



ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ
ΣΧΟΛΗ ΧΗΜΙΚΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ
ΜΗΧΑΝΙΚΩΝ ΠΕΡΙΒΑΛΛΟΝΤΟΣ

ΠΡΟΒΛΕΨΗ ΕΝΕΡΓΕΙΑΚΟΥ ΠΡΟΦΙΛ ΤΟΥ ΛΙΜΕΝΑ ΣΟΥΔΑΣ ΓΙΑ ΤΟ ΕΤΟΣ 2030

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
ΤΟΥ
ΚΩΝΣΤΑΝΤΙΝΟΥ ΚΟΥΛΕΤΑΚΗ

ΣΕΛΙΔΑ ΣΚΟΠΙΜΑ ΚΕΝΗ

ΧΑΝΙΑ,
2021



ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ

ΣΧΟΛΗ ΧΗΜΙΚΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ
ΜΗΧΑΝΙΚΩΝ ΠΕΡΙΒΑΛΛΟΝΤΟΣ

ΕΡΓΑΣΤΗΡΙΟ ΑΝΑΝΕΩΣΙΜΩΝ ΚΑΙ
ΒΙΩΣΙΜΩΝ ΕΝΕΡΓΕΙΑΚΩΝ ΣΥΣΤΗΜΑΤΩΝ

ΠΡΟΒΛΕΨΗ ΕΝΕΡΓΕΙΑΚΟΥ ΠΡΟΦΙΛ ΤΟΥ ΛΙΜΕΝΑ ΣΟΥΔΑΣ ΓΙΑ ΤΟ ΕΤΟΣ 2030

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ ΤΟΥ ΚΩΝΣΤΑΝΤΙΝΟΥ ΚΟΥΛΕΤΑΚΗ

ΤΡΙΜΕΛΗΣ ΕΠΙΤΡΟΠΗ:

ΚΑΘΗΓΗΤΗΣ ΘΕΟΧΑΡΗΣ ΤΣΟΥΤΣΟΣ (ΕΠΙΒΛΕΠΩΝ)

ΑΝ. ΚΑΘΗΓΗΤΗΣ ΤΡΥΦΩΝ ΔΑΡΑΣ

ΚΑΘΗΓΗΤΗΣ ΚΩΝΣΤΑΝΤΙΝΟΣ ΚΑΛΑΪΤΖΑΚΗΣ

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για μη κερδοσκοπικό σκοπό, εκπαιδευτικού ή ερευνητικού χαρακτήρα, με την προϋπόθεση να αναφέρεται η πηγή προέλευσης. Ερωτήματα που αφορούν τη χρήση της εργασίας για άλλη χρήση θα 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 Πολυτεχνείου Κρήτης.

Στην μνήμη του πατέρα μου.

ΣΕΛΙΔΑ ΣΚΟΠΙΜΑ ΚΕΝΗ

Πρόλογος και ευχαριστίες

Πριν την σύνταξη της παρούσας διπλωματικής εργασίας, στα πλαίσια των προπτυχιακών μου σπουδών, θα ήθελα να αποδώσω ευχαριστίες στους ανθρώπους που στήριξαν την προσπάθεια αυτή.

Αρχικά, θα ήθελα να ευχαριστήσω την οικογενειά μου για την ανιδιοτελή και καθολική υποστήριξη σε κάθε στάδιο της ζωής μου και κατά την διάρκεια των σπουδών μου.

Έπειτα, θα ήθελα να ευχαριστήσω θερμά τον επιβλέποντα καθηγητή Θεοχάρη Τσούτσο, υπεύθυνο του Εργαστηρίου Ανανεώσιμων και Βιώσιμων Ενεργειακών Συστημάτων, στον Τομέα της Περιβαλλοντικής Διαχείρισης, για την πολύτιμη βοήθεια και καθοδήγηση καθόλη τη διάρκεια της διπλωματικής εργασίας.

Επιπλέον, ένα μεγάλο ευχαριστώ θέλω να αποδώσω ιδιαιτέρως στον υποψήφιο Διδάκτορα Νικόλαο Σηφάκη για την αποτελεσματική και άριστη συνεργασία μας καθόλη την διάρκεια εκπόνησης της διπλωματικής εργασίας, καθώς και για τις συμβουλές και καθοδήγηση που μου προσέφερε σε οποιαδήποτε ανάγκη παρουσιάστηκε και τέλος για την εμπιστοσύνη που μου έδειξε στην διάρκεια της δημιουργίας αυτής της μελέτης.

Επίσης θα ήθελα να ευχαριστήσω τον αναπληρωτή καθηγητή Τρύφων Δάρα για τη πολύτιμη βοήθειά του στο κομμάτι κατανόησης των μεθοδολογιών και για τον χρόνο που αφιέρωσε για την επεξήγησή τους, ο οποίος διετέλεσε επιπλέον μέλος της τριμελούς επιτροπής.

Θα ήθελα, ακόμα, να ευχαριστήσω τον καθηγητή Κωνσταντίνο Καλαϊτζάκη, υπεύθυνο του εργαστηρίου Κυκλωμάτων, Αισθητήρων και Ανανεώσιμων Πηγών Ενέργειας της σχολής Ηλεκτρολόγων Μηχανικών & Μηχανικών Υπολογιστών, που διετέλεσε μέλος της τριμελούς επιτροπής.

Στην συνέχεια, θα ήθελα να ευχαριστήσω τους φορείς για το νόμιμο δικαίωμα συλλογής και χρήσης των πραγματικών δεδομένων. Χάρης τα ενεργειακά δεδομένα που παραχώρησε το προσωπικό του Λιμενικού Ταμείου Χανίων καθώς και τα μετεωρολογικά δεδομένα που παραχώρησε το Εθνικό Αστεροσκοπείο Αθηνών, η διπλωματική εργασία απέκτησε μια πιο ρεαλιστική προοπτική.

Ολοκληρώνοντας, θα ήθελα να ευχαριστήσω τους φίλους μου για όλες τις ευχάριστες στιγμές που μου χαρίζουν και για όλες τις δυσάρεστες που βρίσκονται δίπλα μου.

ΣΕΛΙΔΑ ΣΚΟΠΙΜΑ ΚΕΝΗ

Περιεχόμενα

1. Εισαγωγή	1
1.1 Παγκόσμιο εμπόριο και λιμάνια	1
1.2 Βιώσιμη ανάπτυξη λιμένων	2
1.3 Μηχανική Μάθηση	4
1.3.1 Τεχνητή Νοημοσύνη	4
1.3.2 Μηχανική Μάθηση - Ορισμός και χρήση	6
1.3.3 Κατηγορίες Μηχανικής Μάθησης	6
1.3.3.1. Μάθηση με επίβλεψη (Supervised Learning)	6
1.3.3.2. Μάθηση χωρίς επίβλεψη (Unsupervised Learning)	6
1.3.3.3. Ενισχυτική μάθηση (Reinforcement Learning)	7
1.3.4 Νευρωνικά Δίκτυα Τεχνητής Νοημοσύνης	8
1.4 Μοντέλα Πρόβλεψης	9
1.4.1 Γενικά	9
1.4.2 Πρόοδος στον τομέα προβλέψεων	10
1.4.3 Μοντέλα πρόβλεψης και κατανάλωση ηλεκτρικής ενέργειας	11
1.5 Στόχος	12
1.6 Δομή επόμενων κεφαλαίων	12
2. Βιβλιογραφική ανασκόπηση	13
3. Μεθοδολογία	18
3.1. Περιγραφή περίπτωσης μελέτης	18
3.1.1. Ηλιακό και Αιολικό δυναμικό περιοχής μελέτης	21
3.1.2. Ενεργειακό προφίλ λιμένα Σούδας	26
3.2 Περιγραφή μοντέλων πρόβλεψης	31
3.2.1 Μοντέλο Γραμμικής Παλινδρόμησης (Linear Regression Models)	31
Απλή Γραμμική Παλινδρόμηση (Simple Linear Regression)	31
3.2.2 Μοντέλα Χρονοσειρών (Timeseries Models)	31
3.2.2.1. Μέθοδος Διάσπασης Χρονοσειρών (Decomposition method)	31
3.2.2.2. Μοντέλο Αυτοπαλίνδρου Ολοκληρωμένου Κινούμενου Μέσου (ARIMA)	32
3.2.3. Μέθοδοι Μηχανικής Μάθησης (Machine Learning Methods)	34
3.2.3.1. Δέντρα Αποφάσεων (Decision Trees)	34
3.2.3.2. Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines)	34
3.2.3.3. Gaussian Process Regression – GPR	35
3.2.3.4. Ensemble Methods	37
3.2.3.5. Τεχνητά Νευρωνικά Δίκτυα (Neural Networks)	38
3.3 Περιγραφή διαδικασίας μοντελοποίησης, χρησιμοποιούμενων προγραμμάτων και δεδομένων	40
3.4. Δείκτες σύγκρισης μοντέλων	45

4. Αποτελέσματα.....	46
4.1. Παρουσίαση μοντέλων	46
4.1.1. Ωριαία δεδομένα	46
4.1.1.1. Ωριαίο Μοντέλο Γραμμικής Παλινδρόμησης - Hourly Linear Regression Model (H-LR).....	46
4.1.1.2. Ωριαίο Μοντέλο Τεχνητών Νευρωνικών Δικτύων – Hourly Artificial Neural Network Model (H-ANN).....	51
4.1.1.3. Ωριαίο Μοντέλο Μηχανικής Μάθησης – Hourly Machine Learning Model (H-ML)	55
4.1.2. Ημερήσια δεδομένα	58
4.1.2.1. Ημερήσιο Μοντέλο Γραμμικής Παλινδρόμησης – Daily Linear Regression Model (D-LR).....	58
4.1.2.2. Ημερήσιο Μοντέλο Τεχνητών Νευρωνικών Δικτύων – Daily Artificial Neural Network Model (D-ANN).....	60
4.1.2.3. Ημερήσιο Μοντέλο Μηχανικής Μάθησης – Daily Machine Learning Model (D-ML)	62
4.1.3. Μηνιαία δεδομένα	65
4.1.3.1. Μηνιαίο Μοντέλο Γραμμικής Παλινδρόμησης – Monthly Linear Regression Model (M-LR)	65
4.1.3.2. Μηνιαίο Μοντέλο Τεχνητών Νευρωνικών Δικτύων – Monthly Artificial Neural Network Model (M-ANN).....	68
4.1.3.3. Μηνιαίο Μοντέλο Μηχανικής Μάθησης – Monthly Machine Learning Model (M-ML).....	70
4.1.3.4. Μοντέλο Μεθόδου Διάσπασης Χρονοσειρών - Decomposition Method Model (DM).....	73
4.1.3.5. Box-Jenkins Μέθοδος – Μοντέλο Αυτοπαλίνδρου Ολοκληρωμένου Κινητού Μέσου ARIMA (SARIMA)	75
4.2 Σύγκριση μοντέλων.....	79
4.2.1. Ωριαία δεδομένα	79
4.2.2. Ημερήσια δεδομένα	81
4.2.3. Μηνιαία δεδομένα	82
4.3 Πρόβλεψη ενεργειακού προφίλ λιμένα Σούδας για το 2030.....	83
4.3.1. Πρόβλεψη ενεργειακού προφίλ για το 2030 με βάση το ωριαίο μοντέλο μηχανικής μάθησης (H-ML).....	83
4.3.2. Πρόβλεψη μοντέλου H-ANN για το 2030.	87
4.3.3. Ετήσια πρόβλεψη μοντέλων για το 2030.	91
5. Συμπεράσματα.....	92
5.1 Ανάλυση συμπερασμάτων	92
5.2 Προτάσεις για το μέλλον.....	94
6. Βιβλιογραφία	95
7. Παράρτημα.....	99

Περίληψη

Τα λιμάνια χαρακτηρίζονται από τη γεωγραφική συγκέντρωση των δραστηριοτήτων υψηλής ενεργειακής ζήτησης λόγω της εγγύτητας τους σε μητροπολιτικές περιοχές, καθώς και την λειτουργία τους ως κεντρικών κόμβων για τη μεταφορά πρώτων υλών. Τις τελευταίες δεκαετίες, η ανάγκη για καλύτερη κατανόηση και παρακολούθηση των δραστηριοτήτων που σχετίζονται με την ενέργεια, οι οποίες πραγματοποιούνται κοντά ή μέσα στο λιμάνι, έχει γίνει πιο εμφανής ως συνέπεια της αυξανόμενης συνάφειας των ενεργειακών συναλλαγών, της ευαισθητοποίησης του κοινού για το περιβάλλον και της μεγαλύτερης εστίασης στην βιομηχανική ενεργειακή απόδοση. Με στόχο μια μακροπρόθεσμη αναπτυξιακή στρατηγική, η εκτίμηση της μελλοντικής ενεργειακής απαίτησης είναι απαραίτητη, πράγμα το οποίο υλοποιείται μέσα από μοντέλα πρόβλεψης.

Στην παρούσα διπλωματική εργασία μελετήθηκε το εγχείρημα δημιουργίας ενός υπερσύγχρονου μοντέλου πρόβλεψης του προφίλ της κατανάλωσης ηλεκτρικής ενέργειας που αναμένεται να έχει ο λιμένας Σούδας για το έτος 2030. Για την εκπλήρωση του σκοπού αυτού δημιουργήθηκαν 11 μοντέλα πρόβλεψης χρησιμοποιώντας πραγματικά δεδομένα κατανάλωσης ενέργειας του λιμένα της πενταετίας 2015-2019, καθώς και μετεωρολογικά δεδομένα της περιοχής, διαχωρισμένα σε τρεις βασικές κατηγορίες – ωριαία, ημερήσια και μηνιαία. Ως μέθοδοι χρησιμοποιήθηκαν η Απλή Γραμμική Παλινδρόμηση, η Μέθοδος Διάσπασης Χρονοσειρών, η Box-Jenkins μέθοδος ARIMA καθώς και αλγόριθμοι Μηχανικής Μάθησης και Τεχνητά Νευρωνικά Δίκτυα.

Από την διεξαγωγή της μελέτης και την ανάλυση των αποτελεσμάτων, αρχικά αποκαλύφθηκε πως κύριος παράγοντας ηλεκτρικής απαίτησης αποτελεί ο εξοπλισμός φωτισμού του λιμενικού χώρου, με μεγαλύτερες καταναλώσεις κατά την διάρκεια της νύχτας και την χειμερινή περίοδο. Κατόπιν, το καλύτερο μοντέλο πρόβλεψης κατανάλωσης ενέργειας, σύμφωνα με το μέσο τετραγωνικό σφάλμα MSE ($4,86 \text{ kWh}^2$), ήταν αυτό του αλγορίθμου μηχανικής μάθησης Exponential GPR, με βάση τα ωριαία δεδομένα, το οποίο εκτιμά ετήσια κατανάλωση ενέργειας στις $1.027.649,94 \text{ kWh}$, αυξημένο κατά περίπου 54% σε σχέση με το 2019. Παράλληλα, όλα τα μοντέλα πρόβλεψης εκτιμούν κατανάλωση ηλεκτρικής ενέργειας πάνω από $1.000.000 \text{ kWh}$, γεγονός το οποίο απαιτεί άμεσες ενέργειες στο παρόν για την αντιμετώπιση της ζήτησης αυτής και αναδεικνύει επιπλέον την ανάγκη για περαιτέρω έρευνα στον τομέα δημιουργίας αξιόπιστων μοντέλων πρόβλεψης.

Abstract

Ports are characterized by the geographical concentration of activities of high energy demand due to their proximity to metropolitan areas, as well as their function as central hubs for the transportation of raw materials. In recent decades, the need for a better understanding and monitoring of energy-related activities, which takes place near or in port, has become more apparent as a result of the growing relevance of energy transactions, public awareness of the environment and focus on industrial energy efficiency. Aiming at a long-term development strategy, estimating future energy demand is essential which is implemented through forecasting models.

In the present dissertation, the project of creating a state-of-the-art model for forecasting the electricity consumption profile that the port of Souda is expected to have for the year 2030, was studied. To fulfill this purpose, 11 forecast models were created, using real port energy consumption data from the five-year period 2015-2019 as well as meteorological data of the region, divided into three main categories - hourly, daily and monthly. Simple Linear Regression, Decomposition Method, Box-Jenkins ARIMA method, as well as Machine Learning algorithms and Artificial Neural Networks, were used as methods.

From the conduct of the study and the analysis of the results, it was initially revealed that the main factor of electrical demand is the lighting equipment of the port area, with higher consumption during the night and the winter period. Then, the best model for predicting energy consumption, according to the mean square error MSE (4.86 kWh^2), was that of the Exponential GPR machine learning algorithm, based on hourly data, which estimates annual energy consumption at $1,027,649.94 \text{ kWh}$, an increase of about 54% compared to 2019. At the same time, all forecast models estimate electricity consumption of over $1,000,000 \text{ kWh}$, which requires immediate action now to address this demand and highlights the need for further research in the field of creating reliable forecasting models.

Πίνακας Συντομογραφιών

Ακαθάριστο Εγχώριο Προϊόν	ΑΕΠ
Τεχνητή Νοημοσύνη	TN
Τεχνητά Νευρωνικά Δίκτυα	TNΔ
Μηχανική Μάθηση	MM
Ανανεώσιμες Πηγές Ενέργειας	ΑΠΕ
Φωτοβολταϊκά	Φ/Β
Machine Learning	ML
Artificial Neural Networks	ANN
Artificial Intelligence	AI
Linear Regression	LR
Autoregressive Integrated Moving Average	ARIMA
Support Vector Machines	SVM
Gaussian Process Regression	GPR
Backpropagation	BP
Mean Squared Error	MSE
Root Mean Squared Error	RMSE
Hourly Linear Regression Model	H-LR
Hourly Artificial Neural Network	H-ANN
Daily Linear Regression Model	D-LR
Daily Artificial Neural Network	D-ANN
Daily Machine Learning Model	D-ML
Monthly Linear Regression Model	M-LR
Monthly Artificial Neural Network	M-ANN
Monthly Machine Learning Model	M-ML
Decomposition Method Model	DM
Box-Jenkins ARIMA Model	SARIMA

Κατάλογος Πινάκων

Πίνακας 1. Δεδομένα περιοχής Σούδας ανά χρόνο.	21
Πίνακας 2. Δεδομένα για το 10% των πιο ανεμώδη περιοχών.	24
Πίνακας 3. Διακύμανση ωριαίας κατανάλωσης ηλεκτρικής ενέργειας (kWh) για τα έτη 2015-2019.	26
Πίνακας 4. Διακύμανση ημερήσιας κατανάλωσης ηλεκτρικής ενέργειας (kWh) για τα έτη 2015-2019.	29
Πίνακας 5. Διακύμανση μηνιαίας κατανάλωσης ηλεκτρικής ενέργειας για τα έτη 2015-2019.	29
Πίνακας 6. Όροι εξίσωσης (19).	46
Πίνακας 7. Ανάλυση συντελεστών εξίσωσης (19).	46
Πίνακας 8. Pairwise Pearson Correlations	47
Πίνακας 9. Ανάλυση διακύμανσης.	47
Πίνακας 10. Διακύμανση ωριαίας κατανάλωσης ηλεκτρικής ενέργειας (kWh) μοντέλου H-LR.	49
Πίνακας 11. Αποτελέσματα μοντέλου H-ANN.	51
Πίνακας 12. Διακύμανση ωριαίας κατανάλωσης ηλεκτρικής ενέργειας (kWh) μοντέλου H-ANN.	53
Πίνακας 13. Αποτελέσματα αλγορίθμων μηχανικής μάθησης για ωριαία δεδομένα.	55
Πίνακας 14. Διακύμανση ωριαίας κατανάλωσης ηλεκτρικής ενέργειας (kWh) μοντέλου H-ML.	55
Πίνακας 15. Όροι εξίσωσης (20).	58
Πίνακας 16. Ανάλυση συντελεστών εξίσωσης (20).	58
Πίνακας 17. Διακύμανση ημερήσιας κατανάλωσης ηλεκτρικής ενέργειας (kWh) μοντέλου D-LR.	59
Πίνακας 18. Αποτελέσματα μοντέλου D-ANN.	60
Πίνακας 19. Διακύμανση ημερήσιας κατανάλωσης ηλεκτρικής ενέργειας (kWh) μοντέλου D-ANN.	61
Πίνακας 20. Αποτελέσματα αλγορίθμων μηχανικής μάθησης για ημερήσια δεδομένα.	63
Πίνακας 21. Χαρακτηριστικά μοντέλου D-ML.	63
Πίνακας 22. Διακύμανση ημερήσιας κατανάλωσης ηλεκτρικής ενέργειας (kWh) μοντέλου D-ML.	63
Πίνακας 23. Όροι εξίσωσης (21).	65
Πίνακας 24. Ανάλυση συντελεστών εξίσωσης (21).	66
Πίνακας 25. Διακύμανση τιμών ηλεκτρικής ενέργειας (kWh) μοντέλου M-LR.	67
Πίνακας 26. Αποτελέσματα μοντέλου M-ANN.	68
Πίνακας 27. Διακύμανση τιμών ηλεκτρικής ενέργειας (kWh) μοντέλου M-ANN.	70
Πίνακας 28. Αποτελέσματα αλγορίθμων μηχανικής μάθησης για μηνιαία δεδομένα.	70
Πίνακας 29. Διακύμανση τιμών ηλεκτρικής ενέργειας (kWh) μοντέλου M-ML.	71
Πίνακας 30. Διακύμανση τιμών ηλεκτρικής ενέργειας (kWh) μοντέλου DM.	74
Πίνακας 31. Διακύμανση τιμών ηλεκτρικής ενέργειας (kWh) μοντέλου SARIMA.	78
Πίνακας 32. Σύγκριση ωριαίων μοντέλων.	79
Πίνακας 33. Σύγκριση ημερήσιων μοντέλων.	81
Πίνακας 34. Σύγκριση μηνιαίων μοντέλων.	82
Πίνακας 35. Διακύμανση τιμών ωριαίας κατανάλωσης ηλεκτρικής ενέργειας (kWh) για το έτος 2030.	83
Πίνακας 36. Διακύμανση τιμών ημερήσιας κατανάλωσης ηλεκτρικής ενέργειας (kWh) για το έτος 2030.	85
Πίνακας 37. Διακύμανση τιμών ωριαίας κατανάλωσης ηλεκτρικής ενέργειας (kWh) για το έτος 2030.	87
Πίνακας 38. Διακύμανση τιμών ημερήσιας κατανάλωσης ηλεκτρικής ενέργειας (kWh) για το έτος 2030.	89
Πίνακας 39. Ετήσια πρόβλεψη κατανάλωσης ηλεκτρικής ενέργειας όλων των χρησιμοποιούμενων μοντέλων για το έτος 2030.	91

Πίνακας 40. Ημερήσιες προβλεπόμενες καταναλώσεις ηλεκτρικής ενέργειας για το 2030.	102
---	-----

Κατάλογος Σχημάτων

Σχήμα 1. Τεχνητή Νοημοσύνη.	5
Σχήμα 2. Διάγραμμα Ροής επιλογής κατάλληλου αλγορίθμου μηχανικής μάθησης.	7
Σχήμα 3. Πολυεπίπεδο ΤΝΔ πρόσθιας τροφοδοσίας.	38
Σχήμα 4. Αυτο-συσχετιζόμενη (αριστερά) και ετερο-συσχετιζόμενη (δεξιά) μνήμη.	39
Σχήμα 5. Διάγραμμα ροής μεθοδολογίας.	41
Σχήμα 6. Διάγραμμα ροής δημιουργίας μοντέλων.	41
Σχήμα 7. Διαχωρισμός δεδομένων για εκπαίδευση, επικύρωση και δοκιμή.	51
Σχήμα 8. Μορφή μοντέλου H-ANN.	51
Σχήμα 9. Μορφή μοντέλου D-ANN.	60
Σχήμα 10. Μορφή μοντέλου M-ANN.	68
Σχήμα 11. Κώδικας MATLAB για την δημιουργία του μοντέλου μηχανικής μάθησης.	99
Σχήμα 12. Κώδικας MATLAB για την δημιουργία του μοντέλου τεχνητών νευρωνικών δικτύων.	100
Σχήμα 13. Κώδικας R συνάρτησης auto.arima()	101

Κατάλογος Διαγραμμάτων

Διάγραμμα 1. Μηνιαίο προφίλ άμεσης κανονικής ακτινοβολίας.	23
Διάγραμμα 2. Ωριαίο προφίλ άμεσης κανονικής ακτινοβολίας [58].	23
Διάγραμμα 3. Ιστόγραμμα ταχύτητας ανέμου.	25
Διάγραμμα 4. Ωριαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας.	26
Διάγραμμα 5. Ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας.	27
Διάγραμμα 6. Μέσο ωριαίο προφίλ απαίτησης ηλεκτρικής ισχύος για τα έτη 2015-2019.	28
Διάγραμμα 7. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας.	29
Διάγραμμα 8. Προφίλ κατανάλωσης ηλεκτρικής ενέργειας από το 2015-2019 σε μηνιαία βάση.	30
Διάγραμμα 9. Μέση ημερήσια κατανάλωση ηλεκτρικής ενέργειας για τα έτη 2015-2019.	30
Διάγραμμα 10. 95% διάστημα εμπιστοσύνης για τη διαφορά μεταξύ των μέσων.	48
Διάγραμμα 11. Υπολείμματα (residuals) μοντέλου H-LR.	48
Διάγραμμα 12. Μέσο ωριαίο προφίλ απαίτησης ηλεκτρικής ισχύος του μοντέλου H-LR.	50
Διάγραμμα 13. Διακύμανση σφαλμάτων μοντέλου H-ANN	53
Διάγραμμα 14. Μέσο ωριαίο προφίλ απαίτησης ηλεκτρικής ισχύος μοντέλου H-ANN.	54
Διάγραμμα 15. Διακύμανση σφαλμάτων μοντέλου H-ML.	56
Διάγραμμα 16. Μέσο ωριαίο προφίλ απαίτησης ηλεκτρικής ισχύος μοντέλου H-ML.	57
Διάγραμμα 17. Ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου D-LR σε σύγκριση με το πραγματικό.	59
Διάγραμμα 18. Διακύμανση σφαλμάτων μοντέλου D-LR.	60
Διάγραμμα 19. Ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου D-ANN σε σύγκριση με το πραγματικό.	62
Διάγραμμα 20. Υπολείμματα μοντέλου D-ANN.	62
Διάγραμμα 21. Ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου D-ML σε σύγκριση με το πραγματικό.	64
Διάγραμμα 22. Διακύμανση σφαλμάτων μοντέλου D-ML.	65
Διάγραμμα 23. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου M-LR σε σύγκριση με το πραγματικό.	67
Διάγραμμα 24. Διακύμανση σφαλμάτων μοντέλου M-LR.	67
Διάγραμμα 25. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου M-ANN σε σύγκριση με το πραγματικό.	69

Διάγραμμα 26. Υπολείμματα μοντέλου M-ANN.....	70
Διάγραμμα 27. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου M-ML σε σύγκριση με το πραγματικό.....	72
Διάγραμμα 28. Διακύμανση σφαλμάτων μοντέλου M-ML.....	72
Διάγραμμα 29. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου DM σε σύγκριση με το πραγματικό.....	74
Διάγραμμα 30. Διακύμανση σφαλμάτων μοντέλου DM.	74
Διάγραμμα 31. Διάγραμμα αυτοσυσχέτισης υπολοίπων χρονοσειράς.	76
Διάγραμμα 32. Διάγραμμα μερικής αυτοσυσχέτισης υπολοίπων χρονοσειράς.	76
Διάγραμμα 33. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου SARIMA σε σύγκριση με το πραγματικό.....	77
Διάγραμμα 34. Προφίλ πρόβλεψης μοντέλου SARIMA έως το 2030.....	77
Διάγραμμα 35. Διακύμανση σφαλμάτων μοντέλου SARIMA.	78
Διάγραμμα 36. Μέσο ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου H-ANN.....	80
Διάγραμμα 37. Μέσο ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου H-ML.	80
Διάγραμμα 38. Ωριαία απαίτηση ηλεκτρικής ισχύος για το 2030.	84
Διάγραμμα 39. Ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας για το έτος 2030..	85
Διάγραμμα 40. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας για το έτος 2030. ...	86
Διάγραμμα 41. Ετήσια κατανάλωση ηλεκτρικής ενέργειας για το έτος 2030.....	86
Διάγραμμα 42. Ωριαία απαίτηση ηλεκτρικής ισχύος του μοντέλου H-ANN για το 2030. ..	88
Διάγραμμα 43. Ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας του μοντέλου H-ANN για το έτος 2030.....	89
Διάγραμμα 44. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας του μοντέλου H-ANN για το έτος 2030.	89
Διάγραμμα 45. Ετήσια κατανάλωση ηλεκτρικής ενέργειας του μοντέλου H-ANN για το έτος 2030.....	90
Διάγραμμα 46. Σύγκριση πρόβλεψης μοντέλων H-ML και H-ANN για το 2030.	90
Διάγραμμα 47. Ετήσια πρόβλεψη κατανάλωσης ηλεκτρικής ενέργειας όλων των χρησιμοποιούμενων μοντέλων για το έτος 2030.	91

Κατάλογος Εικόνων

Εικόνα 1. Θαλάσσιος και Ηπειρωτικός Δρόμος του Μεταξιού [10].	2
Εικόνα 2. Ψηφιακή αναπαράσταση φυσικού νευρώνα [26].	8
Εικόνα 3. Κάτοψη Λιμένα Σούδας [33].	18
Εικόνα 4. Θέση και χαρακτηριστικά λιμένα [33].	19
Εικόνα 5. (α) Κίνηση πλοίων στο λιμάνι της Σούδας, (β) Κίνηση κρουαζιερόπλοιων στο λιμάνι της Σούδας, (γ) Κίνηση κρουαζιερόπλοιων στα λιμάνια της Κρήτης το 2019, (δ) Συνολικοί διακινηθέντες εσωτερικού στα λιμάνια της Κρήτης το 2018.	20
Εικόνα 6. Πόλη και λιμένας Σούδας [58].	21
Εικόνα 7. (α) Μακροπρόθεσμος μέσος όρος ετήσιων συνόλων άμεσης κανονικής ακτινοβολίας [58], (β) Μακροπρόθεσμος μέσος όρος ετήσιων συνόλων δυναμικού Φ/Β ισχύος [58].	22
Εικόνα 8. (Αριστερά) Μέση ταχύτητα ανέμου στα 100m [59], (Δεξιά) Μέση πυκνότητα ισχύος ανέμου στα 100m [59].	24
Εικόνα 9. Ωριαία και Μηνιαία ταχύτητα ανέμου [59].	24
Εικόνα 10. (α) Μέση ταχύτητα ανέμου σε μηνιαία βάση [59], (β) Μέση ταχύτητα ανέμου σε ωριαία βάση [59].	25
Εικόνα 11. Παράδειγμα δέντρου αποφάσεων.	34
Εικόνα 12. Παράδειγμα SVM [64].	35
Εικόνα 13. Παράδειγμα μοντέλου GPR [67].	36
Εικόνα 14. Παράδειγμα ενός Ensemble μοντέλου.	37
Εικόνα 15. Παράδειγμα 5-fold cross-validation [74].	43
Εικόνα 16. Μεθόδους στην εφαρμογή Minitab που χρησιμοποιήθηκαν I.	43
Εικόνα 17. Μεθόδους στην εφαρμογή Minitab που χρησιμοποιήθηκαν II.	44
Εικόνα 18. Εφαρμογές στο περιβάλλον της MATLAB που χρησιμοποιήθηκαν.	44
Εικόνα 19. Περιβάλλον εφαρμογής R-studio.	44
Εικόνα 20. Διαγράμματα παλινδρόμησης του μοντέλου H-ANN για όλα τα στάδια.	52
Εικόνα 21. Διάγραμμα παλινδρόμησης για το μοντέλο H-ML.	56
Εικόνα 22. Διαγράμματα παλινδρόμησης του μοντέλου D-ANN για όλα τα στάδια.	61
Εικόνα 23. Διάγραμμα παλινδρόμησης για το μοντέλο D-ML.	64
Εικόνα 24. Διαγράμματα παλινδρόμησης του μοντέλου M-ANN για όλα τα στάδια.	69
Εικόνα 25. Διάγραμμα παλινδρόμησης για το μοντέλο M-ML.	71
Εικόνα 26. Ανάλυση στοιχείων χρονοσειράς.	73
Εικόνα 27. Αποτελέσματα μοντέλου SARIMA.	75
Εικόνα 28. Ljung-Box test	75
Εικόνα 29. Μέσο ωριαία προφίλ απαίτησης ηλεκτρικής ισχύος για τα έτη 2015-2019 – (α) Πραγματικό, (β) Μοντέλο H-LR, (γ) Μοντέλο H-ANN και (δ) Μοντέλο H-ML.	79
Εικόνα 30. Ημερήσια προφίλ κατανάλωσης ηλεκτρικής ενέργειας για τα έτη 2015-2019 – (α) Μοντέλο D-LR, (β) Μοντέλο D-ANN και (γ) Μοντέλο D-ML.	81
Εικόνα 31. Μηνιαία προφίλ κατανάλωσης ηλεκτρικής ενέργειας για τα έτη 2015-2019 – (α) Μοντέλο M-LR, (β) Μοντέλα DM, (γ) Μοντέλο M-ANN και M-ML και (δ) Μοντέλο SARIMA	82

1. Εισαγωγή

1.1 Παγκόσμιο εμπόριο και λιμάνια

Οι διηπειρωτικές και μικρών αποστάσεων θαλάσσιες μεταφορές αντιπροσωπεύουν το 90% του παγκόσμιου εμπορίου, συμβάλλοντας σημαντικά στην οικονομική και κοινωνική ανάπτυξη σε παγκόσμια κλίμακα, με τα λιμάνια να είναι οι ζωτικοί σύνδεσμοι στην αλυσίδα των θαλάσσιων μεταφορών έχοντας καθοριστικό αντίκτυπο στην ποιότητά τους. Οι θαλάσσιες μεταφορές αποκτούν ολοένα και πιο ηγετικό ρόλο στο παγκόσμιο εμπόριο [1], [2], με τους ερευνητές να επισημαίνουν ότι οι επενδύσεις σε λιμενικές υποδομές έχουν άμεση επιρροή στην εθνική οικονομία, καθώς τα λιμάνια διαδραματίζουν σημαντικό ρόλο στην παγκόσμια μεταφορά ανθρώπων και αγαθών, και περιλαμβάνουν αρκετούς παράγοντες, όπως εταιρείες πλοίων, φορτηγών, logistics καθώς και τοπικές αρχές, πολίτες κ.λπ. Οι θαλάσσιες μεταφορές και ειδικά τα εμπορευματοκιβώτια (φορτία) αντιπροσωπεύουν τη μεγαλύτερη προστιθέμενη αξία σε όρους εμπορικής ανταλλαγής και είναι πιστός οικονομικός δείκτης [3]. Η δυναμική μεταξύ Ακαθάριστου Εθνικού Εγχώριου Προϊόντος (ΑΕΠ) και δεικτών κίνησης προϊόντων έχουν αναδειχθεί ως ένα κρίσιμο στοιχείο για την εμπορική στρατηγική των εμπλεκόμενων φορέων στις ναυτιλιακές επιχειρήσεις [4].

Η Ευρώπη επωφελείται από μια μεγάλη ακτογραμμή που φτάνει από την Βαλτική, στη Μεσόγειο και τη Μαύρη Θάλασσα, με το ευρωπαϊκό λιμενικό σύστημα εμπορευματοκιβωτίων να είναι ένα από τα πιο απασχολημένα σε όλο τον κόσμο. Το ευρωπαϊκό λιμενικό σύστημα δεν μπορεί να θεωρηθεί ως ένα ομοιογενές σύνολο λιμένων. Διαθέτει καθιερωμένα μεγάλα λιμάνια, καθώς και μια ολόκληρη σειρά από μεσαίου και μικρού μεγέθους λιμάνια, το καθένα με συγκεκριμένα χαρακτηριστικά και δυνατότητες ανάλογα με τις ενδοχώριες αγορές που εξυπηρετούν, τα εμπορεύματα που διαχειρίζονται και τις ιδιότητες της τοποθεσίας που βρίσκονται. Αυτό το μείγμα διαφορετικών τύπων και μεγεθών λιμένων σε συνδυασμό με μια τεράστια οικονομικά ισχυρή ενδοχώρα, διαμορφώνει την ιεραρχία των λιμένων και του ανταγωνισμού στην περιοχή.

Με το εμπόριο μεταξύ Ευρώπης και Άπω Ανατολής να γίνεται η σημαντικότερη οδός του διεθνούς εμπορίου στο δεύτερο μισό της δεκαετίας του 1990 και ύστερα, παρατηρείται η μεταφορά του επίκεντρου των εμπορευματομεταφορών από και προς την Ανατολή. Συγκεκριμένα γίνεται μετάβαση των εμπορικών ροών από την Ατλαντική δίοδο σε αυτήν της διώρυγας του Σουέζ, με αποτέλεσμα την μετάβαση της εμπορικής δύναμης από την Βόρεια Θάλασσα στην Μεσόγειο και την δημιουργία ευκαιριών στις χώρες της Μεσογείου. Επίσης, σημαντικό παράγοντα για την μετάβαση της εμπορικής ροής από το πλέγμα λιμανιών Αμβούργο – Αντβέρπη – Ρότερνταμ - Χάβρη σε αυτό της Μεσογείου (Πειραιάς - Γένοβα – Μασσαλία – Βαρκελώνη – Βαλένθια) είναι τα ευεργετικά προς το περιβάλλον αποτελέσματα, καθώς τα πλοία που πλέουν από την διώρυγα του Σουέζ δεν χρειάζεται να παρακάμψουν την Ιβηρική Χερσόνησο, μειώνοντας τους ρύπους CO₂ και NO_x έως και 15%, και τα πλοία κερδίζουν χρόνο μεταφοράς έως και πέντε ημέρες [5], [6].

Η Ελλάδα διαθέτει την μεγαλύτερη ακτογραμμή της Ευρώπης και κατέχει μια άκρως σημαντική γεωγραφική θέση. Τα σύνορα της Ελλάδας αποτελούν και σύνορα της Ευρωπαϊκής Ένωσης, καθιστώντας έτσι την Ελλάδα την κυριότερη πύλη των εμπορικών πλοίων από την Εγγύς και Άπω Ανατολή, που εισέρχονται στην Μεσόγειο θάλασσα μέσω της διώρυγας του Σουέζ. Επιπλέον, στις θερινές περιόδους, τα Ελληνικά νησιά αποτελούν περιβόητο προορισμό για τουρίστες με αποτέλεσμα την προσέλευση κρουαζιερόπλοιων και την αυξημένη κινητικότητα των εγχώριων επιβατικών πλοίων.

Σημαντικός είναι ο ρόλος της Ελλάδας στο εμπόριο μεταξύ Ευρώπης και Κίνας, με την Ελλάδα να είναι η πρώτη πύλη της Ευρώπης στο Θαλάσσιο Δρόμο του Μεταξιού (*Maritime Silk Road – MSR*) [7] (**Εικόνα 1**). Η Κίνα, μέσω επενδύσεων της Cosco, του ύψους των 660.000.000 €, στοχεύει να αναπτύξει το λιμάνι του Πειραιά στο σημαντικότερο λιμάνι της Μεσογείου, με το λιμάνι να μεγαλώνει σε μέγεθος και να διαχειρίζεται 700% παραπάνω όγκο φορτίων από ότι το 2008. Κατά αυτό τον τρόπο το λιμάνι του Πειραιά καθίσταται το τρίτο πιο πολυσύχναστο λιμάνι στην Μεσόγειο μετά από τα λιμάνια της Βαλένθιας και της Αλχεθίρας, στην Ισπανία [8]. Σε παγκόσμια κλίμακα το λιμάνι του Πειραιά καταλαμβάνει την 32^η θέση, διατηρώντας ανοδική τάση με την κίνηση στο λιμάνι να έχει αυξηθεί περίπου κατά 50% τα τελευταία τρία χρόνια [9].



Εικόνα 1. Θαλάσσιος και Ηπειρωτικός Δρόμος του Μεταξιού [10].

1.2 Βιώσιμη ανάπτυξη λιμένων

Στο πλαίσιο της παγκόσμιας ενεργειακής κρίσης και της περιβαλλοντικής υποβάθμισης, η αειφόρος ανάπτυξη έχει γίνει η κύρια στρατηγική κατεύθυνση για τη λιμενική βιομηχανία. Η αειφόρος ανάπτυξη επηρεάζει τη παραγωγή, κατασκευή και διαχείριση διεργασιών του λιμανιού, με βάση τρεις πτυχές, την οικονομική ανάπτυξη, την ποιότητα του περιβάλλοντος και την κοινωνική ευημερία [11]. Αναφορικά με την οικονομία, τα λιμάνια πρέπει να βελτιώνουν συνεχώς την παραγωγική απόδοση, την τεχνική ικανότητα και το επίπεδο διαχείρισης για να ενισχύσουν τη βιώσιμη ανταγωνιστικότητά τους. Σχετικά με το περιβάλλον, τα λιμάνια οφείλουν να εξοικονομήσουν ενέργεια, να μειώσουν τις εκπομπές και να διασφαλίσουν ότι το περιβάλλον και οι φυσικοί πόροι δεν θα υποστούν ζημιά. Στα κοινωνικά πλαίσια, είναι σημαντικό να ενισχυθεί η ενσωμάτωση των πόρων και άλλα συμπληρωματικά πλεονεκτήματα με τους γύρω λιμένες για την επίτευξη περιφερειακής ανάπτυξης [12]. Επομένως, προκειμένου να προσαρμοστούν σε αυτές τις απαιτήσεις, πολλά λιμάνια παγκοσμίως φέρνουν και ναυτιλιακές εταιρείες σε όλο τον κόσμο, έχουν αρχίσει να καταβάλλουν προσπάθειες για βιώσιμη ανάπτυξη [7].

Τα λιμάνια ανήκουν, διαχειρίζονται και συντηρούνται από διάφορους τύπους διοίκησης και μέτοχους οι οποίοι διαφέρουν σε μέγεθος, γεωλογικό και γεωγραφικό περιβάλλον, καθώς και στις δραστηριότητες και στις στρατηγικές τους, πράγμα το οποίο επηρεάζει την τελική τους απόφαση σχετικά με την επένδυση, επέκταση και λειτουργία των λιμανιών [13], [14]. Ορισμένοι λιμένες διαχειρίζονται πλήρως από δημόσιες αρχές ή με υβριδική δημόσια – ιδιωτική επιμέλεια και άλλοι από πλήρως ιδιωτική επιμέλεια. Παρόλη τη διαφορά μεταξύ δημόσιου και ιδιωτικού στόχου, υπάρχουν κοινές επιδιώξεις σχετικά με την βελτίωση των λειτουργιών τους, την αξιοπιστία και την οικονομική βιωσιμότητά τους [15], [16] .

Ένας σημαντικός ελκυστικός παράγοντας για την μετάβαση σε μια πιο βιώσιμη ανάπτυξη είναι η προσέλκυση και διατήρηση πελατών που εκτιμούν την βιωσιμότητα. Ο ενεργός εταιρικός προσανατολισμός και η απτή δέσμευση στην παροχή περιβαλλοντικών επιδόσεων μπορεί να είναι μια επιχειρηματική ευκαιρία. Μέσω του πράσινου μάρκετινγκ (*green marketing*) [11], [17], [18], τα λιμάνια μπορούν να στοχεύσουν στην απόκτηση επωνυμίας «πράσινο λιμάνι» (*green port*) [19], [20] .

Ένα «πράσινο λιμάνι» (*Green Port*), αλλιώς οικολογικό λιμάνι, είναι ένα λιμάνι βιώσιμης ανάπτυξης, το οποίο, πέραν του ότι πληροί τις περιβαλλοντικές απαιτήσεις, αποκτά θετικά οικονομικά συμφέροντα. Ο όρος πράσινο λιμάνι προμηνύει μια εξισορρόπηση μεταξύ οικονομικών συμφερόντων και της φέρουσας ικανότητας του περιβάλλοντος συστήματος. Σημείο ισορροπίας μπορεί να βρεθεί στη σωστή περιβαλλοντική κατανάλωση και της οικονομικό-κοινωνικής ανάπτυξης, ώστε να μην υπάρξουν μη-αναστρέψιμες περιβαλλοντικές αλλαγές. Κύριο πόνημα ενός οικολογικού λιμένα, είναι η εναρμόνιση της αποδοτικότητας του λιμανιού με την βιώσιμη κατασκευή ενός περιβαλλοντικού-κοινοτικού-οικολογικού συστήματος στο λιμάνι. Αποτέλεσμα αυτού είναι η καταξίωση του λιμένα σε μια πρωτοπόρα θέση στις σύγχρονες μεταφορές, λιμενικές υπηρεσίες και logistics [21] .

Εκτός από καλή φήμη τα λιμάνια μπορούν επιπλέον να επιτύχουν μακροπρόθεσμη βιώσιμη ανάπτυξη, κοινωνική ευθύνη και οικονομικά οφέλη. Επομένως, υπάρχει ανάγκη για μακροπρόθεσμη αναπτυξιακή στρατηγική στα λιμάνια, για τη διερεύνηση των τάσεων εξέλιξης και για προτάσεις αντιμέτρων για τη μελλοντική τους ανάπτυξη.

Στα πλαίσια της μακροπρόθεσμα βιώσιμης αναπτυξιακής στρατηγικής υπάρχει σημαντική ανάγκη για την δημιουργία υπερσύγχρονων μοντέλων πρόβλεψης τόσο ενεργειακών καταναλώσεων, όσο και εκπομπών ρύπων στους λιμένες. Με την αυξανόμενη πρόοδο στον τομέα της επιστήμης των δεδομένων (*data science*), της τεχνητής νοημοσύνης (*artificial intelligence*) και την ανάπτυξη περίπλοκων αλγορίθμων από μηχανές μάθησης (*machine learning*), τα εργαλεία για την επίλυση περίπλοκων προβλημάτων, την δημιουργία δυναμικών μοντέλων βραχυπρόθεσμων και μακροπρόθεσμων προβλέψεων και την εύρεση μοτίβων στις καταναλώσεις ενέργειας και εκπομπές ρύπων με κλιματικούς, κοινωνικούς και άλλους παράγοντες, μέσω υπολογιστών, δύναται να αντικαταστήσουν τα κλασσικά στατιστικά και εμπειρικά μοντέλα.

1.3 Μηχανική Μάθηση

1.3.1 Τεχνητή Νοημοσύνη


Η τεχνητή νοημοσύνη (*Artificial Intelligence – AI*) ανήκει στον τομέα της επιστήμης των υπολογιστών η οποία ασχολείται με την ανάπτυξη συστημάτων που παρουσιάζουν ευφυή χαρακτηριστικά, όπως ο άνθρωπος. Από την κατανόηση των δυνατοτήτων της νοημοσύνης, ο άνθρωπος προσπαθεί να προσδώσει αυτό το χαρακτηριστικό στις μηχανές, με στόχο την επίλυση περίπλοκων προβλημάτων και την προσφορά υπηρεσιών. Τα συστήματα τεχνητής νοημοσύνης μπορούν να αναλύουν σύνθετα και μεγάλα δεδομένα, πολλές φορές και σε μικρό χρονικό διάστημα, και να ανακαλύπτουν μοτίβα καθώς και πρότυπα μεταξύ των δεδομένων, συμβάλλοντας με αυτόν τον τρόπο στη λήψη καλύτερων αποφάσεων [22].

Η επίσημη εμφάνιση της τεχνητής νοημοσύνης, στην επιστημονική κοινότητα, έγινε στα περίπου στα μέσα του 20ου αιώνα, σε ένα συνέδριο παρουσίασης ενός προγράμματος συλλογισμού με δυνατότητα απόδειξης μαθηματικών θεωρημάτων, και την οριστική ονομασία ως Τεχνητή Νοημοσύνη. Αρκετές επιστήμες συνεισφέραν για την θεμελίωση της νέας αυτής ερευνητικής περιοχής. Φιλοσοφία και Ψυχολογία, έκαναν αντιληπτή την ύπαρξη της τεχνητής νοημοσύνης μέσω της συλλογιστικής στο ότι μπορούμε να επιλέξουμε μια ενέργεια, ορθολογικά, μέσω της γνώσης και πως όμοια με μια μηχανή το άτομο μπορεί να θεωρηθεί ως μηχανή επεξεργασίας πληροφοριών. Τα Μαθηματικά παρέχουν τα εργαλεία για την εξαγωγή έγκυρων συμπερασμάτων μέσω της Θεωρίας υπολογισμού, τις Πιθανότητες και τον τομέα της Λογικής. Οι Νευροεπιστήμες μέσω μελέτης του ανθρώπινου εγκεφάλου και του νευρικού του συστήματος, έδωσαν το έναυσμα για την δημιουργία τεχνικών μίμησης των νευρώνων του εγκεφάλου, από όπου προέκυψαν τα Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ). Τέλος, η επιστήμη των υπολογιστών έδωσε την δυνατότητα εφαρμογής της τεχνητής νοημοσύνης, αξιοποιώντας το τεχνικό υπόβαθρο των υπολογιστών και του προγραμματισμού [22], [23] .

Βασικές προσεγγίσεις της Τεχνητής Νοημοσύνης θεωρούνται οι εκατέρωθεν:

- ❖ Η Συμβολική προσέγγιση βασίζεται στο γεγονός κατανόησης λειτουργίας του ανθρώπινου εγκεφάλου και της προσέγγισης αυτής με αλγόριθμους και σύμβολα για την αναπαράσταση των εννοιών και των σχέσεων. Ο κλάδος της λογικής, των μαθηματικών, εξυπηρετεί στην αναπαράσταση αυτή
- ❖ Η μη συμβολική ή Υπολογιστική βασίζεται στην μίμηση βιολογικών διεργασιών, όπως για παράδειγμα η λειτουργία του εγκεφάλου, για την παραγωγή ευφυούς συμπεριφοράς. Τα ΤΝΔ και οι γενετικοί αλγόριθμοι είναι παραδείγματα της κατηγορίας αυτής [23] .

Ένας εύκολα κατανοητός τρόπος αναπαράστασης για το τι εμπεριέχεται στην τεχνητή νοημοσύνη, μπορεί να θεωρηθεί το **Σχήμα 1**.



Σχήμα 1. Τεχνητή Νοημοσύνη.

Με την εξέλιξη της τεχνολογίας, του ίντερνετ και του προγραμματισμού επήλθε η ανάπτυξη προγραμματιστικών περιβαλλόντων και βιβλιοθηκών προγραμματιστικών γλωσσών (πχ. *MATLAB*, *Octave*, *NumPy*, *TensorFlow*, *Scikit-learn* κ.α.), διευκολύνοντας τη δημιουργία εξελιγμένων ευφυών συστημάτων, ακόμα και για αρχάριους χρήστες. Η δυνατότητα επικοινωνίας του ανθρώπου με την μηχανή, η δυνατότητα αναπαράστασης της γνώσης, η αυτοματοποιημένη συλλογιστική και η αποθήκευση μεγάλων όγκων πληροφορίας, δίνει την ικανότητα, στην μηχανή, να απαντήσει σε ερωτήματα καθώς και την παραγωγή συμπερασμάτων. Παρακάτω, αναλύεται περεταίρω η μηχανική μάθηση, η οποία εμπεριέχεται στο πεδίο της τεχνητής νοημοσύνης, και δίνει στην υπολογιστική μηχανή την δυνατότητα μάθησης μέσω αναγνώρισης προτύπων και συσχέτισης αυτών.

1.3.2 Μηχανική Μάθηση - Ορισμός και χρήση

Ως ορισμός της μηχανικής μάθησης θα μπορούσε να δοθεί ένας από τους παρακάτω :

Ένα πρόγραμμα υπολογιστή θεωρείται ότι μαθαίνει από την εμπειρία E σε σχέση με μια κατηγορία εργασιών T και μια μετρική απόδοσης P , αν η απόδοση του σε εργασίες της T , όπως μετριοούνται από την P , βελτιώνεται με την εμπειρία E [24].

Η μηχανική εκμάθηση προγραμματίζει υπολογιστές για τη βελτιστοποίηση μιας απόδοσης χρησιμοποιώντας παραδείγματα δεδομένων ή προηγούμενη εμπειρία [25].

Η μηχανική μάθηση ανήκει στον τομέα της τεχνητής νοημοσύνης. Τα συστήματα που σχεδιάζονται μαθαίνουν από τα δεδομένα μέσω εκπαίδευσης και βελτιώνονται με την εμπειρία και με τον χρόνο βελτιστοποιούνται.

Η μηχανική μάθηση βρίσκει χρήσεις σε πλήθος αντικειμένων, όπως:

- Ανάπτυξη λογισμικών για πρόβλεψη μιας τιμής, κατηγορίας ή ρίσκου,
- Ανίχνευση φωνής ή προσώπου,
- Ανίχνευση ανεπιθύμητων email,
- Συναλλαγές μετοχών και τραπεζικές απάτες,
- Ρομποτική,
- Διαφήμιση και προώθηση προϊόντων,
- Ιατρική.

1.3.3 Κατηγορίες Μηχανικής Μάθησης

Η φύση τους προβλήματος και το απαιτούμενο αποτέλεσμα θέτουν το κριτήριο επιλογής της σωστής κατηγορίας από τις τρεις βασικές κατηγορίες της μηχανικής μάθησης (**Σχήμα 2**).

1.3.3.1. Μάθηση με επίβλεψη (Supervised Learning)

Όλα τα δεδομένα συνοδεύονται από ετικέτες "labels" και ο αλγόριθμος μαθαίνει να προβλέψει το αντικείμενο εξαγωγής σύμφωνα με τα δεδομένα εισόδου. Οι αλγόριθμοι χρησιμοποιούνται όταν τα δεδομένα έχουν ανεξάρτητες μεταβλητές και μια μεταβλητή στόχο. Το καθήκον των αλγόριθμων μάθησης με επίβλεψη είναι να βρουν τη σχέση μεταξύ των ανεξάρτητων μεταβλητών και της μεταβλητής στόχου. Στην μάθηση με επίβλεψη είναι γνωστό το είδος της απάντησης Διακρίνονται δύο είδη προβλημάτων:

- ❖ Παλινδρόμησης (*Regression*): Αφορά την δημιουργία μοντέλων πρόβλεψης συνεχόμενων/αριθμητικών τιμών, πχ. τιμή προϊόντος, βάρος, τιμή μετοχής κ.λπ.
- ❖ Ταξινόμησης (*Classification*): Αφορά την δημιουργία μοντέλων πρόβλεψης διακριτών κατηγοριών-κλάσεων, πχ. τύπος καρκίνου, άντρας-γυναίκα, σκύλος-γάτα κ.λπ.

1.3.3.2. Μάθηση χωρίς επίβλεψη (Unsupervised Learning)

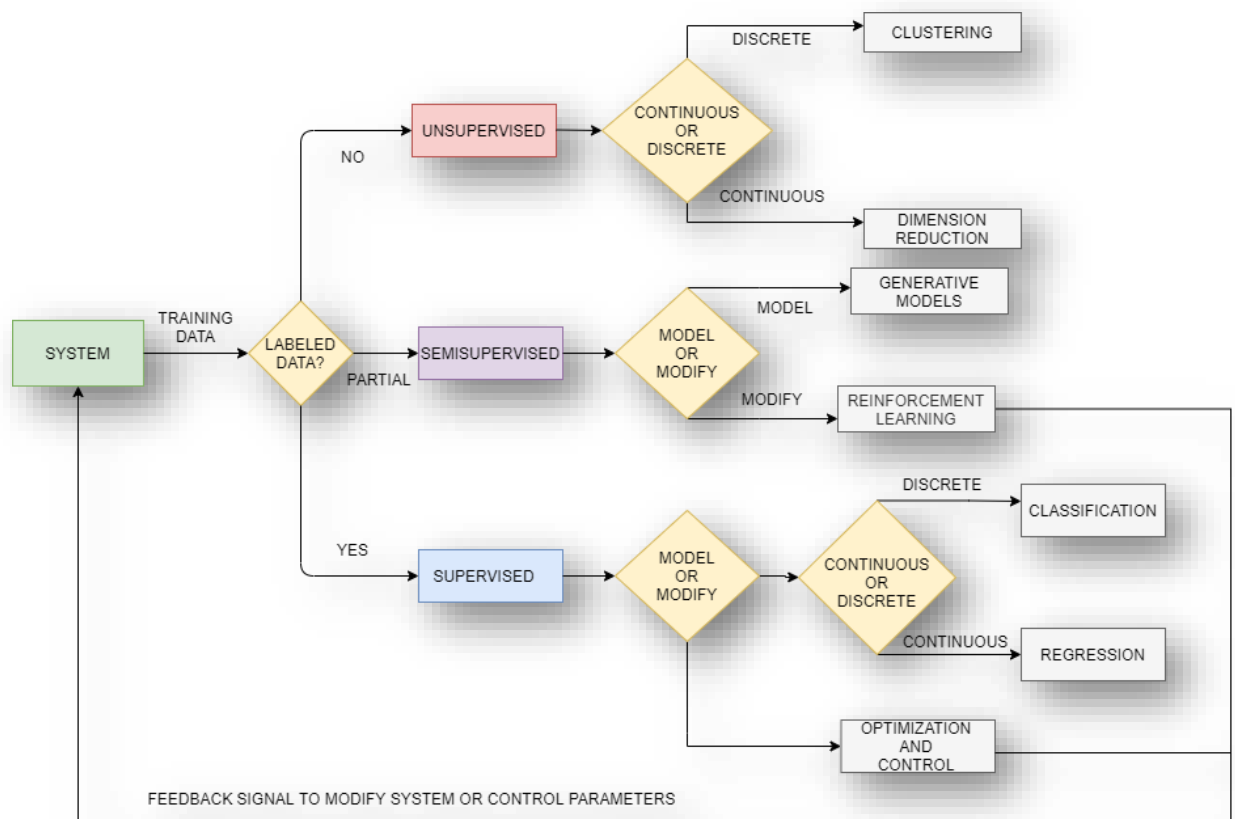
Όλα τα δεδομένα δεν συνοδεύονται από ετικέτες "labels" και ο αλγόριθμος μαθαίνει εγγενή δομή από τα δεδομένα εισόδου. Οι αλγόριθμοι μάθησης χωρίς επίβλεψη μπορούν να χρησιμοποιηθούν όταν δεν υπάρχει μεταβλητή στόχος. Σε αυτή τη περίπτωση δεν προσπαθούμε να προβλέψουμε κάτι αλλά να βρούμε ένα μοτίβο "pattern" στα δεδομένα,

αν αυτό υπάρχει. Διακρίνονται δύο είδη προβλημάτων:

- ❖ Ομαδοποίηση (*Clustering*): Ο αλγόριθμος ομαδοποιεί τα δεδομένα εισόδου, πχ. ομαδοποίηση μερίδας ανθρώπων ανάλογα με το φύλο και από το αν προτιμούν τις χειμερινές ή καλοκαιρινές διακοπές.
- ❖ Ανάλυσης Συσχετισμών (*Association Analysis*): Ο αλγόριθμος βρίσκει πιθανότητες συμβούν δύο ή περισσότερα πράγματα μαζί, πχ. αν η αγορά μοτοσικλέτας συσχετίζεται με την αγορά κράνους

1.3.3.3. Ενισχυτική μάθηση (Reinforcement Learning)


Ο αλγόριθμος αλληλοεπιδρά με το περιβάλλον και μαθαίνει με ένα είδος επιβράβευσης και τιμωρίας. Αποτελεί μια υβριδική παραλλαγή της μάθησης με επίβλεψη και χρησιμοποιείται κυρίως στην ρομποτική.



Σχήμα 2. Διάγραμμα Ροής επιλογής κατάλληλου αλγορίθμου μηχανικής μάθησης.

1.3.4 Νευρωνικά Δίκτυα Τεχνητής Νοημοσύνης

Τα νευρωνικά δίκτυα τεχνητής νοημοσύνης (ANNs) έχουν εμπνευστεί εν μέρει από την παρατήρηση ότι τα βιολογικά συστήματα μάθησης είναι κατασκευασμένα από πολύπλοκους ιστούς διασυνδεδεμένων νευρώνων, όπως ο ανθρώπινος εγκέφαλος. Ο εγκέφαλος αποτελείται από διακριτά στοιχεία, τους νευρώνες (*neurons*), οι οποίοι επικοινωνούν μεταξύ τους και αποτελούν βασικό δομικό κομμάτι του ανθρώπινου εγκεφάλου (**Εικόνα 2**). Περίπου 10 δισεκατομμύρια νευρώνες αποτελούν τον εγκέφαλο, και τοποθετημένους σε ομάδες με καθεμιά από αυτές να συνιστά ένα νευρωνικό δίκτυο. Με αυτόν τον τρόπο, ο ανθρώπινος εγκέφαλος περιέχει εκατοντάδες φυσικά νευρωνικά δίκτυα, καθένα από τα οποία περιέχει χιλιάδες διασυνδεδεμένους νευρώνες με μέσο αριθμό διασυνδέσεων ανά νευρώνα 1.000 με 10.000.



Εικόνα 2. Ψηφιακή αναπαράσταση φυσικού νευρώνα [26].

Τα τεχνητά νευρωνικά δίκτυα (ΤΝΔ) κατασκευάζονται από ένα πυκνά διασυνδεδεμένο σύνολο απλών μονάδων, όπου κάθε μονάδα λαμβάνει ένα αριθμό εισροών πραγματικής αξίας (ακόμα και εξόδους άλλων μονάδων) και παράγει μία μόνο έξοδο πραγματικής αξίας, η οποία μπορεί να γίνει είσοδος σε πολλές άλλες διαφορετικές μονάδες. Κίνητρο για τα συστήματα ΤΝΔ είναι να συλλάβουν τον εξαιρετικά παράλληλο υπολογισμό των φυσικών νευρώνων, με βάση τις κατανεμημένες αναπαραστάσεις. Η πλειοψηφία των λογισμικών των ΤΝΔ εκτελούνταν σε διαδοχικές μηχανές που μιμούνταν κατανεμημένες διεργασίες αλλά τις τελευταίες δεκαετίες οι γρηγορότερες εκδόσεις αλγορίθμων έδωσαν την δυνατότητα για δημιουργία εξειδικευμένου λογισμικού, σχεδιασμένο ειδικά για εφαρμογές ΤΝΔ [24] .

Εφαρμογές των ΤΝΔ συναντιούνται σχεδόν σε κάθε κλάδο, όπου είναι αναγκαία η επίλυση καταστάσεων, που υπάρχει μια σχέση μεταξύ μεταβλητών πρόβλεψης (ανεξάρτητες εισροές) και προβλεπόμενων μεταβλητών (εξαρτημένες εκροές). Ενδεικτικά μερικά προβλήματα όπου έχει εφαρμοστεί με επιτυχία η ανάλυση των νευρωνικών δικτύων είναι τα εκατέρωθεν:

- ❖ Ιατρική διάγνωση για την χορήγηση κατάλληλης θεραπείας,
- ❖ Χρηματιστηριακές προβλέψεις,
- ❖ Πιστωτική ανάθεση,
- ❖ Παρακολούθηση κατάστασης μηχανημάτων,
- ❖ Συστήματα διαχείρισης κινητήρα,
- ❖ Συστήματα πρόβλεψης κατανάλωσης ηλεκτρικής ενέργειας.

1.4 Μοντέλα Πρόβλεψης

1.4.1 Γενικά

Κάθε επιστημονική δραστηριότητα μοντελοποίησης και κάθε συγκροτημένη μέθοδος λήψης απόφασης έχουν ένα κοινό χαρακτηριστικό : Η επιτυχία και των δύο εξαρτάται από την ικανότητα των ερευνητών ή των αποφασίζοντων να προβλέπουν τις συνέπειες των πράξεών τους [27].

Η πρόβλεψη είναι η διαδικασία δημιουργίας προρρήσεων με βάση παρελθοντικά και παροντικά δεδομένα, καθώς και ανάλυσης των τάσεων. Ένα συνηθισμένο παράδειγμα είναι η εκτίμηση κάποιας μελλοντικής μεταβλητής ενδιαφέροντος σε κάποια καθορισμένη μελλοντική ημερομηνία.

Σε γενικές γραμμές, η πρόβλεψη, σαν μέθοδος για λήψη αποφάσεων, θα μπορούσε να χωριστεί σε τρεις κατηγορίες [28] :

- I. **Ποιοτική πρόβλεψη:** Στοιχειοθετείται από την εμπειρία, γνώση και πληροφόρηση των αποφασίζοντων και εμπεριέχει την αβεβαιότητα της ικανότητας του ανθρώπου που κάνει την πρόβλεψη.
- II. **Ποσοτική πρόβλεψη:** Δίνει αντικειμενική πρόγνωση μέσω διάφορων μαθηματικών μοντέλων, η οποία εφόσον αξιοποιηθεί και ερμηνευτεί σωστά, μπορεί να οδηγήσει σε πιο επιτυχημένες προβλέψεις-αποφάσεις.
- III. **Συνδυασμός των δύο παραπάνω:** Με την χρήση ισχυρών μαθηματικών μοντέλων πρόβλεψης καθώς και την εμπειρία του ανθρώπου πάνω στο αντικείμενο πρόβλεψης, δύναται να δημιουργηθεί ένα πανίσχυρο εργαλείο λήψης αποφάσεων μέσω προβλέψεων, ελαχιστοποιώντας τον παράγοντα της αβεβαιότητας.

1.4.2 Πρόοδος στον τομέα προβλέψεων

Οι κυριότεροι τύποι μαθηματικών μοντέλων πρόβλεψης διακρίνονται ανάλογα με τη δομή τους και μπορούν να συνοψιστούν ως εξής [28] :

1. **Στατικά και Δυναμικά Μοντέλα**

Τα δυναμικά μοντέλα μελετούν ένα σύστημα το οποίο εξαρτάται από το χρόνο, δηλαδή οι μεταβλητές του συστήματος είναι συναρτήσεις του χρόνου. Στα στατικά μοντέλα ο χρόνος δεν επηρεάζει τις τιμές των μεταβλητών.

2. **Μηχανιστικά και Εμπειρικά Μοντέλα**

Τα εμπειρικά μοντέλα εξάγουν αποτελέσματα μελετώντας μόνο ποσοτικά τις μεταβολές ενός συστήματος, ενώ τα μηχανιστικά μοντέλα εξάγουν αποτελέσματα χρησιμοποιώντας θεωρητικό υπόβαθρο και ταυτοχρόνως λαμβάνουν υπόψιν τους μηχανισμούς πρόκλησης μεταβολών σε αυτό.

3. **Αιτιοκρατικά (Ντετερμινιστικά) και Στοχαστικά Μοντέλα**

Τα αιτιοκρατικά μοντέλα δεν δέχονται την τυχαία μεταβολή και για συγκεκριμένο σύνολο δεδομένων, δίνουν πάντα τα ίδια αποτελέσματα-προβλέψεις. Τα στοχαστικά μοντέλα, από την άλλη, δέχονται την ύπαρξη της τυχαιότητας και με αυτό τον τρόπο, το σύνολο των δεδομένων και η πληροφορία που εξάγεται, διακατέχονται από τα χαρακτηριστικά της τυχαιότητας και της πιθανότητας.

4. **Μη Πεπλεγμένα (*Explicit*) και Πεπλεγμένα (*Implicit*) Μοντέλα**

Στα μη πεπλεγμένα μοντέλα όλα τα δεδομένα είναι γνωστά και τα αποτελέσματα της εισόδου υπολογίζονται από ένα κλειστό μαθηματικό τύπο, ο οποίος επιλύεται με αναλυτικές μεθόδους. Όταν όμως, οι μαθηματικοί τύποι δεν είναι δυνατόν να επιλυθούν με αναλυτικές μεθόδους, τότε τα μοντέλα ονομάζονται πεπλεγμένα.

5. **Διακριτά και Συνεχή Μοντέλα**

Στα διακριτά μοντέλα οι μεταβλητές λαμβάνουν μονάχα διακριτές τιμές, π.χ. μεταβλητή αναπαράστασης αριθμού παιδιών σε μια απογραφή, ενώ στα συνεχή μοντέλα δέχονται γίνεται η επεξεργασία συνεχών δεδομένων, όπως η ταχύτητα του ανέμου, θερμοκρασία περιβάλλοντος κ.λπ.

6. **Γραμμικά και Μη Γραμμικά Μοντέλα**

Στα γραμμικά μοντέλα οι εξισώσεις που συνδέουν τις μεταβλητές του μοντέλου, είναι γραμμικές. Όταν έστω και μια μεταβλητή δεν είναι γραμμική, το μοντέλο ονομάζεται μη γραμμικό. Συνήθως τα μη γραμμικά μοντέλα, μέσω γραμμικοποίησης από αλγορίθμους, μετατρέπονται σε γραμμικά καθώς είναι δύσκολη η μοντελοποίησή τους.

7. **Μοντέλα Προσομοίωσης**

Μέσω αλγορίθμων γίνεται η επεξεργασία περιγραφής ενός πραγματικού συστήματος καθώς και η πρόβλεψη της συμπεριφοράς του υπό διάφορες συνθήκες, που είναι τα δεδομένα εισόδου. Τα μοντέλα προσομοίωσης δίνουν λύση σε περιπτώσεις όπου η πραγματική μοντελοποίηση θα ήταν αρκετά δαπανηρή και χρονοβόρα καθώς και πολλές φορές μη δυνατή.

8. **Στατιστικά Μοντέλα**

Μέσω στατιστικής και εμπειρικών δεδομένων, αναλύονται υπάρχουσες καταστάσεις ή γίνεται πρόγνωση μελλοντικών συμπεριφορών ενός συστήματος.

9. Προηγμένες μαθηματικές μέθοδοι πρόβλεψης

α) Μέθοδοι Χρονοσειρών

Μελετούν την συμπεριφορά ενός δείγματος δεδομένων, το οποίο λαμβάνεται μαζί με τον χρόνο και παρουσιάζει εσωτερική επαναλαμβανόμενη δομή όπως τάση, εποχικότητα και διαχρονικότητα. Μερικές από τις μεθόδους χρονοσειρών είναι :

- i) Μέθοδοι εξομάλυνσης.
- ii) Μέθοδοι χρονοσειρών μιας μεταβλητής.
- iii) Μοντέλα Box-Jenkins.
- iv) Οι μέθοδοι των πολυμεταβλητών χρονοσειρών.

β) Μέθοδοι Τεχνητής Νοημοσύνης

Αναλύονται στην ενότητα **1.3 Μηχανική Μάθηση** και περιλαμβάνονται από τις κατηγορίες:

- i) Μοντέλα/Μέθοδοι Μηχανικής Μάθησης.
- ii) Τεχνητά Νευρωνικά Δίκτυα.

1.4.3 Μοντέλα πρόβλεψης και κατανάλωση ηλεκτρικής ενέργειας

Τις τελευταίες δεκαετίες η κατανάλωση ηλεκτρικής ενέργειας αυξήθηκε ανάλογα με την αύξηση του πληθυσμού και τη βιομηχανική και οικονομική ανάπτυξη σε πολλές αναπτυσσόμενες και υποανάπτυκτες χώρες. Η σημαντικότητα της διαχείρισης της ζήτησης και κατανάλωσης ηλεκτρικής ενέργειας, είναι ζωτικής σημασίας καθώς οι πόροι μειώνονται, οι εκπομπές αυξάνονται και οι ανανεώσιμες και καθαρές ενέργειες δεν έχουν εφαρμοστεί πλήρως σε παγκόσμια κλίμακα. Κυβερνήσεις και ιδιωτικές εταιρείες επενδύουν όλο και περισσότερο σε συστήματα διαχείρισης και μοντέλα πρόβλεψης της ηλεκτρικής ενεργειακής προσφοράς και ζήτησης, με στόχο τόσο της εξοικονόμηση ηλεκτρικής ενέργειας όσο και την δημιουργία μακροχρόνιων πλάνων ανάπτυξης, καθώς και την κάλυψη αυτής της ζήτησης με συστήματα ΑΠΕ. Επομένως, η δημιουργία και χρήση μοντέλων για ακριβή πρόβλεψη των μελλοντικών τάσεων κατανάλωσης ηλεκτρικής ενέργειας, ειδικά για μη γραμμικά δεδομένα, είναι σημαντικό ζήτημα τόσο για τα συστήματα παραγωγή και διανομής ηλεκτρικής ενέργειας όσο για τους διάφορους κλάδους της βιομηχανίας-οικονομίας-κοινωνίας, είτε είναι εργοστάσια, νοσοκομεία, λιμάνια, σχολεία κ.λπ. [29] .

Σύμφωνα με τις οικονομικές θεωρίες, η ηλεκτρική ενέργεια είναι από τους σημαντικότερους πόρους για τη βιομηχανική παραγωγή και η πρόβλεψη της κατανάλωσης ηλεκτρικής ενέργειας είναι μια σημαντική φάση για τον μακροπρόθεσμο προγραμματισμό της προσφοράς-ζήτησης, η οποία πρέπει επιπλέον να ικανοποιεί τις απαιτήσεις της αιχμώδους ανάπτυξης της κάθε χώρας [30]. Οι ακριβείς προβλέψεις μπορούν να βοηθήσουν τους υπεύθυνους λήψης αποφάσεων να γνωρίζουν τον όγκο και την τάση της μελλοντικής κατανάλωσης ηλεκτρικής ενέργειας για τον καλύτερο προγραμματισμό των λειτουργιών του εκάστοτε τομέα. Τυχών σφάλματα στην πρόβλεψη οδηγούν σε μη ισορροπημένη ζήτηση προσφοράς, η οποία επηρεάζει αρνητικά το λειτουργικό κόστος, την ασφάλεια του δικτύου και την ποιότητα των υπηρεσιών του δικτύου εφοδιασμού [31] . Συγκεκριμένα, η υποτίμηση της ηλεκτρικής ενέργειας μπορεί να οδηγήσει σε διακοπές ρεύματος και από την άλλη, η

υπερεκτίμηση της ζήτησης, μπορεί να οδηγήσει στη δημιουργία αχρησιμοποίητης ικανότητας που ισοδυναμεί σε σπατάλη πόρων. Τα μοντέλα πρόβλεψης ηλεκτρικής ενέργειας πρέπει να είναι αρκετά αξιόπιστα, στο ζήτημα της ακρίβειας, σε διαφορετικές τιμές μεταβλητών εισόδου.

Τέλος σημαντικό είναι να αναφερθούν διάφορα μοτίβα που εμφανίζονται στην κατανάλωση της ηλεκτρικής ενέργειας, στα λιμάνια της Ελλάδας, καθώς και τα αναγκαία δεδομένα για την βραχυπρόθεσμη και μακροπρόθεσμη πρόβλεψη. Τα κύρια μοτίβα που εμφανίζει η κατανάλωση ηλεκτρικής ενέργειας είναι αυτά της εποχικότητας και της διαχρονικότητας. Η εποχικότητα στα λιμάνια της Ελλάδας παρατηρείται κάθε καλοκαίρι όπου η κατανάλωση ανεβαίνει αρκετά σε σχέση με τους χειμερινούς μήνες, κυρίως λόγω τουρισμού. Σχετικά με την διαχρονικότητα, παρατηρείται ότι κάθε τουλάχιστον δύο χρόνια αυξάνεται κατανάλωση λόγω οικονομικο-κοινωνικής ανάπτυξης.

1.5 Στόχος

Στην Ελλάδα, ανέκαθεν στην ιστορία της, η ναυτιλία και το εμπόριο ήταν οι καθοριστικοί παράγοντες ανάπτυξης και επέκτασης της με αποτέλεσμα ύπαρξης πληθώρας λιμένων σε όλη την παραθαλάσσια επικράτειά της. Επιπλέον η Κρήτη, όντας ο μεγαλύτερος και διασημότερος νησιωτικός σταθμός, δέχεται αρκετή κίνηση στα λιμάνια της, ιδιαιτέρως του θερινούς μήνες λόγω τουρισμού. Κίνητρο εκπόνησης αυτής της μελέτης είναι η δημιουργία ενός υπερσύγχρονου μοντέλου πρόβλεψης της κατανάλωσης ηλεκτρικής ενέργειας για το λιμάνι της Σούδας, στον νομό Χανίων, για το έτος 2030, ώστε να καταστεί δυνατή η δημιουργία ενός μακροχρόνιου πλάνου αιεφόρου ανάπτυξης και την μετάλλαξη του λιμένα σε έναν ανταγωνιστικά πράσινο λιμένα και λιμένα σχεδόν μηδενικής ενεργειακής κατανάλωσης (*nearly Zero Energy Port -nZEP*) [32]. Για την δημιουργία του υπερσύγχρονου μοντέλου χρησιμοποιούνται πραγματικά δεδομένα κατανάλωσης ηλεκτρικής ενέργειας του λιμένα Σούδας (από την ευγενική παραχώρηση της υπηρεσίας του **Λιμενικού Ταμείου Νομού Χανίων** [33]) καθώς και μετεωρολογικά δεδομένα (από την ευγενική παραχώρηση του **Εθνικού Αστεροσκοπείου Αθηνών** [34]). Ο στόχος, λοιπόν, που πρέπει να εκπληρωθεί είναι η δημιουργία ενός μοντέλου πρόβλεψης, με δεδομένα εισόδου την κατανάλωση ηλεκτρικής ενέργειας και τα μετεωρολογικά δεδομένα της περιοχής του λιμένα και δεδομένα εξόδου την κατανάλωση της ηλεκτρικής ενέργειας στο έτος 2030.

1.6 Δομή επόμενων κεφαλαίων

Στο δεύτερο κεφάλαιο διεξάγεται μια βιβλιογραφική ανασκόπηση, σχετικά με τα σύγχρονα μοντέλα πρόβλεψης σε διάφορους τομείς, σύμφωνα με μελέτες που πραγματοποιήθηκαν σε διεθνές επίπεδο. Για κάθε επιμέρους μελέτη συντάσσεται μια σύντομη περίληψη με το περιεχόμενο της έρευνας. Στο τρίτο κεφάλαιο γίνεται αναφορά για το λιμάνι της Σούδας, για τον ρόλο του στην Κρήτη και την κοινωνία του νομού Χανίων, και, επίσης, συντάσσεται η μεθοδολογία που χρησιμοποιήθηκε, περιγράφοντας τα δεδομένα, τα μοντέλα πρόβλεψης και τα λογισμικά που αξιοποιήθηκαν. Στην συνέχεια, στο τέταρτο κεφάλαιο, παρουσιάζονται τα αποτελέσματα των χρησιμοποιούμενων μοντέλων, γίνεται σύγκριση μεταξύ τους με στόχο την επιλογή του βέλτιστου, το οποίο, εν συνεχεία, θα χρησιμοποιηθεί για την πρόβλεψη κατανάλωσης ηλεκτρικής ενέργειας για το έτος 2030. Στο πέμπτο κεφάλαιο εμπεριέχεται σχολιασμός των αποτελεσμάτων που προέκυψαν και σχετικά συμπεράσματα επ'αυτών καθώς και προτάσεις για μελλοντικές μελέτες. Έπειτα, στο έκτο κεφάλαιο αναφέρεται η σχετική βιβλιογραφία-πηγές που χρησιμοποιήθηκαν στην παρούσα εργασία και τέλος, στο έβδομο κεφάλαιο, παρουσιάζεται το παράρτημα.

2. Βιβλιογραφική ανασκόπηση

Σημαντική έρευνα έχει πραγματοποιηθεί στον τομέα των προβλέψεων κατανάλωσης ηλεκτρικής ενέργειας. Αν και αναφορικά με την δημιουργία μοντέλων κατανάλωσης ηλεκτρικής ενέργειας σε λιμάνια δεν βρέθηκαν σχετικές έρευνες, θα παρατεθούν έρευνες με μοντέλα πρόβλεψης κατανάλωσης ηλεκτρικής ενέργειας για διάφορους άλλους τομείς, όπως βιομηχανία, οικίες κ.α. Κοινό χαρακτηριστικό ανάμεσα σε προηγούμενες έρευνες με την παρούσα είναι η χρήση μοντέλων μηχανικής μάθησης για την πρόβλεψη κατανάλωσης ηλεκτρικής ενέργειας, βραχυπρόθεσμα ή μακροπρόθεσμα.

Στο κεφάλαιο αυτό θα πραγματοποιηθεί μια παρουσίαση των προηγούμενων ερευνών, κατά χρονολογική σειρά. Σκοπός της παρουσίασης είναι να αναφερθούν οι σημαντικές πληροφορίες που εμπεριέχονται σε αυτές, στο όριο μιας παραγράφου, με όσο πιο απλό και κατανοητό τρόπο γίνεται. Οι αναφορές που θα παρουσιαστούν έχουν εγκριθεί και δημοσιευθεί σε επιστημονικά περιοδικά και βοήθησαν στην καλύτερη κατανόηση του παρόντος εγχειρήματος.

Αρχικά, μια δημοσίευση από τους A. Parlos, E. Oufi, J. Muthusami, Alton D. Patton και Amir F. Atiya, ερευνά την ανάπτυξη και δοκιμή ενός μακροπρόθεσμα υβριδικού ευφυούς συστήματος πρόβλεψης φορτίου ηλεκτρικής ενέργειας διάφορων πόλεων, το οποίο αποτελείται από πολλά μπλοκ πρόβλεψης νευρωνικών δικτύων, γενετικούς αλγορίθμους και ασαφείς κανόνες, καθώς και τον συνδυασμό προβλέψεων, με στόχο την απορρύθμιση της ηλεκτρικής βιομηχανίας. Ανάλογα με τη χρησιμότητα που μελετάται, χρησιμοποιείται ιστορική βάση δεδομένων με τριμηνιαία ή / και ετήσια δεδομένα. Μεταξύ αυτών περιλαμβάνονται, ως δείκτες, τα χρονοδιαγράμματα: χρόνος, ημέρες βαθμού ψύξης και βαθμού θέρμανσης, προσαρμοσμένη τιμή ηλεκτρικής ενέργειας, πελάτες περιοχής εξυπηρέτησης, συνολικός πληθυσμός και άλλοι οικονομικοί δείκτες, όπως το κατά κεφαλήν εισόδημα κ.α. Τα αποτελέσματα, παρατηρείται ότι όλες οι προγνώσεις από τα νευρωνικά δίκτυα παρουσιάζουν καλύτερες αποδόσεις σε σύγκριση με τις προβλέψεις που δημιουργούνται από τα συνεργαζόμενα βοηθητικά προγράμματα. Επίσης, ένα επιπλέον παρατηρηθέν χαρακτηριστικό των νευρωνικών δικτύων είναι η φαινομενική ευρωστία τους [35].

Οι T. Al-Saba και I. El-Amin, παρουσίασαν μια μελέτη όπου χρησιμοποιείται ένα μοντέλο νευρωνικών δικτύων για την πρόβλεψη ενεργειακών απαιτήσεων μια ηλεκτρικής υπηρεσίας. Το μοντέλο δημιουργείται με βάση τα ιστορικά δεδομένα κατανάλωσης της υπηρεσίας από το 1981 έως το 1996 και στην συνέχεια συγκρίνεται με μοντέλα χρονοσειρών. Η σύγκριση αποκαλύπτει ότι το ANN αποδίδει αποτελέσματα πιο κοντά στην πραγματικότητα. Στην συνέχεια το μοντέλο ANN χρησιμοποιείται για την πρόγνωση της ετήσιας μέγιστης ζήτησης ηλεκτρικής ενέργειας μιας βοηθητικής υπηρεσίας παροχής υπηρεσιών σε βιομηχανικό και οικιστικό επίπεδο, στην Μέση Ανατολή, από το 1997 έως το 2006. Η έρευνα καταλήγει ότι το μοντέλο ANN μπορεί να παρέχει σχετικά μακροπρόθεσμη πρόβλεψη με ελάχιστο αριθμό ιστορικών δεδομένων και ελάχιστο σφάλμα [36].

Οι K. Padmakumari, K.P. Mohandas και S. Thiruvengadam, σε ερευνά τους, περιγράφουν την δημιουργία και εφαρμογή μιας υβριδικής ασαφούς νευρικής λογικής που συνδυάζει νευρωνικά δίκτυα με τεχνικές ασαφούς λογικής (RBFN), για μακροπρόθεσμη πρόβλεψη φορτίου διανομής ηλεκτρικής ενέργειας, με βάση τη χρήση γης. Με δεδομένα του φορτίου από το 1987 έως το 1997 δημιουργούνται δύο μοντέλα ANN, το BP (*back propagation*) και RBFN (*radial basis Function Network*) και ένα μοντέλο γραμμικής παλινδρόμησης. Από τα αποτελέσματα της έρευνας φαίνεται ότι την καλύτερη επίδοση σε πρόβλεψη είχε το RBFN

μοντέλο, λόγω του ειδικού χαρακτηριστικού της μη γραμμικής δυνατότητας χαρτογράφησης, με το αμέσως καλύτερο να είναι το BP μοντέλο, το οποίο έδειχνε να καταλήγει σε κορεσμό προβλέψεων μετά τα τρία χρόνια [37].

Μια δημοσίευση από τον C. Hamzaçebi, από το πανεπιστήμιο Zonguldak της Τουρκίας, ερευνά την πρόβλεψη καθαρής κατανάλωσης ηλεκτρικής ενέργειας σε τομεακές βάσεις έως το 2020. Ως κίνητρο εκπόνησης αυτής της μελέτης θεωρείται η ραγδαία ανάπτυξη της Τουρκίας σε οικονομικό και πληθυσμιακό επίπεδο, με αποτέλεσμα την αύξηση της απαίτησης σε ηλεκτρική ενέργεια. Βασίζόμενο σε ιστορικά δεδομένα κατανάλωσης ηλεκτρικής ενέργειας από το 1970 έως το 2004, από τομείς όπως η βιομηχανία, κατοικίες, γεωργία και οι μεταφορές, αναπτύχθηκαν τρία μοντέλα τεχνητών νευρωνικών δικτύων (ANN) και μετέπειτα το καλύτερο από τα τρία συγκρίνεται με αποτελέσματα ενός επίσημου μοντέλου ανάλυσης ζήτησης ενέργειας (MAED). Τα αποτελέσματα φανερώνουν ότι το μοντέλο ANN δίνει καλύτερα αποτελέσματα από ότι το MAED, και φανερώνει την ανάγκη δημιουργίας νέων τρόπων-μοντέλων πρόβλεψης καθώς και την δυναμικότητα αυτών [38].

Οι E. Gonzalez-Romera, M. Jaramillo-Moran και D. Carmona-Fernandez, σε ερευνά τους επικεντρώθηκαν στην μηνιαία πρόβλεψη κατανάλωσης ηλεκτρικής ενέργειας, χρήσιμη για τον σχεδιασμό συντήρησης των δικτύων και την έρευνα αγοράς για παραγωγούς και μεταπωλητές. Καθώς η χρονοσειρά των μηνιαίων απαιτήσεων ηλεκτρικής ενέργειας παρουσιάζει μια αυξανόμενη τάση, λόγω επίδρασης της οικονομικής και τεχνολογικής εξέλιξης, προτείνουν την εξαγωγή αυτής της τάσης για εκτέλεση ξεχωριστών προβλέψεων, τόσο της τάσης όσο και της διακύμανσης, με νευρωνικά δίκτυα. Ως δεδομένα χρησιμοποιήθηκαν οι μηνιαίες καταναλώσεις ηλεκτρικής ενέργειας στην Ισπανία από τον Ιανουάριο του 1975 έως τον Δεκέμβριο του 2002, ως σχεδιασμό οι μήνες έως και τον Δεκέμβριο του 1997 και οι υπόλοιποι ως επικύρωση. Αποτέλεσμα της έρευνας ήταν πως το μοντέλο νευρωνικών δικτύων απέδωσε αρκετά καλή πρόβλεψη, με ελάχιστο σφάλμα [39].

Ο L. Ekononou πραγματοποίησε μια έρευνα με στόχο την μακροπρόθεσμη κατανάλωση ενέργειας της Ελλάδας για τα έτη 2005-2008, 2010, 2012 και 2015, με την χρήση νευρωνικών δικτύων. Ως δεδομένα για την δημιουργία του μοντέλου χρησιμοποιήθηκαν η ετήσια θερμοκρασία περιβάλλοντος, η εγκατεστημένη ισχύς, η ετήσια ανά κάτοικο κατανάλωση ηλεκτρικής ενέργειας και το ακαθάριστο εγχώριο προϊόν. Το μοντέλο ANN που δημιουργήθηκε συγκρίνεται με μοντέλα γραμμικής παλινδρόμησης, διανύσματα υποστήριξης (*support vector*) και πραγματικά δεδομένα. Η έρευνα καταλήγει στο αποτέλεσμα ότι το ANN μοντέλο έδωσε αρκετά καλύτερα αποτελέσματα σε σχέση με το μοντέλο γραμμικής παλινδρόμησης και αρκετά κοντινά με το μοντέλο διανυσμάτων υποστήριξης [40].

Μια μελέτη άξιου αναφοράς είναι των L. Suganthi και A. Samuel, όπου γίνεται αναθεώρηση των διάφορων μοντέλων πρόβλεψης της ενεργειακής ζήτησης. Μέθοδοι όπως οι χρονοσειρές, παλινδρόμηση, οικονομετρική, ARIMA καθώς και τεχνικές AI όπως η ασαφής λογική, οι γενετικοί αλγόριθμοι και τα νευρωνικά δίκτυα, χρησιμοποιούνται εκτενώς για την διαχείριση ζήτησης ηλεκτρικής ενέργειας. Επιπλέον διανύσματα υποστηρικτικής παλινδρόμησης, *ant colony* και *particle swarm optimization* είναι διάφορες νέες τεχνικές για την πρόβλεψη της ενεργειακής ζήτησης, καθώς επίσης και μοντέλα όπως το MARKAL και LEAP χρησιμοποιούνται σε εθνικό και περιφερειακό επίπεδο. Στην μελέτη αυτή διαπιστώνεται ότι μοντέλα όπως η ARIMA συνδέονται με τα νευρωνικά δίκτυα και άλλες τεχνικές AI για τη βελτίωση της ακρίβειας της πρόβλεψης ενεργειακής ζήτησης [41].

Σε έρευνα από τους M. De Felice, A. Alessandri και P. Ruti, εκτελούνται καθημερινές προβλέψεις κατανάλωσης ηλεκτρικής ενέργειας για την Ιταλία, μέσω στατιστικών μοντέλων χρονοσειρών (πχ ARIMA) με σκοπό τη μελέτη της επίδρασης της θερμοκρασίας σε αυτή. Με δεδομένα από τις εργάσιμες μέρες του Ιουνίου και Ιουλίου για τα έτη 2003-2009,

εξάγονται τα αποτελέσματα τα οποία στην συνέχεια αναλύονται σε εθνικό και περιφερειακό επίπεδο. Πόρισμα της έρευνας είναι ότι η κατανάλωση ηλεκτρικής ενέργειας επηρεάζεται αρκετά από την θερμοκρασία, ειδικά σε πιο ζεστές περιοχές και τα μοντέλα πρόβλεψης σε αυτές τις περιοχές βελτιώνονται με την χρήση δεδομένων καιρού. Τέλος, προτείνεται περαιτέρω έρευνα με περισσότερα δεδομένα καιρού, όπως η υγρασία, ταχύτητα αέρα και κάλυψη από σύννεφα και πως αυτά επηρεάζουν την κατανάλωση ηλεκτρικής ενέργειας [31].

Σε μελέτη των S. Jurado, A. Nebot, F. Mugica και N. Avellana, συγκρίνεται η ακρίβεια διαφορετικών μεθοδολογιών μηχανικής μάθησης για την ωριαία πρόβλεψη ηλεκτρικής ενέργειας σε κτίρια. Στόχος της μελέτης είναι να εκτιμηθεί η απόδοση των μοντέλων και η κλιμάκωσή τους σε διαφορετικά προφίλ κατανάλωσης. Οι συγγραφείς προτείνουν μια υβριδική μέθοδο που συνδυάζει την επιλογή χαρακτηριστικών βασιζόμενη σε εντροπίες, soft computing και προσεγγίσεις με μηχανική μάθηση, πχ Fuzzy Inductive Reasoning, Random Forest και ANN. Επιπλέον, τα μοντέλα αυτά, συγκρίνονται με παραδοσιακά στατιστικά μοντέλα όπως η τεχνική ARIMA. Συμπέρασμα της έρευνας είναι ότι οι μεθοδολογίες AI προσαρμόζονται καλύτερα στις αλλαγές κατανάλωσης όταν εκτελούν προβλέψεις, ακολουθώντας το πραγματικό σχήμα της καμπύλης, εντοπίζουν καλύτερα τις κορυφές και επιτυγχάνονται πολύ χαμηλά σφάλματα πρόβλεψης. Αναφορικά με την ARIMA, η οποία είναι πιο συντηρητική μεθοδολογία, δεν παράγει υψηλά σφάλματα αλλά η ακρίβεια δεν είναι εξίσου καλή με τις μεθόδους AI [42].

Οι C. Robinson, B. Dilkina, J. Hubbs, W. Zhang, S. Guhanthakurta, M. Brown και R. Pendyala, παρουσιάζουν, στην σχετική τους έρευνα, μια τεχνική για τον υπολογισμό της εμπορικής κατανάλωσης ηλεκτρικής ενέργειας από ένα μικρό αριθμό κτιρίων στην πόλη της Ατλάντα, με την χρήση μοντέλων μηχανικής μάθησης, σε εθνικά δεδομένα από την Έρευνα Ενεργειακής Κατανάλωσης Κτιρίων (CBECS) της Νέα Υόρκης. Τα αποτελέσματα δείχνουν ότι τα μοντέλα gradient boosting regression έχουν την καλύτερη απόδοση στην πρόβλεψη της εμπορικής κατανάλωσης ενέργειας κτιρίου, σε σχέση με τις πραγματικές τιμές και συμπεραίνεται ότι περαιτέρω έρευνα πάνω σε μοντέλα μηχανικής μάθησης μπορεί να αποδώσει ακόμα καλύτερα μοντέλα [43].

Έρευνα έγινε από τους H. Hamedmoghadam, N. Joorabloo και M. Jalili πάνω στην μακροπρόθεσμη πρόγνωση της κατανάλωσης ηλεκτρικής ενέργειας στην Αυστραλία, με τη χρήση βαθιών νευρωνικών δικτύων (deep neural networks). Χρησιμοποιείται ένας αυτόματος κωδικοποιητής σε συνδυασμό με multilayer perceptrons ή cascade-forward multilayer perceptrons για την πρόβλεψη των εθνικών ποσοστών κατανάλωσης ηλεκτρικής ενέργειας για 1-24 μήνες στο μέλλον. Πόρισμα της έρευνας είναι ότι τα βαθιά νευρωνικά δίκτυα έχουν καλύτερη απόδοση από τα κλασσικά νευρωνικά δίκτυα, ιδιαίτερα για ορίζοντα πρόβλεψης 12 έως 24 μηνών [44].

Οι A. Rahman, V. Srikumar και A. Smith, σε έρευνα τους παρουσιάζουν ένα επαναλαμβανόμενο νευρωνικό δίκτυο (recurrent neural network – RNN) για μέση και μακρά πρόβλεψη κατανάλωσης ηλεκτρικής ενέργειας σε εμπορικά και οικιστικά κτίρια, στην Αμερική, σε ανάλυση μιας ώρας. Επιπλέον στόχος είναι η ανάλυση της σχετικής απόδοσης του μοντέλου για διαφορετικούς τύπους προτύπων κατανάλωσης ηλεκτρικής ενέργειας και η απόδοση σε σύνολο δεδομένων που περιέχουν τμήματα με έλλειψης τιμών. Για την πρόβλεψη προφίλ καταναλώσεων σε ένα εμπορικό κτίριο το RNN είχε καλύτερη πρόγνωση τιμών σε σχέση με ένα multi-layered perceptron νευρωνικό δίκτυο, ενώ στη συνολική κατανάλωση σε οικιστικά κτίρια το multi-layered perceptron νευρωνικό δίκτυο είχε καλύτερη ακρίβεια. Τέλος, παρατηρήθηκε ότι το RNN μπορεί να χρησιμοποιηθεί για την κάλυψη των κενών στις τιμές των δεδομένων [45].

Οι J. Moon, S. Park, S. Rho και E. Hwang σε έρευνά τους κατασκεύασαν διάφορα μοντέλα πρόβλεψης κατανάλωσης ηλεκτρικής ενέργειας σε κτίρια, με βάση τα νευρωνικά δίκτυα, χρησιμοποιώντας διαφορετικούς συνδυασμούς των υπερπαραμέτρων. Από τα πειράματα

κατέληξαν στο συμπέρασμα ότι τα νευρωνικά δίκτυα με κλιμακωτές εκθετικές γραμμικές μονάδες και πέντε κρυφά στρώματα, παρουσιάζουν καλύτερη απόδοση από άλλα μοντέλα βραχυπρόθεσμης πρόβλεψης, όπως του κινητού μέσου (MA), πολλαπλής γραμμικής παλινδρόμησης (MLR), ES και Persistence. Ως δεδομένα εισόδου πέρα από το ιστορικό καταναλώσεων χρησιμοποιούνται και δεδομένα καιρού (θερμοκρασία, υγρασία, ταχύτητα ανέμου κ.α.) [46].

Σε μελέτη των D. Kontogiannis, D. Bargiotas και A. Daskalopulu γίνεται σύγκριση της βασικής απόδοσης και δομής διάφορων τύπων νευρωνικών δικτύων σε δεδομένα οικιακής ενέργειας, βασισμένο σε πραγματικά δεδομένα, για την διατύπωση ενός κατάλληλα προγνωστικού μοντέλου. Στην μελέτη εκπαιδεύονται και δοκιμάζονται τρία είδη νευρωνικών δικτύων, ένα long short-term memory network (LSTM), ένα convolutional neural network (CNN) και ένα, multi-layer perceptron (MLP). Αποτέλεσμα της μελέτης ήταν πως το MLP μοντέλο απέδιδε καλύτερα σε σχέση με τις απώλειες και τον μέσο χρόνο εκπαίδευσης και οι προβλέψεις ήταν αρκετά ακριβείς. Τέλος, προτείνεται περαιτέρω έρευνα πάνω στον καλύτερο σχεδιασμό των μοντέλων και δοκιμές πάνω σε μοντέλα πρόβλεψης κατανάλωσης ηλεκτρικής ενέργειας [47].

Έρευνα των M. Kalimoldayev, A. Drozdenko, I. Koplyk, T. Marinich, A. Abdildayeva και T. Zhukabayeva περιέχει μια αναλυτική ανασκόπηση θεωρητικών και πρακτικών ζητημάτων για ένα αποτελεσματικό σύστημα διαχείρισης ηλεκτρικής ενέργειας με βάση την ανάλυση εσωτερικών (τεχνικών, οικονομικών, διαρθρωτικών) και εξωτερικών (μετεωρολογικών, περιβαλλοντικών, μακροοικονομικών) παραγόντων. Στην έρευνα εξετάζονται και αξιολογούνται συγκριτικά διάφορες τεχνικές μοντελοποίησης για την πρόβλεψη ζήτησης ηλεκτρικής ενέργειας. Ως δεδομένα χρησιμοποιούνται δύο πάνελ, κατανάλωση ηλεκτρικής ενέργειας ανά χώρα, περιοχές, τομείς και βιομηχανίες, και μεμονωμένα αντικείμενα με εξοπλισμό μέτρησης κατανάλωσης υψηλής συχνότητας. Τα μοντέλα που χρησιμοποιούνται κατανέμονται στις κατηγορίες της γραμμικής παλινδρόμησης, των χρονοσειρών, αλγορίθμων μηχανικής μάθησης και νευρωνικά δίκτυα. Από την έρευνα προκύπτει ότι τα μοντέλα μηχανικής μάθησης και τα νευρωνικά δίκτυα υπερέχουν όσον αφορά την ακρίβεια των αποτελεσμάτων, ειδικά για μακρά δείγματα. Επιπλέον, τα μοντέλα αυτά, ήταν λιγότερο επιρρεπή σε υπερβολική προσαρμογή (overfitting) και επέτρεπαν στον χρήστη να εισάγει μη σημαντικές μεταβλητές και παραμέτρους χωρίς αυτό να δημιουργεί απώλειες στην προβλεψιμότητα του μοντέλου [48].

Οι H. Son και C. Kim, σε έρευνά τους προτείνουν την χρήση ενός μοντέλου βαθιάς μηχανικής μάθησης το long short-term memory δίκτυο (LSTM), που ανήκει στα νευρωνικά δίκτυα, για την μηνιαία πρόβλεψη ζήτησης ηλεκτρικής ενέργειας σε οικιστικές περιοχές, με κοινωνικές και μετεωρολογικές μεταβλητές διάρκειας 22 χρόνων, στην Νότια Κορέα. Επιπλέον για περαιτέρω σύγκριση των αποτελεσμάτων του LSTM, χρησιμοποιήθηκαν τέσσερα ακόμα μοντέλα πρόβλεψης, SVR (*support vector regression*), ANN, ARIMA, MLR (*multiple linear regression*). Οι ερευνητές κατέληξαν στο συμπέρασμα ότι το μοντέλο LSTM είχε την καλύτερη απόδοση σύμφωνα με έξι μέτρα (MAE, RMSE, MAPE, C, MBE και UPA) σε σχέση με τα υπόλοιπα μοντέλα και τέλος, προτείνουν την περαιτέρω χρήση και αξιολόγηση αυτού του μοντέλου σε παρόμοιες περιπτώσεις με δεδομένα από διάφορες χώρες [49].

Οι E. Vivas, H. Allende-Cid και R. Salas, σε σχετική τους μελέτη, εφάρμοσαν μια συστηματική ανασκόπηση της βιβλιογραφίας για τον προσδιορισμό του τύπου μοντέλου που έχει την υψηλότερη τάση να δείχνει ακρίβεια στο πλαίσιο πρόβλεψης ηλεκτρικής ενέργειας. Από αποτελέσματα που αναφέρθηκαν σε 257 δοκιμές ακριβείας από πέντε γεωγραφικές περιοχές, καθορίστηκε το υπερσύγχρονο μοντέλο ακριβούς πρόβλεψης ηλεκτρικής ενέργειας. Συγκρίνοντας τις δύο πιο διαδεδομένες τεχνικές πρόβλεψης, τα μοντέλα κλασσικής στατιστικής και μοντέλα μηχανικής μάθησης, κατέληξαν στο πόρισμα ότι τα σφάλματα πρόβλεψης ελαχιστοποιούνται μειώνοντας τον χρονικό ορίζοντα, τα

μοντέλα μηχανικής μάθησης που θεωρούν διάφορες πηγές εξωγενούς μεταβλητότητας τείνουν να έχουν καλύτερη ακρίβεια πρόβλεψης και ότι η ακρίβεια των μοντέλων πρόβλεψης έχει αυξηθεί σημαντικά κατά τη διάρκεια των τελευταίων πέντε ετών [50].

Σε έρευνα των L. Cao, Y. Li, J. Zhang, Y. Jiang, Y. Han και J. Wei, αναπτύσσονται οκτώ μοντέλα μηχανικής μάθησης (μονής και συνολικής μάθησης) για την πρόβλεψη κατανάλωσης ηλεκτρικής ενέργειας σε ένα γενικό νοσοκομείο στη Σαγκάη της Κίνας. Ως δεδομένα εισόδου χρησιμοποιήθηκαν καιρικοί παράγοντες (θερμοκρασία, σχετική υγρασία, ταχύτητα ανέμου, βαρομετρική πίεση και κατακρήμνιση), δεδομένα πληρότητας (αριθμός εξωτερικοί, εσωτερικοί και επείγων ασθενείς), δεδομένα τύπου ημέρας (αν είναι καθημερινή ή σαββατοκύριακο) καθώς και δεδομένα για την θέρμανση και ψύξη του κτιρίου. Διαπιστώθηκε ότι δύο μοντέλα, το Extreme Gradient Boosting (XGBoost) και Random Forest (RF), ξεπέρασαν τα μεμονωμένα μοντέλα σε καθημερινή πρόβλεψη ηλεκτρικού φορτίου. Μέσω περαιτέρω σύγκρισης των μοντέλων που εκπαιδεύονται με ηλεκτρικά δεδομένα ημερήσιας και εβδομαδιαίας χρονικής ανάλυσης, αποδείχθηκε ότι είναι πιο πιθανό να επιτευχθεί υψηλότερη ακρίβεια με μεγαλύτερο βαθμό λεπτομέρειας χρόνου [51].

Οι A. Del Real, F. Dorado και J. Duran, διερεύνησαν τη χρήση τεχνικών βαθιάς μηχανικής μάθησης για την εκτέλεση προβλέψεων ζήτησης ηλεκτρικής ενέργειας. Στην έρευνά τους προτείνουν μια μικτή αρχιτεκτονική αποτελούμενη από ένα συνελκτικό νευρωνικό δίκτυο (*convolutional neural network* - CNN) και ένα τεχνητό νευρωνικό δίκτυο (ANN), με κύριο στόχο την επ'ωφέλεια από τα θετικά και των δύο δομών (οι δυνατότητες παλινδρόμησης του ANN και οι δυνατότητες εξαγωγής χαρακτηριστικών του CNN). Για την δημιουργία του μοντέλου χρησιμοποιούνται δεδομένα καιρού και στόχος είναι η πρόβλεψη ζήτησης ηλεκτρικής ενέργειας στην Γαλλία. Αποτέλεσμα της έρευνας ήταν ότι η προτεινόμενη λύση επιτυγχάνει την υψηλότερη βαθμολογία απόδοσης σε σύγκριση με άλλα εναλλακτικά μοντέλα όπως το ARIMA, SVM, Linear Regression, Regression Trees και τα απλά ANN [52].

Οι M. Shapi, N. Ramli και L. Awalin σε έρευνά τους πάνω στην διαχείριση ηλεκτρικής ενέργειας σε κτίρια, δοκίμασαν τρία μοντέλα μηχανικής μάθησης, SVM, ANN και k-Nearest Neighbour, για την πρόβλεψη κατανάλωσης ηλεκτρικής ενέργειας σε δύο εμπορικά κτίρια στην Μαλαισία, με δεδομένα κατανάλωσης από τον Ιούνιο του 2018 έως τον Δεκέμβριο του 2018. Σύμφωνα με τα αποτελέσματα της έρευνας το μοντέλο SVM είχε το πιο ελπιδοφόρο αποτέλεσμα σε σχέση με τα άλλα δύο. Τέλος, επισημαίνεται ότι σημαντικός παράγοντας για την ταχύτητα απόδοσης αποτελεσμάτων των μοντέλων αποτελεί η επεξεργαστική δύναμη του υπολογιστή που λαμβάνουν χώρα οι μοντελοποιήσεις [53].

Τέλος, έρευνα σχετική με λιμάνια και μοντέλα πρόβλεψης μηχανικής μάθησης που βρέθηκε είναι αυτή των Y. Peng, H. Liu, J. Huang, W. Wang, στην οποία χρησιμοποιούνται μοντέλα μηχανικής μάθησης για την πρόβλεψη ποια χαρακτηριστικά επηρεάζουν την κατανάλωση ενέργειας σε πλοία και επιπλέον αναφέρονται διάφορες τεχνικές μείωσης αυτής της απαιτούμενης ενέργειας. Με δεδομένα 15 διαφορετικά χαρακτηριστικά που επηρεάζουν την κατανάλωση ενέργειας στα πλοία, που συλλέχθηκαν από το λιμάνι του Τζινγκτάνγκ (*Jingtang*) στην Κίνα, κατασκευάζονται πέντε μοντέλα μηχανικής μάθησης, το Gradient Boosting Regression (GBR), Random Forest Regression (RF), BP Network (BP), Linear Regression (LR) και K-Nearest Neighbor Regression (KNN). Τα αποτελέσματα δείχνουν ότι η καθαρή χωρητικότητα, η χωρητικότητα νεκρού βάρους, το πραγματικό βάρος και η αποδοτικότητα των εγκαταστάσεων είναι τα κορυφαία τέσσερα χαρακτηριστικά για την πρόβλεψη της κατανάλωσης ενέργειας των πλοίων. Τέλος, συμπεραίνεται ότι όταν η αποδοτικότητα των εγκαταστάσεων διπλασιάζεται, η κατανάλωση ενέργειας των πλοίων μειώνεται κατά 34,17% σε ελλιμενισμό και 8,41% σε λιμάνι [54].


3. Μεθοδολογία

3.1. Περιγραφή περίπτωσης μελέτης


Η Κρήτη είναι ο πρώτος μεγάλος νησιωτικός ναυτικός σταθμός της Ελλάδας με αποτέλεσμα την μεγάλη προσέλευση εμπορικών και επιβατικών πλοίων στα λιμάνια της. Αποτέλεσμα αυτού είναι η αυξημένη κινητικότητα στα λιμάνια του Ηρακλείου, της Σούδας και του Ρεθύμνου.

Στην περιοχή των Χανίων, ο κόλπος της Σούδας είναι το μεγαλύτερο φυσικό λιμάνι της Κρήτης και ο λιμένας της Σούδας (**Εικόνα 3**) είναι ένα από τα ασφαλέστερα λιμάνια της Μεσογείου, λόγω του γεωγραφικού του προσανατολισμού. Καθημερινά διακινούνται χιλιάδες επιβάτες, πολλά οχήματα (επιβατηγά, φορτηγά) καθώς και εμπορεύματα, θέτοντάς το ως ένα συνεχώς αναπτυσσόμενο λιμάνι, το οποίο συμβάλλει καθοριστικά στην ανάπτυξη του Νομού Χανίων.

Η Σούδα είναι μια κωμόπολη της περιφέρειας της Κρήτης, με πληθυσμό 6.418 κατοίκους, βάση της απογραφής του 2011. Είναι κτισμένη στα νοτιοδυτικά του Κόλπου της Σούδας και στα μεταπολεμικά χρόνια πήρε την πολεοδομική της μορφή. Το λιμάνι της Σούδας καθημερινά συνδέεται με πλοία εσωτερικού με το λιμάνι του Πειραιά, καθώς και με πλοία εξωτερικού, είτε εμπορικά είτε κρουαζιερόπλοια (**Εικόνα 4**). Τέλος σημαντικό μέρος στην ανάπτυξη και σημαντικότητα του λιμανιού διαδραματίζει η ύπαρξη στρατιωτικών εγκαταστάσεων τόσο του Ελληνικού Πολεμικού Ναυτικού όσο και του ΝΑΤΟ στον κόλπο της Σούδας.




Εικόνα 3. Κάτοψη Λιμένα Σούδας [33].




Εικόνα 4. Θέση και χαρακτηριστικά λιμένα [33].


Το λιμάνι της Σούδας, σύμφωνα και με τα πιο πρόσφατα στοιχεία που βρέθηκαν από την **Eurostat** [55] & **ΕΛΣΤΑΤ** [56], καταλαμβάνει την δεύτερη θέση, στην Κρήτη, σχετικά με την κίνηση των πλοίων, μετά το Ηράκλειο. Επιπλέον, από **Εικόνα 5** και τα σχετικά διαγράμματα φαίνεται ότι στο μέλλον θα συνεχίσει να εξυπηρετεί αρκετά εμπορικά και επιβατικά πλοία, καθώς η κίνηση έχει ανοδική τάση. Επίσης σύμφωνα και με την παγκόσμια οικονομικο-κοινωνική ανάπτυξη το λιμάνι θα συνεχίσει το μέλλον να αναπτύσσεται, να μεγαλώνει σε μέγεθος και να δέχεται όλο και περισσότερα πλοία, εμπορικά και επιβατικά.




(α)



(β)



(γ)




(δ)

Εικόνα 5. (α) Κίνηση πλοίων στο λιμάνι της Σούδας, **(β)** Κίνηση κρουαζιερόπλοιων στο λιμάνι της Σούδας, **(γ)** Κίνηση κρουαζιερόπλοιων στα λιμάνια της Κρήτης το 2019, **(δ)** Συνολικοί διακινηθέντες εσωτερικού στα λιμάνια της Κρήτης το 2018.

3.1.1. Ηλιακό και Αιολικό δυναμικό περιοχής μελέτης

Επιπλέον, σημαντικό είναι να αναφερθεί και η δυναμικότητα της περιοχής του κόλπου της Σούδας (**Εικόνα 6**) καθώς και της περιοχής του λιμένα για την παραγωγή ηλεκτρικής ενέργειας από συστήματα ΑΠΕ.

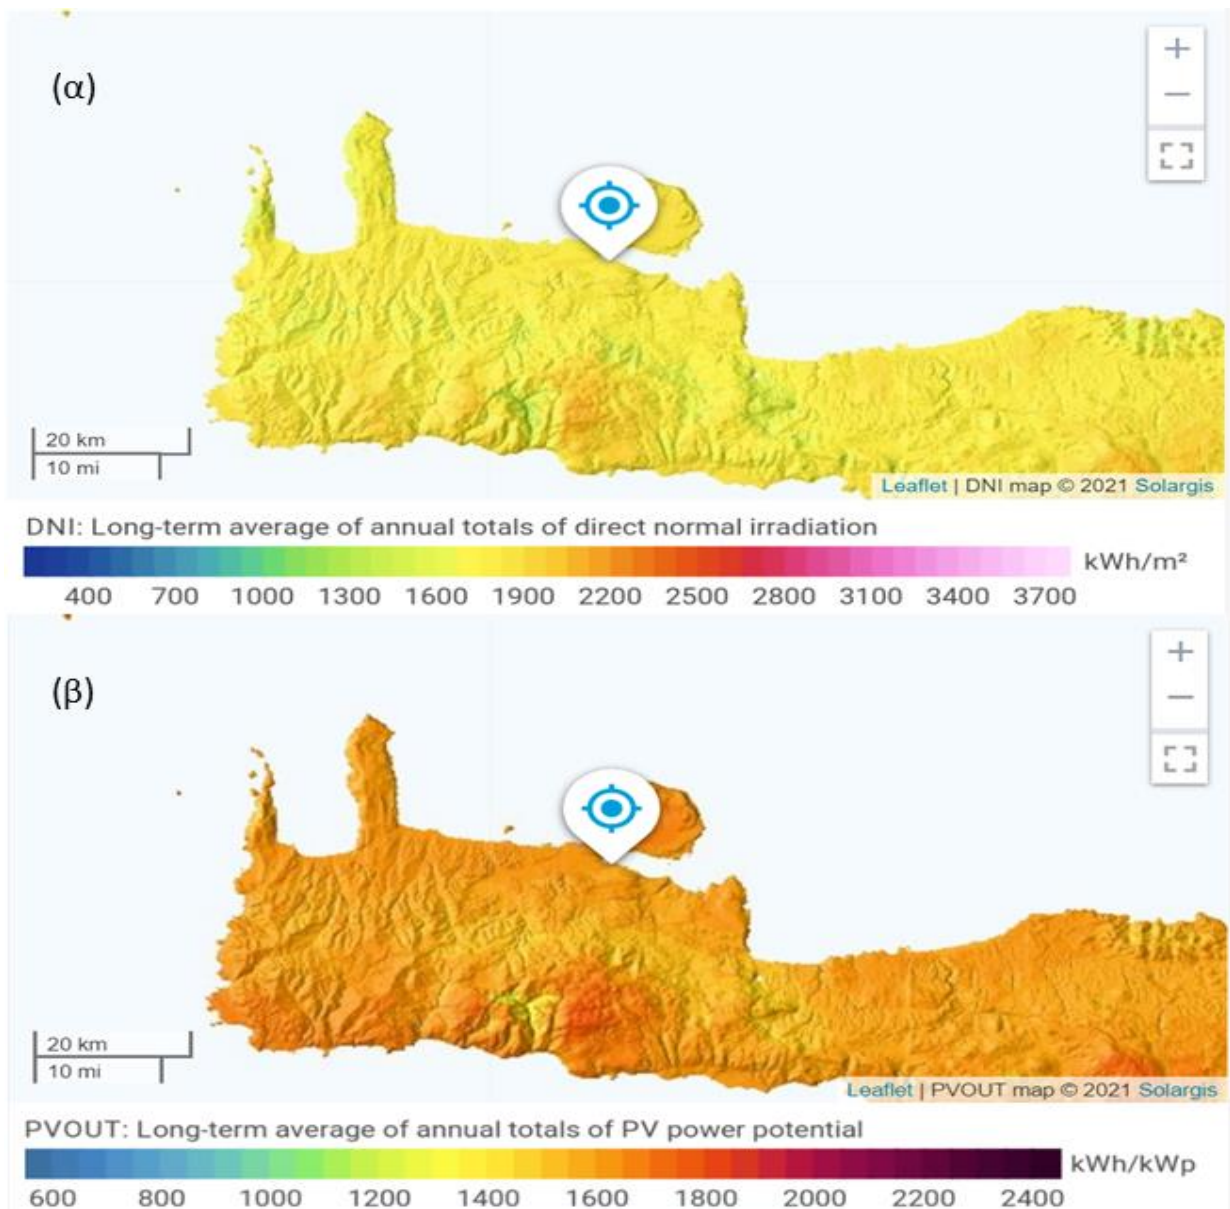
Σύμφωνα με ανοιχτά δεδομένα από την ιστοσελίδα <https://globalsolaratlas.info/map> και <https://globalwindatlas.info/>, που παρέχονται από την **World Bank Group** [57], για την περιοχή της Σούδας εξάγονται τα εκατέρωθεν δεδομένα :



Εικόνα 6. Πόλη και λιμένας Σούδας [58].


Πίνακας 1. Δεδομένα περιοχής Σούδας ανά χρόνο.

Ειδική παραγωγή φ/β ισχύος	PVOUT specific	1.608 kwh/kWp
Άμεση κανονική ακτινοβολία	DNI	1.825 kWh/m ²
Παγκόσμια οριζόντια ακτινοβολία	GHI	1.811 kWh/m ²
Διάχυτη οριζόντια ακτινοβολία	DIF	648 kWh/m ²
Παγκόσμια κεκλιμένη ακτινοβολία σε βέλτιστη γωνία	GTI opta	1.985 kWh/m ²
Βέλτιστη κλίση φ/β μονάδων	OPTA	27 / 180°
Θερμοκρασία αέρα	TEMP	19,1 °C
Υψόμετρο εδάφους	ELE	6 m



Εικόνα 7. (α) Μακροπρόθεσμος μέσος όρος ετήσιων συνόλων άμεσης κανονικής ακτινοβολίας [58], **(β)** Μακροπρόθεσμος μέσος όρος ετήσιων συνόλων δυναμικού Φ/Β ισχύος [58].

Από την **Εικόνα 7** είναι φανερό πως περιοχή της Σούδας έχει αρκετά καλό ηλιακό δυναμικό, το οποίο θα μπορούσε να αξιοποιηθεί από την τοπική κοινωνία. Σύμφωνα και με τον **Πίνακα 1**, το ηλιακό δυναμικό δείχνει αρκετά ικανοποιητικό για αξιοποίηση από συστήματα φωτοβολταϊκών πλαισίων για παραγωγή ηλεκτρικής ενέργειας. Επιπλέον συστήματα ηλιακών συλλεκτών σε κτίρια θα έχουν αρκετά καλή απόδοση καθ' όλη τη διάρκεια του χρόνου (ιδιαίτερως τους θερινούς μήνες), σύμφωνα και με το **Διάγραμμα 1** και **Διάγραμμα 2**.



Διάγραμμα 1. Μηνιαίο προφίλ άμεσης κανονικής ακτινοβολίας.

Direct normal irradiation [Wh/m²]


	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec
0 - 1												
1 - 2												
2 - 3												
3 - 4												
4 - 5												
5 - 6					15	55	21					
6 - 7			9	80	222	340	296	183	54	8		
7 - 8	7	33	154	279	391	503	503	443	338	198	64	
8 - 9	175	238	324	387	498	615	623	574	464	352	260	144
9 - 10	298	335	405	471	582	699	707	667	543	419	344	264
10 - 11	342	383	454	527	628	751	767	727	599	459	382	307
11 - 12	354	406	478	550	653	774	795	754	620	467	392	312
12 - 13	347	398	477	558	654	777	803	759	624	463	394	311
13 - 14	335	380	466	550	641	768	795	746	602	452	367	296
14 - 15	316	350	448	514	613	734	771	717	562	415	322	266
15 - 16	267	305	395	460	556	679	717	663	499	342	268	220
16 - 17	172	238	326	383	482	608	641	584	414	231	121	92
17 - 18	15	74	203	272	379	501	529	455	221	23		
18 - 19			11	48	143	293	311	132	9			
19 - 20						15	16					
20 - 21												
21 - 22												
22 - 23												
23 - 24												
Sum	2629	3139	4150	5077	6459	8111	8295	7404	5549	3830	2914	2212

Διάγραμμα 2. Ωριαίο προφίλ άμεσης κανονικής ακτινοβολίας [58].


Περαιτέρω, πέραν του ηλιακού δυναμικού η περιοχή της Σούδας διαθέτει και ένα ικανοποιητικό αιολικό δυναμικό, το οποίο μέσω ανεμογεννητριών θα μπορούσε να αποτελέσει μια φιλική προς το περιβάλλον παραγωγή ηλεκτρικής ενέργειας. Η περιοχή παρουσιάζει μέση προς υψηλή μέση ταχύτητα ανέμου στα 100m και μέση προς χαμηλή μέση πυκνότητα ισχύος ανέμου στα 100m – (Εικόνα 8, Πίνακας 2).

Πίνακας 2. Δεδομένα για το 10% των πιο ανεμώδη περιοχών.

Μέση πυκνότητα ισχύος ανέμου (W/m^2)	Μέση ταχύτητα ανέμου (m/s)	Ύψος (m)
183	3,85	10
262	4,67	50
321	5,32	100
406	5,87	150
505	6,36	200




Εικόνα 8. (Αριστερά) Μέση ταχύτητα ανέμου στα 100m [59], (Δεξιά) Μέση πυκνότητα ισχύος ανέμου στα 100m [59].




Εικόνα 9. Ωριαία και Μηνιαία ταχύτητα ανέμου [59].

Επιπλέον τους χειμερινούς μήνες φαίνονται να εμφανίζονται οι υψηλότερες τιμές της ταχύτητας ανέμου (**Εικόνα 9, Εικόνα 10**) καθώς και μεταξύ των ωρών 1:00-3:00 τα ξημερώματα και 13:00-15:00 το μεσημέρι. Τέλος, από το **Διάγραμμα 3**, φαίνεται πως η ταχύτητα ανέμου συχνότερα κυμαίνεται μεταξύ 4 έως 6,5 m/s.




Εικόνα 10. (α) Μέση ταχύτητα ανέμου σε μηνιαία βάση [59], **(β)** Μέση ταχύτητα ανέμου σε ωριαία βάση [59].



Διάγραμμα 3. Ιστογράμμο ταχύτητας ανέμου.

3.1.2. Ενεργειακό προφίλ λιμένα Σούδας


Στο **Διάγραμμα 4** φαίνεται το ωριαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας του λιμένα Σούδας. Από το διάγραμμα είναι φανερό πως η κύρια κατανάλωση ηλεκτρικής ενέργειας γίνεται τα ξημερώματα και το βράδυ, πράγμα που οφείλεται στον φωτισμό του λιμανιού. Επίσης, από το **Διάγραμμα 5** παρατηρείται ότι κατά την διάρκεια της εβδομάδας η κατανάλωση ηλεκτρικής ενέργειας του 24ώρου από μέρα σε μέρα, δεν διαφέρει σημαντικά. Τέλος στο **Διάγραμμα 6** αποτυπώνεται το μέσο ωριαίο προφίλ απαίτησης ηλεκτρικής ισχύος για ολόκληρη την πενταετία. Το μπλε χρώμα υποδηλώνει χαμηλή απαίτηση και εμφανίζεται μεταξύ 8:00π.μ. - 4:00μ.μ για χειμερινές περιόδους, (για τις θερινές περίπου 7:00π.μ.- 7:00μ.μ.), ενώ το θερμό χρώμα υποδηλώνει υψηλές απαιτήσεις και εμφανίζεται μεταξύ 5:00μ.μ. – 7:00π.μ. (ή 7:00μ.μ.- 6:00π.μ. για θερινές). Επίσης, στις χειμερινές περιόδους η κατανάλωση είναι μεγαλύτερη σε σχέση με τις θερινές και επιπλέον με την πάροδο του χρόνου η μέση κατανάλωση ηλεκτρικής ενέργειας αυξάνεται, όπως φαίνεται και στον **Πίνακα 3**, λόγω συνεχούς ανάπτυξης του λιμένα. Αναμένεται και στα επόμενα χρόνια να ακολουθηθεί η αυξητική τάση.




Διάγραμμα 4. Ωριαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας.

Πίνακας 3. Διακύμανση ωριαίας κατανάλωσης ηλεκτρικής ενέργειας (kWh) για τα έτη 2015-2019.

	Ελάχιστη	Μέση	Μέγιστη
2015	5,14	49,57	114,16
2016	11,18	56,52	126,97
2017	15,04	61,72	120,13
2018	14,15	73,31	152,22
2019	12,43	76,20	153,35



Διάγραμμα 5. Ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας.




Διάγραμμα 6. Μέσο ωριαίο προφίλ απαίτησης ηλεκτρικής ισχύος για τα έτη 2015-2019.

Όμοια με τις ωριαίες, παρουσιάζεται και η διακύμανση των ημερήσιων καταναλώσεων στον **Πίνακα 4**.

Πίνακας 4. Διακύμανση ημερήσιας κατανάλωσης ηλεκτρικής ενέργειας (kWh) για τα έτη 2015-2019.

	Ελάχιστη	Μέση	Μέγιστη
2015	800,43	1.189,60	1.709,05
2016	981,75	1.356,42	2.214,22
2017	1.076,45	1.481,17	2.130,17
2018	1.157,48	1.760,72	2.469,24
2019	1.442,91	1.827,56	2.504,48




Διάγραμμα 7. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας.

Από **Διάγραμμα 7** το είναι φανερό ότι οι μεγαλύτερες καταναλώσεις ηλεκτρικής ενέργειας λαμβάνουν χώρα του χειμερινούς μήνες, έναντι των θερινών, πράγμα που οφείλεται στην περισσότερη διάρκεια του φωτισμού του λιμένα τους χειμερινούς μήνες λόγω της μικρότερης διάρκειας της ημέρας. Τους θερινούς μήνες, όπου αυξάνεται η διάρκεια της ημέρας, η κατανάλωση ηλεκτρικής ενέργειας μειώνεται. Επιπλέον, στον **Πίνακα 5** φαίνεται η διακύμανση της μηνιαίας κατανάλωσης ηλεκτρικής ενέργειας για τα έτη 2015-2019.


Πίνακας 5. Διακύμανση μηνιαίας κατανάλωσης ηλεκτρικής ενέργειας για τα έτη 2015-2019.

	Ελάχιστη	Μέση	Μέγιστη
2015	28.973,61	36.183,57	44.183,93
2016	35.719,79	41.368,97	55.583,36
2017	38.665,88	45.049,07	57.177,82
2018	43.010,96	53.514,47	69.453,35
2019	48.349,18	55.623,59	70.283,08

Στο **Διάγραμμα 8** φαίνεται το μηνιαίο ενεργειακό προφίλ του λιμένα Σούδας για τα έτη 2015-2019. Παρατηρείται ότι οι καταναλώσεις ηλεκτρικής ενέργειας ακολουθούν μια αυξητική τάση, έχουν εποχικότητα με μεγαλύτερες τις καταναλώσεις κάθε χειμώνα αντί το καλοκαίρι και μια διαχρονικότητα με σημαντικές κορυφές κάθε δύο χρόνια. Επιπλέον, η μέγιστη κατανάλωση ηλεκτρικής ενέργειας παρατηρήθηκε τον Ιανουάριο του 2019 με τιμή 70.283,08 kWh, η ελάχιστη παρατηρήθηκε τον Ιούνιο του 2015, με τιμή 28.973,61 kWh. Τέλος, στο **Διάγραμμα 8** αποτυπώνεται η μέση ημερήσια κατανάλωσης ηλεκτρικής ενέργειας της πενταετίας 2015-2019, από το οποίο επαληθεύεται το γεγονός ότι την χειμερινή περίοδο οι καταναλώσεις είναι μεγαλύτερες, έναντι των θερινών, λόγω κυρίως της λειτουργίας του φωτισμού του λιμανιού.



Διάγραμμα 8. Προφίλ κατανάλωσης ηλεκτρικής ενέργειας από το 2015-2019 σε μηνιαία βάση.



Διάγραμμα 9. Μέση ημερήσια κατανάλωση ηλεκτρικής ενέργειας για τα έτη 2015-2019.

3.2 Περιγραφή μοντέλων πρόβλεψης

Στην ενότητα αυτή γίνεται μια συνοπτική παρουσίαση των μεθόδων που χρησιμοποιήθηκαν για την πρόβλεψη του ενεργειακού προφίλ.

3.2.1 Μοντέλο Γραμμικής Παλινδρόμησης (Linear Regression Models)

Απλή Γραμμική Παλινδρόμηση (Simple Linear Regression)

Η γραμμική παλινδρόμηση είναι μια ευρέως χρησιμοποιούμενη στατιστική προσέγγιση για τη μοντελοποίηση της σχέσης μεταξύ μιας εξαρτημένης μεταβλητής Y και μιας ή περισσότερων ανεξάρτητων μεταβλητών X και η εξίσωση που την περιγράφει είναι:

$$Y = a + bX \quad (1)$$

, όπου το a είναι η σταθερά (constant) και αποδίδει την τιμή Y όταν το X είναι μηδέν και το b αποτελεί την κλίση της ευθείας και αναπαριστά το συντελεστή παλινδρόμησης (coefficient). Η αξιοπιστία του μοντέλου φαίνεται από την απόκλιση ή το υπόλοιπο (residual) της παρατηρούμενης τιμής Y , από την τιμή της πρόβλεψης του Y του μοντέλου μετά την παλινδρόμηση. Τα τετράγωνα των αποκλίσεων αθροίζονται και δίνουν την συνολική απόκλιση του μοντέλου ονομαζόμενη *άθροισμα των τετραγώνων των υπολειπόμενων* RSS (Residuals Sum of Squares). Όσο μικρότερη τιμή έχει το RSS τόσο πιο αξιόπιστο θεωρείται το μοντέλο, ενώ το αντίθετο συμβαίνει όσο το RSS είναι σχετικά μεγάλο. Για περισσότερες από μία μεταβλητές X που επηρεάζουν την τιμή του Y , το μοντέλο ονομάζεται *πολλαπλή γραμμική παλινδρόμηση* (Multiple Linear Regression) και η εξίσωση είναι:

$$Y = a + b_1X_1 + b_2X_2 + \dots + b_nX_n \quad (2)$$

3.2.2 Μοντέλα Χρονοσειρών (Timeseries Models)

3.2.2.1. Μέθοδος Διάσπασης Χρονοσειρών (Decomposition method)

Η ανάλυση των χρονοσειρών με τη μέθοδο αυτή στηρίζεται στη διάσπαση των παρατηρήσεων σε τέσσερα συνθετικά στοιχεία, στην τάση, στην εποχικότητα, στην κυκλικότητα και στη μη-κανονικότητα. Σκοπός της διάσπασης των χρονοσειρών είναι η απομόνωση των τεσσάρων παραπάνω συνθετικών στοιχείων, ώστε να προσδιοριστεί ο βαθμός που επηρεάζει κάθε ένα από αυτά τον τρόπο δημιουργίας των παρατηρήσεων των χρονοσειρών. Η εποχικότητα μετρίεται με τους δείκτες εποχικότητας, σκοπός των οποίων είναι η ανίχνευση του τρόπου συμπεριφοράς των παρατηρήσεων λόγω αυτού του φαινομένου, πράγμα που θα συμβάλλει στην απαλλαγή αυτού του στοιχείου και την δημιουργία πιο αξιόπιστων βραχυπρόθεσμων και μακροπρόθεσμων προβλέψεων. Η τάση φανερώνει τη μακροχρόνια εξέλιξη των τιμών της χρονοσειράς (ανοδική ή πτωτική), η οποία οφείλεται σε δημογραφικούς, τεχνολογικούς, οικονομικούς και άλλους παράγοντες. Η κυκλικότητα παρατηρείται σε χρονικές περιόδους μεγαλύτερες από αυτές της εποχικότητας (π.χ. πενταετία ή δεκαετία σε σχέση με τριμηνιαία ή ετήσια της εποχικότητας) και εμφανίζονται κυρίως σε οικονομικά ζητήματα, όπως μια οικονομική κρίση. Τέλος, η μη-κανονικότητα σχετίζεται με τυχαία φαινόμενα που ίσως επηρεάσουν την χρονοσειρά και δεν υπολογίζονται εύκολα [60]. Στα πλαίσια αυτής της διπλωματικής εργασίας, η κυκλικότητα και η μη-κανονικότητα δεν λαμβάνονται υπόψιν καθώς τα δεδομένα αναφέρονται σε ένα διάστημα πέντε ετών.

Στη μέθοδο διάσπασης υπάρχουν δύο είδη μοντέλων, το προσθετικό και το πολλαπλασιαστικό. Στο προσθετικό, οι πραγματικές τιμές εμφανίζονται ως άθροισμα των συνιστωσών και είναι της μορφής:

$$Y_t = \text{Trend} + \text{Seasonal} + \text{Error} \quad (3)$$

, ενώ στο πολλαπλασιαστικό οι πραγματικές τιμές παρουσιάζονται ως γινόμενο των συνιστωσών και είναι της μορφής:

$$Y_t = \text{Trend} \cdot \text{Seasonal} \cdot \text{Error} \quad (4)$$

3.2.2.2. Μοντέλο Αυτοπαλίνδρομου Ολοκληρωμένου Κινούμενου Μέσου (ARIMA)

Το μοντέλο ARIMA, γνωστό και ως μέθοδος Box-Jenkins, αποτελείται από τρία μέρη, το αυτοπαλίνδρομο μέρος (autoregression – AR), όπου υπάρχει συνδυασμός προηγούμενων τιμών, το μέρος του κινητού μέσου (moving average – MA), όπου χρησιμοποιεί προηγούμενα σφάλματα πρόβλεψης σε ένα σχεδόν-παλίνδρομο μοντέλο και το μέρος ολοκλήρωσης (integration – I), που αναφέρεται στην αντίστροφη διαδικασία διαφοροποίησης για την παραγωγή της πρόβλεψης.

Ένα αυτοπαλίνδρομο μοντέλο τάξης p ή AR(p) στη γενική του μορφή είναι:

$$Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t \quad (5)$$

, όπου $\varphi_1, \varphi_2, \dots, \varphi_p$ είναι οι προς εκτίμηση παράμετροι του μοντέλου και η ε_t καλείται λευκός θόρυβος. Η τάξη p αναφέρεται στο μήκος της υστέρησης και ο όρος αυτοπαλίνδρομο οφείλεται στο γεγονός ότι η παραπάνω σχέση είναι ένα υπόδειγμα παλινδρόμησης με ερμηνευτικές μεταβλητές τις τιμές της εξαρτημένης μεταβλητής Y_t με χρονική υστέρηση.

Ένα μοντέλο κινητού μέσου q τάξης ή MA(q) στη γενική του μορφή είναι:

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (6)$$

, όπου η τάξη q αναφέρεται στο μήκος της υστέρησης της μεταβλητής ε_t για την οποία υποθέτουμε ότι είναι λευκός θόρυβος. Ο όρος κινητός μέσος αναφέρεται στο γεγονός ότι η Y_t εμφανίζεται ως ένα σταθμισμένο άθροισμα των τιμών της ε_t .

Ένα μοντέλο ARMA(p, q) είναι ο συνδυασμός p αυτοπαλίνδρομων όρων και q όρων κινητού μέσου, αποκαλείται μεικτό αυτοπαλίνδρομο-κινητού μέσου υπόδειγμα τάξης (p, q), και έχει την μορφή:

$$\Phi(B)Y_t = \Theta(B)\varepsilon_t \quad (7)$$

, όπου $\Phi(B) = 1 - \varphi_1 B - \dots - \varphi_p B^p$ και $\Theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ και

Ένα μη-εποχικό ARIMA μοντέλο ονομάζεται και ARIMA(p, d, q) μοντέλο όπου :

- p είναι ο αριθμός των αυτοπαλίνδρομων όρων,
- d είναι ο αριθμός των μη-εποχικών διαφορών που απαιτούνται για τη στασιμότητα και
- q είναι ο αριθμός των καθυστερημένων σφαλμάτων προβλέψεων στην εξίσωση πρόβλεψης.

και χρησιμοποιείται όταν η χρονοσειρά δεν είναι στάσιμη (πχ χρονολογικές σειρές οικονομικού, ενεργειακού ή φυσικού περιεχομένου). Με τις πρώτες, (ή δεύτερες, γενικά d τάξης) διαφορές μετατρέπεται σε στάσιμη. Ένα μοντέλο ARIMA(p, d, q) έχει την μορφή:

$$\Phi(B)(1 - B)^d Y_t = \Theta(B)\varepsilon_t \quad (8)$$

Επιπλέον σε χρονοσειρές που παρουσιάζουν εποχικότητα s , χρησιμοποιείται το μοντέλο $SARIMA(p,d,q)(P,D,Q)_s$, όπου P,D,Q είναι τα αντίστοιχα μεγέθη των p,d,q σύμφωνα με την εποχικότητα s . Ένα $SARIMA(p,d,q)(P,D,Q)_s$ μοντέλο έχει την μορφή :

$$\varphi(B)\Phi(B^s)w_t = \theta(B)\theta(B^s)\varepsilon_t \quad (9)$$

, όπου $\varphi(B) = 1 - \varphi_1 B - \dots - \varphi_p B^p$,

$$\Phi(B^s) = 1 - \Phi_1 B^s - \dots - \Phi_P B^{Ps},$$

$$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q,$$

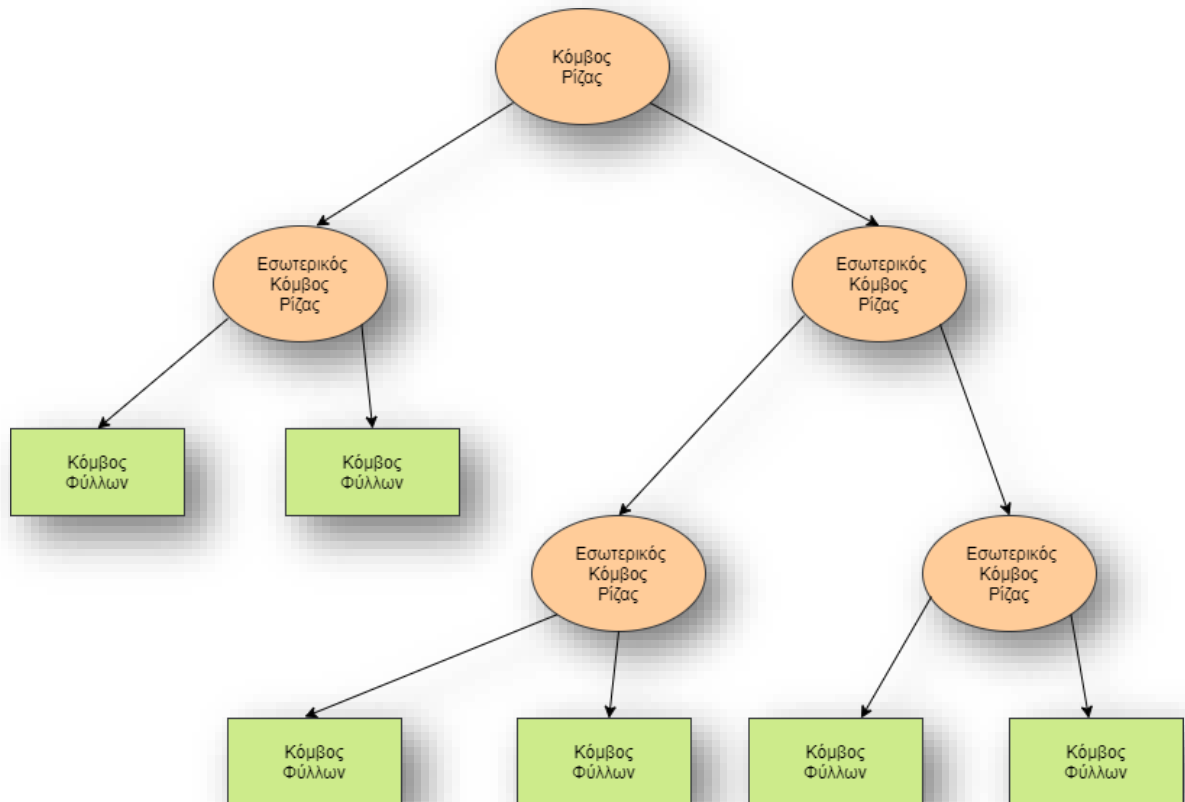
$$\theta(B^s) = 1 - \theta_1 B^s - \dots - \theta_Q B^{Qs} \text{ και } w_t = \nabla^d \nabla_s^D Y_t$$

Σημαντικό για την δημιουργία των μοντέλων είναι τα διαγράμματα αυτοσυσχέτισης ACF και μερικής αυτοσυσχέτισης PACF. Ο συντελεστής αυτοσυσχέτισης (ACF) είναι ένας στατιστικός δείκτης ο οποίος χρησιμοποιείται στην ανάλυση χρονοσειρών για τον καθορισμό της τυχαιότητας ή μη της χρονοσειράς. Ο συντελεστής μερικής αυτοσυσχέτισης (PACF) μετρά το βαθμό της σχέσης μεταξύ των Y_t και Y_{t-k} , όταν οι επιδράσεις όλων των άλλων χρονικών υστερήσεων $1,2,3,\dots,k-1$ έχουν αφαιρεθεί.

3.2.3. Μέθοδοι Μηχανικής Μάθησης (Machine Learning Methods)

3.2.3.1. Δέντρα Αποφάσεων (Decision Trees)

Τα δέντρα αποφάσεων προσπαθούν να προβλέψουν με όσο μεγαλύτερη ακρίβεια την τιμή της μεταβλητής στόχου που μοντελοποιούν σύμφωνα με τα δεδομένα εισόδου [61]. Κάθε δέντρο αποτελείται από κόμβους και κάθε κόμβος είναι συνδεδεμένος με μία από τις μεταβλητές εισαγωγής. Οι κόμβοι επεκτείνονται σε φύλλα τα οποία αντιπροσωπεύουν την τιμή που προκύπτει από την μεταβλητή. Τα δέντρα αποφάσεων ξεκινούν πάντα από την κορυφή (ρίζα) και καταλήγουν σε φύλλο (**Εικόνα 11**) [62].



Εικόνα 11. Παράδειγμα δέντρου αποφάσεων.

3.2.3.2. Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines)


Οι μηχανές διανυσμάτων υποστήριξης προτάθηκαν πρώτα από τον *Vladimir Vapnik* το 1992 και ανήκουν στην κατηγορία των μεθόδων πυρήνων (kernel methods). Οι μέθοδοι πυρήνων χρησιμοποιούν μια συνάρτηση η οποία ομαδοποιεί τα δεδομένα εισόδου, της οποίας την συμπεριφορά στη συνέχεια αναπαριστούν γραφικά (**Εικόνα 12**). Οι εν λόγω μέθοδοι χρησιμοποιώντας τις λεγόμενες συναρτήσεις πυρήνων (ή συναρτήσεις ομοιοτήτων), μπορούν να λειτουργούν σε ένα υπερχώρο απεριόριστων διαστάσεων, χωρίς να χρειάζεται να υπολογίσουν τις συντεταγμένες των δεδομένων στο χώρο αυτό, αλλά υπολογίζοντας τον παραγόμενο χώρο εσωτερικού γινομένου (inner product space), μέσα από τις σχέσεις των δεδομένων μεταξύ τους [63]. Στην *MATLAB* υλοποιείται η γραμμική παλινδρόμηση SVM (ϵ -SVM) που είναι ευαίσθητη στο ϵ , γνωστό και ως απώλεια L1. Στην παλινδρόμηση ϵ -SVM, το σύνολο των δεδομένων εκπαίδευσης περιλαμβάνει μεταβλητές πρόβλεψης και παρατηρούμενες τιμές απόκρισης. Ο στόχος είναι να βρεθεί μια συνάρτηση $f(x)$ που αποκλίνει από το Y_n με τιμή όχι μεγαλύτερη από ϵ για κάθε σημείο προπόνησης X , και ταυτόχρονα να είναι όσο το δυνατόν πιο επίπεδη.

Δηλαδή σε ένα σετ δεδομένων εκπαίδευσης x_i και μεταβλητές στόχους y_i στόχος είναι η ελαχιστοποίηση του διανύσματος της υπερπαραμέτρου w :

$$\text{MIN} \frac{1}{2} \|w\|^2$$

Με περιορισμό:

$$|y_i - w_i x_i| \leq \varepsilon$$



Εικόνα 12. Παράδειγμα SVM [64].

3.2.3.3. Gaussian Process Regression – GPR

Η Gaussian Process Regression είναι μη παραμετρική, δηλαδή δεν περιορίζεται από μια λειτουργική μορφή, οπότε αντί να υπολογίζει την κατανομή πιθανότητας παραμέτρων μια συγκεκριμένης λειτουργίας, υπολογίζει την κατανομή πιθανότητας σε όλες τις αποδεκτές συναρτήσεις που ταιριάζουν στα δεδομένα. Ένα μοντέλο GPR εξηγεί την απόκριση εισάγοντας λανθάνουσες μεταβλητές $f(x_i), i = 1, 2, \dots, n$, από μια Γκαουσιανή διαδικασία (Gaussian Process – GP) και σαφείς συναρτήσεις βάσης, h . Η συνδιακύμανση των λανθάνων μεταβλητών αποτυπώνει την ομαλότητα της απόκρισης και οι συναρτήσεις βάσης προβάλλουν τις εισόδους x σε ένα p -διάστατο χώρο χαρακτηριστικών. Η GP είναι ένα σύνολο τυχαίων μεταβλητών, όπου κάθε πεπερασμένος αριθμός από αυτές να έχει κοινή κατανομή Gauss. Με βάση το θεώρημα Bayes [65], καθορίζεται μια Γκαουσιανή οπίσθια κατανομή σε συναρτήσεις στόχου, η μέση τιμή της οποίας χρησιμοποιείται για πρόβλεψη. Η Bayesian προσέγγιση σε μια γραμμική συνάρτηση $y = wx + \varepsilon$ λειτουργεί με τον καθορισμό της προηγούμενης κατανομής $p(w)$, στην παράμετρο w και μετεγκατάσταση των πιθανοτήτων με βάση τα παρατηρούμενα δεδομένα, σύμφωνα με τον κανόνα Bayes:

$$p(w|y, X) = \frac{p(y|X, w)p(w)}{p(y|X)} \quad (10)$$

Η ενημερωμένη διανομή $p(w|y, X)$, ονομάζεται οπίσθια διανομή, ενσωματώνει πληροφορίες από την προηγούμενη διανομή και από το σύνολο των δεδομένων.

Η GPR μαθαίνει μια συνάρτηση στόχο χρησιμοποιώντας εσωτερικά το «κόλπο του πυρήνα» (kernel trick) και χρησιμοποιεί τον πυρήνα για να καθορίσει τη συν διακύμανση μιας προηγούμενης κατανομής έναντι των συναρτήσεων στόχου και χρησιμοποιεί τα παρατηρούμενα δεδομένα εκπαίδευσης για να καθορίσει μια συνάρτηση πιθανότητας. Η GPR επιλέγει τις υπερπαραμέτρους του πυρήνα με βάση την κλίση στη συνάρτηση οριακής πιθανότητας και μαθαίνει ένα γενετικό, πιθανοτικό μοντέλο της συνάρτησης στόχου με αποτέλεσμα να παρέχει ουσιαστικά διαστήματα εμπιστοσύνης και οπίσθια δείγματα μαζί με τις προβλέψεις (**Εικόνα 13**) [66].

Ένα μοντέλο GPR παρίσταται ως εξής:


$$h(x)^T \beta + f(x) \quad (11)$$

, όπου $f(x) \sim GP(0, k(x, x'))$ από ένα μηδενικό μέσο GP με συνάρτηση συν διακύμανσης $k(x, x')$, $h(x)$ είναι ένα σετ συναρτήσεων βάσης που μεταλλάσσουν το αρχικό διάνυσμα χαρακτηριστικών $x \in \mathbb{R}^d$ σε ένα νέο διάνυσμα χαρακτηριστικών $h(x) \in \mathbb{R}^p$, β είναι ένα $p \times 1$ διάνυσμα συναρτήσεων βάσης συντελεστών.

Ένα παράδειγμα απόκρισης y μπορεί να μοντελοποιηθεί ως:

$$P(y_i | f(x_i), x_i) \sim N(y_i | h(x_i)^T \beta + f(x_i), \sigma^2) \quad (12)$$

, όπου σ^2 είναι η διακύμανση σφάλματος




Εικόνα 13. Παράδειγμα μοντέλου GPR [67].

3.2.3.4. Ensemble Methods

Τα μεταμαθησιακά μοντέλα ή και συνδυαστικές μέθοδοι (Ensemble Methods) είναι συνδυασμοί αλγορίθμων οι οποίοι καλύπτουν τις αδυναμίες που εμφανίζουν ο καθένας ξεχωριστά, με στόχο την βελτιστοποίηση των αποτελεσμάτων. Ο κάθε αλγόριθμος που χρησιμοποιεί μεταμαθησιακά μοντέλα, χωρίζει το σύνολο των δεδομένων, με τυχαιότητα, σε διάφορα σύνολα εκπαίδευσης/τροποποίησης. Έπειτα μέσω ψηφοφορίας (voting) αποδίδοντας είτε ίδια είτε διαφορετική βαρύτητα σε κάθε μέθοδο, με βάση τους δείκτες αξιολόγησης, επιλέγει την τιμή με τις περισσότερες ψήφους, στην περίπτωση της παλινδρόμησης. Κατά περίπτωση εμφανίζουν αυξημένο υπολογιστικό φόρτο [68].

Μια κλασσική μεθοδολογία μεταμαθησιακού αλγορίθμου περιγράφεται από τον αλγόριθμο bagging, που χρησιμοποιεί συνδυασμό ίδιων μεθόδων. Στην περίπτωση των Bagging Trees χρησιμοποιούνται πολλαπλά δέντρα απόφασης στα οποία επιλέγεται με τυχαιότητα το εκάστοτε σύνολο εκπαίδευσης που θα χρησιμοποιηθεί ως είσοδος. Τα σύνολα εκπαίδευσης αποτελούν υποσύνολα του αρχικού συνόλου εκπαίδευσης. Νέοι συνδυασμοί δημιουργούνται σε κάθε επανάληψη εκμάθησης, αφαιρώντας κάθε φορά τους ακατάλληλους. Επίσης, μια άλλη μεθοδολογία είναι η boosting, η οποία χρησιμοποιεί ψηφοφορία. Στην ψηφοφορία αποδίδει βάρη βάσει επιπέδων βεβαιότητας (confidence), του κάθε μοντέλου, και στην συνέχεια συνδυάζει μοντέλα από τον ίδιο αλγόριθμο. Τέλος εκτελεί επαναληπτική διαδικασία κατά την οποία χρησιμοποιεί όποια γνώση προέκυψε από το προηγούμενο μοντέλο με στόχο να βελτιώσει το επόμενο που θα αναπτυχθεί (**Εικόνα 14**) [68].




Εικόνα 14. Παράδειγμα ενός Ensemble μοντέλου.

3.2.3.5. Τεχνητά Νευρωνικά Δίκτυα (Neural Networks)

Τα τεχνητά νευρωνικά δίκτυα αποτελούνται από απλά στοιχεία που λειτουργούν παράλληλα και η λειτουργία του δικτύου καθορίζεται σε μεγάλο βαθμό από τις συνδέσεις μεταξύ των στοιχείων. Ένα ΤΝΔ μπορεί να εκπαιδευτεί για να εκτελέσει μια συγκεκριμένη λειτουργία προσαρμόζοντας τις τιμές των συνδέσεων (βάρη) μεταξύ των στοιχείων, έτσι ώστε μια συγκεκριμένη είσοδος να οδηγεί σε συγκεκριμένη έξοδο στόχου. Σχετικά με το πώς είναι συνδεδεμένα τα στοιχεία μεταξύ τους, τα ΤΝΔ χωρίζονται σε δύο βασικές κατηγορίες [69]:


- Πρόσθιας τροφοδότησης (**Feed forward**),
- Οπίσθιας τροφοδότησης (**Feed backward**)

Στα ΤΝΔ πρόσθιας τροφοδότησης τα στοιχεία είναι οργανωμένα σε διαφορετικά επίπεδα και τα στοιχεία του ενός επιπέδου τροφοδοτούν τα στοιχεία του επόμενου επιπέδου, πράγμα το οποίο συνεχίζεται μέχρι και το τελευταίο επίπεδο (**Σχήμα 3**).



Σχήμα 3. Πολυεπίπεδο ΤΝΔ πρόσθιας τροφοδοσίας.

Στα οπισθίως τροφοδοτούμενα δίκτυα, επίσης γνωστά και ως ανατροφοδοτούμενα ΤΝΔ (**Recurrent ANN**), επιτρέπεται στα στοιχεία ενός επιπέδου να τροφοδοτούν και τις μονάδες του ίδιου ή και προηγούμενου επιπέδου. Αν η ανατροφοδότηση αφορά κόμβους του ίδιου επιπέδου, τα δίκτυα ονομάζονται αυτοσυσχετιζόμενες μνήμες (autoassociated memories) αλλιώς, καλούνται ετεροσυσχετιζόμενες μνήμες (heteroassociated memories) (**Σχήμα 4**) [69].



Σχήμα 4. Αυτο-συσχετιζόμενη (αριστερά) και ετερο-συσχετιζόμενη (δεξιά) μνήμη.

Αν και τα ανατροφοδοτούμενα ΤΝΔ είναι αρκετά χρήσιμα, τις περισσότερες φορές χρησιμοποιούνται ΤΝΔ πρόσθιας τροφοδότησης. Επίσης, στα πολύ-επίπεδα ΤΝΔ ο συνηθέστερος τρόπος μάθησης είναι με οπισθοδιάδοση σφάλματος (error backpropagation), η οποία ανήκει στον τομέα της επιβλεπόμενης μάθησης, και ο αλγόριθμος μάθησης ονομάζεται **Backpropagation ANN**. Κατά την εκπαίδευση των Backpropagation ΤΝΔ, για κάθε είσοδο που δίνεται στο δίκτυο, υπολογίζονται οι έξοδοι με εφαρμογή των συναρτήσεων μετάβασης σε κάθε μονάδα κρυφού ή εξωτερικού επιπέδου. Σε κάθε μονάδα εξωτερικού επιπέδου λαμβάνονται υπόψη οι διαφορές μεταξύ κρυφών επιπέδων, για την διαμόρφωση των βαρών σύνδεσης μεταξύ των μονάδων, με στόχο την μείωση του σφάλματος στην έξοδο [69].

Το πραγματικό σφάλμα E_k μιας μονάδας εξόδου k ενός παραδείγματος p υπολογίζεται ως:

$$E_k = (a_{kp} - o_{kp}) \quad (13)$$

Στην συνέχεια πολλαπλασιάζεται επί την παράγωγο της συνάρτησης ενεργοποίησης στη μονάδα k (u_k), σύμφωνα με τον γενικευμένο κανόνα δέλτα, για να υπολογιστεί το προσαρμοσμένο σφάλμα νευρώνα:

$$\delta_k = (a_{kp} - o_{kp}) \cdot g'(u_k) \quad (14)$$

Το αντίστοιχο σφάλμα σε μια μονάδα κρυφού επιπέδου i υπολογίζεται από τα προσαρμοσμένα σφάλματα στις k μονάδες του επόμενου επιπέδου με τις οποίες η μονάδα συνδέεται με βάρη w_{ik} :

$$\delta_i = g'(u_i) \cdot \sum_1^k w_{ik} \cdot \delta_k \quad (15)$$

Αφού υπολογιστεί για κάθε μονάδα i το σφάλμα δ_i , η αλλαγή στα βάρη εισόδου σε όλους το νευρώνες πραγματοποιείται ως εξής:

$$\Delta w_{ji} = -d \cdot \delta_i \cdot a_j \quad (16)$$

Δηλαδή η αλλαγή στο βάρος από τον νευρώνα i στον επόμενο j εξαρτάται από το σφάλμα του νευρώνα i , την έξοδο του νευρώνα j και το ρυθμό μάθησης d (learning rate).

Πλήθος τέτοιων κύκλων επαναλαμβάνονται κατά την διαδικασία της εκπαίδευσης και ο αλγόριθμος σταματά όταν το σφάλμα έχει φτάσει κάτω από το επιθυμητό όριο. Εναλλακτικά ως συνθήκη τερματισμού μπορεί να θεωρηθεί η πραγματοποίηση ενός συγκεκριμένου αριθμού κύκλων εκπαίδευσης ή η πάροδος ενός συγκεκριμένου χρονικού διαστήματος [69].

3.3 Περιγραφή διαδικασίας μοντελοποίησης, χρησιμοποιούμενων προγραμμάτων και δεδομένων

Για την δημιουργία των μοντέλων πρόβλεψης, χρησιμοποιήθηκαν μετεωρολογικά δεδομένα της περιοχής από το 2015-2019, αποκτώμενα από το **Εθνικό Αστεροσκοπείο Αθηνών** καθώς και για το 2030, τα οποία αποκτήθηκαν από μοντέλα πρόβλεψης μετεωρολογικών δεδομένων από το **Meteonorm** [70], από την πρόβλεψη για το 2030 του **IPCC** (Intergovernment Panel on Climate Change) [71]. Επιπλέον, δεδομένα κατανάλωσης ηλεκτρικής ενέργειας του λιμένα Σούδας, για τα έτη 2015-2019, παραχωρήθηκαν από το **Λιμενικό Ταμείο Χανίων** για την διεξαγωγή της παρούσας έρευνας. Τέλος, τα μοντέλα δημιουργήθηκαν σε υπολογιστή του εργαστηρίου **Ανανεώσιμων και Βιώσιμων Ενεργειακών Συστημάτων** [72], του τμήματος Χημικών Μηχανικών και Μηχανικών Περιβάλλοντος στο Πολυτεχνείο Κρήτης.

Αρχικά γίνεται ανάλυση των δεδομένων που χρησιμοποιήθηκαν για τυχών κενά και συμπλήρωση αυτών. Τα δεδομένα στην συνέχεια κατανέμονται σε τρεις βασικές κατηγορίες:

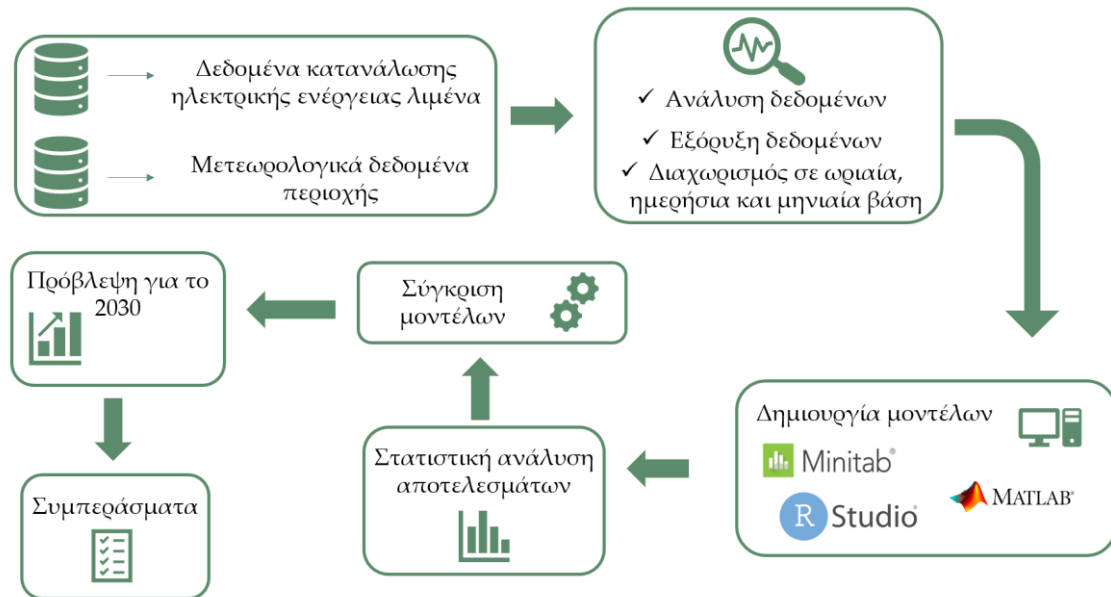
- Ωριαία,
- Ημερήσια,
- Μηνιαία.

, τα οποία αξιοποιήθηκαν αναλόγως με την ικανότητα του μοντέλου και την επεξεργαστική δυνατότητα του υπολογιστή που έλαβαν χώρα οι μοντελοποιήσεις.

Ως μεταβλητή πρόβλεψης είναι η κατανάλωση ηλεκτρικής ενέργειας μετρήσιμη σε kWh. Τα μετεωρολογικά δεδομένα που χρησιμοποιήθηκαν σε όλα τα μοντέλα, **πλην των χρονοσειρών**, είναι:

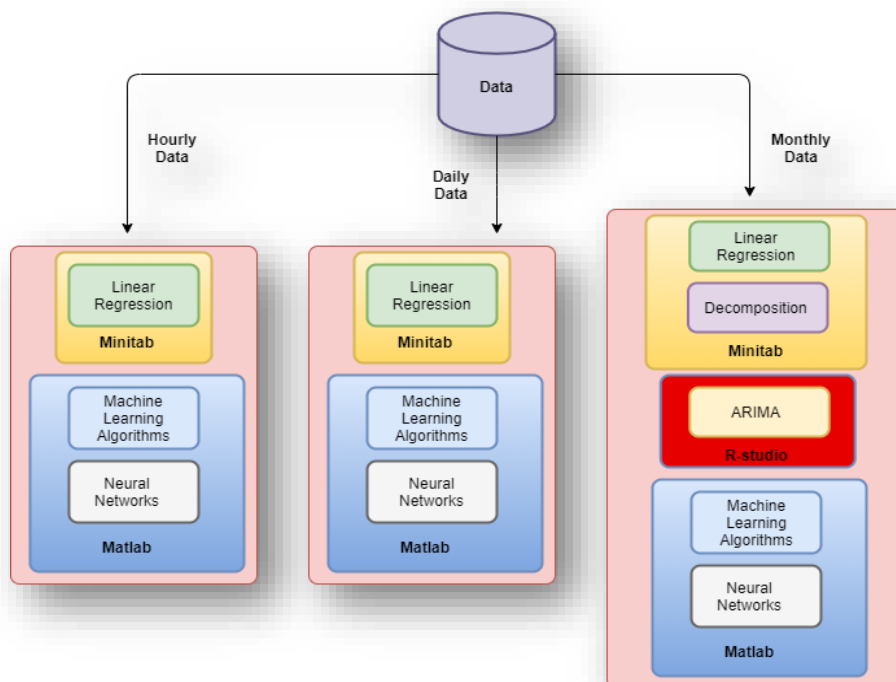
- Θερμοκρασία (Temperature): Μετρήσιμη σε βαθμούς Κελσίου ($^{\circ}\text{C}$)
- Υγρασία (Humidity): Μετρήσιμη σε ποσοστό επί της εκατό (%)
- Σημείο Δρόσου (Dewpoint): Το σημείο της θερμοκρασίας στο οποίο οι υδρατμοί, όταν ψυχθούν δημιουργούν το φαινόμενο δρόσου, μετρήσιμο σε βαθμούς Κελσίου ($^{\circ}\text{C}$)
- Ατμοσφαιρική Πίεση (Pressure): Μετρήσιμη σε hectopascal (hPa)
- Κατακρήμνιση (Precipitation): Μετρήσιμη σε mm
- Ταχύτητα Ανέμου (Wind Speed): Μετρήσιμη σε km/h
- Ηλιακή Ακτινοβολία (Solar Radiation): Μετρήσιμη σε W/m^2
- Χρονικό Βήμα (Timestep): Ακέραιοι αύξων αριθμοί για την αποτύπωση της αυξητικής τάσης.

- Ώρα ή Ημέρα ή Μήνας (Hour or Day or Month): Ακέραιοι αύξων αριθμοί για την αποτύπωση της ώρας ή της ημέρας ή του μήνα, ανάλογα με την κατηγορία των δεδομένων ή και συνδυασμός μερικών.



Σχήμα 5. Διάγραμμα ροής μεθοδολογίας.

Στην συνέχεια γίνεται στατιστική ανάλυση των αποτελεσμάτων των μοντέλων και συγκρίνονται ώστε να βρεθεί το καλύτερο μοντέλο, με το χαμηλότερο μέσο τετραγωνικό σφάλμα (MSE). Έπειτα, το καλύτερο χρησιμοποιείται για πρόβλεψη της κατανάλωσης ηλεκτρικής ενέργειας, του λιμένα, για το 2030. Τέλος, αναπτύσσονται τα συμπεράσματα της έρευνας και συντάσσονται προτάσεις για μελλοντικές μελέτες (**Σχήμα 5**).



Σχήμα 6. Διάγραμμα ροής δημιουργίας μοντέλων.

Ο λόγος που τα δεδομένα χωρίστηκαν σε αυτές τις τρεις κατηγορίες είναι πως με τα μηνιαία δεδομένα υπάρχει η δυνατότητα σύγκρισης των μοντέλων μηχανικής μάθησης και των νευρωνικών δικτύων και με τα κλασσικά στατιστικά μοντέλα χρονοσειρών, πέραν μόνον με το μοντέλο της γραμμικής παλινδρόμησης. Επίσης, επειδή τα μοντέλα NN και ML έχουν καλύτερη απόδοση όταν υπάρχει και μεγαλύτερη βάση δεδομένων, χρησιμοποιούνται τα ωριαία και ημερήσια δεδομένα, τα οποία όμως είχαν αυξημένη υπολογιστική απαίτηση (Σχήμα 6).

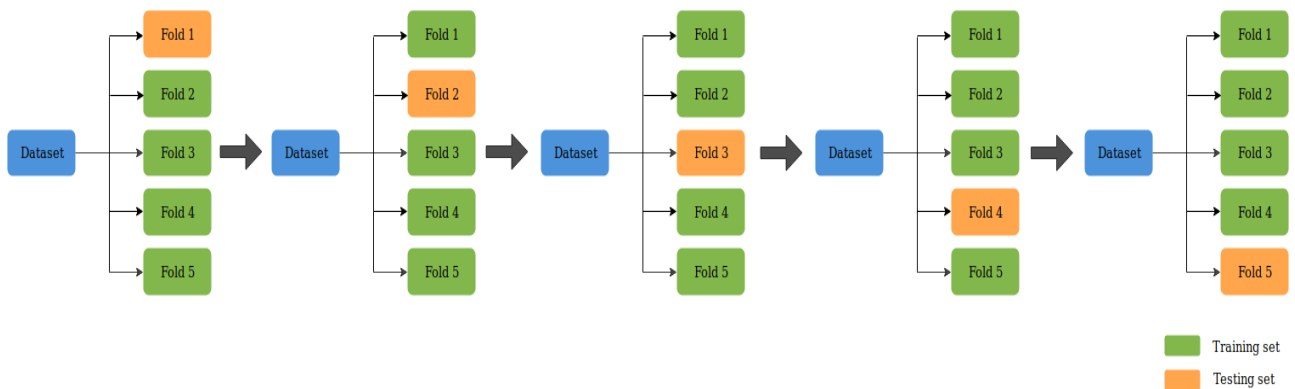
Τα μοντέλα γραμμικής παλινδρόμησης και διάσπασης χρονοσειρών αναπτύσσονται στην εφαρμογή **Minitab**, η οποία παρέχει μια αρκετά φιλική και εύκολα κατανοητή προς νέους χρήστες διεπιφάνεια σε σχέση με άλλες στατιστικές εφαρμογές. Αντιθέτως, το μοντέλο ARIMA λόγω πολυπλοκότητας στην εύρεση των σωστών παραμέτρων p, d και q καθώς και το αν είναι εποχικό ή όχι, χρησιμοποιείται η συνάρτηση **auto.arima()** [73], που υπάρχει στην βιβλιοθήκη **forecast** [74] της γλώσσας προγραμματισμού R, και δημιουργείται στο περιβάλλον της εφαρμογής **R-studio**. Τέλος, τα μοντέλα μηχανικής μάθησης καθώς και τα νευρωνικά δίκτυα αναπτύσσονται στο περιβάλλον εργασίας της **MATLAB®**, στο οποίο υπάρχουν εφαρμογές κατάλληλες για την δημιουργία των προαναφερθέντων μοντέλων (*Regression Learner App* και *Neural Net Fitting App*) (Εικόνα 16, Εικόνα 17, Εικόνα 18, Εικόνα 19).

Στην **MATLAB®** υπάρχει η δυνατότητα ανάπτυξης των εκατέρωθεν αλγορίθμων μηχανικής μάθησης:

- Linear Regression
- Interactions Linear Regression
- Robust Linear Regression
- Stepwise Linear Regression
- Fine Tree
- Medium Tree
- Coarse Tree
- Optimizable Tree
- Linear SVM
- Quadratic SVM
- Cubic SVM
- Fine Gaussian SVM
- Medium Gaussian SVM
- Coarse Gaussian SVM
- Optimizable SVM
- Boosted Trees
- Bagged Trees
- Optimizable Ensemble
- Squared Exponential GPR
- Mattern 5/2 GPR
- Exponential GPR
- Rational Quadratic GPR
- Optimizable GPR

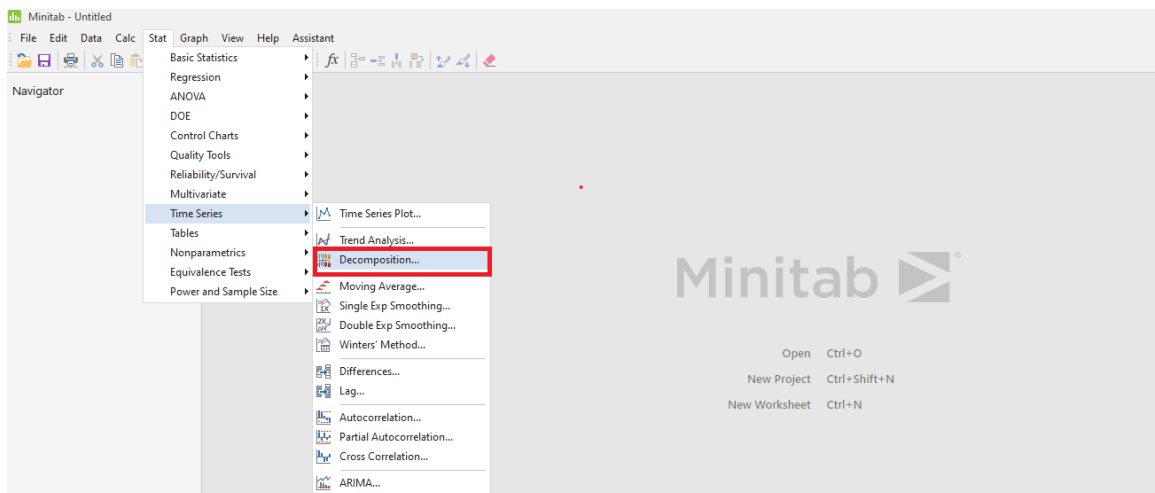
, όλοι οι παραπάνω χρησιμοποιούνται και επιλέγεται ο καλύτερος. Ως μέθοδος εκπαίδευσης και δοκιμής επιλέγεται η ομαδοποίηση των δεδομένων σε k -fold τμήματα τα (k -fold cross-validation) οποία σε όλα γίνεται εκπαίδευση και δοκιμή (Εικόνα 15). Συνήθως χρησιμοποιούνται τιμές $k = 5$ ή 10 (five-fold ή ten-fold). Καθώς στα ωριαία και ημερήσια δεδομένα το υπολογιστικό φόρτο ήταν πολύ υψηλό για τον υπολογιστή, και για αποφυγή τυχών ζημιών στο σύστημα, η λογική δημιουργίας του μοντέλου ήταν η δοκιμή σε 5-fold και

σε περίπτωση αποτυχίας η δοκιμή σε 10-fold

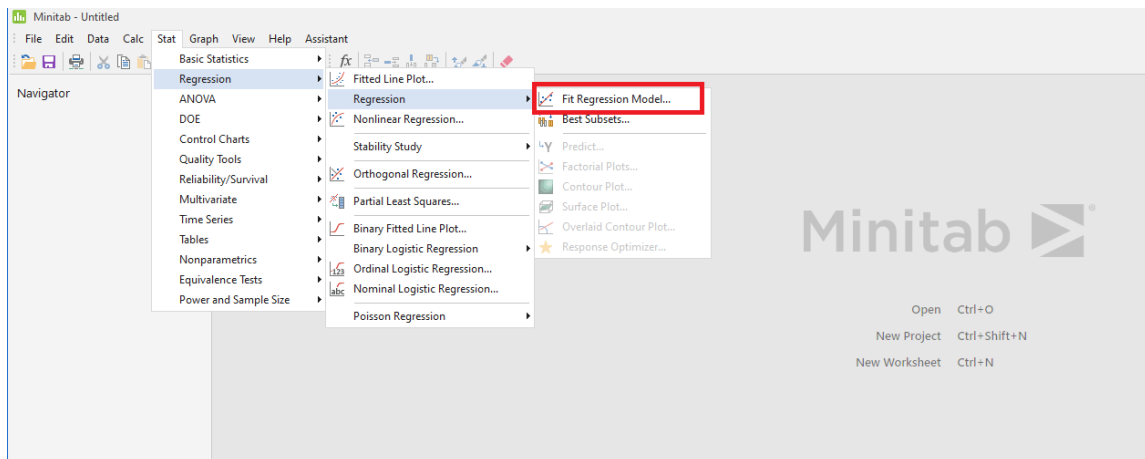


Εικόνα 15. Παράδειγμα 5-fold cross-validation [75].


Για τα νευρωνικά δίκτυα ως αλγόριθμος μάθησης επιλέγεται ο Levenberg-Marquardt (trainlm), ένας συνδυασμός της κλίσης κατάβασης (gradient descent) και των μεθόδων του Newton για την επίλυση προβλημάτων βελτιστοποίησης [76]. Ο αλγόριθμος παρέχει μια ακριβή προσαρμογή βάρους με μέτρια κατανάλωση χρόνου και έχει αρκετά αποτελεσματική εκτέλεση στην **MATLAB®**. Επιπλέον, η εφαρμογή *Neural Net Fitting App* δίνει την δυνατότητα δημιουργίας τεχνητών νευρωνικών δικτύων με ένα κρυφό επίπεδο με εξίσωση μεταφοράς tan-sigmoid (tansig), με τον αριθμό των νευρώνων στην επιλογή του πειραματιστή, και ένα επίπεδο εξόδου με εξίσωση μεταφοράς pure-linear (purelin) και ένα νευρώνα. Στα πλαίσια της διπλωματικής εργασίας τα νευρωνικά δίκτυα που δημιουργήθηκαν κινήθηκαν μέσα σε αυτούς τους περιορισμούς.



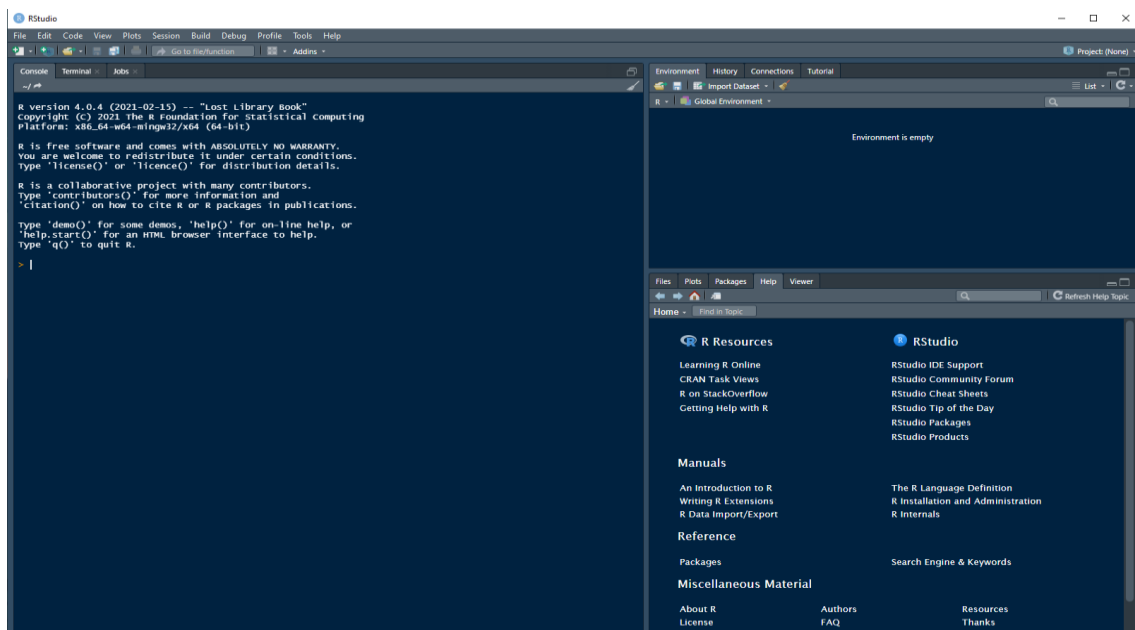
Εικόνα 16. Μεθόδοι στην εφαρμογή Minitab που χρησιμοποιήθηκαν I.



Εικόνα 17. Μέθοδοι στην εφαρμογή Minitab που χρησιμοποιήθηκαν II.



Εικόνα 18. Εφαρμογές στο περιβάλλον της MATLAB που χρησιμοποιήθηκαν.



Εικόνα 19. Περιβάλλον εφαρμογής R-studio.

3.4. Δείκτες σύγκρισης μοντέλων

Για κάθε μοντέλο γίνεται εκπαίδευση πάνω στα δεδομένα από το 2015 έως το 2019. Στην συνέχεια, σε κάθε μοντέλο δοκιμάζεται η ακρίβεια της τιμής ηλεκτρικής ενέργειας που προβλέπει το κάθε μοντέλο για την ίδια χρονική περίοδο και ελέγχεται κατά πόσο αποκλίνουν από τις πραγματικές τιμές. Τέλος, τα μοντέλα χρησιμοποιούνται για την πρόβλεψη της ηλεκτρικής ενέργειας, του λιμένα, για το 2030.

Ως δείκτες σύγκρισης των μοντέλων για την ικανότητα σε πρόβλεψη, σύμφωνα και τα με πραγματικά δεδομένα, επιλέγονται οι εκατέρωθεν:

- **Μέσο τετραγωνικό σφάλμα (Mean Squared Error – MSE):**

Το μέσο τετραγωνικό σφάλμα (MSE) ενός εκτιμητή μετρά τον μέσο όρο των σφαλμάτων, δηλαδή τη μέση τετραγωνική διαφορά μεταξύ των εκτιμώμενων τιμών της πραγματικής τιμής. Είναι ένα μέτρο ποιότητας ενός εκτιμητή και παίρνει πάντα μη αρνητικές τιμές, με αυτές που πλησιάζουν το μηδέν να είναι οι καλύτερες. Για ένα διάνυσμα προβλέψεων \hat{Y} που δημιουργείται από ένα δείγμα σημείων Y δεδομένων σε όλες τις μεταβλητές και Y είναι το διάνυσμα των παρατηρούμενων τιμών της μεταβλητής που προβλέπεται, με το \hat{Y} να είναι οι προβλεπόμενες τιμές, το MSE υπολογίζεται ως:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (17)$$

- **Ρίζα μέσου τετραγωνικού σφάλματος (Root Mean Squared Error – RMSE):**

Το RMSE είναι ουσιαστικά η ρίζα του MSE και ο λόγος που χρησιμοποιείται είναι γιατί λόγω της ρίζας αποκτά τις ίδιες μονάδες μέτρησης με την ποσότητα που εκτιμάται. Υπολογίζεται ως:

$$RMSE = \sqrt{MSE} \quad (18)$$

4. Αποτελέσματα

Τα μοντέλα πρώτα δημιουργήθηκαν με βάση δεδομένα από το 2015-2019, υπολογίζονται οι δείκτες MSE και RMSE, ώστε να γίνει σύγκριση των μοντέλων. Στην συνέχεια το καλύτερο από αυτά χρησιμοποιείται για να βρεθεί το προφίλ της κατανάλωσης ηλεκτρικής ενέργειας του λιμένα Σούδας για το έτος 2030. Τέλος, παρουσιάζονται και οι ετήσιες προβλέψεις όλων των μοντέλων.

4.1. Παρουσίαση μοντέλων

4.1.1. Ωριαία δεδομένα

Αρχικά παρατίθενται τα αποτελέσματα των μοντέλων γραμμικής παλινδρόμησης (LR), των τεχνητών νευρωνικών δικτύων (ANN) και των αλγορίθμων μηχανικής μάθησης (ML), βασιζόμενα σε ωριαία μετεωρολογικά και ενεργειακά δεδομένα.

4.1.1.1. Ωριαίο Μοντέλο Γραμμικής Παλινδρόμησης - Hourly Linear Regression Model (H-LR)

Η εξίσωση που προκύπτει από το μοντέλο γραμμικής παλινδρόμησης είναι:

$$Y = 175,2 + 0,000759 \cdot X_1 + 0,175 \cdot X_2 + 0,9159 \cdot X_3 + 0,2378 \cdot X_4 - 1,1737 \cdot X_5 + 0,1313 \cdot X_6 - 6,20 \cdot X_7 - 0,1348 \cdot X_8 - 0,079385 \cdot X_9 \quad (19)$$

Πίνακας 6. Όροι εξίσωσης (19).

Όροι	Δεδομένα
Y	Ηλεκτρική Ενέργεια (kWh)
X ₁	Χρονικό Βήμα
X ₂	Ώρα
X ₃	Θερμοκρασία (°C)
X ₄	Υγρασία (%)
X ₅	Σημείο Δρόσου (°C)
X ₆	Πίεση (hPa)
X ₇	Κατακρήμνιση (mm)
X ₈	Ταχύτητα Ανέμου (km/h)
X ₉	Ηλιακή Ακτινοβολία (W/m ²)

Επιπλέον από την εφαρμογή εξάγονται και οι απαραίτητοι δείκτες για την αξιολόγηση του μοντέλου:

Πίνακας 7. Ανάλυση συντελεστών εξίσωσης (19).

Όροι	P-value
Regression	0,000
X ₁	0,000
X ₂	0,000
X ₃	0,000
X ₄	0,000
X ₅	0,000
X ₆	0,000
X ₇	0,000
X ₈	0,000
X ₉	0,000

Από τον **Πίνακα 7** παρατηρείται ότι η αρχική υπόθεση (Regression) έχει στατιστική σημασία καθώς έχει $P\text{-value} < 0,05$, επιπλέον όλοι οι όροι έχουν τιμές $P\text{-value} < 0,05$ πράγμα που δείχνει ότι αυτές οι μεταβλητές έχουν στατιστικά σημαντικό συσχετισμό με την μεταβλητή απόκρισης. Επιπλέον, τηρούνται οι προϋποθέσεις για γραμμική παλινδρόμηση καθώς ο συντελεστής **Darbin – Watson** = **0,38** < **4** .

Πίνακας 8. Pairwise Pearson Correlations


Sample	Correlation	95 % CI for p	P-Value
X ₁	0,272	(0,264; 0,281)	0,000
X ₂	-0,571	(-0,577; -0,565)	0,000
X ₃	-0,312	(-0,321; -0,304)	0,000
X ₄	0,316	(0,308; 0,325)	0,000
X ₅	-0,172	(-0,181; -0,163)	0,000
X ₆	0,014	(0,004; 0,023)	0,004
X ₇	0,035	(0,025; 0,044)	0,000
X ₈	-0,224	(-0,233; -0,215)	0,000
X ₉	-0,45	(-0,457; -0,442)	0,000

Στον **Πίνακα 8** φαίνονται οι συσχετίσεις των μεταβλητών σε σχέση με την μεταβλητή πρόβλεψης. Μεγαλύτερη συσχέτιση έχει η μεταβλητή X₉ (Ηλιακή Ακτινοβολία) καθώς η κύρια πηγή κατανάλωσης ηλεκτρικής ενέργειας, στο λιμάνι της Σούδας, αποτελεί ο φωτισμός του λιμανιού, ο οποίος λειτουργεί τις νυχτερινές ώρες όπου η ηλιακή ακτινοβολία είναι μηδενική. Θερμοκρασία και υγρασία (X₃, X₄) συνδέονται με την ώρα και την εποχικότητα – οι υψηλές θερμοκρασίες και χαμηλές τιμές υγρασίας εμφανίζονται τους θερινούς μήνες και την ημέρα, όπου είναι μεγαλύτερη διάρκεια ημέρας, άρα λιγότερη ώρα χρήσης φωτισμού, με το ανάποδο να συμβαίνει τους χειμερινούς μήνες – οι μικρότερες θερμοκρασίες και μεγαλύτερες τιμές υγρασίας εμφανίζονται τους χειμερινούς μήνες και την νύχτα, όπου η διάρκεια της ημέρας είναι μικρότερη, άρα περισσότερη χρήση φωτισμού. Η συσχέτιση της ταχύτητας του ανέμου (X₈) μπορεί να εξηγηθεί πως με μεγάλες τιμές ανέμου δεν ταξιδεύουν τα πλοία άρα λιγότερη κίνηση στο λιμάνι. Αντιθέτως πολύ μικρή συσχέτιση έχουν οι πίεση και κατακρήμνιση (X₆, X₇) καθώς δεν επηρεάζουν ιδιαίτερα την λειτουργία του εξωτερικού φωτισμού του λιμανιού.

Για περεταίρω διερεύνηση της παραπάνω παρατήρησης, δημιουργείται μια μεταβλητή σχετικά με το αν είναι ημέρα ή νύχτα (TimeOfDay) βασιζόμενο στην ώρα – από 7:00 π.μ. έως 6:00 μ.μ. θεωρείται ημέρα και από 7:00 μ.μ. έως και 6:00 π.μ. θεωρείται νύχτα. Μέσω One-way ANOVA ανάλυσης (Analysis Of Variance) εξερευνάται περισσότερο η σχέση που έχει το γεγονός αν είναι ημέρα ή νύχτα στην κατανάλωση ηλεκτρικής ενέργειας στο λιμάνι της Σούδας. Από την ANOVA προκύπτει υψηλό F-value, όπως φαίνεται και στον **Πίνακα 9**, άρα υπάρχει σημαντική διαφορά μεταξύ ημέρας και νύχτας, οι οποίες, επιπλέον, χωρίζονται σε δύο κατηγορίες A και B σύμφωνα με την σύγκριση ζευγών του Tukey. Τέλος στο **Διάγραμμα 10** φαίνονται οι μέσες τιμές των μεταβλητών ημέρας και νύχτας ($M_d = 35,83$ και $M_n = 91,09$) για διάστημα εμπιστοσύνης 95%.


Πίνακας 9. Ανάλυση διακύμανσης.

TimeOfDay	N	Mean	Grouping
Night	21.900	91,09	A
Day	21.900	35,83	B
	F-Value	P-value	
TimeOfDay	71.494	0,000	



Διάγραμμα 10. 95% διάστημα εμπιστοσύνης για τη διαφορά μεταξύ των μέσων.

Το ωριαίο μοντέλο γραμμικής παλινδρόμησης (**H-LR**) έχει συντελεστή προσδιορισμού $R^2 = 0,45$ και συγκρίνοντάς το με τα πραγματικά δεδομένα προκύπτει μέσο τετραγωνικό σφάλμα $MSE = 680,08 \text{ kWh}^2$ και ρίζα μέσου τετραγωνικού σφάλματος $RMSE = 26,08 \text{ kWh}$.



Διάγραμμα 11. Υπολείμματα (residuals) μοντέλου H-LR.


Στο **Διάγραμμα 11** αποτυπώνεται η διακύμανση των σφαλμάτων ($Residuals = Observed -$

Predicted) του μοντέλου H-LR. Τα σφάλματα του μοντέλου έχουν μεγάλο εύρος, -50 kWh έως 50 kWh, πράγμα που δηλώνει πως το μοντέλο δεν προσαρμόζεται καλά στα δεδομένα.

Πίνακας 10. Διακύμανση ωριαίας κατανάλωσης ηλεκτρικής ενέργειας (kWh) μοντέλου H-LR.

	Ελάχιστη	Μέση	Μέγιστη
2015	-23,61	49,87	74,92
2016	-26,63	56,53	80,02
2017	3,33	63,83	114,86
2018	5,08	70,23	94,02
2019	14,95	77,05	99,26

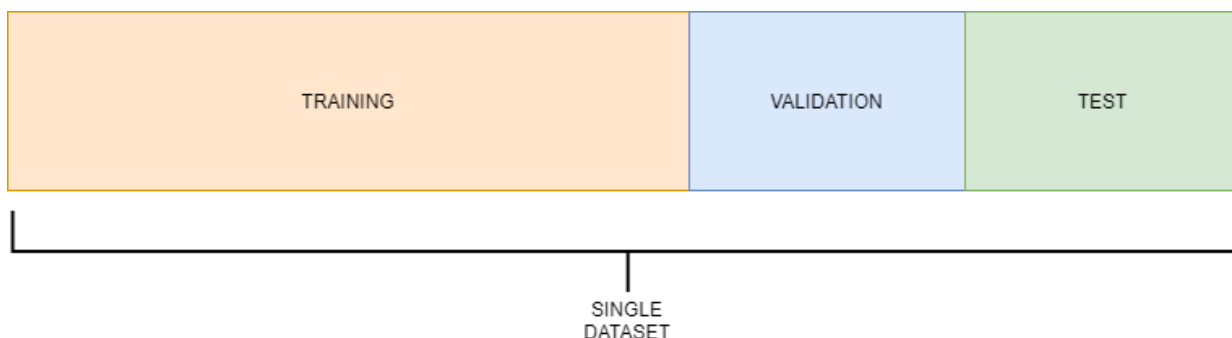
Στο **Διάγραμμα 12** φαίνεται το μέσο ωριαίο προφίλ απαίτησης ηλεκτρικής ισχύος σύμφωνα με το δημιουργούμενο μοντέλο H-LR για τα έτη 2015-2019. Σε συνδυασμό με τον **Πίνακα 10** δύναται μια πλήρη εικόνα της προβλεπτικής ικανότητας του μοντέλου, όπου παρατηρείται πως το μοντέλο παρουσιάζει αρνητικές τιμές κατανάλωσης ηλεκτρικής ενέργειας, πράγμα το οποίο είναι λάθος. Το γεγονός αυτό οφείλεται στο χαμηλό R^2 , το οποίο με τιμή 0,45 υποδηλώνει πως το μοντέλο υπολογίζει σωστά μόνο το 45% των προβλέψεων και καθώς πρόκειται για ωριαίες τιμές κατανάλωσης ενέργειας, που είναι σχετικά χαμηλές, είναι δυνατόν να εμφανίζονται αυτές οι αρνητικές τιμές.



4.1.1.2. Ωριαίο Μοντέλο Τεχνητών Νευρωνικών Δικτύων – Hourly Artificial Neural Network Model (H-ANN)


Καθώς δεν υπάρχει ακριβής μέθοδος για την δημιουργία των τεχνητών νευρωνικών δικτύων, αριθμός κρυφών επιπέδων, αριθμός νευρώνων στο κρυφό επίπεδο, μέσω δοκιμών και σφαλμάτων και των περιορισμών της εφαρμογής *Neural Net Fitting App*, βρέθηκε το καλύτερο μοντέλο με βάση τα υπάρχοντα δεδομένα. Τα δεδομένα χωρίστηκαν τυχαία (dividerand) ως εξής (**Σχήμα 7**):

- 70% για εκπαίδευση (training)
- 15% για επικύρωση (validation)
- 15% για δοκιμή (test)



Σχήμα 7. Διαχωρισμός δεδομένων για εκπαίδευση, επικύρωση και δοκιμή.

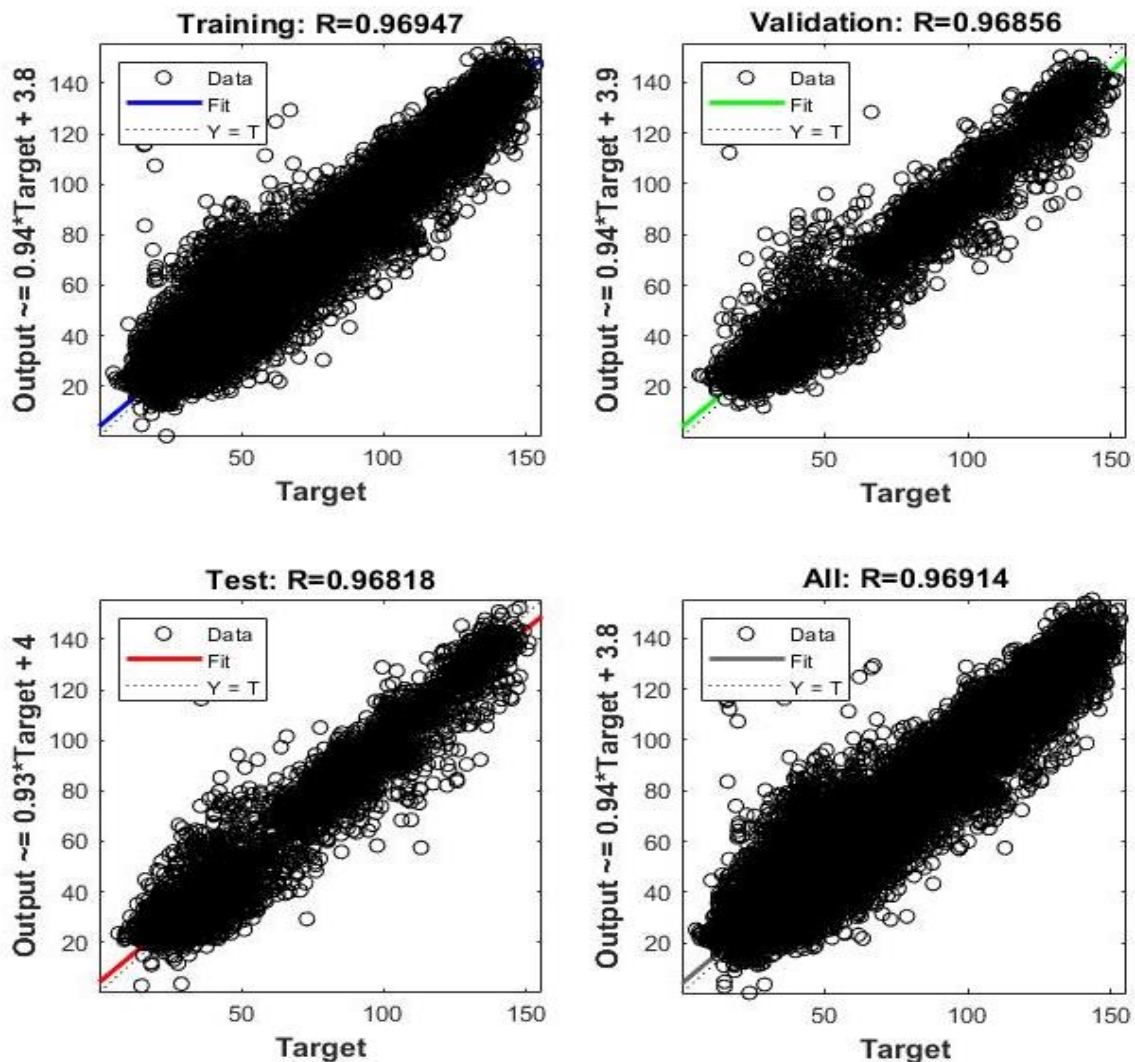
Ως αλγόριθμος μάθησης επιλέγεται ο Levenberg-Marquardt (*trainlm*), ένα κρυφό επίπεδο με εξίσωση μεταφοράς tan-sigmoid (*tansig*) με 27 νευρώνες και ένα επίπεδο εξόδου με εξίσωση μεταφοράς pure-linear (*purelin*) και 1 νευρώνα (**Σχήμα 8**).



Σχήμα 8. Μορφή μοντέλου H-ANN.


Πίνακας 11. Αποτελέσματα μοντέλου H-ANN.

	MSE	R	R ²
Training	73,89	0,97	0,94
Validation	77,55	0,97	0,94
Testing	76,47	0,97	0,94
Gradient = 1,53 at 220 epochs			
Mu = 0,001			



Εικόνα 20. Διαγράμματα παλινδρόμησης του μοντέλου H-ANN για όλα τα στάδια.

Στην **Εικόνα 20** παρουσιάζονται οι συντελεστές συσχέτισης των επί μέρους σταδίων της δημιουργίας του ωριαίου μοντέλου TNN – εκπαίδευση, επικύρωση, δοκιμή και το συνολικό. Σε συνδυασμό και με τον **Πίνακα 11** το μοντέλο προσαρμόζεται ικανοποιητικά στα δεδομένα, έχει συντελεστή προσδιορισμού $R^2 = 0,94$, και προβλέπει την κατανάλωση ηλεκτρικής ενέργειας με μέσο τετραγωνικό σφάλμα $MSE = 74,83 \text{ kWh}^2$, ρίζα μέσου τετραγωνικού σφάλματος $RMSE = 8,65 \text{ kWh}$ και κλίση κατάβασης (gradient descent) 1,53, τα οποία επιτυγχάνονται στους 220 κύκλους επαναλήψεων (epoch). Επιπλέον, στο **Διάγραμμα 13** φαίνονται οι διακυμάνσεις των σφαλμάτων του μοντέλου H-ANN. Τα σφάλματα κυμαίνονται κυρίως σταθερά γύρω από το μηδέν στις -40 έως 40 kWh.




Διάγραμμα 13. Διακύμανση σφαλμάτων μοντέλου H-ANN

Πίνακας 12. Διακύμανση ωριαίας κατανάλωσης ηλεκτρικής ενέργειας (kWh) μοντέλου H-ANN.

	Ελάχιστη	Μέση	Μέγιστη
2015	2,72	49,24	100,18
2016	0,18	57,05	113,36
2017	20,08	61,47	118,20
2018	16,79	72,83	146,83
2019	3,47	75,98	155,23

Στο **Διάγραμμα 14** αποτυπώνεται το μέσο ωριαίο προφίλ απαίτησης ηλεκτρικής ισχύος σύμφωνα με το δημιουργούμενο μοντέλο H-ANN για την πενταετία 2015-2019, όπου φαίνεται πως ακολουθεί την πραγματικότητα – χαμηλές απαιτήσεις την ημέρα και υψηλές την νύχτα. Τέλος, στον **Πίνακας 12** δύναται μια πλήρη εικόνα της προβλεπτικής ικανότητας του μοντέλου για την πενταετία 2015-2019. Επίσης το μοντέλο ακολουθεί την αυξητική τάση της κατανάλωσης ηλεκτρικής ενέργειας.



Διάγραμμα 14. Μέσο ωριαίο προφίλ απαίτησης ηλεκτρικής ισχύος μοντέλου H-ANN.

4.1.1.3. Ωριαίο Μοντέλο Μηχανικής Μάθησης – Hourly Machine Learning Model (H-ML)

Στα ωριαία δεδομένα η δοκιμή σε 5-fold ήταν αρκετά ικανοποιητική, οπότε δεν έγινε δοκιμή σε 10-fold. Επίσης λόγω υψηλού υπολογιστικού φόρτου δεν μπόρεσαν να χρησιμοποιηθούν οι αλγόριθμοι Optimizable SVM και Optimizable GPR. Τα αποτελέσματα των αλγορίθμων που χρησιμοποιήθηκαν συνοψίζονται στον **Πίνακα 13** οι δέκα καλύτεροι με βάση την ρίζα του μέσου τετραγωνικού σφάλματος.

Πίνακας 13. Αποτελέσματα αλγορίθμων μηχανικής μάθησης για ωριαία δεδομένα.


Αλγόριθμος Μηχανικής Μάθησης	RMSE
Exponential GPR	2,21
Optimizable Ensemble	3,00
Optimizable Tree	3,23
Fine Tree	3,23
Medium Tree	4,89
Bagged Trees	5,20
Coarse Tree	6,82
Fine Gaussian SVM	6,91
Mattern 5/2 GPR	9,38
Rational Quadratic GPR	9,40

Από τους παραπάνω καλύτερη απόδοση, σύμφωνα με τον δείκτη RMSE για ωριαία δεδομένα είχε η μέθοδος **Exponential GPR**.


Το ωριαίο μοντέλο μηχανικής μάθησης (**H-ML**) έχει συντελεστή προσδιορισμού $R^2 = 0,99$, μέσο τετραγωνικό σφάλμα $MSE = 4,86 \text{ kWh}^2$ και ρίζα μέσου τετραγωνικού σφάλματος $RMSE = 2,21 \text{ kWh}$. Σύμφωνα με την **Εικόνα 21** το μοντέλο H-ML προσαρμόζεται αρκετά καλά στα δεδομένα και στο **Διάγραμμα 16** αποτυπώνεται το μέσο ωριαίο προφίλ απαίτησης ηλεκτρικής ισχύος του μοντέλου για τα την πενταετία 2015-2019, όπου φαίνεται να είναι αρκετά κοντά στην πραγματικότητα. Στον **Πίνακα 14** φαίνονται οι διακυμάνσεις των τιμών που προβλέπει το μοντέλο για την πενταετία και παρατηρείται ότι ακολουθεί την αυξητική τάση της κατανάλωσης ενέργειας. Τέλος, στο **Διάγραμμα 15** παρουσιάζονται οι διακυμάνσεις των σφαλμάτων του μοντέλου οι περισσότερες των οποίων είναι σταθερές γύρω από το μηδέν και κυμαίνονται μεταξύ -10 έως 10 kWh.

Πίνακας 14. Διακύμανση ωριαίας κατανάλωσης ηλεκτρικής ενέργειας (kWh) μοντέλου H-ML..


	Ελάχιστη	Μέση	Μέγιστη
2015	6,56	49,53	109,85
2016	13,41	56,55	122,87
2017	16,51	61,68	118,32
2018	14,71	73,29	150,17
2019	12,73	76,25	152,48



Εικόνα 21. Διάγραμμα παλινδρόμησης για το μοντέλο H-ML.



Διάγραμμα 15. Διακύμανση σφαλμάτων μοντέλου H-ML.



Διάγραμμα 16. Μέσο ωριαίο προφίλ απαίτησης ηλεκτρικής ισχύος μοντέλου H-ML.

4.1.2. Ημερήσια δεδομένα

Έπειτα παρατίθενται τα αποτελέσματα των μοντέλων γραμμικής παλινδρόμησης (LR), τεχνητών νευρωνικών δικτύων (ANN) και μοντέλων μηχανικής μάθησης (ML), βασιζόμενα σε ημερήσια μετεωρολογικά και ενεργειακά δεδομένα. Στα δεδομένα επιπλέον προστίθεται σαν μεταβλητή ο μήνας.

4.1.2.1. Ημερήσιο Μοντέλο Γραμμικής Παλινδρόμησης – Daily Linear Regression Model (D-LR)

Η εξίσωση που προκύπτει από το μοντέλο γραμμικής παλινδρόμησης είναι:

$$Y = 755 + 0,019226 \cdot X_1 - 0,128 \cdot X_2 + 9,6 \cdot X_3 - 2,0 \cdot X_4 + 0,43 \cdot X_5 - 11,5 \cdot X_6 + 0,63 \cdot X_7 + 419 \cdot X_8 + 0,30 \cdot X_9 - 0,6335 \cdot X_{10} \quad (20)$$

Πίνακας 15. Όροι εξίσωσης (20).

Όροι	Δεδομένα
Y	Ηλεκτρική Ενέργεια (kWh)
X ₁	Χρονικό Βήμα
X ₂	Ημέρα
X ₃	Μήνας
X ₄	Θερμοκρασία (°C)
X ₅	Υγρασία (%)
X ₆	Σημείο Δρόσου (°C)
X ₇	Πίεση (hPa)
X ₈	Κατακρήμνιση (mm)
X ₉	Ταχύτητα Ανέμου (km/h)
X ₁₀	Ηλιακή Ακτινοβολία (W/m ²)

Επιπλέον από την εφαρμογή εξάγονται και οι απαραίτητοι δείκτες για την αξιολόγηση του μοντέλου:


Πίνακας 16. Ανάλυση συντελεστών εξίσωσης (20).

Όροι	P-value
Regression	0,000
X ₁	0,000
X ₂	0,798
X ₃	0,848
X ₄	0,851
X ₅	0,884
X ₆	0,316
X ₇	0,550
X ₈	0,000
X ₉	0,799
X ₁₀	0,000

Από τον **Πίνακας 16** παρατηρείται ότι η αρχική υπόθεση (Regression) έχει στατιστική σημασία καθώς έχει P-value < 0,05. Επιπλέον οι όροι χρονικό βήμα (X₁), κατακρήμνιση (X₈) και ηλιακή ακτινοβολία (X₁₀) έχουν τιμές P-value < 0,05 πράγμα που δείχνει ότι αυτές οι μεταβλητές έχουν στατιστικά σημαντικό συσχετισμό με την μεταβλητή απόκρισης. Όσον αναφορά τις υπόλοιπες μεταβλητές με P-value > 0,05 θα μπορούσαν να αφαιρεθούν χωρίς να επηρεάσουν σημαντικά το μοντέλο καθώς φαίνεται πως εξαρτώνται-συσχετίζονται με άλλη ή άλλες υπάρχουσες μεταβλητές. Επιπλέον, τηρούνται οι προϋποθέσεις για γραμμική παλινδρόμηση καθώς ο συντελεστής **Darbin – Watson = 0,26 < 4**.

Το ημερήσιο μοντέλο γραμμικής παλινδρόμησης (**D-LR**) έχει συντελεστή προσδιορισμού


$R^2 = 0,67$, μέσο τετραγωνικό σφάλμα $MSE = 34.987,57 \text{ kWh}^2$ και ρίζα μέσου τετραγωνικού σφάλματος $RMSE = 187,05 \text{ kWh}$. Από τον **Πίνακα 17** λαμβάνεται η διακύμανση των τιμών κατανάλωσης ενέργειας του μοντέλου, όπου φαίνεται πως ακολουθεί την αυξητική τάση της κατανάλωσης ενέργειας. Στο **Διάγραμμα 17** λαμβάνεται το προφίλ του μοντέλου σε σύγκριση με το πραγματικό από το οποίο παρατηρείται πως το μοντέλο δεν προσαρμόζεται ικανοποιητικά στα δεδομένα. Τέλος, στο **Διάγραμμα 18** φαίνεται η διακύμανση των σφαλμάτων του μοντέλου D-LR. Τα σφάλματα κυμαίνονται περίπου σταθερά γύρω από το μηδέν, με τιμές -500 έως 500 kWh.



Διάγραμμα 17. Ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου D-LR σε σύγκριση με το πραγματικό.

Πίνακας 17. Διακύμανση ημερήσιας κατανάλωσης ηλεκτρικής ενέργειας (kWh) μοντέλου D-LR.

	Ελάχιστη	Μέση	Μέγιστη
2015	686,31	1.186,79	1.529,42
2016	1.173,61	1.354,06	1.812,72
2017	1.332,77	1.533,09	1.839,69
2018	1.503,88	1.686,04	2.029,65
2019	1.619,04	1.861,50	2.305,87




Διάγραμμα 18. Διακύμανση σφαλμάτων μοντέλου D-LR.

4.1.2.2. Ημερήσιο Μοντέλο Τεχνητών Νευρωνικών Δικτύων – Daily Artificial Neural Network Model (D-ANN)

Στο μοντέλο D-ANN τα δεδομένα χωρίστηκαν τυχαία (dividerand) ως εξής:

- 70% για εκπαίδευση (training)
- 15% για επικύρωση (validation)
- 15% για δοκιμή (test)

Ως αλγόριθμος μάθησης επιλέγεται ο Levenberg-Marquardt (trainlm), ένα κρυφό επίπεδο με εξίσωση μεταφοράς tan-sigmoid (tansig) με 11 νευρώνες και ένα επίπεδο εξόδου με εξίσωση μεταφοράς pure-linear (purelin) και 1 νευρώνα (**Σχήμα 9**).



Σχήμα 9. Μορφή μοντέλου D-ANN.

Πίνακας 18. Αποτελέσματα μοντέλου D-ANN.

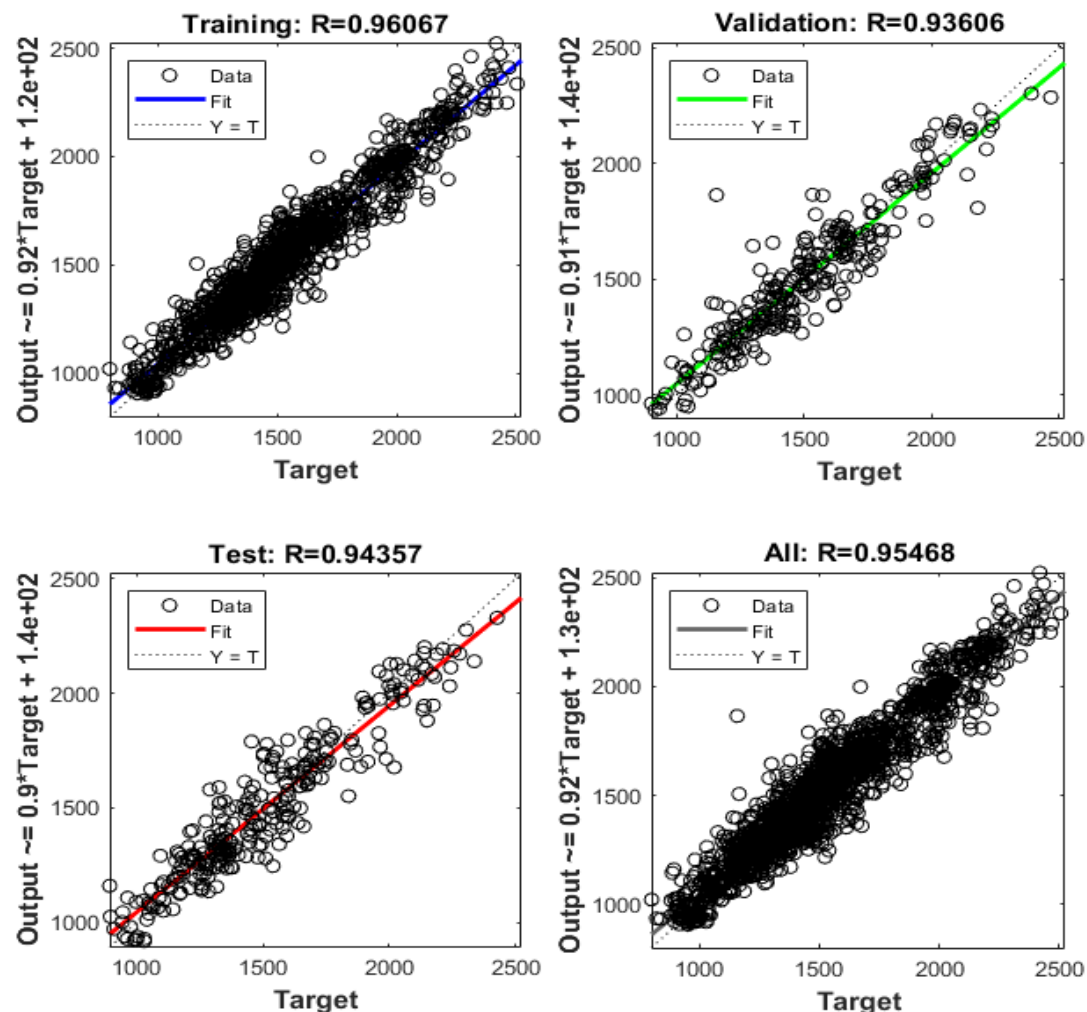
	MSE	R	R ²
Training	8.357,48	0,96	0,92
Validation	11.740,09	0,93	0,86
Testing	12.291,76	0,94	0,88
Gradient = 2,76e+03 at 33 epochs			
Mu = 10,0			

Στην **Εικόνα 22** παρουσιάζονται οι συντελεστές συσχέτισης των επί μέρους σταδίων της δημιουργίας του ημερήσιου μοντέλου TNN – εκπαίδευση, επικύρωση, δοκιμή και το συνολικό, και σε συνδυασμό και με τον **Πίνακα 18** το μοντέλο δείχνει να προσαρμόζεται


ικανοποιητικά στα δεδομένα. Το D-ANN έχει συντελεστή προσδιορισμού $R^2 = 0,90$, και προβλέπει την κατανάλωση ηλεκτρικής ενέργειας με μέσο τετραγωνικό σφάλμα $MSE = 9.456,02 \text{ kWh}^2$, ρίζα μέσου τετραγωνικού σφάλματος $RMSE = 97,24 \text{ kWh}$ και κλίση κατάβασης (gradient descent) $2,76e+03$, τα οποία επιτυγχάνονται στους 33 κύκλους επαναλήψεων (epoch). Επιπλέον, από **Πίνακας 19** λαμβάνεται η διακύμανση των τιμών κατανάλωσης ηλεκτρικής ενέργειας για το μοντέλο D-ANN, όπου φαίνεται να ακολουθεί την αυξητική τάση κατανάλωσης ενέργειας. Στο **Διάγραμμα 19** φαίνεται το προφίλ του μοντέλου έναντι του πραγματικού και παρατηρείται πως το μοντέλο ακολουθεί σε καλό βαθμό την πραγματικότητα. Τέλος, στο **Διάγραμμα 20** φαίνονται οι διακυμάνσεις των σφαλμάτων του μοντέλου D-ANN. Τα σφάλματα κυμαίνονται σχεδόν σταθερά γύρω από το μηδέν με τιμές από περίπου τις -300 έως 300 kWh.

Πίνακας 19. Διακύμανση ημερήσιας κατανάλωσης ηλεκτρικής ενέργειας (kWh) μοντέλου D-ANN.


	Ελάχιστη	Μέση	Μέγιστη
2015	906,01	1.189,98	1.838,95
2016	1.122,21	1.356,34	2.094,67
2017	1.116,08	1.477,98	2.169,93
2018	1.297,18	1.756,25	2.410,11
2019	1.535,68	1.832,94	2.522,08



Εικόνα 22. Διαγράμματα παλινδρόμησης του μοντέλου D-ANN για όλα τα στάδια.



Διάγραμμα 19. Ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου D-ANN σε σύγκριση με το πραγματικό.



Διάγραμμα 20. Υπολείμματα μοντέλου D-ANN.

4.1.2.3. Ημερήσιο Μοντέλο Μηχανικής Μάθησης – Daily Machine Learning Model (D-ML)

Στα ημερήσια δεδομένα το υπολογιστικό φόρτο ήταν αρκετά υψηλό για τον υπολογιστή, και για αποφυγή τυχών ζημιών στο σύστημα, η λογική δημιουργίας του μοντέλου ήταν η δοκιμή σε 5-fold και σε περίπτωση αποτυχίας η δοκιμή σε 10-fold. Στα ημερήσια δεδομένα η δοκιμή σε 5-fold ήταν αρκετά ικανοποιητική, οπότε δεν έγινε δοκιμή σε 10-fold

Τα αποτελέσματα των αλγορίθμων που χρησιμοποιήθηκαν συνοψίζονται στον **Πίνακας 20** οι δέκα καλύτεροι με βάση την ρίζα του μέσου τετραγωνικού σφάλματος.

Πίνακας 20. Αποτελέσματα αλγορίθμων μηχανικής μάθησης για ημερήσια δεδομένα

Αλγόριθμος Μηχανικής Μάθησης	RMSE
Optimizable GPR	29,79
Optimizable Ensemble	85,06
Optimizable Tree	96,96
Medium Tree	97,712
Fine Tree	102,04
Bagged Trees	104,11
Coarse Tree	109,81
Boosted Trees	116,83
Rational Quadratic GPR	124,45
Exponential GPR	124,65

Από τους παραπάνω καλύτερη απόδοση, σύμφωνα με τον δείκτη RMSE για ημερήσια δεδομένα είχε η μέθοδος **Optimizable GPR** και τα χαρακτηριστικά φαίνονται στον **Πίνακας 21**.

Πίνακας 21. Χαρακτηριστικά μοντέλου D-ML.


Basis Function	Linear
Kernel Function	Noninotropic Exponential
Sigma	19,45
Kernel Scale	5.568,33
Signal Standard Deviation	231,06

Το ημερήσιο μοντέλο μηχανικής μάθησης (**D-ML**) έχει συντελεστή προσδιορισμού $R^2 = 0,99$, μέσο τετραγωνικό σφάλμα $MSE = 887,49 \text{ kWh}^2$ και ρίζα μέσου τετραγωνικού σφάλματος $RMSE = 29,79 \text{ kWh}$. Σύμφωνα με την **Εικόνα 23** το μοντέλο D-ML προσαρμόζεται αρκετά καλά στα δεδομένα και στο **Διάγραμμα 21** αποτυπώνεται το προφίλ του μοντέλου για τα την πενταετία 2015-2019, σε σύγκριση με το πραγματικό, και δείχνει πως το μοντέλο ακολουθεί αρκετά καλά τα πραγματικά. Στον **Πίνακας 22** φαίνονται οι διακυμάνσεις των τιμών που προβλέπει το μοντέλο για την πενταετία και παρατηρείται ότι ακολουθεί την αυξητική τάση της κατανάλωσης ενέργειας.


Τέλος, στο **Διάγραμμα 22**, παρουσιάζονται οι διακυμάνσεις των σφαλμάτων του μοντέλου οι οποίες είναι σταθερές γύρω από το μηδέν και κυμαίνονται μεταξύ -50 έως 50 kWh.

Πίνακας 22. Διακύμανση ημερήσιας κατανάλωσης ηλεκτρικής ενέργειας (kWh) μοντέλου D-ML.


	Ελάχιστη	Μέση	Μέγιστη
2015	854,45	1.189,61	1.655,44
2016	1.008,23	1.356,37	1.655,44
2017	1.122,03	1.481,32	2.080,32
2018	1.311,86	1.760,66	2.450,47
2019	1.481,03	1.827,50	2.439,35



Εικόνα 23. Διάγραμμα παλινδρόμησης για το μοντέλο D-ML.



Διάγραμμα 21. Ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου D-ML σε σύγκριση με το πραγματικό.



Διάγραμμα 22. Διακύμανση σφαλμάτων μοντέλου D-ML.

4.1.3. Μηνιαία δεδομένα

Παρατίθενται κατά σειρά τα μοντέλα γραμμικής παλινδρόμησης (LR), τεχνητών νευρωνικών δικτύων (ANN), μοντέλο μηχανικής μάθησης (ML), μέθοδος διάσπασης χρονοσειρών (Decomposition) και από την μέθοδο Box-Jenkins το μοντέλο ARIMA.

4.1.3.1. Μηνιαίο Μοντέλο Γραμμικής Παλινδρόμησης – Monthly Linear Regression Model (M-LR)

Η εξίσωση που προκύπτει από το μοντέλο γραμμικής παλινδρόμησης είναι:

$$Y = 307.413 + 0,5494 \cdot X_1 - 102 \cdot X_2 + 1.673 \cdot X_3 - 663 \cdot X_4 + 1.432 \cdot X_5 - 198 \cdot X_6 + 132.600 \cdot X_7 - 806 \cdot X_8 - 38,2 \cdot X_9 \quad (21)$$

Πίνακας 23. Όροι εξίσωσης (21).

Όροι	Δεδομένα
Y	Ηλεκτρική Ενέργεια (kWh)
X ₁	Χρονικό Βήμα
X ₂	Μήνας
X ₃	Θερμοκρασία (°C)
X ₄	Υγρασία (%)
X ₅	Σημείο Δρόσου (°C)
X ₆	Πίεση (hPa)
X ₇	Κατακρήμνιση (mm)
X ₈	Ταχύτητα Ανέμου (km/h)
X ₉	Ηλιακή Ακτινοβολία (W/m ²)


Επιπλέον από την εφαρμογή εξάγονται και οι απαραίτητοι δείκτες για την αξιολόγηση του μοντέλου:

Πίνακας 24. Ανάλυση συντελεστών εξίσωσης (21).

Όροι	P-value
Regression	0,000
X ₁	0,000
X ₂	0,762
X ₃	0,766
X ₄	0,661
X ₅	0,804
X ₆	0,620
X ₇	0,044
X ₈	0,138
X ₉	0,130

Από τον **Πίνακας 24** παρατηρείται ότι η αρχική υπόθεση (Regression) έχει στατιστική σημασία καθώς έχει P-value < 0,05. Επιπλέον, φαίνεται πως μόνο οι μεταβλητές του χρονικού βήματος (X₁) και κατακρήμνισης (X₇), με P-value < 0,05, δείχνουν να έχουν σημαντικό συσχετισμό με την μεταβλητή απόκρισης. Οι υπόλοιπες μεταβλητές με P-value > 0,05 πρέπει να εξαρτώνται-συσχετίζονται με άλλη ή άλλες υπάρχουσες μεταβλητές. Επιπλέον, τηρούνται οι προϋποθέσεις για γραμμική παλινδρόμηση καθώς ο συντελεστής **Darbin – Watson = 1,06 < 4**.


Το μηνιαίο μοντέλο γραμμικής παλινδρόμησης (**M-LR**) έχει συντελεστή προσδιορισμού **R² = 0,75**, μέσο τετραγωνικό σφάλμα **MSE = 22.474.064,04 kWh²** και ρίζα μέσου τετραγωνικού σφάλματος **RMSE = 4.740,68 kWh**. Από τον **Πίνακας 25** και η διακύμανση των τιμών κατανάλωσης ηλεκτρικής ενέργειας για το μοντέλο M-LR, όπου φαίνεται πως το μοντέλο ακολουθεί την αυξητική τάση της κατανάλωσης ενέργειας. Στο **Διάγραμμα 23** λαμβάνεται η εικόνα του μηνιαίου προφίλ σε σύγκριση με το πραγματικό και από το οποίο παρατηρήται ότι το μοντέλο δεν προσαρμόζεται ικανοποιητικά στα δεδομένα. Τέλος, στο **Διάγραμμα 24** φαίνονται οι διακυμάνσεις των σφαλμάτων του μοντέλου M-LR. Τα σφάλματα κυμαίνονται μεταξύ περίπου -5.000 έως 5.000 kWh αλλά αρχίζουν να αυξάνονται στις -10.000 έως 10.000 kWh σε βάθος χρόνου.



Διάγραμμα 23. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου M-LR σε σύγκριση με το πραγματικό.

Πίνακας 25. Διακύμανση τιμών ηλεκτρικής ενέργειας (kWh) μοντέλου M-LR.

	Ελάχιστη	Μέση	Μέγιστη
2015	32.169,17	36.617,67	42.568,29
2016	37.106,01	41.310,77	49.381,31
2017	43.243,34	47.126,69	53.027,96
2018	45.010,67	50.408,82	57.316,71
2019	51.280,41	57.593,32	66.443,56




Διάγραμμα 24. Διακύμανση σφαλμάτων μοντέλου M-LR.

4.1.3.2. Μηνιαίο Μοντέλο Τεχνητών Νευρωνικών Δικτύων – Monthly Artificial Neural Network Model (M-ANN)

Στο μοντέλο M-ANN τα δεδομένα χωρίστηκαν τυχαία (dividerand) ως εξής:

- 50% για εκπαίδευση (training)
- 25% για επικύρωση (validation)
- 25% για δοκιμή (test)

Ως αλγόριθμος μάθησης επιλέγεται ο Levenberg-Marquardt (trainlm), ένα κρυφό επίπεδο με εξίσωση μεταφοράς tan-sigmoid (tansig) με 9 νευρώνες και ένα επίπεδο εξόδου με εξίσωση μεταφοράς pure-linear (purelin) και 1 νευρώνα (**Σχήμα 10**).

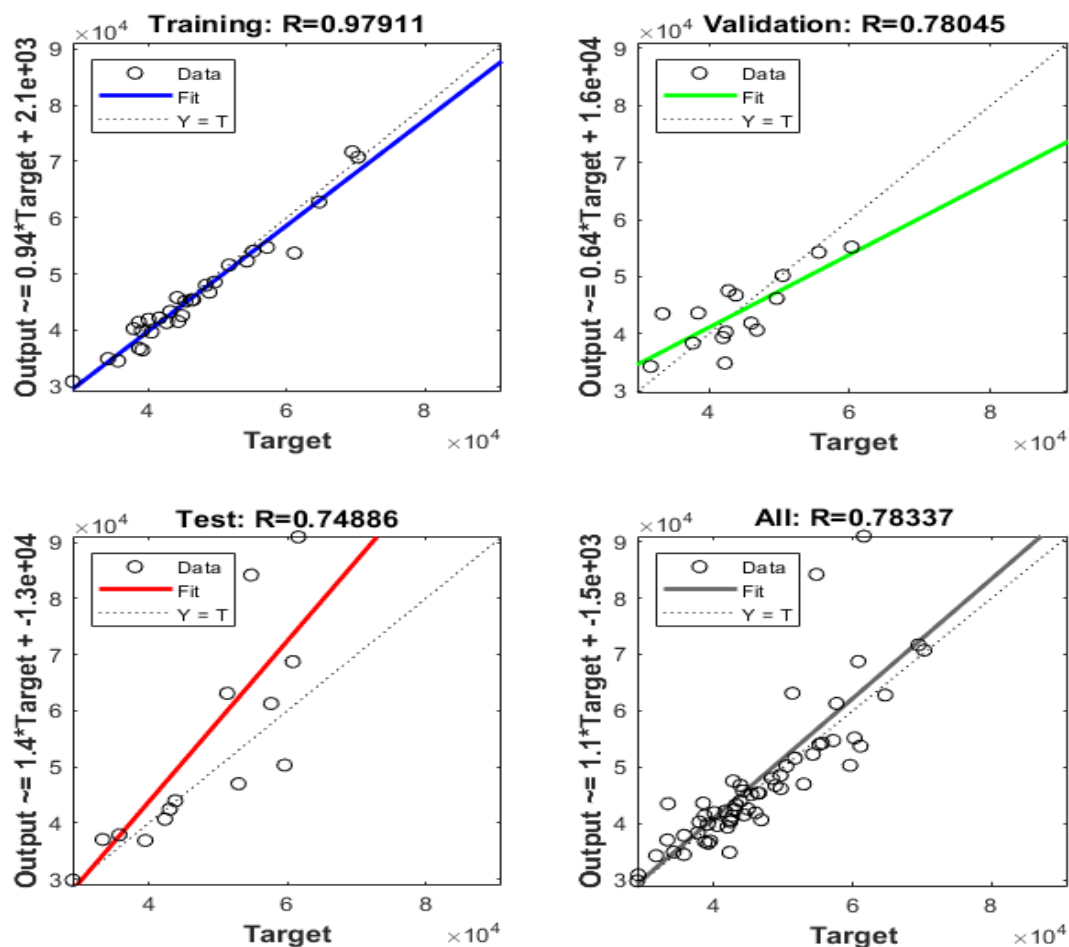


Σχήμα 10. Μορφή μοντέλου M-ANN.


Πίνακας 26. Αποτελέσματα μοντέλου M-ANN.

	MSE	R	R ²
Training	4.474.575,36	0,98	0,96
Validation	21.825.808,08	0,78	0,61
Testing	233.642.268,03	0,75	0,56
Gradient = 2,51e-07 at 10 epochs			
Mu = 0,1			

Στην **Εικόνα 24** παρουσιάζονται οι συντελεστές συσχέτισης των επί μέρους σταδίων της δημιουργίας του μηνιαίου μοντέλου TNN – εκπαίδευση, επικύρωση, δοκιμή και το συνολικό, και φαίνεται επιπλέον πως το μοντέλο αδυνατεί να προσαρμοστεί καλά στα δεδομένα. Σε συνδυασμό και με τον **Πίνακας 26** το μοντέλο έχει συντελεστή προσδιορισμού $R^2 = 0,61$, με μέσο τετραγωνικό σφάλμα $MSE = 66.104.306,70 \text{ kWh}^2$, ρίζα μέσου τετραγωνικού σφάλματος $RMSE = 8.130,46 \text{ kWh}$ και κλίση κατάβασης (gradient descent) $2,51\text{e-}07$, τα οποία επιτυγχάνονται στους 10 κύκλους επαναλήψεων (epoch). Επιπλέον, στο **Διάγραμμα 26** φαίνονται οι διακυμάνσεις των σφαλμάτων του μοντέλου M-ANN, τα οποία κυμαίνονται περίπου μεταξύ -10.000 έως 10.000 kWh, αλλά από τις 1/9/2018 και έπειτα τα σφάλματα αυξάνονται. Στο **Διάγραμμα 25** φαίνεται το προφίλ του μοντέλου για την πενταετία 2015-2019 σε σύγκριση με το πραγματικό, στο οποίο παρατηρείται πως από την 1/9/2018 και ύστερα το μοντέλο παρουσιάζει δύο μεγάλες κορυφές αρκετά μακριά από την πραγματικότητα. Τέλος, από τον **Πίνακας 27** λαμβάνεται η διακύμανση των τιμών κατανάλωσης ηλεκτρικής ενέργειας για το μοντέλο M-ANN και φαίνεται πως το μοντέλο ακολουθεί την αυξητική τάση της κατανάλωσης ενέργειας.




Εικόνα 24. Διαγράμματα παλινδρόμησης του μοντέλου M-ANN για όλα τα στάδια.



Διάγραμμα 25. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου M-ANN σε σύγκριση με το πραγματικό.

Πίνακας 27. Διακύμανση τιμών ηλεκτρικής ενέργειας (kWh) μοντέλου M-ANN.

	Ελάχιστη	Μέση	Μέγιστη
2015	28.813,60	37.326,47	43.636,21
2016	36.485,76	40.850,12	54.275,02
2017	39.858,35	44.165,94	54.724,78
2018	42.473,86	51.785,97	71.708,11
2019	47.991,61	64.421,65	90.974,39



Διάγραμμα 26. Υπολείμματα μοντέλου M-ANN.

4.1.3.3. Μηνιαίο Μοντέλο Μηχανικής Μάθησης – Monthly Machine Learning Model (M-ML)

Τα μηνιαία δεδομένα επειδή ήταν αρκετά λίγα χρειάστηκε τελικά να διαχωριστούν σε 10-fold τμήματα για εκπαίδευση, επικύρωση και δοκιμή. Τα αποτελέσματα των αλγορίθμων που χρησιμοποιήθηκαν συνοψίζονται στον **Πίνακας 28** οι δέκα καλύτεροι με βάση την ρίζα του μέσου τετραγωνικού σφάλματος.

Πίνακας 28. Αποτελέσματα αλγορίθμων μηχανικής μάθησης για μηνιαία δεδομένα.


Αλγόριθμος Μηχανικής Μάθησης	RMSE
Optimizable GPR	3.439,1
Optimizable Ensemble Trees	4.278,3
Optimizable Tree	4.278,3
Linear SVM	4.957,1
Boosted Trees	4.977,1
Fine Tree	5.218,1
Exponential GPR	6.220,7
Medium Tree	5.657,3
Medium Gaussian SVM	5.778,3
Regression Linear	5.786,3

Από τους παραπάνω αλγορίθμους μηχανικής μάθησης παρατηρήθηκε ότι παρότι ορισμένοι είχαν χαμηλό RMSE δεν έδιναν καλές προβλέψεις για το έτος 2030 (χαμηλές τιμές ή αρνητικές τιμές). Ο αλγόριθμος που είχε χαμηλό RMSE και έδινε προβλέψεις ικανοποιητικές για το 2030 ήταν ο **Linear SVM**, οποίος και τελικά χρησιμοποιήθηκε.


Το μηνιαίο μοντέλο μηχανικής μάθησης (**M-ML**) που δημιουργήθηκε σύμφωνα με τον αλγόριθμο Linear SVM έχει συντελεστή προσδιορισμού $R^2 = 0,74$, μέσο τετραγωνικό σφάλμα $MSE = 24.572.705,05 \text{ kWh}^2$ και ρίζα μέσου τετραγωνικού σφάλματος $RMSE = 4.957,09 \text{ kWh}$. Στην **Εικόνα 25** φαίνεται η προσαρμογή του μοντέλου στα δεδομένα δεν είναι αρκετά καλή και από **Πίνακας 29** λαμβάνεται το προφίλ του μοντέλου για τα έτη 2015-2019, από τον οποίο φαίνεται πως το μοντέλο καταφέρνει να αποτυπώσει την αυξητική τάση της κατανάλωσης ενέργειας, σύμφωνα με τις μέσες τιμές. Στο **Διάγραμμα 27** φαίνεται το προφίλ πρόβλεψης του μοντέλου σε σχέση με το πραγματικό, όπου φαίνεται πως το μοντέλο δεν προσαρμόζεται ικανοποιητικά στα δεδομένα. Τέλος, στο **Διάγραμμα 28** παρουσιάζεται η διακύμανση των σφαλμάτων του μοντέλου M-ML, τα οποία παρότι στην αρχή κυμαίνονται γύρω από το μηδέν μεταξύ -5.000 και 5.000 kWh, μεταξύ 1/8/2018 και 1/1/2019 τα σφάλματα αυξάνονται στις 15.000 kWh.

Πίνακας 29. Διακύμανση τιμών ηλεκτρικής ενέργειας (kWh) μοντέλου M-ML.


	Ελάχιστη	Μέση	Μέγιστη
2015	33.321,31	37.292,45	42.418,47
2016	37.087,13	40.773,98	46.830,40
2017	42.421,40	46.106,75	52.483,48
2018	43.286,00	48.739,37	54.542,68
2019	48.993,27	55.151,27	62.527,88



Εικόνα 25. Διάγραμμα παλινδρόμησης για το μοντέλο M-ML



Διάγραμμα 27. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου M-ML σε σύγκριση με το πραγματικό.




Διάγραμμα 28. Διακύμανση σφαλμάτων μοντέλου M-ML.

4.1.3.4. Μοντέλο Μεθόδου Διάσπασης Χρονοσειρών - Decomposition Method Model (DM)

Για το μοντέλο διάσπασης χρονοσειρών χρησιμοποιείται το προσθετικό (additive) μοντέλο γιατί από την **Εικόνα 26** για τα αρχικά δεδομένα φαίνεται πως η τάση και η εποχικότητα προστίθενται το ένα πίσω από το άλλο, πράγμα που υποδηλώνεται από το γεγονός ότι το εύρος των εποχών δεν αλλάζει πολύ δραστικά.


Η προσαρμοσμένη γραμμή τάσης που προκύπτει είναι η:

$$Y_t = 33.673 + 415,6 \cdot t \quad (22)$$



Εικόνα 26. Ανάλυση στοιχείων χρονοσειράς.


Το μοντέλο διάσπασης χρονοσειρών (DM) έχει μέσο τετραγωνικό σφάλμα $MSE = 19.460.260,52 \text{ kWh}^2$ και ρίζα μέσου τετραγωνικού σφάλματος $RMSE = 4.411,38 \text{ kWh}$. Από το **Διάγραμμα 29** λαμβάνεται το μηνιαίο προφίλ του μοντέλου για τα έτη 2015-2019 σε σύγκριση με το πραγματικό, στο οποίο φαίνεται να ακολουθεί το προφίλ αλλά με αρκετές αποκλίσεις, και στον **Πίνακα 30** αποτυπώνονται οι ελάχιστη, μέση και μέγιστη τιμή κατανάλωσης ηλεκτρικής ενέργειας για την πενταετία 2015-2019 όπου φαίνεται πως το μοντέλο αποτυπώνει την αυξητική τάση της κατανάλωσης ηλεκτρικής ενέργειας. Τέλος, στο **Διάγραμμα 30** η διακύμανση σφαλμάτων του μοντέλου DM κυμαίνεται κυρίως μεταξύ -10.000 έως 10.000 kWh. Παρατηρείται ότι παρότι στην αρχή η διακύμανση είναι περίπου σταθερή γύρω από το μηδέν, από τις 1/9/2018 τα σφάλματα του μοντέλου αυξάνουν στις 10.000 kWh.



Διάγραμμα 29. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου DM σε σύγκριση με το πραγματικό.

Πίνακας 30. Διακύμανση τιμών ηλεκτρικής ενέργειας (kWh) μοντέλου DM.

	Ελάχιστη	Μέση	Μέγιστη
2015	28.320,43	36.374,67	47.683,21
2016	33.307,38	41.361,61	52.423,99
2017	38.294,33	46.348,56	57.410,93
2018	43.281,27	51.335,50	62.397,68
2019	48.268,22	56.322,45	67.384,82



Διάγραμμα 30. Διακύμανση σφαλμάτων μοντέλου DM.

4.1.3.5. Box-Jenkins Μέθοδος – Μοντέλο Αυτοπαλίνδρομου Ολοκληρωμένου Κινητού Μέσου ARIMA (SARIMA)

Στην εφαρμογή **R-studio** μέσω της συνάρτησης `auto.arima()` η οποία χρησιμοποιεί μια σταδιακή προσέγγιση για την αναζήτηση πολλαπλών συνδυασμών των παραμέτρων p, d, q και επιλέγει το καλύτερο μοντέλο το οποίο έχει το λιγότερο AIC (Akaike Information Criteria). Το AIC ποσοτικοποιεί τον βαθμό προσαρμογής και την απλότητα/οικονομία του μοντέλου σε μία ενιαία στατιστική. Το μοντέλο που προκύπτει είναι το $ARIMA(1,0,0)(1,1,0)[12]$ με $d=1$ (drift), εν συντομία το μοντέλο μετονομάζεται σε SARIMA. Στην **Εικόνα 27** φαίνονται τα αποτελέσματα και χαρακτηριστικά του μοντέλου SARIMA. Το μοντέλο SARIMA έχει μέσο τετραγωνικό σφάλμα $MSE = 8.899.430,38 \text{ kWh}^2$ και ρίζα μέσου τετραγωνικού σφάλματος $RMSE = 2.983,19 \text{ kWh}$.

```
> summary(autoarima1)
Series: tsdata
ARIMA(1,0,0)(1,1,0)[12] with drift

Coefficients:
      ar1      sar1      drift
    0.8185   -0.6262   388.3535
s.e.  0.0920    0.1203   135.1045

sigma^2 estimated as 11016558:  log likelihood=-459.2
AIC=926.41   AICC=927.34   BIC=933.89
```

Εικόνα 27. Αποτελέσματα μοντέλου SARIMA.

Μέσω του στατιστικού ελέγχου Ljung-Box (**Εικόνα 28**) παρατηρείται ότι $Q^{LB} = 11,01$ με $P - value = 0,3567 > 0,05$, άρα δεν μπορεί να ακυρωθεί η μηδενική υπόθεση, δηλαδή ότι τα δεδομένα είναι ασυσχέτιστα και επομένως τα κατάλοιπα/σφάλματα είναι ασυσχέτιστα (λευκός θόρυβος).

```
> checkresiduals(fit)


Ljung-Box test

data:  Residuals from ARIMA(1,0,0)(1,1,0)[12]
Q* = 11.01, df = 10, p-value = 0.3567


Model df: 2.    Total lags used: 12
```

Εικόνα 28. Ljung-Box test

Στο **Διάγραμμα 31** και **Διάγραμμα 32** φαίνονται τα διαγράμματα αυτοσυσχέτισης και μερικής αυτοσυσχέτισης της χρονοσειράς. Παρατηρείται ότι δεν υπάρχει στατιστικά σημαντικός συντελεστής συσχέτισης και μερικής αυτοσυσχέτισης των υπολοίπων που υποδηλώνει ότι η χρονοσειρά των υπολοίπων είναι λευκός θόρυβος, άρα το μοντέλο είναι καλό. Επιπλέον, από το **Διάγραμμα 35** και την διακύμανση των σφαλμάτων της χρονοσειράς, παρατηρείται ότι πρόκειται για στάσιμη χρονοσειρά με μέση τιμή μηδέν και συσχετίσεις να κυμαίνονται από -5.000 έως 5.000 kWh.




Διάγραμμα 31. Διάγραμμα αυτοσυσχέτισης υπολοίπων χρονοσειράς.




Διάγραμμα 32. Διάγραμμα μερικής αυτοσυσχέτισης υπολοίπων χρονοσειράς.

Στο **Διάγραμμα 33** αποτυπώνεται το προφίλ πρόβλεψης του μοντέλου SARIMA για την πενταετία 2015-2019 σε σχέση με το πραγματικό. Στο **Διάγραμμα 34** παρουσιάζεται το προφίλ πρόβλεψης κατανάλωσης ηλεκτρικής ενέργειας έως το 2030, όπου παρατηρείται ότι το μοντέλο ακολουθεί την αυξητική τάση καθώς και την εποχικότητα της κατανάλωσης ενέργειας. Τέλος, στον **Πίνακα 31** φαίνονται οι μηνιαίες διακυμάνσεις των τιμών κατανάλωσης ηλεκτρικής ενέργειας για την πενταετία, σύμφωνα με το μοντέλο.




Διάγραμμα 33. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου SARIMA σε σύγκριση με το πραγματικό.



Διάγραμμα 34. Προφίλ πρόβλεψης μοντέλου SARIMA έως το 2030.

Πίνακας 31. Διακύμανση τιμών ηλεκτρικής ενέργειας (kWh) μοντέλου SARIMA.

	Ελάχιστη	Μέση	Μέγιστη
2015	28.944,64	36.147,39	44.845,04
2016	34.318,02	40.277,28	46.818,49
2017	35.216,08	45.528,99	52.839,50
2018	43.916,96	51.417,27	68.082,71
2019	49.100,23	56.686,39	70.958,75



Διάγραμμα 35. Διακύμανση σφαλμάτων μοντέλου SARIMA.

4.2 Σύγκριση μοντέλων

Στην υποενότητα αυτή γίνεται σύγκριση των μοντέλων ώστε να βρεθεί το καλύτερο στην αντίστοιχη βάση - ωριαία, ημερήσια και μηνιαία.

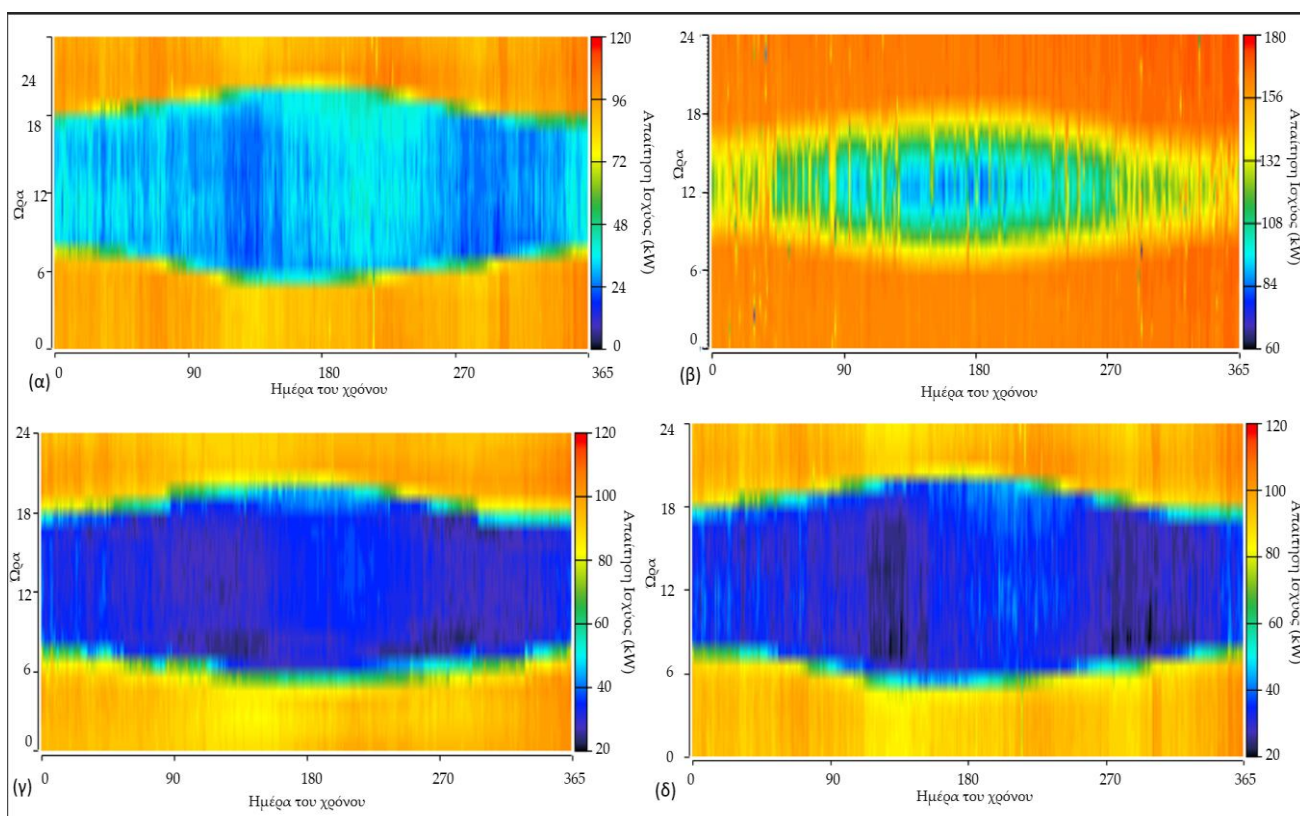
4.2.1. Ωριαία δεδομένα

Τα μοντέλα H-LR, H-ANN και H-ML συγκρίνονται περαιτέρω ώστε να βρεθεί το καλύτερο πάνω σε ωριαία βάση δεδομένων.

Πίνακας 32. Σύγκριση ωριαίων μοντέλων.


Μοντέλο	MSE	RMSE	R ²
H-LR	680,06 kWh^2	26,08 kWh	0,45
H-ANN	74,83 kWh^2	8,65 kWh	0,94
H-ML	4,86 kWh^2	2,21 kWh	0,99

Το ωριαίο μοντέλο αλγορίθμων μηχανικής μάθησης φαίνεται να έχει καλύτερο (χαμηλότερο) μέσο τετραγωνικό σφάλμα στις προβλέψεις ($MSE = 4,86 kWh^2$) έναντι του ωριαίου μοντέλου τεχνητών νευρωνικών δικτύων ($MSE = 74,83 kWh^2$) και του ωριαίου μοντέλου γραμμικής παλινδρόμησης ($MSE = 680,06 kWh^2$). Τέλος, από την **Εικόνα 29** φαίνεται ότι το μοντέλο γραμμικής παλινδρόμησης αδυνατεί να ακολουθήσει το πραγματικό προφίλ μέσης ωριαίας απαίτησης ηλεκτρικής ισχύος. Αντιθέτως τα μοντέλα μηχανικής μάθησης και τεχνητών νευρωνικών δικτύων δείχνουν να προσομοιάζουν αρκετά καλά την πραγματική κατάσταση, με το μοντέλο αλγορίθμων μηχανικής μάθησης να είναι ελαφρώς καλύτερο.




Εικόνα 29. Μέσο ωριαία προφίλ απαίτησης ηλεκτρικής ισχύος για τα έτη 2015-2019 – (α) Πραγματικό, (β) Μοντέλο H-LR, (γ) Μοντέλο H-ANN και (δ) Μοντέλο H-ML.

Επιπλέον από το **Διάγραμμα 36** και το μέσο ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας της πενταετίας 2015-2019 του μοντέλου H-ANN και το αντίστοιχο **Διάγραμμα 37** του μοντέλου H-ML, παρατηρείται ότι το μοντέλο H-ML ακολουθεί καλύτερα το προφίλ κατανάλωσης ηλεκτρικής ενέργειας και επιπλέον λόγω χαμηλότερου MSE (και RMSE) είναι αυτό που επιλέγεται ως το καλύτερο.



Διάγραμμα 36. Μέσο ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου H-ANN.



Διάγραμμα 37. Μέσο ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας μοντέλου H-ML.


4.2.2. Ημερήσια δεδομένα

Οι δείκτες των μοντέλων D-LR, D-ANN και D-ML συνοψίζονται στον παρακάτω πίνακα για επιπλέον σύγκριση.

Πίνακας 33. Σύγκριση ημερήσιων μοντέλων.

Μοντέλο	MSE	RMSE	R ²
D-LR	34.987,57 kWh ²	187,05 kWh	0,67
D-ANN	9.456,02 kWh ²	97,24 kWh	0,90
D-ML	887,49 kWh ²	29,79 kWh	0,99

Σύμφωνα με τα δεδομένα ημερήσιας βάσης, καλύτερο μοντέλο αναδεικνύεται το μοντέλο μηχανικής μάθησης (D-ML) με μέσο τετραγωνικό σφάλμα $MSE = 887,49 \text{ kWh}^2$, δεύτερο βρίσκεται το μοντέλο τεχνητών νευρωνικών δικτύων (D-ANN) με $MSE = 9.456,02 \text{ kWh}^2$ και τελευταίο το μοντέλο γραμμικής παλινδρόμησης (D-LR) με $MSE = 34.987,57 \text{ kWh}^2$. Περαιτέρω από την **Εικόνα 30** και τα σχετικά διαγράμματα, φαίνεται



Εικόνα 30. Ημερήσια προφίλ κατανάλωσης ηλεκτρικής ενέργειας για τα έτη 2015-2019 – (α) Μοντέλο D-LR, (β) Μοντέλο D-ANN και (γ) Μοντέλο D-ML.


4.2.3. Μηνιαία δεδομένα

Στον **Πίνακα 34** γίνεται σύνοψη των δεικτών των μοντέλων M-LR, M-NN, M-ML, DM και SARIMA.

Πίνακας 34. Σύγκριση μηνιαίων μοντέλων.

Μοντέλο	MSE	RMSE
M-LR	22.474,064,04 kWh^2	4.740,68 kWh
M-ANN	66.104.306,70 kWh^2	8.130,46 kWh
M-ML	24.572.705,05 kWh^2	4.957,09 kWh
DM	19.460.260,52 kWh^2	4.411,38 kWh
SARIMA	8.899.430,38 kWh^2	2.983,19 kWh

Το μοντέλο SARIMA έχει το καλύτερο μέσο τετραγωνικό σφάλμα $MSE = 8.899.130,38 kWh^2$, με το μοντέλο διάσπασης χρονοσειρών (DM) να ακολουθεί με $MSE = 19.460.260,52 kWh^2$. Έπειτα σε σειρά έρχεται, το μοντέλο γραμμικής παλινδρόμησης (M-LR) με $MSE = 22.747.064,04 kWh^2$, το μοντέλο αλγορίθμων μηχανικής μάθησης (M-ML) με $MSE = 24.572.705,05 kWh^2$, και τέλος το μοντέλο τεχνητών νευρωνικών δικτύων με $MSE = 66.104.306,70 kWh^2$. Τέλος, στην **Εικόνα 31** φαίνονται τα μηνιαία ενεργειακά προφίλ των μοντέλων,



Εικόνα 31. Μηνιαία προφίλ κατανάλωσης ηλεκτρικής ενέργειας για τα έτη 2015-2019 – (α) Μοντέλο M-LR, (β) Μοντέλα DM, (γ) Μοντέλο M-ANN και M-ML και (δ) Μοντέλο SARIMA

4.3 Πρόβλεψη ενεργειακού προφίλ λιμένα Σούδας για το 2030

Στην υποενότητα αυτή παρουσιάζονται αρχικά η πρόβλεψη ενεργειακού προφίλ του λιμένα Σούδας για το έτος 2030, με την χρήση του καλύτερου μοντέλου, αυτού της μηχανικής μάθησης με βάση τα ωριαία δεδομένα. Στην συνέχεια, παρουσιάζονται τα αποτελέσματα του δεύτερου καλύτερου μοντέλου πρόβλεψης, αυτό των τεχνητών νευρωνικών δικτύων με βάση τα ωριαία δεδομένα (H-ANN). Τέλος, αποτυπώνονται οι ετήσιες τιμές κατανάλωσης ηλεκτρικής ενέργειας όλων των μοντέλων για μια καλύτερη εικόνα της απόδοσης όλων των χρησιμοποιούμενων μεθόδων.


4.3.1. Πρόβλεψη ενεργειακού προφίλ για το 2030 με βάση το ωριαίο μοντέλο μηχανικής μάθησης (H-ML)

Σύμφωνα με το ωριαίο μοντέλο μηχανικής μάθησης H-ML του αλγορίθμου Exponential Gaussian Process Regression εξάγονται τα παρακάτω αποτελέσματα.


Πίνακας 35. Διακύμανση τιμών ωριαίας κατανάλωσης ηλεκτρικής ενέργειας (kWh) για το έτος 2030.

Ελάχιστη	61,86
Μέση	117,31
Μέγιστη	160,44

Σύμφωνα με τον **Πίνακα 35** η ωριαία κατανάλωση ηλεκτρικής ενέργειας για το έτος 2030 αναμένεται να κυμαίνεται μεταξύ των **61,86 kWh** και **160,44 kWh**, με μέση ωριαία κατανάλωση τις **117,31 kWh**. Επιπλέον στο **Διάγραμμα 38** αποτυπώνεται το αναμενόμενο ωριαίο προφίλ απαίτησης ηλεκτρικής ισχύος του λιμένα Σούδας για το έτος 2030. Η απαίτηση το βράδυ και τα ξημερώματα είναι αυξημένη ενώ κατά την διάρκεια της ημέρας μειώνεται.



Διάγραμμα 38. Ωριαία απαίτηση ηλεκτρικής ισχύος για το 2030.




Διάγραμμα 39. Ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας για το έτος 2030.

Πίνακας 36. Διακύμανση τιμών ημερήσιας κατανάλωσης ηλεκτρικής ενέργειας (kWh) για το έτος 2030.

Ελάχιστη	2.419,73
Μέση	2.815,48
Μέγιστη	3.379,73


Με αναγωγή σε ημερήσια δημιουργείται το ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας του λιμένα για το 2030 και αποτυπώνεται στο **Διάγραμμα 39**. Σύμφωνα και με τον **Πίνακα 36** οι ημερήσιες τιμές της κατανάλωσης ηλεκτρικής ενέργειας θα κυμαίνονται από **2.419,73 kWh** έως και **3.379,73 kWh**, με **μέση κατανάλωση** τις **2.815,48 kWh** για το έτος 2030. Παρατηρείται ότι οι μέρες στην χειμερινή περίοδο έχουν μεγαλύτερες καταναλώσεις σε σχέση με την καλοκαιρινή περίοδο.

Με αναγωγή σε μηνιαία λαμβάνεται και το μηνιαίο προφίλ για το έτος 2030. Σύμφωνα με το **Διάγραμμα 40** ο πιο απαιτητικός μήνας θα είναι ο **Δεκέμβριος** με απαίτηση **96.752,02 kWh** και ο λιγότερο φορτισμένος μήνας θα είναι ο **Ιούνιος** με απαίτηση **76.380,25 kWh**.



Διάγραμμα 40. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας για το έτος 2030.

Τέλος, η **ετήσια** κατανάλωση ηλεκτρικής ενέργειας για το 2030 σύμφωνα με το μοντέλο H-ML θα είναι στις **1.027.649,94 kWh**. Από **Διάγραμμα 41** φαίνεται πως ακολουθείται η αυξητική τάση της κατανάλωσης ηλεκτρικής ενέργειας λόγω οικονομικο-κοινωνικής ανάπτυξης, δημιουργώντας με αυτό τον τρόπο σημαντικές ενεργειακές απαιτήσεις στα προσεχή χρόνια.



Διάγραμμα 41. Ετήσια κατανάλωση ηλεκτρικής ενέργειας για το έτος 2030.

4.3.2. Πρόβλεψη μοντέλου H-ANN για το 2030.

Σύμφωνα με το μοντέλο τεχνητών νευρωνικών δικτύων που δημιουργήθηκε με ωριαία δεδομένα, εξάγεται το ωριαίο, ημερήσιο και μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας, του λιμένα Σούδας, για το έτος 2030.

Πίνακας 37. Διακύμανση τιμών ωριαίας κατανάλωσης ηλεκτρικής ενέργειας (kWh) για το έτος 2030.

Ελάχιστη	13,15
Μέση	150,03
Μέγιστη	283,50


Σύμφωνα με τον **Πίνακα 37** η ωριαία κατανάλωση ηλεκτρικής ενέργειας για το έτος 2030 αναμένεται να κυμαίνεται μεταξύ των **13,15 kWh** και **283,50 kWh**, με μέση ωριαία κατανάλωση τις **150,03 kWh**. Επιπλέον στο **Διάγραμμα 42** αποτυπώνεται το αναμενόμενο ωριαίο προφίλ απαίτησης ηλεκτρικής ισχύος του λιμένα Σούδας για το έτος 2030. Η απαίτηση το βράδυ και τα ξημερώματα είναι αυξημένη ενώ κατά την διάρκεια της ημέρας μειώνεται.

Με αναγωγή σε ημερήσια δημιουργείται το ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας του λιμένα για το 2030 και αποτυπώνεται στο **Διάγραμμα 43**. Σύμφωνα και με τον **Πίνακα 36** οι ημερήσιες τιμές της κατανάλωσης ηλεκτρικής ενέργειας θα κυμαίνονται από **2.990,64 kWh** έως και **3.600,80 kWh**, με **μέση κατανάλωση** τις **3.969,92 kWh** για το έτος 2030. Παρατηρείται ότι οι μέρες στην χειμερινή περίοδο έχουν μεγαλύτερες καταναλώσεις σε σχέση με την καλοκαιρινή περίοδο, παραμένουν όμως υψηλές.


Με αναγωγή σε μηνιαία λαμβάνεται και το μηνιαίο προφίλ για το έτος 2030. Σύμφωνα με το **Διάγραμμα 44** ο πιο απαιτητικός μήνας θα είναι ο **Ιανουάριος** με απαίτηση **117,597,84 kWh** και ο λιγότερο φορτισμένος μήνας θα είναι ο **Σεπτέμβριος** με απαίτηση **103.267,86 kWh**.

Τέλος, η **ετήσια** κατανάλωση ηλεκτρικής ενέργειας για το 2030 σύμφωνα με το μοντέλο H-ANN θα είναι στις **1.314.292,45 kWh**. Από **Διάγραμμα 45** φαίνεται πως ακολουθείται η αυξητική τάση της κατανάλωσης ηλεκτρικής ενέργειας.

Σε σύγκριση με το μοντέλο H-ML, το μοντέλο των τεχνητών νευρωνικών δικτύων φαίνεται να εκτιμά αρκετά υψηλότερες τιμές κατανάλωσης ηλεκτρικής ενέργειας, κατά περίπου 300.000 kWh (**Διάγραμμα 46**).




Διάγραμμα 42. Ωριαία απαίτηση ηλεκτρικής ισχύος του μοντέλου H-ANN για το 2030.




Διάγραμμα 43. Ημερήσιο προφίλ κατανάλωσης ηλεκτρικής ενέργειας του μοντέλου H-ANN για το έτος 2030.

Πίνακας 38. Διακύμανση τιμών ημερήσιας κατανάλωσης ηλεκτρικής ενέργειας (kWh) για το έτος 2030.


Ελάχιστη	2.990,64
Μέση	3.600,80
Μέγιστη	3.969,92



Διάγραμμα 44. Μηνιαίο προφίλ κατανάλωσης ηλεκτρικής ενέργειας του μοντέλου H-ANN για το έτος 2030.




Διάγραμμα 45. Ετήσια κατανάλωση ηλεκτρικής ενέργειας του μοντέλου H-ANN για το έτος 2030.



Διάγραμμα 46. Σύγκριση πρόβλεψης μοντέλων H-ML και H-ANN για το 2030.

4.3.3. Ετήσια πρόβλεψη μοντέλων για το 2030.

Στο **Διάγραμμα 47** παρουσιάζονται οι ετήσιες προβλέψεις όλων των μοντέλων για το έτος 2030. Σύμφωνα και με τον **Πίνακα 39** οι προβλέψεις των μοντέλων βρίσκονται όλες σχετικά κοντά, με την πρόβλεψη του μοντέλου M-LR να είναι η υψηλότερη στις 1.561.356,12 kWh και η χαμηλότερη πρόβλεψη να είναι στις 1.027.649,94 kWh, του μοντέλου H-ML.



Διάγραμμα 47. Ετήσια πρόβλεψη κατανάλωσης ηλεκτρικής ενέργειας όλων των χρησιμοποιούμενων μοντέλων για το έτος 2030.

Πίνακας 39. Ετήσια πρόβλεψη κατανάλωσης ηλεκτρικής ενέργειας όλων των χρησιμοποιούμενων μοντέλων για το έτος 2030.

Μοντέλο	Ηλεκτρική Ενέργεια (kWh)
H-LR	1.326.974,50
H-ANN	1.314.292,45
H-ML	1.027.649,94
D-LR	1.349.941,54
D-ANN	1.433.603,20
D-ML	1.359.814,69
M-LR	1.561.356,12
M-ANN	1.459.066,88
M-ML	1.431.339,81
DM	1.334.146,27
SARIMA	1.268.388,70

5. Συμπεράσματα

5.1 Ανάλυση συμπερασμάτων

Η παρούσα διπλωματική εργασία ερευνά την αξιοπιστία και την ευχέρια χρήσης διάφορων ευρέως γνωστών μοντέλων πρόβλεψης και μοντελοποιεί την πρόβλεψη της αναμενόμενης κατανάλωσης ηλεκτρικής ενέργειας του λιμένα Σούδας για το έτος 2030. Τα μοντέλα πρόβλεψης που δημιουργήθηκαν αξιοποιούν τεχνικές όπως την απλή γραμμική παλινδρόμηση, τα μοντέλα χρονοσειρών καθώς και την μηχανική μάθηση. Λογισμικά όπως το **Minitab**, η **MATLAB**® και το **R-studio** χρησιμοποιούνται για την δημιουργία των μοντέλων. Τα αποτελέσματα που προέκυψαν σχολιάζονται σε βάθος, συγκρίνοντας τις μεθόδους και έπειτα προτείνονται επιπλέον ενέργειες/μελέτες για μελλοντικές έρευνες. Περιορισμοί κατά την διάρκεια εκπόνησης της μελέτης υπήρξαν στο κομμάτι συλλογής και προεπεξεργασίας των δεδομένων, από τους αντίστοιχους φορείς, λόγω των κενών στις χρονοσειρές των δεδομένων. Επίσης, τα δεδομένα από το έτος 2020 δεν θεωρήθηκε θεμιτό να χρησιμοποιηθούν καθώς λόγω της πανδημίας από τον ιό **SARS-CoV-2** δεν θα αποτελούσαν αντιπροσωπευτικό δείγμα.

Καθώς τα μοντέλα χωρίζονται σε τρεις κύριες κατηγορίες με βάση τα δεδομένα (ωριαία, ημερήσια και μηνιαία), με αυτή τη σειρά θα γίνει και η αναφορά τους. Αρχικά αναλύονται τα αποτελέσματα που προκύπτουν από τα δημιουργούμενα μοντέλα H-LR, H-ANN και H-ML, στην συνέχεια αναλύονται τα αποτελέσματα των μοντέλων D-LR, D-ANN και D-ML και τέλος τα αποτελέσματα των M-LR, M-ANN, M-ML, DM και SARIMA. Επίσης πραγματοποιείται ανάλυση στις προβλέψεις για το 2030 που προκύπτουν σύμφωνα με τα δύο καλύτερα μοντέλα (H-ML και H-ANN).

Σύμφωνα με τα ωριαία δεδομένα, το μοντέλο γραμμικής παλινδρόμησης (H-LR) που δημιουργείται δεν αποδίδει καλά παρουσιάζοντας υψηλό MSE (**680,08 kWh²**) και χαμηλό R² (**0,45**), πράγμα το οποίο οδηγεί σε κακή προσαρμογή στα υπάρχον δεδομένα (**Πίνακας 10, Διάγραμμα 12**). Έτσι, δεν μπορεί να θεωρηθεί αξιόπιστο για την πρόβλεψη της ηλεκτρικής κατανάλωσης για το έτος 2030. Παρόλα αυτά, η διαδικασία την γραμμικής παλινδρόμησης δίνει την δυνατότητα ανάλυσης των μεταβλητών που χρησιμοποιήθηκαν για την εκτίμηση της κατανάλωσης ηλεκτρικής ενέργειας (**Πίνακας 7**) και σε συνεργασία με την ανάλυση συσχετίσεων του Pearson (**Πίνακας 8**) γίνεται φανερό ποιες έχουν στατιστικά σημαντική συσχέτιση (αλληλοεπίδραση) στην κατανάλωση ενέργειας του λιμένα. Αντιθέτως το μοντέλο τεχνητών νευρωνικών δικτύων (H-ANN), έχει αισθητά χαμηλότερο MSE (**74,83 kWh²**), αρκετά υψηλό R² (**0,94**) και επιτυγχάνει ικανοποιητική προσαρμογή στα υπάρχον δεδομένα (**Διάγραμμα 14**). Παρόλαυτα, εξακολουθεί όμως να αποτελεί περίπλοκη διαδικασία κατά την δημιουργία του. Τέλος, το μοντέλο αλγορίθμων μηχανικής μάθησης έχει το χαμηλότερο MSE (**4,86 kWh²**), υψηλότερο R² (**0,99**) και προσαρμόζεται αρκετά ικανοποιητικά στα πραγματικά δεδομένα (**Διάγραμμα 16**). Όμως, κατά την δημιουργία του όμως απαιτείται υψηλή επεξεργαστική ισχύ.

Όσον αφορά τα ημερήσια δεδομένα, το D-LR έχει το υψηλότερο MSE (**34.987,57 kWh²**), χαμηλότερο R² (**0,67**) και δεν προσαρμόζεται καλά στα δεδομένα (**Διάγραμμα 17**). Το D-ANN έχει το αμέσως χαμηλότερο MSE (**9.456,02 kWh²**) και υψηλότερο R² (**0,90**) και η προσαρμογή στα δεδομένα είναι ελαφρώς καλή (**Διάγραμμα 19**). Παρατηρείται πως η μείωση των δεδομένων εκπαίδευσης του μοντέλου δημιουργεί προβλήματα στην αποτελεσματικότητα. Τέλος, το D-ML εξακολουθεί να αποδίδει τα καλύτερα αποτελέσματα, με το χαμηλότερο MSE (**887,49 kWh²**), υψηλότερο R² (**0,99**) και την καλύτερη προσαρμογή στα δεδομένα (**Εικόνα 30**). Η υπολογιστική απαίτηση παραμένει υψηλή ακόμα και με μικρότερο πλήθος δεδομένων εκπαίδευσης.

Αναφορικά με τα μηνιαία δεδομένα, τα μοντέλα M-LR, M-ANN, M-ML έχουν αρκετά μεγάλα MSE (**Πίνακας 34**) και δεν προσαρμόζονται καλά στα υπάρχον δεδομένα (**Διάγραμμα 23, Διάγραμμα 25, Διάγραμμα 27**). Το γεγονός αυτό οφείλεται στα ελάχιστα δεδομένα που χρησιμοποιούνται για την δημιουργία των μοντέλων. Αντιθέτως, το μοντέλο διάσπασης χρονοσειρών (DM) έχει καλύτερη επίδοση, παρότι τα δεδομένα ήταν λίγα (**Πίνακας 34**) και προσαρμόζεται ελαφρώς καλύτερα στα δεδομένα (**Διάγραμμα 29**), παραμένει όμως αναξιόπιστο μοντέλο. Τέλος, το μοντέλο SARIMA επιτυγχάνει την καλύτερη προσαρμογή (**Διάγραμμα 33**) και έχει το μικρότερο MSE (**Πίνακας 34**). Παρότι το MSE είναι υψηλό (**8.899.430,38 kWh²**), με τα λίγα διαθέσιμα δεδομένα ακολουθεί ικανοποιητικά το προφίλ κατανάλωσης ενέργειας, σε σχέση με τα υπόλοιπα (**Εικόνα 31**).

Για το 2030, το καλύτερο μοντέλο H-ML εκτιμά ετήσια κατανάλωση ενέργειας στις **1.027.649,94 kWh**, αυξημένο κατά περίπου 54% σε σχέση με το 2019 (**Διάγραμμα 41**). Επιπλέον το ωριαίο και ημερήσιο προφίλ κατανάλωσης (**Διάγραμμα 38, Διάγραμμα 39**) δείχνουν πως οι καταναλώσεις εξακολουθούν να είναι υψηλότερες τον χειμώνα έναντι του καλοκαιριού και την νύχτα έναντι της ημέρας. Αντιθέτως το μοντέλο H-ANN εκτιμά ετήσια κατανάλωση ενέργειας στις **1.314.292,45 kWh**, αυξημένο κατά περίπου 97% σε σχέση με το 2019 (**Διάγραμμα 45**) και κατά περίπου 300.000 kWh σε σχέση με την πρόβλεψη του H-ML για το 2030 (**Διάγραμμα 46**). Επίσης, σύμφωνα με το μοντέλο, οι ημερήσιες καταναλώσεις παραμένουν αρκετά υψηλές ακόμα και τους καλοκαιρινούς μήνες (**Διάγραμμα 43**) και κατά την διάρκεια της ημέρας (**Διάγραμμα 42**). Τέλος, άξιο αναφοράς είναι πως όλα τα μοντέλα εκτιμούν τιμές κατανάλωσης ηλεκτρικής ενέργειας πάνω από τις 1.000.000. kWh για το έτος 2030, με τις προβλέψεις να φτάνουν και ως τις 1.500.000 kWh (**Διάγραμμα 47**).

Τα αποτελέσματα της μελέτης δείχνουν να συμφωνούν και με προϋπάρχων έρευνες στον τομέα πρόβλεψης της ενέργειας. Η κατανάλωση ηλεκτρικής ενέργειας έχει άμεση συσχέτιση με την θερμοκρασία και τις υπόλοιπες μετεωρολογικές μεταβλητές και έχει αυξητική τάση με την πάροδο των χρόνων. Επίσης, προκύπτει πως τα μοντέλα μηχανικής μάθησης δύναται να αποτελέσουν πολύτιμο εργαλείο στον τομέα των προβλέψεων και της μακροπρόθεσμης στρατηγικής ανάπτυξης, καθώς σε συνδυασμό με την ολοένα αυξανόμενη υπολογιστική ικανότητα των σύγχρονων υπολογιστών, γίνονται όλο και πιο αξιόπιστα και επιτυγχάνουν να δώσουν λύσεις σε περίπλοκα προβλήματα σε σχετικά μικρά χρονικά διαστήματα. Τα κλασσικά στατιστικά μοντέλα πρόβλεψης παραμένουν όμως ένα σχετικά εύκολο και αρκετά αξιόπιστο εργαλείο στον τομέα των προβλέψεων.

Τέλος, σημαντικό είναι να αναφερθεί πως οι παραπάνω προβλεπόμενες τιμές ηλεκτρικής ενέργειας αποτελούν μια εκτίμηση και μπορεί να διαφέρουν αρκετά από τις πραγματικές τιμές το 2030, καθώς υπάρχουν παράγοντες που μπορεί να επηρεάσουν το αποτέλεσμα, οι οποίοι δεν μπορούν να εκτιμηθούν (οικονομική κρίση, πανδημία, φυσική καταστροφή, κ.α.).

Στην παρούσα έρευνα αναδεικνύεται το μείζων πρόβλημα στην αυξανόμενη απαίτηση σε ηλεκτρική ενέργεια στο λιμάνι της Σούδας με την πάροδο του χρόνου. Αποφάσεις και πράξεις πρέπει να ληφθούν άμεσα για την αντιμετώπιση του προβλήματος, από τους αρμόδιους φορείς, για την συμμόρφωση με τους παγκόσμιους και ευρωπαϊκούς κανόνες για την κάλυψη των ενεργειακών απαιτήσεων με συστήματα ΑΠΕ με στόχο μια πιο βιώσιμη ανάπτυξη. Τα λιμάνια εκτός από την ασφαλή διακίνηση επιβατών και φορτίων, έχουν την δυνατότητα να μετατραπούν σε ενεργειακά ημιαυτόνομα κέντρα και σε λιμάνια σχεδόν μηδενικής ενεργειακής κατανάλωσης (nearly Zero Energy Ports). Καθώς η κύρια κατανάλωση ηλεκτρικής ενέργειας προέρχεται από την χρήση παλαιών εξοπλισμών (πχ. τεχνολογία φωτισμού- λάμπες φθορίου), υπάρχει μεγάλη δυνατότητα στην εγκατάσταση ΑΠΕ για την κάλυψη του ενεργειακού φορτίου. Σε συνεργασία με τα συστήματα ΑΠΕ, η αλλαγή του εξοπλισμού με νεότερης γενιάς (πχ. λάμπες LED) για την μείωση του απαιτούμενου ενεργειακού φορτίου, πέραν της εξοικονόμησης ενέργειας και του χρηματικού

κόστους αγοράς αυτής, βοηθά στην μείωση του CO_{2eq} και των υπολοίπων αερίων θερμοκηπίου κατά την παραγωγή της ηλεκτρικής ενέργειας. Τέλος, η δημιουργία μεγάλων βάσεων δεδομένων, η ανάλυση μεγάλων δεδομένων και η εξόρυξη δεδομένων αναμένεται να αποτελέσουν σημαντικό εργαλείο στον βραχυπρόθεσμο και μακροπρόθεσμο στρατηγικό σχεδιασμό δημόσιων και ιδιωτικών φορέων.

5.2 Προτάσεις για το μέλλον

Ως προς μελλοντική έρευνα σχετικά με το αντικείμενο μελέτης προτείνονται τα εκατέρωθεν:

- Περαιτέρω έρευνα στο κομμάτι των μοντέλων πρόβλεψης – χρήση και άλλων υπαρχόντων μοντέλων
- Δοκιμές χρήσεις πιο περίπλοκων μοντέλων τεχνητών νευρωνικών δικτύων και αλγορίθμων μηχανικής μάθησης
- Χρήση υβριδικών μοντέλων πρόβλεψης
- Δημιουργία καλύτερων και πιο αξιόπιστων βάσεων δεδομένων για μελλοντικές έρευνες
- Επανεξέταση της συγκεκριμένης περίπτωσης το 2025 με ακόμα περισσότερα δεδομένα και τυχόν νέες τεχνικές πρόβλεψης
- Μελέτη εισαγωγής συστημάτων ΑΠΕ για την κάλυψη της ενεργειακής απαίτησης και συστημάτων αποθήκευσης ενέργειας για την αποθήκευση της περίσσειας παραγόμενης ενέργειας, όταν αυτή δεν χρειάζεται
- Μελέτη χρήσης ‘έξυπνων’ συστημάτων και για την μείωση του ενεργειακού φορτίου
- Διεξαγωγή έρευνας και ευαισθητοποίηση της κοινωνίας της περιοχής μελέτης σχετικά με την ενεργειακή αναβάθμιση του λιμένα
- Διεξαγωγή παρόμοιων ερευνών και σε άλλους λιμένες για πιθανόν δημιουργία εθνικού σχεδίου σχετικά με τις ενεργειακές απαιτήσεις και την κάλυψη αυτών, για συμμόρφωση απέναντι στους παγκόσμιους και ευρωπαϊκούς κανονισμούς

6. Βιβλιογραφία

- [1] C. From and T. H. E. Commission, "European Commission Communication from the commission-ports: An engine for growth-COM (2013) 295 final; 2014," 2013.
- [2] U. S. Committee and M. Transportation, "Marine Transportation System Performance Measures Executive Summary."
- [3] C. Grammenos, *The Handbook of Maritime Economics and Business*. Taylor & Francis, 2013.
- [4] J. P. Rodrigue, *The Geography of Transport Systems*. Taylor & Francis, 2020.
- [5] E. van Hassel, H. Meersman, E. Van de Voorde, and T. Vanelander, "North-South container port competition in Europe: The effect of changing environmental policy," *Res. Transp. Bus. Manag.*, vol. 19, no. 2013, pp. 4–18, 2016.
- [6] T. E. Notteboom, "Concentration and the formation of multi-port gateway regions in the European container port system: An update," *J. Transp. Geogr.*, vol. 18, no. 4, pp. 567–583, 2010.
- [7] C. Zhao, Y. Wang, Y. Gong, S. Brown, and R. Li, "The evolution of the port network along the Maritime Silk Road: From a sustainable development perspective," *Mar. Policy*, vol. 126, p. 104426, 2021.
- [8] C. Paris, "China's Cosco Pours More Money Into Greek Port," *The Wall Street Journal*, 2019.
- [9] "Lloyd's List - One Hundred Ports 2019," *Maritime Intelligence*, 2019. [Online]. Available: <https://lloydslist.maritimeintelligence.informa.com/one-hundred-container-ports-2019/>.
- [10] "ΕΒΕΠ: Κομβική η θέση του Πειραιά στον θαλάσσιο «Δρόμο του Μεταξιού»." [Online]. Available: <https://portnet.gr/main-article/17473-evep-komvikh-h-thesi-tou-peiraia-ston-thalassio-dromo-tou-metaxiou.html>.
- [11] J. Siu, L. Lam, and K. X. Li, "Green port marketing for sustainable growth and development," *Transp. Policy*, vol. 84, no. December 2018, pp. 73–81, 2019.
- [12] Ł. Marzantowicz, "The Reasons for the Implementation of the Concept of Green Port in Sea Ports of China," pp. 121–128.
- [13] A. Almutairi, Z. A. Collier, D. Hendrickson, J. M. Palma-Oliveira, T. L. Polmateer, and J. H. Lambert, "Stakeholder mapping and disruption scenarios with application to resilience of a container port," *Reliab. Eng. Syst. Saf.*, vol. 182, pp. 219–232, 2019.
- [14] M.-H. Ha, Z. Yang, and J. S. L. Lam, "Port performance in container transport logistics: A multi-stakeholder perspective," *Transp. Policy*, vol. 73, pp. 25–40, 2019.
- [15] C. Aveta and C. Romano, "A port planning study case: the freight strategy of the new Central Tyrrhenian Sea Port Authority 2017-2020," *Transp. Res. Procedia*, vol. 45, pp. 127–134, 2020.
- [16] T. Yoshitani, "PNW Seaport Alliance: Stakeholder's benefits of port cooperation," *Res. Transp. Bus. Manag.*, vol. 26, pp. 14–17, 2018.
- [17] A. Chamorro, S. Rubio, and F. J. Miranda, "Characteristics of Research on Green Marketing," vol. 239, no. April 2007, pp. 223–239, 2009.
- [18] R. M. Dangelico and D. Vocalelli, "'Green Marketing': An analysis of definitions, strategy steps, and tools through a systematic review of the literature," *J. Clean. Prod.*, vol. 165, pp. 1263–1279, 2017.
- [19] D. Anastasopoulou, S. Kolios, and C. Stylios, "How will Greek Ports become Green Ports?," *Geo-Eco Mar.*, vol. 17, pp. 73–80, 2011.
- [20] Y.-T. Chang, "Environmental efficiency of ports: a Data Envelopment Analysis approach," *Marit. Policy Manag.*, vol. 40, no. 5, pp. 467–478, 2013.
- [21] C.-F. Shao, M.-T. Ju, J.-L. Yu, C.-J. Hu, and C.-L. Chu, "The strategies and proposals for ecological port construction in China," *J. US-China Public Adm.*, vol. 6, no. 7, pp. 23–33, 2009.
- [22] P. Norvig, *Artificial Intelligence*. .

- [23] “Πανεπιστήμιο Πατρών Σχολή Θετικών Επιστημών Τμήμα Μαθηματικών Αλγόριθμοι μηχανικής μάθησης και εφαρμογές σε ιατροβιολογικά προβλήματα Προπτυχιακή Διπλωματική Εργασία Αναστασίου Ευτυχία Επιβλέπων Καθηγητής : Κωτσιαντής Σωτήριος Σεπτέμβριος 2019,” 2019.
- [24] “Machine-Learning-Tom-Mitchell.pdf.” .
- [25] E. Alpaydin, “Introduction to Machine Learning,” *Introduction to Machine Learning*, vol. 111, no. 479. pp. 1009–1010, 1965.
- [26] “Neuron image.” [Online]. Available: https://www.freepik.com/premium-photo/illustration-brain-neurons-structure_10757113.htm#page=1&query=neurons&position=30.
- [27] R. A. Pielke Jr, “The role of models in prediction for decision,” *Model. Ecosyst. Sci.*, pp. 111–135, 2003.
- [28] Ε. Καπτή, “Μοντέλα πρόβλεψης. Θεωρητική επισκόπηση και εφαρμογές,” Σχολή Μηχανικών Παραγωγής και Διοίκησης, Στρατιωτική Σχολή Ευελπίδων, Πολυτεχνείο Κρήτης, Χανιά, 2018.
- [29] I. Ghalekhondabi, E. Ardjmand, G. R. Weckman, and W. A. Young, *An overview of energy demand forecasting methods published in 2005–2015*, vol. 8, no. 2. 2017.
- [30] A. Kazemi, A. F. A. and M. Hosseinzadeh, “A Multi-Level Fuzzy Linear Regression Model for Forecasting Industry Energy Demand of Iran,” *Procedia - Soc. Behav. Sci.*, vol. 41, pp. 342–348, 2012.
- [31] M. De Felice, A. Alessandri, and P. M. Ruti, “Electricity demand forecasting over Italy: Potential benefits using numerical weather prediction models,” *Electr. Power Syst. Res.*, vol. 104, pp. 71–79, 2013.
- [32] “Nearly-Zero-Energy-Ports-A-necessity-or-a-green-upgrade2020IOP-Conference-Series-Earth-and-Environmental-Science.pdf.” .
- [33] “Λιμενικό ταμείο Χανίων.” [Online]. Available: <https://www.ltnx.gr/>.
- [34] “Εθνικό Αστεροσκοπείο Αθηνών.” [Online]. Available: <https://www.iersd.noa.gr/GR/>.
- [35] A. G. Parlos, E. Oufi, J. Muthusami, A. D. Patton, and A. F. Atiya, “Development of an intelligent long-term electric load forecasting system,” *Proc. Int. Conf. Intell. Syst. Appl. to Power Syst. ISAP*, no. 3, pp. 288–292, 1996.
- [36] T. Al-Saba and I. El-Amin, “Artificial neural networks as applied to long-term demand forecasting,” *Artif. Intell. Eng.*, vol. 13, no. 2, pp. 189–197, 1999.
- [37] K. Padmakumari, K. P. Mohandas, and S. Thiruvengadam, “Long term distribution demand forecasting using neuro fuzzy computations,” *Int. J. Electr. Power Energy Syst.*, vol. 21, no. 5, pp. 315–322, 1999.
- [38] C. Hamzaçebi, “Forecasting of Turkey’s net electricity energy consumption on sectoral bases,” *Energy Policy*, vol. 35, no. 3. pp. 2009–2016, 2007.
- [39] E. González-Romera, M. Á. Jaramillo-Morán, and D. Carmona-Fernández, “Forecasting of the electric energy demand trend and monthly fluctuation with neural networks,” *Computers and Industrial Engineering*, vol. 52, no. 3. pp. 336–343, 2007.
- [40] L. Ekonomou, “Greek long-term energy consumption prediction using artificial neural networks,” *Energy*, vol. 35, no. 2. pp. 512–517, 2010.
- [41] L. Suganthi and A. A. Samuel, “Energy models for demand forecasting—A review,” *Renew. Sustain. Energy Rev.*, vol. 16, no. 2, pp. 1223–1240, 2012.
- [42] S. Jurado, À. Nebot, F. Mugica, and N. Avellana, “Hybrid methodologies for electricity load forecasting: Entropy-based feature selection with machine learning and soft computing techniques,” *Energy*, vol. 86, pp. 276–291, 2015.
- [43] C. Robinson *et al.*, “Machine learning approaches for estimating commercial building energy consumption,” *Applied Energy*, vol. 208. pp. 889–904, 2017.
- [44] H. Hamedmoghadam, N. Joorabloo, and M. Jalili, “Australia’s long-term electricity demand forecasting using deep neural networks,” *arXiv Prepr. arXiv1801.02148*, 2018.
- [45] A. Rahman, V. Srikumar, and A. D. Smith, “Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks,” *Appl.*

- Energy*, vol. 212, pp. 372–385, 2018.
- [46] J. Moon, S. Park, S. Rho, and E. Hwang, “A comparative analysis of artificial neural network architectures for building energy consumption forecasting,” *Int. J. Distrib. Sens. Networks*, vol. 15, no. 9, 2019.
 - [47] D. Kontogiannis, D. Bargiotas, and A. Daskalopulu, “Minutely active power forecasting models using neural networks,” *Sustain.*, vol. 12, no. 8, p. 3177, 2020.
 - [48] M. Kalimoldayev, A. Drozdenko, I. Koplyk, T. Marinich, A. Abdildayeva, and T. Zhukabayeva, “Analysis of modern approaches for the prediction of electric energy consumption,” *Open Eng.*, vol. 10, no. 1, pp. 350–361, 2020.
 - [49] H. Son and C. Kim, “A deep learning approach to forecasting monthly demand for residential-sector electricity,” *Sustain.*, vol. 12, no. 8, p. 3103, 2020.
 - [50] E. Vivas, H. Allende-Cid, and R. Salas, “A systematic review of statistical and machine learning methods for electrical power forecasting with reported mape score,” *Entropy*, vol. 22, no. 12, pp. 1–24, 2020.
 - [51] L. Cao, Y. Li, J. Zhang, Y. Jiang, Y. Han, and J. Wei, “Electrical load prediction of healthcare buildings through single and ensemble learning,” *Energy Reports*, vol. 6, pp. 2751–2767, 2020.
 - [52] A. J. Del Real, F. Dorado, and J. Durán, “Energy demand forecasting using deep learning: Applications for the French grid,” *Energies*, vol. 13, no. 9, 2020.
 - [53] M. K. M. Shapi, N. A. Ramli, and L. J. Awalin, “Energy consumption prediction by using machine learning for smart building: Case study in Malaysia,” *Dev. Built Environ.*, vol. 5, no. July 2020, p. 100037, 2021.
 - [54] Y. Peng, H. Liu, X. Li, J. Huang, and W. Wang, “Machine learning method for energy consumption prediction of ships in port considering green ports,” *Journal of Cleaner Production*, vol. 264, 2020.
 - [55] “European Statistics.” [Online]. Available: <https://ec.europa.eu/eurostat>.
 - [56] “Ελληνική Στατιστική Αρχή - ΕΛΣΤΑΤ.” [Online]. Available: <https://www.statistics.gr/>.
 - [57] “World Bank Group.” [Online]. Available: <https://www.worldbank.org/en/home>.
 - [58] “Global Solar Atlas.” [Online]. Available: <https://globalsolaratlas.info/map>.
 - [59] “Global Wind Atlas.” [Online]. Available: <https://globalwindatlas.info/>.
 - [60] Γ. Μαργιά, “Ανάλυση και Πρόβλεψη Χρονοσειρών,” Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης, Σχολή Θετικών Επιστημών, Τμήμα Φυσικής, 2009.
 - [61] J. Bell, *Machine learning: hands-on for developers and technical professionals*. John Wiley & Sons, 2020.
 - [62] L. Breiman, “Bagging predictors,” *Mach. Learn.*, vol. 24, no. 2, pp. 123–140, 1996.
 - [63] A. Ben-Hur and J. Weston, “A user’s guide to support vector machines,” in *Data mining techniques for the life sciences*, Springer, 2010, pp. 223–239.
 - [64] “An Introduction to Support Vector Regression (SVR).” [Online]. Available: <https://towardsdatascience.com/an-introduction-to-support-vector-regression-svr-a3ebc1672c2>.
 - [65] J. Joyce, “Bayes’ theorem,” 2003.
 - [66] J. Quinonero-Candela, C. E. Rasmussen, and C. K. I. Williams, “Approximation methods for Gaussian process regression,” in *Large-scale kernel machines*, MIT Press, 2007, pp. 203–223.
 - [67] “Quick Start to Gaussian Process Regression.” [Online]. Available: <https://towardsdatascience.com/quick-start-to-gaussian-process-regression-36d838810319>.
 - [68] D. Opitz and R. Maclin, “□□ Popular Ensemble Methods,” vol. 1, 1999.
 - [69] Α. Γεωργούλη, “Μηχανική Μάθηση,” 2015.
 - [70] “Meteonorm.” [Online]. Available: <https://meteonorm.com/en/>.
 - [71] “IPCC.” [Online]. Available: <https://www.ipcc.ch/>.
 - [72] “Renewable and Sustainable Energy Systems Lab.” [Online]. Available: <http://www.resel.tuc.gr/>.
 - [73] “Auto.ARIMA.” [Online]. Available: <https://otexts.com/fpp2/arima-r.html>.
 - [74] R. J. Hyndman and Y. Khandakar, “Automatic Time Series Forecasting: The

- forecast Package for R,” *J. Stat. Software, Artic.*, vol. 27, no. 3, pp. 1–22, 2008.
- [75] “K-fold Cross Validation.” [Online]. Available:
<https://medium.datadriveninvestor.com/k-fold-cross-validation-6b8518070833>.
- [76] C. M. Bishop and others, *Neural networks for pattern recognition*. Oxford university press, 1995.

7. Παράρτημα

Στο **Σχήμα 11** και **Σχήμα 12** αποτυπώνονται οι κώδικες που **εξάγονται** από την **MATLAB®** για την δημιουργία του καλύτερου μοντέλου μηχανικής μάθησης και των τεχνητών νευρωνικών δικτύων.

```
function [trainedModel, validationRMSE] =  
trainRegressionModel(trainingData)  
  
% This code processes the data into the right shape for training the  
%model.  
inputTable = trainingData;  
predictorNames = {'Period', 'Hour', 'Temp', 'Hum', 'Dewp', 'Pres',  
'Precip', 'WindSpeed', 'SolRad'};  
predictors = inputTable(:, predictorNames);  
response = inputTable.Energy_Hourly;  
isCategoricalPredictor = [false, false, false, false, false, false,  
false, false, false];  
  
% Train a regression model  
% This code specifies all the model options and trains the model.  
regressionGP = fitrgp(...  
    predictors, ...  
    response, ...  
    'BasisFunction', 'constant', ...  
    'KernelFunction', 'exponential', ...  
    'Standardize', true);  
  
predictorExtractionFcn = @(t) t(:, predictorNames);  
gpPredictFcn = @(x) predict(regressionGP, x);  
trainedModel.predictFcn = @(x) gpPredictFcn(predictorExtractionFcn(x));  
  
% Perform cross-validation  
partitionedModel = crossval(trainedModel.RegressionGP, 'KFold', 5);  
  
% Compute validation predictions  
validationPredictions = kfoldPredict(partitionedModel);  
  
% Compute validation RMSE  
validationRMSE = sqrt(kfoldLoss(partitionedModel, 'LossFun', 'mse'));  
  
% To make predictions with the returned 'trainedModel' on new data T2,  
use  
% T2= readtable('new_data.xlsx');  
% yfit = trainedModel.predictFcn(T2);
```

Σχήμα 11. Κώδικας MATLAB για την δημιουργία του μοντέλου μηχανικής μάθησης.

```

% Solve an Input-Output Fitting problem with a Neural Network
% Script generated by Neural Fitting app

%   inputH - input data.
%   targetH - target data.

x = inputH;
t = targetH;

trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.

% Create a Fitting Network
hiddenLayerSize = 27;
net = fitnet(hiddenLayerSize,trainFcn);

% Setup Division of Data for Training, Validation, Testing
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'sample'; % Divide up every sample
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Choose a Performance Function
net.performFcn = 'mse'; % Mean Squared Error

% Choose Plot Functions
net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...
    'plotregression', 'plotfit'};

% Train the Network
[net,tr] = train(net,x,t);

% Test the Network
y = net(x);
e = gsubtract(t,y);
performance = perform(net,t,y)

% View the Network
view(net)

% Make new predictions
Xpred = predH;
Ypred = net(Xpred);

```

Σχήμα 12. Κώδικας MATLAB για την δημιουργία του μοντέλου τεχνητών νευρωνικών δικτύων.

Στο **Σχήμα 13** αποτυπώνεται ο κώδικας για την δημιουργία του μοντέλο ARIMA στην εφαρμογή **R studio** σύμφωνα με την συνάρτηση **auto.arima()** .

```
#Auto Arima Forecasting in R #

install.packages("forecast")
library(readxl)
library(forecast)

#Load the dataset from Excel using readxl
data <-
read_xlsx("F:/Users/User_name/Desktop/CHQ_models/Timeseries/Auto.Arima/data.xlsx")
#file location

#Use ts() function to place in time-series format
tsdata <- ts(data$Energy,frequency=12,start=c(2015,1))

# auto.arima() function to get the optimal arima model
autoarima1<-auto.arima(tsdata)
summary(autoarima1)

# Forecasts for 2030
forecast1 <- forecast(autoarima1, h=132)

#Show forecasted values
forecast1

#plot the forecasted data from the auto arima model
plot(forecast1)

#plot the residuals over time to see congruence or variance
plot(forecast1$residuals)

#plot the residuals (sample vs. theoretical)
acf(forecast1$residuals)
pacf(forecast1$residuals)
```

Σχήμα 13. Κώδικας R συνάρτησης auto.arima() .

Στον **Πίνακα 40** παρουσιάζονται οι τιμές κατανάλωσης ηλεκτρικής ενέργειας για το 2030, του λιμένα Σούδας, σύμφωνα με το μοντέλο H-ML, αναγόμενες σε ημερήσια βάση.

Πίνακας 40. Ημερήσιες προβλεπόμενες καταναλώσεις ηλεκτρικής ενέργειας για το 2030.

Ημέρα	kWh	Ημέρα	kWh	Ημέρα	kWh	Ημέρα	kWh
1/1/2030	2.824,35	13/4/2030	2.699,27	24/7/2030	2.485,31	3/11/2030	2.966,62
2/1/2030	2.853,49	14/4/2030	2.760,41	25/7/2030	2.532,04	4/11/2030	2.964,70
3/1/2030	3.007,72	15/4/2030	2.867,22	26/7/2030	2.552,95	5/11/2030	2.905,32
4/1/2030	2.953,96	16/4/2030	2.670,40	27/7/2030	2.544,25	6/11/2030	2.850,73
5/1/2030	3.068,82	17/4/2030	2.676,37	28/7/2030	2.540,21	7/11/2030	2.886,31
6/1/2030	3.146,90	18/4/2030	2.919,41	29/7/2030	2.571,41	8/11/2030	2.932,38
7/1/2030	3.087,72	19/4/2030	2.914,19	30/7/2030	2.511,01	9/11/2030	2.973,17
8/1/2030	3.023,26	20/4/2030	2.842,28	31/7/2030	2.509,25	10/11/2030	2.986,45
9/1/2030	3.074,60	21/4/2030	3.001,23	1/8/2030	2.504,03	11/11/2030	2.853,58
10/1/2030	3.199,29	22/4/2030	2.728,42	2/8/2030	2.564,01	12/11/2030	2.851,38
11/1/2030	3.097,89	23/4/2030	2.731,96	3/8/2030	2.494,23	13/11/2030	3.064,76
12/1/2030	3.328,74	24/4/2030	2.723,72	4/8/2030	2.657,67	14/11/2030	3.102,50
13/1/2030	3.351,39	25/4/2030	2.895,33	5/8/2030	2.574,96	15/11/2030	2.932,10
14/1/2030	3.233,11	26/4/2030	2.655,53	6/8/2030	2.589,97	16/11/2030	2.908,73
15/1/2030	3.098,32	27/4/2030	2.659,85	7/8/2030	2.545,08	17/11/2030	2.948,31
16/1/2030	3.107,83	28/4/2030	2.708,18	8/8/2030	2.500,86	18/11/2030	2.999,52
17/1/2030	3.268,23	29/4/2030	3.027,04	9/8/2030	2.609,87	19/11/2030	2.858,63
18/1/2030	3.257,55	30/4/2030	2.934,60	10/8/2030	2.572,04	20/11/2030	2.962,67
19/1/2030	3.137,37	1/5/2030	2.802,84	11/8/2030	2.510,27	21/11/2030	3.117,23
20/1/2030	3.082,64	2/5/2030	2.710,55	12/8/2030	2.566,23	22/11/2030	3.005,88
21/1/2030	2.994,18	3/5/2030	2.709,78	13/8/2030	2.600,49	23/11/2030	2.946,63
22/1/2030	2.959,57	4/5/2030	2.574,87	14/8/2030	2.613,23	24/11/2030	3.215,76
23/1/2030	3.118,15	5/5/2030	2.750,59	15/8/2030	2.539,03	25/11/2030	3.172,41
24/1/2030	3.120,40	6/5/2030	2.665,79	16/8/2030	2.572,26	26/11/2030	3.048,08
25/1/2030	3.077,26	7/5/2030	2.807,87	17/8/2030	2.566,50	27/11/2030	2.931,51
26/1/2030	2.985,20	8/5/2030	2.802,47	18/8/2030	2.527,19	28/11/2030	3.100,07
27/1/2030	3.118,94	9/5/2030	2.837,19	19/8/2030	2.515,17	29/11/2030	3.205,76
28/1/2030	3.033,66	10/5/2030	2.852,25	20/8/2030	2.514,37	30/11/2030	3.015,48
29/1/2030	3.016,08	11/5/2030	2.696,02	21/8/2030	2.560,53	1/12/2030	2.960,05
30/1/2030	3.120,83	12/5/2030	2.619,31	22/8/2030	2.612,26	2/12/2030	3.181,05
31/1/2030	2.896,03	13/5/2030	2.571,20	23/8/2030	2.600,31	3/12/2030	2.961,18
1/2/2030	2.855,16	14/5/2030	2.582,66	24/8/2030	2.687,35	4/12/2030	3.133,43
2/2/2030	3.084,10	15/5/2030	2.667,32	25/8/2030	2.793,64	5/12/2030	3.083,35
3/2/2030	3.201,91	16/5/2030	2.696,48	26/8/2030	2.671,62	6/12/2030	2.914,09
4/2/2030	3.379,73	17/5/2030	2.624,61	27/8/2030	2.518,33	7/12/2030	2.876,67
5/2/2030	3.085,99	18/5/2030	2.572,02	28/8/2030	2.634,84	8/12/2030	2.948,69
6/2/2030	3.183,38	19/5/2030	2.505,83	29/8/2030	2.676,34	9/12/2030	2.995,10
7/2/2030	3.217,71	20/5/2030	2.498,81	30/8/2030	2.626,39	10/12/2030	2.956,56
8/2/2030	3.290,67	21/5/2030	2.499,57	31/8/2030	2.594,88	11/12/2030	3.062,72
9/2/2030	3.375,79	22/5/2030	2.510,26	1/9/2030	2.552,08	12/12/2030	3.203,44
10/2/2030	3.195,41	23/5/2030	2.511,91	2/9/2030	2.697,01	13/12/2030	3.292,27
11/2/2030	3.119,45	24/5/2030	2.532,99	3/9/2030	2.980,23	14/12/2030	3.174,13
12/2/2030	3.001,26	25/5/2030	2.567,53	4/9/2030	2.934,76	15/12/2030	3.074,24
13/2/2030	3.117,24	26/5/2030	2.537,30	5/9/2030	2.599,00	16/12/2030	3.103,74
14/2/2030	3.268,19	27/5/2030	2.508,49	6/9/2030	2.690,48	17/12/2030	3.218,13
15/2/2030	3.169,43	28/5/2030	2.517,04	7/9/2030	2.586,03	18/12/2030	3.052,81
16/2/2030	2.846,65	29/5/2030	2.556,15	8/9/2030	2.727,81	19/12/2030	3.229,98
17/2/2030	2.852,45	30/5/2030	2.536,54	9/9/2030	2.651,15	20/12/2030	2.993,29
18/2/2030	2.927,23	31/5/2030	2.515,69	10/9/2030	2.676,34	21/12/2030	3.188,73

19/2/2030	2.958,97	1/6/2030	2.677,61	11/9/2030	2.853,73	22/12/2030	3.128,60
20/2/2030	2.813,63	2/6/2030	2.715,98	12/9/2030	2.990,44	23/12/2030	3.251,65
21/2/2030	2.734,20	3/6/2030	2.645,15	13/9/2030	2.602,65	24/12/2030	3.287,44
22/2/2030	2.767,07	4/6/2030	2.524,66	14/9/2030	2.615,34	25/12/2030	3.298,73
23/2/2030	3.282,86	5/6/2030	2.554,58	15/9/2030	2.801,14	26/12/2030	3.194,30
24/2/2030	2.923,42	6/6/2030	2.515,28	16/9/2030	2.670,52	27/12/2030	3.266,90
25/2/2030	2.827,95	7/6/2030	2.499,40	17/9/2030	2.693,05	28/12/2030	3.199,36
26/2/2030	2.947,21	8/6/2030	2.514,91	18/9/2030	2.689,67	29/12/2030	3.141,89
27/2/2030	2.896,07	9/6/2030	2.515,32	19/9/2030	2.593,57	30/12/2030	3.062,19
28/2/2030	3.048,99	10/6/2030	2.489,03	20/9/2030	2.598,49	31/12/2030	3.317,32
1/3/2030	2.871,61	11/6/2030	2.496,52	21/9/2030	2.670,23		
2/3/2030	2.859,24	12/6/2030	2.546,43	22/9/2030	2.919,19		
3/3/2030	2.866,32	13/6/2030	2.528,06	23/9/2030	2.701,04		
4/3/2030	2.922,39	14/6/2030	2.447,18	24/9/2030	2.569,27		
5/3/2030	3.152,15	15/6/2030	2.507,16	25/9/2030	2.646,76		
6/3/2030	2.881,01	16/6/2030	2.483,04	26/9/2030	2.693,81		
7/3/2030	2.847,40	17/6/2030	2.532,04	27/9/2030	2.744,25		
8/3/2030	2.988,90	18/6/2030	2.612,76	28/9/2030	2.787,83		
9/3/2030	3.244,52	19/6/2030	2.471,76	29/9/2030	2.795,32		
10/3/2030	3.098,17	20/6/2030	2.419,73	30/9/2030	2.754,15		
11/3/2030	2.925,09	21/6/2030	2.480,85	1/10/2030	2.680,33		
12/3/2030	2.955,81	22/6/2030	2.517,26	2/10/2030	2.672,03		
13/3/2030	2.823,39	23/6/2030	2.576,71	3/10/2030	2.754,84		
14/3/2030	3.127,25	24/6/2030	2.495,14	4/10/2030	2.771,73		
15/3/2030	3.003,08	25/6/2030	2.562,30	5/10/2030	2.902,66		
16/3/2030	2.971,36	26/6/2030	2.699,89	6/10/2030	2.676,01		
17/3/2030	2.664,30	27/6/2030	2.780,74	7/10/2030	2.859,56		
18/3/2030	2.781,35	28/6/2030	2.486,62	8/10/2030	2.987,03		
19/3/2030	2.786,84	29/6/2030	2.492,23	9/10/2030	2.755,36		
20/3/2030	2.754,44	30/6/2030	2.591,90	10/10/2030	2.899,52		
21/3/2030	2.746,35	1/7/2030	2.563,04	11/10/2030	2.846,31		
22/3/2030	2.766,13	2/7/2030	2.592,65	12/10/2030	2.766,00		
23/3/2030	3.059,98	3/7/2030	2.655,41	13/10/2030	2.792,24		
24/3/2030	3.045,07	4/7/2030	2.575,57	14/10/2030	2.762,97		
25/3/2030	3.077,96	5/7/2030	2.480,11	15/10/2030	2.803,16		
26/3/2030	3.140,35	6/7/2030	2.477,36	16/10/2030	2.972,60		
27/3/2030	3.057,06	7/7/2030	2.441,58	17/10/2030	2.922,16		
28/3/2030	2.907,54	8/7/2030	2.452,33	18/10/2030	2.799,06		
29/3/2030	2.802,44	9/7/2030	2.427,59	19/10/2030	2.929,96		
30/3/2030	2.726,03	10/7/2030	2.421,24	20/10/2030	2.978,20		
31/3/2030	2.641,35	11/7/2030	2.484,24	21/10/2030	2.880,84		
1/4/2030	2.716,37	12/7/2030	2.687,01	22/10/2030	2.887,28		
2/4/2030	2.754,83	13/7/2030	2.481,68	23/10/2030	3.045,87		
3/4/2030	2.708,74	14/7/2030	2.565,23	24/10/2030	3.066,91		
4/4/2030	2.692,07	15/7/2030	2.540,00	25/10/2030	3.033,12		
5/4/2030	2.687,49	16/7/2030	2.493,29	26/10/2030	2.909,17		
6/4/2030	3.023,68	17/7/2030	2.520,77	27/10/2030	2.985,27		
7/4/2030	2.698,78	18/7/2030	2.592,22	28/10/2030	2.900,03		
8/4/2030	2.599,39	19/7/2030	2.619,56	29/10/2030	2.893,59		
9/4/2030	2.646,43	20/7/2030	2.508,24	30/10/2030	2.887,85		
10/4/2030	2.563,74	21/7/2030	2.535,73	31/10/2030	3.065,70		
11/4/2030	2.567,14	22/7/2030	2.593,42	1/11/2030	3.139,66		
12/4/2030	2.596,79	23/7/2030	2.486,97	2/11/2030	3.019,72		