον αφορά τα υπόλοιπα μοντέλα, το μοντέλο XGBoost παρουσιάζει μερικώς ικανοποιητική συμπεριφορά, σημειώνοντας καλύτερες επιδόσεις έναντι του Naive στους περισσότερους μήνες, αλλά χωρίς να ξεχωρίζει σε ακρίβεια. Υπερέχει μόνο τον Νοέμβριο, ενώ τον Δεκέμβριο παρουσιάζει σαφή υποβάθμιση της απόδοσής του (88.27 €/MWh). Από την άλλη πλευρά, το Naive δεν καταγράφει την καλύτερη τιμή σε κανέναν μήνα, ωστόσο επιδεικνύει αξιοσημείωτη ανταγωνιστικότητα σε περιόδους ήπιας διακύμανσης. Για παράδειγμα, στους θερινούς μήνες, τον Οκτώβριο και τον Δεκέμβριο, η απόδοση του Naive συγκλίνει με εκείνη πιο σύνθετων μοντέλων, ενώ σε ορισμένες περιπτώσεις υπερέχει ακόμη και του XGBoost. Το εύρημα αυτό ενισχύει την άποψη ότι η εποχική σταθερότητα ή προβλεψιμότητα μπορεί να ευνοήσει την αποτελεσματικότητα απλών μονομεταβλητών προσεγγίσεων, ειδικά όταν η πληροφορία είναι περιορισμένη.

Όπως παρουσιάζεται στον Πίνακα 5.9, τα πρότυπα απόδοσης των μοντέλων στον δείκτη RMSE ευθυγραμμίζονται σε γενικές γραμμές με εκείνα του MAE. Λόγω της αυξημένης ευαισθησίας του RMSE σε ακραίες τιμές, οι περίοδοι αστάθειας αναδεικνύονται εντονότερα. Το μοντέλο ARIMA παραμένει το πιο αξιόπιστο στη διάρκεια του έτους, διατηρώντας χαμηλό σφάλμα στους περισσότερους μήνες και παρουσιάζοντας ιδιαίτερα σταθερή συμπεριφορά κατά τους πρώτους πέντε μήνες. Αντίθετα, το LEAR σημειώνει υψηλά σφάλματα κατά τους καλοκαιρινούς και φθινοπωρινούς

μήνες, με αποκορύφωμα τον Οκτώβριο (185.67 €/MWh) και τον Δεκέμβριο (143.89 €/MWh). Το XGBoost παρουσιάζει σταθερότερη εικόνα, αν και υστερεί αισθητά κατά τους τελευταίους μήνες του έτους. Το μοντέλο Naive, όπως και το ARIMA, εμφανίζεται ιδιαίτερα ανταγωνιστικό τον Δεκέμβριο, όπου ξεπερνά τόσο το LEAR, όσο και το XGBoost, επιβεβαιώνοντας ότι η απλότητα και η ιστορική συνέπεια μπορούν να λειτουργήσουν αποτελεσματικά υπό συνθήκες έντονης μεταβλητότητας.

Πίνακας 5.9: Μηνιαία ανάλυση του δείκτη RMSE (€/MWh) για την Ισπανία ανά μοντέλο πρόβλεψης


	Τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) €/MWh			
Μήνας	ARIMA	LEAR	XGB	Naive
1	14.52	19.85	16.48	18.00
2	12.46	30.51	12.80	18.41
3	13.90	19.62	13.70	15.20
4	8.34	10.02	8.62	9.88
5	8.67	20.70	21.25	12.03
6	17.45	18.53	18.82	24.41
7	16.12	31.76	18.59	25.04
8	10.86	34.45	15.46	15.04
9	23.26	49.82	24.42	26.99
10	52.09	185.67	58.11	57.63
11	39.00	56.58	32.42	38.18
12	93.00	143.89	110.42	99.11

Όπως παρουσιάζεται στον Πίνακα 5.10 και το Σχήμα 5.5, ο δείκτης sMAPE επιβεβαιώνει τη γενική υπεροχή του μοντέλου ARIMA, το οποίο καταγράφει τις χαμηλότερες ποσοστιαίες αποκλίσεις στους περισσότερους μήνες, ιδίως από τον Μάρτιο έως και τον Σεπτέμβριο. Το μοντέλο LEAR παρουσιάζει έντονες διακυμάνσεις, με ακραίες τιμές τον Φεβρουάριο (82.87 %) και τον Δεκέμβριο (97.32 %), ενώ το XGBoost εμφανίζει πιο σταθερή, αλλά όχι πάντα ακριβέστερη συμπεριφορά. Στους περισσότερους μήνες, το ARIMA καταγράφει το χαμηλότερο ποσοστιαίο σφάλμα, ενώ το XGBoost ακολουθεί με ελαφρώς υψηλότερες τιμές. Αξιοσημείωτη είναι η αύξηση του δείκτη sMAPE στους πρώτους μήνες του έτους (Ιανουάριος, Φεβρουάριος), όπως παρουσιάζεται στον Πίνακα 5.10, παρά τα σχετικά χαμηλά απόλυτα σφάλματα στους δείκτες MAE και RMSE. Το φαινόμενο αυτό αποδίδεται στη φύση του δείκτη, ο οποίος μετράει το σφάλμα σε σχέση με τον μέσο όρο προβλεπόμενης και πραγματικής τιμής. Συνεπώς, ακόμη και μικρές αποκλίσεις μπορεί να παράγουν υψηλές ποσοστιαίες τιμές όταν οι πραγματικές τιμές είναι χαμηλές. Αντιθέτως, η απότομη αύξηση του sMAPE τον Δεκέμβριο αντανakλά πραγματικά σημαντικά σφάλματα πρόβλεψης σε περιβάλλον υψηλών τιμών αγοράς, όπως έχει ήδη επισημανθεί και στους δείκτες MAE και RMSE.

Είναι αξιοσημείωτο ότι, σε αντίθεση με την Ιρλανδία (Υποενότητα 5.2.1), στην Ισπανική Αγορά Εξισορρόπησης δεν παρατηρείται αιχμή σφαλμάτων τον Σεπτέμβριο, ούτε σε απόλυτους, ούτε σε ποσοστιαίους δείκτες. Η διαφοροποίηση αυτή ενδέχεται να απορρέει από διαφορετικούς εξωτερικούς παράγοντες, αλλά και από την ίδια τη δομή και τη λειτουργική δυναμική της ισπανικής αγοράς, όπως θα παρουσιαστεί στη συνέχεια.

Πίνακας 5.10: Μηνιαία ανάλυση του δείκτη sMAPE (%) για την Ισπανία ανά μοντέλο πρόβλεψης

	Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (sMAPE) %		
Μήνας	ARIMA	LEAR	XGB
1	75.34	76.52	71.6
2	55.44	82.87	62.36
3	26.54	33.90	28.84
4	8.95	10.41	9.94
5	7.49	22.05	28.03
6	17.80	19.79	22.40
7	19.81	29.73	21.95
8	7.40	22.15	11.59
9	11.55	22.43	11.78
10	38.35	75.87	54.96
11	13.60	18.83	11.60
12	96.80	97.32	100.48




Σχήμα 5.5: Διάγραμμα μηνιαίας ανάλυσης του δείκτη sMAPE (%) για την Ισπανία ανά μοντέλο πρόβλεψης

Αφού εξετάστηκε η χρονική επίδοση των μοντέλων πρόβλεψης σε μηνιαία βάση, η ανάλυση επεκτείνεται πλέον στη διερεύνηση της επίδρασης του χρονικού παραθύρου εισόδου. Όπως και στην περίπτωση της Ιρλανδίας, αξιολογείται η ευαισθησία των μοντέλων σε διαφορετικά βάθη ιστορικής πληροφορίας, με στόχο την κατανόηση του τρόπου με τον οποίο το μέγεθος του παραθύρου εκπαίδευσης επηρεάζει την ακρίβεια των προβλέψεων στην Ισπανική Αγορά Εξισορρόπησης.

Πίνακας 5.11: Ανάλυση του δείκτη MAE (€/MWh) για την Ισπανία ανά χρονικό παράθυρο εκπαίδευσης και μοντέλο πρόβλεψης

Μοντέλο	Μέσο Απόλυτο σφάλμα (MAE) €/MWh				
	Χρονικό Παράθυρο Εισόδου				
	48	72	96	144	336
ARIMA	19.32	18.03	18.55	18.46	18.04
LEAR	30.70	30.75	41.02	49.04	30.11
XGB	22.12	19.64	23.95	24.12	25.16
Naive	22.93				

**Σχήμα 5.6:** Διάγραμμα ανάλυσης του δείκτη MAE (€/MWh) για την Ισπανία ανά χρονικό παράθυρο εισόδου και μοντέλο πρόβλεψης

Όπως παρουσιάζεται στον Πίνακα 5.11 και το Σχήμα 5.6, το μοντέλο ARIMA καταγράφει σταθερά χαμηλά σφάλματα σε όλα τα βάθη ιστορικού παραθύρου, με την καλύτερη επίδοση να σημειώνεται στα 72 και 336 ημέρες (18.03 και 18.04 €/MWh αντίστοιχα). Η συμπεριφορά του είναι σταθερή και ενδεικτική της προσαρμοστικότητας του μοντέλου σε διαφορετικά επίπεδα πληροφορίας. Αντίθετα, το μοντέλο LEAR παρουσιάζει σαφή επιδείνωση με την αύξηση του παραθύρου, φτάνοντας σε MAE 49.04 €/MWh στα 144 ημέρες, ενώ το XGBoost επιτυγχάνει τη βέλτιστη απόδοσή του για 72 ημέρες και στη συνέχεια επιδεινώνεται σταδιακά, φτάνοντας τα 25.16 €/MWh στο μέγιστο βάθος.

Αξιοσημείωτη είναι η εικόνα του μοντέλου Naive, το οποίο εμφανίζει σταθερή τιμή MAE (22.93 €/MWh) ανεξαρτήτως παραθύρου. Το γεγονός αυτό οφείλεται στη φύση της μεθοδολογίας, η οποία δεν βασίζεται σε σύνολο εισόδου μεταβλητού μεγέθους. Αν και η επίδοσή του φαίνεται

ανταγωνιστική σε μεγάλα παράθυρα, το αποτέλεσμα αυτό είναι εν μέρει παραπλανητικό, καθώς η τιμή του αντιστοιχεί στον μέσο όρο απόδοσης όλου του έτους 2021 και επηρεάζεται σημαντικά από τη σχετική ανθεκτικότητα του μοντέλου σε περιόδους όπως ο Δεκέμβριος. Η υπεροχή του ARIMA αναμένεται να επιβεβαιωθεί και στον δείκτη RMSE, ο οποίος λόγω της αυξημένης ευαισθησίας του στις μεγάλες αποκλίσεις ενδέχεται να αναδείξει με μεγαλύτερη σαφήνεια τις διαφορές μεταξύ των μοντέλων.

Όπως παρουσιάζεται στον Πίνακα 5.12, ο δείκτης RMSE επιβεβαιώνει τα πρότυπα απόδοσης που παρατηρήθηκαν στον MAE, με το μοντέλο ARIMA να διατηρεί την υπεροχή του σε όλα τα βάθη παραθύρου. Το LEAR εμφανίζει τη χειρότερη συμπεριφορά στα μεγαλύτερα παράθυρα, ενώ το XGBoost παρουσιάζει ήπια αύξηση RMSE σε μεγαλύτερα παράθυρα χωρίς απότομες μεταβολές. Το Naive διατηρεί σταθερή τιμή (30.00 €/MWh) σε όλα τα παράθυρα λόγω της φύσης του, με τις επιδόσεις του να παραμένουν κοντά στο XGBoost μόνο σε ορισμένες περιπτώσεις. Σε γενικές γραμμές, η εικόνα των μοντέλων δεν διαφοροποιείται δραστικά από εκείνη του δείκτη MAE, αν και ο RMSE αναδεικνύει με μεγαλύτερη σαφήνεια τη σταθερότητα του ARIMA σε διαφορετικά μεγέθη ιστορικού παραθύρου και την ανθεκτικότητά του σε τιμές μεμονωμένων αποκλίσεων.

Πίνακας 5.12: Ανάλυση του δείκτη RMSE (€/MWh) για την Ισπανία ανά χρονικό παράθυρο εκπαίδευσης και μοντέλο πρόβλεψης

Μοντέλο	Τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) €/MWh				
	Χρονικό Παράθυρο Εισόδου				
	48	72	96	144	336
ARIMA	27.22	25.06	25.69	25.62	25.44
LEAR	47.02	45.43	61.65	67.21	37.6
XGB	27.62	26.63	30.01	30.47	31.56
Naive	30.00				

Πίνακας 5.13: Ανάλυση του δείκτη sMAPE (%) για την Ισπανία ανά χρονικό παράθυρο εκπαίδευσης και μοντέλο πρόβλεψης

Μοντέλο	Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (sMAPE) %				
	Χρονικό Παράθυρο Εισόδου				
	48	72	96	144	336
ARIMA	32.33	31.07	31.56	31.7	31.28
LEAR	44.52	44.74	47.09	41.75	35.17
XGB	36.28	35.09	37.39	36.78	35.94

Όπως φαίνεται στον Πίνακα 5.13, οι διαφοροποιήσεις μεταξύ των μοντέλων ως προς τον δείκτη sMAPE είναι πιο ήπιες σε σχέση με τις απόλυτες μετρικές (MAE και RMSE). Το μοντέλο ARIMA διατηρεί την καλύτερη επίδοση για όλα τα βάθη παραθύρου, με την χαμηλότερη τιμή να καταγράφεται στο παράθυρο των 72 ημώρων, ωστόσο παρουσιάζει σημαντική βελτίωση στο μέγιστο παράθυρο εισόδου (336 ημώρων), εύρημα που επιβεβαιώνεται και από τις προηγούμενες μετρικές. Το XGBoost εμφανίζει σταθερή συμπεριφορά με μικρές διακυμάνσεις, χωρίς ουσιαστική διαφοροποίηση ως προς τη σχετική του απόδοση έναντι των άλλων μεθόδων.

Συνοψίζοντας, η Ισπανική Αγορά Εξισορρόπησης χαρακτηρίζεται από σχετικά ήπια εποχική μεταβλητότητα και χαμηλή μέση τιμή Εξισορρόπησης, γεγονός που επιτρέπει στα περισσότερα μοντέλα να διατηρούν συνεπή απόδοση καθ' όλη τη διάρκεια του έτους. Το μοντέλο ARIMA καταγράφει σταθερά την καλύτερη συμπεριφορά, τόσο στη μηνιαία ανάλυση, όσο και στην ανάλυση ανά παράθυρο εκπαίδευσης. Ιδιαίτερα σε βάθη εισόδου 72 και 336 ημίων παρουσιάζει τις χαμηλότερες τιμές MAE και RMSE, καθώς και τη μικρότερη ποσοστιαία απόκλιση στον δείκτη sMAPE. Η σταθερή απόδοση του αναδεικνύει την ικανότητά του να προσαρμόζεται σε διαφορετικά μοτίβα εποχικότητας και να διατηρεί υψηλό βαθμό ακρίβειας, ακόμα και σε περιόδους μεμονωμένων αποκλίσεων. Αντίθετα, το LEAR εμφανίζει έντονη αστάθεια, ιδιαίτερα για μεσαία ιστορικά παράθυρα, ενώ παρουσιάζει σχετική βελτίωση μόνο στο μέγιστο βάθος ιστορικού παραθύρου εισόδου (336 ημίωρα). Το XGBoost διατηρεί σταθερή και μερικώς ανταγωνιστική απόδοση, ιδίως για τα μικρότερα παράθυρα, χωρίς όμως να ξεπερνά συστηματικά την ακρίβεια του ARIMA. Ο δείκτης sMAPE, αν και λιγότερο διακριτικός στις αποκλίσεις, επιβεβαιώνει τη συνολική υπεροχή του ARIMA, με τις χαμηλότερες ποσοστιαίες τιμές στους περισσότερους μήνες και στα περισσότερα παράθυρα εκπαίδευσης.

Ενδιαφέρον παρουσιάζει η εικόνα του μοντέλου Naive, το οποίο, παρά την απλότητά του και την απουσία παραμέτρων εκπαίδευσης, εμφανίζεται ανταγωνιστικό σε ορισμένες περιόδους. Σύμφωνα με τον Πίνακα 5.8, καταγράφει τιμές σφάλματος συγκρίσιμες ή και χαμηλότερες από τα πολυμεταβλητά μοντέλα σε μήνες όπως ο Μάιος, ο Αύγουστος και ο Δεκέμβριος, όπου αυτά παρουσιάζουν επιδείνωση. Ωστόσο, η καλή του απόδοση προκύπτει κυρίως από συγκεκριμένα επεισόδια μεταβλητότητας και δεν αντικατοπτρίζει σταθερή συμπεριφορά σε βάθος χρόνου. Επιπλέον, στους δείκτες RMSE και sMAPE, το ARIMA διατηρεί σαφές πλεονέκτημα, γεγονός που επιβεβαιώνει ότι το Naive δεν αποτελεί επαρκώς γενικεύσιμο εργαλείο πρόβλεψης, παρά μόνο χρήσιμο σημείο αναφοράς.

Επιπλέον, η συνολική εικόνα των μοντέλων επιδεινώνεται αισθητά τον Δεκέμβριο του 2021, όπου καταγράφεται αιφνίδια αύξηση των σφαλμάτων σε όλους σχεδόν τους δείκτες. Το φαινόμενο αυτό οφείλεται σε διαφόρους εξωγενείς παράγοντες: τη ραγδαία αύξηση των τιμών φυσικού αερίου σε πανευρωπαϊκό επίπεδο, τη μειωμένη παραγωγή από αιολικά κατά τους χειμερινούς μήνες, καθώς και την αυξημένη αβεβαιότητα στη ζήτηση [32],[33],[34]. Αξιοσημείωτο είναι το γεγονός ότι σε αντίθεση με την Ιρλανδία (Υποενότητα 5.2.1), στην Ισπανία δεν παρατηρείται αιχμή σφαλμάτων τον Σεπτέμβριο, γεγονός που αντανάκλα τις διαρθρωτικές διαφορές των δύο αγορών. Από την μία, η ιρλανδική Αγορά Εξισορρόπησης χαρακτηρίζεται από περιορισμένες διασυνδέσεις, πολυπλοκότητα στον μηχανισμό εξισορρόπησης και υψηλή ευαισθησία σε αστάθειες παραγωγής, γεγονός που την καθιστά ιδιαίτερα ευάλωτη σε εξωτερικές μεταβλητές, όπως παρουσιάστηκε στην Υποενότητα 2.3.1. Από την άλλη, η ισπανική Αγορά Εξισορρόπησης, παρότι έχει επίσης χαμηλή διασυνδεσιμότητα, διαθέτει μεγαλύτερη συμμετοχή σε ευρωπαϊκές πλατφόρμες εξισορρόπησης και εμφανίζει διαφοροποιημένη κατανομή πηγών ενέργειας με υψηλή διείσδυση ΑΠΕ, όπως παρουσιάστηκε στη Υποενότητα 2.3.2. Αυτά τα χαρακτηριστικά ενδέχεται να προσδίδουν μεγαλύτερη λειτουργική ευελιξία και ανθεκτικότητα σε αιφνίδιες εξωτερικές διακυμάνσεις, περιορίζοντας την εμφάνιση σφαλμάτων σε περιόδους όπως ο Σεπτέμβριος.

Τέλος, η χαμηλή μέση τιμή εξισορρόπησης που καταγράφεται για την Ισπανία (57.89 €/MWh, Πίνακας 5.1) συμβάλλει στην εμφάνιση υψηλών τιμών sMAPE κατά τους πρώτους μήνες του έτους. Σε εκείνες τις περιόδους, μικρές απόλυτες αποκλίσεις οδηγούν σε υπερβολικά υψηλά ποσοστά σφάλματος λόγω του χαμηλού παρονομαστή στον υπολογισμό του δείκτη. Παράλληλα, οι τιμές του δείκτη MAE για το μοντέλο ARIMA αντιστοιχούν περίπου στο 32% της μέσης τιμής σε μηνιαία βάση και στο 31% στην ανάλυση ανά παράθυρο (336 ημίων), ποσοστά που αναδεικνύουν τη


δυσκολία επίτευξης χαμηλών σφαλμάτων σε αγορές με μικρό εύρος τιμών. Τα παραπάνω ευρήματα επιβεβαιώνουν την ανάγκη κατάλληλης επιλογής μοντέλου και παραμέτρων, λαμβάνοντας υπόψη τα εποχικά χαρακτηριστικά και τις διαρθρωτικές ιδιαιτερότητες της εκάστοτε αγοράς.

5.2.3 Βέλγιο

Η παρουσίαση των αποτελεσμάτων συνεχίζεται με την περίπτωση της Βελγικής Αγοράς Εξισορρόπησης, η οποία, όπως αναλύθηκε στην Υποενότητα 2.3.3, χαρακτηρίζεται από σημαντική συμμετοχή διασυνωριακών ροών, μέτρια εποχική διακύμανση και υψηλή μέση Τιμή Εξισορρόπησης, η οποία ανέρχεται σε 97.69 €/MWh σύμφωνα με τον Πίνακα 5.1. Αρχικά παρουσιάζεται η μηνιαία απόδοση των μοντέλων ARIMA, LEAR, XGBoost και Naive για το έτος 2021, με στόχο την αξιολόγηση της συμπεριφοράς τους ως προς την εποχικότητα της αγοράς.

Πίνακας 5.14: Μηνιαία ανάλυση του δείκτη MAE (€/MWh) για το Βέλγιο ανά μοντέλο πρόβλεψης

Μήνας	Μέσο Απόλυτο σφάλμα (MAE) €/MWh			
	ARIMA	LEAR	XGB	Naive
1	52.11	262.98	54.37	72.94
2	49.27	166.18	65.96	54.69
3	65.07	65.62	85.54	85.45
4	63.08	63.63	71.46	82.28
5	60.67	62.96	60.99	75.57
6	96.09	100.52	106.97	125.66
7	75.16	92.66	90.06	90.15
8	75.25	138.33	82.54	97.79
9	84.65	273.28	95.68	106.73
10	131.95	126.52	123.26	133.76
11	121.26	115.87	120.55	160.55
12	106.62	140.74	130.14	141.04



Σχήμα 5.7: Διάγραμμα μηνιαίας ανάλυσης του δείκτη MAE (€/MWh) για το Βέλγιο ανά μοντέλο πρόβλεψης

Όπως παρουσιάζεται στον Πίνακα 5.14 και το Σχήμα 5.7, οι τιμές του δείκτη MAE στη Βελγική Αγορά Εξισορρόπησης είναι γενικά αυξημένες για όλα τα μοντέλα πρόβλεψης, γεγονός που αντανακλά τη μεταβλητότητα και την πρόκληση της συγκεκριμένης αγοράς. Το μοντέλο ARIMA παρουσιάζει τη σταθερότερη συμπεριφορά, με τιμές του δείκτη MAE που κυμαίνονται από 49.27 έως 131.95 €/MWh, επιτυγχάνοντας την καλύτερη συνολική απόδοση. Το LEAR, αντίθετα, εμφανίζει ιδιαίτερα ασταθή και ακραία συμπεριφορά, με τιμές του δείκτη MAE που υπερβαίνουν τα 160 €/MWh τον Ιανουάριο, Φεβρουάριο και Σεπτέμβριο. Στους συγκεκριμένους μήνες, ενώ τα υπόλοιπα μοντέλα (ARIMA, XGBoost και Naive) διατηρούν τις τιμές τους σε πιο ελεγχόμενα επίπεδα, το LEAR παρουσιάζει απότομες αποκλίσεις. Αυτό πιθανόν οφείλεται στην εσωτερική του δομή, η οποία αναλύεται στην Υποενότητα 4.2.2, όπου εκπαιδεύονται ξεχωριστά μοντέλα για κάθε χρονικό βήμα του ορίζοντα πρόβλεψης, γεγονός που το καθιστά ιδιαίτερα ευάλωτο σε χρονικά σημεία με ακραία μεταβολή τιμών. Το XGBoost αποδίδει σχετικά καλά, με MAE κυρίως εντός του εύρους 60–130 €/MWh, και σε ορισμένους μήνες, όπως ο Σεπτέμβριος, παρουσιάζει μεγαλύτερη σταθερότητα σε σύγκριση με το LEAR, το οποίο παρουσιάζει εξαιρετικά υψηλά σφάλματα (273.28 €/MWh).

Το μοντέλο Naive χαρακτηρίζεται από υψηλή διασπορά στην απόδοσή του, με σημαντική επιδείνωση από τον Σεπτέμβριο και μετά, καταγράφοντας τις υψηλότερες τιμές MAE του συνόλου (έως και 160.55 €/MWh τον Νοέμβριο). Αν και σε επιλεγμένους μήνες, όπως ο Φεβρουάριος, επιτυγχάνει χαμηλότερο σφάλμα από το XGBoost, δεν προσεγγίζει το επίπεδο ακρίβειας που επιτυγχάνει το ARIMA. Η συμπεριφορά αυτή εξηγείται από τη φύση του μοντέλου: το Naive στηρίζεται αποκλειστικά σε μια παρελθοντική τιμή, χωρίς να διαθέτει κάποιον μηχανισμό πρόβλεψης ή προσαρμογής. Αυτό το καθιστά εγγενώς ανεπαρκές για την αποτύπωση έντονων ή μη γραμμικών μεταβολών, γεγονός που δεν ισχύει για πιο εξελιγμένα μοντέλα όπως το ARIMA, τα οποία ενσωματώνουν τη δυναμική της ιστορικής πληροφορίας. Ωστόσο, η απλότητα του Naive το καθιστά εύλογο σημείο αναφοράς για τη σύγκριση των υπολοίπων μοντέλων.

Συνολικά, η απόδοση των μοντέλων στο Βέλγιο υποδεικνύει την ανάγκη για δυναμικά και εύρωστα μοντέλα πρόβλεψης, ικανά να ανταποκρίνονται σε ακραία γεγονότα. Το ARIMA διατηρεί μια συνεπή υπεροχή, ενώ το LEAR, παρά τις θεωρητικές δυνατότητές του, απαιτεί περαιτέρω ενίσχυση για να αντιμετωπίσει τις συνθήκες υψηλής διακύμανσης που παρατηρούνται κυρίως στο τέλος του έτους. Τέλος, η αύξηση των σφαλμάτων από τον Οκτώβριο και μετά, που είναι εμφανής σε όλα τα μοντέλα, καταδεικνύει γενικότερα τη δυσκολία πρόβλεψης σε περιόδους έντονης αστάθειας.

Πίνακας 5.15: Μηνιαία ανάλυση του δείκτη RMSE (€/MWh) για το Βέλγιο ανά μοντέλο πρόβλεψης


Μήνας	Τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) €/MWh			
	ARIMA	LEAR	XGB	Naive
1	73.10	805.45	78.22	105.16
2	73.64	397.77	94.00	88.95
3	86.17	91.27	110.86	117.89
4	100.26	102.46	109.90	134.90
5	84.17	90.30	83.88	107.36
6	144.03	151.04	155.8	190.44
7	91.59	113.14	112.31	118.75
8	98.84	599.07	106.38	128.75
9	116.17	1076.83	125.20	156.41
10	156.42	154.21	150.09	181.98
11	156.32	150.39	155.54	209.57
12	133.15	178.38	168.61	183.96

Όπως παρουσιάζεται στον Πίνακα 5.15, ο δείκτης RMSE επιβεβαιώνει τη γενική εικόνα της υψηλής μεταβλητότητας στη Βελγική Αγορά Εξισορρόπησης, αναδεικνύοντας όμως με σαφέστερο τρόπο τις ακραίες αποκλίσεις σε συγκεκριμένους μήνες. Το μοντέλο ARIMA εξακολουθεί να εμφανίζει τη χαμηλότερη και σταθερότερη απόδοση, ενώ το LEAR καταγράφει εξαιρετικά υψηλές τιμές RMSE, φτάνοντας σε επίπεδα άνω των 1000 €/MWh τον Σεπτέμβριο. Αξιοσημείωτη είναι η διαφοροποίηση που παρατηρείται μεταξύ των μοντέλων Naive και XGBoost. Ενώ στον δείκτη MAE υπήρξαν μήνες όπου το Naive προσέγγισε ή και ξεπέρασε οριακά το XGBoost, η εικόνα αυτή ανατρέπεται πλήρως στον RMSE: το Naive εμφανίζει σταθερά υψηλότερα σφάλματα, ιδίως στο τελευταίο τετράμηνο, γεγονός που αποκαλύπτει πιο καθαρά τους περιορισμούς του ως μοντέλο βάσης. Η παρατήρηση αυτή αναδεικνύει τη σημασία της επιλογής του κατάλληλου δείκτη αξιολόγησης, καθώς, ενώ ο MAE μπορεί να υποβαθμίζει την επίδραση των ακραίων λαθών, ο RMSE, λόγω της ευαισθησίας του σε μεγάλες αποκλίσεις, αναδεικνύει με μεγαλύτερη σαφήνεια τις πραγματικές επιδόσεις των μοντέλων και συμβάλλει στη διαμόρφωση πιο αξιόπιστης ιεράρχησης. Συνολικά, η κατάταξη των μοντέλων παραμένει συμβατή με εκείνη του MAE, με το ARIMA να διατηρεί σταθερή υπεροχή, ενώ το LEAR συνεχίζει να εμφανίζει αυξημένα σφάλματα σε κρίσιμους μήνες, γεγονός που υποδηλώνει την ανάγκη για βελτίωση της σταθερότητας και της προσαρμοστικότητάς του.

Συνεχίζοντας την ανάλυση της μηνιαίας απόδοσης των μοντέλων, ο δείκτης sMAPE, όπως παρουσιάζεται στον Πίνακα 5.16 και το Σχήμα 5.8, επιβεβαιώνει τη χαμηλή ακρίβεια πρόβλεψης στη Βελγική Αγορά Εξισορρόπησης. Το μοντέλο ARIMA παρουσιάζει τη συνολικά πιο συνεπή συμπεριφορά, καταγράφοντας τις χαμηλότερες ποσοστιαίες αποκλίσεις στους περισσότερους μήνες, αν και φτάνει σε τιμή sMAPE 155.21% τον Ιούλιο, που αποτελεί και την υψηλότερη τιμή του μέσα στο έτος. Αντίθετα, τα μοντέλα LEAR και XGBoost παρουσιάζουν υψηλές αποκλίσεις, με μέγιστες τιμές 139.66% και 139.23% αντίστοιχα. Οι τιμές αυτές υποδεικνύουν ότι το μέσο ποσοστιαίο σφάλμα υπερβαίνει το 100% σε μεγάλο μέρος του έτους, καταδεικνύοντας τη σημαντική απόκλιση των προβλέψεων από τις πραγματικές τιμές. Το φαινόμενο αυτό σχετίζεται με την έντονη διακύμανση και τις απότομες αυξομειώσεις που χαρακτηρίζουν τη Βελγική Αγορά Εξισορρόπησης, οι οποίες επηρεάζουν σημαντικά την ονομαστική διαφορά μεταξύ προβλεπόμενων και πραγματικών τιμών.

Πίνακας 5.16: Μηνιαία ανάλυση του δείκτη sMAPE (%) για το Βέλγιο ανά μοντέλο πρόβλεψης

Μήνας	Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (sMAPE) %		
	ARIMA	LEAR	XGB
1	86.33	107.71	92.70
2	116.12	124.91	125.46
3	121.94	120.55	139.23
4	90.88	87.01	96.34
5	94.44	108.83	104.32
6	100.78	110.14	104.63
7	155.21	139.66	138.42
8	83.88	91.59	97.47
9	73.85	83.34	79.79
10	98.48	90.98	92.78
11	55.98	54.77	57.62
12	82.71	82.23	81.30

**Σχήμα 5.8:** Διάγραμμα μηνιαίας ανάλυσης του δείκτη sMAPE (%) για το Βέλγιο ανά μοντέλο πρόβλεψης


Αν και τα αποτελέσματα του sMAPE συμφωνούν γενικά με τα ευρήματα των δεικτών MAE και RMSE, η συγκεκριμένη μετρική αναδεικνύει με μεγαλύτερη ένταση τις ποσοστιαίες αποκλίσεις και την πρόκληση επίτευξης σταθερής σχετικής ακρίβειας. Το LEAR παρουσιάζει συνολικά πιο συγκεντρωμένες τιμές sMAPE σε σχέση με τους δείκτες MAE και RMSE, επιδεικνύοντας σε αρκετούς μήνες, όπως ο Απρίλιος και ο Νοέμβριος, καλύτερη ή ισοδύναμη συμπεριφορά έναντι των υπολοίπων μοντέλων. Το γεγονός αυτό υποδεικνύει ότι, παρότι υστερεί σε επίπεδο απόλυτου σφάλματος (MAE, RMSE), η σχετική του απόδοση ως προς τις ποσοστιαίες αποκλίσεις είναι περισσότερο ανταγωνιστική.

Αφού εξετάστηκε η χρονική επίδοση των μοντέλων σε μηνιαία βάση, η ανάλυση επεκτείνεται στην επίδραση του βάθους του ιστορικού παραθύρου εισόδου. Στόχος είναι να διερευνηθεί πώς το

μέγεθος του ιστορικού παραθύρου εισόδου που χρησιμοποιείται για την εκπαίδευση και την πρόβλεψη των μοντέλων επηρεάζει την ακρίβεια πρόβλεψης στη Αγορά Εξισορρόπησης του Βελγίου.

Πίνακας 5.17: Ανάλυση του δείκτη MAE (€/MWh) για το Βέλγιο ανά χρονικό παράθυρο εκπαίδευσης και μοντέλο πρόβλεψης

Μοντέλο	Μέσο Απόλυτο σφάλμα (MAE) €/MWh				
	Χρονικό Παράθυρο Εισόδου				
	48	72	96	144	336
ARIMA	84.24	78.19	82.90	80.39	78.63
LEAR	86.38	103.27	174.12	104.2	202.57
XGB	90.39	96.86	87.62	89.10	89.15
Naive	102.22				



Σχήμα 5.9: Διάγραμμα ανάλυσης του δείκτη MAE (€/MWh) για το Βέλγιο ανά χρονικό παράθυρο εισόδου και μοντέλο πρόβλεψης

Όπως παρουσιάζεται στον Πίνακα 5.17 και το Σχήμα 5.9, το μοντέλο ARIMA καταγράφει σταθερά τις χαμηλότερες τιμές MAE για όλα τα βάθη παραθύρου, με τιμές που κυμαίνονται από 78.19 έως 84.24 €/MWh, και την καλύτερη επίδοση να σημειώνεται όταν χρησιμοποιείται ιστορικό παράθυρο διάρκειας 36 ωρών (72 ημίωρα). Το XGBoost εμφανίζει οριακά υψηλότερες τιμές, με μικρές διακυμάνσεις και μέγιστο MAE ίσο με 96.86 €/MWh για το ίδιο παράθυρο, ενώ στα μεγαλύτερα ιστορικά βάθη κυμαίνεται σταθερά γύρω από τα 87–89 €/MWh. Αντιθέτως, το μοντέλο LEAR παρουσιάζει έντονη αστάθεια, με επιδείνωση της απόδοσης κυρίως για μεγάλο ιστορικό βάθος, όπου η τιμή MAE ανέρχεται στα 202.57 €/MWh (336 ημίωρα), ενώ ακόμη και για ενδιάμεσο βάθος 96 ημιώρων παρατηρείται σημαντική αύξηση (174.12 €/MWh). Το μοντέλο Naive παραμένει

αμετάβλητο σε όλες τις περιπτώσεις με τιμή MAE ίση με 102.22 €/MWh, γεγονός που το καθιστά κατώτερο των ARIMA και XGBoost, αλλά αισθητά καλύτερο από το LEAR, ιδιαίτερα για μεγάλα ιστορικά παράθυρα εισόδου. Η συνολική εικόνα καταδεικνύει ότι το ARIMA παραμένει το πιο αξιόπιστο μοντέλο για όλα τα μεγέθη του ιστορικού παραθύρου εισόδου, ενώ το LEAR παρουσιάζει μειωμένη απόδοση για μεγαλύτερα βάθη ιστορικού, πιθανώς λόγω φαινομένων υπερεκπαίδευσης και αυξημένης πολυπλοκότητας του μοντέλου.

Ακόμη, σύμφωνα με τον Πίνακα 5.18, ο δείκτης RMSE επιβεβαιώνει την έντονη διακύμανση που παρατηρείται στο μοντέλο LEAR, το οποίο εμφανίζει εξαιρετικά υψηλές τιμές για μεγάλα ιστορικά παράθυρα, ξεπερνώντας τα 480 €/MWh για βάθος 96 ημιώρων και τα 650 €/MWh για βάθος 336 ημιώρων. Το XGBoost διατηρεί μέτρια και σταθερή απόδοση, ενώ το ARIMA εμφανίζει τις χαμηλότερες τιμές RMSE, με τιμές που κυμαίνονται μεταξύ 106.70 και 112.69 €/MWh, επιβεβαιώνοντας τη σχετική του σταθερότητα σε μια αγορά με υψηλή μέση τιμή Εξισορρόπησης, όπως παρουσιάζεται στον Πίνακα 5.1. Το μοντέλο Naive παρουσιάζει RMSE ίσο με 143.68 €/MWh, τιμή συστηματικά υψηλότερη από εκείνες των υπολοίπων μεθόδων. Συνεπώς, η κατάταξη των μοντέλων παραμένει συμβατή με αυτή που προέκυψε βάσει του δείκτη MAE.

Πίνακας 5.18: Ανάλυση του δείκτη RMSE (€/MWh) για το Βέλγιο ανά χρονικό παράθυρο εκπαίδευσης και μοντέλο πρόβλεψης

Μοντέλο	Τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) €/MWh				
	Χρονικό Παράθυρο Εισόδου				
	48	72	96	144	336
ARIMA	112.69	106.07	110.35	107.94	106.21
LEAR	116.71	164.55	483.01	208.95	656.08
XGB	119.84	126.25	117.98	120.03	120.40
Naive	143.68				

Πίνακας 5.19: Ανάλυση του δείκτη sMAPE (%) για το Βέλγιο ανά χρονικό παράθυρο εκπαίδευσης και μοντέλο πρόβλεψης

Μοντέλο	Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (sMAPE) %				
	Χρονικό Παράθυρο Εισόδου				
	48	72	96	144	336
ARIMA	98.43	96.8	97.08	96.48	94.65
LEAR	98.17	100.03	101.52	97.85	103.15
XGB	102.32	104.59	99.56	98.76	98.97

Τέλος, όπως παρουσιάζεται στον Πίνακα 5.19, ο δείκτης sMAPE καθιστά ακόμη πιο εμφαντική την εικόνα γενικευμένης αστάθειας και υψηλών αποκλίσεων στη Βελγική αγορά, καθώς ακόμη και το ARIMA, το οποίο αναδείχθηκε ως το πλέον αποδοτικό μοντέλο, καταγράφει ποσοστιαία σφάλματα της τάξης του 95%–98%. Το LEAR και το XGBoost ξεπερνούν το 100% στα περισσότερα παράθυρα, χωρίς να διαφοροποιούν την κατάταξη των μοντέλων σε σχέση με τους δείκτες MAE και RMSE. Τα ιδιαίτερα υψηλά ποσοστά σφάλματος που καταγράφονται σε όλα τα μοντέλα αντανakλούν τη χαμηλή προβλεψιμότητα της βελγικής αγοράς, όπως καταδεικνύεται από τα συνολικά ευρήματα της Ενότητας 5.2.3.

Συνοψίζοντας, η Αγορά Εξισορρόπησης του Βελγίου εμφανίζει εξαιρετικά υψηλά επίπεδα σφάλματος σε όλες τις μετρικές και για όλα τα μοντέλα, κατατάσσοντάς την ως μία από τις δυσκολότερες περιπτώσεις πρόβλεψης μεταξύ των χωρών μελέτης. Η μέση Τιμή Εξισορρόπησης για το Βέλγιο ανέρχεται σε 97.69 €/MWh, όπως παρουσιάστηκε στον Πίνακα 5.1. Κατά τη μηνιαία ανάλυση, ο δείκτης MAE για το μοντέλο ARIMA κυμαίνεται περίπου μεταξύ 50% και 135% της μέσης τιμής εξισορρόπησης, γεγονός που υπογραμμίζει τη μεγάλη διακύμανση της απόδοσης και τη δυσκολία πρόβλεψης ακόμη και για σταθερά μοντέλα. Αντίστοιχα, κατά την ανάλυση ανά παράθυρο εκπαίδευσης, τα απόλυτα σφάλματα του ARIMA κυμαίνονται μεταξύ 78 και 84 €/MWh, δηλαδή περίπου στο 80%–86% της μέσης τιμής, ποσοστά που επιβεβαιώνουν τη δυσκολία επίτευξης ακριβούς πρόβλεψης ακόμη και με προηγμένα στατιστικά μοντέλα. Τα ποσοστιαία σφάλματα sMAPE παραμένουν επίσης ιδιαίτερα αυξημένα (95%–139%), ενισχύοντας την εικόνα χαμηλής προβλεψιμότητας της αγοράς ακόμη και για τα πλέον αποδοτικά μοντέλα. Μεταξύ των μοντέλων, το ARIMA καταγράφει τη σταθερότερη και πλέον αξιόπιστη απόδοση για όλα τα βάθη παραθύρου, με καλύτερα αποτελέσματα στο ιστορικό βάθος των 336 ημιώρων. Το XGBoost εμφανίζει ήπια μεταβλητότητα και ικανοποιητικά αποτελέσματα χωρίς ακραίες αποκλίσεις, ενώ το LEAR παρουσιάζει έντονη επιδείνωση στα ενδιάμεσα και μεγάλα ιστορικά διαστήματα (96–336 ημιώρων), καταγράφοντας εξαιρετικά υψηλές τιμές σφάλματος και αστάθεια.

Αξιοσημείωτη είναι και η συμπεριφορά του μοντέλου Naive, το οποίο εμφανίζεται ανταγωνιστικό σε ορισμένους μήνες με ήπια διακύμανση, όπως τον Φεβρουάριο, επιτυγχάνοντας χαμηλότερες τιμές MAE σε σύγκριση με τα πολυμεταβλητά μοντέλα. Ωστόσο, κατά την αξιολόγηση με τον δείκτη RMSE, η απόδοσή του υπολείπεται σημαντικά, καταγράφοντας τιμές μεγαλύτερες από όλα τα άλλα μοντέλα και υποδηλώνοντας την αδυναμία του να ανταποκριθεί σε περιόδους ακραίας μεταβλητότητας. Το εύρημα αυτό υπογραμμίζει ότι η επιλογή μετρικής μπορεί να επηρεάσει ουσιαστικά τη σύγκριση των μοντέλων πρόβλεψης, καθώς η χρήση μόνο του MAE ενδέχεται να υπερεκτιμήσει την απόδοση απλών μεθόδων βάσης όπως το Naive, ενώ δείκτες όπως το RMSE αποκαλύπτουν τις περιορισμένες δυνατότητές τους σε περιόδους υψηλής μεταβλητότητας.

Η απόδοση όλων των μοντέλων επιδεινώνεται σημαντικά κατά το τελευταίο τρίμηνο του έτους, γεγονός που ερμηνεύεται από τη ραγδαία άνοδο των τιμών ενέργειας στην Ευρώπη, την αύξηση του κόστους φυσικού αερίου, την έντονη αστάθεια των διασυνοριακών ροών και τη μειωμένη ικανότητα πρόβλεψης του φορτίου και της παραγωγής ΑΠΕ κατά την περίοδο αυτή [31],[32],[34]. Παρόμοια τάση επιδείνωσης παρατηρείται και στις αγορές της Ιρλανδίας και της Ισπανίας, γεγονός που ενισχύει την υπόθεση ύπαρξης γενικευμένων προβλημάτων πρόβλεψης σε πανευρωπαϊκό επίπεδο κατά το τελευταίο τρίμηνο του 2021. Η συνολική εικόνα επιβεβαιώνει ότι η επιλογή μοντέλου και παραμέτρων πρέπει να προσαρμόζεται στη δυναμική της εκάστοτε αγοράς, λαμβάνοντας υπόψη τόσο τις εποχικές μεταβολές όσο και τους εξωγενείς ενεργειακούς παράγοντες που επηρεάζουν την ακρίβεια των προβλέψεων.

5.3 ΣΥΓΚΡΙΤΙΚΗ ΑΞΙΟΛΟΓΗΣΗ


Η Ενότητα 5.2 επικεντρώθηκε στην αποτίμηση της απόδοσης των μοντέλων πρόβλεψης για κάθε χώρα χωριστά, τόσο σε μηνιαία βάση, όσο και ως προς το βάθος του ιστορικού παραθύρου εισόδου. Στην παρούσα ενότητα επιχειρείται μια πιο εστιασμένη αποτίμηση, μέσω της ανάλυσης των βέλτιστων συνδυασμών μήνα και παραθύρου εκπαίδευσης για κάθε μοντέλο και χώρα ενδιαφέροντος. Η αξιολόγηση βασίζεται αφενός στις μετρικές σφάλματος που παρουσιάστηκαν στη Ενότητα 4.3, και αφετέρου σε διαγράμματα σύγκρισης πραγματικών και προβλεπόμενων Τιμών Εξισορρόπησης, τα οποία αφορούν το σύνολο αξιολόγησης κάθε μοντέλου και αποτυπώνουν τη χρονική εξέλιξη των τιμών όπως προβλέφθηκαν σε σχέση με τις αντίστοιχες πραγματικές παρατηρήσεις. Η ενότητα ολοκληρώνεται με συγκριτική αξιολόγηση της απόδοσης των μοντέλων για την Ιρλανδική Αγορά Εξισορρόπησης, σε αντιπαραβολή με πρόσφατα αποτελέσματα της σχετικής διεθνούς βιβλιογραφίας.

5.3.1 Βέλτιστοι συνδυασμοί μοντελοποίησης ανά χώρα


Η παρούσα υποενότητα εστιάζει στην ερμηνεία των αποτελεσμάτων των μοντέλων για τους βέλτιστους συνδυασμούς πρόβλεψης ανά χώρα, βάσει του μήνα και του παραθύρου εκπαίδευσης που οδήγησαν στη χαμηλότερη τιμή σφάλματος. Για κάθε περίπτωση διερευνάται κατά πόσο η ποσοτική αξιολόγηση μέσω των μετρικών σφάλματος αντανακλάται στην ακρίβεια της καμπύλης πρόβλεψης ως προς την αναπαράσταση της πραγματικής εξέλιξης των τιμών, λαμβάνοντας υπόψη τη δυναμική και τη μεταβλητότητα της εκάστοτε αγοράς.

Πίνακας 5.20: Βέλτιστος συνδυασμός μήνα και παραθύρου εκπαίδευσης ανά μοντέλο για τη Ιρλανδία


Μοντέλο	Μήνας	Παράθυρο Εκπαίδευσης (ημέρες)	MAE (€/MWh)	RMSE (€/MWh)	sMAPE (%)
ARIMA	8	48	27.10	35.75	17.66
XGBoost	8	72	30.48	39.31	19.91
LEAR	6	48	35.38	66.56	31.52
Naive	8	—	32.85	43.95	—




Σχήμα 5.10: Διάγραμμα πραγματικών και προβλεπόμενων τιμών στο σύνολο αξιολόγησης για τον βέλτιστο συνδυασμό του μοντέλου ARIMA στην Ιρλανδία



Σχήμα 5.11: Διάγραμμα πραγματικών και προβλεπόμενων τιμών στο σύνολο αξιολόγησης για τον βέλτιστο συνδυασμό του μοντέλου XGBoost στην Ιρλανδία



Σχήμα 5.12: Διάγραμμα πραγματικών και προβλεπόμενων τιμών στο σύνολο αξιολόγησης για τον βέλτιστο συνδυασμό του μοντέλου LEAR στην Ιρλανδία



Σχήμα 5.13: Διάγραμμα πραγματικών και προβλεπόμενων τιμών στο σύνολο αξιολόγησης για τον καλύτερο μήνα εφαρμογής του μοντέλου Naive στην Ιρλανδία

Για την Ιρλανδία, τα αποτελέσματα του Πίνακα 5.20 αναδεικνύουν ξεκάθαρα την υπεροχή του μοντέλου ARIMA, το οποίο παρουσιάζει τη μικρότερη τιμή MAE (27.10 €/MWh) και το χαμηλότερο ποσοστιαίο σφάλμα sMAPE (17.66%). Το Σχήμα 5.10 δείχνει ότι η πρόβλεψη αποδίδει αρκετά καλά τη γενική τάση της χρονοσειράς, ακολουθώντας ικανοποιητικά τις μέσες διακυμάνσεις. Ωστόσο, παρατηρούνται αποκλίσεις σε σημεία έντονης μεταβλητότητας, όπως στις 30 και 31 Αυγούστου, όπου το μοντέλο αδυνατεί να αποδώσει τις απότομες αυξήσεις της πραγματικής τιμής. Παρά τα σχετικά χαμηλά σφάλματα, η καμπύλη πρόβλεψης δεν αποδίδει απόλυτα τη δυναμική της αγοράς, κάτι που αναδεικνύει τη σημασία της παράλληλης οπτικής αξιολόγησης.

Στο Σχήμα 5.11 απεικονίζεται η πρόβλεψη του XGBoost, με MAE 30.48 €/MWh και sMAPE 19.91%. Το μοντέλο αποδίδει σωστά τη βασική μορφή της πραγματικής χρονοσειράς, με πιο ομαλή συμπεριφορά, ωστόσο χάνει συστηματικά τις έντονες αιχμές και τις τοπικές διακυμάνσεις. Η ευθυγράμμιση με τις έντονες μεταβολές είναι περιορισμένη, και η πρόβλεψη φαίνεται να ακολουθεί με καθυστέρηση τις αλλαγές κατεύθυνσης.



Το μοντέλο LEAR, η πρόβλεψη του οποίου απεικονίζεται στο Σχήμα 5.12, παρουσιάζει τα υψηλότερα σφάλματα (MAE 35.38 €/MWh, sMAPE 31.52%), κάτι που αντανακλάται και οπτικά. Η καμπύλη πρόβλεψης παραμένει περιορισμένη σε εύρος, εξομαλύνοντας πλήρως τις μεταβολές και αποτυγχάνοντας να αποδώσει τη χρονική και τιμολογιακή δυναμική της αγοράς. Εντονότερες αποκλίσεις παρατηρούνται στο δεύτερο μισό του διαστήματος αξιολόγησης, όπου η πραγματική τιμή αυξάνεται απότομα και η πρόβλεψη παραμένει σε χαμηλότερα επίπεδα.


Στο Σχήμα 5.13 παρουσιάζεται η πρόβλεψη του μοντέλου Naive, με τιμή σφάλματος RMSE 43.95 €/MWh. Αν και το Naive εμφανίζει καλύτερες τιμές από το LEAR στο συγκεκριμένο μήνα, αυτό είναι πλασματικό, καθώς πρόκειται για τον Αύγουστο, μήνα με χαμηλή σχετική μεταβλητότητα, στον οποίο όλα τα μοντέλα παρουσιάζουν βελτιωμένες επιδόσεις. Το Naive εκμεταλλεύεται τη φύση του (πρόβλεψη βασισμένη στην τιμή της ίδιας χρονικής στιγμής της προηγούμενης ημέρας) και αποδίδει σχετικά καλύτερα όταν οι τιμές είναι πιο ομαλές. Η προβλεπόμενη καμπύλη ταυτίζεται ουσιαστικά με την πραγματική, με χρονική μετατόπιση μιας ημέρας, γεγονός που περιορίζει την ικανότητά της να αποδώσει τις ξαφνικές διακυμάνσεις της αγοράς.

Η συνολική εικόνα που προκύπτει από τα διαγράμματα των βέλτιστων συνδυασμών επιβεβαιώνει την πρόκληση που θέτει η Ιρλανδική αγορά εξισορρόπησης, η οποία, όπως παρουσιάστηκε στο Κεφάλαιο 2, χαρακτηρίζεται από έντονη μεταβλητότητα και ευαισθησία σε εξωτερικούς παράγοντες, όπως η αιολική παραγωγή και οι διακυμάνσεις της ζήτησης. Το γεγονός ότι ακόμη και το καλύτερο μοντέλο δεν αποδίδει πλήρως τη χρονική δυναμική της αγοράς, παρότι επιτυγχάνει τις χαμηλότερες τιμές σφάλματος, υπογραμμίζει τη σημασία της συνδυαστικής αξιολόγησης.


Πίνακας 5.21: Βέλτιστος συνδυασμός μήνα και παραθύρου εκπαίδευσης ανά μοντέλο για τη Ισπανία

Μοντέλο	Μήνας	Παράθυρο Εκπαίδευσης (ημέωρα)	MAE (€/MWh)	RMSE (€/MWh)	sMAPE (%)
ARIMA	5	336	5.32	8.50	6.95
XGBoost	5	72	5.83	7.56	7.60
LEAR	4	336	5.33	7.02	7.89
Naive	4	—	7.53	9.88	—

**Σχήμα 5.14:** Διάγραμμα πραγματικών και προβλεπόμενων τιμών στο σύνολο αξιολόγησης για τον βέλτιστο συνδυασμό του μοντέλου ARIMA στην Ισπανία**Σχήμα 5.15:** Διάγραμμα πραγματικών και προβλεπόμενων τιμών στο σύνολο αξιολόγησης για τον βέλτιστο συνδυασμό του μοντέλου XGBoost στην Ισπανία



Σχήμα 5.16: Διάγραμμα πραγματικών και προβλεπόμενων τιμών στο σύνολο αξιολόγησης για τον βέλτιστο συνδυασμό του μοντέλου LEAR στην Ισπανία



Σχήμα 5.17: Διάγραμμα πραγματικών και προβλεπόμενων τιμών στο σύνολο αξιολόγησης για τον καλύτερο μήνα εφαρμογής του μοντέλου Naive στην Ισπανία

Στην περίπτωση της Ισπανίας, τα αποτελέσματα του Πίνακα 5.21 δείχνουν ότι τα μοντέλα ARIMA και XGBoost επιτυγχάνουν παρόμοιες επιδόσεις, με MAE 5.32 €/MWh και 5.83 €/MWh αντίστοιχα, και σφάλματα sMAPE κάτω από 8%. Το ARIMA παρουσιάζει τη χαμηλότερη ποσοστιαία απόκλιση (6.95%) και επιλέγεται ως το πιο αξιόπιστο μοντέλο για τη συγκεκριμένη αγορά. Όπως φαίνεται στο Σχήμα 5.14, η πρόβλεψη του ARIMA ακολουθεί τη γενική τάση της αγοράς, αποδίδοντας αρκετά καλά τα επίπεδα τιμών κατά το πρώτο μέρος της περιόδου. Ωστόσο, παρατηρούνται χρονικές υστερήσεις και επίπεδες περιοχές, ειδικά στο δεύτερο μισό του διαστήματος, όπου η πρόβλεψη χάνει μέρος των απότομων και αιφνίδιων αλλαγών στην χρονοσειρά και εξομαλύνει τις μεταβολές.

Το μοντέλο XGBoost, του οποίου η πρόβλεψη απεικονίζεται στο Σχήμα 5.15, καταγράφει παρόμοιο MAE με το ARIMA, αλλά ελαφρώς υψηλότερο sMAPE (7.6%). Παρατηρείται ότι

παρουσιάζει μεγαλύτερη ευελιξία στην πρόβλεψη των αυξομειώσεων της τιμής, ιδίως στο τέλος της περιόδου. Παρ' όλα αυτά, εμφανίζει στιγμές χρονικής καθυστέρησης και υποεκτιμήσεις σε ορισμένα τοπικά άκρα, χωρίς να διατηρεί απόλυτη ευθυγράμμιση με την πραγματική δυναμική των τιμών.

Το LEAR, όπως φαίνεται στο Σχήμα 5.16, καταγράφει αξιοσημείωτα καλή επίδοση (MAE 5.33 €/MWh και RMSE 7.02 €/MWh), συγκρίσιμη με το ARIMA, παρουσιάζοντας όμως ελαφρώς υψηλότερο σφάλμα sMAPE (7.89%), γεγονός που οδηγεί στην τελική προτίμηση του ARIMA ως πιο αξιόπιστου μοντέλου για την Ισπανική αγορά. Αν και η πρόβλεψη του LEAR καταγράφει τη βασική κατεύθυνση της αγοράς, η καμπύλη παρουσιάζει περιορισμένη μεταβλητότητα και τείνει να εξομαλύνει τις πραγματικές διακυμάνσεις. Η απόκριση στις έντονες αιχμές είναι περιορισμένη, ενώ σε πολλά σημεία οι μεταβολές της τιμής δεν αποδίδονται ούτε ποσοτικά ούτε χρονικά με ακρίβεια.


Επιπλέον, στο Σχήμα 5.17 παρουσιάζεται η πρόβλεψη του μοντέλου Naive, η οποία βασίζεται στην τιμή της ίδιας ώρας της προηγούμενης ημέρας. Όπως είναι αναμενόμενο, παρατηρούνται σημαντικές αποκλίσεις στις αιχμές και στις απότομες πτώσεις, τις οποίες το Naive αδυνατεί να αποδώσει. Η απόδοσή του επηρεάζεται θετικά από τη σχετική σταθερότητα του συστήματος τον Απρίλιο, ο οποίος χαρακτηρίζεται από ήπια μεταβλητότητα, στοιχείο που ευνοεί τη φύση της μεθόδου. Παρ' όλα αυτά, το Naive εξακολουθεί να υπολείπεται όλων των εξελιγμένων μεθόδων πρόβλεψης και λειτουργεί κυρίως ως σημείο αναφοράς, έναντι του οποίου αξιολογείται η υπεροχή των υπολοίπων μοντέλων.

Συνολικά, η Ισπανική αγορά εξισορρόπησης, όπως παρουσιάστηκε στο Κεφάλαιο 2, χαρακτηρίζεται από σχετικά χαμηλή μεταβλητότητα και σταθερό εύρος τιμών. Τα χαμηλά επίπεδα σφάλματος που καταγράφονται και για τα τρία μοντέλα αντανακλούν αυτή τη σταθερότητα. Παρ' όλα αυτά, η συγκριτική αξιολόγηση των διαγραμμάτων στους βέλτιστους συνδυασμούς αξιολόγησης δείχνει ότι, ακόμη και όταν δύο μοντέλα όπως το ARIMA και το XGBoost παρουσιάζουν παρόμοιες μετρικές για τον ίδιο μήνα, η μορφή και η χρονική συμπεριφορά των προβλέψεών τους μπορεί να διαφέρει σημαντικά. Το γεγονός αυτό αναδεικνύει τη σημασία της οπτικής αξιολόγησης ως αναπόσπαστο συμπλήρωμα της ποσοτικής ανάλυσης, ακόμη και σε αγορές χαμηλής δυναμικότητας.


Ολοκληρώνοντας την ανάλυση των βέλτιστων συνδυασμών μήνα και παραθύρου εκπαίδευσης για κάθε μοντέλο και χώρα, η Αγορά Εξισορρόπησης του Βελγίου, όπως παρουσιάστηκε στο Κεφάλαιο 2, χαρακτηρίζεται από έντονη αστάθεια και υψηλή μεταβλητότητα, κυρίως λόγω των διασυννοριακών ροών, των έντονων διακυμάνσεων ζήτησης και της ευαισθησίας του συστήματος σε ακραίες τιμές. Ο Πίνακας 5.22 αποτυπώνει τη δυσκολία πρόβλεψης σε αυτήν την αγορά, με εξαιρετικά υψηλές τιμές σφάλματος για όλα τα μοντέλα.

Πίνακας 5.22: Βέλτιστος συνδυασμός μήνα και παραθύρου εκπαίδευσης ανά μοντέλο για το Βέλγιο


Μοντέλο	Μήνας	Παράθυρο Εκπαίδευσης (ημίωρα)	MAE (€/MWh)	RMSE (€/MWh)	sMAPE (%)
ARIMA	2	96	48.07	71.61	111.57
XGBoost	1	336	52.12	75.09	91.1
LEAR	1	144	51.42	73.06	83.27
Naive	2	-	54.69	88.95	-




Σχήμα 5.18: Διάγραμμα πραγματικών και προβλεπόμενων τιμών στο σύνολο αξιολόγησης για τον βέλτιστο συνδυασμό του μοντέλου ARIMA στο Βέλγιο



Σχήμα 5.19: Διάγραμμα πραγματικών και προβλεπόμενων τιμών στο σύνολο αξιολόγησης για τον βέλτιστο συνδυασμό του μοντέλου XGBoost στο Βέλγιο



Σχήμα 5.20: Διάγραμμα πραγματικών και προβλεπόμενων τιμών στο σύνολο αξιολόγησης για τον βέλτιστο συνδυασμό του μοντέλου LEAR στο Βέλγιο



Σχήμα 5.21: Διάγραμμα πραγματικών και προβλεπόμενων τιμών στο σύνολο αξιολόγησης για τον καλύτερο μήνα εφαρμογής του μοντέλου Naive στο Βέλγιο

Το μοντέλο ARIMA καταγράφει το χαμηλότερο MAE (48.07 €/MWh), αλλά παρουσιάζει πολύ υψηλό σφάλμα sMAPE (111.57%), γεγονός που υποδεικνύει ότι παρότι ακολουθεί μερικώς τα απόλυτα επίπεδα τιμών, αποτυγχάνει να αποδώσει σωστά τις σχετικές μεταβολές. Στο Σχήμα 5.18 διαπιστώνεται ότι η πρόβλεψη αποτυπώνει τη γενική τάση, αλλά αγνοεί πλήρως τις ξαφνικές πτώσεις και αιχμές, ειδικά στις πρώτες και τελευταίες ημέρες του συνόλου αξιολόγησης, όπου εμφανίζονται και αρκετές έντονες αρνητικές τιμές. Οι έντονες αυτές διακυμάνσεις, και ειδικά η παρουσία ακραίων αρνητικών τιμών, επιβεβαιώνουν τη δυσκολία πρόβλεψης στη Βέλγικη Αγορά Εξισορρόπησης που έχει ήδη επισημανθεί στην Υποενότητα 2.3.3.

Αντίστοιχα, το XGBoost, η πρόβλεψη του οποίου παρουσιάζεται στο Σχήμα 5.19, παρουσιάζει ακόμη μεγαλύτερο MAE (52.12 €/MWh) και sMAPE 91.1%. Αν και το μοντέλο καταφέρνει να εντοπίσει ορισμένα επαναλαμβανόμενα μοτίβα, η πρόβλεψή του παρουσιάζει υπερβολική εξομάλυνση, με αποτέλεσμα να αγνοούνται οι ραγδαίες διακυμάνσεις. Η πρόβλεψη ακολουθεί με καθυστέρηση τη χρονοσειρά, αποτυγχάνοντας να ανταποκριθεί στις ακραίες αυξομειώσεις και στη δυναμική των πραγματικών τιμών, ενώ δεν αποδίδει σωστά τις αρνητικές τιμές.

Η πρόβλεψη του μοντέλου LEAR, όπως παρουσιάζεται στο Σχήμα 5.20, αποτυγχάνει επίσης να προσεγγίσει τη μεταβλητότητα της αγοράς. Με MAE 51.42 €/MWh και το χαμηλότερο sMAPE (83.27%) ανάμεσα στα τρία μοντέλα, η συνολική του απόδοση είναι παραπλανητικά ικανοποιητική, καθώς δεν προκύπτει από ουσιαστική εκμάθηση της δυναμικής της αγοράς, αλλά από το γεγονός ότι η πρόβλεψη παραμένει σχεδόν αμετάβλητη. Το μοντέλο LEAR αποτυγχάνει να προσαρμοστεί στις συνθήκες υψηλής μεταβλητότητας της αγοράς του Βελγίου και κρίνεται ανεπαρκές, καθώς η καμπύλη πρόβλεψης περιορίζεται σε επίπεδα χωρίς ουσιαστική αντίδραση στις διακυμάνσεις. Η εξομαλυσμένη αυτή συμπεριφορά οδηγεί σε υποεκτίμηση τόσο των ανοδικών αιχμών όσο και των χαμηλών τιμών, γεγονός που υποβαθμίζει την αξιοπιστία των αποτελεσμάτων του.

Επιπλέον, το Σχήμα 5.21 παρουσιάζει την πρόβλεψη του μοντέλου Naïve για τον Φεβρουάριο. Με MAE 54.69 €/MWh και RMSE 88.95 €/MWh, το Naïve καταγράφει τη χειρότερη συνολική απόδοση από όλα τα μοντέλα. Η καμπύλη πρόβλεψης ταυτίζεται σχεδόν με την πραγματική, μετατοπισμένη όμως κατά μία ημέρα, αντανακλώντας τη βασική του υπόθεση. Η αδυναμία του να ανταποκριθεί στις απότομες μεταβολές της αγοράς επιβεβαιώνει τους περιορισμούς του ως μοντέλου αναφοράς σε συνθήκες υψηλής μεταβλητότητας.

Συνολικά, η αξιολόγηση των μοντέλων για το Βέλγιο επιβεβαιώνει τη δυσκολία πρόβλεψης σε μια από τις πιο ασταθείς και απαιτητικές ευρωπαϊκές Αγορές Εξισορρόπησης. Το ARIMA εμφανίζεται ως η πιο αξιόπιστη επιλογή από πλευράς MAE, αλλά παρουσιάζει υψηλότερο sMAPE, γεγονός που αναδεικνύει τον περιορισμένο βαθμό κατανόησης των σχετικών μεταβολών της τιμής. Το LEAR παρουσιάζει χαμηλότερο sMAPE, όμως αυτό οφείλεται στη σταθερότητα της καμπύλης πρόβλεψης και όχι σε επιτυχή αποτύπωση της δυναμικής της αγοράς. Το XGBoost ισορροπεί μεταξύ των δύο, αλλά αποτυγχάνει στις αιχμές και στις καθυστερήσεις. Κοινός παρονομαστής όλων των μοντέλων είναι η αδυναμία πρόβλεψης των συχνών και έντονων αρνητικών τιμών εξισορρόπησης, που εμφανίζονται σε μεγάλο μέρος της περιόδου, κυρίως ως αποτέλεσμα των διασυνοριακών εκκαθαρίσεων και των ακραίων συνθηκών φορτίου. Όπως παρουσιάστηκε στην Υποενότητα 2.3.3, οι αρνητικές τιμές αποτελούν εγγενές χαρακτηριστικό της Βελγικής Αγοράς Εξισορρόπησης, επηρεάζοντας δραστικά τόσο την απόδοση των μοντέλων, όσο και την αξιοπιστία των ποσοτικών δεικτών. Το γεγονός αυτό ενισχύει την ανάγκη για την ανάπτυξη ειδικών μεθοδολογιών πρόβλεψης, ικανών να ανταποκριθούν στις ιδιαιτερότητες της αγοράς, ενσωματώνοντας τεχνικά και ρυθμιστικά χαρακτηριστικά.

5.3.2 Σύγκριση αποτελεσμάτων για τη αγορά της Ιρλανδίας με βιβλιογραφία

Ολοκληρώνοντας την αξιολόγηση των μοντέλων πρόβλεψης για τις αγορές Εξισορρόπησης της Ιρλανδίας, του Βελγίου και της Ισπανίας, κρίθηκε σκόπιμο να διερευνηθεί κατά πόσο τα αποτελέσματα της παρούσας διπλωματικής εργασίας ευθυγραμμίζονται ή διαφοροποιούνται σε σχέση με πρόσφατα ευρήματα της διεθνούς βιβλιογραφίας. Στο πλαίσιο αυτό, ιδιαίτερο ενδιαφέρον παρουσιάζει η περίπτωση της Ιρλανδικής Αγοράς Εξισορρόπησης, για την οποία είναι διαθέσιμη σχετική εμπεριστατωμένη μελέτη [6]. Για τον λόγο αυτό επιλέγεται η συγκριτική αξιολόγηση των επιδόσεων των μοντέλων της παρούσας διπλωματικής εργασίας με εκείνες που παρουσιάζονται στη συγκεκριμένη βιβλιογραφική πηγή.

Η βιβλιογραφική μελέτη καλύπτει την περίοδο 2019–2022 και βασίζεται σε άμεση πρόβλεψη των τιμών για τα επόμενα 16 χρονικά βήματα, με χρονικό βήμα 30 λεπτών, καλύπτοντας συνολικό χρονικό ορίζοντα 8 ωρών. Ακολουθείται η μεθοδολογία πρόβλεψης μελλοντικής ακολουθίας βημάτων (Multi-Step Prediction), κατά την οποία όλες οι τιμές του ορίζοντα προβλέπονται

ταυτόχρονα. Η διαδικασία αυτή επαναλαμβάνεται κάθε 8 ώρες, με πλήρη επανεκπαίδευση των μοντέλων σε κάθε νέο κύκλο πρόβλεψης. Επιπλέον, οι παράμετροι των μοντέλων ρυθμίζονται ανά τρίμηνο, βάσει της απόδοσής τους σε ξεχωριστά υποσύνολα ελέγχου, ενώ χρησιμοποιούνται διαφορετικά μεγέθη συνόλων εκπαίδευσης, τα οποία εκτείνονται από έναν μήνα έως και έναν ολόκληρο χρόνο (30, 60, 90 και 365 ημέρες), με σκοπό τη διερεύνηση της επίδρασης της μακροχρόνιας πληροφορίας στην συνέπεια και την αξιοπιστία των προβλέψεων. Τα παραπάνω χαρακτηριστικά παρουσιάζονται συνοπτικά στον Πίνακα 5.23.

Πίνακας 5.23: Κύρια χαρακτηριστικά της μεθοδολογίας της βιβλιογραφικής μελέτης για την Ιρλανδική αγορά Εξισορρόπησης [6]

Χαρακτηριστικό	Μεθοδολογική προσέγγιση της βιβλιογραφίας	Μεθοδολογική προσέγγιση παρούσας διπλωματικής εργασίας
Περίοδος μελέτης	2019–2022	2021
Συχνότητα δεδομένων	30 λεπτά	30 λεπτά
Ορίζοντας πρόβλεψης	8 ώρες	8 ώρες
Είδος πρόβλεψης	Πολυβηματική πρόβλεψη	Πρόβλεψη με λογική κλειστού βρόχου
Συχνότητα πρόβλεψης	Ανά 8 ώρες	Ανά 8 ώρες
Επανεκπαίδευση μοντέλου	Πλήρης, σε κάθε νέο κύκλο πρόβλεψης	Όχι (ARIMA: επανεκπαίδευση για κάθε σύνολο πρόβλεψης)
Παράθυρα εκπαίδευσης	30, 60, 90 και 365 ημερών	1, 1.5, 2, 3 και 7 ημερών
Ρύθμιση υπερπαραμέτρων	Ανά τρίμηνο	Μία φορά στο πρώτο 80% κάθε μήνα (σύνολο εκπαίδευσης)
Διαχωρισμός συνόλων ελέγχου για αξιολόγηση	Ναι (ξεχωριστά υποσύνολα επαλήθευσης)	Ναι (τελευταίο 20% κάθε μήνα αξιολόγησης)
Πηγές δεδομένων Ιρλανδικής αγοράς	SEMO, SEMOpX	ENTSO-e

Σε αντιπαραβολή με την παραπάνω μεθοδολογική προσέγγιση, στο πλαίσιο της παρούσας διπλωματικής εργασίας ακολουθείται διαφορετική στρατηγική πρόβλεψης, όπως παρουσιάζεται στις Ενότητες 3.5 και 4.2. Η ανάλυση επικεντρώνεται στο έτος 2021 και εφαρμόζει βραχυπρόθεσμη πρόβλεψη 16 χρονικών βημάτων, αξιοποιώντας τα πιο πρόσφατα διαθέσιμα ιστορικά δεδομένα, όπως καθορίζονται από το εκάστοτε παράθυρο εκπαίδευσης. Η διαδικασία πρόβλεψης βασίζεται στη λογική κλειστού βρόχου, κατά την οποία κάθε προβλεπόμενη τιμή επανεισάγεται ως είσοδος για την επόμενη χρονική στιγμή. Συμπληρωματικά, η αξιολόγηση πραγματοποιείται σε διακριτό σύνολο δεδομένων ανά μήνα, το οποίο δεν χρησιμοποιείται κατά την εκπαίδευση των μοντέλων.

Με βάση τα παραπάνω, η συγκριτική αξιολόγηση μεταξύ των δύο προσεγγίσεων βασίζεται στις μετρικές μέσου απόλυτου σφάλματος (MAE), μέσου τετραγωνικού σφάλματος (RMSE) και συμμετρικής ποσοστιαίας απόκλισης (sMAPE). Η αποτίμηση επικεντρώνεται στην Ιρλανδική Αγορά Εξισορρόπησης, ώστε να καταστεί δυνατή η άμεση σύγκριση με τα ευρήματα της βιβλιογραφικής μελέτης. Για τις ανάγκες της σύγκρισης, αξιοποιούνται τα καλύτερα αποτελέσματα που προέκυψαν

για κάθε μοντέλο πρόβλεψης στο πλαίσιο της παρούσας διπλωματικής εργασίας, βάσει του βέλτιστου συνδυασμού μήνα και παραθύρου εκπαίδευσης, τα οποία παρουσιάστηκαν στον Πίνακα 5.20.

Πίνακας 5.24: Σύγκριση αποτελεσμάτων του μοντέλου ARIMA με τη βιβλιογραφική μελέτη για την Ιρλανδία

Μετρική σφάλματος	Παράθυρο Εκπαίδευσης στη βιβλιογραφία				Αποτελέσματα παρούσας μελέτης - καλύτερος χρονικός συνδυασμός	Σχόλιο
	30 ημέρες	60 ημέρες	90 ημέρες	365 ημέρες	Αύγουστος – 48 ιστορικά βήματα	
MAE (€/MWh)	43.15	42.72	42.44	41.51	27.10	Υπεροχή σε όλες τις μετρικές
RMSE (€/MWh)	68.54	67.61	67.20	66.00	35.75	
sMAPE (%)	76.26	75.82	75.50	74.24	17.66	

Πίνακας 5.25: Σύγκριση αποτελεσμάτων του μοντέλου XGBoost με τη βιβλιογραφική μελέτη για την Ιρλανδία

Μετρική σφάλματος	Παράθυρο Εκπαίδευσης στη βιβλιογραφία				Αποτελέσματα παρούσας μελέτης - καλύτερος χρονικός συνδυασμός	Σχόλιο
	30 ημέρες	60 ημέρες	90 ημέρες	365 ημέρες	Αύγουστος – 72 ιστορικά βήματα	
MAE (€/MWh)	35.35	34.40	34.29	33.71	30.48	Υπεροχή σε όλες τις μετρικές
RMSE (€/MWh)	60.46	58.03	56.89	57.03	39.31	
sMAPE (%)	69.71	67.62	67.12	66.89	19.91	

Πίνακας 5.26: Σύγκριση αποτελεσμάτων μοντέλου LEAR με τη βιβλιογραφική μελέτη για την Ιρλανδία

Μετρική σφάλματος	Παράθυρο Εκπαίδευσης στη βιβλιογραφία				Αποτελέσματα παρούσας μελέτης -καλύτερος χρονικός συνδυασμός	Σχόλιο
	30 ημέρες	60 ημέρες	90 ημέρες	365 ημέρες	Ιούνιος – 48 ιστορικά βήματα	
MAE (€/MWh)	35.95	34.12	33.57	32.82	35.38	Ελαφρώς υψηλότερα MAE και RMSE, αλλά σημαντική υπεροχή στο sMAPE
RMSE (€/MWh)	57.89	56.38	56.34	56.53	66.56	
sMAPE (%)	72.14	67.19	66.20	64.93	31.52	

Η συγκριτική αξιολόγηση αναδεικνύει τη δυναμική των μοντέλων που εφαρμόστηκαν στην παρούσα διπλωματική εργασία σε σχέση με τη προσέγγιση της βιβλιογραφίας, η οποία παρουσιάστηκε στον Πίνακα 5.23. Όπως παρουσιάζεται στον Πίνακα 5.24, το μοντέλο ARIMA εμφανίζει σαφή υπεροχή σε όλες τις βασικές μετρικές σφάλματος, καθώς οι τιμές σφάλματος που επιτυγχάνονται στην παρούσα διπλωματική εργασία για τον βέλτιστο χρονικό συνδυασμό είναι αισθητά χαμηλότερες από εκείνες που καταγράφονται σε όλα τα χρονικά παράθυρα εκπαίδευσης της βιβλιογραφίας. Όμοια, το μοντέλο XGBoost, όπως αποτυπώνεται στον Πίνακα 5.25, εμφανίζει την καλύτερη συνολικά επίδοση με τα χαμηλότερα επίπεδα σφάλματος σε κάθε μετρική, γεγονός που καταδεικνύει την αποτελεσματικότητα της μεθοδολογίας βραχυπρόθεσμης πρόβλεψης και της χρήσης πρόσφατων ιστορικών δεδομένων. Από την άλλη πλευρά, το μοντέλο LEAR, όπως παρουσιάζεται στον Πίνακα 5.26, αν και εμφανίζει ελαφρώς αυξημένα σφάλματα ως προς το μέσο απόλυτο και το μέσο τετραγωνικό σφάλμα, υπερέχει σημαντικά ως προς τον δείκτη sMAPE, αποδεικνύοντας βελτιωμένη σχετική ακρίβεια. Τα ευρήματα αυτά αναδεικνύουν ότι η επιλογή μικρότερου ιστορικού παραθύρου εκπαίδευσης και η εστίαση στη βραχυπρόθεσμη πρόβλεψη μπορούν να οδηγήσουν σε ουσιαστικά βελτιωμένες επιδόσεις συγκριτικά με τη μεθοδολογία της υπάρχουσας βιβλιογραφίας.

ΣΥΜΠΕΡΑΣΜΑΤΑ

6.1 ΣΥΝΟΨΗ ΤΗΣ ΕΡΓΑΣΙΑΣ ΚΑΙ ΤΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΤΗΣ

Η παρούσα διπλωματική εργασία ανέλυσε τη δυνατότητα πρόβλεψης των τιμών Εξισορρόπησης για τις αγορές της Ιρλανδίας, της Ισπανίας και του Βελγίου, μέσω τεσσάρων μοντέλων: ARIMA, LEAR, XGBoost και Naive. Όπως παρουσιάστηκε στο Κεφάλαιο 2, κάθε ευρωπαϊκή αγορά χαρακτηρίζεται από διαφορετικό βαθμό πολυπλοκότητας, εποχικότητας και μεταβλητότητας, οι οποίες διαφορές επηρεάζουν καθοριστικά την πρόβλεψη. Οι διαφορές αυτές επιβεβαιώθηκαν στα πειραματικά αποτελέσματα του Κεφαλαίου 5, αναδεικνύοντας τις ιδιαιτερότητες και τις προκλήσεις πρόβλεψης σε κάθε αγορά.

Στην Ιρλανδία, το ARIMA εμφάνισε καθαρή υπεροχή. Όπως παρουσιάστηκε στην Υποενότητα 5.3.1, το μοντέλο κατέγραψε τις χαμηλότερες τιμές MAE και sMAPE στον Αύγουστο, με MAE ίσο με 27.10 €/MWh και sMAPE ίσο με 17.66% για παράθυρο εκπαίδευσης 48 ημιώρων. Αντίθετα, το LEAR κατέρρευσε σε μήνες με υψηλή μεταβλητότητα, όπως ο Σεπτέμβριος και ο Οκτώβριος, με τιμές MAE που ξεπέρασαν τα 480 €/MWh και RMSE άνω των 800 €/MWh. Το XGBoost παρουσίασε ικανοποιητική απόδοση ως προς τον δείκτη MAE, χωρίς όμως να καταφέρει να προβλέψει με ακρίβεια τις αιχμές ή τις απότομες μεταβολές. Η αδυναμία αυτή δεν είναι συγκυριακή, αλλά απορρέει από τη φύση του αλγορίθμου, ο οποίος είναι ιδιαίτερα αποδοτικός στην αναγνώριση προτύπων, αλλά τείνει να εξομαλύνει τη συμπεριφορά της χρονοσειράς, μειώνοντας την ευαισθησία του σε ακραίες τιμές.

Η υπεροχή του ARIMA ενισχύεται και από τη σύγκριση με προηγούμενες μελέτες: σε σχετική εργασία που εξετάζει την Ιρλανδική Αγορά Εξισορρόπησης για την περίοδο 2019–2022, αναφέρονται τιμές sMAPE άνω του 60% για αντίστοιχες προβλέψεις, γεγονός που καταδεικνύει την πρόκληση του προβλήματος [6]. Αντίθετα, στην παρούσα διπλωματική εργασία, το ARIMA πέτυχε τιμή sMAPE ίση με 17.66% στον βέλτιστο συνδυασμό μήνα και παραθύρου εκπαίδευσης, ενώ το XGBoost σημείωσε αντίστοιχη απόδοση με sMAPE = 19.91% για μεγαλύτερο παράθυρο εκπαίδευσης (72 ημίωρα), όπως παρουσιάστηκε στην Υποενότητα 5.3.2. Η βελτιωμένη απόδοση των μοντέλων αποδίδεται στη στρατηγική μηνιαίας εκπαίδευσης, στη χρήση στοχευμένων χρονικών παραθύρων και στη λεπτομερή αξιολόγηση ανά μήνα. Σε αντίθεση με τις περισσότερες μελέτες της βιβλιογραφίας, οι οποίες εφαρμόζουν εκπαίδευση μοντέλων σε μεγάλα χρονικά διαστήματα, η παρούσα προσέγγιση βασίζεται σε βραχυπρόθεσμα παράθυρα εκπαίδευσης, γεγονός που ενισχύει τη χρονική προσαρμοστικότητα και επιτρέπει στα μοντέλα να ανταποκρίνονται πιο εύστοχα στις συνθήκες κάθε περιόδου. Ο συνδυασμός αυτών των παραμέτρων καθιστά δυνατή την ανάπτυξη ευέλικτων και αποτελεσματικών μοντέλων πρόβλεψης.

Στην Ισπανία, η χαμηλή μεταβλητότητα της αγοράς και η ομαλή διακύμανση των τιμών επέτρεψαν την επίτευξη χαμηλών σφαλμάτων από όλα τα μοντέλα, όπως αναλύεται στην Υποενότητα 5.2.2. Το ARIMA κατέγραψε τις καλύτερες επιδόσεις τον Μάιο με παράθυρο εκπαίδευσης ίσο με 336 ημίωρα, επιτυγχάνοντας MAE ίσο με 5.3 €/MWh και sMAPE ίσο με 7.6%. Παρόμοια αποτελέσματα καταγράφηκαν και από τα μοντέλα LEAR και XGBoost, με μικρές αποκλίσεις, γεγονός που επιβεβαιώνει τη σταθερότητα του περιβάλλοντος πρόβλεψης. Οι χαμηλές τιμές και η απουσία έντονων αιχμών περιόρισαν τις αποκλίσεις και ευνόησαν τη συνολική επίδοση όλων των προσεγγίσεων. Αξιοσημείωτο είναι ότι, σε αντίθεση με την Ιρλανδική Αγορά Εξισορρόπησης, δεν καταγράφηκε αιχμή σφαλμάτων τον Σεπτέμβριο. Η διαφοροποίηση αυτή αποδίδεται σε διαρθρωτικά χαρακτηριστικά της ισπανικής αγοράς, όπως η συμμετοχή σε κοινές ευρωπαϊκές πλατφόρμες, η αυξημένη διείσδυση ΑΠΕ και η λειτουργική σταθερότητα απέναντι σε εξωτερικές διακυμάνσεις. Αντίθετα, στην Ιρλανδία, οι περιορισμένες ηλεκτρικές διασυνδέσεις και η υψηλή εξάρτηση από τεχνολογίες μεταβλητής παραγωγής, όπως οι ανεμογεννήτριες, καθιστούν το σύστημα πιο ευάλωτο σε αστάθειες, δυσχεραίνοντας σημαντικά την πρόβλεψη κατά τη διάρκεια περιόδων με έντονη αβεβαιότητα.

Επιπλέον, η χαμηλή μέση τιμή Εξισορρόπησης που καταγράφεται για την Ισπανία, όπως παρουσιάζεται στον Πίνακα 5.1, εξηγεί εν μέρει την υψηλή τιμή του sMAPE στους πρώτους μήνες του έτους. Σε εκείνες τις περιόδους, ακόμη και μικρές απόλυτες αποκλίσεις (π.χ. 3–4 €/MWh) μεταφράζονται σε σημαντικές ποσοστιαίες αποκλίσεις λόγω του χαμηλού παρονομαστή στον υπολογισμό του δείκτη. Ακόμη, η επίδοση του ARIMA σε αυτό το περιβάλλον αποδεικνύει τη δυσκολία επίτευξης χαμηλού σχετικού σφάλματος, όταν το εύρος τιμών είναι περιορισμένο. Ειδικότερα, οι τιμές του MAE αντιστοιχούν περίπου στο 32% της μέσης μηνιαίας τιμής εξισορρόπησης και στο 31% για παράθυρο εκπαίδευσης ίσο με 336 ημίωρα, γεγονός που υποδηλώνει ότι ακόμη και μικρές απόλυτες αποκλίσεις έχουν αναλογικά σημαντικό αντίκτυπο. Τα παραπάνω ευρήματα ενισχύουν την ανάγκη εφαρμογής μοντέλων προσαρμοσμένων στα διαρθρωτικά χαρακτηριστικά κάθε αγοράς, τα οποία διατηρούν υψηλή αξιοπιστία ακόμα και σε περιόδους περιορισμένης ή μεταβαλλόμενης μεταβλητότητας.

Στο Βέλγιο, η πρόβλεψη των τιμών Εξισορρόπησης αποδείχθηκε σημαντικά πιο απαιτητική. Όπως παρουσιάστηκε στην Υποενότητα 5.2.3, το ARIMA σημείωσε τη χαμηλότερη τιμή MAE ίση με 48.07 €/MWh τον Φεβρουάριο με παράθυρο 96 ημωρών, ενώ σε παράθυρο εκπαίδευσης 336 ημωρών το MAE διαμορφώθηκε σε 49.34 €/MWh. Ωστόσο, οι τιμές του δείκτη sMAPE παρέμειναν εξαιρετικά υψηλές, κυμαινόμενες από 98.43% έως 94.65%, όπως καταγράφεται στον Πίνακα 5.18. Το γεγονός αυτό αποτυπώνει την αδυναμία του μοντέλου να κατανοήσει τις σχετικές μεταβολές των τιμών, παρά την επιτυχία του σε απόλυτες αποκλίσεις. Το LEAR, αν και εμφάνισε σε ορισμένα σενάρια χαμηλότερες τιμές sMAPE, απέτυχε να αποτυπώσει τη δυναμική της αγοράς, παρέχοντας επίπεδες προβλέψεις με υψηλά σφάλματα MAE, όπως 174.12 €/MWh στο παράθυρο των 96 ημωρών. Το XGBoost κινήθηκε ενδιάμεσα, με πιο σταθερές προβλέψεις αλλά επίσης χωρίς ουσιαστική υπεροχή, καθώς παρουσίασε MAE 87.62 €/MWh και sMAPE 99.56% στο ίδιο παράθυρο εκπαίδευσης. Κοινός παρονομαστής όλων των μοντέλων είναι η αδυναμία πρόβλεψης των συχνών και έντονων αρνητικών τιμών Εξισορρόπησης που παρατηρούνται σε μεγάλο μέρος της περιόδου αξιολόγησης. Όπως επισημαίνεται στην Υποενότητα 2.3.3, οι αρνητικές τιμές αποτελούν εγγενές χαρακτηριστικό της Βελγικής Αγοράς Εξισορρόπησης, προερχόμενο από τις διασυννοριακές εκκαθαρίσεις και τις ακραίες συνθήκες ζήτησης. Το γεγονός αυτό επηρεάζει δραστικά την επίδοση των μοντέλων και υπονομεύει την αξιοπιστία των συμβατικών δεικτών. Τα ευρήματα αυτά αναδεικνύουν την ανάγκη εξειδικευμένων μεθόδων πρόβλεψης με ενσωμάτωση ρυθμιστικών και τεχνικών παραμέτρων.

Το μοντέλο Naive, χρησιμοποιήθηκε ως βασική γραμμή σύγκρισης. Εμφάνισε ανεκτές επιδόσεις σε μήνες με χαμηλή μεταβλητότητα, όπως ο Αύγουστος, αλλά αδυνατούσε πλήρως να προσαρμοστεί

στις αιχμές ή σε περιβάλλοντα με έντονη αβεβαιότητα, όπως το Βέλγιο ή η Ιρλανδία. Παρότι σε ορισμένες περιπτώσεις το μοντέλο Naive παρουσίασε τιμές MAE συγκρίσιμες με εκείνες πιο σύνθετων μοντέλων, το RMSE αποκάλυψε με σαφήνεια τις αποκλίσεις, υπογραμμίζοντας τη σημασία επιλογής κατάλληλων μετρικών.

Ένα κοινό εύρημα, όπως αναδείχθηκε στη Ενότητα 5.2, είναι η συστηματική επιδείνωση της απόδοσης των μοντέλων κατά το τελευταίο τρίμηνο του έτους και στις τρεις αγορές ενδιαφέροντος. Οι τελευταίοι μήνες του έτους συνοδεύτηκαν από αυξημένα σφάλματα και μειωμένη ακρίβεια. Ο Αύγουστος, από την άλλη πλευρά, χαρακτηρίστηκε από περιορισμένη διακύμανση και αποτέλεσε τον μήνα με τις χαμηλότερες αποκλίσεις πρόβλεψης στις περισσότερες περιπτώσεις. Τα παραπάνω επιβεβαιώνουν ότι η χρονική περίοδος εφαρμογής επηρεάζει ουσιαστικά την πρόβλεψη και στηρίζουν την ανάγκη προσαρμογής της μοντελοποίησης στις εποχικές και δομικές ιδιαιτερότητες κάθε αγοράς, οι οποίες αναλύθηκαν στη Ενότητα 2.3.

Συμπερασματικά, το ARIMA αναδείχθηκε ως το πιο αξιόπιστο μοντέλο, προσφέροντας ισορροπία μεταξύ απλότητας, ευρωστίας και προσαρμοστικότητας. Η μονομεταβλητή φύση του το καθιστά ανθεκτικό σε εξωγενείς θορυβώδεις εισόδους, όπως προβλέψεις φορτίου ή ΑΠΕ, γεγονός κρίσιμο σε σύνθετες αγορές. Η συνοχή και αξιοπιστία του ARIMA σε περιβάλλοντα έντονης αβεβαιότητας το καθιστούν κατάλληλο για πραγματικές εφαρμογές πρόβλεψης, ενώ το σύνολο των αποτελεσμάτων υποδεικνύει ότι η επιτυχής πρόβλεψη εξαρτάται από την αρχιτεκτονική προσέγγιση, τα χαρακτηριστικά της αγοράς και τη χρονική περίοδο εφαρμογής.

6.2 ΠΕΡΙΟΡΙΣΜΟΙ ΚΑΙ ΔΥΣΚΟΛΙΕΣ

Η παρούσα διπλωματική εργασία, παρά την μεθοδική συγκρότηση και την πολυεπίπεδη συγκριτική αξιολόγηση των μοντέλων πρόβλεψης, αντιμετώπισε ορισμένους περιορισμούς που σχετίζονται με τη φύση των δεδομένων, τα χαρακτηριστικά των Αγορών Εξισορρόπησης και τις επιλεγμένες μεθοδολογικές προσεγγίσεις. Όπως παρουσιάστηκε στην Ενότητα 2.4, οι Αγορές Εξισορρόπησης χαρακτηρίζονται από ασυμμετρία, έντονη στοχαστικότητα και ευαισθησία σε εξωτερικές διαταραχές, χαρακτηριστικά που καθιστούν ιδιαίτερα δύσκολη την πρόβλεψη της πλήρους κατανομής των τιμών. Το πρόβλημα εντείνεται στην περίπτωση ακραίων τιμών, όπως οι αρνητικές ή οι ιδιαίτερα υψηλές, οι οποίες συχνά δεν εμφανίζονται σε ιστορικά πρότυπα και εκδηλώνονται αιφνிடίως. Όπως καταγράφηκε στο Κεφάλαιο 5, το μοντέλο LEAR παρουσίασε πολύ χαμηλή ακρίβεια σε περιόδους υψηλής μεταβλητότητας στην Ιρλανδία, ενώ στο Βέλγιο όλα τα μοντέλα απέτυχαν να αποδώσουν ικανοποιητικά στις συχνές και έντονες αρνητικές τιμές που οφείλονται σε διασυννοριακές εκκαθαρίσεις και σε επεισόδια υψηλής ζήτησης, όπως αναλύθηκε στην Υποενότητα 5.2.3. Η βασική παραδοχή μοντέλων όπως το ARIMA και το LEAR, δηλαδή ότι οι ιστορικές τάσεις επαρκούν για την πρόβλεψη της μελλοντικής συμπεριφοράς, αποδεικνύεται ανεπαρκής σε αγορές με έντονη στοχαστικότητα.

Επιπρόσθετα, η παρούσα διπλωματική εργασία δεν αξιοποίησε τεχνικές πιθανοτικής πρόβλεψης ή εξειδικευμένες μεθόδους πρόβλεψης ακραίων τιμών, οι οποίες έχουν αναγνωριστεί στη βιβλιογραφία ως κατάλληλες για περιβάλλοντα με υψηλό βαθμό αβεβαιότητας, ακόμη και αν η χρήση τους συνεπάγεται μικρότερη μέση ακρίβεια [6]. Παράλληλα, η αξιοποίηση δεδομένων με μεγαλύτερη χρονική ευκρίνεια, όπως χρονοσειρές πεντάλεπτης ανάλυσης ή στοιχεία εμπορικών εντολών και εκκαθαρίσεων, θα μπορούσε να ενισχύσει περαιτέρω την ακρίβεια και την προσαρμοστικότητα των μοντέλων, ιδίως σε αγορές που επηρεάζονται σημαντικά από την κατεύθυνση και την ένταση των διασυννοριακών ροών. Επιπλέον, η κατάλληλη επιλογή περιόδων

εκπαίδευσης των μοντέλων επέτρεψε την εποχική προσαρμογή των μοντέλων στις συνθήκες κάθε περιόδου, προσφέροντας ευελιξία και τοπική προσαρμοστικότητα. Ωστόσο, σε περιόδους με έντονη δυναμική και μη επαναλαμβανόμενα πρότυπα, όπως ραγδαίες ενδοημερήσιες μεταβολές ή ξαφνικές αιχμές, διαπιστώθηκαν αδυναμίες στην απόδοση των μοντέλων πρόβλεψης. Το γεγονός αυτό αναδεικνύει τα όρια των συμβατικών τεχνικών πρόβλεψης, ιδιαίτερα όταν δεν ενισχύονται από σύνθετες ή πιθανοτικές μεθόδους, ικανές να αποδώσουν την αβεβαιότητα και την ποικιλομορφία των πραγματικών αγορών.

Τέλος, τα αποτελέσματα βασίζονται σε δεδομένα 30λεπτης ανάλυσης για την περίοδο 2021–2022, περιορίζοντας τη δυνατότητα γενίκευσης των συμπερασμάτων σε βάθος χρόνου. Η σταδιακή μεταβολή της ενεργειακής στρατηγικής, όπως η αυξανόμενη διείσδυση των ΑΠΕ, η ανάπτυξη μονάδων αποθήκευσης και η ενίσχυση των ηλεκτρικών διασυνδέσεων, ενδέχεται να επηρεάσει τη συμπεριφορά των αγορών και την απόδοση των μοντέλων στο μέλλον. Ωστόσο, το προτεινόμενο πλαίσιο πρόβλεψης εμφανίζει σημαντική ευελιξία και προσαρμοστικότητα, γεγονός που το καθιστά κατάλληλο για μελλοντικές εφαρμογές σε πιο εκτεταμένα ή εναλλασσόμενα συστήματα.

6.3 ΜΕΛΛΟΝΤΙΚΕΣ ΚΑΤΕΥΘΥΝΣΕΙΣ

Η παρούσα διπλωματική εργασία ανέδειξε τη σημασία κατάλληλης μοντελοποίησης για την πρόβλεψη των Τιμών Εξισορρόπησης, ανάλογα με τα δομικά και εποχικά χαρακτηριστικά κάθε αγοράς. Τα αποτελέσματα που καταγράφηκαν στο Κεφάλαιο 5 επιβεβαίωσαν τις διαφορετικές ανάγκες ανά χώρα και τη σημαντική επίδραση της χρονικής περιόδου στην αποδοτικότητα των μοντέλων. Βάσει αυτών των ευρημάτων, διαφαίνονται σημαντικές κατευθύνσεις για μελλοντική έρευνα και βελτίωση.

Μία βασική προοπτική είναι η ενσωμάτωση περισσότερων χαρακτηριστικών εισόδου, τα οποία μπορούν να εμπλουτίσουν τη μαθησιακή διαδικασία των μοντέλων. Εκτός από τα χαρακτηριστικά εισόδου που χρησιμοποιήθηκαν στην παρούσα διπλωματική εργασία, η προσθήκη επιπλέον εξωτερικών μεταβλητών, όπως οι τιμές καυσίμων, τα δεδομένα παραγωγής από συνδεδεμένες αγορές ή οι μετεωρολογικές συνθήκες, δύναται να προσφέρει μία πιο ρεαλιστική αναπαράσταση των δυναμικών της αγοράς και να ενισχύσει την απόδοση, ιδίως σε αγορές με πολύπλοκη δυναμική, όπως του Βελγίου. Εξίσου σημαντική είναι η διεύρυνση του στόχου πρόβλεψης πέραν της απόλυτης τιμής, με έμφαση στην πρόβλεψη της κατεύθυνσης και του μεγέθους της ανισορροπίας. Μια τέτοια διακριτή προσέγγιση, που εστιάζει στην πρόβλεψη των περιπτώσεων ανοδικής ή καθοδικής ανισορροπίας, μπορεί να ενισχύσει τη στρατηγική λήψη αποφάσεων για φορείς που δραστηριοποιούνται στην αγορά, όπως μονάδες αποθήκευσης ή παραγωγοί με δυνατότητα ευέλικτης απόκρισης.

Ένα ακόμη σημαντικό πεδίο μελλοντικής έρευνας αφορά στη συνεκτίμηση προβλέψεων μέσω συνδυαστικών μεθόδων (ensemble methods). Όπως ανέδειξε η μηνιαία ανάλυση των αποτελεσμάτων ανά μοντέλο, κάθε προσέγγιση παρουσίασε διαφοροποιημένη απόδοση υπό διαφορετικές συνθήκες. Η αξιοποίηση ενός υβριδικού σχήματος, που επιλέγει το καταλληλότερο μοντέλο για κάθε χρονική ζώνη ή συνδυάζει τις επιμέρους προβλέψεις με κατάλληλη στάθμιση, μπορεί να αυξήσει σημαντικά την ευρωστία και την ακρίβεια των εκτιμήσεων, ιδιαίτερα σε περιβάλλοντα με έντονη αβεβαιότητα και διακυμάνσεις. Περαιτέρω κατευθύνσεις περιλαμβάνουν την υιοθέτηση πιθανοτικών τεχνικών πρόβλεψης, οι οποίες επιτρέπουν την εκτίμηση της αβεβαιότητας γύρω από την προβλεπόμενη τιμή. Επιπλέον, η διεύρυνση των δεδομένων εισόδου με πληροφορίες υψηλότερης ανάλυσης ή επιχειρησιακών χαρακτηριστικών θα μπορούσε να ενισχύσει την ακρίβεια των εκτιμήσεων και να επιτρέψει την ανάπτυξη πιο προσαρμοστικών μεθόδων πρόβλεψης.

Παράλληλα, η επέκταση της ανάλυσης σε άλλες Αγορές Εξισορρόπησης, όπως εκείνες της Κεντρικής Ευρώπης, θα μπορούσε να βελτιώσει τη γενικευσιμότητα των συμπερασμάτων και να

αναδεικνύει διαρθρωτικές διαφορές μεταξύ των αγορών. Τέλος, η αξιοποίηση μοντέλων μηχανικής μάθησης με δυνατότητες εντοπισμού αιχμών ή ταξινόμησης σπάνιων επεισοδίων δύναται να προσφέρει πρακτικά πλεονεκτήματα σε εφαρμογές όπως η διαχείριση κινδύνου και η στρατηγική αξιοποίηση διαφορών τιμών μεταξύ της Αγοράς Επόμενης Ημέρας και της Αγοράς Εξισορρόπησης. Η διερεύνηση αυτών των προσεγγίσεων συνιστά εύφορο έδαφος για μελλοντική έρευνα, ικανή να ενισχύσει την επιχειρησιακή αξία των προβλέψεων σε σύγχρονα ενεργειακά περιβάλλοντα με αυξημένη αβεβαιότητα.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1]. European Commission. (2020). *Electricity market design*. Διαθέσιμο στην ιστοσελίδα: <https://energy.ec.europa.eu>
- [2]. Wang, J., Zhang, L., Zhao, P., & Liu, Y. (2021). Short-term electricity price forecasting in balancing markets with high RES penetration. *Energy*, 231, 120872. DOI: <https://doi.org/10.1016/j.energy.2021.120872>
- [3]. ACER & CEER. (2023). *Annual Report on the Results of Monitoring the Internal Electricity Market*. Διαθέσιμο στην ιστοσελίδα: https://www.acer.europa.eu/sites/default/files/documents/Publications/ACER_CEER_Electricity_Market_Monitoring_Report_2023.pdf
- [4]. NEMO Committee. (2022). *EUPHEMIA & XBID Public Descriptions*. Διαθέσιμο στην ιστοσελίδα: <https://www.nemo-committee.eu>
- [5]. ENTSO-E. (2021). *Balancing Market Design 2021 Report*. Διαθέσιμο στην ιστοσελίδα: <https://www.entsoe.eu>
- [6]. O'Connor, C., Collins, J., Prestwich, S., & Visentin, A. (2024). Electricity price forecasting in the Irish balancing market. *Energy Strategy Reviews*, 54, 101436. DOI: <https://doi.org/10.1016/j.esr.2024.101436>
- [7]. Birkeland, A., & AlSkaif, T. (2023). A review of research on European intraday electricity markets. *Renewable and Sustainable Energy Reviews*, 177, 113293. DOI: <https://doi.org/10.1016/j.rser.2023.113293>
- [8]. Bueno-Lorenzo, M., Moreno, M. Á., & Usaola, J. (2013). Analysis of the imbalance price scheme in the Spanish electricity market: A wind power test case. *Energy Policy*, 62, 1010–1019. DOI: <https://doi.org/10.1016/j.enpol.2013.08.039>
- [9]. Bailera, M., & Lisbona, P. (2018). Energy storage in Spain: Forecasting electricity excess and assessment of power-to-gas potential up to 2050. *Energy*, 143, 900–910. DOI: <https://doi.org/10.1016/j.energy.2017.11.069>
- [10]. Rabobank. (2025). *Backup power for Europe – part 4: Spain's BESS market is heating up*. Διαθέσιμο στην ιστοσελίδα: <https://www.rabobank.com/knowledge/d011476239-backup-power-for-europe-part-4-spain-s-bess-market-is-heating-up>
- [11]. ENTSO-E. (2023). *Market Report 2023*. Διαθέσιμο στην ιστοσελίδα: https://eepublicdownloads.entsoe.eu/clean-documents/nc-tasks/ENTSO_E_Market_Report_2023.pdf
- [12]. Morales, J. M., Conejo, A. J., Madsen, H., Pinson, P., & Zugno, M. (2014). *Integrating renewables in electricity markets: Operational problems*. Springer. DOI: <https://doi.org/10.1007/978-1-4471-5100-1>

- [13]. European Parliament and Council (2009). Regulation (EC) No 714/2009 on conditions for access to the network for cross-border exchanges in electricity and repealing Regulation (EC) No 1228/2003. *Official Journal of the European Union*, L 211, 15–25. Διαθέσιμο στην ιστοσελίδα: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32009R0714>
- [14]. European Parliament and Council (2019). Regulation (EU) 2019/943 on the internal market for electricity. *Official Journal of the European Union*, L 158, 54–124. Διαθέσιμο στην ιστοσελίδα: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32019R0943>
- [15]. ENTSO-E (2021). *ENTSO-E Market Data Platform API Documentation*. European Network of Transmission System Operators for Electricity. Διαθέσιμο στην ιστοσελίδα: <https://transparency.entsoe.eu>
- [16]. Χασιριτζόγλου, Μ. (2020). Ανάλυση και πρόβλεψη χρονοσειρών με μοντέλα ARIMA και εφαρμογές [Μεταπτυχιακή διπλωματική εργασία, ΕΜΠ].
- [17]. Chen, T., & Guestrin, C. (2016). *XGBoost: A scalable tree boosting system*. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). DOI: <https://doi.org/10.1145/2939672.2939785>
- [18]. Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2η έκδοση). OTexts. Διαθέσιμο στην ιστοσελίδα: <https://otexts.com/fpp2/>
- [19]. Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (2008). *Time series analysis: Forecasting and control* (4th ed.). Wiley.
- [20]. Nardi, Y., & Rinaldo, A. (2008). Autoregressive process modelling via the Lasso procedure. *TR 862, Carnegie Mellon University*.
- [21]. Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1), 267–288. DOI: <https://doi.org/10.1111/j.2517-6161.1996.tb02080.x>
- [22]. Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer.
- [23]. Ziel, F. (2016). Forecasting electricity spot prices using Lasso: On capturing the autoregressive intraday structure. *IEEE Transactions on Power Systems*, 31(6), 4977–4987. DOI: <https://doi.org/10.1109/TPWRS.2016.2535521>
- [24]. Bentéjac, C., Csörgő, A., & Martínez-Muñoz, G. (2021). A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, *54*(3), 1937–1967. DOI: <https://doi.org/10.1007/s10462-020-09896-5>
- [25]. Zhou, Z. H. (2021). *Machine Learning: Foundations and Applications*. Springer. DOI: <https://doi.org/10.1007/978-981-15-1967-3>
- [26]. He, B., Wang, J., & Guo, J. (2019). “Improving power load forecasting accuracy with an XGBoost-based model.” *Energy*, 189, 116225. DOI: [10.1016/j.energy.2019.116225](https://doi.org/10.1016/j.energy.2019.116225)
- [27]. Omarzai, F. (2023). *XGBoost Classification in Depth* [Online]. Διαθέσιμο στο: <https://medium.com/@fraidoonomarzai99/xgboost-classification-in-depth-979f11ef4bf9>
- [28]. Kou, P., Gao, F., & Guan, X. (2023). Probabilistic electricity price forecasting with hybrid ensemble learning. *IEEE Transactions on Power Systems*, 38(2), 1234–1247. DOI: <https://doi.org/10.1109/TPWRS.2022.3187325>
- [29]. Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). *Statistical and Machine Learning forecasting methods: Concerns and ways forward*. PLoS ONE, 13(3), e0194889. DOI: <https://doi.org/10.1371/journal.pone.0194889>
- [30]. LCP Delta. *What is causing the record prices in the GB power market?* (2021). Διαθέσιμο στην ιστοσελίδα: <https://www.lcp.com/en/insights/blogs/what-is-causing-the-record-prices-in-the-gb-power-market>

-
- [31]. International Energy Agency (IEA), *The Global Energy Crisis Highlighted the Need to Accelerate Investments in Renewables*, Paris: IEA, 2022. Διαθέσιμο στην ιστοσελίδα: <https://www.iea.org/news/the-global-energy-crisis-highlighted-the-need-to-accelerate-investments-in-renewables>
- [32]. Red Eléctrica de España (REE), *Informe del sistema eléctrico español 2021*, Madrid: REE, 2022. Διαθέσιμο στην ιστοσελίδα: <https://www.ree.es/es/publicaciones/informes-del-sistema-electrico>
- [33]. Agency for the Cooperation of Energy Regulators (ACER), *Market Monitoring Report 2021 – Electricity Wholesale Volume*, Brussels: ACER, 2022. Διαθέσιμο στην ιστοσελίδα: <https://www.acer.europa.eu/electricity-market-monitoring-report>
- [34]. H. Hippert, C. Pedreira, and R. Souza, “Neural networks for short-term load forecasting: A review and evaluation,” *IEEE Transactions on Power Systems*, vol. 16, no. 1, pp. 44–55, 2001. DOI: <https://doi.org/10.1109/59.910780>
- [35]. Π. Σ. Γεωργιλάκης, *Σύγχρονα Συστήματα Μεταφοράς και Διανομής Ηλεκτρικής Ενέργειας*. Ηλεκτρονικό Βιβλίο, Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών (ΣΕΑΒ), Αθήνα, 2015. Διαθέσιμο στην ιστοσελίδα: <http://repository.kallipos.gr/handle/11419/2013>
- [36]. Π. Σ. Γεωργιλάκης, *Οικονομική και Αξιοπιστη Λειτουργία Σύγχρονων Συστημάτων Ηλεκτρικής Ενέργειας*. Ηλεκτρονικό Βιβλίο, Κάλλιπος, Ανοικτές Ακαδημαϊκές Εκδόσεις, Αθήνα, 2023. Διαθέσιμο στην ιστοσελίδα: <https://repository.kallipos.gr/handle/11419/9369>