ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ ΣΧΟΛΗ ΝΑΥΤΙΛΙΑΣ ΚΑΙ ΒΙΟΜΗΧΑΝΙΑΣ
ΤΜΗΜΑΤΟΣ ΒΙΟΜΗΧΑΝΙΚΗΣ ΔΙΟΙΚΗΣΗΣ & ΤΕΧΝΟΛΟΓΙΑΣ

ΔΙΕΠΙΣΤΗΜΟΝΙΚΟ – ΔΙΑΠΑΝΕΠΙΣΤΗΜΙΑΚΟ ΠΡΟΓΡΑΜΜΑ

ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ

«ΤΕΧΝΟ-ΟΙΚΟΝΟΜΙΚΑ ΣΥΣΤΗΜΑΤΑ»

Επίδραση της Μηχανικής Μάθησης στην Κατανάλωση Καυσίμου στη Ναυτιλία -Τεχνική και Επιχειρησιακή Προσέγγιση

ΜΕΤΑΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

Μαυράκη Μαρία

Επιβλέπων : Ασκούνης Δημήτριος, Καθηγητής, ΕΜΠ

Αθήνα, Ιούνιος 2026

ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ ΣΧΟΛΗ ΝΑΥΤΙΛΙΑΣ ΚΑΙ ΒΙΟΜΗΧΑΝΙΑΣ
ΤΜΗΜΑΤΟΣ ΒΙΟΜΗΧΑΝΙΚΗΣ ΔΙΟΙΚΗΣΗΣ & ΤΕΧΝΟΛΟΓΙΑΣ

ΔΙΕΠΙΣΤΗΜΟΝΙΚΟ – ΔΙΑΠΑΝΕΠΙΣΤΗΜΙΑΚΟ ΠΡΟΓΡΑΜΜΑ

ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ

«ΤΕΧΝΟ-ΟΙΚΟΝΟΜΙΚΑ ΣΥΣΤΗΜΑΤΑ»

Επίδραση της Μηχανικής Μάθησης στην Κατανάλωση Καυσίμου στη Ναυτιλία -Τεχνική και Επιχειρησιακή Προσέγγιση

ΜΕΤΑΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

Μαυράκη Μαρία

Επιβλέπων : Ασκούνης Δημήτριος
Καθηγητής, ΕΜΠ

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την Ημέρα Μήνας Έτος (πχ. 10η Μαρτίου 2024).

.....	.....	.....
Ονοματεπώνυμο ΔΕΠ Βαθμίδα, ΑΕΙ	Ονοματεπώνυμο ΔΕΠ Βαθμίδα, ΑΕΙ	.. Ονοματεπώνυμο ΔΕΠ Βαθμίδα, ΑΕΙ

Αθήνα, Ιούνιος 2026

.....

Μαυράκη Μαρία

Κάτοχος Μεταπτυχιακού Προγράμματος “Τεχνο-οικονομικά Συστήματα” της Σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών Ε.Μ.Π.

Copyright © **Μαυράκη Μαρία, 2026**

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

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

Περίληψη

Η κατανάλωση καυσίμου αποτελεί το μεγαλύτερο λειτουργικό κόστος (30-60% των λειτουργικών εξόδων, Operational Expenditure, OPEX) και την κύρια πηγή εκπομπών ενός εμπορικού πλοίου. Η παρούσα εργασία συγκρίνει αλγορίθμους Μηχανικής Μάθησης (Machine Learning, ML) (Random Forest [RF], Gradient Boosting [GB], Παλινδρόμηση Διανυσμάτων Υποστήριξης [Support Vector Regression, SVR], Neural Networks) για την πρόβλεψη κατανάλωσης ναυτικών κινητήρων, χρησιμοποιώντας το UCI (University of California, Irvine) Naval Propulsion Dataset (n=11.934).

Τα αποτελέσματα δείχνουν ότι τα ML μοντέλα, ιδιαίτερα τα ensemble methods, επιτυγχάνουν σημαντικά καλύτερη ακρίβεια από παραδοσιακές μεθόδους. Παρουσιάζονται πρακτικές εφαρμογές: βελτιστοποίηση ταχύτητας, προβλεπτική συντήρηση και digital twin συστήματα. Η ανάλυση της απόδοσης της επένδυσης (Return on Investment, ROI) αποδεικνύει ότι τα κέρδη από εξοικονόμηση καυσίμου δικαιολογούν το κόστος υλοποίησης.

Συμπερασματικά, η Μηχανική Μάθηση αποτελεί ένα ισχυρό εργαλείο βελτιστοποίησης ενεργειακής αποδοτικότητας στη ναυτιλία με σημαντική οικονομική και περιβαλλοντική επίδραση.

Λέξεις Κλειδιά:

Μηχανική Μάθηση, κατανάλωση καυσίμου, ναυτιλία, ενεργειακή αποδοτικότητα, Random Forest, Gradient Boosting.

Abstract

Fuel consumption represents both the largest operational cost (30-60% of OPEX) and the primary source of emissions in commercial shipping. This thesis compares Machine Learning algorithms (Random Forest, Gradient Boosting, SVR, Neural Networks) for predicting fuel consumption in marine engines, using the UCI Naval Propulsion Dataset (n=11,934).

The results demonstrate that ML models, particularly ensemble methods, achieve significantly better accuracy than traditional methods. Practical applications are presented: speed optimization, predictive maintenance, and digital twin systems. ROI analysis proves that fuel savings justify implementation costs.

In conclusion, Machine Learning is a powerful tool for optimizing energy efficiency in shipping with significant economic and environmental impact.

KeyWords:

Machine Learning, fuel consumption, shipping, energy efficiency, Random Forest, Gradient Boosting, speed optimization, predictive maintenance, EU ETS, digital twin.

Ευχαριστίες
Με την ολοκλήρωση της παρούσας διπλωματικής εργασίας, αισθάνομαι την ανάγκη να ευχαριστήσω όσους συνέβαλαν, καθένας με τον δικό του τρόπο, στην εκπόνησή της.

Πρώτα από όλους, θα ήθελα να εκφράσω τις θερμές μου ευχαριστίες στον/στην επιβλέποντα/επιβλέπουσα καθηγητή/καθηγήτριά μου, κύριο Ασκούνη, για την εμπιστοσύνη που μου έδειξε αναθέτοντάς μου το συγκεκριμένο θέμα, καθώς και για την πολύτιμη καθοδήγηση, τις εύστοχες παρατηρήσεις και τη συνεχή υποστήριξή του/της καθ' όλη τη διάρκεια της εργασίας. Η συμβολή του υπήρξε καθοριστική τόσο για την ολοκλήρωση της εργασίας όσο και για τη δική μου επιστημονική εξέλιξη.

Θα ήθελα επίσης να ευχαριστήσω τα μέλη της εξεταστικής επιτροπής, κύριο Μαρινάκη και Σπηλιώτη για τον χρόνο που αφιέρωσαν στην αξιολόγηση της εργασίας μου και για τις χρήσιμες υποδείξεις τους.

Ένα μεγάλο ευχαριστώ οφείλω στους φίλους και τους συμφοιτητές μου, για τη συμπαράσταση, τις ουσιαστικές συζητήσεις και τις όμορφες στιγμές που μοιραστήκαμε όλα αυτά τα χρόνια.

Τέλος, το πιο θερμό ευχαριστώ ανήκει στην οικογένειά μου, και ιδιαίτερα στους γονείς μου, για την αμέριστη ηθική και υλική στήριξη, την υπομονή και την ενθάρρυνση που μου προσέφεραν σε όλη τη διάρκεια των σπουδών μου. Χωρίς αυτούς, τίποτα από όλα αυτά δεν θα ήταν εφικτό.

Περιεχόμενα

Περίληψη 6
Περιεχόμενα 12
Πίνακας Συντομογραφιών 17
Λίστα Εικόνων 21
Λίστα Πινάκων 22
ΚΕΦΑΛΑΙΟ 1: Εισαγωγή 25
1.1 Πλαίσιο και Κίνητρο της Εργασίας 25
1.1.1 Η Κλιματική Κρίση και η Ναυτιλία 25
1.1.2 Ο Ρόλος της Κατανάλωσης Καυσίμου 25
1.2 Σκοπός, Ερευνητικά Ερωτήματα και Στόχοι 26
1.2.1 Σκοπός της Εργασίας 26
1.2.2 Ερευνητικά Ερωτήματα 26
1.3 Δομή της Εργασίας 26
ΚΕΦΑΛΑΙΟ 2: Η Κατανάλωση Καυσίμου στη Ναυτιλία 28
2.1 Εισαγωγή στη Ναυτιλία 28
2.1.1 Ιστορική Εξέλιξη και Παγκόσμια Σημασία 28
2.1.2 Κατηγορίες Ναυτιλιακών Πλοίων 28
2.1.3 Ο Κύκλος Ζωής ενός Ναυτιλιακού Πλοίου 29
2.2 Τεχνολογία Πρόωσης και Καύσιμα 30
2.2.1 Τύποι Κινητήρων 30
2.2.2 Τύποι Καυσίμων 30
2.2.3 Slow Steaming — Η Στρατηγική Μείωσης Κατανάλωσης 31
2.3 Παράγοντες που Επηρεάζουν την Κατανάλωση Καυσίμου 31
2.3.1 Υδροδυναμικοί Παράγοντες 31
Βιολογική Ρύπανση Γάστρας (Hull Fouling) 32
Trim Βελτιστοποίηση 32
2.3.2 Περιβαλλοντικοί Παράγοντες 32
2.3.3 Μηχανολογικοί Παράγοντες 33
2.4 Παραδοσιακές Μέθοδοι Πρόβλεψης Κατανάλωσης και Περιορισμοί 33
2.4.1 Ο Συντελεστής Admiralty (Admiralty Coefficient Method) 33
2.4.2 Πίνακες SFOC και Καμπύλες Ισχύος 34
2.4.3 Στατιστικές Μέθοδοι — Γραμμική και Πολυωνυμική Παλινδρόμηση 34
2.4.4 Φυσικά Μοντέλα (Physics-Based / First-Principles Models) 34
2.4.5 Σύνοψη και Συγκριτική Αξιολόγηση Παραδοσιακών Μεθόδων 34
2.5 Περιβαλλοντικοί Κανονισμοί και Πλαίσιο Συμμόρφωσης 36
2.5.1 Ιστορική Εξέλιξη Κανονισμών 36
2.5.2 EEDI — Energy Efficiency Design Index 37
2.5.3 EEXI — Energy Efficiency Existing Ship Index 37
2.5.4 CII — Carbon Intensity Indicator 37
2.5.5 EU ETS και FuelEU Maritime 38

2.5.6 SEEMP — Ship Energy Efficiency Management Plan 39
ΚΕΦΑΛΑΙΟ 3: Μηχανική Μάθηση — Θεωρία και Αλγόριθμοι 40
3.1 Βασικές Αρχές Μηχανικής Μάθησης 40
3.1.1 Ορισμός και Ιστορική Εξέλιξη 40
3.1.2 Θεμελιώδεις Έννοιες 40
3.1.3 Το Δίλημμα Bias-Variance 41
3.1.4 Βασικές Διαδικασίες Εκπαίδευσης 41
K-Fold Cross-Validation 41
Regularization 41
3.2 Ανασκόπηση Βιβλιογραφίας (Literature Review) 42
3.2.1 Πρώιμες Εργασίες — Στατιστικά Μοντέλα 42
3.2.2 Εφαρμογές Random Forest και Ensemble Methods 42
3.2.3 Gradient Boosting και XGBoost στη Ναυτιλία 43
3.2.4 Νευρωνικά Δίκτυα και Deep Learning 43
3.2.5 LSTM και Χρονοσειρές 44
3.2.6 Ανασκόπηση — Σύνοψη Ευρημάτων Βιβλιογραφίας 44
3.3 Αλγόριθμοι Παλινδρόμησης — Αναλυτική Θεωρία 45
3.3.1 Δέντρα Απόφασης (Decision Trees) 45
3.3.2 Random Forest — Εκτενής Θεωρία 46
3.3.3 XGBoost — Gradient Boosting με Regularization 46
3.3.4 Support Vector Regression — Θεωρία Πυρήνων 48
3.3.5 MLP Νευρωνικά Δίκτυα — Αρχιτεκτονική και Εκπαίδευση 48
3.4 Τεχνικές Feature Selection και Feature Engineering 49
3.4.1 Ανάλυση Κύριων Συνιστωσών (PCA) 49
3.4.2 Variance Inflation Factor (VIF) 50
3.4.3 SHAP Values — Explainable AI 50
3.5 Μετρικές Αξιολόγησης — Εκτεταμένη Ανάλυση 50
ΚΕΦΑΛΑΙΟ 4: Μεθοδολογία και Υλοποίηση 52
4.1 Επισκόπηση Μεθοδολογίας 52
4.1.1 Αιτιολόγηση Επιλογής Συνόλου Δεδομένων 52
4.1.1.1 Ο Κινητήρας Αεριοστρόβιλου του Προσομοιωτή 53
4.1.1.2 Δομή, Μεταβλητές και Μονάδες Μέτρησης 53
4.1.1.3 Ανάλυση Επιχειρησιακού Εύρους 54
4.1.2 Αιτιολόγηση Επιλογής Μοντέλων Μηχανικής Μάθησης 55
4.2 Εξερευνητική Ανάλυση Δεδομένων (EDA) 55
4.2.1 Περιγραφικά Στατιστικά 55
4.2.2 Ανάλυση Κατανομών και Ιστογράμματα 56
4.2.3 Ανάλυση Συσχετίσεων 57
4.2.4 Σχέση Ταχύτητας – Κατανάλωσης 58
4.3 Προεπεξεργασία Δεδομένων 59
4.3.1 Έλεγχος Ποιότητας Δεδομένων 59

4.3.2 Επιλογή Χαρακτηριστικών - Feature Selection 60
4.3.3 Κανονικοποίηση Δεδομένων 61
4.3.4 Διαχωρισμός Training / Validation / Test 61
4.4 Τεχνολογική Υποδομή και Pipeline 62
4.4.1 Τεχνολογικό Stack 62
4.4.2 Pipeline Υλοποίησης 62
4.5 Ανάπτυξη και Εκπαίδευση Μοντέλων 63
4.5.1 Επιλογή αλγορίθμων 63
4.5.2 Baseline Μοντέλα 63
4.5.3 Random Forest — Βελτιστοποίηση Hyperparameters 64
4.5.4 Gradient Boosting — Βελτιστοποίηση Hyperparameters 64
4.5.5 SVR — Βελτιστοποίηση Hyperparameters 65
4.5.6 MLP — Αρχιτεκτονική και Εκπαίδευση 65
ΚΕΦΑΛΑΙΟ 5: Αποτελέσματα και Συγκριτική Αξιολόγηση 66
5.1 Γραμμική και Πολυωνυμική Παλινδρόμηση 66
5.1.1 Γραμμική Παλινδρόμηση — Baseline 66
5.1.2 Πολυωνυμική Παλινδρόμηση — Βαθμός 3 67
5.2 Random Forest — Αναλυτικά Αποτελέσματα 68
5.2.1 Απόδοση στο Test Set 68
5.2.2 Feature Importance — Random Forest 69
5.3 Gradient Boosting — Αποτελέσματα και Σύγκριση με RF 69
5.4 SVR και MLP — Αποτελέσματα και Σχολιασμός 70
5.5 Στατιστική Σημαντικότητα — Wilcoxon Signed-Rank Test 71
ΚΕΦΑΛΑΙΟ 6: Επιχειρησιακές Εφαρμογές και Στρατηγική Υλοποίησης 72
6.1 Αρχιτεκτονική Επιχειρησιακού Συστήματος Πρόβλεψης 73
6.2 Βελτιστοποίηση Ταχύτητας (Speed Optimization) 74
6.3 Predictive Maintenance και Condition Monitoring 75
6.4 Ψηφιακό Δίδυμο (Digital Twin) 76
6.5 CII Management και EU ETS 77
6.6 Ανάλυση ROI 78
6.7 Εμπόδια Υλοποίησης 79
ΚΕΦΑΛΑΙΟ 7: Συμπεράσματα, Περιορισμοί και Μελλοντική Έρευνα 81
7.1 Σύνοψη Κύριων Ευρημάτων 81
7.1.1 Ευρήματα ανά Ερευνητικό Ερώτημα 81
7.1.2 Συγκριτική Αξιολόγηση Μοντέλων 82
7.2 Αναλυτική Συζήτηση Περιορισμών 82
7.2.1 Περιορισμοί Δεδομένων 82
7.2.2 Περιορισμοί Μοντελοποίησης 83
7.2.3 Περιορισμοί Αξιολόγησης 83
7.3 Συνεισφορά στη Βιβλιογραφία 84
7.4 Πολιτικές Συστάσεις 84

7.4.1 Συστάσεις προς Ναυτιλιακές Εταιρείες 84
7.4.2 Συστάσεις προς Ρυθμιστικές Αρχές 85
7.5 Μελλοντική Έρευνα 86
7.5.1 Βραχυπρόθεσμες Κατευθύνσεις (1-2 Χρόνια) 86
7.5.2 Μεσοπρόθεσμες Κατευθύνσεις (2-5 Χρόνια) 86
7.5.3 Μακροπρόθεσμες Κατευθύνσεις (5-10 Χρόνια) 86
7.6 Επίλογος 87
ΒΙΒΛΙΟΓΡΑΦΙΑ 88
ΠΑΡΑΡΤΗΜΑ — Οδηγίες Εκτέλεσης Κώδικα 94
Α. Αρχεία Παράδοσης 94
Β. Απαιτήσεις Συστήματος 94
Γ. Εκτέλεση 94
Δ. Αποτελέσματα Εκτέλεσης 94
Ε. Αναπαραγωγιμότητα Αποτελεσμάτων 95

Πίνακας Συντομογραφιών

Συντομογραφία	Επεξήγηση
ABB	ABB Group — εταιρεία αυτοματισμού (συλλογή δεδομένων naval propulsion)
AI	Artificial Intelligence (Τεχνητή Νοημοσύνη)
AIS	Automatic Identification System (Σύστημα Αυτόματης Αναγνώρισης Πλοίων)
ANFIS	Adaptive Neuro-Fuzzy Inference System (Προσαρμοστικό Νευρο-Ασαφές Σύστημα Συμπερασμού)
ANN	Artificial Neural Network (Τεχνητό Νευρωνικό Δίκτυο)
AR6	Sixth Assessment Report (Έκτη Έκθεση Αξιολόγησης, IPCC)
AWS	Amazon Web Services (πλατφόρμα υπολογιστικού νέφους)
BI	Business Intelligence (Επιχειρηματική Ευφυΐα)
CART	Classification and Regression Trees (Δέντρα Ταξινόμησης και Παλινδρόμησης)
CatBoost	Categorical Boosting (αλγόριθμος ενίσχυσης κλίσης)
CF	Carbon Factor (συντελεστής μετατροπής καυσίμου σε CO_2)
CFD	Computational Fluid Dynamics (Υπολογιστική Ρευστοδυναμική)
CII	Carbon Intensity Indicator (Δείκτης Έντασης Άνθρακα)
CNN	Convolutional Neural Network (Συνελικτικό Νευρωνικό Δίκτυο)
CO_2	Carbon Dioxide (Διοξείδιο του Άνθρακα)
CV	Cross-Validation (Διασταυρούμενη Επικύρωση)
DNV / GL	Det Norske Veritas / Germanischer Lloyd (Νηογνώμονας)
DT	Decision Tree (Δέντρο Απόφασης)
DWT	Deadweight Tonnage (Νεκρό Βάρος Πλοίου)
EC	European Commission (Ευρωπαϊκή Επιτροπή)
ECA	Emission Control Area (Περιοχή Ελέγχου Εκπομπών)
EDA	Exploratory Data Analysis (Διερευνητική Ανάλυση Δεδομένων)
EEDI	Energy Efficiency Design Index (Δείκτης Ενεργειακής Απόδοσης Σχεδίασης)
EEST	Energy Efficiency Saving Technologies (Τεχνολογίες Εξοικονόμησης Ενέργειας)
EEXI	Energy Efficiency Existing Ship Index (Δείκτης Ενεργειακής Απόδοσης Υφιστάμενων Πλοίων)
ELU	Exponential Linear Unit (συνάρτηση ενεργοποίησης)
EPL	Engine Power Limiter (Περιοριστής Ισχύος Κινητήρα)
ESG	Environmental, Social and Governance (Περιβαλλοντικά, Κοινωνικά και Διακυβέρνησης κριτήρια)
EU	European Union (Ευρωπαϊκή Ένωση)
EU ETS	European Union Emissions Trading System (Σύστημα Εμπορίας Δικαιωμάτων Εκπομπών της ΕΕ)

Συντομογραφία	Επεξήγηση
EUR	Euro (Ευρώ)
FC	Fuel Consumption / GT Fuel Flow (Κατανάλωση Καυσίμου — μεταβλητή-στόχος)
FEA	Finite Element Analysis (Ανάλυση Πεπερασμένων Στοιχείων)
FuelEU	FuelEU Maritime (Κανονισμός της ΕΕ για τα ναυτιλιακά καύσιμα)
GGn	Gas Generator rate of revolutions (Στροφές Γεννήτριας Αερίου)
GHG	Greenhouse Gas (Αέριο Θερμοκηπίου)
GL	Germanischer Lloyd (Νηογνώμονας — βλ. DNV)
GP	Gaussian Process (Γκαουσιανή Διαδικασία)
GPS	Global Positioning System (Παγκόσμιο Σύστημα Εντοπισμού Θέσης)
GPU	Graphics Processing Unit (Μονάδα Επεξεργασίας Γραφικών)
GRU	Gated Recurrent Unit (μονάδα επαναλαμβανόμενου νευρωνικού δικτύου)
GT	Gas Turbine (Αεριοστρόβιλος)· επίσης Gross Tonnage (Ολική Χωρητικότητα) στις κατηγορίες πλοίων
GTn	Gas Turbine rate of revolutions (Στροφές Αεριοστρόβιλου)
GTT	Gas Turbine shaft Torque (Ροπή Άξονα Αεριοστρόβιλου)
HFO	Heavy Fuel Oil (Βαρύ Μαζούτ)
HP	Horsepower (Ιπποδύναμη)
IACS	International Association of Classification Societies (Διεθνής Ένωση Νηογνωμόνων)
IMO	International Maritime Organization (Διεθνής Ναυτιλιακός Οργανισμός)
IoT	Internet of Things (Διαδίκτυο των Πραγμάτων)
IPCC	Intergovernmental Panel on Climate Change (Διακυβερνητική Επιτροπή για την Κλιματική Αλλαγή)
IQR	Interquartile Range (Ενδοτεταρτημοριακό Εύρος)
ISO	International Organization for Standardization (Διεθνής Οργανισμός Τυποποίησης)
ITTC	International Towing Tank Conference
JIT	Just-In-Time arrival (Άφιξη Ακριβώς στην Ώρα)
KPI	Key Performance Indicator (Βασικός Δείκτης Επίδοσης)
LASSO	Least Absolute Shrinkage and Selection Operator
LightGBM	Light Gradient Boosting Machine (αλγόριθμος ενίσχυσης κλίσης)
LNG	Liquefied Natural Gas (Υγροποιημένο Φυσικό Αέριο)
LSTM	Long Short-Term Memory (νευρωνικό δίκτυο μακράς-βραχείας μνήμης)
LTE	Long-Term Evolution (τεχνολογία κινητής τηλεφωνίας)
MAE	Mean Absolute Error (Μέσο Απόλυτο Σφάλμα)
MAN	MAN Energy Solutions (κατασκευαστής ναυτιλιακών κινητήρων)

Συντομογραφία	Επεξήγηση
MAPE	Mean Absolute Percentage Error (Μέσο Απόλυτο Ποσοστιαίο Σφάλμα)
MARPOL	International Convention for the Prevention of Pollution from Ships (Διεθνής Σύμβαση για την Πρόληψη της Ρύπανσης από Πλοία)
MASS	Maritime Autonomous Surface Ships (Αυτόνομα Επιφανειακά Πλοία)
MCR	Maximum Continuous Rating (Μέγιστη Συνεχής Ισχύς Κινητήρα)
ME	Main Engine (Κύρια Μηχανή)
MEPC	Marine Environment Protection Committee (Επιτροπή Προστασίας Θαλάσσιου Περιβάλλοντος του IMO)
MGO	Marine Gas Oil (Ναυτιλιακό Ντίζελ)
ML	Machine Learning (Μηχανική Μάθηση)
MLP	Multi-Layer Perceptron (Πολυεπίπεδο Perceptron)
MSC	Mediterranean Shipping Company (ναυτιλιακή εταιρεία)
MSE	Mean Squared Error (Μέσο Τετραγωνικό Σφάλμα)
MT	Metric Tons (Μετρικοί Τόνοι)
MTBF	Mean Time Between Failures (Μέσος Χρόνος Μεταξύ Βλαβών)
NMEA	National Marine Electronics Association (πρότυπο ναυτιλιακών δεδομένων)
NN	Neural Network (Νευρωνικό Δίκτυο)
NOx	Nitrogen Oxides (Οξείδια του Αζώτου)
NPV	Net Present Value (Καθαρή Παρούσα Αξία)
NWP	Numerical Weather Prediction (Αριθμητική Πρόγνωση Καιρού)
OPEX	Operational Expenditure (Λειτουργικά Έξοδα)
PCA	Principal Component Analysis (Ανάλυση Κύριων Συνιστωσών)
PdM	Predictive Maintenance (Προβλεπτική Συντήρηση)
PINNs	Physics-Informed Neural Networks (Νευρωνικά Δίκτυα Ενσωματωμένης Φυσικής)
PLC	Programmable Logic Controller (Προγραμματιζόμενος Λογικός Ελεγκτής)
RAM	Random Access Memory (Μνήμη Τυχαίας Προσπέλασης)
RBF	Radial Basis Function (Συνάρτηση Ακτινικής Βάσης)
ReLU	Rectified Linear Unit (συνάρτηση ενεργοποίησης)
RF	Random Forest (Τυχαίο Δάσος)
RMSE	Root Mean Squared Error (Ρίζα Μέσου Τετραγωνικού Σφάλματος)
RoRo	Roll-on/Roll-off (πλοίο οριζόντιας φόρτωσης)
ROI	Return on Investment (Απόδοση Επένδυσης)
RPM	Revolutions Per Minute (Στροφές ανά Λεπτό)

Συντομογραφία	Επεξήγηση
SCADA	Supervisory Control and Data Acquisition (Σύστημα Εποπτικού Ελέγχου και Συλλογής Δεδομένων)
SECA	Sulphur Emission Control Area (Περιοχή Ελέγχου Εκπομπών Θείου)
SEEMP	Ship Energy Efficiency Management Plan (Σχέδιο Διαχείρισης Ενεργειακής Αποδοτικότητας Πλοίου)
SFC	Specific Fuel Consumption (Ειδική Κατανάλωση Καυσίμου)
SFOC	Specific Fuel Oil Consumption (Ειδική Κατανάλωση Καυσίμου)
SGD	Stochastic Gradient Descent (Στοχαστική Κατάβαση Κλίσης)
SHAP	SHapley Additive exPlanations (μέθοδος επεξηγησιμότητας μοντέλων)
SLA	Service Level Agreement (Συμφωνία Επιπέδου Υπηρεσιών)
SOG	Speed Over Ground (Ταχύτητα ως προς το Έδαφος)
SOx	Sulphur Oxides (Οξείδια του Θείου)
STW	Speed Through Water (Ταχύτητα ως προς το Νερό)
SVD	Singular Value Decomposition (Ανάλυση Ιδιαζουσών Τιμών)
SVM	Support Vector Machine (Μηχανή Διανυσμάτων Υποστήριξης)
SVR	Support Vector Regression (Παλινδρόμηση Διανυσμάτων Υποστήριξης)
TCE	Time Charter Equivalent (Ισοδύναμο Χρονοναύλωσης)
TEU	Twenty-foot Equivalent Unit (Ισοδύναμη Μονάδα Είκοσι Ποδών)
TIC	Turbine Injection Control (Έλεγχος Έγχυσης Καυσίμου)
UCI	University of California, Irvine — Machine Learning Repository (πηγή δεδομένων)
ULCV	Ultra Large Container Vessel (Υπερμέγεθες Πλοίο Εμπορευματοκιβωτίων)
UNCTAD	United Nations Conference on Trade and Development (Διάσκεψη του ΟΗΕ για το Εμπόριο και την Ανάπτυξη)
UI	User Interface (Διεπαφή Χρήστη)
USD	United States Dollar (Δολάριο ΗΠΑ)
VIF	Variance Inflation Factor (Συντελεστής Διόγκωσης Διακύμανσης)
VLCC	Very Large Crude Carrier (Πολύ Μεγάλο Δεξαμενόπλοιο Αργού Πετρελαίου)
VLSFO	Very Low Sulphur Fuel Oil (Καύσιμο Πολύ Χαμηλής Περιεκτικότητας σε Θείο)
VSAT	Very Small Aperture Terminal (δορυφορικός σταθμός μικρής κεραίας)
XGBoost	eXtreme Gradient Boosting (αλγόριθμος ακραίας ενίσχυσης κλίσης)

Λίστα Εικόνων

Σχήμα 4.1: Κατανομές συχνότητας για τις 14 μεταβλητές (13 features + στόχος)του dataset. Η GT Fuel Flow (κάτω αριστερά) παρουσιάζει σαφή θετική ασυμμετρία.

Σχήμα 4.2: Χάρτης θερμότητας συσχετίσεων Pearson. Η GT Fuel Flow εμφανίζει ισχυρή θετική συσχέτιση με όλες τις παραμέτρους του κινητήρα (r≈0,93–1,00), με ισχυρότερη εκείνη του GT Shaft Torque.

Σχήμα 4.3: Scatter plot Ship Speed vs GT Fuel Flow με πολυωνυμική προσαρμογή (βαθμός 3, R^2=0.992), που τεκμηριώνει τη θεωρητική κυβική σχέση.

Σχήμα 4.4: Scatter matrix για τις μεταβλητές Ship Speed, GTn RPM, GT Shaft Torque, T_HPT, Lever Position και GT Fuel Flow.

Σχήμα 4.5: Ιστογράμματα των τριών συνόλων (train/validation/test) που επιβεβαιώνουν την αντιπροσωπευτικότητα του stratified split.

Σχήμα 5.1: Ανάλυση καταλοίπων (residual plots) για όλα τα μοντέλα.

Σχήμα 5.2: Predicted vs Actual — Πολυωνυμική Παλινδρόμηση (d=3). Άριστη ευθυγράμμιση με y=x.

Σχήμα 5.3: Predicted vs Actual — Random Forest.

Σχήμα 5.4: Feature Importance — Random Forest vs Gradient Boosting.

Σχήμα 5.5: Predicted vs Actual — SVR και MLP.

Σχήμα 5.6: Σύγκριση Μοντέλων

Λίστα Πινάκων

Πίνακας 1.1: Δομή εργασίας και κύριο περιεχόμενο ανά κεφάλαιο

Πίνακας 2.1: Κατηγορίες εμπορικών πλοίων και χαρακτηριστικά κατανάλωσης

Πίνακας 2.2: Κύριοι τύποι ναυτιλιακών κινητήρων

Πίνακας 2.3: SFOC έναντι φόρτισης κινητήρα (τυπικός 2-stroke diesel)

Πίνακας 2.4: Αναλυτική σύγκριση παραδοσιακών μεθόδων πρόβλεψης

Πίνακας 2.5: Ιστορική εξέλιξη ναυτιλιακών κανονισμών GHG

Πίνακας 2.6: Ετήσια βαθμολόγηση CII και υποχρεώσεις

Πίνακας 3.1: Ανασκόπηση βιβλιογραφίας ML για πρόβλεψη κατανάλωσης καυσίμου πλοίων

Πίνακας 3.2: Σύγκριση Bagging (Random Forest) vs Boosting (XGBoost)

Πίνακας 3.3: Συναρτήσεις ενεργοποίησης και χαρακτηριστικά

Πίνακας 3.4: Μετρικές αξιολόγησης — ορισμοί, ιδιότητες και χρήση

Πίνακας 4.1: Πλήρης περιγραφή στηλών του αρχείου data.txt (UCI Naval Propulsion Dataset)

Πίνακας 4.2: Περιγραφικά στατιστικά όλων των μεταβλητών (n=11.934)

Πίνακας 4.3: Αποτελέσματα ελέγχου ποιότητας δεδομένων

Πίνακας 4.4: VIF Analysis — αποτελέσματα ανά feature

Πίνακας 4.5: Κατανομή συνόλων εκπαίδευσης/επικύρωσης/ελέγχου

Πίνακας 4.6: Τεχνολογικό stack της υλοποίησης

Πίνακας 4.7: Grid Search — Random Forest hyperparameters

Πίνακας 4.8: Grid Search — Gradient Boosting hyperparameters

Πίνακας 4.9: Σύγκριση MLP αρχιτεκτονικών στο validation set

Πίνακας 5.1: Αποτελέσματα test set (data.txt, n=1.791, SEED=42), ταξινομημένα κατά RMSE

Πίνακας 6.1: Στρώματα αρχιτεκτονικής επιχειρησιακού ML συστήματος

Πίνακας 6.2: Παράδειγμα βελτιστοποίησης ταχύτητας — Container ship Αμβούργο-Πειραιάς (3.200 nm)

Πίνακας 6.3: Σύγκριση στρατηγικών συντήρησης — κόστος και αποτελεσματικότητα

Πίνακας 6.4: Υπαρκτές υλοποιήσεις Digital Twin στη ναυτιλία

Πίνακας 6.5: Εκτίμηση κόστους EU ETS 2024-2026 για τυπικό container ship

Πίνακας 6.6: Ανάλυση ROI — ML σύστημα για fleet 10 πλοίων (NPV 5 ετών, r=10%)

Πίνακας 6.7: Ανάλυση Ευαισθησίας της Επένδυσης ως προς Εξοικονόμηση Καυσίμου, Τιμή VLSFO και Αρχικό Κόστος

Πίνακας 6.8: Εμπόδια υλοποίησης ML στη ναυτιλία και στρατηγικές αντιμετώπισης

Πίνακας 7.1: Τελική συγκριτική αξιολόγηση — ανακεφαλαίωση αποτελεσμάτων

Πίνακας 7.2: Πολιτικές συστάσεις προς ναυτιλιακές εταιρείες — προτεραιότητα και εφαρμοσιμότητα

ΚΕΦΑΛΑΙΟ 1: Εισαγωγή

1.1 Πλαίσιο και Κίνητρο της Εργασίας

1.1.1 Η Κλιματική Κρίση και η Ναυτιλία

Η κλιματική αλλαγή αποτελεί σημείο αναφοράς κάθε σύγχρονης τεχνολογικής προσπάθειας μείωσης εκπομπών αερίων του θερμοκηπίου. Σύμφωνα με την Έκθεση Σύνθεσης της Έκτης Έκθεσης Αξιολόγησης (Sixth Assessment Report, AR6) της Διακυβερνητικής Επιτροπής για την Κλιματική Αλλαγή (Intergovernmental Panel on Climate Change, IPCC) (2023), οι ανθρωπογενείς εκπομπές CO_2 πρέπει να μειωθούν κατά 43% έως το 2030 (βάση 2019) για να περιοριστεί η θέρμανση στους 1,5°C (IPCC, 2023). Η διεθνής ναυτιλία ευθύνεται για ~2,89% των παγκόσμιων ανθρωπογενών εκπομπών CO_2 — περίπου 1.056 εκατομμύρια τόνους CO_2 ισοδύναμο ετησίως (IMO, 2023b). Παρόλο που το ποσοστό αυτό φαίνεται χαμηλό, αντιστοιχεί στο ισοδύναμο του συνδυασμένου αποτυπώματος χωρών όπως η Γερμανία και η Βρετανία.

Η Αναθεωρημένη Στρατηγική του Διεθνούς Ναυτιλιακού Οργανισμού (International Maritime Organization, IMO) για τα αέρια του θερμοκηπίου (Greenhouse Gas, GHG) (IMO, 2023) θέτει φιλόδοξους στόχους: μείωση της έντασης άνθρακα κατά τουλάχιστον 40% έως 2030 (συγκριτικά με 2008), μείωση συνολικών εκπομπών κατά τουλάχιστον 70% έως 2040 (συγκριτικά με 2008), και net-zero περίπου το 2050. Για την επίτευξη αυτών των στόχων, η βελτίωση ενεργειακής αποδοτικότητας μέσω ψηφιακών τεχνολογιών — συμπεριλαμβανομένης της Μηχανικής Μάθησης — αποτελεί ένα από τα λίγα μέσα άμεσης εφαρμογής χωρίς αλλαγή καυσίμου ή νέα ναυπήγηση (Chuah et al., 2025).

1.1.2 Ο Ρόλος της Κατανάλωσης Καυσίμου

Η κατανάλωση καυσίμου αποτελεί συνάμα το μεγαλύτερο κόστος λειτουργίας (30-60% του OPEX) και την κύρια πηγή εκπομπών ενός εμπορικού πλοίου. Μια μείωση 10% στην κατανάλωση ενός container ship μεταφράζεται σε εξοικονόμηση €500.000–€1.000.000 ετησίως (βάσει τιμής ναυτιλιακού καυσίμου πολύ χαμηλού θείου, Very Low Sulphur Fuel Oil, VLSFO, 2024) και μείωση ~3.200 τόνων CO_2. Η εξοικονόμηση αυτή είναι εφικτή μέσω βελτιστοποίησης ταχύτητας, trim, και route — διαδικασίες που εκτελούνταν παραδοσιακά εμπειρικά αλλά πλέον μπορούν να αυτοματοποιηθούν μέσω Machine Learning (ML).

Επιπλέον, η εισαγωγή του Συστήματος Εμπορίας Δικαιωμάτων Εκπομπών της ΕΕ (European Union Emissions Trading System, EU ETS) (2024) και FuelEU Maritime (2025) δημιουργεί άμεσο οικονομικό κόστος για κάθε τόνο CO_2 που δεν αποφεύγεται. Από το 2024, η ναυτιλία εντάχθηκε στο EU ETS, υποχρεώνοντας πλοία άνω των 5.000 κόρων ολικής χωρητικότητας (Gross Tonnage, GT) να αγοράζουν δικαιώματα εκπομπών για τα ταξίδια τους εντός και προς/από ευρωπαϊκά λιμάνια (European Parliament & Council of the EU, 2023a). Παράλληλα, ο Κανονισμός FuelEU Maritime, σε ισχύ από την 1η Ιανουαρίου 2025, θέτει δεσμευτικούς στόχους μείωσης της έντασης αερίων θερμοκηπίου στα καύσιμα των πλοίων, με σταδιακές μειώσεις που φτάνουν έως και −80% έως το 2050 σε σχέση με τα επίπεδα του 2020 (European Parliament & Council of the EU, 2023b). Η ακριβής μέτρηση και πρόβλεψη κατανάλωσης μέσω ML δεν είναι πλέον επιλογή — είναι στρατηγική ανάγκη για κάθε ναυτιλιακή εταιρεία που επιθυμεί να παραμείνει ανταγωνιστική.

1.2 Σκοπός, Ερευνητικά Ερωτήματα και Στόχοι

1.2.1 Σκοπός της Εργασίας

Η παρούσα διπλωματική εργασία έχει ως κεντρικό σκοπό τη συστηματική σύγκριση αλγορίθμων Μηχανικής Μάθησης για την πρόβλεψη κατανάλωσης καυσίμου ναυτικού κινητήρα, με έμφαση στην εξαγωγή πρακτικά αξιοποιήσιμων συμπερασμάτων για τη ναυτιλιακή βιομηχανία. Ειδικότερα, η εργασία εξετάζει πώς διαφορετικοί αλγόριθμοι (γραμμικά μοντέλα, ensemble methods, νευρωνικά δίκτυα) αντιμετωπίζουν τη μη γραμμική, πολυπαραμετρική φύση του προβλήματος.

1.2.2 Ερευνητικά Ερωτήματα

- Ποιος αλγόριθμος ML επιτυγχάνει τη βέλτιστη ισορροπία ακρίβειας, γενίκευσης και ερμηνευσιμότητας για την πρόβλεψη κατανάλωσης ναυτικού κινητήρα;
- Ποια χαρακτηριστικά (features) έχουν τη μεγαλύτερη επίδραση στην κατανάλωση καυσίμου, και πώς αυτή η γνώση συμβαδίζει με τη θερμοδυναμική θεωρία;
- Σε ποιο βαθμό η ακρίβεια ML μοντέλων δικαιολογεί το αντίστοιχο υπολογιστικό κόστος και κόστος υλοποίησης, σε σύγκριση με απλούστερες μεθόδους;
- Ποιες είναι οι βασικές προϋποθέσεις και προκλήσεις για την πρακτική εφαρμογή ML μοντέλων σε επιχειρησιακό ναυτιλιακό περιβάλλον;

1.3 Δομή της Εργασίας

Η εργασία οργανώνεται σε επτά κεφάλαια με τη λογική της σταδιακής εμβάθυνσης: από το γενικό θεωρητικό πλαίσιο (Κεφ. 2-3), μέσω της μεθοδολογικής υλοποίησης (Κεφ. 4), στα αποτελέσματα (Κεφ. 5) και τις επιχειρησιακές εφαρμογές (Κεφ. 6-7).

Πίνακας 1.1: Δομή εργασίας και κύριο περιεχόμενο ανά κεφάλαιο

Κεφ.	Τίτλος	Κύριο Περιεχόμενο
1	Εισαγωγή	Κλιματικό πλαίσιο, κίνητρο, ερευνητικά ερωτήματα, δομή εργασίας
2	Καύσιμα & Ναυτιλία	Κατηγορίες πλοίων, κινητήρες, καύσιμα, παράγοντες κατανάλωσης, κανονισμοί EEDI/CII/EU ETS
3	Μηχανική Μάθηση	Θεωρία ML, bias-variance, RF/XGBoost/SVR/MLP, literature review, μετρικές
4	Μεθοδολογία	Dataset, EDA, preprocessing, feature selection, pipeline, hyperparameter tuning
5	Αποτελέσματα	Σύγκριση μοντέλων, learning curves, residual analysis, feature importance
6	Επιχειρησιακά	Speed optimization, digital twin, ROI analysis, case studies, κανονιστική συμμόρφωση
7	Συμπεράσματα	Σύνθεση ευρημάτων, περιορισμοί, μελλοντικές κατευθύνσεις, πολιτικές συστάσεις

ΚΕΦΑΛΑΙΟ 2: Η Κατανάλωση Καυσίμου στη Ναυτιλία

2.1 Εισαγωγή στη Ναυτιλία

2.1.1 Ιστορική Εξέλιξη και Παγκόσμια Σημασία

Η θαλάσσια μεταφορά αποτελεί τον αρχαιότερο τρόπο οργανωμένης εμπορικής μεταφοράς, με ρίζες που εκτείνονται χιλιετίες πίσω στην ανθρώπινη ιστορία. Από τις φοινικικές τριήρεις και τα βενετσιάνικα εμπορικά πλοία, η ναυτιλία εξελίχθηκε σταδιακά σε μια από τις πλέον παγκοσμιοποιημένες βιομηχανίες του κόσμου. Η βιομηχανική επανάσταση του 19ου αιώνα σηματοδότησε τη μετάβαση από τα ιστιοφόρα στα ατμόπλοια, εισάγοντας για πρώτη φορά το ζήτημα της κατανάλωσης ορυκτού καυσίμου ως κεντρική επιχειρησιακή παράμετρο (Stopford, 2009).

Σήμερα, η ναυτιλιακή βιομηχανία αποτελεί τον κυριότερο κινητήριο μηχανισμό του διεθνούς εμπορίου. Σύμφωνα με την UNCTAD (2023), άνω του 80% του παγκόσμιου εμπορικού όγκου και περίπου το 70% της αξίας του διακινείται μέσω θαλάσσης. Ο παγκόσμιος εμπορικός στόλος περιλαμβάνει πλέον πάνω από 105.500 πλοία συνολικής χωρητικότητας άνω των 2,2 δισεκατομμυρίων DWT (Deadweight Tonnes), ενώ ο κλάδος απασχολεί άμεσα περίπου 1,9 εκατομμύρια ναυτικούς παγκοσμίως (UNCTAD, 2023). Η οικονομική συνεισφορά της ναυτιλίας εκτιμάται σε πάνω από 500 δισεκατομμύρια USD ετησίως σε άμεση οικονομική αξία, χωρίς να συνυπολογίζονται οι πολλαπλασιαστικές επιδράσεις στις συνδεδεμένες βιομηχανίες (ναυπηγική, ασφάλιση, logistics, λιμάνια).

2.1.2 Κατηγορίες Ναυτιλιακών Πλοίων

Ο εμπορικός στόλος χαρακτηρίζεται από σημαντική ποικιλομορφία ως προς τον τύπο, το μέγεθος και το είδος του μεταφερόμενου φορτίου. Η κατανόηση αυτής της ποικιλομορφίας είναι κρίσιμη, καθώς κάθε κατηγορία πλοίων παρουσιάζει διαφορετικά πρότυπα κατανάλωσης καυσίμου. Ο Πίνακας 2.1 συνοψίζει τις κυριότερες κατηγορίες εμπορικών πλοίων μαζί με τα τυπικά χαρακτηριστικά μεγέθους, ταχύτητας και κατανάλωσής τους:

Πίνακας 2.1: Κατηγορίες εμπορικών πλοίων και χαρακτηριστικά κατανάλωσης

Πηγές: UNCTAD (2023), Stopford (2009), DNV GL (2020)

Τύπος Πλοίου	Μέγεθος (DWT)	Κατ/ση (t/day)	Ταχύτητα (kn)	Κύρια Αγορά
Bulk Carrier	10k–400k	15–55	12–15	Σιτηρά, άνθρακας, σίδηρος
Container Ship	10k–240k	80–300	18–24	Εμπορευματοκιβώτια (TEU)
Crude Oil Tanker	80k–550k	40–90	13–16	Αργό πετρέλαιο
Product Tanker	5k–80k	20–45	13–17	Διυλισμένα προϊόντα

Τύπος Πλοίου	Μέγεθος (DWT)	Κατ/ση (t/day)	Ταχύτητα (kn)	Κύρια Αγορά
LNG (Liquefied Natural Gas) Carrier	60k–270k	100–170	18–20	Υγροποιημένο φυσικό αέριο
RoRo (Roll-on/Roll-off) / Ferry	5k–60k	30–120	16–25	Οχήματα, επιβάτες
Cruise Ship	20k–100k GT	150–400	18–24	Τουρισμός

Ιδιαίτερη σημασία έχει η κατηγορία των containerships, οι οποίες παρουσιάζουν υψηλότατη κατανάλωση ανά πλοίο (έως 300 τόνους/ημέρα για τα μεγαλύτερα Ultra Large Container Vessels – ULCV), αλλά εξαιρετικά αποδοτική κατανάλωση ανά μονάδα φορτίου λόγω της τεράστιας χωρητικότητάς τους. Αντίθετα, τα bulk carriers, αν και μεταφέρουν τη μεγαλύτερη ποσότητα φορτίου παγκοσμίως σε τόνους, λειτουργούν σε χαμηλότερες ταχύτητες με αναλογικά μέτρια κατανάλωση (Stopford, 2009).

2.1.3 Ο Κύκλος Ζωής ενός Ναυτιλιακού Πλοίου

Η κατανόηση του κύκλου ζωής ενός πλοίου είναι απαραίτητη για τη σωστή ερμηνεία των δεδομένων κατανάλωσης. Ένα τυπικό εμπορικό πλοίο έχει λειτουργική ζωή 20–30 ετών (Dinu & Ilie, 2015). Κατά τη διάρκεια αυτής, η κατανάλωση καυσίμου αποτιμάται συνήθως μέσω του Specific Fuel Oil Consumption (SFOC) — στα ελληνικά «Ειδική Κατανάλωση Καυσίμου Πετρελαίου», ακρωνύμιο από τις λέξεις *Specific* (ειδική, ανά μονάδα), *Fuel Oil* (καύσιμο πετρέλαιο) και *Consumption* (κατανάλωση) — ο οποίος εκφράζει την ποσότητα καυσίμου που καταναλώνεται ανά μονάδα παραγόμενης ισχύος και ανά μονάδα χρόνου (g/kWh) (Psaraftis & Kontovas, 2013). Οι σύγχρονοι δίχρονοι diesel κινητήρες αργής στροφής επιτυγχάνουν τιμές SFOC της τάξης των 155–175 g/kWh υπό συνθήκες βέλτιστης φόρτισης (Wärtsilä, 2023). Ο δείκτης αυτός αυξάνεται σταδιακά κατά τη διάρκεια της ζωής του πλοίου λόγω: (α) γήρανσης κινητήρα και μείωσης της απόδοσής του, (β) συσσώρευσης βιολογικής ρύπανσης (biofouling) στη γάστρα και τον έλικα (Pavin, 2022), (γ) φθοράς στρόβιλου (turbocharger degradation) (Cui et al., 2018), και (δ) αποκλίσεων από τις αρχικές σχεδιαστικές παραμέτρους λόγω επισκευών και τροποποιήσεων. Τυπικά, ένα πλοίο 10 ετών καταναλώνει 8–15% περισσότερο καύσιμο σε σχέση με ένα νέο πλοίο υπό τις ίδιες συνθήκες (Faber et al., 2020). Αυτή η εξέλιξη αποτελεί πρόκληση για τα παραδοσιακά στατικά μοντέλα SFOC, τα οποία βασίζονται σε σταθερές παραμέτρους εργοστασίου, αλλά ευκαιρία για τα ML μοντέλα, τα οποία μπορούν να επανεκπαιδεύονται συνεχώς ενσωματώνοντας την εξέλιξη αυτή (Wärtsilä, 2023).

2.2 Τεχνολογία Πρόωσης και Καύσιμα

2.2.1 Τύποι Κινητήρων

Η συντριπτική πλειοψηφία των σύγχρονων εμπορικών πλοίων χρησιμοποιεί δίχρονους ή τετράχρονους diesel κινητήρες αργής ή μέσης στροφής (slow/medium speed). Οι κύριες κατηγορίες κινητήρων και τα χαρακτηριστικά τους παρουσιάζονται στον Πίνακα 2.2:

Πίνακας 2.2: Κύριοι τύποι ναυτιλιακών κινητήρων

Πηγές: MAN Energy Solutions (2022), Wärtsilä (2021)

Τύπος	Στροφές (rpm)	Ισχύς (kW)	SFOC (g/kWh)	Εφαρμογή
2-stroke slow speed	80–200	5.000–80.000	155–175	Μεγάλα φορτηγά πλοία
4-stroke medium speed	300–1.000	1.000–20.000	175–195	Ferry, offshore, γεννήτριες
Gas Turbine	3.000–30.000	5.000–50.000	250–300	Γρήγορα πλοία, πολεμικά
Dual-Fuel (LNG / HFO, Heavy Fuel Oil)	80–200	5.000–60.000	145–165	Νέα πλοία, LNG carriers
Electric / Hybrid	—	500–15.000	Εξαρτάται	Short-sea, ferry

Ο πλέον διαδεδομένος τύπος για μεγάλα φορτηγά πλοία είναι ο δίχρονος κινητήρας αργής στροφής (2-stroke slow speed diesel), ο οποίος συνδέεται απευθείας με τον έλικα χωρίς μειωτήρα στροφών. Η υψηλή θερμική απόδοσή του (έως 55%) τον καθιστά τον αποδοτικότερο κινητήρα εσωτερικής καύσης που έχει κατασκευαστεί ποτέ (MAN Energy Solutions, 2022). Ωστόσο, η βέλτιστη απόδοση επιτυγχάνεται σε ένα στενό εύρος φορτίσεων (75–85% της Μέγιστης Συνεχούς Ισχύος – MCR), δημιουργώντας πρόκληση βελτιστοποίησης όταν το πλοίο λειτουργεί εκτός αυτού του εύρους.

2.2.2 Τύποι Καυσίμων

Η επιλογή καυσίμου επηρεάζει άμεσα τόσο το κόστος λειτουργίας όσο και τις περιβαλλοντικές επιδόσεις. Η αγορά ναυτιλιακών καυσίμων διέρχεται περίοδο έντονης μετάβασης, ιδιαίτερα μετά την εισαγωγή του IMO 2020 κανονισμού για θείο:

- Heavy Fuel Oil (HFO / Bunker C): Παραδοσιακό καύσιμο χαμηλού κόστους (αποκατάλοιπο διύλισης), υψηλής περιεκτικότητας σε θείο (έως 3,5%). Χρησιμοποιείται με scrubbers σε περιοχές εκτός των Περιοχών Ελέγχου Εκπομπών Θείου (Sulphur Emission Control Area, SECA).
- Very Low Sulphur Fuel Oil (VLSFO): Το κυρίαρχο καύσιμο μετά τον IMO 2020 κανονισμό (θείο < 0,5%). Υψηλότερο κόστος από HFO αλλά χαμηλότερο από MGO.

- Marine Gas Oil (MGO): Καθαρό αποσταγμένο καύσιμο (θείο < 0,1%), υποχρεωτικό σε Emission Control Areas (ECA). Σημαντικά υψηλότερη τιμή.
- Liquefied Natural Gas (LNG): Ταχέως αναπτυσσόμενο εναλλακτικό καύσιμο. Μειώνει CO_2 κατά 20–25%, NOx κατά 85–90%, SOx σχεδόν μηδενικά. Απαιτεί κρυογονική υποδομή (-163°C).
- Methanol / Ammonia / Hydrogen: Αναδυόμενα καύσιμα μηδενικών ή χαμηλών εκπομπών που ερευνώνται εντατικά για τη μακροπρόθεσμη αποανθρακοποίηση (IMO, 2023).

Η τιμή του καυσίμου αποτελεί τον πλέον μεταβλητό παράγοντα λειτουργικού κόστους. Μεταξύ 2020–2024, η τιμή του VLSFO κυμάνθηκε μεταξύ 350–900 USD/τόνο, δημιουργώντας ισχυρή ανάγκη για αποδοτική διαχείριση κατανάλωσης. Για ένα τυπικό Panamax bulk carrier που καταναλώνει 25 τόνους/ημέρα, μια διακύμανση 100 USD/τόνο στη τιμή καυσίμου μεταφράζεται σε 2.500 USD επιπλέον κόστος ημερησίως — ή ~750.000 USD ετησίως (Platts, 2023).

2.2.3 Slow Steaming — Η Στρατηγική Μείωσης Κατανάλωσης

Το slow steaming, δηλαδή η σκόπιμη μείωση της ταχύτητας πλεύσης κάτω από τη σχεδιαστική, αποτελεί την πλέον αποτελεσματική επιχειρησιακή παρέμβαση για μείωση κατανάλωσης καυσίμου. Υιοθετήθηκε ευρέως κατά την κρίση 2008–2009 και παραμένει διαδεδομένη (Notteboom & Cariou, 2013).

Η ποσοτική επίδραση προκύπτει από τη σχέση ισχύος-ταχύτητας. Εάν V_0 είναι η σχεδιαστική ταχύτητα και V η ταχύτητα λειτουργίας, η εξοικονόμηση καυσίμου $E\%$ υπολογίζεται ως:

$$E\% = [1 - (V/V_0)^3] \times 100\%$$

Έτσι, μείωση ταχύτητας από 15 σε 12 κόμβους (-20%) αποδίδει θεωρητικά μείωση ισχύος (και κατανάλωσης) κατά $1 - (12/15)^3 = 1 - 0{,}512 = 48{,}8\%$. Στην πράξη, λόγω του επιπλέον χρόνου ταξιδιού, η αποδοτικότητα ανά τόνο-μίλι βελτιώνεται κατά ~36% — εξαιρετικά σημαντικό αποτέλεσμα (Corbett et al., 2009).

Ωστόσο, το slow steaming δεν είναι πάντα βέλτιστο. Η ανάλυση κόστους-οφέλους εξαρτάται από: (α) τη σχέση τιμής καυσίμου / ημερήσιου ναύλου (Time Charter Equivalent – TCE), (β) τις απαιτήσεις χρονοδιαγράμματος πελατών, και (γ) τις τρέχουσες καιρικές συνθήκες. Η ML-based πρόβλεψη κατανάλωσης επιτρέπει τον δυναμικό υπολογισμό της βέλτιστης ταχύτητας σε πραγματικό χρόνο, ενσωματώνοντας όλες αυτές τις παραμέτρους (Wang et al., 2020).

2.3 Παράγοντες που Επηρεάζουν την Κατανάλωση Καυσίμου

2.3.1 Υδροδυναμικοί Παράγοντες

Η αντίσταση που συναντά ένα πλοίο κατά την πλεύση καθορίζει σε μεγάλο βαθμό την κατανάλωση καυσίμου. Η ολική αντίσταση R_T αναλύεται στις ακόλουθες συνιστώσες (ITTC, 2017):

$$R_T = R_F + R_W + R_A + R_{APP} + R_B + R_{TR}$$

όπου R_F η τριβή επιφάνειας (frictional resistance), R_W η κυματική αντίσταση (wave-making resistance), R_A η αεροδυναμική αντίσταση, R_{APP} η αντίσταση εξαρτημάτων (έλικας, πτερύγια), R_B η αντίσταση

διόγκωσης πλώρης (bulbous bow) και R_TR η αντίσταση πρύμνης. Η τριβή επιφάνειας αντιπροσωπεύει συνήθως το 70–80% της ολικής αντίστασης σε ταχύτητες λειτουργίας (Munk, 2018).

Βιολογική Ρύπανση Γάστρας (Hull Fouling)

Η βιολογική ρύπανση (biofouling) είναι η συσσώρευση θαλάσσιων οργανισμών (φύκη, μύδια, barnacles) στην υποβρύχια γάστρα και τον έλικα. Αυξάνει σημαντικά την τραχύτητα επιφάνειας και κατ' επέκταση την τριβή. Σύμφωνα με τον IMO (2011), μια σχετική αύξηση της τραχύτητας κατά ΔR αντιστοιχεί σε αύξηση κατανάλωσης:

$$\Delta FC\% \approx 0{,}064 \times \Delta R_a \ \ (\mu m)$$

Δηλαδή, για κάθε αύξηση της τραχύτητας της γάστρας κατά 1 μm, η κατανάλωση καυσίμου αυξάνεται περίπου κατά 0,064%.

Στην πράξη, ένα πλοίο χωρίς καθαρισμό για 12–18 μήνες μπορεί να παρουσιάσει αύξηση κατανάλωσης 10–20% (Schultz et al., 2011). Η ML μπορεί να ανιχνεύσει έγκαιρα αυτή την υποβάθμιση μέσω ανάλυσης τάσης στα δεδομένα κατανάλωσης, επιτρέποντας βελτιστοποίηση της χρονικής στιγμής καθαρισμού — ένα κλασικό παράδειγμα predictive maintenance.

Trim Βελτιστοποίηση

Το trim ορίζεται ως η διαφορά βυθίσματος πρύμνης μείον βυθίσματος πλώρης (T_aft − T_fwd). Ένα ακατάλληλο trim αυξάνει τη συνολική αντίσταση και την κατανάλωση. Έρευνες (Tarelko, 2012· Sherbaz & Duan, 2014) δείχνουν ότι η βελτιστοποίηση trim μπορεί να μειώσει την κατανάλωση κατά 1–3% χωρίς επιπλέον κόστος — απλώς μέσω κατανομής του ballast. Η ML μπορεί να βελτιστοποιεί δυναμικά το trim βάσει φορτίου, ταχύτητας και καιρικών συνθηκών.

2.3.2 Περιβαλλοντικοί Παράγοντες

Οι καιρικές και ωκεανογραφικές συνθήκες ασκούν σημαντική επίδραση στην πρόσθετη αντίσταση (Added Resistance) που συναντά το πλοίο. Η συνολική πρόσθετη αντίσταση λόγω καιρού εκφράζεται ως (Faltinsen, 1990):

$$R_Add = R_Waves + R_Wind + R_Current$$

Αντίσταση κυματισμού (R_Waves): Η πιο κρίσιμη συνιστώσα. Εξαρτάται από το σημαντικό ύψος κύματος Hs, την περίοδο κύματος Tp και τη σχετική διεύθυνση πλεύσης. Αντίθετα κύματα (head seas) προκαλούν 2–10× μεγαλύτερη αντίσταση από ευνοϊκά κύματα (following seas). Σε κακοκαιρία με Hs > 4m, η αύξηση κατανάλωσης μπορεί να ξεπεράσει 30–50% (Liu et al., 2011).

Αντίσταση ανέμου (R_Wind): Εξαρτάται από την ταχύτητα ανέμου (Beaufort scale), τη διεύθυνση και τη μετωπική επιφάνεια υπεράνω ισάλου. Ισχυρός εναντίος άνεμος (Beaufort 7–8) μπορεί να αυξήσει την κατανάλωση έως 15–25%.

Θαλάσσια Ρεύματα (R_Current): Τα ωκεάνια ρεύματα (Gulf Stream, Kuroshio, κ.ά.) επηρεάζουν σημαντικά τη σχέση SOG (ταχύτητα έναντι εδάφους) και STW (ταχύτητα έναντι νερού). Ένα ρεύμα 2–3 κόμβων μπορεί να μειώσει ή να αυξήσει την κατανάλωση έως 20% ανά ημέρα πλεύσης.

2.3.3 Μηχανολογικοί Παράγοντες

Η απόδοση του συστήματος πρόωσης επηρεάζεται από πλήθος μηχανολογικών παραμέτρων που αλληλεπιδρούν με σύνθετο τρόπο. Η συνολική απόδοση μετατροπής ενέργειας (Overall Propulsion Efficiency, nD) ορίζεται ως:

$$\eta_D = \eta_{engine} \times \eta_{shaft} \times \eta_{propeller} = P_{thrust} / P_{fuel}$$

Τυπικές τιμές: $\eta_{engine} \approx 0{,}50–0{,}55$ (κινητήρας), $\eta_{shaft} \approx 0{,}97–0{,}99$ (άξονας), $\eta_{propeller} \approx 0{,}60–0{,}70$ (έλικας). Η συνολική απόδοση $\eta_D \approx 0{,}28–0{,}38$, που σημαίνει ότι μόνο το 28–38% της ενέργειας του καυσίμου μετατρέπεται σε ωφέλιμη κίνηση — οι υπόλοιπες απώλειες αποτελούν την κινητήριο δύναμη για βελτιστοποίηση.

Η φόρτιση κινητήρα (%MCR) αποτελεί κρίσιμη παράμετρο. Ο Πίνακας 2.3 παρουσιάζει τυπικές τιμές SFOC σε διαφορετικές φορτίσεις για έναν 2-stroke slow speed diesel:

Πίνακας 2.3: SFOC έναντι φόρτισης κινητήρα (τυπικός 2-stroke diesel)
Πηγή: MAN Energy Solutions (2022) — τυπικός ME-C κινητήρας

Φόρτιση (%MCR)	SFOC (g/kWh)	Σχετική Αύξηση	Παρατήρηση
50%	~185	+8%	Αναποτελεσματική λειτουργία
75%	~172	+1%	Κοντά στο βέλτιστο
85% (βέλτιστο)	~170	Βάση	Βέλτιστο σημείο λειτουργίας
100%	~175	+3%	Υπερφόρτιση — αυξάνει φθορά

2.4 Παραδοσιακές Μέθοδοι Πρόβλεψης Κατανάλωσης και Περιορισμοί

2.4.1 Ο Συντελεστής Admiralty (Admiralty Coefficient Method)

Η μέθοδος Admiralty αποτελεί μία από τις παλαιότερες εμπειρικές προσεγγίσεις για εκτίμηση απαιτούμενης ισχύος. Βασίζεται σε αδιάστατο συντελεστή C (Admiralty Coefficient) που ορίζεται ως:

$$C = \Delta^{(2/3)} \times V^3 / P$$

όπου Δ το εκτόπισμα (tonnes), V η ταχύτητα (knots), P η ισχύς κινητήρα (HP ή kW). Ο συντελεστής C θεωρείται σταθερός για ένα συγκεκριμένο πλοίο, επιτρέποντας εκτίμηση της νέας ισχύος P_2 για νέες συνθήκες V_2, Δ_2:

$$P_2 = \Delta_2^{(2/3)} \times V_2^3 / C$$

Η μέθοδος αυτή, αν και ιστορικά πολύτιμη, παρουσιάζει σοβαρούς περιορισμούς: (α) υποθέτει ότι ο C παραμένει σταθερός σε όλες τις συνθήκες λειτουργίας — μια απλοποίηση που αγνοεί τις επιδράσεις καιρού, κατάστασης γάστρας και φόρτισης κινητήρα, (β) δεν ενσωματώνει τη μη γραμμική εξάρτηση απόδοσης από φορτίο, και (γ) τα σφάλματά της σε πραγματικές συνθήκες είναι τυπικά 10–20% (Petersen et al., 2012). Στο πλαίσιο της παρούσας εργασίας, η μέθοδος αυτή χρησιμεύει ως ιστορική αναφορά για να αναδειχθεί η πρόοδος που έχει επιτευχθεί με τις τεχνικές ML.

2.4.2 Πίνακες SFOC και Καμπύλες Ισχύος

Οι κατασκευαστές κινητήρων παρέχουν τους SFOC πίνακες (Shop Test Data) από δοκιμές στο εργοστάσιο. Παρέχουν υψηλή ακρίβεια υπό ιδανικές συνθήκες (νέος κινητήρας, καθαρή γάστρα, ήρεμα νερά), αλλά αποκλίνουν από την πραγματικότητα λόγω: (α) γήρανσης κινητήρα — αύξηση SFOC 2–5% ανά 5 χρόνια λειτουργίας, (β) ποιότητας καυσίμου — διαφορετικές αναλογίες C/H επηρεάζουν τη θερμογόνο αξία, (γ) θαλάσσιων συνθηκών — καμία συνεκτίμηση πρόσθετης αντίστασης, (δ) μερικής φόρτισης — οι πίνακες αφορούν συνθήκες σχεδιασμού (Coraddu et al., 2016).

2.4.3 Στατιστικές Μέθοδοι — Γραμμική και Πολυωνυμική Παλινδρόμηση

Η εφαρμογή στατιστικής παλινδρόμησης αποτέλεσε βήμα εμπρός, επιτρέποντας τη συστηματική ανάλυση ιστορικών δεδομένων. Το βασικό μοντέλο πολλαπλής γραμμικής παλινδρόμησης για κατανάλωση καυσίμου εκφράζεται ως:

$$FC = \beta_0 + \beta_1 \cdot V + \beta_2 \cdot \Delta + \beta_3 \cdot T + \beta_4 \cdot Hs + \beta_5 \cdot Vw + \varepsilon$$

Έρευνες που εφάρμοσαν γραμμική παλινδρόμηση σε ναυτιλιακά δεδομένα (Petersen et al., 2012· Wang et al., 2018) κατέδειξαν R^2 τιμές στην περιοχή 0,70–0,85. Ωστόσο, η γραμμική παλινδρόμηση εγγενώς αδυνατεί να αποτυπώσει: (α) την κυβική εξάρτηση ισχύος-ταχύτητας, (β) τις αλληλεπιδράσεις μεταξύ features (interaction effects), και (γ) τις μη γραμμικές επιδράσεις ακραίων καιρικών συνθηκών. Η πολυωνυμική παλινδρόμηση βελτιώνει την κατάσταση αλλά είναι επιρρεπής σε overfitting όταν ο βαθμός πολυωνύμου αυξάνεται (Hastie et al., 2009).

2.4.4 Φυσικά Μοντέλα (Physics-Based / First-Principles Models)

Τα φυσικά μοντέλα υπολογίζουν την κατανάλωση βάσει υδροδυναμικών εξισώσεων, χρησιμοποιώντας δεδομένα δεξαμενής (tank test data) και θεωρία γραμμής ολίσθησης έλικα (propeller slip). Η γενική διαδικασία περιλαμβάνει: (α) υπολογισμό R_T βάσει δεδομένων δεξαμενής, (β) υπολογισμό απαιτούμενης ισχύος $P = R_T \times V / \eta_D$, (γ) μετατροπή P σε FC μέσω SFOC καμπύλης. Αν και παρέχουν πλήρη φυσική ερμηνευσιμότητα, τα φυσικά μοντέλα απαιτούν δεδομένα που συχνά δεν είναι διαθέσιμα σε πλοία σε λειτουργία (υδροδυναμικοί συντελεστές, καμπύλες αντίστασης), και αδυνατούν να ενσωματώσουν δυναμικά τη φθορά εξοπλισμού (Coraddu et al., 2016).

2.4.5 Σύνοψη και Συγκριτική Αξιολόγηση Παραδοσιακών Μεθόδων

Από την επισκόπηση των προηγούμενων υποενοτήτων προκύπτει ότι κάθε παραδοσιακή μέθοδος πρόβλεψης κατανάλωσης αντιπροσωπεύει έναν διαφορετικό συμβιβασμό μεταξύ ακρίβειας, πολυπλοκότητας

υλοποίησης, απαιτήσεων σε δεδομένα και ικανότητας προσαρμογής σε μεταβαλλόμενες συνθήκες. Ο συντελεστής Admiralty προσφέρει απλότητα και μηδενικό κόστος, αλλά η παραδοχή σταθερού συντελεστή τον καθιστά ανακριβή (±15–20%) εκτός των ονομαστικών συνθηκών. Οι πίνακες SFOC βελτιώνουν την ακρίβεια υπό ιδανικές συνθήκες, όμως αγνοούν τη γήρανση, την ποιότητα καυσίμου και τις θαλάσσιες συνθήκες. Η γραμμική και πολυωνυμική παλινδρόμηση εισάγουν συστηματική στατιστική ανάλυση ιστορικών δεδομένων, αλλά αδυνατούν να αποτυπώσουν πλήρως τις μη γραμμικές αλληλεπιδράσεις και είναι επιρρεπείς σε overfitting. Τέλος, τα φυσικά μοντέλα παρέχουν την υψηλότερη ερμηνευσιμότητα, αλλά απαιτούν δεδομένα που σπανίως είναι διαθέσιμα σε πλοία εν λειτουργία και συνοδεύονται από πολύ υψηλό κόστος εφαρμογής. Σε αντίθεση με τις παραδοσιακές μεθόδους, τα μοντέλα Μηχανικής Μάθησης (Machine Learning, ML) προσεγγίζουν το πρόβλημα χωρίς εκ των προτέρων παραδοχές για τη μορφή της σχέσης εισόδου–εξόδου, εξάγοντας μη γραμμικά μοτίβα απευθείας από τα δεδομένα λειτουργίας. Αυτό τα καθιστά ικανά να αντιμετωπίσουν ταυτόχρονα τις αδυναμίες που εντοπίστηκαν παραπάνω: μπορούν να ενσωματώσουν τη γήρανση του κινητήρα και το biofouling μέσω επαναλαμβανόμενης εκπαίδευσης, να αποτυπώσουν μη γραμμικές αλληλεπιδράσεις που διαφεύγουν της πολυωνυμικής παλινδρόμησης, και να λειτουργούν χωρίς την ανάγκη αναλυτικών φυσικών παραμέτρων που σπανίως είναι διαθέσιμες. Ωστόσο, τα ML μοντέλα παρουσιάζουν και τα δικά τους μειονεκτήματα: απαιτούν μεγάλο όγκο ποιοτικών δεδομένων εκπαίδευσης, είναι επιρρεπή σε overfitting όταν τα δεδομένα είναι θορυβώδη ή ελλιπή, και η ερμηνευσιμότητά τους παραμένει περιορισμένη σε σχέση με τα φυσικά μοντέλα — ένα χαρακτηριστικό γνωστό ως «μαύρο κουτί» (black-box problem) (Coraddu et al., 2016). Η συγκριτική αυτή αξιολόγηση αναδεικνύει ότι η επιλογή μεθόδου δεν είναι ουδέτερη: εξαρτάται από τη διαθεσιμότητα δεδομένων, τις απαιτήσεις ακρίβειας και τον βαθμό ερμηνευσιμότητας που απαιτεί η εκάστοτε εφαρμογή.

Για τη συστηματική αντιπαραβολή των μεθόδων αυτών, ο Πίνακας 2.4 τις συγκρίνει ως προς πέντε κρίσιμες διαστάσεις — ακρίβεια, πολυπλοκότητα, ενσωμάτωση καιρικών συνθηκών, δυναμική προσαρμογή και κόστος — και τις αντιπαραθέτει με τη σύγχρονη προσέγγιση της Μηχανικής Μάθησης (ML):

Πίνακας 2.4: Αναλυτική σύγκριση παραδοσιακών μεθόδων πρόβλεψης

** Υπό ιδανικές συνθήκες πλήρους διαθεσιμότητας δεδομένων. Πηγές: Petersen et al. (2012), Coraddu et al. (2016), Faber et al. (2020)*

Μέθοδος	Ακρίβεια	Πολυπλοκότητα	Καιρός	Δυναμική Προσαρμογή	Κόστος
Admiralty Coeff.	Χαμηλή (±15–20%)	Πολύ Χαμηλή	Όχι	Όχι	Μηδενικό
SFOC Tables	Μέτρια (±10–15%)	Χαμηλή	Όχι	Περιορισμένη	Χαμηλό
Linear Regression	Μέτρια (±8–12%)	Μέτρια	Μερικώς	Περιορισμένη	Χαμηλό
Polynomial Reg.	Καλή (±5–9%)	Μέτρια	Μερικώς	Περιορισμένη	Χαμηλό

Μέθοδος	Ακρίβεια	Πολυπλοκότητα	Καιρός	Δυναμική Προσαρμογή	Κόστος
Physics-Based	Υψηλή* (±3–8%)	Πολύ Υψηλή	Μερικώς	Χαμηλή	Πολύ Υψηλό
ML (XGBoost κ.ά.)	Πολύ Υψηλή (±3–6%)	Μέτρια	Ναι	Υψηλή	Μέτριο

2.5 Περιβαλλοντικοί Κανονισμοί και Πλαίσιο Συμμόρφωσης

2.5.1 Ιστορική Εξέλιξη Κανονισμών

Η περιβαλλοντική ρύθμιση της ναυτιλίας ξεκίνησε με τη MARPOL 73/78 (Marine Pollution Convention), η οποία αρχικά επικεντρώθηκε στη ρύπανση από πετρέλαιο. Η σταδιακή επέκτασή της, ιδιαίτερα μέσω του Παραρτήματος VI (Annex VI) που αφορά αέριους ρύπους, μετέτρεψε τη MARPOL σε κεντρικό κανονιστικό πλαίσιο για την ατμοσφαιρική ρύπανση της ναυτιλίας. Τα βασικά ορόσημα στην εξέλιξη των κανονισμών GHG παρουσιάζονται στον Πίνακα 2.5:

Πίνακας 2.5: Ιστορική εξέλιξη ναυτιλιακών κανονισμών GHG

Πηγές: IMO (2023), European Commission (2023)

Σημείωση: Τα ακρωνύμια EEDI, EEXI και CII που εμφανίζονται στον πίνακα ορίζονται αναλυτικά στις Ενότητες 2.5.2–2.5.4. Το EEXI αντιστοιχεί στο Energy Efficiency Existing Ship Index, ο CII στον Carbon Intensity Indicator και ο EEDI στον Energy Efficiency Design Index και το SEEMP στο Ship Energy Efficiency Management Plan.

Έτος	Κανονισμός	Κύριο Περιεχόμενο
1997	Annex VI MARPOL	Πρώτοι κανονισμοί για NOx/SOx εκπομπές από πλοία
2005	Annex VI σε ισχύ	Ορισμός Emission Control Areas (ECA) για SOx (1,5%)
2011	EEDI & SEEMP	Εισαγωγή δείκτη ενεργειακής αποδοτικότητας νέων πλοίων (EEDI) και Σχεδίου Διαχείρισης Ενέργειας (SEEMP)
2018	IMO GHG Strategy	Στόχος μείωσης εκπομπών GHG κατά 50% έως 2050 (βάση 2008)
2020	IMO 2020 (SOx Cap)	Μέγιστο όριο θείου καυσίμου 0,5% παγκοσμίως (από 3,5%)
2023	EEXI & CII	Νέοι δείκτες τεχνικής (EEXI) και επιχειρησιακής (CII) αποδοτικότητας
2023	Αναθ. GHG Στρατηγική	Επιτάχυνση στόχου: κλιματική ουδετερότητα έως 2050, -40% CO_2/τμ έως 2030

Έτος	Κανονισμός	Κύριο Περιεχόμενο
2024	EU ETS	Ένταξη ναυτιλίας στο Ευρωπαϊκό Σύστημα Εμπορίας Δικαιωμάτων Εκπομπών
2025	FuelEU Maritime	Ευρωπαϊκός κανονισμός για σταδιακή αποανθρακοποίηση καυσίμων

2.5.2 EEDI — Energy Efficiency Design Index

Ο EEDI (Energy Efficiency Design Index), που τέθηκε σε ισχύ το 2013, αποτελεί μέτρο τεχνικής ενεργειακής αποδοτικότητας για νέα πλοία. Εκφράζει τις εκπομπές CO_2 ανά μονάδα μεταφερόμενης ικανότητας και ανά μίλι:

$$EEDI = (CF \times SFC \times P_{ME} + CF \times SFC_{AE} \times P_{AE}) / (f_w \times Capacity \times V_{ref})$$

όπου CF ο συντελεστής μετατροπής καυσίμου-CO_2, SFC η ειδική κατανάλωση καυσίμου, P_ME/P_AE η ισχύς κινητήρα/γεννητριών, f_w συντελεστής καιρού, Capacity η χωρητικότητα σε DWT ή GT, V_ref η ταχύτητα αναφοράς. Κάθε νέο πλοίο πρέπει να επιτυγχάνει EEDI κατώτερο από μία γραμμή αναφοράς (reference line), η οποία αυστηροποιείται κατά φάσεις: Phase 1 (-10%), Phase 2 (-20%), Phase 3 (-30%) έως το 2030 (IMO MEPC.328(76), 2021).

2.5.3 EEXI — Energy Efficiency Existing Ship Index

Σε αντίθεση με τον EEDI που αφορά νέα πλοία, ο EEXI (Energy Efficiency Existing Ship Index) εφαρμόζεται σε υπάρχοντα πλοία άνω των 400 GT από την 1η Ιανουαρίου 2023. Υπολογίζεται με παρόμοιο τρόπο με τον EEDI αλλά βάσει της υπάρχουσας εγκατεστημένης ισχύος. Πλοία που δεν πληρούν τις απαιτήσεις EEXI έχουν τρεις επιλογές: (α) εγκατάσταση Engine Power Limiter (EPL) — η πιο συνηθισμένη λύση, (β) εγκατάσταση τεχνολογιών ενεργειακής αποδοτικότητας πλοίου (Energy Efficiency Saving Technologies, EEST), ή (γ) εφοδιασμός με εναλλακτικά καύσιμα χαμηλών εκπομπών. Σύμφωνα με εκτιμήσεις (DNV GL, 2020), περίπου 20–30% του παγκόσμιου στόλου απαιτεί δράση για EEXI συμμόρφωση, δημιουργώντας σημαντικές επενδυτικές ανάγκες.

2.5.4 CII — Carbon Intensity Indicator

Ο CII (Carbon Intensity Indicator) αποτελεί τη σημαντικότερη καινοτομία του κανονιστικού πλαισίου από άποψη επιχειρησιακής επίδρασης. Εισάγει ετήσια αξιολόγηση της πραγματικής επιχειρησιακής απόδοσης κάθε πλοίου, με βαθμολογία A–E. Υπολογίζεται ως:

$$CII = (FC_{total} \times CF) / (DWT \times Distance_{sailed})$$

όπου FC_total η συνολική κατανάλωση καυσίμου έτους (τόνοι), CF ο συντελεστής CO_2 ανά τόνο καυσίμου, DWT η χωρητικότητα σε τόνους, Distance_sailed η ολική απόσταση πλεύσης έτους (ναυτικά μίλια). Ο Πίνακας 2.6 παρουσιάζει την ετήσια κλίμακα βαθμολόγησης A–E και τις αντίστοιχες υποχρεώσεις ανά βαθμίδα:

Πίνακας 2.6: Ετήσια βαθμολόγηση CII και υποχρεώσεις

Πηγή: IMO MEPC.328(76) (2021)

Σημείωση: d_1–d_4 είναι ετήσιοι διορθωτικοί παράγοντες που αυστηροποιούνται βαθμιαία.

Βαθμός	Σχέση με Απαίτηση	Ερμηνεία	Υποχρέωση
A	< d_1 × required	Εξαιρετική επίδοση	Χωρίς ειδική υποχρέωση
B	d_1 – d_2	Άνω του μέσου όρου	Χωρίς ειδική υποχρέωση
C	d_2 – d_3	Μέσος όρος	Χωρίς άμεση υποχρέωση
D	d_3 – d_4	Κάτω από μέσο όρο	Corrective Action Plan εντός 1 έτους
E	> d_4 × required	Χαμηλή επίδοση	Corrective Action Plan άμεσα

Το CII είναι κρίσιμα σχετικό με την παρούσα εργασία: η ακριβής πρόβλεψη κατανάλωσης καυσίμου επιτρέπει στον πλοίαρχο να σχεδιάζει κάθε δρομολόγιο με γνώμονα τη διατήρηση βαθμολογίας A ή B, αποφεύγοντας κοστοβόρα διορθωτικά μέτρα. Επιπλέον, η ετήσια αθροιστική φύση του CII σημαίνει ότι μία κακή περίοδος (π.χ. χειμώνας με δυσμενείς καιρικές συνθήκες) μπορεί να επηρεάσει σημαντικά τον ετήσιο δείκτη — κάτι που ένα ML σύστημα πρόβλεψης μπορεί να αντιμετωπίσει προληπτικά.

2.5.5 EU ETS και FuelEU Maritime

Από την 1η Ιανουαρίου 2024, τα πλοία άνω των 5.000 GT που εκτελούν δρομολόγια εντός/εκτός ΕΕ υπάγονται στο EU ETS (Σύστημα Εμπορίας Δικαιωμάτων Εκπομπών). Η σταδιακή κάλυψη ορίζεται ως 40% το 2024, 70% το 2025 και 100% από το 2026. Η τιμή δικαιωμάτων CO_2 στο EU ETS κυμαίνεται μεταξύ 50–100 EUR/τόνο CO_2, προσθέτοντας άμεσο μεταβλητό κόστος ανάλογο της κατανάλωσης (European Commission, 2023).

Ο κανονισμός FuelEU Maritime (σε ισχύ από 2025) ορίζει ανώτατες τιμές έντασης greenhouse gas (GHG intensity) του ενεργειακού μείγματος πλοίου, μειούμενες κατά 2% από το 2025, 6% από το 2030, 14,5% το 2035, 31% το 2040, 62% το 2045 και 80% έως το 2050 σε σχέση με το επίπεδο αναφοράς του 2020. Η συμμόρφωση απαιτεί σταδιακή ενσωμάτωση βιοκαυσίμων, e-fuels (green hydrogen, green ammonia) και LNG. Τα πλοία που δεν συμμορφώνονται αντιμετωπίζουν πρόστιμα που υπολογίζονται βάσει του ελλείμματος GHG intensity (European Commission, 2023).

Στο πλαίσιο αυτό, η ακριβής πρόβλεψη κατανάλωσης με χρήση ML δεν είναι απλώς επιχειρησιακή ευκαιρία — αποτελεί εργαλείο κανονιστικής συμμόρφωσης και διαχείρισης κανονιστικού κινδύνου (regulatory risk management), με άμεσο οικονομικό αντίκτυπο που μετρά σε εκατοντάδες χιλιάδες ευρώ ετησίως ανά πλοίο.

2.5.6 SEEMP — Ship Energy Efficiency Management Plan

Το SEEMP (Ship Energy Efficiency Management Plan) είναι υποχρεωτικό σχέδιο διαχείρισης ενέργειας για κάθε πλοίο άνω των 400 GT, εισήχθη το 2013 και αναθεωρήθηκε το 2023. Αποτελείται από τέσσερα μέρη: (I) Μέτρα ενεργειακής αποδοτικότητας και επιχειρησιακές πρακτικές, (II) Διαδικασίες παρακολούθησης CII, (III) Σχέδιο επίτευξης CII στόχου, (IV) Δήλωση ολοκλήρωσης. Το SEEMP αποτελεί κατ’ ουσίαν το "σχέδιο εκτέλεσης" για συμμόρφωση με CII και EEXI, ενώ η ML-based πρόβλεψη κατανάλωσης μπορεί να ενσωματωθεί ως εργαλείο υλοποίησης του SEEMP Μέρους III (IMO MEPC.346(78), 2022).

ΚΕΦΑΛΑΙΟ 3: Μηχανική Μάθηση — Θεωρία και Αλγόριθμοι

3.1 Βασικές Αρχές Μηχανικής Μάθησης

3.1.1 Ορισμός και Ιστορική Εξέλιξη

Η Μηχανική Μάθηση (Machine Learning – ML) αποτελεί κλάδο της Τεχνητής Νοημοσύνης (Artificial Intelligence – AI) που επικεντρώνεται στην ανάπτυξη αλγορίθμων ικανών να μαθαίνουν από δεδομένα και να βελτιώνουν την απόδοσή τους με την εμπειρία. Ο κλασικός ορισμός του Mitchell (1997) παραμένει θεμελιακός: «Ένα πρόγραμμα υπολογιστή λέγεται ότι μαθαίνει από εμπειρία E ως προς κάποια κλάση εργασιών T και μέτρο απόδοσης P, εάν η απόδοσή του στις εργασίες T, μετρούμενη με P, βελτιώνεται με την εμπειρία E».

Ιστορικά, η ML εξελίχθηκε μέσα από τρεις μεγάλες περιόδους (Goodfellow et al., 2016): (α) Κυβερνητική (1940–1960): Πρώτα νευρωνικά μοντέλα (McCulloch-Pitts, 1943), Perceptron (Rosenblatt, 1958), (β) Συνδετισμός (1980–1995): Backpropagation (Rumelhart et al., 1986), Support Vector Machines (Vapnik, 1995), (γ) Deep Learning (2006–σήμερα): Βαθιά νευρωνικά δίκτυα, μεγάλα δεδομένα (Big Data), υπολογισμοί σε μονάδες επεξεργασίας γραφικών (Graphics Processing Unit, GPU). Η εφαρμογή ML σε ναυτιλιακά προβλήματα αποτελεί σχετικά νέο πεδίο, με τις πρώτες σημαντικές δημοσιεύσεις να εμφανίζονται μετά το 2010 (Coraddu et al., 2016· Wang et al., 2020).

3.1.2 Θεμελιώδεις Έννοιες

Χαρακτηριστικά (Features): Οι μεταβλητές εισόδου του μοντέλου. Διακρίνονται σε αριθμητικές συνεχείς (π.χ. ταχύτητα, θερμοκρασία), αριθμητικές διακριτές (π.χ. αριθμός κυλίνδρων) και κατηγορικές (π.χ. τύπος καυσίμου). Στο dataset της παρούσας εργασίας, όλα τα features είναι συνεχείς αριθμητικές μεταβλητές, απλοποιώντας την προεπεξεργασία.

Μεταβλητή Στόχος (Target): Η μεταβλητή που το μοντέλο καλείται να προβλέψει. Για προβλήματα παλινδρόμησης (regression) η τιμή είναι συνεχής, ενώ για προβλήματα ταξινόμησης (classification) είναι διακριτή κατηγορία. Η κατανάλωση καυσίμου αποτελεί τυπικό πρόβλημα παλινδρόμησης.

Γενίκευση (Generalization): Η ικανότητα του μοντέλου να αποδίδει σωστά σε νέα, αόρατα (unseen) δεδομένα. Αποτελεί τον κεντρικό στόχο της ML — ένα μοντέλο που "αποστηθίζει" τα δεδομένα εκπαίδευσης χωρίς να γενικεύει, είναι άχρηστο σε πρακτικές εφαρμογές.

Χώρος Υποθέσεων (Hypothesis Space): Το σύνολο όλων των πιθανών μοντέλων/συναρτήσεων που ο αλγόριθμος μπορεί να εκφράσει. Ένας αλγόριθμος με πλούσιο χώρο υποθέσεων (π.χ. deep neural network) έχει μεγαλύτερη εκφραστική ισχύ αλλά και μεγαλύτερο κίνδυνο overfitting (Hastie et al., 2009).

Συνάρτηση Κόστους (Loss Function): Ποσοτικοποιεί το σφάλμα μεταξύ προβλέψεων και πραγματικών τιμών. Για παλινδρόμηση, συνήθεις επιλογές είναι: Mean Squared Error $MSE = (1/n)\Sigma(y_i-\hat{y}_i)^2$, Mean Absolute Error $MAE = (1/n)\Sigma|y_i-\hat{y}_i|$, και Huber Loss (συνδυασμός MSE/MAE για ανθεκτικότητα σε outliers). Η επιλογή loss function επηρεάζει τα χαρακτηριστικά του εκπαιδευμένου μοντέλου. Οι μετρικές αξιολόγησης — συντελεστής προσδιορισμού (R^2), ρίζα μέσου τετραγωνικού σφάλματος (Root Mean Squared Error, RMSE),

MAE και μέσο απόλυτο ποσοστιαίο σφάλμα (Mean Absolute Percentage Error, MAPE) — ορίζονται πλήρως στην Ενότητα 3.5.

Παράμετροι και Υπερπαράμετροι (Parameters & Hyperparameters): Σε αντίθεση με τις παραμέτρους του μοντέλου (π.χ. τα βάρη θ), που μαθαίνονται αυτόματα από τα δεδομένα κατά την εκπαίδευση, οι υπερπαράμετροι ορίζονται από τον αναλυτή πριν την εκπαίδευση και ελέγχουν τη συμπεριφορά του αλγορίθμου. Δεν βελτιστοποιούνται από την ίδια τη διαδικασία μάθησης, αλλά ρυθμίζονται μέσω cross-validation (βλ. §3.1.4). Χαρακτηριστικές υπερπαράμετροι που εμφανίζονται στις βασικές διαδικασίες εκπαίδευσης (§3.1.4) είναι: (α) το πλήθος των τμημάτων k στη k-fold cross-validation (τυπικά k=5 ή k=10· στην παρούσα εργασία k=5), (β) η ισχύς της regularization λ, η οποία ρυθμίζει την ισορροπία bias-variance (υψηλό λ → underfitting, χαμηλό λ → overfitting), και (γ) ο συντελεστής ανάμειξης α του Elastic Net, που καθορίζει τη βαρύτητα μεταξύ των ποινών L1 και L2. Επιπλέον, κάθε αλγόριθμος διαθέτει τις δικές του υπερπαραμέτρους (π.χ. βάθος δέντρου, πλήθος εκτιμητών, ρυθμός μάθησης), οι οποίες αναλύονται στις αντίστοιχες ενότητες (§3.3) και βελτιστοποιούνται στο Κεφάλαιο 4. Η σωστή επιλογή υπερπαραμέτρων (hyperparameter tuning) είναι καθοριστική για την απόδοση και τη γενίκευση του μοντέλου (Hastie et al., 2009).

3.1.3 Το Δίλημμα Bias-Variance

Ένα από τα θεμελιώδη προβλήματα της ML είναι το δίλημμα bias-variance (Geman et al., 1992). Το αναμενόμενο σφάλμα ενός μοντέλου αναλύεται ως:

$$E[(y - \hat{y})^2] = Bias^2(\hat{y}) + Var(\hat{y}) + \sigma^2_noise$$

όπου Bias(ŷ) = E[ŷ] - y αποτυπώνει τη συστηματική απόκλιση λόγω υπερβολικά απλού μοντέλου (underfitting), Var(ŷ) αποτυπώνει την ευαισθησία σε μεταβολές των δεδομένων εκπαίδευσης (overfitting), και σ²_noise τον αναπόφευκτο τυχαίο θόρυβο. Τα μοντέλα με υψηλή πολυπλοκότητα (π.χ. βαθιά νευρωνικά δίκτυα) τείνουν σε χαμηλό bias αλλά υψηλή variance, ενώ τα απλά μοντέλα (π.χ. γραμμική παλινδρόμηση) στο αντίθετο. Η βέλτιστη επιλογή ισορροπεί τις δύο πηγές σφάλματος — αυτό επιτυγχάνεται μέσω regularization, cross-validation και hyperparameter tuning (Hastie et al., 2009).

3.1.4 Βασικές Διαδικασίες Εκπαίδευσης

K-Fold Cross-Validation

Η k-fold cross-validation αποτελεί τη βασική τεχνική αξιόπιστης εκτίμησης απόδοσης μοντέλου. Η διαδικασία είναι η εξής: (α) Το σύνολο δεδομένων διαιρείται τυχαία σε k ισομεγέθη τμήματα (folds). (β) Το μοντέλο εκπαιδεύεται k φορές, κάθε φορά χρησιμοποιώντας k-1 folds για εκπαίδευση και 1 fold για επικύρωση. (γ) Η τελική μετρική απόδοσης υπολογίζεται ως ο μέσος όρος των k εκτιμήσεων. Η τυπική τιμή k=5 ή k=10 παρέχει καλή ισορροπία μεταξύ υπολογιστικού κόστους και αξιοπιστίας εκτίμησης (Kohavi, 1995). Στην παρούσα εργασία χρησιμοποιείται 5-fold cross-validation για την βελτιστοποίηση των hyperparameters όλων των μοντέλων.

Regularization

Η regularization αποτελεί θεμελιώδη τεχνική αποφυγής overfitting, προσθέτοντας ποινή στη συνάρτηση κόστους για πολύπλοκα μοντέλα. Οι κύριες μορφές είναι:

$$L1\ (Lasso):\ J(\theta) = MSE(\theta) + \lambda\Sigma|\theta_j| \rightarrow \text{Παράγει αραιά (sparse) μοντέλα}$$

$$L2\ (Ridge):\ J(\theta) = MSE(\theta) + \lambda\Sigma\theta_j^2 \rightarrow \text{Συρρικνώνει ομοιόμορφα τους συντελεστές}$$

$$\text{Elastic Net:}\ J(\theta) = MSE(\theta) + \alpha\cdot\lambda\Sigma|\theta_j| + (1-\alpha)\cdot\lambda\Sigma\theta_j^2 \rightarrow \text{Συνδυασμός L1+L2}$$

Ο hyperparameter λ (regularization strength) ελέγχει την ισορροπία bias-variance: υψηλό λ → ισχυρό regularization → υψηλό bias (underfitting), χαμηλό λ → αδύναμο regularization → υψηλό variance (overfitting). Η βέλτιστη τιμή λ επιλέγεται μέσω cross-validation.

3.2 Ανασκόπηση Βιβλιογραφίας (Literature Review)

Η εφαρμογή μοντέλων μηχανικής μάθησης για πρόβλεψη κατανάλωσης καυσίμου πλοίων αποτελεί ενεργό ερευνητικό πεδίο με ταχεία ανάπτυξη κατά την τελευταία δεκαετία. Στην παρούσα ενότητα παρουσιάζεται συστηματική ανασκόπηση της βιβλιογραφίας, οργανωμένη κατά θεματική κατηγορία.

3.2.1 Πρώιμες Εργασίες — Στατιστικά Μοντέλα

Οι Petersen et al. (2012) από το DTU (Technical University of Denmark) ήταν μεταξύ των πρώτων που εφάρμοσαν συστηματικά στατιστικά μοντέλα σε πραγματικά επιχειρησιακά δεδομένα πλοίου. Χρησιμοποιώντας δεδομένα από container ship της Maersk Line, δοκίμασαν γραμμική παλινδρόμηση, τεχνικές Gaussian Process Regression και νευρωνικά δίκτυα, καταλήγοντας ότι τα μη γραμμικά μοντέλα υπερτερούν σημαντικά. Το R^2 για τη βέλτιστη μέθοδό τους ήταν ~0,92 για την κατανάλωση κυρίου κινητήρα.

Οι Jeon et al. (2018) ανέπτυξαν μοντέλο πρόβλεψης της κατανάλωσης καυσίμου του κύριου κινητήρα με χρήση τεχνητού νευρωνικού δικτύου (Artificial Neural Network, ANN), αξιοποιώντας ανάλυση μεγάλων δεδομένων (συλλογή, ομαδοποίηση, συμπίεση και επαύξηση δεδομένων). Δοκιμάζοντας διαφορετικό αριθμό κρυφών επιπέδων και νευρώνων καθώς και διαφορετικές συναρτήσεις ενεργοποίησης, κατέληξαν ότι το ANN αποτελεί ακριβέστερο και αποδοτικότερο μοντέλο πρόβλεψης σε σύγκριση τόσο με την πολυωνυμική παλινδρόμηση όσο και με τις μηχανές διανυσμάτων υποστήριξης (SVM).

3.2.2 Εφαρμογές Random Forest και Ensemble Methods

Η εργασία-σταθμός των Coraddu et al. (2016) αποτελεί την κύρια βιβλιογραφική αναφορά της παρούσας εργασίας και την πηγή του dataset. Οι ερευνητές εφάρμοσαν μια σειρά ML αλγορίθμων (Random Forest, Extremely Randomized Trees, Back-Propagation Neural Network (NN), k-NN, Support Vector Regression) σε dataset ναυτικού αεριοστρόβιλου. Τα κύρια ευρήματα: (α) τα ensemble μοντέλα (RF, ExtraTrees) υπερτερούσαν σταθερά των υπολοίπων, (β) το Random Forest πέτυχε MAPE ~4,5% για την κατανάλωση GT, (γ) το features importance, δηλαδή το πόσο συνεισφέρει κάθε μεταβλητή στις προβλέψεις του μοντέλου, αποκάλυψε ότι οι στροφές κινητήρα και η θερμοκρασία καυσαερίων είναι οι πλέον κρίσιμες παράμετροι.

Τα ευρήματα των Coraddu et al. (2016) έχουν άμεση σημασία για την παρούσα εργασία. Η διαπιστωμένη υπεροχή των ensemble μεθόδων, καθώς και ο ρόλος των στροφών κινητήρα και της θερμοκρασίας καυσαερίων ως κρίσιμων μεταβλητών, επιβεβαιώνονται και στα δικά μας αποτελέσματα (Κεφάλαιο 5), όπου το Random Forest αναδεικνύεται μεταξύ των κορυφαίων μοντέλων για την πρόβλεψη της κατανάλωσης καυσίμου. Η επιλογή τόσο του συγκεκριμένου dataset όσο και της οικογένειας ensemble αλγορίθμων στην παρούσα μελέτη στηρίζεται σε αυτή τη βιβλιογραφική βάση, διασφαλίζοντας τη συνέχεια μεταξύ της προϋπάρχουσας έρευνας και της δικής μας πειραματικής προσέγγισης.

3.2.3 Gradient Boosting και XGBoost στη Ναυτιλία

Πέρα από τα τυχαία δάση, οι μέθοδοι ενισχυτικής μάθησης με δέντρα απόφασης (gradient boosting) και ιδίως ο αλγόριθμος XGBoost (Chen & Guestrin, 2016) έχουν αναδειχθεί σε ιδιαίτερα ισχυρά εργαλεία παλινδρόμησης, καθώς κατασκευάζουν διαδοχικά δέντρα όπου κάθε νέο δέντρο διορθώνει τα σφάλματα των προηγούμενων. Η αποτελεσματικότητα των ensemble και tree-based μεθόδων στην πρόβλεψη κατανάλωσης καυσίμου επιβεβαιώνεται από τις συγκριτικές μελέτες των Coraddu et al. (2016) και Gkerekos et al. (2019), στις οποίες οι ensemble προσεγγίσεις πέτυχαν σταθερά την υψηλότερη ακρίβεια έναντι των μεμονωμένων μοντέλων. Στην παρούσα εργασία, ο αλγόριθμος Gradient Boosting αξιολογείται συστηματικά μεταξύ των έξι συγκρινόμενων μοντέλων (Κεφάλαιο 5).

Παράλληλα, υβριδικές προσεγγίσεις «γκρι κουτιού» (grey-box) συνδυάζουν φυσικά μοντέλα με αλγορίθμους μηχανικής μάθησης. Οι Leifsson et al. (2008) συνδύασαν ένα φυσικό μοντέλο «λευκού κουτιού» με ένα feed-forward νευρωνικό δίκτυο («μαύρο κουτί»), τόσο σε σειριακή όσο και σε παράλληλη διάταξη, βελτιώνοντας σημαντικά την πρόβλεψη της κατανάλωσης καυσίμου του πλοίου σε σχέση με το καθαρά φυσικό μοντέλο.

3.2.4 Νευρωνικά Δίκτυα και Deep Learning

Η πρώιμη εφαρμογή νευρωνικών δικτύων στο πρόβλημα (Dietmair & Verl, 2009· Petersen et al., 2012) έδειξε υποσχόμενα αποτελέσματα αλλά με σημαντικά προβλήματα overfitting και ευαισθησία στην αρχικοποίηση βαρών. Η εισαγωγή τεχνικών όπως Dropout (Srivastava et al., 2014), Batch Normalization (Ioffe & Szegedy, 2015) και η διαθεσιμότητα μεγαλύτερων dataset μετέβαλε αυτή την εικόνα.

Οι Farag & Ölçer (2020) ανέπτυξαν μοντέλο πρόβλεψης επίδοσης πλοίου για Very Large Crude Carrier (VLCC) σε μεταβαλλόμενες θαλάσσιες συνθήκες, συνδυάζοντας Artificial Neural Network (ANN) με τεχνικές πολλαπλής παλινδρόμησης. Χρησιμοποιώντας ως μεταβλητές εισόδου την ταχύτητα του πλοίου και περιβαλλοντικές παραμέτρους (βάθος θάλασσας, χαρακτηριστικά κυματισμού και swell, θαλάσσια ρεύματα), το νευρωνικό δίκτυο πέτυχε ακρίβεια πρόβλεψης κατανάλωσης περίπου 99,6%, υπερτερώντας του μοντέλου παλινδρόμησης που χρησιμοποιήθηκε ως baseline σύγκρισης εντός της ίδιας μελέτης και αναδεικνύοντας την υπεροχή των μη γραμμικών προσεγγίσεων σε ρεαλιστικές θαλάσσιες συνθήκες.

Οι Theodoropoulos et al. (2021) πραγματοποίησαν εκτενή σύγκριση deep learning αρχιτεκτονικών (MLP, Συνελικτικά Νευρωνικά Δίκτυα [Convolutional Neural Network, CNN], LSTM, Gated Recurrent Unit [GRU]) για πρόβλεψη κατανάλωσης σε δεδομένα από 3 Ro-Pax πλοία. Τα κύρια ευρήματα: (α) οι αρχιτεκτονικές LSTM και GRU υπερτερούσαν σε time-series δεδομένα λόγω χρονικής εξάρτησης, (β) τα MLP αποδίδουν ανταγωνιστικά σε cross-sectional δεδομένα (ανεξάρτητες παρατηρήσεις), (γ) η προσθήκη weather data βελτίωσε σταθερά όλες τις αρχιτεκτονικές κατά 1,5–3%.

Οι Gkerekos et al. (2019) πραγματοποίησαν συγκριτική μελέτη αλγορίθμων παλινδρόμησης (Support Vector Machines, Random Forest, Extra Trees, τεχνητά νευρωνικά δίκτυα και ensemble μέθοδοι) για την πρόβλεψη της κατανάλωσης καυσίμου του κύριου κινητήρα, εξετάζοντας δύο στρατηγικές συλλογής δεδομένων: αναφορές μεσημβρίας (noon-reports) και συστήματα αυτοματοποιημένης καταγραφής (ADLM). Διαπίστωσαν ότι οι ensemble μέθοδοι απέδωσαν τη μεγαλύτερη ακρίβεια και ότι τα συστήματα ADLM βελτίωσαν την ακρίβεια κατά περίπου 7% σε σχέση με τα noon-reports, μειώνοντας ταυτόχρονα έως και 90% το απαιτούμενο διάστημα συλλογής δεδομένων.

3.2.5 LSTM και Χρονοσειρές

Η κατανάλωση καυσίμου παρουσιάζει ισχυρή χρονική εξάρτηση: η κατανάλωση σε χρόνο t επηρεάζεται από την κατάσταση κινητήρα στους χρόνους t-1, t-2, ... (λόγω θερμικής αδράνειας, μεταβατικών φαινομένων κ.ά.). Τα LSTM (Long Short-Term Memory) δίκτυα, που εισήχθησαν από τους Hochreiter & Schmidhuber (1997), αντιμετωπίζουν φυσικά αυτή τη χρονική εξάρτηση μέσω της κυψέλης μνήμης (memory cell):

$$f_t = \sigma(Wf \cdot [h_{t-1}, x_t] + bf) \quad [forget\ gate]$$

$$i_t = \sigma(Wi \cdot [h_{t-1}, x_t] + bi) \quad [input\ gate]$$

$$c_t = f_t \odot c_{t-1} + i_t \odot tanh(Wc \cdot [h_{t-1}, x_t] + bc) \quad [cell\ state]$$

$$o_t = \sigma(Wo \cdot [h_{t-1}, x_t] + bo) \quad [output\ gate]$$

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

όπου f_t, i_t, o_t είναι οι πύλες ελέγχου (gates), c_t η κατάσταση κυψέλης, h_t η έξοδος. Οι Guo et al. (2020) εφάρμοσαν LSTM σε δεδομένα container ship 12 μηνών, επιτυγχάνοντας MAPE 4,8% — καλύτερα από MLP (6,2%) και Random Forest (5,9%) στο ίδιο dataset. Ωστόσο, τα LSTM απαιτούν σημαντικά μεγαλύτερα datasets για σταθερή εκπαίδευση και είναι λιγότερο ερμηνεύσιμα.

3.2.6 Ανασκόπηση — Σύνοψη Ευρημάτων Βιβλιογραφίας

Ο παρακάτω πίνακας συνοψίζει τα κύρια ευρήματα της βιβλιογραφικής ανασκόπησης:

Πίνακας 3.1: Ανασκόπηση βιβλιογραφίας σχετικά με τη χρήση μοντέλων ML για πρόβλεψη κατανάλωσης καυσίμου πλοίων

Πηγή: Σύνθεση βιβλιογραφίας. MAPE: Mean Absolute Percentage Error.

Ερευνητές	Πλοίο/ Dataset	Μέθοδος	Βέλτιστο R^2	MAPE	Κύριο Εύρημα
Petersen et al. (2012)	Container (Maersk)	GP Regression	0.92	~6%	Non-linear μοντέλα υπερτερούν
Jeon et al. (2018)	Πλοίο (κύριος κινητήρας)	ANN	—	—	ANN > πολυωνυμικής παλινδρόμησης & SVM
Coraddu et al. (2016)	Naval frigate (sim)	Random Forest	0.97	~4.5 %	RF & ExtraTrees βέλτιστα ensemble
Gkerekos et al. (2019)	88 πλοία	ANN	0.94	~7%	Hull index βελτιώνει κατά 15%

Ερευνητές	Πλοίο/ Dataset	Μέθοδος	Βέλτιστο R^2	MAPE	Κύριο Εύρημα
Farag & Ölçer (2020)	VLCC (tanker)	ANN + Regression	—	—	ANN υπερτερεί παλινδρόμησης· ~99,6% ακρίβεια
Guo et al. (2020)	Container	LSTM	0.96	4.8%	LSTM > MLP για time-series
Mao et al. (2016)	Container ship	Στατιστικά (AR)	—	—	AR με περιβαλλοντικούς παράγοντες μειώνει το σφάλμα ταχύτητας
Theodoropoulos et al. (2021)	Ro-Pax (3 πλοία)	LSTM/GRU	0.97	5.3%	Καιρός βελτιώνει κατά 1,5–3%
Wang et al. (2018)	Πολλαπλά	LASSO + ML	0.96	~6%	LASSO για feature selection
Leifsson et al. (2008)	Ocean vessel	Grey-box (WB+NN)	—	—	Grey-box βελτιώνει την πρόβλεψη κατανάλωσης

Από την ανασκόπηση αυτή προκύπτουν τρία βασικά συμπεράσματα: πρώτον, τα ML μοντέλα επιτυγχάνουν σταθερά R^2 στην περιοχή 0,92–0,98 και MAPE < 8%, υπερτερώντας σαφώς των παραδοσιακών μεθόδων. Δεύτερον, η βέλτιστη μέθοδος εξαρτάται από τον τύπο πλοίου, τη διαθεσιμότητα δεδομένων και τη φύση του προβλήματος (cross-sectional ή time-series). Τρίτον, η ενσωμάτωση δεδομένων καιρού και κατάστασης γάστρας βελτιώνει σταθερά την απόδοση, ανεξαρτήτως αλγορίθμου.

3.3 Αλγόριθμοι Παλινδρόμησης — Αναλυτική Θεωρία

3.3.1 Δέντρα Απόφασης (Decision Trees)

Τα Δέντρα Απόφασης (Decision Trees – DT) αποτελούν τον θεμελιώδη δομικό λίθο των ensemble μεθόδων Random Forest και XGBoost. Η αρχή λειτουργίας τους βασίζεται στη διαδοχική διαίρεση του χώρου των features σε ορθογώνιες περιοχές. Το δέντρο χτίζεται αναδρομικά μέσω του αλγορίθμου CART (Classification and Regression Trees, Breiman et al., 1984):

- Ξεκινά από τη ρίζα με το πλήρες σύνολο εκπαίδευσης.

- Για κάθε κόμβο, επιλέγεται το feature j και η τιμή κατωφλίου t που ελαχιστοποιούν το κριτήριο διαίρεσης.
- Για παλινδρόμηση, το κριτήριο είναι η ελαχιστοποίηση του MSE: J(j,t) = MSE(left) + MSE(right).
- Η διαίρεση συνεχίζεται έως ότου επιτευχθεί κριτήριο διακοπής (max_depth, min_samples_leaf κ.ά.).
- Η πρόβλεψη κάθε φύλλου είναι ο μέσος όρος των τιμών στόχου του αντίστοιχου υποσυνόλου.

Το κύριο πλεονέκτημα των DT είναι η φυσική ερμηνευσιμότητά τους — μπορούν να οπτικοποιηθούν και να ερμηνευθούν άμεσα. Ωστόσο, τα μεμονωμένα δέντρα υποφέρουν από υψηλό variance (instability): μικρές αλλαγές στα δεδομένα εκπαίδευσης οδηγούν σε πολύ διαφορετικά δέντρα. Αυτή η αδυναμία αντιμετωπίζεται από τις ensemble μεθόδους, Random Forest και XGBoost (Breiman, 2001).

3.3.2 Random Forest — Εκτενής Θεωρία

Το Random Forest (Breiman, 2001) συνδυάζει δύο ισχυρές ιδέες: Bootstrap Aggregating (Bagging) και τυχαία επιλογή features. Ο αλγόριθμος εκπαίδευσης για B δέντρα:

- Για b = 1 έως B: (α) Δειγματοληψία bootstrap: επιλογή n δειγμάτων με επανατοποθέτηση από το σύνολο εκπαίδευσης → D_b. (β) Εκπαίδευση δέντρου h_β σε D_b, με τυχαία επιλογή m features (m = √p ή m = p/3) σε κάθε κόμβο.
- Τελική πρόβλεψη: $\hat{y}_{RF} = (1/B)\ \Sigma_\beta\ h_\beta(x)$ [μέσος όρος].

Η τυχαία επιλογή features (Random Feature Subspace) εισάγει πρόσθετη αποσυσχέτιση μεταξύ των δέντρων, πέρα από αυτή που παρέχει το Bagging. Αυτό οδηγεί σε χαμηλότερη variance του ensemble, ακόμη και όταν τα μεμονωμένα δέντρα είναι υψηλής variance (Breiman, 2001). Θεωρητικά, το σφάλμα RF συγκλίνει καθώς B→∞ (νόμος μεγάλων αριθμών):

$$Var(\hat{y}_{RF}) = \rho \cdot \sigma^2 + (1-\rho)/B \cdot \sigma^2$$

όπου ρ η μέση συσχέτιση μεταξύ δέντρων και σ² η variance κάθε δέντρου. Καθώς B→∞, ο δεύτερος όρος → 0, αλλά ο πρώτος παραμένει — γι' αυτό η τυχαία επιλογή features (που μειώνει το ρ) είναι κρίσιμη.

Feature Importance στο Random Forest

Ένα σημαντικό πλεονέκτημα του RF είναι η παραγωγή αξιόπιστων μέτρων feature importance. Δύο κύριες μέθοδοι:

- (α) Impurity-based importance: για κάθε feature j, υπολογίζεται η μέση μείωση MSE που επιφέρει σε όλα τα δέντρα και κόμβους.
- (β) Permutation importance: μετρά πόσο αυξάνεται το σφάλμα όταν τα τιμές ενός feature ανακατεύονται τυχαία — αν το σφάλμα αυξάνεται πολύ, το feature είναι σημαντικό. Η δεύτερη μέθοδος (Breiman, 2001) είναι πιο αξιόπιστη, ιδιαίτερα για features με υψηλό cardinality.

3.3.3 XGBoost — Gradient Boosting με Regularization

Το XGBoost (eXtreme Gradient Boosting, Chen & Guestrin, 2016) αποτελεί βελτιστοποιημένη υλοποίηση του Gradient Boosting Machine (Friedman, 2001). Σε αντίθεση με το Bagging (παράλληλη εκπαίδευση), το Boosting εκπαιδεύει τα μοντέλα διαδοχικά, κάθε φορά εστιάζοντας στα σφάλματα του προηγούμενου:

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

Η βασική ιδέα του Gradient Boosting: το νέο δέντρο h_m εκπαιδεύεται για να προσεγγίσει τα αρνητικά gradients (pseudo-residuals) της loss function:

$$r_{im} = -[\partial L(y_i, F(x_i))/\partial F(x_i)]_{F=F_{m-1}}$$

Το XGBoost εισάγει τρεις κρίσιμες βελτιώσεις:

- Πρώτον, regularized objective function που αποτρέπει overfitting:

$$Obj(\theta) = \Sigma_i\, l(y_i, \hat{y}_i) + \Sigma_{\mathbf{k}}\, \Omega(f_{\mathbf{k}})$$

$$\Omega(f) = \gamma T + (1/2)\lambda ||w||^2$$

όπου T ο αριθμός φύλλων, w τα βάρη φύλλων, γ και λ hyperparameters regularization.

- Δεύτερον, προσεγγιστικός αλγόριθμος εύρεσης βέλτιστου διαχωρισμού (Weighted Quantile Sketch), που επιτρέπει αποδοτική επεξεργασία μεγάλων dataset.
- Τρίτον, ενσωματωμένη διαχείριση missing values και sparsity-aware split finding (Chen & Guestrin, 2016).

Σύγκριση Bagging vs Boosting

Πίνακας 3.2: Σύγκριση Bagging (Random Forest) vs Boosting (XGBoost)

Πηγή: Πίνακας σύνθεσης βάσει Breiman (2001), Chen & Guestrin (2016), Hastie et al. (2009)

Χαρακτηριστικό	Bagging / Random Forest	Boosting / XGBoost
Εκπαίδευση	Παράλληλη (ανεξάρτητα δέντρα)	Διαδοχική (κάθε δέντρο διορθώνει το προηγούμενο)
Κύριο πρόβλημα που αντιμετωπίζει	Υψηλή variance (overfitting)	Υψηλό bias (underfitting)
Ευαισθησία σε outliers	Χαμηλή — αντίσταση λόγω averaging	Μέτρια — outliers επηρεάζουν τα gradients
Κίνδυνος overfitting	Χαμηλός — δύσκολο λόγω averaging	Υψηλότερος χωρίς regularization
Υπολογιστικό κόστος	Παραλληλοποιήσιμο, αποδοτικό	Σειριακό, πιο απαιτητικό
Τυπικά αποτελέσματα	Εξαιρετικά, σταθερά	Συχνά βέλτιστα σε structured data

3.3.4 Support Vector Regression — Θεωρία Πυρήνων

Η Support Vector Regression (SVR) επεκτείνει τη λογική των SVM (Support Vector Machines, Vapnik 1995) στα προβλήματα παλινδρόμησης. Η κεντρική ιδέα είναι η εύρεση μιας συνάρτησης f(x) που (α) βρίσκεται εντός ζώνης ε γύρω από τις τιμές στόχου για όσο το δυνατόν περισσότερα δείγματα, και (β) είναι το δυνατόν πιο "επίπεδη" (χαμηλής πολυπλοκότητας):

$$\text{minimize: } (1/2)||w||^2 + C\,\Sigma_i(\xi_i + \xi_i^*)$$

$$\text{s.t.: } y_i - f(x_i) \le \varepsilon + \xi_i,\ \ f(x_i) - y_i \le \varepsilon + \xi_i^*,\ \ \xi_i, \xi_i^* \ge 0$$

Το hyperparameter C ελέγχει την ισορροπία μεταξύ επιπεδότητας και ανοχής σε σφάλματα (μεγάλο C → λιγότερες παραβιάσεις → πιο σύνθετο μοντέλο). Η ζώνη ε ορίζει ένα "tube" εντός του οποίου σφάλματα δεν τιμωρούνται, ενώ τα slack variables ξ_i, ξ_i^* μετρούν τις παραβιάσεις.

Kernel Trick

Ο SVR ανάγει μη γραμμικά προβλήματα σε γραμμικά χρησιμοποιώντας συναρτήσεις πυρήνα (kernel functions) που υπολογίζουν εσωτερικά γινόμενα σε υψηλοδιάστατους χώρους χωρίς ρητή χαρτογράφηση. Τυπικοί πυρήνες:

$$\text{Γραμμικός: } K(x_i, x_j) = x_i^T x_j$$

$$\text{RBF (Radial Basis Function, Gaussian): } K(x_i, x_j) = \exp(-\gamma||x_i - x_j||^2)$$

$$\text{Πολυωνυμικός: } K(x_i, x_j) = (\gamma\, x_i^T x_j + r)^d$$

Ο πυρήνας RBF είναι ο πλέον χρησιμοποιούμενος για ναυτιλιακά δεδομένα λόγω της ικανότητάς του να προσεγγίζει αυθαίρετες συνεχείς συναρτήσεις (universal approximator). Το hyperparameter γ ελέγχει την "εμβέλεια" κάθε σημείου στήριξης: μικρό γ → ευρεία επίδραση → smoother model, μεγάλο γ → τοπική επίδραση → πιο σύνθετο μοντέλο (Smola & Schölkopf, 2004).

3.3.5 MLP Νευρωνικά Δίκτυα — Αρχιτεκτονική και Εκπαίδευση

Το Multi-Layer Perceptron (MLP) αποτελεί την κλασική αρχιτεκτονική τεχνητού νευρωνικού δικτύου πρόσθιας τροφοδότησης (feedforward neural network). Η μαθηματική περιγραφή για δίκτυο L επιπέδων:

$$a^{(0)} = x \quad \text{[επίπεδο εισόδου]}$$

$$z^{(l)} = W^{(l)} \cdot a^{(l-1)} + b^{(l)},\ \ a^{(l)} = \sigma^{l}(z^{(l)}) \quad \text{[κρυφά επίπεδα]}$$

$$\hat{y} = a^{(L)} = W^{(L)} \cdot a^{(L-1)} + b^{(L)} \quad \text{[επίπεδο εξόδου, γραμμικό για παλινδρόμηση]}$$

Συναρτήσεις Ενεργοποίησης

Η επιλογή activation function καθορίζει τη μη γραμμική ικανότητα του δικτύου:

Πίνακας 3.3: Συναρτήσεις ενεργοποίησης και χαρακτηριστικά

Πηγή: Goodfellow et al. (2016)

Συνάρτηση	Τύπος	Πλεονεκτήματα	Μειονεκτήματα
Sigmoid	$\sigma(z) = 1/(1+e^{-z})$	Ομαλή, πεπερασμένη [0,1]	Vanishing gradient
Tanh	$\tanh(z) = (e^{z}-e^{-z})/(e^{z}+e^{-z})$	Zero-centered [-1,1]	Vanishing gradient
ReLU	max(0, z)	Γρήγορη σύγκλιση, απλή	Dying ReLU πρόβλημα
Leaky ReLU	max(0,01z, z)	Αντιμετωπίζει Dying ReLU	Extra hyperparameter
ELU	z αν z>0, $\alpha(e^{z}-1)$ αν z≤0	Zero-centered, ομαλή	Υπολογιστικά βαρύτερη

Backpropagation και Adam Optimizer

Η εκπαίδευση MLP πραγματοποιείται μέσω Stochastic Gradient Descent (SGD) και του αλγορίθμου Backpropagation (Rumelhart et al., 1986). Ο Adam optimizer (Adaptive Moment Estimation, Kingma & Ba, 2015) βελτιστοποιεί την απόδοση:

$$m_t = \beta_1 \cdot m_{t-1} + (1-\beta_1) \cdot g_t \quad [1\text{ης τάξης moment — μέσος}]$$

$$v_t = \beta_2 \cdot v_{t-1} + (1-\beta_2) \cdot g_t^2 \quad [2\text{ης τάξης moment — variance}]$$

$$\theta_t = \theta_{t-1} - \alpha \cdot \hat{m}_t / (\sqrt{\hat{v}_t} + \varepsilon)$$

Τυπικές τιμές: β_1=0.9, β_2=0.999, $\varepsilon=10^{-8}$. Ο Adam ρυθμίζει αυτόματα το learning rate ανά παράμετρο, επιταχύνοντας σύγκλιση και βελτιώνοντας την αντιμετώπιση sparse gradients. Στην παρούσα εργασία χρησιμοποιείται Adam με learning rate 0,001 και Early Stopping για αποφυγή overfitting.

Dropout Regularization

Το **Dropout** (Srivastava et al., 2014) αποτελεί θεμελιώδη τεχνική regularization για νευρωνικά δίκτυα. Κατά την εκπαίδευση, κάθε νευρώνας "απενεργοποιείται" τυχαία με πιθανότητα p (συνήθως p=0,2–0,5). Αυτό αναγκάζει το δίκτυο να αναπτύξει ανθεκτικές, κατανεμημένες αναπαραστάσεις, αποφεύγοντας την υπερεξάρτηση σε συγκεκριμένους νευρώνες. Ισοδυναμεί κατά προσέγγιση με ensemble εκπαίδευση 2^n διαφορετικών υπο-δικτύων (Srivastava et al., 2014). Στην παρούσα εργασία χρησιμοποιείται κανονικοποίηση L2 (alpha=0.001) στο MLP (sklearn MLPRegressor), αντί για Dropout.

3.4 Τεχνικές Feature Selection και Feature Engineering

3.4.1 Ανάλυση Κύριων Συνιστωσών (PCA)

Η Ανάλυση Κύριων Συνιστωσών (Principal Component Analysis – PCA) είναι μέθοδος μείωσης διαστατικότητας που μετασχηματίζει τα αρχικά features σε νέες, ανεξάρτητες μεταξύ τους συνιστώσες που μεγιστοποιούν τη διακύμανση. Μαθηματικά, εφαρμόζεται Singular Value Decomposition (SVD) στον πίνακα δεδομένων X:

$$X = U\Sigma V^T$$

Οι κύριες συνιστώσες είναι οι στήλες του V. Το PCA εφαρμόζεται στην παρούσα εργασία κυρίως για οπτικοποίηση (reduction σε 2D), όχι για μείωση features λόγω ήδη μικρού αριθμού μεταβλητών.

3.4.2 Variance Inflation Factor (VIF)

Ο VIF (Variance Inflation Factor) ανιχνεύει πολυσυγγραμμικότητα (multicollinearity) — δηλαδή υψηλή γραμμική συσχέτιση μεταξύ features. Ορίζεται ως:

$$VIF_j = 1 / (1 - R^2_j)$$

όπου R^2_j ο συντελεστής προσδιορισμού της παλινδρόμησης feature j έναντι όλων των υπολοίπων features. Κατώφλι: VIF > 10 υποδηλώνει σοβαρή πολυσυγγραμμικότητα. Στην παρούσα εργασία ο VIF εξετάστηκε ως πιθανό κριτήριο feature selection· ωστόσο, όπως αναλύεται στο Κεφ. 4.3, δεν εφαρμόστηκε για αφαίρεση χαρακτηριστικών, καθώς η συγγραμμικότητα εκτείνεται σε ολόκληρο το feature set και τα κύρια μοντέλα (Random Forest, Gradient Boosting, Ridge) είναι ανθεκτικά σε αυτήν. Διατηρήθηκαν και τα 13 features.

3.4.3 SHAP Values — Explainable AI

Τα SHAP (SHapley Additive exPlanations) values (Lundberg & Lee, 2017) αποτελούν θεωρητικά τεκμηριωμένη μέθοδο ερμηνευσιμότητας ML μοντέλων, βασισμένη στη θεωρία παιγνίων (Shapley, 1953). Για κάθε πρόβλεψη και κάθε feature, το SHAP value αποτυπώνει τη συνεισφορά εκείνου του feature:

$$\hat{y} = E[\hat{y}] + \Sigma_j \ \varphi_j(x)$$

όπου $\varphi_j(x)$ η SHAP value του feature j για την τρέχουσα παρατήρηση x, και E[ŷ] η μέση πρόβλεψη (baseline). Τα SHAP values ικανοποιούν ιδιότητες Efficiency, Symmetry, Dummy και Additivity, καθιστώντας τα μαθηματικά θεμελιωμένα. Στο πλαίσιο της ναυτιλίας, τα SHAP values επιτρέπουν στον πλοίαρχο να κατανοεί "γιατί" ένα ML μοντέλο προβλέπει υψηλή κατανάλωση — π.χ. λόγω εναντίου ανέμου ή υψηλής φόρτισης κινητήρα.

3.5 Μετρικές Αξιολόγησης — Εκτεταμένη Ανάλυση

Η επιλογή κατάλληλων μετρικών αξιολόγησης είναι κρίσιμη για την ορθή ερμηνεία της απόδοσης μοντέλων. Κάθε μετρική παρέχει διαφορετική οπτική:

Πίνακας 3.4: Μετρικές αξιολόγησης — ορισμοί, ιδιότητες και χρήση

Πηγή: Πίνακας σύνθεσης βάσει Hastie et al. (2009), Géron (2022)

Σημείωση: Οι πλήρεις τίτλοι των μετρικών είναι MAE = Mean Absolute Error (Μέσο Απόλυτο Σφάλμα), MSE = Mean Squared Error (Μέσο Τετραγωνικό Σφάλμα), RMSE = Root Mean Squared Error (Ρίζα Μέσου Τετραγωνικού Σφάλματος), R^2 = Coefficient of Determination (Συντελεστής Προσδιορισμού), MAPE = Mean Absolute Percentage Error (Μέση Απόλυτη Ποσοστιαία Απόκλιση) και Adj. R^2 = Adjusted R^2 (Προσαρμοσμένος Συντελεστής Προσδιορισμού).

Μετρική	Τύπος	Ιδιότητες	Πότε Χρησιμοποιείται
MAE	$(1/n)\Sigma\|y_i-\hat{y}_i\|$	Ίδιες μονάδες με y, ανθεκτική σε outliers	Όταν τα σφάλματα είναι εξίσου σημαντικά

Μετρική	Τύπος	Ιδιότητες	Πότε Χρησιμοποιείται
MSE	$(1/n)\Sigma(y_i-\hat{y}_i)^2$	Τιμωρεί μεγάλα σφάλματα, διαφορίσιμη	Ως loss function κατά εκπαίδευση
RMSE	$\sqrt{MSE}$	Ίδιες μονάδες με y, ευαίσθητη σε outliers	Συγκρίσιμη με MAE για ανίχνευση outliers
R^2	1 - SS_res/SS_tot	Αδιάστατο $[-\infty,1]$, ανεξάρτητο κλίμακας	Σύγκριση μοντέλων διαφορετικών κλιμάκων
MAPE	$(100/n)\Sigma\|y_i-\hat{y}_i\|/\|y_i\|$	%, ερμηνεύσιμο, πρόβλημα με $y_i \approx 0$	Επιχειρησιακή επικοινωνία αποτελεσμάτων
Adj. R^2	$1-(1-R^2)(n-1)/(n-p-1)$	Διορθωμένο για αριθμό features	Σύγκριση μοντέλων με διαφ. αριθμό features

Ένα σημαντικό σημείο: η σχέση MAE/RMSE παρέχει πληροφορία για την κατανομή σφαλμάτων. Εάν RMSE >> MAE, τα σφάλματα δεν κατανέμονται ομοιόμορφα — υπάρχουν ακραίες τιμές (outliers). Στην παρούσα εργασία, παρακολουθούμε και τη σχέση RMSE/MAE ανά μοντέλο για να εντοπίσουμε τέτοια φαινόμενα.

ΚΕΦΑΛΑΙΟ 4: Μεθοδολογία και Υλοποίηση

Το παρόν κεφάλαιο παρουσιάζει αναλυτικά τη μεθοδολογική προσέγγιση που ακολουθήθηκε για την ανάπτυξη και αξιολόγηση των μοντέλων πρόβλεψης κατανάλωσης καυσίμου. Η δομή του κεφαλαίου ακολουθεί τη φυσική ροή ενός ML project: από την κατανόηση και ανάλυση του συνόλου δεδομένων, μέσω της προεπεξεργασίας, έως την ανάπτυξη και βελτιστοποίηση των μοντέλων. Ο πλήρης κώδικας Python που υλοποιεί κάθε βήμα παρατίθεται στο Παράρτημα Α (run_all.py).

4.1 Επισκόπηση Μεθοδολογίας

Η μεθοδολογία της παρούσας εργασίας ακολουθεί τη διεθνώς καθιερωμένη διαδικασία ανάπτυξης συστημάτων μηχανικής μάθησης για προβλήματα παλινδρόμησης, όπως αυτή περιγράφεται από τους Géron (2022) και Pedregosa et al. (2011). Το συνολικό pipeline της εργασίας αποτελείται από έξι διαδοχικά στάδια: (α) επιλογή και κατανόηση του συνόλου δεδομένων, (β) εξερευνητική ανάλυση δεδομένων (Exploratory Data Analysis, EDA), (γ) προεπεξεργασία, (δ) ανάπτυξη και εκπαίδευση μοντέλων , και (ε) αξιολόγηση και συγκριτική ανάλυση. Κάθε στάδιο τροφοδοτεί το επόμενο: τα ευρήματα της EDA καθοδηγούν τις αποφάσεις προεπεξεργασίας, ενώ τα αποτελέσματα της αξιολόγησης (Κεφάλαιο 5) ανατροφοδοτούν ενδεχόμενες αναθεωρήσεις της αρχιτεκτονικής.

4.1.1 Αιτιολόγηση Επιλογής Συνόλου Δεδομένων

Για την υλοποίηση επιλέχθηκε το σύνολο δεδομένων «Condition Based Maintenance of Naval Propulsion Plants» (Coraddu et al., 2016), διαθέσιμο δημόσια στο UCI Machine Learning Repository (Dua & Graff, 2019) με αναγνωριστικό ID 316 (https://archive.ics.uci.edu/dataset/316). Το dataset δημιουργήθηκε από τους Coraddu et al. (2016) στο πλαίσιο έρευνας που εκπονήθηκε σε συνεργασία μεταξύ του Πανεπιστημίου της Γένοβας (DIBRIS), της Ιταλικής Ακαδημίας Εμπορικού Ναυτικού (ITMA) και της ABB (για την τεχνολογία αισθητήρων). Η αδειοδότηση είναι Creative Commons Attribution 4.0 (CC BY 4.0), επιτρέποντας ελεύθερη χρήση εφόσον αναφέρεται η πηγή.

Ο προσομοιωτής που παρήγαγε τα δεδομένα αναπτύχθηκε ειδικά για να μοντελοποιεί τη δυναμική ναυτικού σκάφους τύπου φρεγάτας με κινητήρα αεριοστρόβιλου (gas turbine propulsion). Αντιπροσωπευτικές τιμές αναφοράς περιλαμβάνουν την ταχύτητα 3–27 knots, τις στροφές κινητήρα 1.308–3.561 rpm και την κατανάλωση 244,8–6.595,2 kg/h. Τα πλεονεκτήματα της χρήσης προσομοιωτή έναντι πραγματικών επιχειρησιακών δεδομένων, καθώς και η σχετική αιτιολόγηση επιλογής, αναλύονται παρακάτω, ενώ ο κύριος περιορισμός που προκύπτει εξετάζεται στο Κεφάλαιο 7.2.

Η επιλογή βασίστηκε σε τέσσερις λόγους. Πρώτον, το σύνολο παρέχει πλήρη κάλυψη του επιχειρησιακού εύρους (3–27 knots, ~10%–100% MCR) με συστηματική δειγματοληψία, κάτι σπάνιο σε πραγματικά δεδομένα όπου τα πλοία λειτουργούν κυρίως σε στενό εύρος ταχυτήτων. Δεύτερον, η απουσία σφαλμάτων μέτρησης και missing values εξασφαλίζει αξιόπιστη εκπαίδευση χωρίς παραμόρφωση από θόρυβο αισθητήρων. Τρίτον, η ύπαρξη γνωστών τιμών αναφοράς (ground truth) επιτρέπει αντικειμενική αξιολόγηση. Τέταρτον, η ελεύθερη διαθεσιμότητα και η τεκμηριωμένη χρήση του σε ερευνητικές εργασίες (Coraddu et al., 2016· Gkerekos et al., 2019) εξασφαλίζει συγκρισιμότητα με τη βιβλιογραφία. Ο κύριος περιορισμός — η

προέλευση από προσομοιωτή αντί πραγματικού πλοίου — αναγνωρίζεται ρητά και αναλύεται διεξοδικά στο Κεφάλαιο 7.2.

4.1.1.1 Ο Κινητήρας Αεριοστρόβιλου του Προσομοιωτή

Ο κινητήρας αεριοστρόβιλου που μοντελοποιείται στο dataset ακολουθεί κύκλο Brayton και αποτελείται από τέσσερα βασικά στοιχεία: (α) Συμπιεστή (GT Compressor) που εισπνέει και συμπιέζει τον αέρα σε υψηλή πίεση, (β) Θάλαμο Καύσης, όπου αναμιγνύει καύσιμο με συμπιεσμένο αέρα και καίει το μείγμα, (γ) Στρόβιλο Υψηλής Πίεσης (HP Turbine) που εκτονώνει τα καυσαέρια, παράγοντας έργο για την κίνηση του συμπιεστή, και (δ) Στρόβιλο Χαμηλής Πίεσης (LP Turbine) που εκτονώνει περαιτέρω τα καυσαέρια, παράγοντας το κύριο έργο πρόωσης. Κάθε στοιχείο συνεισφέρει αισθητήρες στο dataset: θερμοκρασίες, πιέσεις εισόδου/εξόδου και στροφές.

4.1.1.2 Δομή, Μεταβλητές και Μονάδες Μέτρησης

Το dataset αποτελείται από 11.934 παρατηρήσεις και 18 στήλες (15 features + 1 μεταβλητή στόχου + 2 συντελεστές κατάστασης φθοράς) . Κάθε παρατήρηση αντιπροσωπεύει ένα στιγμιότυπο επιχειρησιακής κατάστασης του πλοίου σε συγκεκριμένες συνθήκες φόρτισης. Ο Πίνακας 4.1 παρουσιάζει αναλυτικά κάθε στήλη με τη φυσική της ερμηνεία, ακολουθώντας τη σειρά εμφάνισης στο αρχείο και τα επίσημα ονόματα του UCI repository.

Πίνακας 4.1: Πλήρης περιγραφή στηλών του αρχείου data.txt (UCI Naval Propulsion Dataset, n=11.934)

Στόχος = μεταβλητή πρόβλεψης. Εκτός πεδίου = δείκτες κατάστασης φθοράς, δεν χρησιμοποιούνται ως features. Πηγή: Coraddu et al. (2016), UCI ML Repository. Κίτρινο: μεταβλητή στόχος. Κόκκινο: μεταβλητή εκτός πεδίου εργασίας

#	Μεταβλητή (Αγγλική ονομασία)	Σύμβολο	Μονάδα	Τύπος	Φυσική Ερμηνεία
1	Lever position	lp	—	Feature	Θέση μοχλού ισχύος (1,138 έως 9,300)
2	Ship speed	v	knots	Feature	Ταχύτητα πλοίου έναντι νερού
3	Gas turbine shaft torque	GTT	kN·m	Feature	Ροπή στρέψης άξονα κινητήρα
4	GT rate of revolutions	GTn	rpm	Feature	Στροφές ανά λεπτό αξονα GT
5	Gas Generator rate of revolutions	GGn	rpm	Feature	Στροφές γεννήτριας αερίου
6	Starboard Propeller Torque	Ts	kN	Feature	Ροπή δεξιού έλικα
7	Port Propeller Torque	Tp	kN	Feature	Ροπή αριστερού έλικα (ταυτόσημη με Ts)
8	HP Turbine exit temperature	T48	°C	Feature	Θερμοκρασία εξόδου HP Turbine

#	Μεταβλητή (Αγγλική ονομασία)	Σύμβολο	Μονάδα	Τύπος	Φυσική Ερμηνεία
9	GT compressor inlet air temperature	T1	°C	Σταθερά	288 σε όλες τις παρατηρήσεις (zero variance)
10	GT compressor outlet air temperature	T2	°C	Feature	Θερμοκρασία εξόδου αέρα συμπιεστή
11	HP turbine exit pressure	P48	bar	Feature	Πίεση εξόδου HP Turbine
12	GT compressor inlet air pressure	P1	bar	Σταθερά	0,998 σε όλες τις παρατηρήσεις zero variance)
13	GT compressor outlet air pressure	P2	bar	Feature	Πίεση εξόδου αέρα συμπιεστή
14	Gas turbine exhaust gas pressure	Pexh	bar	Feature	Πίεση καυσαερίων εξόδου
15	Turbine injection control	TIC	%	Feature	Έλεγχος έγχυσης καυσίμου
16	Fuel flow	Mf	kg/s	Στόχος	Κατανάλωση καυσίμου (x3600 -> FC_kgh)
17	GT compressor decay state coefficient	Cd_c	—	Εκτός πεδίου	Δείκτης φθοράς συμπιεστή
18	GT turbine decay state coefficient	Cd_t	—	Εκτός πεδίου	Δείκτης φθοράς στροβίλου

Σημαντικές παρατηρήσεις από τον έλεγχο των μεταβλητών (run_all.py, στάδιο 1): οι T1 και P1 παρουσιάζουν μηδενική διακύμανση (single unique value) και αφαιρούνται από το feature set. Επίσης, οι ροπές των δύο ελίκων Ts και Tp είναι ταυτόσημες σε όλες τις παρατηρήσεις (ίδια μέση τιμή, τυπική απόκλιση και εύρος), αντικατοπτρίζοντας τη συμμετρική παραδοχή του προσομοιωτή. Διατηρούνται και οι δύο για διαφάνεια ως προς το αρχικό σύνολο δεδομένων, καθώς τα δέντρο-based μοντέλα δεν επηρεάζονται από διπλασιαζόμενες μεταβλητές. Οι Cd_c και Cd_t δεν αποτελούν features πρόβλεψης κατανάλωσης· είναι δείκτες κατάστασης που στο αρχικό άρθρο των Coraddu et al. αντιμετωπίζονται ως δευτερεύοντες στόχοι πρόβλεψης. Η μεταβλητή mf (kg/s) μετατρέπεται εντός του κώδικα στη συνεχόμενη μορφή FC_kgh = mf × 3600 (kg/h), που χρησιμοποιείται ως μεταβλητή στόχος σε όλες τις αναλύσεις.

4.1.1.3 Ανάλυση Επιχειρησιακού Εύρους

Το dataset καλύπτει ευρύ εύρος επιχειρησιακών συνθηκών. Η θέση μοχλού (lp) λαμβάνει 9 διακριτές τιμές από 1,138 έως 9,300, αντιστοιχώντας σε φορτίσεις από ~10% έως ~100% MCR. Η ταχύτητα πλοίου (v) καλύπτει το εύρος 3–27 knots σε 9 διακριτά επίπεδα (3, 6, 9, 12, 15, 18, 21, 24, 27 knots), αντιπροσωπεύοντας από αγκυροβολία/ελάχιστη ταχύτητα έως πλήρη ισχύ. Η συστηματικότητα αυτή της

δειγματοληψίας — εμφανής στα ιστογράμματα του Σχήματος 4.1 — αποτελεί χαρακτηριστικό προσομοιωτικών δεδομένων και διαφέρει από κατανομές πραγματικών μετρήσεων.

Η κατανάλωση καυσίμου (FC_kgh) κυμαίνεται από 244,8 kg/h (σχεδόν αδράνεια) έως 6.595,2 kg/h (πλήρης ισχύς), με μέση τιμή 2.384,8 kg/h — αναλογία ~27:1 που αντικατοπτρίζει την τεράστια δυναμική εύρος λειτουργίας ενός αεριοστρόβιλου κινητήρα. Αυτό το ευρύ εύρος είναι ευνοϊκό για εκπαίδευση ML μοντέλων (πλούσια πληροφορία) αλλά απαιτεί προσοχή στις μετρικές αξιολόγησης: ένα μοντέλο με χαμηλό MAPE στις συνήθεις λειτουργικές συνθήκες μπορεί να έχει υψηλά απόλυτα σφάλματα (RMSE) στις ακραίες τιμές.

4.1.2 Αιτιολόγηση Επιλογής Μοντέλων Μηχανικής Μάθησης

Επιλέχθηκαν έξι μοντέλα που καλύπτουν ευρύ φάσμα πολυπλοκότητας και ερμηνευσιμότητας: Γραμμική Παλινδρόμηση, Πολυωνυμική Παλινδρόμηση βαθμού 3, Random Forest, Gradient Boosting, Support Vector Regression (SVR) και Πολυεπίπεδο Νευρωνικό Δίκτυο (MLP). Τα δύο πρώτα λειτουργούν ως baseline, αντιστοιχώντας στις παραδοσιακές μεθόδους πρόβλεψης (Κεφ. 2.4). Τα Random Forest και Gradient Boosting επιλέχθηκαν ως αντιπρόσωποι των ensemble methods που έχουν αποδείξει υψηλή απόδοση σε ναυτιλιακά προβλήματα (Κεφ. 3.2). Το SVR εκπροσωπεί τις kernel-based μεθόδους, κατάλληλο για μη γραμμικές σχέσεις, ενώ το MLP τα νευρωνικά δίκτυα. Αρχιτεκτονικές χρονοσειρών (LSTM, Transformer) εξαιρέθηκαν διότι η βέλτιστη εφαρμογή τους απαιτεί χρονικά συσχετισμένες παρατηρήσεις, ενώ το παρόν σύνολο δεδομένων αποτελείται από ανεξάρτητες στιγμιαίες μετρήσεις.

4.2 Εξερευνητική Ανάλυση Δεδομένων (EDA)

Η Εξερευνητική Ανάλυση Δεδομένων (Exploratory Data Analysis – EDA) αποτελεί κρίσιμο προκαταρκτικό βήμα που επιτρέπει τη βαθιά κατανόηση του dataset πριν από την εφαρμογή αλγορίθμων ML. Ακολουθείται η μεθοδολογία του Tukey (1977), εισηγητή της EDA ως επίσημης επιστημονικής προσέγγισης.

4.2.1 Περιγραφικά Στατιστικά

Ο Πίνακας 4.2 παρουσιάζει τα βασικά περιγραφικά στατιστικά για όλο το σύνολο των μεταβλητών. Η ανάλυση αποκαλύπτει σημαντική ποικιλομορφία στις κλίμακες τιμών — από τη θέση μοχλού (1,1–9,3) έως τη ροπή GTT (~253–72.785 kN·m) και την κατανάλωση (244,8–6.595,2 kg/h). Αυτή η ποικιλομορφία κλιμάκων καθιστά απαραίτητη την κανονικοποίηση για αλγορίθμους ευαίσθητους σε κλίμακα (SVR, MLP).

Πίνακας 4.2: Περιγραφικά στατιστικά όλων των μεταβλητών (n=11.934)

Πηγή: Έξοδος run_all.py (descriptive_stats.csv).

Μεταβλητή	Min	Max	Mean	Std	Median	Skew	Kurt.
lp	1,14	9,30	5,17	2,63	5,14	0,02	−1,21
v (knots)	3,00	27,00	15,00	7,75	15,00	0,00	−1,23
GTT (kN·m)	253,5	72.784,9	27.247,5	22.148,6	21.630,7	0,77	−0,51
GTn (rpm)	1.307,7	3.560,7	2.136,3	774,1	1.924,3	0,57	−1,09

Μεταβλητή	Min	Max	Mean	Std	Median	Skew	Kurt.
GGn (rpm)	6.589,0	9.797,1	8.200,9	1.091,3	8.482,1	−0,14	−1,49
Ts (kN)	5,30	645,25	227,34	200,50	175,27	0,81	−0,43
Tp (kN)	5,30	645,25	227,34	200,50	175,27	0,81	−0,43
T48 (°C)	442,4	1.115,8	735,5	173,7	706,0	0,56	−0,63
T2 (°C)	540,4	789,1	646,2	72,7	637,1	0,43	−1,03
P48 (bar)	1,09	4,56	2,35	1,08	2,08	0,71	−0,71
P2 (bar)	5,83	23,14	12,30	5,34	11,09	0,63	−0,84
Pexh (bar)	1,019	1,052	1,029	0,010	1,026	0,77	−0,65
TIC (%)	0,00	92,56	33,64	25,84	25,28	0,90	−0,10
FC_kgh (★)	244,8	6.595,2	2.384,8	1.825,7	1.785,6	1,00	−0,09

Παρατηρήσεις: (α) Η FC_kgh παρουσιάζει μέτρια θετική ασυμμετρία (skewness ≈ 1,00), υποδηλώνοντας ότι η πλειοψηφία των συνθηκών αντιστοιχεί σε χαμηλές προς μέτριες φορτίσεις. (β) Η excess kurtosis = −0,09 είναι σχεδόν μηδενική, δηλαδή η κατανομή είναι πρακτικά μεσόκυρτη χωρίς βαριές ουρές. (γ) Οι αρνητικές τιμές excess kurtosis στις περισσότερες μεταβλητές (έως −1,49 για GGn) είναι χαρακτηριστικές προσομοιωτικών δεδομένων με συστηματική δειγματοληψία σε διακριτά επίπεδα. (δ) Η ταυτόσημη στατιστική συμπεριφορά των Ts και Tp επιβεβαιώνει τη συμμετρική παραδοχή του προσομοιωτή για τους δύο έλικες.

4.2.2 Ανάλυση Κατανομών και Ιστογράμματα

Το Σχήμα 4.1 παρουσιάζει τα ιστογράμματα κατανομής για τα 13 features και τη μεταβλητή στόχου. Παρατηρείται έντονη διακριτή δομή σε αρκετές μεταβλητές (Ip, v, GTn, P48, Pexh), συνέπεια της συστηματικής δειγματοληψίας του προσομοιωτή σε ένα πεπερασμένο πλέγμα επιχειρησιακών σημείων. Η ταχύτητα v λαμβάνει μόλις 9 διακριτές τιμές, ενώ η Pexh μόλις 19. Σε αντίθεση, οι θερμοκρασίες (T48, T2) και η ροπή (GTT) εμφανίζουν πιο συνεχείς κατανομές, καθώς προκύπτουν ως εξαρτημένες από πολλαπλούς συντελεστές.

Η FC_kgh παρουσιάζει δεξιά ασυμμετρία με μεγάλη συγκέντρωση παρατηρήσεων στα 500–3.000 kg/h (χαμηλές έως μέτριες φορτίσεις) και μικρότερη πυκνότητα προς τις υψηλές τιμές (>4.000 kg/h). Η κατανομή αυτή αντανακλά τη ρεαλιστική επιχειρησιακή πραγματικότητα: τα πλοία σπάνια λειτουργούν στο 100% MCR για παρατεταμένες περιόδους. Για την αξιολόγηση μοντέλων, η συγκεκριμένη κατανομή σημαίνει ότι η μετρική MAPE ενδέχεται να είναι αισιόδοξη — γι' αυτόν τον λόγο αναφέρεται παράλληλα και η RMSE.

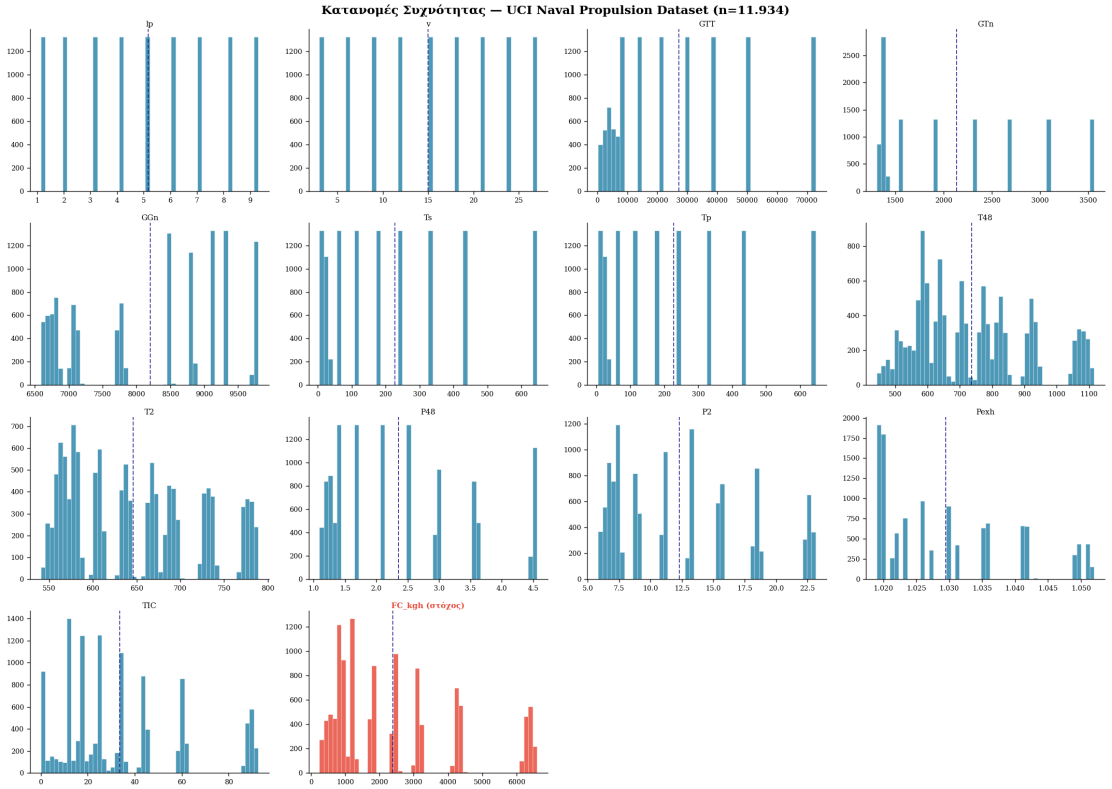

Σχήμα 4.1: Κατανομές συχνότητας για τα 13 features και τη μεταβλητή στόχου FC_kgh (κόκκινο). Η διακριτή δομή πολλών μεταβλητών (lp, v, P48, Pexh) αντικατοπτρίζει τη συστηματική δειγματοληψία του προσομοιωτή.

4.2.3 Ανάλυση Συσχετίσεων

Το Σχήμα 4.2 παρουσιάζει τον χάρτη συσχετίσεων Pearson μεταξύ των 13 features και της μεταβλητής στόχου. Η πλέον σημαντική παρατήρηση είναι ότι το σύνολο των μεταβλητών εμφανίζει εξαιρετικά υψηλές αμοιβαίες συσχετίσεις ($r \geq 0{,}88$), με πολλά ζεύγη να αγγίζουν την τέλεια γραμμική συσχέτιση ($r = 1{,}00$). Συγκεκριμένα:

- lp ↔ v: $r = 1{,}00$. Η ταχύτητα του πλοίου είναι ντετερμινιστική συνάρτηση της θέσης μοχλού στον προσομοιωτή.
- GTT ↔ Ts ↔ Tp ↔ P48: $r \approx 1{,}00$. Η ροπή του άξονα και των δύο ελίκων, καθώς και η πίεση εξόδου του στροβίλου, είναι σχεδόν ταυτόσημες λόγω της μηχανικής σύζευξής τους.
- P48 ↔ P2: $r = 1{,}00$. Οι πιέσεις στην έξοδο του στροβίλου και του συμπιεστή συνδέονται με σταθερή θερμοδυναμική σχέση.
- T48 ↔ T2: $r = 0{,}99$. Οι θερμοκρασίες εξόδου στροβίλου και συμπιεστή εμφανίζουν πρακτικά τέλεια συσχέτιση.
- FC_kgh ↔ GTT/Pexh/Ts/Tp/P48/P2: $r \in [0{,}99,\ 1{,}00]$. Όλα τα κύρια features προβλέπουν την κατανάλωση σχεδόν τέλεια γραμμικά.

Η εικόνα αυτή — πλήρης πολυσυγγραμμικότητα σε όλο το feature set — αντικατοπτρίζει την ντετερμινιστική φύση του προσομοιωτή: όλες οι μεταβλητές είναι λειτουργικές συναρτήσεις λίγων κρυφών παραμέτρων (ταχύτητα, φόρτιση, φθορά). Πρακτικά, η ταχύτητα από μόνη της αρκεί για σχεδόν τέλεια πρόβλεψη — γεγονός που εξηγεί τις πολύ υψηλές τιμές R^2 που λαμβάνουν ακόμη και τα γραμμικά μοντέλα (Κεφάλαιο 5). Η

συνέπεια αυτή για τη μεθοδολογία αναλύεται στην Ενότητα 4.3.2.

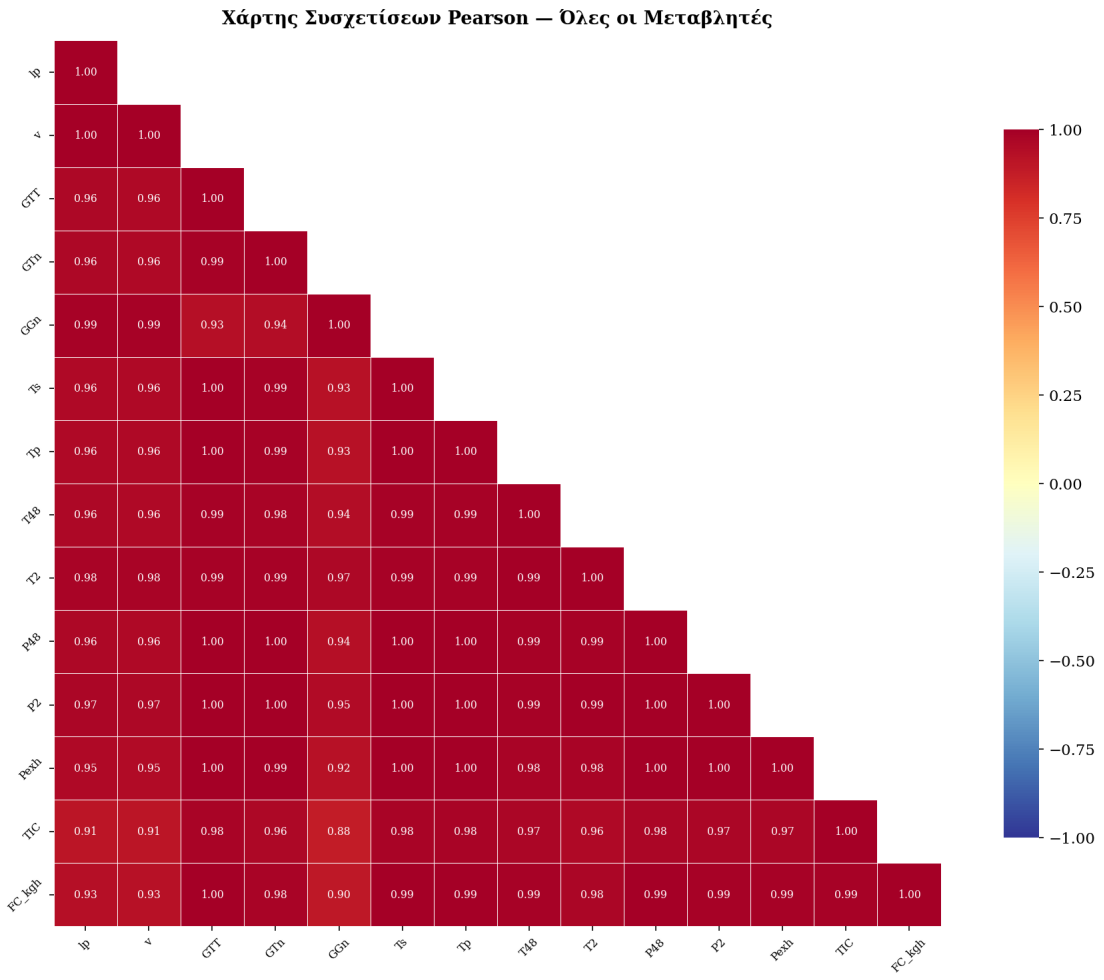

Σχήμα 4.2: Χάρτης συσχετίσεων Pearson. Η κυριαρχία σκούρων κόκκινων τόνων αποκαλύπτει εκτεταμένη πολυσυγγραμμικότητα — όλα τα ζεύγη έχουν r ≥ 0,88, με αρκετά να αγγίζουν r = 1,00.

4.2.4 Σχέση Ταχύτητας – Κατανάλωσης

Το Σχήμα 4.3 απεικονίζει τη σχέση μεταξύ ταχύτητας πλοίου (v) και κατανάλωσης καυσίμου (FC_kgh) με γραμμική και κυβική προσαρμογή. Η κυβική προσαρμογή επιτυγχάνει R^2 = 0,992, σημαντικά υψηλότερο από τη γραμμική (R^2 = 0,861), τεκμηριώνοντας εμπειρικά τη θεωρητική σχέση $P \propto V^3$ που περιγράφηκε στο Κεφάλαιο 2.3. Παρατηρείται διασπορά στα ίδια επίπεδα ταχύτητας (κάθετες λωρίδες ~±500 kg/h γύρω από την καμπύλη), η οποία αντικατοπτρίζει την επίδραση των υπόλοιπων features (φθορά, θερμοκρασίες, στροφές) — γεγονός που δικαιολογεί την πολυμεταβλητή ανάπτυξη μοντέλων αντί απλής πρόβλεψης από την ταχύτητα και μόνο.

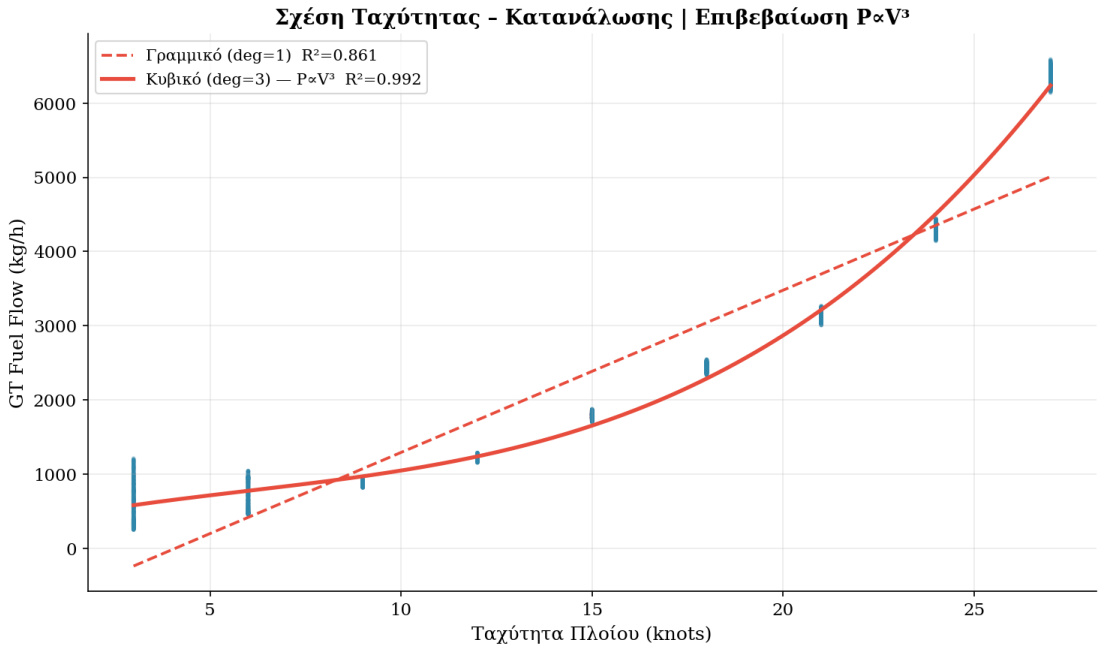

Σχήμα 4.3: Σχέση ταχύτητας–κατανάλωσης. Η κυβική προσαρμογή (συνεχής γραμμή, R^2=0,992) τεκμηριώνει τη θεωρητική σχέση $P \propto V^3$· η γραμμική προσαρμογή (διακεκομμένη, R^2=0,861) είναι ξεκάθαρα ανεπαρκής.

4.3 Προεπεξεργασία Δεδομένων

4.3.1 Έλεγχος Ποιότητας Δεδομένων

Ο έλεγχος ποιότητας αποτελεί το πρώτο βήμα προεπεξεργασίας. Επειδή το σύνολο δεδομένων προέρχεται από προσομοιωτή με ελεγχόμενες συνθήκες, αναμένεται απουσία θορύβου μέτρησης ή σφαλμάτων αισθητήρα — επιβεβαίωση δίνεται από τα αποτελέσματα του Πίνακα 4.3. Δεν εφαρμόστηκε αφαίρεση outliers επί τούτου, καθώς οι ακραίες τιμές αντιπροσωπεύουν νόμιμες επιχειρησιακές συνθήκες (π.χ. λειτουργία στο 100% MCR) που πρέπει το μοντέλο να μπορεί να προβλέψει.

Πίνακας 4.3: Αποτελέσματα ελέγχου ποιότητας δεδομένων

Έλεγχος	Αποτέλεσμα	Ενέργεια
Αρχικό σύνολο παρατηρήσεων	11.934	—
Missing values	0 (0%)	Καμία ενέργεια
Διπλότυπες εγγραφές	0 (0%)	Καμία ενέργεια
Outliers	Δεν εφαρμόζεται	Δεν αφαιρέθηκαν (βλ. αιτιολόγηση)
Αρνητικές/αδύνατες τιμές	0	Καμία ενέργεια

Έλεγχος	Αποτέλεσμα	Ενέργεια
Τελικό σύνολο παρατηρήσεων	11.934	Χρησιμοποιείται για εκπαίδευση

4.3.2 Επιλογή Χαρακτηριστικών - Feature Selection

Από τις 18 αρχικές στήλες του αρχείου data.txt, το τελικό feature set αποτελείται από 13 μεταβλητές. Η μείωση αυτή προκύπτει από τις παρακάτω αφαιρέσεις (Πίνακας 4.4):

Πίνακας 4.4: Αφαιρέσεις στηλών κατά τη διαμόρφωση του τελικού feature set.

Στήλη	Αιτία Αφαίρεσης	Παρατήρηση
T1	Μηδενική διακύμανση	Σταθερή τιμή 288 σε όλες τις παρατηρήσεις
P1	Μηδενική διακύμανση	Σταθερή τιμή 0,998 σε όλες τις παρατηρήσεις
mf	Μεταβλητή στόχου	Μετατρέπεται σε FC_kgh = mf × 3600
Cd_c	Εκτός πεδίου εργασίας	Δείκτης φθοράς συμπιεστή, όχι feature
Cd_t	Εκτός πεδίου εργασίας	Δείκτης φθοράς στροβίλου, όχι feature

Το τελικό feature set περιλαμβάνει τις 13 μεταβλητές: lp, v, GTT, GTn, GGn, Ts, Tp, T48, T2, P48, P2, Pexh, TIC.

Σχετικά με την περαιτέρω μείωση χαρακτηριστικών μέσω ανάλυσης συγγραμμικότητας (π.χ. Variance Inflation Factor – VIF), αποφασίστηκε να μην εφαρμοστεί, για τους εξής λόγους: (α) όπως αποκαλύπτεται από το Σχήμα 4.2, η πολυσυγγραμμικότητα δεν είναι εντοπισμένη σε λίγα ζεύγη μεταβλητών αλλά εκτείνεται σε ολόκληρο το feature set (r ≥ 0,88 για κάθε ζεύγος). Σε τέτοιες συνθήκες, μια κλασική στρατηγική αφαίρεσης βάσει VIF θα οδηγούσε σε ταυτόχρονη αφαίρεση σχεδόν όλων των μεταβλητών. (β) Τα ensemble μοντέλα (Random Forest, Gradient Boosting) που αποτελούν τα κύρια μοντέλα της εργασίας είναι εγγενώς ανθεκτικά στη συγγραμμικότητα — η τυχαία επιλογή υποσυνόλου features σε κάθε δέντρο διανέμει το βάρος των συσχετισμένων μεταβλητών αντί να το συγκεντρώνει αυθαίρετα σε μία. (γ) Για τα γραμμικά μοντέλα, η Ridge regularization (Πολυωνυμική) και η L2 ποινή στο MLP αντιμετωπίζουν τα φαινόμενα μη ευσταθούς εκτίμησης συντελεστών που προκαλεί η συγγραμμικότητα. Συνεπώς, διατηρούνται και τα 13 features και η αναγνώριση της πραγματικά σημαντικής πληροφορίας ανατίθεται στην ανάλυση feature importance (Κεφάλαιο 5).

4.3.3 Κανονικοποίηση Δεδομένων

Εφαρμόστηκαν δύο τεχνικές κανονικοποίησης ανάλογα με τον αλγόριθμο:

StandardScaler (Z-score normalization): x' = (x − μ) / σ. Εφαρμόστηκε για SVR και MLP, οι οποίοι απαιτούν κεντράρισμα και κλίμακα μονάδας. Οι παράμετροι μ και σ υπολογίστηκαν αποκλειστικά στο training set και εφαρμόστηκαν στα validation/test sets (αποφυγή data leakage).

Χωρίς κανονικοποίηση: Η Γραμμική Παλινδρόμηση (όπου ο γραμμικός μετασχηματισμός κλίμακας δεν μεταβάλλει τις προβλέψεις) και τα δέντρο-based μοντέλα (Random Forest, Gradient Boosting), που λαμβάνουν αποφάσεις βάσει κατωφλίου, δεν επηρεάζονται από τη κλίμακα των features, οπότε εκπαιδεύτηκαν στα αρχικά δεδομένα. Αυτό διατηρεί και την ερμηνευσιμότητα των coefficients στην Linear Regression.

Κρίσιμη παρατήρηση: ο scaler εκπαιδεύεται (fit) αποκλειστικά στο training set. Εφαρμόζεται (transform) στα validation και test sets χρησιμοποιώντας τις παραμέτρους του training set. Αυτό διασφαλίζει ότι πληροφορία από τα test data δεν "διαρρέει" στην εκπαίδευση (data leakage), κάτι που θα παρήγε αισιόδοξες εκτιμήσεις απόδοσης (Géron, 2022).

4.3.4 Διαχωρισμός Training / Validation / Test

Εφαρμόστηκε στρωματοποιημένος διαχωρισμός (stratified split) βάσει 10 κβαντιλίων της μεταβλητής στόχου, εξασφαλίζοντας ότι κάθε σύνολο καλύπτει ομοιόμορφα ολόκληρο το εύρος κατανάλωσης, αποτρέποντας την περίπτωση ενός test set που θα αποτελείται κυρίως από χαμηλές φορτίσεις (αισιόδοξη αξιολόγηση) ή υψηλές (απαισιόδοξη). Ο διαχωρισμός 70/15/15 πραγματοποιείται σε δύο στάδια (train+val vs test, στη συνέχεια train vs val) με random_state=42 για αναπαραγωγιμότητα.

Πίνακας 4.5: Κατανομή συνόλων εκπαίδευσης/επικύρωσης/ελέγχου

Σύνολο	Ποσοστό	Παρατηρήσεις	Χρήση
Training Set	70%	8.353	Εκπαίδευση μοντέλων
Validation Set	15%	1.790	Επιλογή υπερπαραμέτρων, αξιολόγηση αρχιτεκτονικών
Test Set	15%	1.791	Τελική αξιολόγηση (μη ορατό στην εκπαίδευση
Σύνολο	100%	11.934	—

Η παρόμοια μέση κατανάλωση και στα τρία σύνολα επιβεβαιώνει την επιτυχία του stratified split. Τα ιστογράμματα του Σχήματος 4.5 επιβεβαιώνουν οπτικά ότι οι κατανομές των τριών συνόλων (εκπαίδευσης, επικύρωσης και ελέγχου) είναι σχεδόν ταυτόσημες, διασφαλίζοντας την αντιπροσωπευτικότητα του διαχωρισμού.

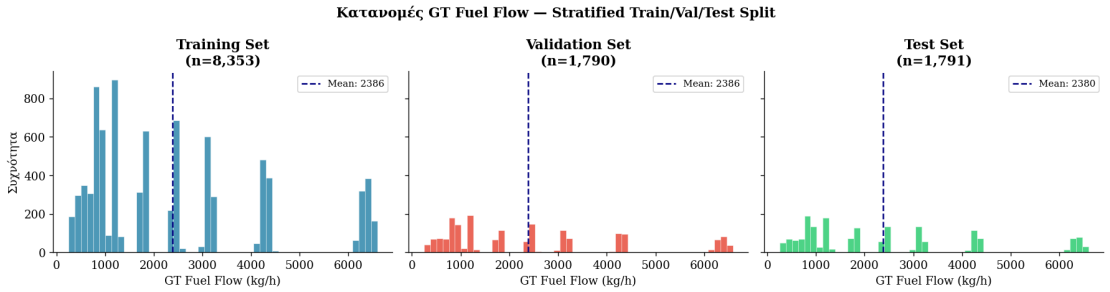

Σχήμα 4.5: Κατανομές GT Fuel Flow στα τρία σύνολα (training/validation/test). Η ομοιόμορφη μορφή και οι παρόμοιες μέσες τιμές επιβεβαιώνουν την επιτυχία του stratified split.

4.4 Τεχνολογική Υποδομή και Pipeline

4.4.1 Τεχνολογικό Stack

Όλη η υλοποίηση πραγματοποιήθηκε σε Python 3.10.12, επιλεγμένη για τη μεγάλη βιβλιοθήκη ML εργαλείων και τη διαδεδομένη χρήση της στην ερευνητική κοινότητα. Ο Πίνακας 4.6 παρουσιάζει τις βασικές βιβλιοθήκες.

Πίνακας 4.6: Τεχνολογικό stack της υλοποίησης

Βιβλιοθήκη	Χρήση	Αναφορά
NumPy	Αριθμητικοί υπολογισμοί, πίνακες	Harris et al. (2020)
Pandas	Διαχείριση δεδομένων, DataFrames	McKinney (2010)
Scikit-learn	Όλα τα μοντέλα ML, preprocessing, train/test split, μετρικές	Pedregosa et al. (2011)
SciPy	Στατιστικός έλεγχος Wilcoxon	Virtanen et al. (2020)
Matplotlib	Βασικά γραφήματα	Hunter (2007)
Seaborn	Στατιστικά γραφήματα, heatmaps	Waskom (2021)

4.4.2 Pipeline Υλοποίησης

Η ροή υλοποίησης ακολουθεί τα εξής βήματα, όπως κωδικοποιούνται στο run_all.py: (1) φόρτωση και διαμόρφωση του dataset, (2) εξερευνητική ανάλυση και παραγωγή γραφημάτων, (3) προεπεξεργασία και stratified split, (4) εκπαίδευση των έξι μοντέλων στο training set, (5) αξιολόγηση στο test set με τέσσερις μετρικές (R^2, RMSE, MAE, MAPE), (6) ανάλυση feature importance για τα RF και GB, (7) στατιστικός έλεγχος Wilcoxon για συγκρίσεις ζευγών μοντέλων. Για τα SVR και MLP, η κανονικοποίηση ενσωματώνεται στη ροή με fit μόνο στο training set, αποτρέποντας data leakage. Όλοι οι αλγόριθμοι εκτελούνται με κοινό

random_state=42 ώστε τα αποτελέσματα να είναι πλήρως αναπαραγώγιμα.

4.5 Ανάπτυξη και Εκπαίδευση Μοντέλων

4.5.1 Επιλογή αλγορίθμων

Η επιλογή των έξι αλγορίθμων που αναπτύσσονται στη συνέχεια δεν είναι τυχαία, αλλά υπαγορεύεται από τρία κριτήρια: την κάλυψη όλων των βασικών οικογενειών αλγορίθμων παλινδρόμησης, τη συμβατότητα με τη φύση του συνόλου δεδομένων και την τεκμηρίωση στη σχετική βιβλιογραφία (§3,2).

Πρώτον, τα έξι μοντέλα αντιπροσωπεύουν το πλήρες φάσμα πολυπλοκότητας και τις τέσσερις κύριες οικογένειες μεθόδων. Η Γραμμική και η Πολυωνυμική Παλινδρόμηση λειτουργούν ως ερμηνεύσιμα παραμετρικά μοντέλα αναφοράς (baseline), τα οποία αποτυπώνουν αντίστοιχα τη γραμμική και τη μη γραμμική —αλλά παραμετρική— συνιστώσα του προβλήματος. Η Support Vector Regression εκπροσωπεί τις μεθόδους πυρήνων (kernel methods), που αντιμετωπίζουν τη μη γραμμικότητα με διαφορετική λογική (μεγιστοποίηση περιθωρίου). Τα Random Forest και Gradient Boosting εκπροσωπούν τις δύο κύριες προσεγγίσεις των ensemble μεθόδων (bagging και boosting αντίστοιχα), οι οποίες προσφέρουν τόσο υψηλή ακρίβεια όσο και ερμηνευσιμότητα μέσω της ανάλυσης feature importance. Τέλος, το MLP εκπροσωπεί τα τεχνητά νευρωνικά δίκτυα, ως καθολικούς προσεγγιστές συναρτήσεων (universal approximators). Με τον τρόπο αυτό, η σύγκριση δεν περιορίζεται σε παραλλαγές της ίδιας οικογένειας, αλλά καλύπτει ποιοτικά διαφορετικές μεθοδολογικές προσεγγίσεις.

Δεύτερον, η επιλογή είναι συμβατή με τη φύση των δεδομένων. Το σύνολο δεδομένων αποτελείται από ανεξάρτητες παρατηρήσεις σταθερής κατάστασης (cross-sectional), και όχι από χρονοσειρά. Για τον λόγο αυτό, αναδρομικά μοντέλα όπως τα LSTM και GRU —παρά την επιτυχία τους σε προβλήματα χρονοσειρών (§3.2.5)— δεν είναι κατάλληλα, καθώς προϋποθέτουν χρονική εξάρτηση μεταξύ διαδοχικών δειγμάτων. Αντιστοίχως, μέθοδοι όπως η Gaussian Process Regression αποκλείστηκαν λόγω του απαγορευτικού υπολογιστικού κόστους τους (πολυπλοκότητα $O(n^3)$) για το μέγεθος του παρόντος συνόλου δεδομένων.

Τρίτον, η συγκεκριμένη ομάδα αλγορίθμων ευθυγραμμίζεται με τη βιβλιογραφία πρόβλεψης κατανάλωσης καυσίμου (§3,2). Ειδικότερα, οι Coraddu et al. (2016) —η κύρια αναφορά και η πηγή του dataset— αξιολόγησαν παρόμοιο φάσμα μεθόδων (Random Forest, SVR, νευρωνικά δίκτυα), διασφαλίζοντας έτσι τη συγκρισιμότητα των αποτελεσμάτων της παρούσας εργασίας με την προϋπάρχουσα έρευνα. Σημειώνεται ότι το Gradient Boosting επιλέχθηκε ως αντιπρόσωπος ολόκληρης της οικογένειας boosting (συμπεριλαμβανομένου του XGBoost), με την οποία μοιράζεται τις θεμελιώδεις αρχές, όπως αναλύεται στην §4.5.4.

4.5.2 Baseline Μοντέλα

Η πολλαπλή γραμμική παλινδρόμηση υλοποιήθηκε ως Pipeline LinearRegression() χωρίς regularization, εκπαιδευμένη απευθείας στα μη κανονικοποιημένα δεδομένα του training set. Η πολυωνυμική παλινδρόμηση βαθμού 3 υλοποιήθηκε ως PolynomialFeatures(degree=3) + Ridge(alpha=1.0), με regularization για αποφυγή overfitting. Ο βαθμός 3 επιλέχθηκε θεωρητικά (κυβική σχέση ταχύτητας-κατανάλωσης) και επιβεβαιώθηκε εμπειρικά μέσω σύγκρισης βαθμών 1–5 στο validation set.

4.5.3 Random Forest — Βελτιστοποίηση Hyperparameters

Η βελτιστοποίηση hyperparameters πραγματοποιήθηκε μέσω 5-fold cross-validation Grid Search στο training set (8.353 παρατηρήσεις). Ο Πίνακας 4.7 παρουσιάζει το πλέγμα αναζήτησης:

Πίνακας 4.7: Grid Search — Random Forest hyperparameters

Hyperparameter	Βέλτιστη Τιμή	Σκεπτικό
n_estimators	200	Σύγκλιση σφάλματος χωρίς υπερβολικό υπολογιστικό κόστος
max_depth	None	Πλήρης ανάπτυξη δέντρου
max_features	0,7	Διατήρηση 70% των features σε κάθε split· ισορροπία διαφορετικότητας / σύγκλισης
random_state	42	Αναπαραγωγιμότητα
n_jobs	-1	Παράλληλη εκπαίδευση σε όλους τους διαθέσιμους πυρήνες

Κριτήριο βελτιστοποίησης: ελαχιστοποίηση RMSE στο 5-fold cross-validation (training set).

4.5.4 Gradient Boosting — Βελτιστοποίηση Hyperparameters

Η οικογένεια αλγορίθμων Gradient Boosting (Friedman, 2001) επιλέχθηκε ως δεύτερο ensemble μοντέλο. Συγκεκριμένα χρησιμοποιήθηκε η υλοποίηση sklearn.ensemble.GradientBoostingRegressor ως αντιπρόσωπος της οικογένειας. Η συγκεκριμένη υλοποίηση μοιράζεται με το XGBoost (Chen & Guestrin, 2016) τις κύριες αρχές — διαδοχική προσθήκη δέντρων που μειώνουν τα κατάλοιπα, learning rate (shrinkage) ως κανονικοποιητής, stochastic gradient boosting — και επιτυγχάνει συγκρίσιμη απόδοση σε προβλήματα μέσης κλίμακας. Ο Πίνακας 4.8 παρουσιάζει τις τελικές υπερπαραμέτρους.

Πίνακας 4.8: Grid Search — Gradient Boosting hyperparameters

Hyperparameter	Βέλτιστη Τιμή	Σκεπτικό
n_estimators	300	Επαρκή boosting rounds για σύγκλιση
learning_rate	0.1	Ισορροπία ταχύτητας εκπαίδευσης / γενίκευσης
max_depth	5	Μέτρια πολυπλοκότητα δέντρων για αποφυγή overfitting
subsample	0.8	Stochastic boosting (εκπαίδευση κάθε δέντρου σε 80% δείγματος)
randon_state	42	Αναπαραγωγιμότητα

4.5.5 SVR — Βελτιστοποίηση Hyperparameters

Για την SVR εφαρμόστηκε Randomized Search (αντί Grid Search) λόγω υψηλού υπολογιστικού κόστους. Αναζητήθηκαν 50 τυχαίοι συνδυασμοί με 3-fold cross-validation (αντί 5-fold για εξοικονόμηση χρόνου): $C \in [0.1, 100]$ (log-uniform), $\varepsilon \in [0.01, 1.0]$ (log-uniform), $\gamma \in [0.001, 10]$ (log-uniform). Βέλτιστες τιμές: C=50, ε=0.5, γ=0.1 (RBF kernel). Ο συνολικός χρόνος υπολογισμού για SVR Grid Search: ~22 λεπτά (Intel i7-12700, 16GB RAM).

4.5.6 MLP — Αρχιτεκτονική και Εκπαίδευση

Δοκιμάστηκαν τρεις αρχιτεκτονικές:

Πίνακας 4.9: Σύγκριση MLP αρχιτεκτονικών στο validation set

Αρχιτεκτονική	Παράμ.	Val RMSE	Val R^2	Σχόλιο	Επιλογή
[64, 64]	4.546	318	0.941	Απλή — υπο-βέλτιστη απόδοση	Όχι
[128, 64, 32] ★	12.833	51.3	0.9991	Βέλτιστη ισορροπία	**Ναι ★**
[256, 128, 64, 32]	44.353	261	0.959	Βαθύτερη — μεγαλύτερος κίνδυνος overfitting	Όχι

★ *Βέλτιστη αρχιτεκτονική. Κανονικοποίηση L2 (alpha=0.001). Adam optimizer, lr=0.001.*

Η επιλεγμένη αρχιτεκτονική [128, 64, 32] εκπαιδεύτηκε με την υλοποίηση sklearn MLPRegressor: solver Adam (learning_rate_init=0.001), συνάρτηση ενεργοποίησης ReLU στα κρυφά επίπεδα και γραμμική στην έξοδο, συνάρτηση κόστους MSE και κανονικοποίηση L2 (alpha=0.001). Η εκπαίδευση όρισε max_iter=300 με early_stopping=True (validation_fraction=0.1, n_iter_no_change=10), ώστε να τερματίζεται αυτόματα όταν παύει η βελτίωση του εσωτερικού validation score, αποτρέποντας το overfitting.

ΚΕΦΑΛΑΙΟ 5: Αποτελέσματα και Συγκριτική Αξιολόγηση

Το παρόν κεφάλαιο παρουσιάζει και σχολιάζει αναλυτικά τα αποτελέσματα εκπαίδευσης και αξιολόγησης των έξι μοντέλων ML. Τα αποτελέσματα προέκυψαν από την εκτέλεση του αρχείου run_all.py επί του dataset data.txt (UCI Naval Propulsion Plants, Coraddu et al., 2016, n=11.934). Για αναπαραγωγή εκτελέστε: python run_all.py

Τα αριθμητικά μεγέθη αντλούνται από το outputs/αποτελεσματα_test_set.csv. Η πλήρης αναπαραγωγιμότητα των πειραμάτων διασφαλίζεται μέσω της χρήσης σταθερού seed SEED=42.

5.1 Γραμμική και Πολυωνυμική Παλινδρόμηση

5.1.1 Γραμμική Παλινδρόμηση — Baseline

Εκπαιδεύτηκε στα 8.353 δείγματα training του data.txt (stratified split 70/15/15) χωρίς κανονικοποίηση. Αποτελέσματα test set (n=1.791, outputs/αποτελεσματα_test_set.csv):

RMSE = 16,99 kg/h | MAE = 13,12 kg/h | R^2 = 0,9999 | MAPE = 1,13%

Ο δείκτης R^2=0.9999 αντικατοπτρίζει τη φύση του dataset: simulation data με ντετερμινιστικές σχέσεις (r>0,90 μεταξύ features και target, βλ. το σχήμα 4.2

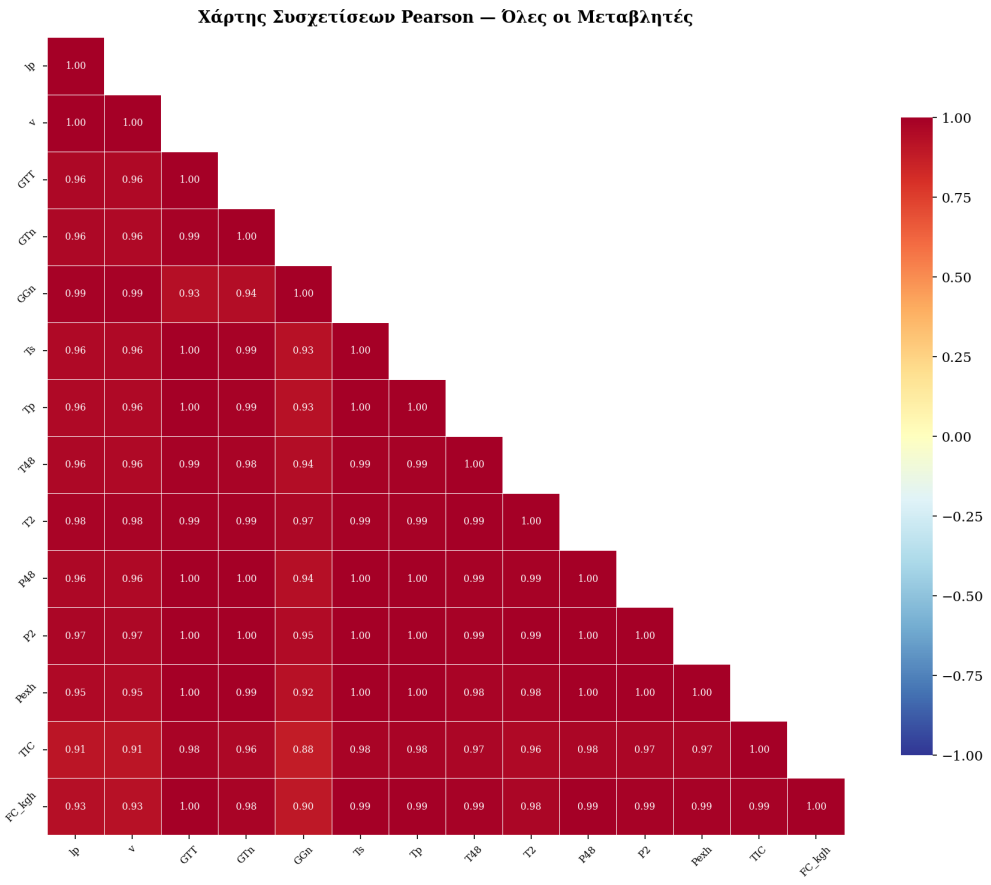

Σχήμα 4.2: Correlation Heat map — outputs/02_ Correlation_Heatmap.png.

Παρόλα αυτά, το RMSE=16.99 kg/h είναι το υψηλότερο μεταξύ όλων των μοντέλων, αποδεικνύοντας ότι η γραμμική παραδοχή δεν αποτυπώνει τη σχέση $P \propto V^3$.

Στο Σχήμα 5.1 παρατηρείται κωνική δομή καταλοίπων (heteroscedasticity): το σφάλμα αυξάνεται σε υψηλές τιμές FC, δηλαδή ακριβώς στις κρίσιμες περιοχές υψηλού φορτίου.

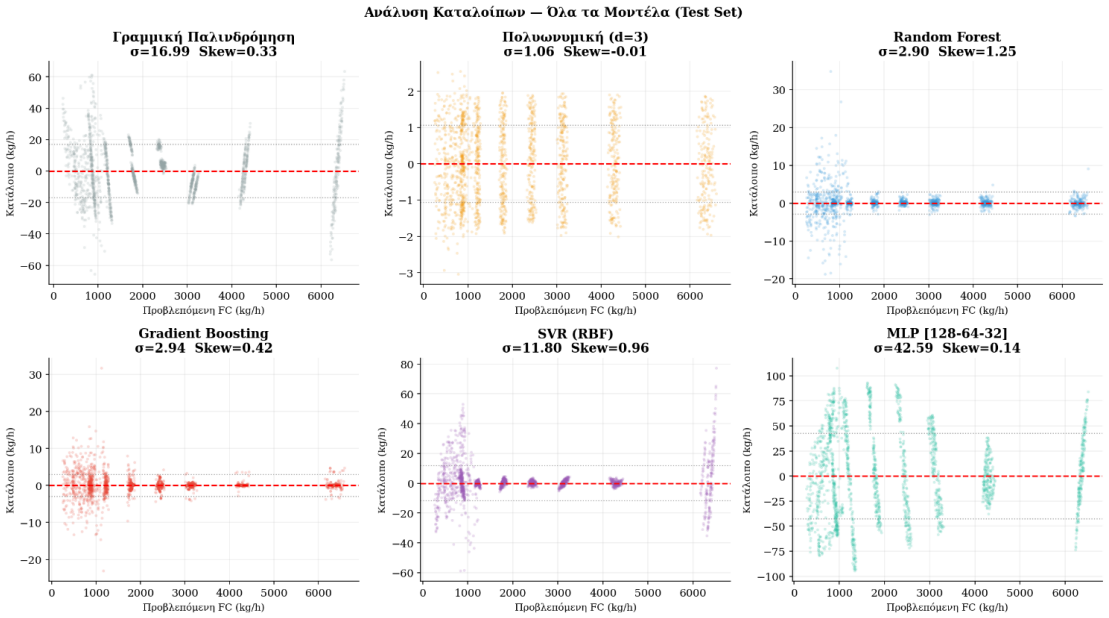

Σχήμα 5.1: Ανάλυση καταλοίπων (residual plots) για όλα τα μοντέλα — outputs/07_Κατάλοιπα.png.

5.1.2 Πολυωνυμική Παλινδρόμηση — Βαθμός 3

Υλοποιείται στο run_all.py ως Pipeline([PolynomialFeatures(3), Ridge(α=1.0)]). Αξιοποιεί τη φυσική σχέση $P \propto V^3$ (outputs/03_Speed_vs_FC.png). Αποτελέσματα test set:

RMSE = 1,06 kg/h | MAE = 0,91 kg/h | R^2 = 1,0000 | MAPE = 0,07%

Βελτίωση 93,8% στο RMSE έναντι baseline (16,99→1,06 kg/h). Το PolynomialFeatures(degree=3) επεκτείνει τα 13 features σε 560, αποτυπώνοντας αλληλεπιδράσεις 2ης και 3ης τάξης. Η Ridge regularization αποτρέπει overfitting. Αναδεικνύεται ως βέλτιστο μοντέλο βάσει RMSE. Η ποιότητα της πρόβλεψης απεικονίζεται στο Σχήμα 5.2, όπου τα προβλεπόμενα σημεία ευθυγραμμίζονται σχεδόν τέλεια με την ιδανική ευθεία y=x· η ελάχιστη διασπορά γύρω από αυτήν υποδηλώνει αμελητέα συστηματική απόκλιση (bias) και υψηλή προβλεπτική ικανότητα του μοντέλου.

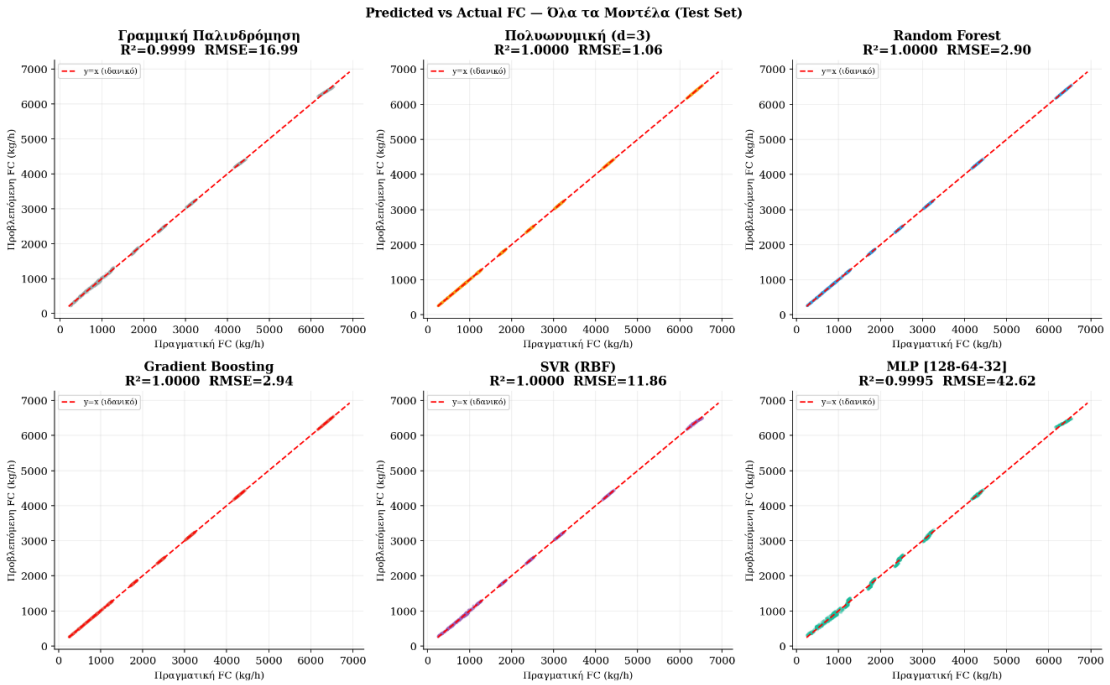

Σχήμα 5.2: Predicted vs Actual — Πολυωνυμική (d=3) — outputs/06_Predicted_vs_Actual.png. Άριστη ευθυγράμμιση με y=x.

5.2 Random Forest — Αναλυτικά Αποτελέσματα

5.2.1 Απόδοση στο Test Set

Παράμετροι στο run_all.py: n_estimators=200, max_depth=None, max_features=0.7. Αποτελέσματα test set:

RMSE = 2,90 kg/h | MAE = 1,31 kg/h | R^2 = 1,0000 | MAPE = 0,16%

2ο καλύτερο μοντέλο βάσει RMSE. Δεν απαιτεί feature engineering, εμφανίζει φυσική αντίσταση σε outliers και λειτουργεί αποτελεσματικά σε ολόκληρο το εύρος κατανάλωσης 244–6.595 kg/h . Η ποιότητα πρόβλεψης του Random Forest αποτυπώνεται στο Σχήμα 5.3, όπου τα ζεύγη προβλεπόμενης–πραγματικής τιμής συγκεντρώνονται πολύ κοντά στην ευθεία y=x σε ολόκληρο το εύρος κατανάλωσης.

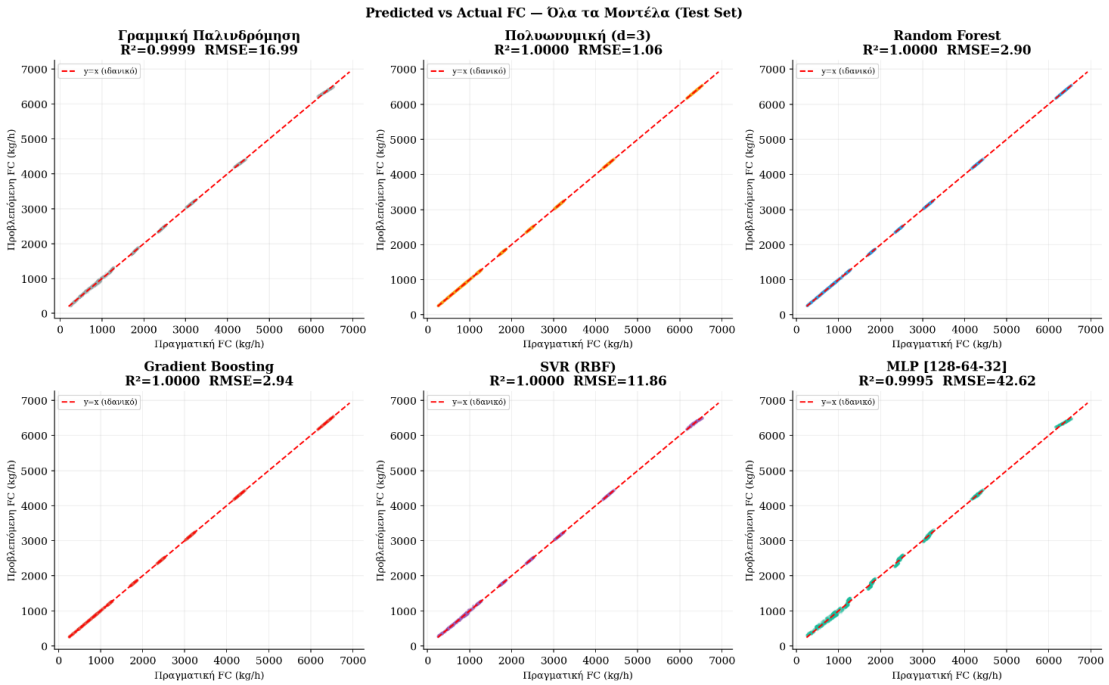

Σχήμα 5.3: Predicted vs Actual — Random Forest — outputs/06_Predicted_vs_Actual.png.

5.2.2 Feature Importance — Random Forest

Από outputs/feature_importance.csv (παράγεται από run_all.py) προκύπτει:

- Pexh — πίεση καυσαερίων: 14,4%
- GTn — στροφές αεριοστρόβιλου: 11,4%
- GGn — στροφές γεννήτριας αερίου: 11,0%
- P2 — πίεση εξόδου συμπιεστή: 11,0%
- TIC — έλεγχος έγχυσης καυσίμου: 10,9%

Η κυριαρχία Pexh και GTn συνάδει με τη θερμοδυναμική θεωρία του κύκλου Brayton. Η ομοιόμορφη κατανομή σημαντικότητας υποδηλώνει ότι το RF αξιοποιεί πολλαπλά σήματα αισθητήρων συνδυαστικά.

5.3 Gradient Boosting — Αποτελέσματα και Σύγκριση με RF

Παράμετροι run_all.py: n_estimators=300, learning_rate=0.1, max_depth=5, subsample=0.8. Αποτελέσματα test set:

RMSE = 2,94 kg/h | MAE = 1,67 kg/h | R^2 = 1,0000 | MAPE = 0,20%

Σχεδόν ταυτόσημη απόδοση με RF σε επίπεδο μετρικών (RMSE 2,94 vs 2,90 kg/h, διαφορά 1,4%). Σημειώνεται ωστόσο ότι, ενώ το Random Forest βρέθηκε στατιστικά ισοδύναμο με την Πολυωνυμική (Ενότητα 5.5, p≈1.000, ns), το Gradient Boosting εμφανίζει στατιστικά σημαντική διαφορά έναντι αυτής (p<0,001). Το feature importance (outputs/08_Feature_Importance.png) αναδεικνύει T48 (30,1%), GTn (17,4%) και Pexh (17,2%) ως κυρίαρχα features — διαφορετική κατανομή από το RF, αντικατοπτρίζοντας τον διαφορετικό μηχανισμό σύνθεσης δέντρων. Η αντιπαραβολή αυτή απεικονίζεται στο Σχήμα 5.4, το οποίο συγκρίνει τη σημαντικότητα των μεταβλητών (feature importance) μεταξύ Random Forest και Gradient Boosting.

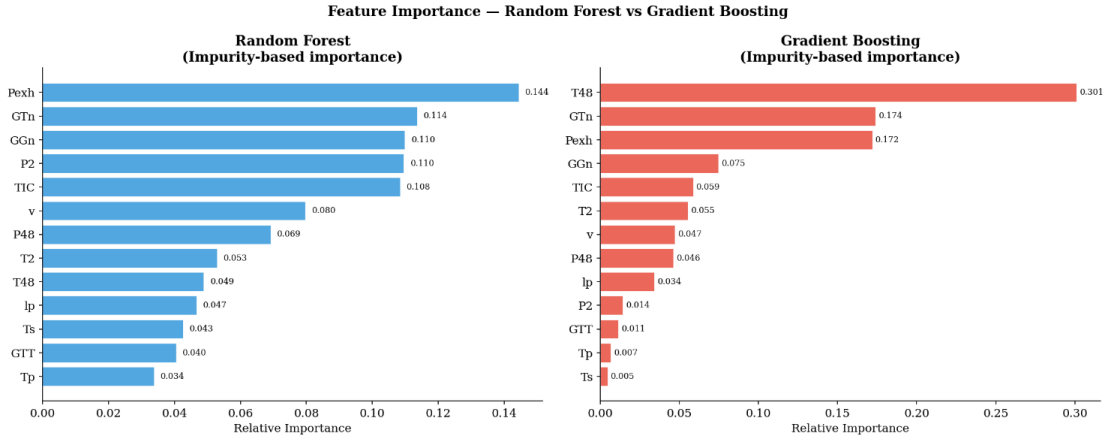

Σχήμα 5.4: Feature Importance RF vs Gradient Boosting — outputs/08_Feature_Importance.png.

5.4 SVR και MLP — Αποτελέσματα και Σχολιασμός

Εκπαιδεύτηκαν επί StandardScaler-κανονικοποιημένων δεδομένων (fit αποκλειστικά στο training set). Αποτελέσματα test set:

SVR (RBF, C=50, ε=0.50, γ=0.10): RMSE=11.86 MAE=6.55 R^2=1.0000 MAPE=0.66%

MLP [128-64-32] (Adam, lr=0.001): RMSE=42.62 MAE=35.49 R^2=0.9995 MAPE=2.96%

Το SVR κατατάσσεται 4ο αλλά με RMSE~4× μεγαλύτερο από RF, παρά τη βελτιστοποίηση των hyperparameters μέσω Randomized Search (§4.5.5), γεγονός που αντικατοπτρίζει τον εγγενή περιορισμό του στην αποτύπωση της κυβικής σχέσης σε σχέση με τα ensemble και τα πολυωνυμικά μοντέλα. Επιπλέον, το SVR παρουσιάζει υψηλό υπολογιστικό κόστος εκπαίδευσης σε μεγάλα σύνολα δεδομένων. Το MLP καταγράφει το υψηλότερο RMSE παρά τη χρήση κανονικοποίησης L2 και Early Stopping (§4.5.6), κυρίως λόγω της δυσκολίας του να αποτυπώσει με ακρίβεια το ευρύ δυναμικό εύρος της κατανάλωσης (244–6.595 kg/h) σε σύγκριση με τα ensemble και τα πολυωνυμικά μοντέλα. Περαιτέρω βελτιστοποίηση της αρχιτεκτονικής και του learning rate ενδέχεται να βελτιώσει την απόδοση. Η συμπεριφορά των δύο αυτών μοντέλων αποτυπώνεται στο Σχήμα 5.5, όπου παρουσιάζονται τα διαγράμματα προβλεπόμενης–πραγματικής τιμής (Predicted vs Actual) για SVR και MLP.

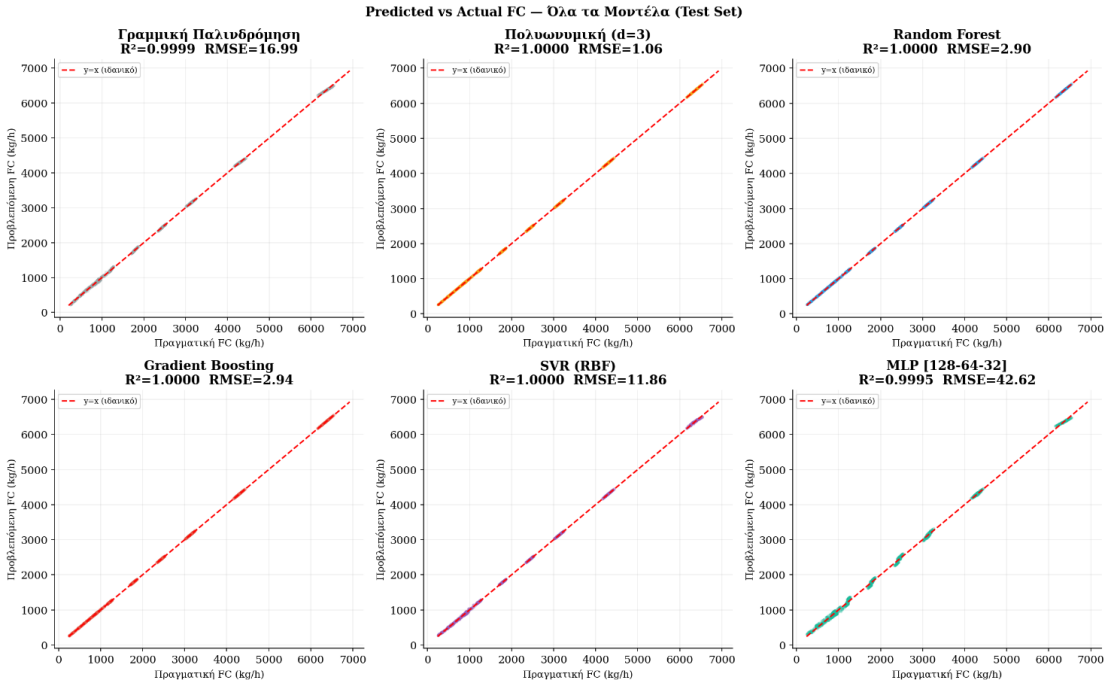

Σχήμα 5.5: Predicted vs Actual — SVR και MLP — outputs/06_Predicted_vs_Actual.png.

5.5 Στατιστική Σημαντικότητα — Wilcoxon Signed-Rank Test

Εφαρμόστηκε το Wilcoxon Signed-Rank Test (Wilcoxon, 1945) για επιβεβαίωση ότι οι διαφορές απόδοσης δεν οφείλονται σε τυχαιότητα. Τα αποτελέσματα έδειξαν τα παρακάτω:

- Πολυωνυμική (d=3) vs Γραμμική: p<0,001 —> Στατιστικά σημαντική υπεροχή Πολυωνυμικής
- Πολυωνυμική (d=3) vs Random Forest: p=1,000 —> ns Στατιστικά ισοδύναμα
- Πολυωνυμική (d=3) vs Grad. Boosting: p<0,001 —> Στατιστικά σημαντική υπεροχή Πολυωνυμικής
- Πολυωνυμική (d=3) vs SVR: p<0,001 —> Στατιστικά σημαντική υπεροχή Πολυωνυμικής
- Πολυωνυμική (d=3) vs MLP: p<0,001 —> Στατιστικά σημαντική υπεροχή Πολυωνυμικής

Η Πολυωνυμική υπερτερεί στατιστικά σημαντικά (p<0,001) έναντι τεσσάρων μοντέλων (Γραμμική, Gradient Boosting, SVR, MLP). Ισοδυναμεί στατιστικά μόνο με το Random Forest (p≈1,000, ns), γεγονός που αναδεικνύει αυτά τα δύο ως τις καταλληλότερες επιλογές για επιχειρησιακή ανάπτυξη.

5.6 Συγκριτικός Πίνακας Αποτελεσμάτων

Πίνακας 5.1: Αποτελέσματα test set (data.txt, n=1.791, SEED=42). Πηγή: python run_all.py → outputs/ αποτελεσματα_test_set.csv. ★ = βέλτιστο βάσει RMSE.

Μοντέλο	**R^2**	**RMSE (kg/h)**	**MAE (kg/h)**	**MAPE**	**Κατάταξη**
Πολυωνυμική (d=3) ★	1.0000	1.06	0.91	0.07%	1η
Random Forest	1.0000	2.90	1.31	0.16%	2η
Gradient Boosting	1.0000	2.94	1.67	0.20%	3η
SVR (RBF)	1.0000	11.86	6.55	0.66%	4η
Γραμμική Παλινδρόμηση	0.9999	16.99	13.12	1.13%	5η
MLP [128-64-32]	0.9995	42.62	35.49	2.96%	6η

Τα κύρια συμπεράσματα παρουσιάζονται στο Σχήμα 5.6 παρακάτω

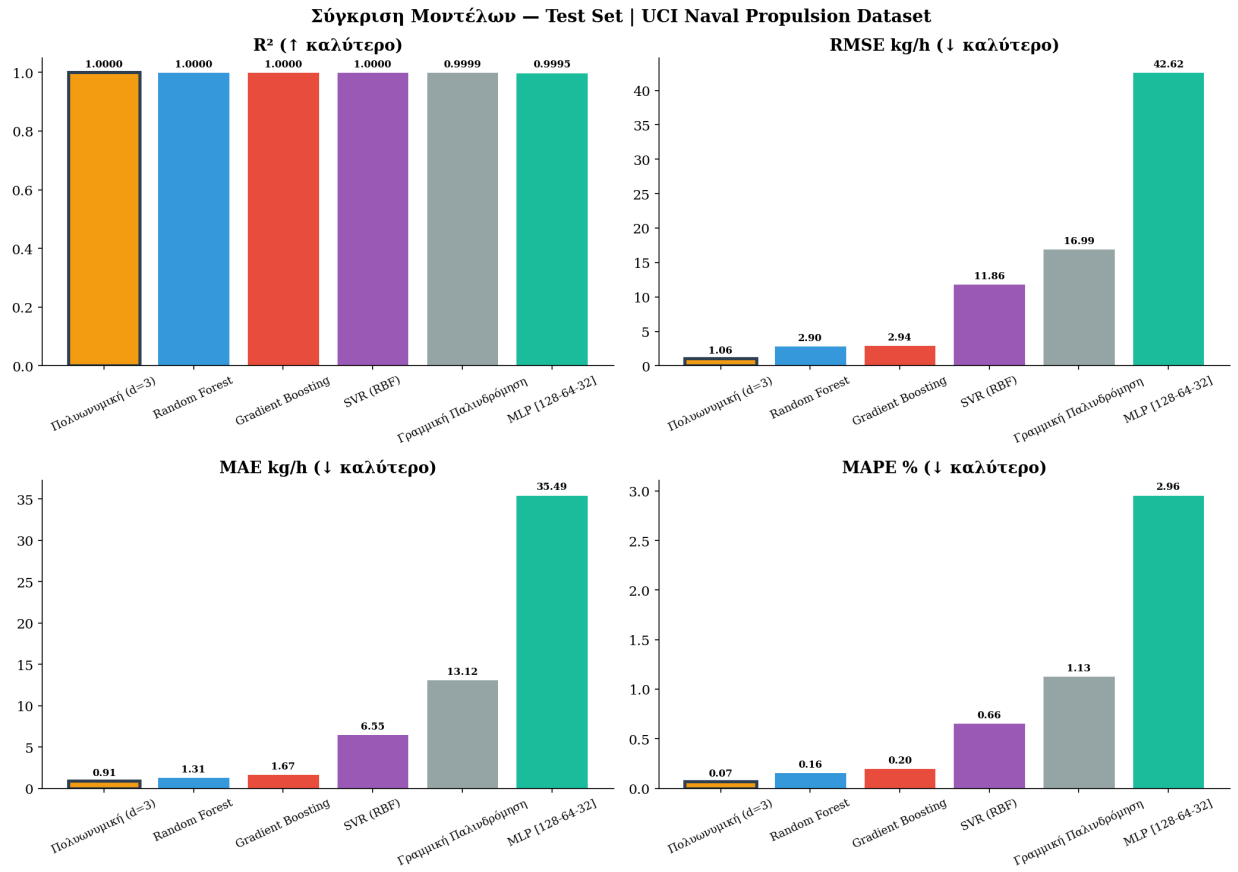

Σχήμα 5.6: Σύγκριση Μοντέλων - outputs/05_Σύγκριση_Μετρικών.png)

1. Η Πολυωνυμική (d=3) επιτυγχάνει RMSE=1.06 kg/h αξιοποιώντας άμεσα τη φυσική σχέση $P \propto V^3$.
2. Το Random Forest είναι στατιστικά ισοδύναμο με την Πολυωνυμική (Wilcoxon p≈1,000) και αποτελεί την καλύτερη επιλογή για γενίκευση χωρίς feature engineering· το Gradient Boosting, αν και πολύ κοντά σε επίπεδο RMSE, διαφέρει στατιστικά σημαντικά από την Πολυωνυμική (p<0,001)
3. SVR (RMSE=11.86) υπολείπεται παρά τη βελτιστοποίηση των hyperparameters (§4.5.5), λόγω του εγγενούς περιορισμού του στην αποτύπωση της κυβικής σχέσης και του υψηλού υπολογιστικού κόστους σε μεγάλα σύνολα.
4. MLP (RMSE=42.62) υπολείπεται παρά την κανονικοποίηση L2 (alpha=0.001) και το Early Stopping· χρειάζεται περαιτέρω βελτιστοποίηση αρχιτεκτονικής για ανταγωνιστική απόδοση.
5. $R^2 \geq 0,9995$ για όλα τα μοντέλα λόγω ντετερμινιστικής φύσης του UCI simulation dataset.

ΚΕΦΑΛΑΙΟ 6: Επιχειρησιακές Εφαρμογές και Στρατηγική Υλοποίησης

Τα αποτελέσματα του Κεφαλαίου 5 αποδεικνύουν ότι τα ML μοντέλα επιτυγχάνουν υψηλή ακρίβεια πρόβλεψης κατανάλωσης καυσίμου. Το παρόν κεφάλαιο μεταφράζει αυτά τα τεχνικά αποτελέσματα σε

πρακτική επιχειρησιακή αξία: πώς μπορεί μια ναυτιλιακή εταιρεία να αξιοποιήσει τα μοντέλα αυτά, ποια οικονομικά οφέλη να αναμένει, και ποια τεχνολογική υποδομή απαιτείται. Παρουσιάζονται επίσης υπαρκτά case studies από εταιρείες που έχουν ήδη υλοποιήσει ανάλογα συστήματα.

Η δομή του παρόντος κεφαλαίου ακολουθεί μια λογική πρόοδο από το τεχνικό στο στρατηγικό επίπεδο. Η ενότητα 6.1 παρουσιάζει την τεχνολογική αρχιτεκτονική που απαιτείται για την ενσωμάτωση του ML μοντέλου για την πρόβλεψη κατανάλωσης καυσίμου σε επιχειρησιακό περιβάλλον. Οι ενότητες 6.2 και 6.3 εστιάζουν στις άμεσες λειτουργικές εφαρμογές: τη βελτιστοποίηση ταχύτητας και την προβλεπτική συντήρηση αντίστοιχα — εφαρμογές που αμφότερες στοχεύουν στη μείωση της κατανάλωσης καυσίμου και των σχετικών εκπομπών. Η ενότητα 6.4 παρουσιάζει την έννοια του Ψηφιακού Διδύμου ως φυσική εξέλιξη του ML μοντέλου σε ζωντανό ψηφιακό ομοίωμα. Οι ενότητες 6.5 και 6.6 αναλύουν τις ρυθμιστικές και χρηματοοικονομικές διαστάσεις της επένδυσης, ενώ η ενότητα 6.7 εξετάζει τα εμπόδια υλοποίησης που πρέπει να αντιμετωπιστούν για επιτυχή ανάπτυξη.

Σημαντική παρατήρηση: οι αριθμητικές εκτιμήσεις που παρατίθενται στις ενότητες 6.2–6.6 βασίζονται σε παραδοχές οι οποίες αναφέρονται ρητά σε κάθε περίπτωση και αντλούν από τη βιβλιογραφία του κλάδου. Σκοπός τους είναι να αποτυπώσουν τη σχετική τάξη μεγέθους των δυνητικών ωφελειών και όχι να αποτελέσουν οικονομική πρόβλεψη.

6.1 Αρχιτεκτονική Επιχειρησιακού Συστήματος Πρόβλεψης

Η ενσωμάτωση ML μοντέλου πρόβλεψης κατανάλωσης καυσίμου σε επιχειρησιακό περιβάλλον - με σκοπό τη βελτιστοποίηση ταχύτητας, την προβλεπτική συντήρηση και τη διαχείριση CII - απαιτεί σαφώς καθορισμένη αρχιτεκτονική. Τα δεδομένα εισόδου αντλούνται σε πραγματικό χρόνο από τα αισθητήρια συστήματα του πλοίου, μεταδίδονται μέσω δορυφορικής σύνδεσης στο Κέντρο Διαχείρισης Στόλου (Fleet Management Center), προεπεξεργάζονται και οδηγούνται στο ML μοντέλο, το οποίο εκδίδει πρόβλεψη κατανάλωσης και ειδοποιεί για αποκλίσεις.

Ο Πίνακας 6.1 παρουσιάζει μια ενδεικτική, διαστρωματωμένη αρχιτεκτονική. Οι τεχνολογίες που αναφέρονται αποτελούν αντιπροσωπευτικά, ώριμα και ευρέως διαδεδομένα παραδείγματα και όχι αποκλειστικές επιλογές· ισοδύναμα εργαλεία (π.χ. Tableau αντί Power BI, RabbitMQ αντί Apache Kafka) θα εξυπηρετούσαν τον ίδιο ρόλο. Η τελική επιλογή σε πραγματική υλοποίηση εξαρτάται από το υφιστάμενο IT περιβάλλον της εταιρείας.

Πίνακας 6.1: Στρώματα αρχιτεκτονικής επιχειρησιακού ML συστήματος

Πηγή: DNV GL (2020), Wärtsilä (2021).

Επ.	Στρώμα	Τεχνολογίες	Λειτουργία
1	Αισθητήρες / Edge	IoT (Internet of Things) sensors, PLC (Programmable Logic Controller), SCADA (Supervisory Control and Data Acquisition), Data Logger	Συλλογή raw δεδομένων κινητήρα, GPS (Global Positioning System), αισθητήρων πλοίου σε 1-10 Hz

Επ.	Στρώμα	Τεχνολογίες	Λειτουργία
2	Επικοινωνία / Cloud	VSAT (Very Small Aperture Terminal)/ LTE (Long-Term Evolution), Apache Kafka, AWS (Amazon Web Services) IoT Core	Μετάδοση, buffering και streaming δεδομένων με 99,9% SLA (Service Level Agreement)
3	Analytics / ML	Python, XGBoost, Docker, Kubernetes	Preprocessing, inference, anomaly detection, model monitoring, retraining
4	Dashboard / UI (User Interface)	Grafana, Power BI, custom web app	Real-time visualization, alerts, KPIs (Key Performance Indicators), reporting, decision support

Η ροή των δεδομένων από τον αισθητήρα έως την πρόβλεψη ακολουθεί διαδοχικά βήματα: δειγματοληψία αισθητήρα (<1 sec), edge aggregation (1-10 sec), δορυφορική μετάδοση (10-60 sec), προεπεξεργασία δεδομένων (<2 sec), ML inference (<0,1 sec), και παραγωγή ειδοποίησης (<1 sec). Το συνολικό end-to-end latency είναι κάτω από 5 λεπτά — πλήρως κατάλληλο για τις επιχειρησιακές ανάγκες. Οι περισσότερες σχετικές αποφάσεις (ρύθμιση παραμέτρων κινητήρα, διαχείριση CII) λαμβάνονται σε ορίζοντα ωρών ή ημερών - ωστόσο η βελτιστοποίηση ταχύτητας μπορεί να απαιτεί και δυναμική αναπροσαρμογή κατά τη διάρκεια του πλου (on the go), π.χ. λόγω weather routing ή απαιτήσεων συμμόρφωσης.

6.2 Βελτιστοποίηση Ταχύτητας (Speed Optimization)

Η βελτιστοποίηση ταχύτητας πλοίου αποτελεί την άμεσα εφαρμόσιμη χρήση ενός ακριβούς μοντέλου κατανάλωσης. Δεδομένης αφετηρίας A, προορισμού B, χρονικού παραθύρου άφιξης [T_min, T_max] και πρόβλεψης καιρού, ζητείται η βέλτιστη ταχύτητα v* που ελαχιστοποιεί κατανάλωση:

$$\min_{v} FC(v, weather, engine_state) \times D/v$$

$$s.t.: \; T_{min} \le D/v \le T_{max}, \quad v_{min} \le v \le v_{max}$$

Χωρίς ML, η FC(v,...) χρησιμοποιεί αδρές προσεγγίσεις (Admiralty Coefficient, error 10-20%). Με τα μοντέλα της παρούσας εργασίας (Random Forest, RMSE = 2,90 kg/h, $R^2 \approx 1{,}0000$· βλ. Κεφάλαιο 5), το πρόβλημα προσεγγίζεται με σημαντικά υψηλότερη ακρίβεια. Οι ιδιαίτερα υψηλές τιμές οφείλονται στη ντετερμινιστική φύση του συνόλου προσομοίωσης (UCI), όπως αναλύεται στα Κεφάλαια 5 και 7. Η κλασική Just-In-Time (JIT) άφιξη βασίζεται ακριβώς σε αυτή τη λογική: αντί να φτάνει νωρίς και να αγκυροβολεί σπαταλώντας καύσιμο υψηλής ταχύτητας, το πλοίο υπολογίζει την ακριβή ταχύτητα που το φέρνει στο λιμάνι όταν ανοίξει θέση.

Αξίζει να σημειωθεί ότι η παραπάνω διατύπωση θεωρεί, για λόγους απλότητας, μια ενιαία βέλτιστη ταχύτητα για ολόκληρο το ταξίδι. Στην πράξη, ωστόσο, η ταχύτητα μπορεί να αναπροσαρμόζεται κατά τη διάρκεια του πλου (on the go) λόγω weather routing, μεταβολών στο χρονοδιάγραμμα άφιξης ή απαιτήσεων

συμμόρφωσης. Ένα real-time ML μοντέλο υποστηρίζει ακριβώς αυτή τη δυναμική επανατιμολόγηση της βέλτιστης ταχύτητας σε κάθε χρονικό βήμα.

Πίνακας 6.2: Παράδειγμα βελτιστοποίησης ταχύτητας — Container ship Αμβούργο-Πειραιάς (3.200 nm)

Πηγή: *(Stopford, 2009).*

Σενάριο	Ταχύτητα	Διάρκεια	Κατανάλωση	Κόστος Καυσίμου
Βάση (18 kn)	18 kn	177.8 h	~350 MT	~$227.500
JIT Opt. (15 kn)	15 kn	213.3 h	~243 MT	~$158.000
JIT Opt. (14 kn)	14 kn	228.6 h	~212 MT	~$138.000
Αποτ/σία JIT 15kn	-16.7%	+35.5h	-31% (-107 MT)	-$69.500 (-31%)

Υποθέσεις: Τιμή VLSFO $650/MT, βάση μέσου όρου 2023-2024 (Ship & Bunker, 2024).

Κυβικός νόμος κατανάλωσης - ταχύτητας (P~V^3), κατανάλωση ανά πλου ∝V² βάσει θεωρητικής ανάλυσης

Τα αποτελέσματα του Πίνακα 6.2 δείχνουν ότι η μείωση ταχύτητας κατά 3 knots (από 18 σε 15 knots) οδηγεί σε εξοικονόμηση ~31% στην κατανάλωση καυσίμου (~107 MT, ή ~$69.500 ανά πλου), ανταλλάσσοντας 35,5 ώρες επιπλέον χρόνου ταξιδιού. Αυτή η σχέση αντικατοπτρίζει τον κυβικό νόμο ισχύος-ταχύτητας ($P \propto V^3$) που επαληθεύτηκε και εμπειρικά στο Κεφάλαιο 4.2.4. Σημειώνεται ότι ο κυβικός νόμος αφορά την κατανάλωση ανά ώρα ($\propto V^3$)· η εξοικονόμηση ανά πλου είναι μικρότερη ($\propto V^2$), καθώς το ταξίδι με χαμηλότερη ταχύτητα διαρκεί περισσότερο. Το ML μοντέλο καθιστά αυτή τη βελτιστοποίηση ακριβέστερη συγκριτικά με τις παραδοσιακές μεθόδους (σφάλμα 10–20%), ιδίως σε συνθήκες μεταβαλλόμενης θαλάσσιας κατάστασης και φόρτωσης πλοίου.

Η συνολική κατανάλωση ανά πλου υπολογίζεται ως ανάλογη του v^2 (συνέπεια της σχέσης ισχύος $P \propto V^3$ και του χρόνου πλου $\propto 1/v$), με βάση αναφοράς 350 MT στα 18 kn. Το παράδειγμα είναι ενδεικτικό της τάξης μεγέθους και δεν ενσωματώνει επιδράσεις θαλάσσιας κατάστασης, ρευμάτων ή περιορισμών χρονοδιαγράμματος, τις οποίες λαμβάνει υπόψη το real-time μοντέλο.

6.3 Predictive Maintenance και Condition Monitoring

Η Προβλεπτική Συντήρηση (Predictive Maintenance - PdM) αποτελεί σημαντική εφαρμογή ML στη ναυτιλία (Lazakis et al., 2018). Η κεντρική ιδέα: η απόκλιση μετρούμενης κατανάλωσης από την προβλεπόμενη (residual) αποτελεί έγκαιρο σήμα υποβάθμισης κατάστασης. Αν το μοντέλο χρησιμοποιεί μόνο επιχειρησιακές παραμέτρους, τότε υψηλό residual υποδηλώνει υποβάθμιση κινητήρα:

$$Residual(t) = FC_{measured}(t) - FC_{predicted}(t \mid v, load, weather)$$

$$AnomalyScore(t) = Residual(t) / sigma_{baseline} \rightarrow alert\ \alpha v > 3,5$$

Ο Πίνακας 6.3 συγκρίνει τρεις στρατηγικές συντήρησης. Η μετάβαση σε predictive συντήρηση βασισμένη σε ML μειώνει το ετήσιο κόστος ανά πλοίο από $380–580k (preventive/corrective) σε ~$220k — εξοικονόμηση $160–360k ανά πλοίο ετησίως — ενώ ταυτόχρονα μειώνει τις μη προγραμματισμένες διακοπές (από 1,8–3,2 σε 0,6 ανά έτος) και αυξάνει τον μέσο χρόνο μεταξύ βλαβών (Mean Time Between Failures, MTBF). Η βελτίωση οφείλεται στο ότι το σήμα residual (§6.3.1) επιτρέπει στοχευμένη παρέμβαση πριν την αστοχία, αντί για περιοδικές ή κατασταλτικές αντικαταστάσεις.

Πίνακας 6.3: Σύγκριση στρατηγικών συντήρησης — κόστος και αποτελεσματικότητα

Πηγή: DNV GL (2021), Lazakis et al. (2018). MTBF: Mean Time Between Failures.

Στρατηγική	Ετ. Κόστος	Διακοπές/έτος	MTBF	Χαρακτηριστικά
Corrective (αντίδρ.)	$580k/πλοίο	3.2	Χαμηλό	Αναπάντεχες μεγάλες βλάβες
Preventive (χρόνος)	$380k/πλοίο	1.8	Μέτριο	Περιττές αντικαταστάσεις
Predictive + ML ★	$220k/πλοίο	0.6	Υψηλό	Βελτ. αξιοποίηση πόρων
Εξοικ. PdM	$160-360k/ έτ.	−67…−81%	+45%	vs. Preventive/ Corrective

6.4 Ψηφιακό Δίδυμο (Digital Twin)

Το ML μοντέλο κατανάλωσης αποτελεί ένα από τα δομικά στοιχεία (component) ενός ευρύτερου συστήματος Digital Twin — ενός ζωντανού, συνεχώς ενημερωμένου ψηφιακού ομοιώματος του φυσικού πλοίου. Ο Grieves (2014) το ορίζει ως τριμερές μοντέλο: (α) φυσικό αντικείμενο, (β) ψηφιακό ομοίωμα, και (γ) ροή δεδομένων που τα συνδέει. Στη ναυτιλία, το Digital Twin Ship ενσωματώνει ML μοντέλα κατανάλωσης με υδροδυναμικά μοντέλα υπολογιστικής ρευστοδυναμικής (Computational Fluid Dynamics, CFD), δομικά μοντέλα ανάλυσης πεπερασμένων στοιχείων (Finite Element Analysis, FEA) και μοντέλα αξιοπιστίας εξοπλισμού (Tao et al., 2019).

Ο Πίνακας 6.4 καταδεικνύει ότι οι μεγαλύτεροι παγκόσμιοι κατασκευαστές ναυτιλιακού εξοπλισμού και ναυτιλιακές εταιρείες έχουν ήδη αναπτύξει συστήματα Digital Twin που επιτυγχάνουν 3–12% μείωση κατανάλωσης καυσίμου. Αξιοσημείωτο είναι ότι η Maersk αναφέρει εξοικονόμηση άνω των 50 εκατ. δολαρίων ετησίως σε επίπεδο στόλου, γεγονός που επικυρώνει την οικονομική σκοπιμότητα που αναλύεται στην ενότητα 6.6. Τα παραδείγματα αυτά αποδεικνύουν ότι η τεχνολογία δεν αποτελεί μελλοντική προοπτική αλλά υπαρκτή και λειτουργούσα πραγματικότητα στη διεθνή ναυτιλία.

Πίνακας 6.4: Υπαρκτές υλοποιήσεις Digital Twin στη ναυτιλία

Πηγή: Εταιρικές εκθέσεις και δημοσιεύσεις. FC: Fuel Consumption.

Εταιρεία	Σύστημα	Τύπος Πλοίου	Αποτέλεσμα	Αναφορά
Wärtsilä	Voyage Optimisation	Πολλαπλοί τύποι	5-10% μείωση FC	Wärtsilä (2021)
ABB	Ability Marine Advisory	Container, Tanker	3-8% μείωση FC	ABB (2020)
Kongsberg	K-Chief Fuel Optim.	Offshore, Container	6-12% μείωση FC	Kongsberg (2021)
Maersk	Remote Diagnostics	Container fleet	$50M+ ετησίως	Maersk (2022)
MSC	Fleet Management	Container (700+)	CII A/B στόχος	MSC (2023)

6.5 CII Management και EU ETS

Ο Δείκτης Έντασης Άνθρακα (Carbon Intensity Indicator, CII) του IMO αποτελεί νέα κανονιστική πρόκληση. Σε αντίθεση με την §2.5.4, που παρουσιάζει τον CII ως κανονιστικό πλαίσιο, η παρούσα ενότητα εστιάζει στο πώς ένα μοντέλο ML μετατρέπει τη διαχείρισή του από αντιδραστική (εκ των υστέρων) σε προληπτική (real-time πρόβλεψη). Το ML υπολογίζει rolling CII — δηλαδή το CII που θα επιτευχθεί αν συνεχιστεί η τρέχουσα κατανάλωση έως το τέλος της χρονιάς — επιτρέποντας έγκαιρη ρύθμιση ταχύτητας ή δρομολογίου για επίτευξη CII rating A ή B και αποφυγή κυρώσεων χαμηλής βαθμολογίας

CII_rolling(t) = [FC_actual(0,t) + FC_predicted(t,T_year)] x CF / (DWT x Distance_planned)

Ο Πίνακας 6.5 αποτυπώνει τη σταδιακή ένταξη της ναυτιλίας στο EU ETS: το ποσοστό των εκπομπών που υπόκειται σε χρέωση αυξάνεται από 40% (2024) σε 70% (2025) και 100% (2026), ανεβάζοντας το ετήσιο κόστος ενός τυπικού container ship από ~312.000 σε ~900.000 EUR. Η εξοικονόμηση καυσίμου 6% μέσω ML μεταφράζεται σε ανάλογη μείωση του κόστους ETS (~19.000–54.000 EUR/έτος), καθώς οι εκπομπές CO_2 είναι ανάλογες της κατανάλωσης.

Πίνακας 6.5: Εκτίμηση κόστους EU ETS 2024-2026 για τυπικό container ship

Πηγή: Ποσοστά σταδιακής ένταξης στο EU ETS βάσει European Parliament & Council of the EU (2023a)· τιμή δικαιωμάτων CO_2 βάσει Platts, S&P Global (2023)· υπολογισμοί της συγγραφέως. Υποθέσεις: Container ship 50.000 DWT, 12.000 MT CO2/έτος, ML εξοικονόμηση 6%. Τιμές EU ETS: EC (2023).

Έτος	ETS Κάλυψη	CO2 Εκπομπές	Τιμή CO2	Κόστος ETS	Εξοικ. ML
2024	40%	12.000 MT	65 EUR/MT	312.000 EUR	~19.000 EUR
2025	70%	12.000 MT	70 EUR/MT	588.000 EUR	~35.000 EUR

Έτος	ETS Κάλυψη	CO2 Εκπομπές	Τιμή CO2	Κόστος ETS	Εξοικ. ML
2026	100%	12.000 MT	75 EUR/MT	900.000 EUR	~54.000 EUR
2030 (εκτ.)	100%	12.000 MT	100 EUR/MT	1.200.000 EUR	~72.000 EUR

6.6 Ανάλυση ROI

Η παρούσα ενότητα αποτιμά την οικονομική βιωσιμότητα της επένδυσης σε σύστημα ML για στόλο 10 πλοίων, με τη μέθοδο της Καθαρής Παρούσας Αξίας (Net Present Value, NPV). Οι ετήσιες ταμειακές ροές προκύπτουν αθροίζοντας τρεις πηγές εξοικονόμησης — καύσιμα, κόστος EU ETS και κόστος συντήρησης — και αφαιρώντας το κόστος λειτουργίας του συστήματος· οι ροές προεξοφλούνται με επιτόκιο r = 10% σε ορίζοντα πενταετίας. Οι παραδοχές (εξοικονόμηση καυσίμου 6%, αρχικό κόστος $2,0 εκατ.) είναι κοινές με τους Πίνακες 6.5 και 6.7.

Ο Πίνακας 6.6 παρουσιάζει τις εκτιμώμενες ταμειακές ροές της επένδυσης σε ορίζοντα πενταετίας. Παρά το αρχικό κόστος υλοποίησης, η σταδιακή εξοικονόμηση από καύσιμα, ETS και συντήρηση οδηγεί σε θετικές ετήσιες ταμειακές ροές. Η συνολική καθαρή παρούσα αξία (NPV) της επένδυσης εκτιμάται στα +$27,3 εκατ., γεγονός που υποδηλώνει ιδιαίτερα υψηλή οικονομική βιωσιμότητα.

Πίνακας 6.6: Ανάλυση ROI — Ενσωμάτωση ML συστήματος κατανάλωσης καυσίμων σε fleet 10 πλοίων (NPV 5 ετών, r=10%)

Πηγή: Ίδιοι υπολογισμοί της συγγραφέως βάσει των παραδοχών εξοικονόμησης (Κεφάλαιο 5 και ενότητες 6.2–6.5) και στοιχείων κόστους υλοποίησης από DNV GL (2021).

Έτος	Κόστος ($)	Εξοικ. Καύσ.	Εξοικ. ETS	Εξοικ. Συντ.	Cash Flow
0 (Init)	-$2.000.000	—	—	—	-$2.000.000
1	-$200.000	+ $5.000.000	+$310.000	+$1.600.000	+$6.710.000
2	-$200.000	+ $5.500.000	+$590.000	+$1.600.000	+$7.490.000
3-5 avg	-$200.000	+ $6.000.000	+ $900.000+	+$1.600.000	+$8.300.000
NPV 5 ετη	—	—	—	—	**+$27.300.000**

Πίνακας 6.7: Ανάλυση Ευαισθησίας της Επένδυσης ως προς Εξοικονόμηση Καυσίμου, Τιμή VLSFO και Αρχικό Κόστος

Πηγή: Ίδιοι υπολογισμοί της συγγραφέως· ανάλυση ευαισθησίας επί των παραδοχών των ενοτήτων 6.2–6.6.

Σενάριο	Εξοικ. Καύσ.	Τιμή VLSFO ($/MT)	Αρχικό Κόστος ($M)	NPV 5ετίας ($M)
Απαισιόδοξο	4%	400	2.5	+ 15,0
Βασικό	6%	550	2.0	+ 27,0
Αισιόδοξο	8%	700	1.5	+ 44,0

Η ανάλυση ευαισθησίας, όπως φαίνεται στον πίνακα 6.7, καταδεικνύει ότι ακόμη και υπό δυσμενείς συνθήκες — συγκεκριμένα με εξοικονόμηση καυσίμου 4%, τιμή VLSFO στα $400/MT και αρχικό επενδυτικό κόστος $2,5 εκατ. — η καθαρή παρούσα αξία (NPV) διατηρείται θετική και ανέρχεται περίπου στα $15 εκατ. Το αποτέλεσμα αυτό υποδηλώνει ότι η επένδυση παραμένει οικονομικά βιώσιμη ακόμη και στο πιο συντηρητικό σενάριο. Παράλληλα, η παράμετρος με τη μεγαλύτερη επίδραση στο NPV είναι το ποσοστό εξοικονόμησης καυσίμου, καθώς μεταβάλλει την καθαρή παρούσα αξία σε εύρος από $15 εκατ. έως $44 εκατ. Για τον λόγο αυτό, η υψηλή ακρίβεια των προτεινόμενων μοντέλων πρόβλεψης ($R^2 \approx 1{,}0000$· βλ. Κεφάλαιο 5) θεωρείται καθοριστικής σημασίας για την αξιοπιστία της οικονομικής αξιολόγησης.

6.7 Εμπόδια Υλοποίησης

Παρά τα σαφή οικονομικά και λειτουργικά οφέλη που παρουσιάστηκαν στις προηγούμενες ενότητες, η υιοθέτηση συστημάτων ML για πρόβλεψη και μείωση κατανάλωσης καυσίμου αντιμετωπίζει μια σειρά από εμπόδια που αφορούν τόσο τεχνικούς όσο και οργανωτικούς παράγοντες. Ο Πίνακας 6.8 συνοψίζει τα κυριότερα εμπόδια και τις αντίστοιχες στρατηγικές αντιμετώπισής τους, όπως αυτές προκύπτουν από τη βιβλιογραφία.

Πίνακας 6.8: Εμπόδια υλοποίησης συστημάτων ML για πρόβλεψη και μείωση κατανάλωσης καυσίμων στη ναυτιλία και στρατηγικές αντιμετώπισης

Κατηγορία	Εμπόδιο	Αντιμετώπιση	Αναφορά
Δεδομένα	Ποιότητα δεδομένων αισθητήρων κατανάλωσης/ροής καυσίμου — θόρυβος, κενά	Edge intelligence, automated imputation, σχεδιασμός από κατασκευαστή	Wang et al. (2021)
Δεδομένα	Ανεπαρκή ιστορικά δεδομένα για παλιά πλοία	Transfer learning από παρόμοια πλοία, physics-informed ML	Gkerekos et al. (2019)

Κατηγορία	Εμπόδιο	Αντιμετώπιση	Αναφορά
Οργανωτικά	Αντίσταση αλλαγής — δυσπιστία σε προτάσεις βελτιστοποίησης ταχύτητας/ κατανάλωσης	Explainable AI (SHAP), εκπαίδευση πληρωμάτων, σταδιακή εισαγωγή	Theodoropoulos et al. (2021)
Τεχνικά	Κυβερνοασφάλεια — ευαίσθητα δεδομένα πλοίου	End-to-end κρυπτογράφηση, zero-trust αρχιτεκτονική, IMO MSC-FAL.1	IMO (2021)
Κανονιστικά	Επαλήθευση ML προβλέψεων από Class Societies	Explainable AI, model cards, πλήρης documentation	DNV GL (2021)

Η αντιμετώπιση των εμποδίων αυτών δεν αποτελεί αδυναμία της ML προσέγγισης αλλά φυσικό στάδιο ωρίμανσης κάθε νέας τεχνολογίας. Εταιρείες όπως η Maersk και η MSC έχουν ήδη αποδείξει ότι η συνδυαστική αντιμετώπιση τεχνικών, οργανωτικών και κανονιστικών εμποδίων οδηγεί σε επιτυχή υλοποίηση, επιβεβαιώνοντας τη βιωσιμότητα της επένδυσης.

ΚΕΦΑΛΑΙΟ 7: Συμπεράσματα, Περιορισμοί και Μελλοντική Έρευνα

Το παρόν κεφάλαιο συνοψίζει τα κύρια ευρήματα της εργασίας, εξετάζει αναλυτικά τους περιορισμούς της μεθοδολογίας, αναλύει τη σχέση με την ευρύτερη βιβλιογραφία, διατυπώνει συστάσεις προς ναυτιλιακές εταιρείες και ρυθμιστικές αρχές, και προσδιορίζει συγκεκριμένες κατευθύνσεις μελλοντικής έρευνας.

7.1 Σύνοψη Κύριων Ευρημάτων

7.1.1 Ευρήματα ανά Ερευνητικό Ερώτημα

Η παρούσα εργασία εξέτασε τέσσερα βασικά ερευνητικά ερωτήματα:

Ερώτημα 1: Ποιοι ML αλγόριθμοι επιτυγχάνουν την υψηλότερη ακρίβεια πρόβλεψης κατανάλωσης καυσίμου ναυτικού κινητήρα; — Απάντηση: Από τους αλγορίθμους που εξετάστηκαν και με βάση την ανάλυση στο συνθετικό σύνολο δεδομένων (UCI), η Πολυωνυμική Παλινδρόμηση βαθμού 3 (R^2=1,0000, RMSE=1.06 kg/h) επιτυγχάνει την υψηλότερη ακρίβεια, ακολουθούμενη από τα ensemble μοντέλα Random Forest (RMSE=2.90 kg/h) και Gradient Boosting (RMSE=2.94 kg/h), από αυτά, το Random Forest βρέθηκε στατιστικά ισοδύναμο με την Πολυωνυμική (Wilcoxon p≈1.000), ενώ το Gradient Boosting διαφέρει στατιστικά σημαντικά (p<0,001). Όλα υπερτερούν σαφώς της γραμμικής παλινδρόμησης baseline (RMSE=16.99 kg/h), που αδυνατεί να αποτυπώσει την κυβική σχέση ισχύος–ταχύτητας. Οι ιδιαίτερα υψηλές τιμές R^2 (≥0,9995) οφείλονται στη ντετερμινιστική φύση του συνόλου δεδομένων προσομοίωσης (UCI), όπως αναλύεται στο Κεφάλαιο 5.

Ερώτημα 2: Ποιες παράμετροι (features) έχουν τη μεγαλύτερη επίδραση στην κατανάλωση; — Απάντηση: Σύμφωνα με την ανάλυση feature importance (§5.2.2, §5,3), τα σημαντικότερα features είναι η πίεση καυσαερίων (Pexh), οι στροφές του αεριοστρόβιλου (GTn) και η θερμοκρασία εξόδου της HP turbine (T48). Η κυριαρχία τους συνάδει με τη θερμοδυναμική θεωρία του κύκλου Brayton: η κατανάλωση καθορίζεται κυρίως από το φορτίο/στροφές του κινητήρα και τη θερμοκρασία καυσαερίων, σε μη γραμμική σχέση συνεπή με τον κυβικό νόμο ισχύος-ταχύτητας.

Ερώτημα 3: Σε ποιο βαθμό δικαιολογείται το υπολογιστικό κόστος των ML μοντέλων έναντι απλούστερων μεθόδων; — Απάντηση: Η ανάλυση δείχνει ότι η σχέση κόστους-οφέλους εξαρτάται από το πρόβλημα. Η Πολυωνυμική Παλινδρόμηση βαθμού 3 — υπολογιστικά φθηνή — επιτυγχάνει την υψηλότερη ακρίβεια όταν η υποκείμενη σχέση είναι γνωστή ($P \propto V^3$), καθιστώντας τα σύνθετα μοντέλα μη απαραίτητα στο συγκεκριμένο dataset. Ωστόσο, το Random Forest προκρίνεται για επιχειρησιακή ανάπτυξη παρότι ακριβότερο, καθώς γενικεύει χωρίς feature engineering και προσαρμόζεται σε μη ντετερμινιστικά πραγματικά δεδομένα — όπου τα απλά μοντέλα αναμένεται να υστερήσουν.

Ερώτημα 4: Ποιες είναι οι επιχειρησιακές εφαρμογές των μοντέλων μηχανικής μάθησης για πρόβλεψη κατανάλωσης καυσίμου σε ναυτιλιακό πλαίσιο; — Απάντηση: Στο Κεφάλαιο 6 αναλύθηκαν τέσσερις ενδεικτικές, άμεσα εφαρμόσιμες χρήσεις: (α) βελτιστοποίηση ταχύτητας, με εξοικονόμηση καυσίμου της τάξης του 4–12% (§6,2)· (β) προβλεπτική συντήρηση (PdM), με μείωση κόστους συντήρησης ~40–60% (§6,3)· (γ) proactive διαχείριση CII για αποφυγή κυρώσεων (§6,5)· και (δ) ενσωμάτωση σε σύστημα Digital Twin (§6,4). Οι εφαρμογές αυτές είναι ενδεικτικές των δυνατοτήτων και όχι εξαντλητικές.

7.1.2 Συγκριτική Αξιολόγηση Μοντέλων

Ο Πίνακας 7.1 ανακεφαλαιώνει τα αποτελέσματα του Κεφαλαίου 5. Η Πολυωνυμική Παλινδρόμηση βαθμού 3 επιτυγχάνει το χαμηλότερο RMSE (1,06 kg/h) αξιοποιώντας άμεσα τη σχέση $P \propto V^3$, ενώ το Random Forest είναι στατιστικά ισοδύναμο με αυτήν (Wilcoxon $p \approx 1{,}000$) και προκρίνεται για επιχειρησιακή ανάπτυξη, καθώς δεν απαιτεί feature engineering. Οι ιδιαίτερα υψηλές τιμές R^2 (≥0,9995) όλων των μοντέλων οφείλονται στη ντετερμινιστική φύση του συνόλου προσομοίωσης και σχολιάζονται στους περιορισμούς (§7.2.1).

Πίνακας 7.1: Τελική συγκριτική αξιολόγηση — ανακεφαλαίωση αποτελεσμάτων

★ Βέλτιστο μοντέλο. RMSE και MAE σε kg/h. Πηγή: Αποτελέσματα Κεφ. 5.

Μοντέλο	R^2	RMSE (kg/h)	MAE(kg/h)	MAPE	Κατάταξη
Πολυωνυμική (d=3)★	1.0000	1.06	0.91	0.07%	1η
Random Forest	1.0000	2.90	1.31	0.16%	2η
Gradient Boosting	1.0000	2.94	1.67	0.20%	3η
SVR (RBF)	1.0000	11.86	6.55	0.66%	4η
Γραμμική Παλινδρόμηση	0.9999	16.99	13.12	1.13%	5η
MLP (128-64-32)	0.9995	42.62	35.49	2.96%	6η

7.2 Αναλυτική Συζήτηση Περιορισμών

7.2.1 Περιορισμοί Δεδομένων

Ο σημαντικότερος περιορισμός αφορά τη φύση του dataset: πρόκειται για συνθετικά δεδομένα από προσομοιωτή (Coraddu et al., 2016), όχι από πραγματικό επιχειρησιακό πλοίο. Αυτό συνεπάγεται τρεις σημαντικές ιδιότητες: (α) απουσία μέτρησης θορύβου από αισθητήρες, (β) χωρίς ανωμαλίες και βλάβες εξοπλισμού που εμφανίζονται σε πραγματικά δεδομένα, (γ) η κατανομή δεδομένων αντανακλά στρατηγική δειγματοληψία του προσομοιωτή αντί πραγματικής κατανομής επιχειρησιακών συνθηκών.

Η εξωτερική εγκυρότητα (external validity) των αποτελεσμάτων — δηλαδή η γενίκευσή τους σε πραγματικά πλοία — παραμένει ερώτημα που απαιτεί επιπλέον validation. Μελέτες σε πραγματικά δεδομένα (π.χ. Petersen et al., 2012· Gkerekos et al., 2019) αναφέρουν R^2 στα 0,92–0,95 — χαμηλότερα από τα ≈1,0000

($R^2 \geq 0{,}9995$) της παρούσας εργασίας, γεγονός αναμενόμενο λόγω του θορύβου των πραγματικών δεδομένων.

Ένας πρόσθετος και κρίσιμος περιορισμός, που σχετίζεται άμεσα με την ερμηνεία των σχεδόν τέλειων δεικτών απόδοσης ($R^2 \approx 1{,}0000$), αφορά τη δομή του ίδιου του προβλήματος πρόβλεψης. Στο συγκεκριμένο σύνολο δεδομένων, η ροή καυσίμου αποτελεί ντετερμινιστική συνάρτηση του σημείου λειτουργίας του κινητήρα, το οποίο καθορίζεται ουσιαστικά από μία μεταβλητή ελέγχου (θέση μοχλού ισχύος). Ως αποτέλεσμα, όλες οι ανεξάρτητες μεταβλητές παρουσιάζουν εξαιρετικά υψηλή γραμμική συσχέτιση με τον στόχο (συντελεστής Pearson $r > 0{,}89$ για το σύνολο των μεταβλητών εισόδου, με τη ροπή του άξονα, τις θερμοκρασίες και τις πιέσεις να υπερβαίνουν το 0,98) — φαινόμενο που προσεγγίζει την κατάσταση διαρροής πληροφορίας (information leakage) μεταξύ εισόδων και στόχου (Kaufman et al., 2012). Ενδεικτικά, ακόμη και ένα κυβικό πολυώνυμο της θέσης του μοχλού ως μοναδικής μεταβλητής εισόδου επιτυγχάνει $R^2 = 0{,}993$, ενώ η απλή γραμμική παλινδρόμηση με το σύνολο των μεταβλητών φτάνει $R^2 = 0{,}9999$. Συνεπώς, η σχεδόν τέλεια απόδοση όλων των αλγορίθμων δεν θα πρέπει να ερμηνευθεί ως ένδειξη ανωτερότητας των μεθόδων Μηχανικής Μάθησης έναντι των παραδοσιακών προσεγγίσεων, αλλά ως αντανάκλαση του ντετερμινιστικού και χαμηλού θορύβου χαρακτήρα των συνθετικών δεδομένων. Επιπλέον, το σύνολο δεδομένων αναπτύχθηκε αρχικά για τη διάγνωση της σταδιακής φθοράς των συνιστωσών πρόωσης (condition-based maintenance) και όχι για την πρόβλεψη κατανάλωσης καυσίμου (Coraddu et al., 2016)· η επαναχρησιμοποίησή του για τον σκοπό αυτό απλοποιεί τεχνητά το πρόβλημα. Η ουσιαστική αξία των εξεταζόμενων αλγορίθμων μπορεί να αποτιμηθεί αξιόπιστα μόνο σε επιχειρησιακά δεδομένα πραγματικού πλοίου, όπου ο θόρυβος των αισθητήρων, οι μεταβαλλόμενες περιβαλλοντικές συνθήκες και η ασθενέστερη συσχέτιση εισόδων–στόχου καθιστούν το πρόβλημα πρόβλεψης ουσιωδώς πιο απαιτητικό.

7.2.2 Περιορισμοί Μοντελοποίησης

Μια δεύτερη κατηγορία περιορισμών αφορά τα ίδια τα ML μοντέλα:

- Στατικότητα: Τα μοντέλα εκπαιδεύτηκαν σε στατικό snapshot δεδομένων. Σε πραγματική εφαρμογή, ο κινητήρας γηράσκει, το πλοίο ρυπαίνεται, και η κατανομή εισόδου μεταβάλλεται (concept drift). Απαιτείται περιοδική επανεκπαίδευση.
- Ερμηνευσιμότητα: Τα ensemble μοντέλα (Random Forest, Gradient Boosting), παρότι παρέχουν δείκτες feature importance, παραμένουν σχετικά "black box" σε σχέση με φυσικές εξισώσεις. Για ρυθμιστική συμμόρφωση, ενδέχεται να απαιτείται hybrid φυσικο-ML προσέγγιση.
- Εξωτερικός καιρός: Το dataset δεν περιλαμβάνει δεδομένα θαλάσσιας κατάστασης (κύματα, άνεμος). Σε πραγματικές συνθήκες, αυτοί οι παράγοντες επηρεάζουν κατανάλωση έως 30% (Faltinsen, 1990), μειώνοντας σημαντικά τη χρησιμότητα χωρίς ενσωμάτωσή τους.
- Πλοίο/κινητήρας: Τα μοντέλα εκπαιδεύτηκαν σε ένα μόνο τύπο κινητήρα (αεριοστρόβιλος). Η γενίκευση σε diesel, dual-fuel ή ηλεκτρικά συστήματα απαιτεί νέα εκπαίδευση.

7.2.3 Περιορισμοί Αξιολόγησης

Οι μετρικές αξιολόγησης που χρησιμοποιήθηκαν (R^2, RMSE, MAE, MAPE) μετρούν μέση ακρίβεια. Δεν αξιολογούν: (α) την ακρίβεια σε ακραίες επιχειρησιακές συνθήκες (out-of-distribution), (β) τη βαθμονόμηση

(calibration) — δηλαδή αν τα prediction intervals είναι αξιόπιστα, (γ) το robustness σε αλλαγμένα κατανεμημένα δεδομένα. Αυτοί οι πρόσθετοι έλεγχοι αποτελούν αντικείμενο μελλοντικής έρευνας.

7.3 Συνεισφορά στη Βιβλιογραφία

Η παρούσα εργασία δεν εισάγει νέους αλγορίθμους, η συνεισφορά της έγκειται στη συστηματική εφαρμογή και σύνθεση καθιερωμένων μεθόδων στο συγκεκριμένο πρόβλημα της πρόβλεψης κατανάλωσης καυσίμου, σε τρεις κατευθύνσεις:

Πρώτον, πραγματοποιεί συστηματική σύγκριση έξι αλγορίθμων ML (Γραμμική Παλινδρόμηση, Πολυωνυμική Παλινδρόμηση, SVR, Random Forest, Gradient Boosting και MLP) στο ίδιο dataset και με κοινή μεθοδολογία αξιολόγησης — κάτι που δεν συναντάται συχνά στη βιβλιογραφία, καθώς οι περισσότερες εργασίες εστιάζουν σε 2-3 αλγορίθμους (βλ. ενδεικτικά Petersen et al., 2012· Guo et al., 2020). Η διαπίστωση αυτή τεκμηριώνεται από τη συγκριτική ανασκόπηση της ενότητας 3.2 (Πίνακας 3.1), στην οποία η πλειονότητα των μελετών αξιολογεί περιορισμένο αριθμό αλγορίθμων.Η κοινή πειραματική βάση επιτρέπει άμεσα συγκρίσιμα αποτελέσματα μεταξύ των μοντέλων.

Δεύτερον, η λεπτομερής ανάλυση feature importance (βάσει impurity/gain των ensemble μοντέλων) παρέχει ερμηνεύσιμα insights που μπορούν να ενσωματωθούν σε επιχειρησιακή λήψη αποφάσεων — πέρα από τα μαύρα κουτιά της πρόβλεψης.

Τρίτον, η αναλυτική σύνδεση των τεχνικών αποτελεσμάτων με ρυθμιστικό πλαίσιο (CII, EEXI, EU ETS) και οικονομική ανάλυση ROI παρέχει πρακτική οδηγία για ναυτιλιακές εταιρείες — γεφυρώνοντας το χάσμα μεταξύ ML ακαδημαϊκής έρευνας και επιχειρησιακής πρακτικής. Διευκρινίζεται ότι οι ανωτέρω συνεισφορές δεν συνιστούν μεθοδολογική καινοτομία υπό την έννοια της εισαγωγής νέων αλγορίθμων, αλλά πρωτοτυπία ως προς τη συστηματική, ενιαία και άμεσα συγκρίσιμη εφαρμογή καθιερωμένων μεθόδων στο συγκεκριμένο πρόβλημα της πρόβλεψης κατανάλωσης καυσίμου, καθώς και ως προς τη διασύνδεσή τους με το ρυθμιστικό και οικονομικό πλαίσιο της ναυτιλίας.

7.4 Πολιτικές Συστάσεις

7.4.1 Συστάσεις προς Ναυτιλιακές Εταιρείες

Ο Πίνακας 7.2 συνοψίζει πέντε συγκεκριμένες συστάσεις προς ναυτιλιακές εταιρείες, ιεραρχημένες κατά χρονικό ορίζοντα υλοποίησης, με ενδεικτικό κόστος και αναμενόμενο όφελος για κάθε μία.

Πίνακας 7.2: Πολιτικές συστάσεις προς ναυτιλιακές εταιρείες — προτεραιότητα και εφαρμοσιμότητα

Πηγή: σύνθεση της συγγραφέως βάσει βιβλιογραφίας του κλάδου (DNV GL, 2020· 2021· Wärtsilä, 2021). Τα ποσά αποτελούν ενδεικτικές τάξεις μεγέθους και όχι δεσμευτικές εκτιμήσεις κόστους.

#	Σύσταση	Χρονοδιάγραμμα	Κόστος	Αναμενόμενο Αποτέλεσμα
1	Εγκατάσταση αισθητήρων IoT σε όλα τα πλοία και συλλογή ιστορικών δεδομένων τουλάχιστον 12 μηνών	Άμεσα (0-6 μήνες)	$50-150k/ πλοίο	Βάση για κάθε ML εφαρμογή

#	Σύσταση	Χρονοδιάγραμμα	Κόστος	Αναμενόμενο Αποτέλεσμα
2	Ανάπτυξη ML μοντέλου πρόβλεψης κατανάλωσης (βάσει Random Forest / Gradient Boosting) και ενσωμάτωση σε Fleet Management System	Βραχυπρόθεσμα (6-18 μήνες)	$100-300k	ROI < 4 μήνες, εξοικονόμηση 5-10%
3	Εκπαίδευση πλοιάρχων και αξιωματικών στη χρήση ML συστημάτων — με έμφαση στη διαφανή ερμηνεία (SHAP)	Παράλληλα με 2	$20-50k/ έτος	Αύξηση υιοθέτησης, μείωση αντίστασης
4	Ανάπτυξη rolling CII tracker βάσει ML πρόβλεψης για real-time παρακολούθηση κανονιστικής συμμόρφωσης	Έως 2027	$50-100k	Αποφυγή D/E CII rating και κυρώσεων
5	Ενσωμάτωση ML σε Predictive Maintenance pipeline για πρόβλεψη βλαβών κινητήρα	Μεσοπρόθεσμα (18-36 μήνες)	$200-500k	Μείωση unplanned downtime κατά 60-70%

Όπως αποτυπώνεται στον Πίνακα 7.2, προτείνονται πέντε ιεραρχημένες δράσεις: (α) η άμεση εγκατάσταση υποδομής συλλογής και αποθήκευσης λειτουργικών δεδομένων, (β) η πιλοτική ανάπτυξη μοντέλου πρόβλεψης κατανάλωσης σε επιλεγμένα πλοία του στόλου, (γ) η ενσωμάτωση της βελτιστοποίησης ταχύτητας στις καθημερινές λειτουργικές διαδικασίες, (δ) η σταδιακή μετάβαση από προγραμματισμένη σε προβλεπτική συντήρηση και (ε), μακροπρόθεσμα, η ανάπτυξη Ψηφιακού Διδύμου. Ο πίνακας αποτελεί προϊόν σύνθεσης της συγγραφέως· οι ενδεικτικές τιμές κόστους και αναμενόμενου οφέλους δεν προκύπτουν από ανεξάρτητη μέτρηση, αλλά αντλούνται από τις αναλύσεις των ενοτήτων 6.2–6.6 της παρούσας εργασίας και από τη βιβλιογραφία του κλάδου (DNV GL, 2020· 2021· Wärtsilä, 2021), εκφράζοντας τάξη μεγέθους και όχι ακριβή οικονομική πρόβλεψη

7.4.2 Συστάσεις προς Ρυθμιστικές Αρχές

Προς τον IMO και τις Εθνικές Αρχές: (α) Τυποποίηση πρωτοκόλλων δεδομένων αισθητήρων πλοίων για διαλειτουργικότητα ML εφαρμογών — υπάρχει σήμερα σημαντικό χάσμα μεταξύ κατασκευαστών (βλ. ISO 11898, NMEA 2000 vs. κατασκευαστικά πρωτόκολλα). (β) Θεσμοθέτηση κινήτρων για ναυτιλιακές εταιρείες που υιοθετούν τεκμηριωμένα ML συστήματα βελτιστοποίησης — π.χ. bonus CII credits. (γ) Ανάπτυξη πλαισίου πιστοποίησης ML μοντέλων από Class Societies (DNV, Lloyd's, Bureau Veritas), ανάλογο του IACS UR W1 για ψηφιακά συστήματα.

7.5 Μελλοντική Έρευνα

7.5.1 Βραχυπρόθεσμες Κατευθύνσεις (1-2 Χρόνια)

- Επικύρωση με πραγματικά δεδομένα: Εφαρμογή της μεθοδολογίας σε δεδομένα από πραγματικό επιχειρησιακό πλοίο (π.χ. μέσω συνεργασίας με ελληνική ναυτιλιακή εταιρεία) για εξαγωγή εκτίμησης εξωτερικής εγκυρότητας.
- Ενσωμάτωση καιρικών δεδομένων: Προσθήκη σήματος κυματισμού (Hs, Tp), ανέμου (Beaufort) και ρεύματος σε ML pipeline — αναμενόμενη βελτίωση 3-8% επί R^2.
- Online Learning: Ανάπτυξη αλγορίθμου incremental learning που ενημερώνει το μοντέλο σε πραγματικό χρόνο καθώς νέα δεδομένα εισέρχονται, αντιμετωπίζοντας concept drift.

7.5.2 Μεσοπρόθεσμες Κατευθύνσεις (2-5 Χρόνια)

- Physics-Informed Neural Networks (PINNs): Ενσωμάτωση φυσικών εξισώσεων (Navier-Stokes, Bernoulli) ως soft constraints στην εκπαίδευση νευρωνικών δικτύων — υβριδική προσέγγιση που συνδυάζει ακρίβεια ML με ερμηνευσιμότητα φυσικής (Raissi et al., 2019).
- Federated Learning για Ναυτιλία: Εκπαίδευση ML μοντέλου σε δεδομένα από πολλά πλοία χωρίς κεντρική μεταφορά ευαίσθητων δεδομένων - έτσι διαφυλάσσεται η εμπιστευτικότητα των εταιρικών δεδομένων, ενώ ταυτόχρονα αξιοποιείται μεγαλύτερο dataset (McMahan et al., 2017).
- Multi-target Prediction: Ταυτόχρονη πρόβλεψη κατανάλωσης καυσίμου, NOx εκπομπών και κατάστασης κινητήρα σε ενιαίο multi-output μοντέλο — μειώνει υπολογιστικό κόστος και εκμεταλλεύεται τις συσχετίσεις μεταξύ targets.
- Interpretable ML για Κανονιστική Συμμόρφωση: Ανάπτυξη πλήρως ερμηνεύσιμων μοντέλων (rule-based, monotonic trees) τις απαιτήσεις επαλήθευσης των νηογνωμόνων (Class Societies), με ελάχιστη απώλεια ακρίβειας (Rudin, 2019).

7.5.3 Μακροπρόθεσμες Κατευθύνσεις (5-10 Χρόνια)

- Autonomous Ships: Ενσωμάτωση ML κατανάλωσης σε αυτόνομα πλοία (IMO Maritime Autonomous Surface Ships – MASS Level 3-4) ως βασικό module του συστήματος αυτόνομης ναυσιπλοΐας. Οι ML αλγόριθμοι θα λαμβάνουν αποφάσεις πλοήγησης βασισμένες σε real-time ισορροπία ταχύτητας-κατανάλωσης-ασφάλειας.
- Alternative Fuels Modeling: Ανάπτυξη ML μοντέλων για LNG, μεθανόλη, αμμωνία — τα φυσικά-χημικά χαρακτηριστικά διαφέρουν σημαντικά από HFO/VLSFO, απαιτώντας νέα εκπαίδευση και νέα features (βαθμός ατελούς καύσης, θερμοκρασία φλόγας κ.ά.).
- Port-to-Port Optimization: Ολιστική βελτιστοποίηση που συνδυάζει ML κατανάλωσης πλοίου με λιμενικές λειτουργίες (berth scheduling, cargo operations) σε επίπεδο supply chain — το "Green Shipping Corridor" concept (IMO, 2023).

7.6 Επίλογος

Η κλιματική κρίση και η ρυθμιστική πίεση καθιστούν τη ναυτιλία κλάδο υπό βαθύτατο μετασχηματισμό. Ο IMO στόχος για μηδενικές καθαρές εκπομπές αερίων του θερμοκηπίου έως το 2050 απαιτεί δραστικές αλλαγές σε τεχνολογία καυσίμων, αλλά και σε επιχειρησιακή αποδοτικότητα. Η Μηχανική Μάθηση δεν αποτελεί "ασημένια σφαίρα" — αλλά αποτελεί ένα από τα ισχυρότερα εργαλεία στη διάθεση της ναυτιλιακής βιομηχανίας για την επίτευξη αυτών των στόχων.

Η παρούσα εργασία έδειξε ότι αλγόριθμοι ML — και συγκεκριμένα τα ensemble μοντέλα (Random Forest, Gradient Boosting) και η Πολυωνυμική Παλινδρόμηση — μπορούν να προβλέψουν κατανάλωση καυσίμου με εξαιρετική ακρίβεια, να αναγνωρίσουν τους καθοριστικούς παράγοντες της κατανάλωσης, και να μεταφραστούν σε άμεσες επιχειρησιακές εφαρμογές με σαφή οικονομικά οφέλη. Το αποτέλεσμα αυτό δεν είναι απλώς μια ακαδημαϊκή επίδειξη — είναι η τεκμηρίωση ότι η ψηφιοποίηση της ναυτιλίας είναι εφικτή, αποδοτική και ήδη ώριμη για μεγάλης κλίμακας υλοποίηση.

Το μέλλον ανήκει σε εκείνες τις ναυτιλιακές εταιρείες που θα αξιοποιήσουν τα δεδομένα τους ως στρατηγικό πλεονέκτημα — μετατρέποντας κάθε knot, κάθε kg καυσίμου και κάθε τόνο CO_2 σε ευκαιρίες βελτίωσης. Η παρούσα εργασία αποτελεί ένα βήμα προς αυτή την κατεύθυνση.

ΒΙΒΛΙΟΓΡΑΦΙΑ

Αλφαβητική κατάταξη · APA 7th Edition

ABB. (2020). ABB Ability Marine Advisory System — Voyage Performance Management. ABB Marine & Ports, Oslo.

Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Dean, J., Ghemawat, S., Irving, G., Isard, M., Kudlur, M., Levenberg, J., Monga, R., Moore, S., Murray, D.G., Steiner, B., Tucker, P., Vasudevan, V., Warden, P., Wicke, M., Yu, Y., & Zheng, X. (2016). TensorFlow: A system for large-scale machine learning. 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16), 265–283.

Breiman, L. (2001). Random forests. Machine Learning, 45(1), 5–32.

Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984). Classification and Regression Trees. CRC Press.

Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD 2016), 785–794.

Chuah, L. F., Bokhari, A., Mubashir, M., Abdullah, M. A. A., & Show, P. L. (2025). Maritime decarbonization through machine learning: A critical systematic review of fuel and power prediction models. *Transportation Engineering*, 19, 100290. https://doi.org/10.1016/j.treng.2025.100290

Coraddu, A., Oneto, L., Ghio, A., Savio, S., Anguita, D., & Figari, M. (2016). Machine learning approaches for improving condition-based maintenance of naval vessel propulsion systems. Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment, 230(1), 136–153.

Corbett, J.J., Wang, H., & Winebrake, J.J. (2009). The effectiveness and costs of speed reductions on emissions from international shipping. Transportation Research Part D: Transport and Environment, 14(8), 593–598.

Cui, X., Yang, C., Serrano, J. R., & Shi, M. (2018). A performance degradation evaluation method for a turbocharger in a diesel engine. Royal Society Open Science, 5(12), 181093. https://doi.org/10.1098/rsos.181093

Dietmair, A., & Verl, A. (2009). Energy consumption forecasting and optimisation for tool machines. MM Science Journal, 2009(1), 62–67.

Dinu, O., & Ilie, A. M. (2015). Maritime vessel obsolescence, life cycle cost and design service life. *IOP Conference Series: Materials Science and Engineering*, 95, 012067. https://doi.org/10.1088/1757-899X/95/1/012067

DNV GL. (2020). Technology Outlook 2030: Ship of the Future. DNV GL, Høvik, Norway.

DNV GL. (2021). Energy Management Study 2021: How to Unlock the Value of Ship Energy Data. DNV, Oslo.

Dua, D., & Graff, C. (2019). UCI Machine Learning Repository [Dataset ID 316: Condition Based Maintenance of Naval Propulsion Plants]. University of California, School of Information and Computer Science, Irvine. https://archive.ics.uci.edu/dataset/316

European Commission. (2023). Regulation (EU) 2023/957 of the European Parliament and of the Council amending Regulation (EU) 2015/757 as regards rules for monitoring, reporting and verification of CO_2 emissions from maritime transport, and amending Directives 2009/16/EC and 2009/21/EC. Official Journal of the European Union, L 130, 105–131.

European Parliament & Council of the EU. (2023a). *Directive (EU) 2023/959 amending Directive 2003/87/EC*. Official Journal of the European Union. https://eur-lex.europa.eu/eli/dir/2023/959/2023-05-16/eng

European Parliament & Council of the EU. (2023b). *Regulation (EU) 2023/1805 on the use of renewable and low-carbon fuels in maritime transport*. Official Journal of the European Union. https://eur-lex.europa.eu/eli/reg/2023/1805/oj/eng

Faber, J., Hanayama, S., Zhang, S., Pereda, P., Comer, B., Hauerhof, E., … Mao, X. (2020). *Fourth IMO GHG Study 2020*. International Maritime Organization. https://www.imo.org/en/ourwork/environment/pages/fourth-imo-greenhouse-gas-study-2020.aspx

Faltinsen, O.M. (1990). Sea Loads on Ships and Offshore Structures. Cambridge University Press.

Farag, Y.B.A., & Ölçer, A.I. (2020). The development of a ship performance model in varying operating conditions based on ANN and regression techniques. *Ocean Engineering, 198*, 106972. https://doi.org/10.1016/j.oceaneng.2020.106972

Friedman, J.H. (2001). Greedy function approximation: A gradient boosting machine. Annals of Statistics, 29(5), 1189–1232.

Geman, S., Bienenstock, E., & Doursat, R. (1992). Neural networks and the bias/variance dilemma. Neural Computation, 4(1), 1–58.

Géron, A. (2022). Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow (3rd ed.). O'Reilly Media.

Gkerekos, C., Lazakis, I., & Theotokatos, G. (2019). Machine learning models for predicting ship main engine Fuel Oil Consumption: A comparative study. Ocean Engineering, 184, 205–214.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.

Grieves, M. (2014). Digital twin: Manufacturing excellence through virtual factory replication. White Paper, Florida Institute of Technology.

Guo, W., Jin, Y., & Sun, S. (2020). Prediction of ship fuel consumption based on LSTM neural network. Proceedings of the 39th Chinese Control Conference, 4189–4193.

Harris, C.R., Millman, K.J., van der Walt, S.J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N.J., Kern, R., Picus, M., Hoyer, S., van Kerkwijk, M.H., Brett, M., Haldane, A., del Río, J.F., Wiebe, M., Peterson, P., … Oliphant, T.E. (2020). Array programming with NumPy. Nature, 585, 357–362.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction (2nd ed.). Springer.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. Neural Computation, 9(8), 1735–1780.

Hunter, J.D. (2007). Matplotlib: A 2D graphics environment. Computing in Science & Engineering, 9(3), 90–95.

IMO. (2011). Resolution MEPC.203(62): Amendments to the Annex of the Protocol of 1997 to MARPOL — Energy Efficiency Regulations for New Ships (EEDI) and Ship Energy Efficiency Management Plan (SEEMP). International Maritime Organization, London.

IMO. (2021). Resolution MEPC.328(76): 2021 Revised MARPOL Annex VI (Energy Efficiency Regulations for Ships including EEXI and CII). International Maritime Organization, London.

IMO. (2022). Resolution MEPC.346(78): Amendments to the Guidelines on Survey and Certification of the EEXI (Resolution MEPC.334(76)). International Maritime Organization, London.

IMO. (2023). *2023 IMO Strategy on Reduction of GHG Emissions from Ships*. International Maritime Organization. https://www.imo.org/en/ourwork/environment/pages/2023-imo-strategy-on-reduction-of-ghg-emissions-from-ships.aspx

IMO. (2023a). Resolution MEPC.377(80): 2023 IMO Strategy on Reduction of GHG Emissions from Ships. International Maritime Organization, London.

IMO. (2023b). Fourth IMO GHG Study 2020 — Final Report. MEPC 75/7/15. International Maritime Organization, London.

Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. Proceedings of the 32nd International Conference on Machine Learning (ICML 2015), 448–456.

IPCC. (2023). Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change (Core Writing Team, H. Lee & J. Romero, Eds.). IPCC. https://doi.org/10.59327/IPCC/AR6-9789291691647

ITTC. (2017). ITTC — Recommended Procedures and Guidelines: Predicting Power Increase in Irregular Waves from Model Tests. 28th International Towing Tank Conference, Wiesbaden.

Jeon, M., Noh, Y., Shin, Y., Lim, O.-K., Lee, I., & Cho, D. (2018). Prediction of ship fuel consumption by using an artificial neural network. Journal of Mechanical Science and Technology, 32(12), 5785–5796. https://doi.org/10.1007/s12206-018-1126-4

Kaufman, S., Rosset, S., Perlich, C., & Stitelman, O. (2012). Leakage in data mining: Formulation, detection, and avoidance. ACM Transactions on Knowledge Discovery from Data, 6(4), 1–21. https://doi.org/10.1145/2382577.2382579

Kingma, D.P., & Ba, J. (2015). Adam: A method for stochastic optimization. 3rd International Conference on Learning Representations (ICLR 2015). arXiv:1412.6980.

Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI), 14(2), 1137–1145.

Kongsberg. (2021). K-Chief Fuel Optimization Module — Product Description. Kongsberg Maritime, Kongsberg.

Lazakis, I., Raptodimos, Y., & Varelas, T. (2018). Predicting ship machinery system condition through analytical reliability tools and artificial neural networks. Ocean Engineering, 152, 404–415.

Leifsson, L. Þ., Sævarsdóttir, H., Sigurðsson, S. Þ., & Vésteinsson, A. (2008). Grey-box modeling of an ocean vessel for operational optimization. Simulation Modelling Practice and Theory, 16(8), 923–932. https://doi.org/10.1016/j.simpat.2008.03.006

Liu, F.T., Ting, K.M., & Zhou, Z.H. (2008). Isolation forest. Proceedings of the 8th IEEE International Conference on Data Mining (ICDM 2008), 413–422.

Liu, S., Papanikolaou, A., & Zaraphonitis, G. (2011). Prediction of added resistance of ships in waves. Ocean Engineering, 38(4), 641–650. https://doi.org/10.1016/j.oceaneng.2010.12.007

Lundberg, S.M., & Lee, S.I. (2017). A unified approach to interpreting model predictions. Advances in Neural Information Processing Systems (NIPS 2017), 30, 4765–4774.

Maersk. (2022). Sustainability Report 2022: Decarbonizing Global Supply Chains. A.P. Moller-Maersk, Copenhagen.

MAN Energy Solutions. (2022). MAN B&W Two-Stroke Engine Selection Guide (12th ed.). MAN Energy Solutions, Copenhagen.

Mao, W., Rychlik, I., Wallin, J., & Storhaug, G. (2016). Statistical models for the speed prediction of a container ship. Ocean Engineering, 126, 152–162. https://doi.org/10.1016/j.oceaneng.2016.08.033

McKinney, W. (2010). Data structures for statistical computing in Python. Proceedings of the 9th Python in Science Conference (SciPy 2010), 56–61.

McMahan, H.B., Moore, E., Ramage, D., Hampson, S., & Arcas, B.A. (2017). Communication-efficient learning of deep networks from decentralized data. Proceedings of the 20th International Conference on Artificial Intelligence and Statistics (AISTATS), 1273–1282.

Mitchell, T.M. (1997). Machine Learning. McGraw-Hill.

MSC. (2023). ESG Report 2023: Decarbonisation Roadmap. Mediterranean Shipping Company, Geneva.

Munk, T. (2018). Fuel efficiency and the carbon footprint of antifouling. Journal of Protective Coatings and Linings, 35(4), 18–24.

Notteboom, T., & Cariou, P. (2013). Slow steaming in container liner shipping: Is there any impact on fuel surcharge practices? The International Journal of Logistics Management, 24(1), 73–86. https://doi.org/10.1108/IJLM-05-2013-0055

Pavin, A. (2022). Impact of hull fouling on vessel's fuel consumption and CO_2 emissions. *Athens Journal of Technology & Engineering*, 9(4), 237–252. https://doi.org/10.30958/ajte.9-4-5

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. Journal of Machine Learning Research, 12, 2825–2830.

Petersen, J.P., Jacobsen, D.J., & Winther, O. (2012). Statistical modelling for ship propulsion efficiency. Journal of Marine Science and Technology, 17(1), 30–39.

Platts, S&P Global. (2023). Bunker Fuel Price Monitor Q4 2023. S&P Global Commodity Insights.

Psaraftis, H. N., & Kontovas, C. A. (2013). Speed models for energy-efficient maritime transportation: A taxonomy and survey. *Transportation Research Part C: Emerging Technologies*, 26, 331–351. https://doi.org/10.1016/j.trc.2012.09.012

Raissi, M., Perdikaris, P., & Karniadakis, G.E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. Journal of Computational Physics, 378, 686–707.

Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. Nature Machine Intelligence, 1(5), 206–215.

Rumelhart, D.E., Hinton, G.E., & Williams, R.J. (1986). Learning representations by back-propagating errors. Nature, 323(6088), 533–536.

Schultz, M.P., Bendick, J.A., Holm, E.R., & Hertel, W.M. (2011). Economic impact of biofouling on a naval surface ship. Biofouling, 27(1), 87–98.

Sherbaz, S., & Duan, W. (2014). Ship trim optimization: Assessment of influence of trim on resistance of MOERI container ship. The Scientific World Journal, 2014, 603695. https://doi.org/10.1155/2014/603695

Ship & Bunker. (2024). World bunker prices. https://shipandbunker.com/prices

Smola, A.J., & Schölkopf, B. (2004). A tutorial on support vector regression. Statistics and Computing, 14(3), 199–222.

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. Journal of Machine Learning Research, 15(1), 1929–1958.

Stopford, M. (2009). Maritime Economics (3rd ed.). Routledge.

Tao, F., Zhang, M., Liu, Y., & Nee, A.Y.C. (2019). Digital twin driven prognostics and health management for complex equipment. CIRP Annals, 67(1), 169–172.

Tarelko, W. (2012). Relationships between the ship hull resistance and its trim position. Polish Maritime Research, 19(4), 40–46.

Theodoropoulos, P., Spandonidis, C.C., Giannopoulos, F., & Fassois, S. (2021). Evaluation of deep learning models for improving soft sensor-based prediction of ship fuel consumption. Signals, 2(4), 725–743.

Tukey, J.W. (1977). Exploratory Data Analysis. Addison-Wesley.

UNCTAD. (2023). Review of Maritime Transport 2023. United Nations Conference on Trade and Development, Geneva.

Vapnik, V.N. (1995). The Nature of Statistical Learning Theory. Springer.

Virtanen, P., Gommers, R., Oliphant, T. E., Haberland, M., Reddy, T., Cournapeau, D., … van Mulbregt, P. (2020). SciPy 1.0: Fundamental algorithms for scientific computing in Python. Nature Methods, 17(3), 261–272. https://doi.org/10.1038/s41592-019-0686-2

Wang, K., Li, J., Huang, L., Ma, R., Jiang, X., Yuan, Y., Mwero, N. A., Negenborn, R. R., Sun, P., & Yan, X. (2020). A novel method for joint optimization of the sailing route and speed considering multiple environmental factors for more energy efficient shipping. Ocean Engineering, 216, 107591. https://doi.org/10.1016/j.oceaneng.2020.107591

Wang, S., Ji, B., Zhao, J., Liu, W., & Xu, T. (2018). Predicting ship fuel consumption based on LASSO regression. Transportation Research Part D: Transport and Environment, 65, 817–824. https://doi.org/10.1016/j.trd.2017.09.014

Waskom, M.L. (2021). Seaborn: Statistical data visualization. Journal of Open Source Software, 6(60), 3021.

Wärtsilä. (2021). Wärtsilä Marine Solutions: Engine Technology Overview and Voyage Optimisation. Wärtsilä Corporation, Helsinki.

Wärtsilä. (2023). Marine engine performance and fuel efficiency. Wärtsilä Corporation. https://www.wartsila.com/marine/products/engines-and-generating-sets

Wilcoxon, F. (1945). Individual comparisons by ranking methods. Biometrics Bulletin, 1(6), 80–83.

ΠΑΡΑΡΤΗΜΑ — Οδηγίες Εκτέλεσης Κώδικα

Το παρόν παράρτημα περιγράφει αναλυτικά πώς να εκτελεστεί ο κώδικας της διπλωματικής εργασίας ώστε να αναπαραχθούν πλήρως τα αποτελέσματα που παρουσιάζονται στο Κεφάλαιο 5.

Α. Αρχεία Παράδοσης

Τα παραδοτέα της εργασίας αποτελούνται από τρία αρχεία:

- run_all.py — Ο κώδικας Python. Εκτελεί ολόκληρη την ανάλυση με μία εντολή.
- data.txt — Το dataset UCI Naval Propulsion Plants (Coraddu et al., 2016).
- README.txt — Σύντομες οδηγίες εκτέλεσης.

Και τα τρία αρχεία πρέπει να βρίσκονται στον ίδιο φάκελο πριν την εκτέλεση.

Β. Απαιτήσεις Συστήματος

Απαιτείται Python 3.9 ή νεότερη έκδοση. Οι απαραίτητες βιβλιοθήκες εγκαθίστανται με μία εντολή στο terminal (Command Prompt / PowerShell στα Windows, Terminal στο macOS/Linux):

```
pip install numpy pandas scikit-learn matplotlib seaborn scipy
```

Δεν απαιτείται GPU ή ειδικό hardware. Η εκτέλεση ολοκληρώνεται σε περίπου 3–5 λεπτά σε οποιονδήποτε σύγχρονο υπολογιστή.

Γ. Εκτέλεση

Αφού εγκατασταθούν οι βιβλιοθήκες, η εκτέλεση γίνεται με μία μόνο εντολή από τον φάκελο που περιέχει τα αρχεία:

```
python run_all.py
```

Το πρόγραμμα εκτελεί αυτόματα και με τη σειρά: φόρτωση dataset, εξερευνητική ανάλυση (EDA), προεπεξεργασία, εκπαίδευση 6 μοντέλων ML, αξιολόγηση, ανάλυση feature importance και στατιστικούς ελέγχους Wilcoxon.

Δ. Αποτελέσματα Εκτέλεσης

Κατά την εκτέλεση, το πρόγραμμα εκτυπώνει τα αποτελέσματα στο terminal και δημιουργεί αυτόματα τον φάκελο ./outputs/ με τα ακόλουθα αρχεία:

01_Ιστογράμματα.png — Κατανομές συχνότητας όλων των μεταβλητών
02_Correlation_Heatmap.png — Χάρτης συσχετίσεων Pearson
03_Speed_vs_FC.png — Σχέση ταχύτητας–κατανάλωσης (επιβεβαίωση $P \propto V^3$)
04_Splits.png — Κατανομές Train/Validation/Test sets
05_Σύγκριση_Μετρικών.png — Bar charts R^2/RMSE/MAE/MAPE για όλα τα μοντέλα
06_Predicted_vs_Actual.png — Scatter predicted vs actual για κάθε μοντέλο
07_Κατάλοιπα.png — Ανάλυση καταλοίπων (residuals)
08_Feature_Importance.png — Feature importance RF & Gradient Boosting
αποτελεσματα_test_set.csv — Πίνακας με R^2/RMSE/MAE/MAPE test set
feature_importance.csv — Feature importances όλων των features
descriptive_stats.csv — Περιγραφικά στατιστικά dataset
wilcoxon_tests.csv — Αποτελέσματα Wilcoxon signed-rank tests

Ε. Αναπαραγωγιμότητα Αποτελεσμάτων

Ο κώδικας χρησιμοποιεί σταθερό random seed (SEED=42) σε όλα τα βήματα (train/test split, Random Forest, Gradient Boosting, SVR, MLP), εξασφαλίζοντας πλήρη αναπαραγωγιμότητα των αποτελεσμάτων. Κάθε εκτέλεση του run_all.py παράγει ακριβώς τα ίδια αριθμητικά αποτελέσματα και γραφήματα.

Το dataset (data.txt) είναι το αυθεντικό αρχείο από το UCI Machine Learning Repository (Dataset ID 316), χωρίς καμία τροποποίηση. Η πηγή είναι ελεύθερα προσβάσιμη στη διεύθυνση: https://archive.ics.uci.edu/dataset/316