



Πολυτεχνείο
Κρήτης

**ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ & ΜΗΧΑΝΙΚΩΝ
ΥΠΟΛΟΓΙΣΤΩΝ**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**ΝΕΥΡΟ-ΑΣΑΦΕΙΣ ΤΕΧΝΙΚΕΣ ΠΡΟΒΛΕΨΗΣ ΠΑΡΑΓΩΓΗΣ
ΕΝΕΡΓΕΙΑΣ**

Πέτικας Βασίλειος



Εξεταστική Επιτροπή

Καθηγητής Σταυρακάκης Γεώργιος (επιβλέπων)

Αναπληρωτής Καθηγητής Ατσαλάκης Γεώργιος

Καθηγητής Κουτρούλης Ευτύχιος

Χανιά, Ιούλιος 2024

Ευχαριστίες

Θα ήθελα να ευχαριστήσω θερμά πρώτα απ' όλα τον καθηγητή μου κ. Γεώργιο Σταυρακάκη, για τις διαρκείς συμβουλές, καθώς και την υποστήριξη και υπομονή του κατά τη διάρκεια ολοκλήρωσης αυτής της διπλωματικής εργασίας. Η συνεισφορά του ήταν κρίσιμη για την πρόοδο αυτού του ερευνητικού έργου, ιδιαίτερα στη διαμόρφωση των υπό εξέταση αλγορίθμων και στη δομή της παρούσας εργασίας, παρέχοντας πολύτιμες παρατηρήσεις και οδηγίες ανά τακτά χρονικά διαστήματα.

Θα ήθελα επίσης να ευχαριστήσω τα μέλη της εξεταστικής επιτροπής, Καθηγητές κ. Γεώργιο Ατσαλάκη και κ. Ευύχιο Κουτρούλη για την τιμή που μου έκαναν αξιολογώντας την διπλωματική μου εργασία, καθώς και για το πάθος τους κατά τη διάρκεια των διαλέξεων, βοηθώντας τους φοιτητές να κατανοήσουν αποτελεσματικά το αντίστοιχο ερευνητικό τους πεδίο.

Τέλος, θα ήθελα να ευχαριστήσω την οικογένειά μου και τους φίλους μου, που έδειξαν τεράστια κατανόηση, ενθάρρυνση και με υποστήριξαν καθ' όλη τη διάρκεια των σπουδών μου. Η συνεχής παρουσία και υποστήριξή τους μου έδωσαν τη δύναμη να συνεχίσω και να φέρω εις πέρας αυτή τη διπλωματική εργασία.

Περίληψη

Η αυξημένη ζήτηση για καθαρές και βιώσιμες πηγές ενέργειας, σε συνδυασμό με τις ανησυχίες για την κλιματική αλλαγή και τη μείωση των ορυκτών καυσίμων, έχει οδηγήσει στην προώθηση των ανανεώσιμων πηγών ενέργειας (ΑΠΕ) ως βασικό στόχο της παγκόσμιας ενεργειακής πολιτικής. Η στροφή προς τις ανανεώσιμες πηγές, όπως η ηλιακή, η αιολική και η υδροηλεκτρική ενέργεια, κρίνεται αναγκαία για τη μείωση των εκπομπών αερίων θερμοκηπίου, την ενίσχυση της ενεργειακής ασφάλειας και την επίτευξη βιώσιμης ανάπτυξης.

Σε αυτό το πλαίσιο, η παρούσα διπλωματική εργασία εξετάζει την εφαρμογή νευρο-ασαφών τεχνικών, ειδικότερα του Προσαρμοστικού Νευρο-Ασαφούς Συστήματος Συμπερασμού (ANFIS), για την εκτίμηση της παραγωγής ενέργειας από Φωτοβολταϊκά.

Ο στόχος της μελέτης είναι να αντιμετωπίσει τις προκλήσεις που ανακύπτουν από την αυξανόμενη ενσωμάτωση των ΑΠΕ στο ηλεκτρικό δίκτυο, καθώς απαιτεί ακριβείς και αξιόπιστες μεθόδους εκτίμησης για τη διασφάλιση της σταθερότητας και της αποδοτικότητας του δικτύου. Η πρόβλεψη της απόδοσης των ΑΠΕ είναι κρίσιμη λόγω της ασταθούς και απρόβλεπτης φύσης τους. Τα ηλεκτρικά δίκτυα χρειάζονται σταθερή και αξιόπιστη παροχή ενέργειας, και η ακριβής εκτίμηση μπορεί να μειώσει τους κινδύνους και τα κόστη που σχετίζονται με την αποθήκευση ή την αναπλήρωση ενέργειας.

Η μεθοδολογία περιλαμβάνει τη συλλογή και επεξεργασία ιστορικών δεδομένων παραγωγής ενέργειας από φωτοβολταϊκά συστήματα, ακολουθούμενη από την ανάπτυξη και εκπαίδευση του μοντέλου ANFIS. Το μοντέλο αυτό συγκρίνεται με παραδοσιακές στατιστικές μεθόδους όπως τα μοντέλα Αυτοπαλινδρόμησης (AR) και Αυτοπαλινδρόμησης Κινούμενου Μέσου (ARMA), καθώς και με ένα Τεχνητό Νευρωνικό Δίκτυο (ANN) και ένα Ασαφές Σύστημα Συμπερασμού Τύπου-2 (Type-2 FIS), βελτιστοποιημένο με χρήση του Σμήνους Σωματιδίων (PSO).

Τα αποτελέσματα δείχνουν ότι το ANFIS υπερτερεί έναντι των επιλεγμένων μοντέλων όσον αφορά την ακρίβεια των προβλέψεων και την προσαρμοστικότητα σε μεταβαλλόμενες περιβαλλοντικές συνθήκες. Η μελέτη καταλήγει στο συμπέρασμα ότι

η ενσωμάτωση ευφυών συστημάτων όπως το ANFIS μπορεί να βελτιώσει σημαντικά την ακρίβεια και την αξιοπιστία των εκτιμήσεων παραγωγής από ΑΠΕ, διευκολύνοντας έτσι την αποδοτική και σταθερή ενσωμάτωσή τους στο ενεργειακό δίκτυο.

Αυτή η έρευνα συνεισφέρει στον τομέα της Ενέργειας και παρέχει μια ολοκληρωμένη συγκριτική ανάλυση διαφόρων μοντέλων εκτίμησης. Επιπλέον, αναδεικνύει τα πλεονεκτήματα των νευρο-ασαφών τεχνικών στη διαχείριση της μεταβλητότητας και της αβεβαιότητας που συνδέονται με τις ΑΠΕ. Τα ευρήματα καταδεικνύουν τη δυναμική του ANFIS ως ένα ισχυρό εργαλείο για την εκτίμηση παραγωγής ενέργειας, προωθώντας έτσι την ανάπτυξη και υιοθέτηση τεχνολογιών που σχετίζονται με τις ΑΠΕ.

Λέξεις – Κλειδιά

ANFIS Μοντέλο, Νευρο-Ασαφή Συστήματα, Ασαφής Λογική, Ανανεώσιμες Πηγές Ενέργειας, Πρόβλεψη Παραγωγής, Ωριαίες Προβλέψεις, Ηλιακή Ενέργεια, Φωτοβολταϊκά Συστήματα, Τεχνητά Νευρωνικά Δίκτυα, Ασαφή Συστήματα Συμπερασμού Τύπου-2, Βελτιστοποίηση Σμήνους Σωματιδίων, Μοντέλο Αυτοπαλινδρόμησης, Μοντέλο Αυτοπαλινδρόμησης Κινούμενου Μέσου

Abstract

The increased demand for clean and sustainable energy sources, combined with concerns about climate change and the reduction of fossil fuels, has led to the promotion of renewable energy sources (RES) as a key objective of global energy policy. The shift towards renewable sources, such as solar, wind and hydroelectric power, is considered necessary to reduce greenhouse gas emissions, enhance energy security and achieve sustainable development.

In this context, this thesis examines the application of neuro-fuzzy techniques, in particular the Adaptive Neuro-Fuzzy Inference System (ANFIS), for the estimation of energy production from Photovoltaics.

The objective of the study is to address the challenges posed by the increasing integration of RES in the power grid, which requires accurate and reliable estimation methods to ensure grid stability and efficiency. Forecasting the performance of RES is critical due to their volatile and unpredictable nature. Power grids require stable and reliable energy supplies, and accurate estimation can reduce the risks and costs associated with energy storage or replenishment.

The methodology involves the collection and processing of historical energy data from PV systems, followed by the development and training of the ANFIS model. This model is compared to traditional statistical methods, such as Autoregressive (AR) and Autoregressive Moving Average (ARMA) models, as well as an Artificial Neural Network (ANN), and a Type-2 Fuzzy Inference System optimized using Particle Swarm Optimization (PSO).

The results show that ANFIS outperforms the selected models in terms of prediction accuracy and adaptability to changing environmental conditions. The study concludes that integrating intelligent systems such as ANFIS can significantly improve the accuracy and reliability of RES generation estimates, thus facilitating their efficient and stable integration into the energy grid.

This research contributes to the energy sector and provides a comprehensive comparative analysis of different estimation models. Furthermore, it highlights the advantages of neuro-fuzzy techniques in managing the variability and uncertainty

associated with renewable energy sources. The findings demonstrate the potential of ANFIS as a powerful tool for energy production estimation, thus promoting the development and adoption of renewable energy-related technologies.

Keywords

ANFIS Model, Neuro-Fuzzy Systems, Fuzzy Logic, Renewable Energy Sources, Production Forecasting, Hourly Forecasts, Solar Energy, Photovoltaic Systems, Artificial Neural Networks, Type-2 Fuzzy Inference Systems, Particle Swarm Optimization, Auto-Regression Model, Auto-Regression Moving Average Model

Πίνακας Περιεχομένων

Κεφάλαιο 1: Εισαγωγή και Δομή του Ερευνητικού Έργου

περιληπτικά	20
1.1 Αντικείμενο της Εργασίας.....	20
1.2 Δομή του Ερευνητικού Έργου	21
1.3 Οι Ανανεώσιμες Πηγές Ενέργειας (ΑΠΕ) και τα χρονικά ορόσημα για την ανάπτυξή τους στην παγκόσμια κοινότητα.....	23
1.4 Οι Ανανεώσιμες Πηγές Ενέργειας, γιατί είναι σημαντικές οι ΑΠΕ και οι προκλήσεις τους - Τα Φ/Β και οι κανόνες λειτουργίας τους.....	26
1.5 Η εξέλιξη της ενέργειας ιστορικά	27
1.6 Η ανάγκη πρόβλεψης της παραγωγής ενέργειας	31
1.7 Η εξέλιξη των ΑΠΕ στην Παγκόσμια Κοινότητα και στην Ευρωπαϊκή Ένωση.	34
1.8 Αγορά Ανανεώσιμων Πηγών Ενέργειας	43
1.8.1 Τύποι αγορών ενέργειας	43
1.8.2 Μηχανισμοί Υποστήριξης Επενδύσεων σε Ανανεώσιμες Πηγές Ενέργειας.....	44
1.9 Η χρήση προσαρμοστικού νεύρο-ασαφούς δικτύου για την πρόβλεψη της παραγωγής ενέργειας	46

Κεφάλαιο 2: Σκοπός και στόχοι ερευνητικού έργου47

2.1 Ερευνητικός στόχος του Συγγραφέα	47
2.2 Οικονομικά και Ενεργειακά Οφέλη των ΑΠΕ.....	48

Κεφάλαιο 3: Ανασκόπηση Ελληνικής & Διεθνούς Βιβλιογραφίας ..50

3.1 Ανασκόπηση Ελληνικής και Διεθνούς Βιβλιογραφίας - Μέθοδοι Πρόβλεψης Παραγωγής Ενέργειας από Φ/Β και σύγκρισή τους	50
3.2 Ταξινόμηση των προβλέψεων παραγωγής ενέργειας	59

3.2.1 Ταξινόμηση με βάση τον ορίζοντα πρόβλεψης	59
3.2.2 Ταξινόμηση με βάση τις μεθόδους πρόβλεψης.....	61
3.2.3 Υβριδικά μοντέλα (Hybrid models)	67
Κεφάλαιο 4: Τεχνητά Νευρωνικά Δίκτυα	69
4.1 Εισαγωγή στα Τεχνητά Νευρωνικά Δίκτυα	69
4.2 Ορισμός	70
4.3 Απομνημόνευση και Γενίκευση	71
4.4 Απόκτηση γνώσης μέσω της μάθησης.....	71
4.5 Ένας τεχνητός νευρώνας	73
4.6 Μονοστρωματικά Δίκτυα	75
4.7 Πολυστρωματικά Δίκτυα.....	75
4.8 Αρχιτεκτονική Νευρωνικών Δικτύων	77
4.8.1 Νευρωνικά Δίκτυα Πρωσοτροφοδότησης.....	77
4.8.2 Νευρωνικά Δίκτυα Ανατροφοδότησης	78
4.9 Τα Τεχνητά Νευρωνικά Δίκτυα ως εργαλεία πρόβλεψης, Πλεονεκτήματα & Μειονεκτήματα	79
4.9.1 Πλεονεκτήματα Τεχνητών Νευρωνικών Δικτύων	80
4.9.2 Μειονεκτήματα Τεχνητών Νευρωνικών Δικτύων	81
Κεφάλαιο 5: Ασαφής Λογική.....	82
5.1 Η έννοια της ασαφούς λογικής.....	82
5.1.1 Πλεονεκτήματα Ασαφούς Λογικής.....	82
5.1.2 Μειονεκτήματα Ασαφούς Λογικής	83
5.2 Ασαφή Σύνολα	83

5.3 Ασαφής Κανόνας και Ασαφή Συστήματα	85
5.3.1 Ασαφή Συστήματα Συμπερασμού (Fuzzy Inference Systems- FIS).....	85
5.3.2 Ασαφείς Κανόνες.....	87
5.3.2.1 Ασαφές Σύστημα Συμπερασμού Takagi-Sugeno-Kang (TSK).....	88
5.3.3 Ασαφές Σύστημα Συμπερασμού Τύπου 2 (Type-2 Fuzzy Inference System) με Χρήση Βελτιστοποίησης Σμήνους Σωματιδίων (Particle Swarm Optimization - PSO)...	90

Κεφάλαιο 6: Προσαρμοστικό Νευρο-Ασαφές Σύστημα

Συμπερασμού (Adaptive Neuro-Fuzzy Inference System – ANFIS) 92

6.1 Εισαγωγή / Νευροασαφή Συστήματα	92
6.2 Δίκτυο ANFIS και νευρώνες	93
6.3 Αρχιτεκτονική μοντέλου ANFIS	96
6.4 Εκπαίδευση μοντέλου ANFIS.....	102
6.4.1 Διάδοση προς τα εμπρός (forward pass).....	103
6.4.2 Οπισθοδρόμηση για Πρώσο-Τροφοδοτούμενα Δίκτυα (backward pass)	103
6.4.3 Εκτιμητής Ελαχίστων Τετραγώνων (Least Squares (LSE) Batch Algorithm).....	104
6.5 Υβριδικός Αλγόριθμος μοντέλου ANFIS.....	105
6.6 Περιορισμοί ενός μοντέλου ANFIS.....	108

Κεφάλαιο 7: Μεθοδολογία του μοντέλου ANFIS109

7.1 Εισαγωγή στη Μεθοδολογία.....	109
7.2 Συλλογή Δεδομένων	109
7.3 Προεπεξεργασία Δεδομένων.....	110
7.3.1 Καθαρισμός και Διαχείριση Δεδομένων	110
7.3.2 Διαμοιρασμός Δεδομένων	110
7.4 Δημιουργία Ασαφούς Συστήματος Συμπερασμού (FIS).....	111

7.4.1 Καθορισμός εισόδων - εξόδων	111
7.4.1.1 Δημιουργία χρονικών υστερήσεων	111
7.4.1.2 Καθορισμός των Συναρτήσεων Συμμετοχής (Membership Functions – MFs)	112
7.4.2 Καθορισμός μεθόδου ομαδοποίησης	113
7.4.3 Δημιουργία Κανόνων Βάσης	113
7.5 Δημιουργία και εκπαίδευση του ANFIS	114
7.5.1 Εξαγωγή και Απεικόνιση των πληροφοριών του τελικού ANFIS	115
7.5.2 Προβλέψεις με δεδομένα εκπαίδευσης και αξιολόγησης	116
7.6 Αξιολόγηση της απόδοσης του Μοντέλου Πρόβλεψης	117
7.6.1 Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error - MSE)	118
7.6.2 Ρίζα Μέσου Τετραγωνικού Σφάλματος (Root Mean Squared Error - RMSE)	118
7.6.3 Μέσο Απόλυτο Σφάλμα (Mean Absolute Error - MAE)	119
7.6.4 Συντελεστής Προσδιορισμού (Coefficient of Determination – DC / R-squared - R^2)	119
7.7 Σύγκριση με άλλα Μοντέλα Πρόβλεψης	120
7.7.1 Μοντέλο Αυτοπαλινδρόμησης - Autoregressive (AR) Model	120
7.7.2 Μοντέλο Αυτοπαλινδρόμησης Κινούμενου Μέσου - Autoregressive Moving Average (ARMA) Model	121
7.7.3 Τεχνητό Νευρωνικό Δίκτυο - Artificial Neural Networks (ANN)	121
7.7.4 Ασαφές Σύστημα Συμπερασμού Τύπου-2 με Βελτιστοποίηση Σμήνους Σωματιδίων - Type-2 Fuzzy Inference System (Type-2 FIS) with Particle Swarm Optimization (PSO)	122

Κεφάλαιο 8: Αποτελέσματα από τη χρήση του μοντέλου ANFIS .. 123

8.1 Εισαγωγή	123
8.2 Προεπεξεργασία των Δεδομένων	123
8.3 Δημιουργία και εκπαίδευση του ANFIS	124

8.4 Αξιολόγηση του ANFIS.....	133
8.5 Σύγκριση με άλλες μεθόδους πρόβλεψης	138
8.5.1 Μοντέλο Αυτοπαλινδρόμησης (AutoRegressive Model - AR)	139
8.5.2 Μοντέλο Αυτοπαλινδρόμησης Κινούμενου Μέσου (AutoRegressive Moving Average Model – ARMA)	140
8.5.3 Μοντέλο Ασαφούς Συστήματος Συμπερασμού Τύπου-2 με Βελτιστοποίηση Σμήνους Σωματιδίων (Fuzzy Inference System Type-2 Model with Particle Swarm Optimization- FT2-PSO).....	141
8.5.4 Μοντέλο Τεχνητού Νευρωνικού Δικτύου (Artificial Neural Network Model – ANN)	142
8.6 Αποτελέσματα Σύγκρισης	143
8.7 Εναλλακτικοί τρόποι εκπαίδευσης και αξιολόγησης του ANFIS σε περιβάλλον Matlab	145

Κεφάλαιο 9: Συμπεράσματα, Περιορισμοί και Μελλοντικές Έρευνες

147

9.1 Συμπεράσματα.....	147
9.2 Περιορισμοί	148
9.3 Μελλοντικές Έρευνες	149

Κεφάλαιο 10: Βιβλιογραφία

150

Κεφάλαιο 11: Παραρτήματα

164

11.1 Μπεϊσιανά (Bayesian) Δίκτυα.....	164
11.2 T-Νόρμες.....	164

Λίστα Εικόνων

Εικόνα 1: Προβλεπόμενη κατανάλωση ενέργειας παγκοσμίως από το 1990 έως το 2040, ανά πηγή ενέργειας ,σε εκατομμύρια μετρικούς τόνους ισοδυνάμου πετρελαίου (Statista, n.d.)	29
Εικόνα 2: Μέση θερμοκρασιακή ανωμαλία για τα έτη 1880-2023 (NASA/GISS)	30
Εικόνα 3: Εκτιμώμενη παραγωγή ενέργειας ΑΠΕ ανά Τεχνολογία Παραγωγής για τα έτη 2020-2028 (IEA,2024)	35
Εικόνα 4: Παραγωγή ΑΠΕ ανά είδος Τεχνολογίας (IEA, 2024)	36
Εικόνα 5: Παραγωγή ενέργειας από ΑΠΕ στην Παγκόσμια Κοινότητα, για την περίοδο 2023-2027 (IEA, 2024)	37
Εικόνα 6: Πρόβλεψη παραγωγής ενέργειας από ΑΠΕ, ανά είδος Τεχνολογίας για την περίοδο 2023-2028 (IEA, 2024)	38
Εικόνα 7: Ανάπτυξη της παραγωγής από Φ/Β για την περίοδο 2001 -2023 (Solar Power Europe, 2023)	39
Εικόνα 8: Παραγωγή ΑΠΕ ανά χώρα ΕΕ 2000-2023 (Solar Power Europe, 2023) ..	41
Εικόνα 9: Παραγωγή ΑΠΕ, ανά χώρα ΕΕ 2022/2023 (Solar Power Europe, 2023) .	41
Εικόνα 10: Εγκατεστημένη ηλιακή Φ/Β ισχύς from 2000 to 2023 για τις 10 μεγαλύτερες σε παραγωγή χώρες της Ευρωπαϊκής Ένωσης (Solar Power Europe, 2023)	42
Εικόνα 11: Ταξινόμηση πρόβλεψης φωτοβολταϊκής ισχύος με βάση τον χρονικό ορίζοντα	60
Εικόνα 12: Ταξινόμηση πρόβλεψης φωτοβολταϊκής ισχύος με βάση την προσέγγιση	62
Εικόνα 13: Διαφορετικές Τεχνικές Στατιστικών Μοντέλων	64
Εικόνα 14: Εικόνα ενός Φυσικού Νευρώνα	69
Εικόνα 15: Μορφή ενός Νευρωνικού Δικτύου	69

Εικόνα 16: Αναπαράσταση του προβλήματος εκπαίδευσης overfitting (Voudris, 2006)	73
Εικόνα 17: Ένας τεχνητός νευρώνας (Χασιακός & Τσίκας, 2019)	74
Εικόνα 18: Παραδείγματα αρχιτεκτονικής πολυστρωματικών νευρωνικών δικτύων (Voudris, 2006).....	75
Εικόνα 19: Δίκτυο Οπισθοδρόμησης (Back Propagation Network) (Voudris, 2006). 76	
Εικόνα 20: Πολυστρωματικό Νευρωνικό Δίκτυο πρώστοτροφοδότησης (μερικώς διασυνδεδεμένο) (Κούρους, 2012)	78
Εικόνα 21: Πολυστρωματικό ΝΔ Ανατροφοδότησης (Κουρούς, 2012)	79
Εικόνα 22: Ημέρες που θεωρούμε ότι ανήκουν στο Σ/Κ κατά Boolean και ασαφή λογική (Λέκκου, 2011)	84
Εικόνα 23: Δομή του ασαφούς συστήματος εξαγωγής συμπερασμάτων (Ζερβουδάκης, 2008)	86
Εικόνα 24: Σχηματικό διάγραμμα ενός ασαφούς συστήματος συμπερασμού (Fuzzy Inference System-FIS) (Kiran και Rajput, 2011).....	86
Εικόνα 25: Ένα απλό σύστημα συμπερασμού (Singh et.al, 2012).....	87
Εικόνα 26: Λειτουργία Ασαφούς Συστήματος Takagi-Sugeno-Kang (TSK) (Bonissone, 2002)	88
Εικόνα 27: Σχηματική απεικόνιση συναρτήσεων συμμετοχής στο FIS μοντέλο τύπου Takagi-Sugeno-Kang (Talei et.al, 2010).....	90
Εικόνα 28: Δίκτυο ANFIS (Bonissone, 2002).....	94
Εικόνα 29: Σχηματική αναπαράσταση της δομής ενός ANFIS μοντέλου για κάθε στρώμα/επίπεδο (Mesbahi et.al, 2012)	94
Εικόνα 30: Διάγραμμα Ροής της μεθόδου πρόβλεψης ενός μοντέλου ANFIS (Cus et .al, 2006)	96
Εικόνα 31: Γραφική αναπαράσταση της επίδρασης που έχει η αλλαγή των παραμέτρων a , b και c της καμπανοειδούς συνάρτησης (Bonissonne, 2002).....	97

Εικόνα 32: Προσαρμοστικό Νεύρο-ασαφές Σύστημα υιοθετεί το ασαφές σύστημα TSK. Γραφική παράσταση της διαδικασίας συμπερασμού βασισμένη στο μοντέλο TSK (Tan et.al, 2011).....	100
Εικόνα 33: Αρχιτεκτονική μοντέλου ANFIS, όπως αναπτύχθηκε από τον Jang το 1992 (Wanb et.al, 2011).....	101
Εικόνα 34: Γενική αρχιτεκτονική ενός μοντέλου ANFIS (Bey και Benhammadi, 2010)	101
Εικόνα 35: Το Dataset - Διακύμανση παραγόμενης ενέργειας (σε MWh).....	123
Εικόνα 36: Δεδομένα εκπαίδευσης - αξιολόγησης (Training - Evaluation Data)	124
Εικόνα 37: Δεδομένα εκπαίδευσης σε γραφικές παραστάσεις διασποράς 2-Δ	125
Εικόνα 38: Δεδομένα εκπαίδευσης σε γραφική παράσταση διασποράς 3-Δ.....	125
Εικόνα 39: Δεδομένα εκπαίδευσης ως διασπορά, ταξινομημένα ανά χρονική υστέρηση.....	126
Εικόνα 40: Πληροφορίες ANFIS κατά την εκκίνηση της εκπαίδευσής του	127
Εικόνα 41: Αρχικές Συναρτήσεις Συμμετοχής σε κάθε είσοδο.....	128
Εικόνα 42: Τελικές Συναρτήσεις Συμμετοχής σε κάθε είσοδο.....	128
Εικόνα 43: Αρχική δομή Ασαφούς Συστήματος Συμπερασμού	129
Εικόνα 44: Δομή Προσαρμοστικού Νεύρο-ασαφούς Συστήματος Συμπερασμού... ..	129
Εικόνα 45: Σφάλμα εκπαίδευσης – ελέγχου ανά επανάληψη / Μέγεθος Βήματος ανά επανάληψη.....	130
Εικόνα 46: Τελικοί κανόνες μοντέλου ANFIS.....	131
Εικόνα 47: Συντονισμένο Ασαφές Σύστημα Συμπερασμού μετά την εκπαίδευση ..	132
Εικόνα 48: Surface Viewer για το εκπαιδευμένο FIS.....	133
Εικόνα 49: Πραγματικές τιμές και τιμές μεθόδου πρόβλεψης ANFIS ανά ώρα - Δεδομένα Εκπαίδευσης (Last 60 samples)	134
Εικόνα 50: Σφάλματα Πρόβλεψης ANFIS ανά ώρα – Δεδομένα εκπαίδευσης (Last 60 samples).....	134

Εικόνα 51: Πραγματικές τιμές και τιμές μεθόδου πρόβλεψης ANFIS ανά ώρα - Δεδομένα Αξιολόγησης (Last 60 samples)	135
Εικόνα 52: Σφάλματα Πρόβλεψης ANFIS ανά ώρα – Δεδομένα αξιολόγησης (Last 60 samples).....	135
Εικόνα 53: Διασπορά σφαλμάτων πρόβλεψης μοντέλου ANFIS.....	136
Εικόνα 54: Πραγματικές τιμές και τιμές μεθόδου πρόβλεψης AR ανά ώρα (Last 60 samples).....	139
Εικόνα 55: Πραγματικές τιμές και τιμές μεθόδου πρόβλεψης ARMA ανά ώρα (Last 60 samples).....	140
Εικόνα 56: Πραγματικές τιμές και τιμές μεθόδου πρόβλεψης FT2-PSO ανά ώρα (Last 60 samples).....	141
Εικόνα 57: Πραγματικές τιμές και τιμές μεθόδου πρόβλεψης ΤΝΔ ανά ώρα (Last 60 samples).....	142
Εικόνα 58: Σύγκριση συνολικών αποτελεσμάτων μοντέλων πρόβλεψης με πραγματικές τιμές ανά ώρα (Last 60 samples).....	143
Εικόνα 59: Παράδειγμα Μπεϊσιανού Δικτύου	164

Λίστα Πινάκων

Πίνακας 1: Συγκριτική ανάλυση των πλεονεκτημάτων και μειονεκτημάτων των ανανεώσιμων πηγών ενέργειας (Ipsakis, 2011)	32
Πίνακας 2: Συνοπτικός πίνακας διαφορετικών ερευνών με σύγκριση μεθόδων πρόβλεψης παραγωγής ενέργειας (Ελληνική και Διεθνής Βιβλιογραφία)	57
Πίνακας 3: Μορφές συναρτήσεων συμμετοχής (Sadrmomtazi et.al, 2012)	87
Πίνακας 4: Υπολογιστική πολυπλοκότητα του συστήματος ANFIS (Bonissone, 2002)	99
Πίνακας 5: Τα δύο περάσματα στη διαδικασία εκπαίδευσης του αλγορίθμου σε ένα μοντέλο ANFIS (Cruz, 2009)	106
Πίνακας 6: Ρίζα Μέσου Τετραγωνικού Σφάλματος για το μοντέλο ANFIS πάνω στα δεδομένα εκπαίδευσης (σε MWh)	137
Πίνακας 7: Σφάλματα Μέτρησης για το μοντέλο ANFIS πάνω στα δεδομένα αξιολόγησης (σε MWh).....	137
Πίνακας 8: Κανονικοποιημένα Σφάλματα Μέτρησης για το μοντέλο ANFIS	137
Πίνακας 9: Σφάλματα Μέτρησης για το μοντέλο AR (σε MWh)	139
Πίνακας 10: Κανονικοποιημένα Σφάλματα Μέτρησης για το μοντέλο AR.....	139
Πίνακας 11: Σφάλματα Μέτρησης για το μοντέλο ARMA (σε MWh)	140
Πίνακας 12: Κανονικοποιημένα Σφάλματα Μέτρησης για το μοντέλο ARMA	140
Πίνακας 13: Σφάλματα Μέτρησης για το μοντέλο FT2-PSO (σε MWh) – Δεδομένα Εκπαίδευσης	141
Πίνακας 14: Σφάλματα Μέτρησης για το μοντέλο FT2-PSO (σε MWh) – Δεδομένα Αξιολόγησης.....	141
Πίνακας 15: Κανονικοποιημένα Σφάλματα Μέτρησης για το μοντέλο FT2-PSO	142
Πίνακας 16: Σφάλματα Μέτρησης για το μοντέλο ΤΝΔ (σε MWh)	142
Πίνακας 17: Κανονικοποιημένα Σφάλματα Μέτρησης για το μοντέλο ΤΝΔ	143
Πίνακας 18: Σφάλματα Πρόβλεψης για κάθε Μοντέλο (σε MWh)	144

Πίνακας 19: Κανονικοποιημένα Σφάλματα Πρόβλεψης για κάθε Μοντέλο	144
--	-----

Λίστα Συντομογραφιών

ANFIS: Adaptive Neuro-Fuzzy Inference System (Προσαρμοστικό Νευρο-ασαφές Σύστημα Συμπερασμού)

ANN: Artificial Neural Network (Τεχνητό Νευρωνικό Δίκτυο)

AR: Auto-Regression (Αυτοπαλινδρόμηση)

ARIMA: Auto-Regression Integrated Moving Average

ARMA: Auto-Regression Moving Average (αυτοπαλινδρόμηση κινούμενου μέσου)

DC: Direct Current (Συνεχές Ρεύμα)

FIS: Fuzzy Inference System (Ασαφές Σύστημα Συμπερασμού-ΑΣΣ)

fMF: Final Membership Function (Τελική Συνάρτηση Συμμετοχής)

GDO: Gradient Descent Optimization

GMPPT: Global Maximum Power Point Tracking

iMF: Initial Membership function (Αρχική ή Τελική Συνάρτηση Συμμετοχής)

LSE: Least Squares Estimation (Μέθοδος Ελαχίστων Τετραγώνων)

MAE: Mean Absolute Error

MAPE: Mean Absolute Percentage Error

MSE: Mean Squared Error

MLR: Multiple Linear Regression (Πολλαπλή Γραμμική Παλινδρόμηση)

nMAE: normalized Mean Absolute Error

nMSE: normalized Mean Squared Error

nRMSE: normalized Root Mean Squared Error

PSO: Particle Swarm Optimization

PV/ΦΒ: Photovoltaic (Φωτοβολταϊκό)

RMSE: Root Mean Squared Error

SVM: Support Vector Machine

TSK: Takagi-Sugeno-Kang

Type-2 FIS: Type-2 Fuzzy Inference System (Ασαφές Σύστημα Συμπερασμού Τύπου-2)

IEA: International Energy Association

ΑΠΕ: Ανανεώσιμες Πηγές Ενέργειας

ΗΕ: Ηνωμένα Έθνη

ΝΔ: Νευρωνικά Δίκτυα

ΣΚ: Σάββατο Κύριακο

ΤΝΔ: Τεχνητά Νευρωνικά Δίκτυα

Φ/Β: Φωτοβολταϊκό

Κεφάλαιο 1: Εισαγωγή και Δομή του Ερευνητικού Έργου

περιληπτικά

1.1 Αντικείμενο της Εργασίας

Τα ακραία φαινόμενα και οι σοβαρές οικολογικές καταστροφές, που απορρέουν από την αυξανόμενη ένταση και συχνότητα των κλιματικών αλλαγών, έχουν δημιουργήσει νέες παγκόσμιες συνθήκες στον τομέα της ενέργειας. Αυτές οι συνθήκες επηρεάζουν τόσο την παγκόσμια, όσο και τις εθνικές οικονομίες, καθώς και τη βιωσιμότητα του πλανήτη.

Η βιωσιμότητα του πλανήτη αμφισβητείται και η ανάγκη αξιοποίησης των ανανεώσιμων πηγών ενέργειας (ΑΠΕ) έχει καταστεί επιτακτική. Η ζήτηση για πιο πράσινες μορφές ενέργειας αναδεικνύει την παραγωγή της από ανανεώσιμες πηγές, ως βασικό παράγοντα στις παγκόσμιες και ευρωπαϊκές αγορές.

Μέχρι πρόσφατα, όταν η προέλευση της ενέργειας ήταν κυρίως από παραδοσιακές μονάδες παραγωγής που χρησιμοποιούν ορυκτά καύσιμα, η ηλεκτρική ενέργεια που διατίθετο στο δίκτυο είχε μια σταθερή τιμή, η οποία καθοριζόταν από την κατανάλωση του φορτίου. Εντούτοις, το συνεχώς αυξανόμενο ποσοστό ενσωμάτωσης των ΑΠΕ έχει διαμορφώσει νέες συνθήκες και προκλήσεις για την κάλυψη των αναγκών ηλεκτρικής ενέργειας του δικτύου.

Προκειμένου να ενσωματωθούν αυτές οι πηγές και να ελαχιστοποιηθούν οι τεχνικές και οικονομικές επιπτώσεις σε όλους τους εμπλεκόμενους στην αγορά ηλεκτρικής ενέργειας, χρειάζονται αξιόπιστες μέθοδοι για την ακριβή πρόβλεψη της παραγόμενης ενέργειας.

Η χρήση των ιστορικών δεδομένων παραγόμενης ενέργειας των φωτοβολταϊκών, τα οποία περιλαμβάνουν εγγενώς μεταβλητές όπως η ηλιακή ακτινοβολία αλλά και άλλους παράγοντες επηρεασμού, σε συνδυασμό με τα κατάλληλα μοντέλα πρόβλεψης, επιτρέπει την παροχή αξιόπιστων λύσεων για την πρόβλεψη της παραγωγής ενέργειας σε διάφορες χρονικές περιόδους.

Τα μοντέλα αυτά παρέχουν μεγάλη ευελιξία και συμβάλλουν στην αύξηση της διείσδυσης των ΑΠΕ στο δίκτυο ενέργειας.

Συμπερασματικά, η αξιόπιστη πρόβλεψη της παραγωγής ενέργειας διασφαλίζει τη λειτουργία του δικτύου με μεγαλύτερη συνέπεια και σταθερότητα, διατηρώντας το κόστος σε αποδεκτά επίπεδα υπό διάφορες συνθήκες ζήτησης. Χωρίς κάποιο αξιόπιστο σύστημα πρόβλεψης, η παραγωγή ηλεκτρικής ενέργειας από τις ΑΠΕ μπορεί να αφήσει μια χώρα εκτεθειμένη σε σημαντικούς κινδύνους, όπως συνεχείς διακοπές ρεύματος, πτώση της ηλεκτρικής τάσης και αδυναμία κάλυψης των ενεργειακών αναγκών.

1.2 Δομή του Ερευνητικού Έργου

Στο πρώτο κεφάλαιο, το ερευνητικό έργο αρχίζει με μια εισαγωγή που περιλαμβάνει το αντικείμενο και τη δομή του, εστιάζοντας στις ΑΠΕ και την ανάπτυξή τους γεωγραφικά με κύρια εστίαση στην Ευρωπαϊκή Ένωση (ΕΕ). Αναλύεται η σημασία των ΑΠΕ, οι προκλήσεις που αντιμετωπίζουν, καθώς και η ιστορική εξέλιξη της ενέργειας και τα προβλήματα που προέκυψαν από την υπερβολική χρήση της μέσα στο χρόνο. Επιπλέον, επισημαίνεται η ανάγκη πρόβλεψης της παραγωγής ενέργειας από τον ήλιο, ως ένα από τα πιο σημαντικά κανάλια παραγωγής των ΑΠΕ, αφού αποτελεί την ευκολότερη και περισσότερο προσβάσιμη πηγή παγκοσμίως. Στη συνέχεια περιγράφεται η εξέλιξη των ΑΠΕ παγκοσμίως και στην ΕΕ, ενώ εξετάζεται η πρόβλεψη της παραγωγής ενέργειας με την χρήση προσαρμοστικού νεύρο-ασαφούς δικτύου.

Στο δεύτερο κεφάλαιο, καθορίζεται ο σκοπός και οι στόχοι της διπλωματικής εργασίας, αναφέροντας τα οικονομικά και ενεργειακά οφέλη των ΑΠΕ, αλλά και τη μείωση του κόστους κατασκευής τους, και την ορθολογική επέκτασή τους.

Στο τρίτο κεφάλαιο, πραγματοποιείται ανασκόπηση της Ελληνικής και της Διεθνούς βιβλιογραφίας, όσον αφορά παρεμφερείς έρευνες αλλά και καθώς και τις μεθόδους πρόβλεψης παραγωγής ενέργειας με έμφαση σε αυτή που παράγεται μέσω ηλιακής ενέργειας.

Στο τέταρτο κεφάλαιο, παρουσιάζονται τα Τεχνητά Νευρωνικά Δίκτυα, ένα από τα δομικά στοιχεία του μοντέλου ANFIS που ερευνώνται στην παρούσα εργασία, δίνοντας έμφαση στη λειτουργία τους, την απομνημόνευση και γενίκευση, την

απόκτηση γνώσης μέσω της μάθησης, ενώ γίνεται περιγραφή ενός τεχνητού νευρώνα, όπως επίσης και των μονοστρωματικών και των πολυστρωματικών δικτύων, την αρχιτεκτονική τους καθώς και τη χρήση τους ως εργαλεία πρόβλεψης.

Στο πέμπτο κεφάλαιο, αναλύεται το δεύτερο από τα δομικά στοιχεία του μοντέλου ANFIS που ερευνώνται στην παρούσα εργασία, η ασαφής λογική, και συγκεκριμένα τα πλεονεκτήματα και τα μειονεκτήματά της, τα ασαφή σύνολα, οι ασαφείς κανόνες και τα ασαφή συστήματα συμπερασμού, συμπεριλαμβανομένου του συστήματος Takagi-Sugeno-Kang και των ασαφών συνόλων τύπου 2 με χρήση βελτιστοποίησης σμήνους σωματιδίων, εξετάζοντας τη θεωρία πίσω από τη γενικότερη αποτελεσματικότητα των συστημάτων αυτών, όσον αφορά στην ακρίβεια της πρόβλεψης παραγωγής.

Στο έκτο κεφάλαιο, παρουσιάζεται το προσαρμοστικό νεύρο-ασαφές σύστημα εξαγωγής συμπερασμού (ANFIS), που συνιστά την ένωση της ασαφούς λογικής και των τεχνητών νευρωνικών δικτύων. Αναλύεται η αρχιτεκτονική του μοντέλου ANFIS, η εκπαίδευσή του με διάδοση προς τα εμπρός και οπισθοδρόμηση για πρωσοτροφοδοτούμενα δίκτυα, ο υπολογισμός εκτίμησης με τη χρήση των Ελάχιστων Τετραγώνων (Least Square Estimation), ο υβριδικός αλγόριθμός του ANFIS και οι περιορισμοί του.

Στο έβδομο κεφάλαιο, περιγράφεται και αναλύεται η μεθοδολογία του μοντέλου ANFIS που ακολουθήθηκε στην παρούσα εργασία, από τη συλλογή και προεπεξεργασία των δεδομένων μέχρι την εκπαίδευση και αξιολόγηση του μοντέλου, συμπεριλαμβανομένης της σύγκρισης με άλλα μοντέλα πρόβλεψης ενεργειακής παραγωγής από τις μονάδες ηλιακής ενέργειας.

Στο όγδοο κεφάλαιο, αναλύονται τα αποτελέσματα από την υλοποίηση βήμα προς βήμα της μεθοδολογίας του προηγούμενου κεφαλαίου. Συμπεριλαμβάνονται επίσης τα συμπεράσματα που προέκυψαν, ενώ περιγράφονται και εναλλακτικές μέθοδοι εκπαίδευσης και αξιολόγησης του ANFIS στο περιβάλλον της Matlab.

Στο ένατο κεφάλαιο, παρουσιάζονται τα συνολικά συμπεράσματα της έρευνας, περιορισμοί αλλά και μελλοντικές έρευνες.

Στο δέκατο κεφάλαιο, παρατίθεται η βιβλιογραφία καθώς και οι αναφορές που χρησιμοποιήθηκαν στο παρόν ερευνητικό έργο.

Στο ενδέκατο κεφάλαιο, περιλαμβάνονται τα παραρτήματα που συμπληρώνουν και υποστηρίζουν το κύριο σώμα της έρευνας.

1.3 Οι Ανανεώσιμες Πηγές Ενέργειας (ΑΠΕ) και τα χρονικά ορόσημα για την ανάπτυξή τους στην παγκόσμια κοινότητα

Ένα από τα κύρια χαρακτηριστικά της σύγχρονης ενεργειακής πραγματικότητας αποτελεί η αυξανόμενη χρήση ΑΠΕ, σε σύγκριση με τις παραδοσιακές πηγές ενέργειας όπως τα ορυκτά καύσιμα. Λόγω του ανησυχητικού ρυθμού αύξησης της ζήτησης ενέργειας, καθώς και των εκπομπών αερίων του θερμοκηπίου και των λοιπών παραγόντων ρύπανσης από την εκτεταμένη χρήση ορυκτών καυσίμων, οι μεγαλύτερες χώρες στον κόσμο δεσμεύτηκαν να αναλάβουν κοινές δράσεις για να αποτρέψουν μια παγκόσμια οικολογική κρίση.

Οι κυριότερες συναντήσεις που οργανώθηκαν για τον λόγο αυτό είναι οι εξής:

Πρωτόκολλο του Κιότο (Ιαπωνία, 1997) (United Nations, 1998) το οποίο έχουν προσυπογράψει μέχρι σήμερα 191 χώρες ("The Kyoto Protocol - Status of Ratification | UNFCCC," n.d.)

Σε αυτή τη συνάντηση, οι βιομηχανικά ανεπτυγμένες χώρες δεσμεύτηκαν για τη συλλογική μείωση των εκπομπών 6 αερίων του θερμοκηπίου για την περίοδο 2008 με 2012, κατά 5,2% συγκριτικά με τα επίπεδα του έτους 1990.

Διάσκεψη της Κοπεγχάγης (2009):

Οι συζητήσεις σε αυτή τη διάσκεψη οδήγησαν στο "**Σύμφωνο της Κοπεγχάγης**", το περιεχόμενο του οποίου δήλωνε τη σημασία της μείωσης των παγκόσμιων εκπομπών ρύπων και προσδιόριζε δεσμεύσεις των κρατών για τον περιορισμό τους, χωρίς ωστόσο συμφωνία για συγκεκριμένες χρονικές περιόδους ή ποσότητες μείωσης των ρύπων.

Διάσκεψη Κανκούν στο Μεξικό για την Κλιματική Αλλαγή (Μεξικό, 2010):

Σε αυτή τη διάσκεψη η παγκόσμια κοινότητα συμφώνησε σημαντικά σημεία:

- i. Η αύξηση της παγκόσμιας θερμοκρασίας πρέπει να διατηρηθεί κάτω από τους 2°C.

- ii. Νομική δέσμευση των βιομηχανικά ανεπτυγμένων χωρών να δημιουργήσουν ένα ταμείο οικονομικής υποστήριξης, για να βοηθήσουν τις αναπτυσσόμενες χώρες να προσαρμοστούν στην πράσινη ανάπτυξη για τα επόμενα τρία χρόνια.
- iii. Συμφωνία για τη χρηματοδότηση χωρών με πλούσιο δασικό πλούτο, ώστε να προστατευτούν από την υλοτομία και τη γεωργία.
- iv. Επανεγκαθίδρυση της ισχύος του Πρωτοκόλλου του Κιότο, που περιορίζει τις εκπομπές ρυπαντών στις ανεπτυγμένες χώρες.

Διάσκεψη του Durban, (Νότια Αφρική, 2011):

Αυτή η διάσκεψη περιλαμβάνει μια συμφωνία για την παγκόσμια κλιματική πολιτική, με στόχο τη μείωση των εκπομπών αερίων του θερμοκηπίου. Ένας από τους επιθυμητούς στόχους είναι ο περιορισμός της αύξησης της παγκόσμιας θερμοκρασίας στους 2°C. Επιπλέον, αποφασίστηκε ότι μια νέα συμφωνία για την περαιτέρω βελτίωση και αύξηση των διεθνών δράσεων για τη μείωση των εκπομπών πρέπει να δημιουργηθεί μέχρι το 2015 και να εφαρμοστεί το 2020.

Διάσκεψη της Doha (Κατάρ, 2012):

Ο κύριος στόχος αυτής της διάσκεψης ήταν η επέκταση των εφαρμογών του Πρωτοκόλλου του Κιότο έως το 2020, μέχρι να δημιουργηθεί μια νέα, πιο φιλόδοξη συμφωνία για την κλιματική αλλαγή.

Συμφωνία του Παρισιού (Γαλλία, 2015) (United Nations, 2015):

Ένα σχέδιο δράσης διαμορφώθηκε για να περιορίσει την αύξηση της παγκόσμιας θερμοκρασίας κάτω από τους 2°C, προσαρμοζόμενο στην κλιματική αλλαγή, και παρέχοντας χρηματοδότηση για να υποστηρίξει αυτήν την προσπάθεια. Η εφαρμογή αυτής της συμφωνίας είναι για την περίοδο από το 2020 και μετά. Οι κύριοι στόχοι της συμφωνίας:

A. Οι κυβερνήσεις αποφάσισαν να διατηρήσουν την αύξηση της μέσης παγκόσμιας θερμοκρασίας κάτω από τους 2 βαθμούς Κελσίου και να συνεχίσουν τις δράσεις για να την περιορίσουν μακροπρόθεσμα στους 1,5 βαθμούς Κελσίου.

Β. Οι χώρες που συμμετέχουν στη Συμφωνία του Παρισιού έχουν υποβάλει οργανωμένα εθνικά σχέδια δράσης που θα οδηγήσουν σε σημαντική μείωση των εκπομπών αερίων του θερμοκηπίου.

Γ. Όλες οι χώρες θα υποχρεούνται να υποβάλλουν διαφανείς αναφορές για τις συνεισφορές και την πρόοδό τους κάθε 5 χρόνια. Αυτές οι αναφορές θα αξιολογούνται και οι χώρες θα λαμβάνουν συστάσεις για το πώς να θέσουν πιο φιλόδοξους στόχους για την περαιτέρω πρόοδο των δράσεων για την κλιματική αλλαγή.

Δ. Τα ήδη καθιερωμένα χρηματοδοτικά ταμεία από τις προηγούμενες συναντήσεις, δια μέσω των οποίων οι ανεπτυγμένες χώρες παρέχουν βοήθεια στον αναπτυσσόμενο κόσμο για να προσαρμοστούν στις δράσεις για την κλιματική αλλαγή θα συνεχιστούν, και θα αναληφθούν μεγαλύτερες ακόμη δράσεις για να μειώσουν τις εκπομπές ρύπων.

Επιπλέον των διασκέψεων με συζήτηση την καταπολέμηση της υπερθέρμανσης του πλανήτη, η απελευθέρωση της αγοράς ηλεκτρικής ενέργειας στην Ευρώπη το έτος 2004, υπήρξε ένα πολύ σημαντικό εναρκτήριο γεγονός για την ανάπτυξη των ΑΠΕ.

Σύμφωνα με αυτόν τον ευρωπαϊκό κανονισμό, τα άτομα μπορούν να επιλέγουν ελεύθερα τους προμηθευτές τους από την 1η Ιουλίου 2007 και οι εταιρείες μπορούν να επιλέγουν ελεύθερα τους προμηθευτές τους από την 1η Ιουλίου 2004.

Για τους ιδιώτες, αυτό το βήμα επιτεύχθηκε τελικά, καθώς η καθιέρωση της εκλογικής ελευθερίας προμηθευτών ήρθε αργότερα από ό,τι ήλπιζε αρχικά το Ευρωπαϊκό Κοινοβούλιο, σε συμβιβασμό με τις κυβερνήσεις που εκπροσωπούνται στο Συμβούλιο. (Ενεργειακή δέσμη για την Ευρώπη - Ελεύθερη εκλογή των καταναλωτών, n.d).

Συμπερασματικά, η ελεύθερη επιλογή των καταναλωτών μαζί με την διαρκώς αυξανόμενη ανάγκη για αειφόρο ενέργεια, υπήρξαν τα σημεία αφετηρίας που οδήγησαν πολιτικούς και επενδυτικούς φορείς στο να αξιοποιήσουν περαιτέρω τις ΑΠΕ σε όλα τα μήκη και τα πλάτη του πλανήτη.

1.4 Οι Ανανεώσιμες Πηγές Ενέργειας, γιατί είναι σημαντικές οι ΑΠΕ και οι προκλήσεις τους - Τα Φ/Β και οι κανόνες λειτουργίας τους

Τα τελευταία χρόνια, οι μορφές ΑΠΕ που χρησιμοποιούνται περισσότερο ανά τον κόσμο για την παραγωγή ηλεκτρικής ενέργειας είναι: η ηλιακή, η αιολική, η υδροηλεκτρική, η ενέργεια των θαλάσσιων κυμάτων, η γεωθερμική ενέργεια, η ενέργεια της βιομάζας και οι κυψελίδες καυσίμου.

Η εργασία αυτή εστιάζει κυρίως στην ηλιακή ενέργεια ως μια από τις σημαντικότερες πηγές των ΑΠΕ.

Η ηλιακή ενέργεια είναι η ενέργεια που προέρχεται από τον ήλιο και μπορεί να αξιοποιηθεί μέσω διάφορων μεθόδων, κυρίως μέσω φωτοβολταϊκών συστημάτων και ηλιακών θερμικών συλλεκτών. Τα φωτοβολταϊκά συστήματα μετατρέπουν το ηλιακό φως απευθείας σε ηλεκτρική ενέργεια μέσω του φωτοβολταϊκού φαινομένου, όπου οι ηλιακές κυψέλες, που περιέχουν ημιαγωγούς όπως το πυρίτιο, απορροφούν φωτόνια και απελευθερώνουν ηλεκτρόνια, παράγοντας ηλεκτρικό ρεύμα. Οι ηλιακοί θερμικοί συλλέκτες απορροφούν τη θερμότητα από την ηλιακή ακτινοβολία για την παραγωγή θερμικής ενέργειας (National Renewable Energy Laboratory, 2021).

Όπως είναι γνωστό, η ηλιακή ενέργεια αποτελεί μια ανανεώσιμη και καθαρή πηγή ενέργειας, με σημαντική συμβολή στη μείωση των περιβαλλοντικών επιπτώσεων και των εκπομπών άνθρακα. Επιπλέον, σύμφωνα με την Εθνική Υπηρεσία Ανανεώσιμων Πηγών Ενέργειας των ΗΠΑ (National Renewable Energy Laboratory, 2021), η ηλιακή ενέργεια είναι μία από τις πλέον άφθονες και ευρέως διαθέσιμες πηγές ενέργειας παγκοσμίως, και θεωρείται ένας από τους πιο υποσχόμενους ανανεώσιμους πόρους για τη μαζική παραγωγή ενέργειας.

Πολλαπλά φωτοβολταϊκά κελιά συνιστούν μια φωτοβολταϊκή μονάδα (panel), και πολλαπλές μονάδες συνδέονται σε σειρά ή παράλληλα για να δημιουργήσουν ένα σύστημα φωτοβολταϊκών συστοιχιών (arrays). Το ηλιακό φως που προσπίπτει στις κυψέλες προκαλεί την απελευθέρωση ηλεκτρονίων υψηλής ενέργειας, τα οποία κινούνται ελεύθερα. Ένα ηλεκτρικό δυναμικό βοηθά αυτά τα ηλεκτρόνια να δημιουργήσουν τάση, η οποία χρησιμοποιείται για την παραγωγή ρεύματος μέσω κυκλωμάτων. Η ηλεκτρική απόδοση εξαρτάται από το μήκος και την ένταση του

ηλιακού φωτός, καθώς και από τον τύπο και την ποιότητα των φωτοβολταϊκών στοιχείων και των υλικών που χρησιμοποιούνται στην ηλιακή μονάδα.

Η παραγωγή ηλεκτρικής ενέργειας μέσω φωτοβολταϊκών έχει ενισχύσει την κοινωνική ευαισθητοποίηση, καθώς πέρα από τα περιβαλλοντικά οφέλη έχει υποστηρίξει και την οικονομική ανάπτυξη (Hosenuzzaman et al., 2015).

Εκτός από τη χρήση φωτοβολταϊκών για την παραγωγή ηλεκτρικής ενέργειας, η ηλιακή ενέργεια εφαρμόζεται σε θερμικές εφαρμογές για τη θέρμανση εσωτερικών χώρων στα βιοκλιματικά κτίρια, αλλά και για τη θέρμανση υγρών μέσω ενεργητικών ηλιακών συστημάτων (π.χ. ηλιακοί θερμοσίφωνες). Αξιοσημείωτο είναι ότι η συνολική ποσότητα ηλιακής ενέργειας που προσπίπτει στη Γη υπερβαίνει κατά πολύ τις τρέχουσες παγκόσμιες ενεργειακές ανάγκες. Ειδικότερα, σε 90 λεπτά, το ηλιακό φως που φτάνει στη Γη είναι αρκετό για να καλύψει τις ενεργειακές ανάγκες ολόκληρου του πλανήτη για ένα έτος (Phil, 2011). Συνεπώς, αν αξιοποιηθεί επαρκώς μέρος αυτής της διάσπαρτης πηγής ενέργειας, η παγκόσμια ενεργειακή κοινότητα έχει τη δυνατότητα να καλύψει τις μελλοντικές ενεργειακές ανάγκες της ανθρωπότητας.

1.5 Η εξέλιξη της ενέργειας ιστορικά

Η εξέλιξη της καθημερινής δραστηριότητας έως τις μέρες μας είναι άρρηκτα συνυφασμένη με τη χρήση της ενέργειας, καθώς διαχρονικά χρησιμοποιούνται διάφορες μορφές αυτής για την ικανοποίηση των βασικών αναγκών διαβίωσης της ανθρώπινης κοινότητας. Ο σύγχρονος τρόπος ζωής είναι δομημένος πάνω στη χρήση ενέργειας, με τον βαθμό εξάρτησης να είναι τόσο μεγάλος, που καμία παρατεταμένη ολική διακοπή της ενέργειας δεν θεωρείται αποδεκτή. Ένα τέτοιο ενδεχόμενο θα έθετε το μεγαλύτερο μέρος του πλανήτη αντιμέτωπο με μη διαχειρίσιμες κοινωνικές καταστάσεις.

Επιπλέον, ο ραγδαίος ρυθμός μεταβολής του παγκόσμιου πληθυσμού δημιουργεί συνεχώς αυξανόμενες απαιτήσεις για κατανάλωση ενέργειας. Οι ΑΠΕ βρίσκονται στο επίκεντρο της μετάβασης σε συστήματα χαμηλής έντασης άνθρακα και βιώσιμα ενεργειακά συστήματα. Σύμφωνα με τον Διεθνή Οργανισμό Ενέργειας (International Energy Agency, n.d.), η δυναμικότητα παραγωγής έχει αυξηθεί σημαντικά τα τελευταία


χρόνια λόγω της πολιτικής υποστήριξης των ΑΠΕ και των σημαντικών μειώσεων του κόστους για τα ηλιακά φωτοβολταϊκά.

Η ανάπτυξη των ΑΠΕ στους τομείς της ηλεκτρικής ενέργειας, της θερμότητας και των μεταφορών αποτελεί κύριο παράγοντα για την αντιμετώπιση της αύξησης της μέσης παγκόσμιας θερμοκρασίας κατά λιγότερο από 1,5°C. Σύμφωνα με τον στόχο των Καθαρών Μηδενικών Εκπομπών έως το 2050 (Net Zero Emissions by 2050) (European Commission, n.d.) και τον Διεθνή Οργανισμό Ενέργειας, οι ΑΠΕ μπορούν να υποκαταστήσουν σχεδόν πλήρως την παραγωγή ηλεκτρικής ενέργειας από άνθρακα.

Τα ανανεώσιμα καύσιμα μεταφορών και οι ΑΠΕ που παράγουν θερμότητα ήδη συμβάλλουν και θα συνεχίσουν να συμβάλλουν σημαντικά στη μείωση των εκπομπών στους τομείς των μεταφορών, των κτιρίων και της βιομηχανίας. Ο τομέας της ηλεκτρικής ενέργειας παραμένει ο πιο κρίσιμος για τις ΑΠΕ, με κύριο στόχο την ταχεία ανάπτυξη των φωτοβολταϊκών και αιολικών πάρκων τα τελευταία χρόνια, κεφαλαιοποιώντας τη σημαντική συμβολή της υδροηλεκτρικής ενέργειας τις προηγούμενες δεκαετίες.

Καθώς η ηλεκτρική ενέργεια από ΑΠΕ αντιπροσωπεύει μόνο το ένα πέμπτο της παγκόσμιας κατανάλωσης, το ζητούμενο είναι η εύρεση μεγαλύτερου ρόλου για τις ΑΠΕ στις μεταφορές και τη θέρμανση, τομείς που είναι ιδιαίτερα κρίσιμοι για την επιθυμητή ενεργειακή μετάβαση. Σύμφωνα με τα Ηνωμένα Έθνη (United Nations, Department of Economic and Social Affairs, 2018), το 55% του παγκόσμιου πληθυσμού κατοικεί σήμερα σε αστικές περιοχές, ενώ για το 2050 το αντίστοιχο ποσοστό αναμένεται να ανέλθει στο 68%. Συνεπώς, τις επόμενες δεκαετίες οι πόλεις και τα μητροπολιτικά κέντρα θα διαδραματίσουν κεντρικό ρόλο στην ανάπτυξη και διανομή της παγκόσμιας ζήτησης ενέργειας (Madlener & Sunak, 2011).

Η ολοένα αυξανόμενη ζήτηση ενέργειας, που απεικονίζεται στην Εικόνα 1, εκφράζει τη βαθιά εξαρτημένη σχέση ενέργειας και κοινωνίας (Statista, n.d.).



Εικόνα 1: Προβλεπόμενη κατανάλωση ενέργειας παγκοσμίως από το 1990 έως το 2040, ανά πηγή ενέργειας, σε εκατομμύρια μετρικούς τόνους ισοδυνάμου πετρελαίου (Statista, n.d.)

Ένα από τα κρίσιμα ζητήματα που ενδιαφέρει την παγκόσμια κοινότητα αφορά την πρωτογενή παραγωγή ενέργειας. Τα τελευταία διακόσια χρόνια περίπου, οι άνθρωποι βασίζονταν σε μεγάλο βαθμό στον άνθρακα, το πετρέλαιο και άλλα ορυκτά καύσιμα για την τροφοδότηση από απλές καθημερινές συσκευές έως μέσα μεταφοράς και εργοστάσια. Τα ορυκτά καύσιμα έχουν ενσωματωθεί σε κάθε ανθρώπινη δραστηριότητα και οι εκπομπές αερίων από την καύση αυτών των πρώτων υλών έχουν φτάσει σε δραματικά υψηλά επίπεδα για τον πλανήτη.


Με την έναρξη της βιομηχανικής επανάστασης, έγινε φανερό ότι η ανθρώπινη δραστηριότητα άρχισε να επιφέρει σημαντικές και πολυ-επίπεδες αλλαγές στο περιβάλλον. Αρχικά, οι αλλοιώσεις είχαν αντίκτυπο μόνο σε τοπική κλίμακα, αλλά με την πάροδο του χρόνου, τη μεγέθυνση των ανθρωπίνων επεμβάσεων και την

επέκταση σχετικών δραστηριοτήτων παγκοσμίως, το πρόβλημα της περιβαλλοντικής ρύπανσης διογκώθηκε.

Η περιβαλλοντική ρύπανση αναφέρεται στην επιβάρυνση της φύσης και των οικοσυστημάτων από την ανθρώπινη δραστηριότητα, με αποτέλεσμα τη μόλυνση του περιβάλλοντος, που περιλαμβάνει τη ρύπανση του νερού, του εδάφους και του αέρα. Μία από τις σημαντικότερες μεταβολές που παρατηρούνται ως επακόλουθο της μόλυνσης του πλανήτη και οποία συνδέεται με πολλαπλές συνέπειες στο οικοσύστημά μας είναι η αύξηση της μέσης θερμοκρασίας της Γης (Εικόνα 2), ορολογία που συναντάται στη διεθνή βιβλιογραφία ως global warming.

GLOBAL LAND-OCEAN TEMPERATURE INDEX

Data source: NASA's Goddard Institute for Space Studies (GISS). Credit: NASA/GISS



Εικόνα 2: Μέση θερμοκρασιακή ανωμαλία για τα έτη 1880-2023 (NASA/GISS)

Η μέση θερμοκρασιακή ανωμαλία από το 1880 έως το 2023, σύμφωνα με την επίσημη σελίδα της NASA για τα ζωτικά σημεία του πλανήτη της Γης το 2023 ήταν η υψηλότερη στα χρονικά από τότε που άρχισε η καταγραφή των δεδομένων, δηλαδή το 1880! Η Γη ήταν περίπου 1.36 βαθμούς Κελσίου θερμότερη το 2023 σε σύγκριση με τον μέσο όρο του τέλους του 19ου αιώνα (1850-1900). (Global Temperature , n.d.)

Η υπερθέρμανση του πλανήτη λοιπόν είναι ένα από τα συμπτώματα της κλιματικής αλλαγής, των πολλαπλών και περίπλοκων αλλαγών, που συνεπακόλουθα επηρεάζουν τα καιρικά και κλιματικά του συστήματα.

Η κλιματική αλλαγή περιλαμβάνει τόσο την αύξηση των μέσων θερμοκρασιών, όσο και ακραία καιρικά φαινόμενα, που έχουν δραματικές συνέπειες, όπως τη μετατόπιση ζωικών, αλλά και ανθρώπινων πληθυσμών, με πιο πρόσφατο παράδειγμα στην Ελλάδα τις πλημμύρες με βιβλικές καταστροφές που έλαβαν χώρα στο Βόλο το 2023, τις καταστροφικές πλημμύρες που έλαβαν χώρα στα Ηνωμένα Αραβικά Εμιράτα το 2024, την καταστροφή της άγριας φύσης, την τήξη των παγετώνων, την άνοδο της θάλασσας, τους καύσωνες, τις ξηρασίες και τις πλημμύρες, την καταστροφή της βιοποικιλότητας, και μια σειρά άλλων σοβαρών επιπτώσεων.

Η κλιματική αλλαγή επιδεινώνεται σε μεγάλο βαθμό από την ατμοσφαιρική ρύπανση, η οποία είναι αποτέλεσμα της υπερεκμετάλλευσης των εμπορικών δραστηριοτήτων. Συνεπώς, η επιλογή εναλλακτικών πηγών ενέργειας σε γεωγραφικές περιοχές με κατάλληλα χαρακτηριστικά καθίσταται αναγκαία. Τα παραπάνω απεικονίζουν επίσης τη γενική δυσκολία παραγωγής ηλεκτρικής ενέργειας, σε κλίμακα συγκρίσιμη με τις συμβατικές πηγές ορυκτών καυσίμων. Αν και υπάρχουν εμπόδια στην εγκατάσταση και τη διάδοση των ΑΠΕ, αυτές οι πηγές ενέργειας γίνονται πιο βιώσιμες, ώριμες εμπορικά και τεχνολογικά, ενώ αντιπροσωπεύουν μεγαλύτερο μερίδιο της παραγωγής ηλεκτρικής ενέργειας (Ferrari, 2020).

1.6 Η ανάγκη πρόβλεψης της παραγωγής ενέργειας

Ο βασικότερος λόγος που η χρήση ΑΠΕ συνιστά έναν από τους σημαντικότερους στόχους σε πανευρωπαϊκό και παγκόσμιο επίπεδο είναι η προστασία του περιβάλλοντος με τη μείωση των εκπομπών ρύπων, αλλά και η ανάπτυξη μιας εύρωστης, σταθερής και βιώσιμης οικονομίας, μέσα από τον έλεγχο της παραγωγής και της διανομής της ενέργειας που παράγεται από τις ΑΠΕ. Αυτή η πολιτική θα συμβάλει στη σταθερότητα του δικτύου ενέργειας, καθώς και στον προσδιορισμό χαμηλότερου κόστους της μονάδας παραγωγής ενέργειας.

Στον **Πίνακα 1** παρακάτω, αναφέρεται το επίπεδο των εκπομπών ρύπων από ποικίλες τεχνολογίες παραγωγής ηλεκτρικής ενέργειας από το έτος 1880 έως το 2023, ώστε να γίνει αντιληπτή η αναγκαιότητας επιπλέον ανάπτυξης των ΑΠΕ.

Πίνακας 1: Συγκριτική ανάλυση των πλεονεκτημάτων και μειονεκτημάτων των ανανεώσιμων πηγών ενέργειας (Ipsakis, 2011)

Τεχνολογία	SO ₂ σε kg/MWh	NO _x σε kg/MWh	CO ₂ σε kg/MWh
Καύση άνθρακα (καμίνι)	630-1370	630-1560	830-920
Πυρηνική	0	0	0
Αεριοστρόβιλοι συνδυασμένου Κύκλου	45-140	650-810	370-420
Μεγάλοι ΥδροΗλεκτρικοί Σταθμοί	18-21	34-40	370-420
Ανανεώσιμη ΔΠ	0	0	0
Μικρές ΥΗ μονάδες	38-46	71-86	16-20
Μεσαίες ΥΗ μονάδες	24-29	45-56	10-12
Ανεμογεννήτριες 4.5 m/s	18-32	26-43	19-34
Ανεμογεννήτριες 5.5 m/s	13-20	18-27	13-22
Ανεμογεννήτριες 6.5 m/s	10-16	14-22	10-17
Φωτοβολταϊκά Μονοκρυσταλλικά	230-295	270-340	200-260
Πολυκρυσταλλικά	260-330	250-310	190-250
Άμορφα	135-175	160-200	170-220
Γεωθερμία	0	0	0
Ωκεάνια	0	0	0

Στον πίνακα αυτόν παρατηρείται ότι, στην καύση ορυκτού άνθρακα με τη λειτουργία των Ατμοηλεκτρικών Σταθμών (ΑΗΣ) παρουσιάζεται η μεγαλύτερη κατανάλωση διοξειδίων του θείου (SO₂), οξειδίων του αζώτου (NO_x) και διοξειδίου του άνθρακα (CO₂), οι οποίοι είναι οι ρύποι με τη μεγαλύτερη επίδραση στο φαινόμενο του θερμοκηπίου και την κλιματική αλλαγή,. Στον αντίποδα, μηδενικούς ρύπους έχουν η γεωθερμία, οι πυρηνικοί σταθμοί παραγωγής ενέργειας και η ενέργεια των ωκεανών. Ακόμη, όσον αφορά τους υδροηλεκτρικούς σταθμούς (ΗΔΣ), τις ανεμογεννήτριες, καθώς και τα Φ/Β, εμφανίζουν μειωμένους ρύπους. Συμπερασματικά, οι μονάδες ΑΠΕ μπορούν να προσφέρουν λύσεις στο πρόβλημα της μείωσης των εναέριων ρύπων που προέρχονται από την καύση των ορυκτών καυσίμων.

Επιπλέον, οι ΑΠΕ και η πρόβλεψη της παραγωγής τους ανά σημείο ενδιαφέροντος μπορούν να συμβάλουν στην καλύτερη ανάπτυξη και διαχείριση των δικτύων διανομής ενέργειας, στην εξισορρόπηση της προσφοράς και της ζήτησης στην εθνική και διεθνή

αγορά ενέργειας, καθώς και στη διαχείριση των δικαιούμενων ρύπων ανά χώρα ή οργανισμό. Η πρόβλεψη της ηλεκτρικής ενέργειας που παράγεται από τα φωτοβολταϊκά (Φ/Β) σε ωριαία βάση είναι ζήτημα καθολικής σημασίας, όχι μόνο για την ασφαλή λειτουργία του συστήματος, αλλά και για την παροχή υψηλής ποιότητας ισχύος, με όσο το δυνατόν χαμηλότερο κόστος, στο συντομότερο δυνατό χρονικό διάστημα πρόβλεψης. Συνήθως, οι προβλέψεις παραγωγής των Φ/Β δίνονται ως προβλέψεις σημείου, που αντιπροσωπεύουν την πιο πιθανή τιμή της μελλοντικής παραγόμενης ενέργειας για ένα συγκεκριμένο χρονικό διάστημα.

Τα μοντέλα πρόβλεψης των Φ/Β πάρκων χρησιμοποιούν ως είσοδο δεδομένα διάφορων μοντέλων, κάποια εκ των οποίων θα αναλυθούν στην παρούσα εργασία. Αυτά τα μοντέλα παρέχουν εκτιμήσεις της μελλοντικής παραγωγής ενέργειας, χρησιμοποιώντας ιστορικές τιμές με ενσωματωμένες παραμέτρους εποχικότητας, λαμβάνοντας υπόψη διάφορους παράγοντες επηρεασμού και παλαιότερες χρονοσειρές της φωτοβολταϊκής παραγωγής.

Ως απόρροια όλων των παραπάνω προβληματισμών, στα πλαίσια της παρούσας διπλωματικής εργασίας, ο ερευνητής εξετάζει την αποτελεσματικότητα της πρόβλεψης ενέργειας (μέσω τεχνολογιών πρόσληψης ηλιακής ενέργειας όπως τα Φ/Β) με χρήση των εξής μοντέλων:

A. Προσαρμοστικό Νευροασαφές Σύστημα Συμπερασμού (ANFIS),

B. Τεχνητό Νευρωνικό Δίκτυο (ΤΝΔ),

Γ. Μοντέλο Αυτοπαλινδρόμησης (Auto Regression),

Δ. Μοντέλο Αυτοπαλινδρόμησης Κινούμενου Μέσου (Auto Regression Moving Average-ARMA),

Ε. Μοντέλο Ασαφούς Συστήματος Συμπερασμού Τύπου 2 (FIS Type-2) με χρήση Particle Swarm Optimization (PSO).


1.7 Η εξέλιξη των ΑΠΕ στην Παγκόσμια Κοινότητα και στην Ευρωπαϊκή Ένωση

Η εκτεταμένη ενσωμάτωση των ΑΠΕ στα Συστήματα Ηλεκτρικής Ενέργειας (ΣΗΕ) και η αναδιάρθρωση των αγορών ηλεκτρικής ενέργειας, αποτελούν βασικούς στόχους της ενεργειακής πολιτικής της Ευρωπαϊκής Ένωσης (ΕΕ). Αυτό θα συνεχιστεί όπως δείχνει και η έκθεση του Διεθνούς Οργανισμού Ενέργειας (International Energy Agency, IEA) στην Εικόνα 3, η οποία παρουσιάζει τις τάσεις των ΑΠΕ στην παγκόσμια κοινότητα τα επόμενα χρόνια ανά τεχνολογία. Το 2023 υπήρξε καθοριστική χρονιά για την ανάπτυξη των ΑΠΕ για την επόμενη πενταετία.

Οι προσθήκες δυναμικότητας ηλεκτρικής ενέργειας από ΑΠΕ υπολογίζονταν σε 507 GW το 2023, σχεδόν 50% υψηλότερα από το 2022, σε περισσότερες από 130 χώρες, υποκινώντας μια σημαντική αλλαγή στην ευρεία αναπτυξιακή τάση των ΑΠΕ. Η παγκόσμια επιτάχυνση το 2023 οφειλόταν κυρίως στην επέκταση από έτος σε έτος της ακμάζουσας αγοράς της Κίνας για ηλιακά φωτοβολταϊκά (+116%) και αιολικά πάρκα (+66%).

Οι προσθήκες δυναμικότητας ανανεώσιμων πηγών ενέργειας θα συνεχίσουν να αυξάνονται τα επόμενα πέντε χρόνια, με τα ηλιακά φωτοβολταϊκά και τα αιολικά να σημειώνουν ρεκόρ αύξησης +96%. Αυτή η αύξηση οφείλεται στο χαμηλότερο κόστος παραγωγής τους σε σύγκριση με τα ορυκτά καύσιμα, καθώς και στην πολιτική στήριξη σε διεθνές επίπεδο που υποστηρίζει την ανάπτυξή τους.

Renewable electricity capacity additions by technology and segment




IEA. CC BY 4.0.

Notes: CSP = concentrated solar power. Capacity additions refer to net additions. Historical and forecast solar PV capacity may differ from previous editions of the renewable energy market report. This year, PV data for all countries have been converted to DC (direct current), increasing capacity for countries reporting in AC (alternating current). Conversions are based on an IEA survey of more than 80 countries and interviews with PV industry associations. Solar PV systems work by capturing sunlight using photovoltaic cells and converting it into DC electricity. The DC electricity is then usually converted using an inverter, as most electrical devices and power systems use AC. Until about 2010, AC and DC capacity in most PV systems were similar, but with developments in PV system sizing, these two values may now differ by up to 40%, especially in utility-scale installations. Solar PV and wind additions include capacity dedicated to hydrogen production.

Εικόνα 3: Εκτιμώμενη παραγωγή ενέργειας ΑΠΕ ανά Τεχνολογία Παραγωγής για τα έτη 2020-2028 (IEA,2024)

Σύμφωνα με το International Energy Association, οι προσθήκες ηλιακών φωτοβολταϊκών και αιολικών πάρκων προβλέπονται να υπερδιπλασιαστούν έως το 2028, σε σύγκριση με το 2022, ξεπερνώντας συνεχώς τα ρεκόρ παραγωγής κατά την προβλεπόμενη περίοδο, που εκτιμάται ότι θα ανέλθει σχεδόν σε συνολική ισχύ 710 GW. Ταυτόχρονα, θα γίνουν προσθήκες υδροηλεκτρικής και βιοενέργειας σε χαμηλότερο επίπεδο από την ανάπτυξη που συνέβη στα τελευταία πέντε χρόνια, καθώς η ανάπτυξη τους επιβραδύνεται στις αναδυόμενες οικονομίες, ιδιαίτερα στην Κίνα.

Electricity generation by technology, 2000-2028



IEA. CC BY 4.0.

Notes: Electricity generation from wind and solar PV indicate potential generation including current curtailment rates. However, it does not project future curtailment of wind and solar PV, which may be significant in a few countries by 2028. The Curtailment section below discusses some of these recent trends.

Εικόνα 4: Παραγωγή ΑΠΕ ανά είδος Τεχνολογίας (IEA, 2024)

Σύμφωνα με τις ίδιες εκτιμήσεις, οι ΑΠΕ θα ξεπεράσουν τον άνθρακα στις αρχές του 2025, καθιστώντας τις τη μεγαλύτερη πηγή παραγωγής ηλεκτρικής ενέργειας παγκοσμίως.

Μέχρι το 2028, η δυνητική παραγωγή ηλεκτρικής ενέργειας από ΑΠΕ αναμένεται να φτάσει περίπου τις 14.400 TWh, σημειώνοντας αύξηση σχεδόν 70% από το 2022.

Επιπλέον, κατά την επόμενη πενταετία, αναμένονται διάφορα σημαντικά ορόσημα για τις ΑΠΕ:

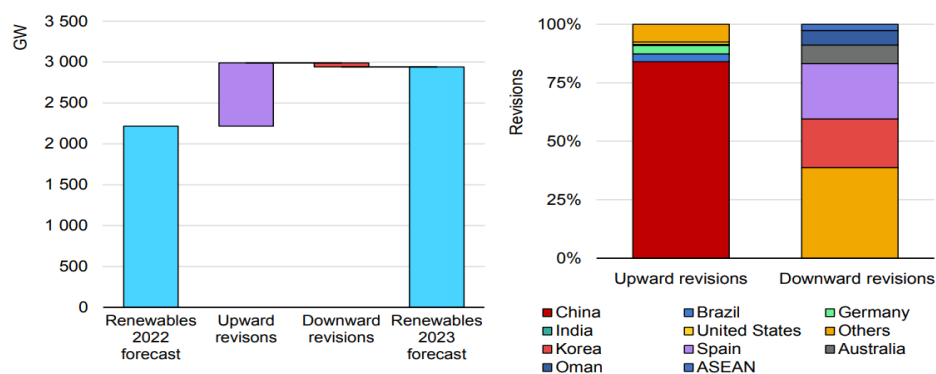
- ✓ Το 2024, η παραγωγή των ΑΠΕ θα ξεπεράσει την υδροηλεκτρική ενέργεια.
- ✓ Το 2025, οι ΑΠΕ θα ξεπεράσουν την παραγωγή ηλεκτρικής ενέργειας από άνθρακα.
- ✓ Το 2025, η παραγωγή από τα Αιολικά Πάρκα θα ξεπεράσει την παραγωγή ηλεκτρικής ενέργειας από πυρηνικά.

- ✓ Το 2026, τα ηλιακά φωτοβολταϊκά θα ξεπεράσουν την παραγωγή ηλεκτρικής ενέργειας από πυρηνικά, ενώ το 2028 θα ξεπεράσουν την παραγωγή αιολικής ενέργειας.
- ✓ Το 2028, οι ΑΠΕ υπολογίζεται ότι θα αντιπροσωπεύουν το 42% της παγκόσμιας παραγωγής ηλεκτρικής ενέργειας, με τα αιολικά και ηλιακά φωτοβολταϊκά να κατέχουν μερίδιο 25%. Η υδροηλεκτρική ενέργεια θα παραμείνει η μεγαλύτερη ανανεώσιμη πηγή ηλεκτρικής ενέργειας.

Κατά την προβλεπόμενη περίοδο, η αύξηση της παραγωγής ηλεκτρικής ενέργειας από ΑΠΕ θα υπερβαίνει την αύξηση της παγκόσμιας ζήτησης, υποδηλώνοντας μια αργή μείωση της παραγωγής ενέργειας από άνθρακα, ενώ η χρήση φυσικού αερίου θα παραμείνει σταθερή.

Ωστόσο, ενώ οι ΑΠΕ είναι σήμερα η μεγαλύτερη πηγή παραγωγής ηλεκτρικής ενέργειας σε 57 χώρες, κυρίως λόγω της υδροηλεκτρικής ενέργειας, αυτές οι χώρες αντιπροσωπεύουν μόλις το 14% της παγκόσμιας ζήτησης ενέργειας. Μέχρι το 2028, 68 χώρες θα έχουν τις ΑΠΕ ως κύρια πηγή παραγωγής ηλεκτρικής ενέργειας, αλλά θα αντιπροσωπεύουν μόνο το 17% της παγκόσμιας ζήτησης.

Renewable electricity capacity forecast revisions by country, 2023-2027, Renewables 2023 vs Renewables 2022




IEA. CC BY 4.0.

Notes: ASEAN = Association of Southeast Asian Nations. Capacity additions refer to net additions. Comparison periods are the forecasts for 2023 to 2027.

Εικόνα 5: Παραγωγή ενέργειας από ΑΠΕ στην Παγκόσμια Κοινότητα, για την περίοδο 2023-2027 (IEA, 2024)

Όπως απεικονίζεται και στις Εικόνες 5 και 6, οι προβλέψεις για την ανάπτυξη των ΑΠΕ έχουν αναθεωρηθεί προς τα πάνω, με τις τάσεις της τεχνολογίας να ποικίλλουν ανάλογα με τη χώρα και την περιοχή. Σύμφωνα με τον Διεθνή Οργανισμό Ενέργειας (International Energy Agency, IEA), οι παγκόσμιες προβλέψεις για τις ΑΠΕ αναθεωρούνται ετησίως. Για το έτος 2023, η αναθεώρηση ανήλθε σε 728 GW.


Για τις περισσότερες χώρες και περιοχές, αυτή η αναθεώρηση αντανακλά αλλαγές στην πολιτική και βελτιωμένα οικονομικά στοιχεία για μεγάλης κλίμακας αιολική και ηλιακή ενέργεια, φωτοβολταϊκά (Φ/Β) έργα, καθώς και ταχύτερη υιοθέτηση καταναλωμένων φωτοβολταϊκών συστημάτων από τους καταναλωτές. Επιπλέον, ανταποκρίνεται βοηθητικά έναντι στις υψηλότερες τιμές ηλεκτρικής ενέργειας.



Εικόνα 6: Πρόβλεψη παραγωγής ενέργειας από ΑΠΕ, ανά είδος Τεχνολογίας για την περίοδο 2023-2028 (IEA, 2024)

Ευρωπαϊκή Ένωση και οι Ευρωπαϊκές αγορές ηλιακής ενέργειας 2023 / Φωτοβολταϊκά Πάρκα

Συνολικά η παραγωγή της Ευρώπης σε ΑΠΕ σύμφωνα με τον οργανισμό Solar Power Europe για το έτος 2023 υπήρξε η εξής:



Εικόνα 7: Ανάπτυξη της παραγωγής από Φ/Β για την περίοδο 2001 -2023 (Solar Power Europe, 2023)

Όπως φαίνεται από την Εικόνα 7 παραπάνω, το 2023, η παραγωγή ενέργειας από Φ/Β της ΕΕ ακολούθησαν το κύμα που δημιουργήθηκε από τις πολιτικές και ενεργειακές αναταράξεις που προέκυψαν το έτος 2022.

Η αύξηση των τιμών της ηλεκτρικής ενέργειας και του αερίου και ο φόβος για διακοπές στην προμήθεια ενέργειας που τροφοδοτήθηκε από την ρωσική εισβολή στην Ουκρανία, είχαν ως αποτέλεσμα σοβαρές ανησυχίες για την ενεργειακή ασφάλεια, ενώ έθεσαν την ηλιακή ενέργεια σε ένα εντελώς νέο πλαίσιο, κάνοντας το 2022 το έτος της αναγνώρισης της φωτοβολταϊκής τεχνολογίας ως καθοριστικής, οικονομικά αποδοτικής και γρήγορα αναπτυσσόμενης τεχνολογίας για την παραγωγή ενέργειας.


Περισσότερο από ποτέ, οι Ευρωπαίοι ανακάλυψαν τη λύση να ηλεκτροδοτούν τα συστήματα θέρμανσής τους μέσω αντλιών θερμότητας. Πολλοί Ευρωπαίοι πολιτικοί αναγνώρισαν την ηλιακή ενέργεια ως ένα κρίσιμο εργαλείο για να επιτρέψουν στους πολίτες την πρόσβαση σε ηλεκτρική ενέργεια, που είναι ταυτόχρονα πράσινη και οικονομικά προσιτή.

Το 2023, οι επιπτώσεις αυτής της αλλαγής έγιναν ακόμη πιο εμφανείς - με νέα ρεκόρ εγκαταστάσεων σε όλη την ΕΕ, αλλά και πολλές προκλήσεις. Ως αποτέλεσμα, η τιμή της ηλεκτρικής ενέργειας μειώθηκε σημαντικά καθόλη τη διάρκεια του 2023. Για παράδειγμα, στη Γερμανία, η τιμή της ηλεκτρικής ενέργειας για τα νοικοκυριά αυξήθηκε σε 58 eurocents/kWh τον Οκτώβριο του 2022 και μειώθηκε απότομα εντός 12 μηνών σε 39 eurocents/kWh.

Παρόλο που η τιμή της ηλεκτρικής ενέργειας είναι ακόμα υψηλότερη από τις τιμές που υπήρχαν πριν από την ενεργειακή κρίση, η αντίληψη της επείγουσας ανάγκης έχει μειωθεί, ειδικά καθώς ο φόβος για διακοπή της ηλεκτροδότησης έχει σχεδόν εξαφανιστεί!


Σε συνδυασμό με τους υψηλούς πληθωριστικούς ρυθμούς, η ζήτηση για οικιακά φωτοβολταϊκά Φ/Β επιβραδύνθηκε στο δεύτερο εξάμηνο του 2023. Εγκαταστάθηκαν 55.9 GW νέων φωτοβολταϊκών στα 27 κράτη μέλη, με ρυθμό ανάπτυξης 40% από τα επίπεδα του 2022, και, για τρίτη συνεχόμενη χρονιά, ήρθε ένα νέο ρεκόρ εγκαταστάσεων, (βλ. Εικόνες 4 & 5). Είναι εντυπωσιακό να σημειωθεί ότι, για τρίτη συνεχόμενη χρονιά, η ετήσια αγορά της ΕΕ-27 έχει αυξηθεί κατά τουλάχιστον 40% ετησίως. Αυτή η επίδοση σηματοδοτεί επίσης το 6ο συνεχόμενο έτος ανάπτυξης της αγοράς της ΕΕ σε σύγκριση με το προηγούμενο έτος. Αναδρομικά στην αρχή αυτής της σειράς, το 2017, το μέγεθος της αγοράς ήταν χαμηλό στα 5.1 GW, λιγότερο από ένα δέκατο των σημερινών όγκων. Μόνο μετά την άρση των μέτρων προστασίας του εμπορίου για τα φωτοβολταϊκά PV το 2018, η αγορά άρχισε να αναπτύσσεται ισχυρά.

Στις παρακάτω Εικόνες 8, 9 και 10, παρουσιάζεται η παραγωγή ΑΠΕ ανά χώρα της ΕΕ. Επίσης, απεικονίζονται οι πρωτοπόρες χώρες (TOP 10 MARKETS) για το 2022-2023 σε παραγωγή GW από Φωτοβολταϊκά (Solar Power Europe, 2023).




© SOLARPOWER EUROPE 2023

Εικόνα 8: Παραγωγή ΑΠΕ ανά χώρα ΕΕ 2000-2023 (Solar Power Europe, 2023)



© SOLARPOWER EUROPE 2023

Εικόνα 9: Παραγωγή ΑΠΕ, ανά χώρα ΕΕ 2022/2023 (Solar Power Europe, 2023)



© SOLARPOWER EUROPE 2023

Εικόνα 10: Εγκατεστημένη ηλιακή Φ/Β ισχύς from 2000 to 2023 για τις 10 μεγαλύτερες σε παραγωγή χώρες της Ευρωπαϊκής Ένωσης (Solar Power Europe, 2023)

Παρατηρώντας τα συνολικά μερίδια των κορυφαίων αγορών ηλιακής ενέργειας της Ευρωπαϊκής Ένωσης (ΕΕ), φαίνεται ότι η Γερμανία έχασε έδαφος παρά τη σημαντική της ανάπτυξη το 2023.

Συγκεκριμένα, ο στόλος ηλιακής ενέργειας της Γερμανίας μειώθηκε κατά 2 ποσοστιαίες μονάδες, φτάνοντας το 31%. Αυτό το ποσοστό είναι σημαντικό, καθώς υποδεικνύει ότι το ένα τρίτο του συνόλου της ηλιακής ενέργειας της ΕΕ βρίσκεται στα χέρια μίας μόνο χώρας. Ωστόσο, είναι σημαντικό ότι το συγκεντρωτικό μερίδιο της ομάδας των 11 κορυφαίων σε παραγωγή ΑΠΕ χωρών συνεχίζει να μειώνεται προοδευτικά, φτάνοντας στο επίπεδο του 89% το 2023, σε σύγκριση με το 90% το 2022 και το 94% το 2021. Αυτό πρακτικά σημαίνει ότι νέες χώρες εισέρχονται στην παραγωγή των ΑΠΕ, κάτι που θα ενισχύσει τόσο τις εθνικές τους οικονομίες, όσο και τους συνολικούς στόχους της ΕΕ για έναν καθαρότερο πλανήτη.

1.8 Αγορά Ανανεώσιμων Πηγών Ενέργειας

Οι παγκόσμιες ενεργειακές ανάγκες εξακολουθούν να καλύπτονται κυρίως από την καύση ορυκτών καυσίμων, καθώς αυτά προσφέρουν χαμηλότερο κόστος παραγωγής. Τα τελευταία χρόνια, το χάσμα μεταξύ του κόστους των συμβατικών πηγών και των ΑΠΕ μειώνεται σημαντικά, καθιστώντας την επένδυση στις ΑΠΕ πιο ελκυστική, ενώ το κόστος τους αναμένεται να μειωθεί ακόμη περισσότερο στο εγγύς μέλλον.

1.8.1 Τύποι αγορών ενέργειας

Σε αυτή την ενότητα, ο στόχος είναι να παρουσιαστούν οι διαφορετικοί τύποι αγορών ενέργειας που υφίστανται, καθώς και να αναλυθούν οι υφιστάμενοι μηχανισμοί για την υποστήριξη επενδύσεων στις ΑΠΕ.

Η τρέχουσα αγορά ενέργειας μπορεί να χωριστεί σε τέσσερις διακριτές κατηγορίες: προθεσμιακή, ημερήσια, ενδοημερήσια και αγορά εξισορρόπησης.

α. Προθεσμιακή αγορά ενέργειας (forward energy market): Επιτρέπει σε δύο μέρη να διαπραγματεύονται συμβόλαια μελλοντικής εκπλήρωσης, τα οποία είναι συμφωνίες που επιτρέπουν την αγορά ή πώληση ενός προκαθορισμένου ποσού ενέργειας, σε μια προκαθορισμένη τιμή σε συγκεκριμένη χρονική στιγμή στο μέλλον. Αυτά τα συμβόλαια μπορούν να συμφωνηθούν διμερώς (over-the-counter) ή να ανταλλαγούν μέσω μιας ενεργειακής ανταλλακτικής αγοράς (forward market). Ο αγοραστής είναι υποχρεωμένος να αγοράσει την ποσότητα ενέργειας που συμφωνήθηκε και ο πωλητής να την πωλήσει.

β. Ημερήσια αγορά ενέργειας (day ahead energy market): Στην αγορά αυτή, τα εμπλεκόμενα μέρη αγοράζουν ή πωλούν ηλεκτρική ενέργεια με την υποχρέωση παράδοσης την επόμενη μέρα. Η ενέργεια μπορεί να διαπραγματευτεί με διμερείς συμφωνίες (over-the-counter) ή μέσω μιας ενεργειακής ανταλλακτικής αγοράς.

γ. Ενδοημερήσια αγορά ενέργειας (intraday energy market): Σε αυτή την αγορά, επιτρέπεται η αγοραπωλησία ενέργειας από τους συμμετέχοντες κατά τη διάρκεια της ίδιας ημέρας. Θεωρείται πολύτιμο εργαλείο για τα εμπλεκόμενα μέρη, καθώς μπορούν συνεχώς να βελτιώνουν τις θέσεις τους, μειώνοντας πιθανές αποκλίσεις από τις προσφορές τους στην Ημερήσια αγορά.

δ. Αγορά εξισορρόπησης ενέργειας (balancing energy market): Οι συμμετέχοντες έχουν την ευκαιρία από τον διαχειριστή του ενεργειακού συστήματος να εξισορροπήσουν την παραγωγή ή την κατανάλωσή τους, για να εξασφαλίσουν μια σταθερή συχνότητα στο σύστημα. Οι συμμετέχοντες αποζημιώνονται όταν απαιτείται να αυξήσουν την παραγωγή ή να μειώσουν την κατανάλωσή τους, ενώ πρέπει να πληρώσουν ένα τέλος αν μειώσουν την παραγωγή ή αυξήσουν την κατανάλωσή τους.

1.8.2 Μηχανισμοί Υποστήριξης Επενδύσεων σε Ανανεώσιμες Πηγές Ενέργειας

Η κλιματική αλλαγή, η εξάντληση των ορυκτών καυσίμων και η επακόλουθη αύξηση των τιμών τους, έχουν επιταχύνει την υιοθέτηση των ΑΠΕ. Για να είναι όμως ανταγωνιστικές στην αγορά ενέργειας, οι κυβερνήσεις προσφέρουν οικονομικά πλεονεκτήματα στις ΑΠΕ και συνεπακόλουθα έχουν θεσπίσει ειδικούς φόρους για την παραγωγή ρυπαντών, καθώς και τη χρήση ορυκτών καυσίμων στην παραγωγή ηλεκτρικής ενέργειας.

Στον αντίποδα, για την προώθηση των ΑΠΕ υπάρχουν τρεις κύριοι μηχανισμοί: εγγυημένες τιμές, φορολογικά κίνητρα, όπως επιδοτήσεις ή εκπτώσεις φόρων, και πράσινα πιστοποιητικά.

1. **Εγγυημένη τιμή (Feed-in tariff, FIT):** Σύμφωνα με τους Couture et al. (2010), η εγγυημένη τιμή είναι ένας μηχανισμός σχεδιασμένος για να επιταχύνει περαιτέρω τις επενδύσεις στην αγορά ανανεώσιμης ενέργειας, εξασφαλίζοντας στους παραγωγούς μακροπρόθεσμα συμβόλαια αγοράς για την πώληση της παραγόμενης ηλεκτρικής ενέργειας. Για τη διάρκεια αυτών των συμβολαίων, οι παραγωγοί πληρώνονται με σταθερή τιμή για κάθε μονάδα ενέργειας που παράγουν και παρέχουν στο σύστημα ηλεκτρικής ενέργειας. Υπάρχουν δύο διακριτοί τρόποι εφαρμογής αυτού του μηχανισμού: σταθερή FIT και premium FIT, με την πρώτη να είναι η πιο ευρέως υιοθετημένη.

Η πολιτική της σταθερής FIT προσφέρει στους παραγωγούς, μια σταθερή τιμή για την ενέργειά που παράγουν για συγκεκριμένο χρονικό διάστημα, ανεξάρτητα από τις τρέχουσες τιμές ενέργειας. Αυτό λειτουργεί ως εξασφάλιση ότι, ό,τι κι αν συμβεί, οι

παραγωγοί θα κερδίσουν από την πώληση της ενέργειας τους, απομακρύνοντας έτσι μερικούς από τους κινδύνους που εμπλέκονται στις επενδύσεις σε ανανεώσιμη ενέργεια.

Από την άλλη πλευρά, η premium FIT προσφέρει στους παραγωγούς ενέργειας μια συμφωνία βασισμένη στην τιμή, που εξασφαλίζει ότι οι παραγωγοί ενέργειας θα πληρώνονται με βάση μια premium τιμή.

Η premium τιμή είναι το άθροισμα της χονδρικής τιμής με μια επιπλέον πληρωμή που μπορεί να είναι σταθερή ή κυμαινόμενη, βασισμένη σε μια κλίμακα που υπολογίζεται από τη διαφορά μεταξύ της μέσης χονδρικής τιμής και μιας προκαθορισμένης και συμφωνημένης τιμής. Αυτά τα συμβόλαια προσφέρουν επενδύσεις υψηλού κινδύνου - υψηλής ανταμοιβής, που αποφέρουν ανάλογα υψηλά κέρδη όταν η τιμή της ενέργειας αυξάνεται, αλλά επίσης έχουν αντίστοιχες απώλειες όταν μειώνονται. Είναι επίσης συνηθισμένο να καθορίζονται ανώτατα και κατώτατα όρια πληρωμών για να περιορίζεται η διαφορά μεταξύ των κερδών και των απωλειών.

2. Φορολογικές μειώσεις και επιδοτήσεις: Χρησιμοποιούνται ως χρηματοοικονομικά κίνητρα για να προωθηθούν οι επενδύσεις σε ΑΠΕ σε πολλές χώρες του κόσμου. Η Γερμανία, για παράδειγμα, χρησιμοποιεί μια πολιτική φορολογικής πίστωσης (Gesley, 2022) που βοηθά πολλούς παραγωγούς ανανεώσιμης ενέργειας να μειώσουν τις φορολογικές τους υποχρεώσεις, καθιστώντας έτσι τις ΑΠΕ πιο ανταγωνιστικές έναντι των συμβατικών πηγών, που έχουν υψηλότερους φορολογικούς συντελεστές, καθώς και φόρους εκπομπών ρυπαντών.

3. Πράσινα πιστοποιητικά: Σύμφωνα με την Ευρωπαϊκή Επιτροπή (The European Commission, 2021), τα πράσινα πιστοποιητικά θεωρούνται μια από τις πιο διαδεδομένες πολιτικές που αποσκοπούν στην προώθηση των ΑΠΕ, μαζί με την εγγυημένη τιμή. Σε αντίθεση με τις εγγυημένες τιμές που βασίζονται στην τιμή της αγοράς ενέργειας, αυτή η πολιτική βασίζεται στην ποσότητα της ενέργειας. Οι παραγωγοί ενέργειας επιβραβεύονται με πράσινα πιστοποιητικά που αποδεικνύουν την παραγωγή μιας καθορισμένης ποσότητας ενέργειας από ανανεώσιμες πηγές, η οποία καθορίζεται από τις κυβερνήσεις, για να διασφαλίσει ότι ένα ορισμένο ποσοστό της συνολικής παραγόμενης ενέργειας

θα προέρχεται από ανανεώσιμες πηγές. Αυτά τα πιστοποιητικά είναι επίσης διαπραγματεύσιμα και η τιμή τους καθορίζεται ανάλογα με την σχετιζόμενη αγορά.

Τα πράσινα πιστοποιητικά θεωρούνται το αντίθετο των πιστοποιητικών εκπομπών ρύπων, που επιβάλλουν κόστος στην παραγωγή ενέργειας από συμβατικές, μη ανανεώσιμες πηγές.

1.9 Η χρήση προσαρμοστικού νεύρο-ασαφούς δικτύου για την πρόβλεψη της παραγωγής ενέργειας

Για να διασφαλιστεί η ενσωμάτωση της παραγόμενης ενέργειας από τα φωτοβολταϊκά (και γενικότερα από τις μονάδες αξιοποίησης της ηλιακής ενέργειας) στο ηλεκτρικό δίκτυο, η ακριβής πρόβλεψή της έχει καταστεί κρίσιμο στοιχείο των συστημάτων διαχείρισης ενέργειας. Η σωστή πρόβλεψη μπορεί να συμβάλει στη βελτίωση της εξισορρόπησης της παραγωγής με την ζήτηση στο δίκτυο και, συνεπώς, στη μείωση του συνολικού κόστους της ενέργειας για όλα τα εμπλεκόμενα μέρη.

Η παρούσα ερευνητική εργασία αποσκοπεί στην εξέταση και ανάλυση του συνδυασμού ασαφούς λογικής με τεχνητά νευρωνικά δίκτυα, για τη βελτίωση των προβλέψεων στον τομέα παραγωγής ηλεκτρικής ενέργειας από την αξιοποίηση της ηλιακής.

Ειδικότερα, εξετάζει διάφορα μοντέλα πρόβλεψης παραγωγής, εστιάζοντας στο ANFIS - Προσαρμοστικό Νευροασαφές Σύστημα Συμπερασμού, ένα Τεχνητό Νευρωνικό Δίκτυο (ΤΝΔ), ενώ εξετάζει το μοντέλο Αυτοπαλινδρόμησης AR, το μοντέλο Αυτοπαλινδρόμησης Κινούμενου Μέσου ARMA, και το Ασαφές Σύστημα Συμπερασμού Τύπου-2 (FIS type-2) με τη χρήση Particle Swarm Optimization (PSO).

Η ενσωμάτωση της παραγόμενης ηλεκτρικής ενέργειας στο δίκτυο, απαιτεί υψηλού επιπέδου ακρίβεια στις προβλέψεις, καθώς οι διακυμάνσεις στην παραγωγή μπορούν να έχουν σημαντικές επιπτώσεις στην σταθερότητα και στην αποδοτικότητα του συνόλου του συστήματος.

Επίσης, η επιλογή της μεθόδου ANFIS ως εργαλείου για την πρόβλεψη της παραγόμενης ενέργειας από μονάδες όπως τα Φ/Β, έχει ως στόχο την εκμετάλλευση των πλεονεκτημάτων που προσφέρει ο συνδυασμός της ασαφούς λογικής με τα νευρωνικά δίκτυα, δηλαδή την ικανότητα επεξεργασίας αβέβαιων και ανακριβών δεδομένων και την αντιμετώπιση πολύπλοκων μη-γραμμικών σχέσεων.

Κεφάλαιο 2: Σκοπός και στόχοι ερευνητικού έργου

2.1 Ερευνητικός στόχος του Συγγραφέα

Η διπλωματική αυτή εργασία εστιάζει στην ακριβή και σύγχρονη πρόβλεψη της ενέργειας που παράγεται από τις αντίστοιχες μονάδες ΑΠΕ, εκκινώντας από το μοντέλο υπολογισμού ANFIS.

Ο ερευνητής αποσκοπεί στο να εξηγήσει στον αναγνώστη τη σημασία της πρόβλεψης της παραγόμενης ενέργειας από τις ΑΠΕ, χρησιμοποιώντας ως παράδειγμα την ηλεκτρική ενέργεια που παράγεται από φωτοβολταϊκά.

Για να διασφαλιστεί η ενσωμάτωση της παραγόμενης ενέργειας στο δίκτυο, η ακριβής πρόβλεψή της έχει καταστεί ως κρίσιμος παράγοντας στα συστήματα διαχείρισης ενέργειας. Η σωστή πρόβλεψη μπορεί να συμβάλει στη βελτίωση της εξισορρόπησης της παραγωγής με την ζήτηση στο δίκτυο και, συνεπώς, στη μείωση του συνολικού κόστους της ενέργειας για τους πελάτες και το συνολικό σύστημα, αλλά και την αποφυγή «blackouts».

Η εργασία αυτή θα παρουσιάσει μια συγκριτική ανάλυση των αποτελεσμάτων που επιτυγχάνονται από τη χρήση του ANFIS και άλλων μοντέλων πρόβλεψης παραγωγής όπως, ένα Τεχνητό Νευρωνικό Δίκτυο (ΤΝΔ), ένα μοντέλο Αυτοπαλινδρόμησης (Auto Regression), ένα μοντέλο Αυτοπαλινδρόμησης Κινούμενου Μέσου ARMA (Auto Regression Moving Average) και ένα ασαφές σύστημα τύπου-2 με βελτιστοποίηση σμήνους σωματιδίων (Fuzzy Type-2 System with Particle Swarm Optimization).

Η έρευνα παρέχει σαφή δείγματα των επιδόσεων και της αποδοτικότητας του ANFIS σε σύγκριση με τα υπόλοιπα μοντέλα πρόβλεψης.

Έτσι, η ανάλυση της έρευνας αυτής θα επιτρέψει την κατανόηση των πλεονεκτημάτων και των περιορισμών της κάθε μεθόδου, ενισχύοντας τη βάση της επιστημονικής γνώσης για την ανάπτυξη πιο αποδοτικών και ταχύτερων μοντέλων πρόβλεψης στο άμεσο μέλλον.

2.2 Οικονομικά και Ενεργειακά Οφέλη των ΑΠΕ

Η ανάπτυξη των ΑΠΕ συνεισφέρει σημαντικά στην ενεργειακή ασφάλεια και τη βιώσιμη οικονομική ανάπτυξη, μειώνοντας την εξάρτηση από εισαγόμενα ορυκτά καύσιμα, και παρέχοντας οικονομικά οφέλη μέσω της εξοικονόμησης κόστους. Η συνεχής μείωση του κόστους κατασκευής των αιολικών πάρκων και των φωτοβολταϊκών εγκαταστάσεων ενισχύει την ανταγωνιστικότητα των ΑΠΕ και προωθεί μια ορθολογική αιφόρο ανάπτυξη. Επίσης, η μετάβαση στις ΑΠΕ συνδέεται άμεσα με την προώθηση μιας βιώσιμης και ανθεκτικής οικονομίας. Για παράδειγμα, στην έκθεση της IRENA για το 2022 μπορούμε να επιβεβαιώσουμε ότι οι ΑΠΕ μπορούν να μειώσουν σημαντικά το κόστος ενέργειας, να βελτιώσουν σημαντικά την ενεργειακή ασφάλεια, και να μειώσουν την εξάρτηση από εισαγόμενα ορυκτά καύσιμα (International Renewable Energy Agency [IRENA], 2022).

Βάσει της συγκεκριμένης μελέτης της IRENA, οι δείκτες που σχετίζονται με την παραγωγή ισχύος της αιολικής και – εν προκειμένω - της ηλιακής ενέργειας ως σημείο μιας εύρωστης εθνικής οικονομίας περιλαμβάνουν:

1. Μεγέθη Εγκατεστημένης Ισχύος και Παραγωγής:

Η συνολική εγκατεστημένη ισχύς και η ετήσια παραγωγή ηλεκτρικής ενέργειας που παράγεται από τα ηλιακά συστήματα, αλλά και τις υπόλοιπες ΑΠΕ, αποτελούν κρίσιμους δείκτες για την αξιολόγηση της συμβολής τους στην εθνική ενεργειακή οικονομία (Cherp et al., 2021).

2. Κόστος Ηλεκτρικής Ενέργειας: Η μείωση του κόστους ηλεκτρικής ενέργειας από αιολική και ηλιακή ενέργεια σε σύγκριση με τις παραδοσιακές πηγές ενέργειας ενισχύει την οικονομική ανταγωνιστικότητα των ΑΠΕ (Erdiwansyah et al., 2021).

3. Συμβολή στην Απασχόληση: Η δημιουργία θέσεων εργασίας από την ανάπτυξη της αιολικής και ηλιακής ενέργειας αποτελεί έναν σημαντικό δείκτη για την συνεισφορά τους στην εθνική οικονομία.

4. Εξοικονόμηση Κόστους και Ανταγωνιστικότητα: Η εξοικονόμηση κόστους λόγω της μειωμένης εξάρτησης από εισαγόμενα ορυκτά καύσιμα και η βελτίωση της ενεργειακής ασφάλειας μέσω της χρήσης ΑΠΕ, αποτελούν σημαντικούς δείκτες για την αξιολόγηση της συμβολής τους σε μια εύρωστη εθνική οικονομία (Smirnova et al., 2021).

5. Ενεργειακή Ανεξαρτησία: Η βελτίωση της ενεργειακής ανεξαρτησίας μέσω της αύξησης της παραγωγής ηλεκτρικής ενέργειας από ανανεώσιμες πηγές αποτελεί έναν ακόμη δείκτη για την εκτίμηση της συμβολής των ΑΠΕ σε μια εύρωστη εθνική οικονομία.

Αυτοί οι δείκτες υποδεικνύουν ότι η ανάπτυξη των ΑΠΕ είναι κρίσιμη για την ενίσχυση της οικονομικής ανάπτυξης, τη βελτίωση της ενεργειακής ασφάλειας και την προώθηση της εν γένει βιώσιμης ανάπτυξης.

Κεφάλαιο 3: Ανασκόπηση Ελληνικής & Διεθνούς Βιβλιογραφίας

3.1 Ανασκόπηση Ελληνικής και Διεθνούς Βιβλιογραφίας - Μέθοδοι Πρόβλεψης Παραγωγής Ενέργειας από Φ/Β και σύγκρισή τους

Τόσο η ελληνική, όσο και η διεθνής έρευνα στον τομέα των φωτοβολταϊκών συστημάτων και της πρόβλεψης παραγωγής ενέργειας έχει αναπτυχθεί σημαντικά, ιδιαίτερα τα τελευταία χρόνια με την διαρκώς αυξανόμενη ανάπτυξη των ανανεώσιμων πηγών ενέργειας. Ο ερευνητής μελέτησε λεπτομερώς διάφορες εργασίες και έρευνες πάνω στον τομέα αυτόν, που δίνουν έμφαση σε διαφορετικές τεχνικές πρόβλεψης και που περιγραφεί συνοπτικά στην παρούσα υποενότητα.

Οι Lai et al. (2020) έκαναν ανασκόπηση εφαρμογών μοντέλων μηχανικής μάθησης στις προβλέψεις διαφόρων πηγών ανανεώσιμης ενέργειας, μελετώντας AI τεχνικές όπως τεχνητά νευρωνικά δίκτυα (ANN) και δίκτυα μακράς βραχυπρόθεσμης μνήμης (LSTM), στατιστικές και υβριδικές μεθόδους όπως το προσαρμοστικό νευροασαφές σύστημα συμπερασμού (ANFIS). Εξέτασαν πολυποίκιλους τύπους δεδομένων εισόδου ανάλογα με την πηγή ανανεώσιμης ενέργειας. Τελικά διαπίστωσαν ότι οι AI και οι υβριδικές μέθοδοι βελτιώνουν την ακρίβεια πρόβλεψης, υπογραμμίζοντας παράλληλα τη σημασία της προεπεξεργασίας δεδομένων και της επιλογής κατάλληλων παραμέτρων.

Ο Νταφαλιάς (2021) διερεύνησε την πρόβλεψη παραγωγής ενέργειας από φωτοβολταϊκά (PV) πάρκα χρησιμοποιώντας ένα υπολογιστικό μοντέλο βασισμένο στα τεχνητά νευρωνικά δίκτυα (ANN) και την πολλαπλή γραμμική παλινδρόμηση (MLR). Τα δεδομένα εισόδου περιλάμβαναν μετεωρολογικές πληροφορίες και ιστορικά δεδομένα παραγωγής ηλεκτρικής ενέργειας. Τα αποτελέσματα έδειξαν σφάλματα πρόβλεψης MSE που κυμαίνονταν από 0,57% έως 13,75%, με μέσο σφάλμα 5,13%, ενώ η απόδοση του μοντέλου ήταν βελτιωμένη σε ηλιόλουστες ημέρες, ιδιαίτερα το καλοκαίρι. Το αναπτυγμένο μοντέλο συμβάλλει στην ακριβή πρόβλεψη ενέργειας και τη συμμόρφωση με τους κανονισμούς.

Οι Pitalúa-Díaz et al. (2019) συνέκριναν το ANFIS με τα μοντέλα πολλαπλής γραμμικής παλινδρόμησης (MLR) και βελτιστοποίησης καθόδου κλίσης (GDO) για την εκτίμηση της φωτοβολταϊκής ισχύος σε διάφορες τοποθεσίες στο Μεξικό. Τα δεδομένα

εισόδου περιλάμβαναν ηλιακή ακτινοβολία, θερμοκρασία, ταχύτητα ανέμου, ώρες ηλιοφάνειας και φωτοβολταϊκή ισχύ. Τα αποτελέσματα έδειξαν ότι το ANFIS πέτυχε το χαμηλότερο μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE), με 5.8% για το Hermosillo και 1.6% για την Πόλη του Μεξικού, σε σύγκριση με το MLR και το GDO. Η μελέτη κατέδειξε την υπεροχή του ANFIS έναντι των παραδοσιακών στατιστικών μεθόδων, αποδεικνύοντας βελτιωμένη ακρίβεια στην πρόβλεψη της φωτοβολταϊκής ισχύος σε διάφορες γεωγραφικές τοποθεσίες.

Η Οικονόμου (2023) διερεύνησε την βραχυπρόθεσμη πρόβλεψη της φωτοβολταϊκής ισχύος χρησιμοποιώντας δίκτυα Long-Short Term Memory (LSTM). Η μελέτη συνέκρινε το LSTM με μοντέλα ARIMA και ανέπτυξε ένα υβριδικό μοντέλο που συνδυάζει και τις δύο μεθόδους. Τα δεδομένα εισόδου περιλάμβαναν ιστορική παραγωγή ενέργειας, ηλιακή ακτινοβολία και μετεωρολογικά δεδομένα. Τα αποτελέσματα έδειξαν ότι τα μοντέλα LSTM υπερέιχαν των ARIMA, ιδίως όσον αφορά την ακρίβεια, ενώ το υβριδικό μοντέλο βελτίωσε περαιτέρω την απόδοση της πρόβλεψης, αποτυπώνοντας τη δυνατότητα για εφαρμογές σε πραγματικό χρόνο. Αυτή η έρευνα συμβάλλει στη βελτιστοποίηση των προβλέψεων παραγωγής ενέργειας από φωτοβολταϊκά πάρκα, υπογραμμίζοντας την αποτελεσματικότητα των τεχνικών μηχανικής μάθησης.

Οι Perveen et al. (2019) ανέπτυξαν ένα μοντέλο βασισμένο στο ANFIS για την πρόβλεψη της ενέργειας και την εφαρμογή του σε έξυπνα δίκτυα. Η μελέτη χρησιμοποίησε μετεωρολογικές παραμέτρους, όπως η θερμοκρασία περιβάλλοντος, η σχετική υγρασία και το σημείο δρόσου υπό διάφορες καιρικές συνθήκες, όπως καθαρό, θολό και νεφελώδη ουρανό. Το μοντέλο ANFIS συγκρίθηκε με τα SVM, FFNN, MARS, GRNN, LNN και μοντέλα πολλαπλής παλινδρόμησης. Τα αποτελέσματα έδειξαν ότι το ANFIS υπερτερεί των άλλων μοντέλων σε ακρίβεια, με χαμηλότερο MAPE και nRMSE. Αυτή η έρευνα κατέδειξε την αποτελεσματικότητα του ANFIS στη βελτίωση της αξιοπιστίας και της ανθεκτικότητας των προβλέψεων ενέργειας των φωτοβολταϊκών σε συστήματα έξυπνων δικτύων.

Το 2020, οι Perveen et al. ανέπτυξαν μοντέλα τεχνητών νευρωνικών δικτύων (ANN) για την πρόβλεψη της παγκόσμιας ενέργειας που παράγεται από φωτοβολταϊκά (Φ/Β) υπό διαφορετικές συνθήκες ουρανού στην Ινδία. Η μελέτη χρησιμοποίησε

μετεωρολογικά δεδομένα όπως ηλιακή ακτινοβολία, θερμοκρασία περιβάλλοντος, ταχύτητα ανέμου και σχετική υγρασία. Τα μοντέλα περιλάμβαναν το Radial Basis Function Neural Network (RBFNN) και προωθητικά νευρωνικά δίκτυα, τα οποία δοκιμάστηκαν υπό ηλιόλουστες, θολές, μερικώς νεφελώδεις και πλήρως νεφελώδεις συνθήκες. Το μοντέλο RBFNN παρουσίασε τα χαμηλότερα σφάλματα, με τιμές μέσου απόλυτου ποσοστού σφάλματος (MAPE) έως 0.0019% για θολές συνθήκες, ακολουθούμενες από 0.024% για ηλιόλουστες, 0.054% για μερικώς νεφελώδεις και 0.109% για πλήρως νεφελώδεις συνθήκες. Έτσι, φαίνεται η αποτελεσματικότητα των μοντέλων ANN στην ακριβή πρόβλεψη της παραγόμενης ενέργειας από Φ/Β, παρέχοντας πολύτιμες πληροφορίες για τη διαχείριση και τον σχεδιασμό της ενέργειας.

Εξάλλου, οι ίδιοι συγγραφείς το 2024, συνεχίζοντας τις έρευνές τους, ανέπτυξαν δύο μοντέλα ANN-ANFIS για την πρόβλεψη της ενέργειας υπό διάφορες καιρικές συνθήκες. Η μελέτη χρησιμοποίησε μετεωρολογικές παραμέτρους όπως ηλιακή ακτινοβολία, θερμοκρασία και ιστορικά δεδομένα παραγωγής ισχύος. Τα μοντέλα ANN-ANFIS συγκρίθηκαν με ασαφή μοντέλα και τα αποτελέσματα έδειξαν ότι το μοντέλο ANFIS πέτυχε με διαφορά την καλύτερη τιμή πρόβλεψης, όσον αφορά το μέσο όρο MAPE με 0.0031%, με το ANN να ακολουθεί με 0.011% και τελευταία να έρχονται τα ασαφή μοντέλα με μέσο MAPE 0.089%. Υπογραμμίζεται έτσι η ανώτερη ακρίβεια των μοντέλων ANN-ANFIS και η αποτελεσματικότητά τους στη βελτίωση των προβλέψεων ισχύος των φωτοβολταϊκών για τα συστήματα έξυπνων δικτύων.

Οι Viswanandya et al. (2019) ανέπτυξαν μοντέλα για βραχυπρόθεσμη πρόβλεψη της ηλεκτρικής ενέργειας από ηλιακή, χρησιμοποιώντας Ασαφή Λογική και το ANFIS. Οι ερευνητές χρησιμοποίησαν ως είσοδο μετεωρολογικά δεδομένα, όπως η ηλιακή ακτινοβολία, η θερμοκρασία, η σχετική υγρασία και η ταχύτητα του ανέμου. Τα αποτελέσματα έδειξαν ότι το ANFIS πέτυχε χαμηλότερα σφάλματα πρόβλεψης σε σύγκριση με την Ασαφή Λογική, με το MAPE και το nRMSE να δείχνουν την ανώτερη ακρίβεια του μοντέλου ANFIS. Αυτή η έρευνα υπογραμμίζει τη δυνατότητα του ANFIS για βελτίωση της πρόβλεψης της ενέργειας και την εφαρμογή της σε συστήματα έξυπνων δικτύων.

Οι Yadav et al. (2019) πρότειναν ένα μοντέλο PSO-tuned ANFIS, όπου ο αλγόριθμος PSO βελτιστοποίησε τις παραμέτρους του ANFIS, για βραχυπρόθεσμη πρόβλεψη της ισχύος φωτοβολταϊκών (PV). Η μελέτη χρησιμοποίησε μετεωρολογικά δεδομένα όπως ηλιακή ακτινοβολία, θερμοκρασία και ιστορική παραγωγή ισχύος PV από ένα φωτοβολταϊκό πάρκο 100 kW στην Ghaziabad, Ινδία. Τα αποτελέσματα έδειξαν ότι το μοντέλο PSO-ANFIS πέτυχε χαμηλότερο RMSE, MAPE και sMAPE σε σύγκριση με τα μοντέλα BPNN και standard ANFIS. Έτσι, η προτεινόμενη μέθοδος απέδειξε βελτιωμένη ακρίβεια πρόβλεψης και υπολογιστική αποδοτικότητα.

Ο Τσαγαλάς (2023) υλοποίησε το μοντέλο ARIMA και τη μεθοδολογία Box-Jenkins για την πρόβλεψη της παραγωγής ενέργειας από φωτοβολταϊκά (Φ/Β) συστήματα στην Ελλάδα, χρησιμοποιώντας ως δεδομένα εισόδου ιστορικές τιμές παραγωγής ενέργειας. Τα αποτελέσματα ανέδειξαν την αυξανόμενη τάση στην παραγωγή ενέργειας από Φ/Β, υπογραμμίζοντας την ανάγκη περαιτέρω επενδύσεων και ανάπτυξης στις ανανεώσιμες πηγές ενέργειας στην Ελλάδα.

Οι Abdullah et al. (2019) πρότειναν ένα μοντέλο WT-ANFIS-HFPSO, που υλοποιεί μετασχηματισμό κυματιδίου (WT), υβριδικούς αλγόριθμους πυγολαμπίδας (FF) και σμήνους σωματιδίων (PSO) για αξιόπιστη βραχυπρόθεσμη πρόβλεψη της ενέργειας από Φ/Β. Η μελέτη χρησιμοποίησε μετεωρολογικά δεδομένα όπως παγκόσμια ακτινοβολία, κεκλιμένη ακτινοβολία, θερμοκρασία πάνελ και δεδομένα ηλιακής ενέργειας. Τα αποτελέσματα έδειξαν ότι το WT-ANFIS-HFPSO υπερέιχε έναντι οκτώ άλλων μεθόδων πρόβλεψης, έχοντας τις χαμηλότερες τιμές RMSE, MSE και NRMSE, σε κάθε είδους καιρική συνθήκη.

Ο Χουστουλάκης (2022) συνείσφερε στην βελτίωση της ακρίβειας των προβλέψεων ισχύος Φ/Β, εξετάζοντας τη βραχυπρόθεσμη πρόβλεψη παραγωγής ενέργειας από αυτά, χρησιμοποιώντας ανάλυση δεδομένων και τεχνικές μηχανικής μάθησης. Η μελέτη συνέκρινε διάφορα μοντέλα, όπως Δέντρα Αποφάσεων, Μηχανές Διανυσμάτων Υποστήριξης (SVM) και Γραμμική Παλινδρόμηση, καθώς και υβριδικούς συνδυασμούς αυτών των μεθόδων. Χρησιμοποιήθηκαν ιστορικά δεδομένα παραγωγής και μετεωρολογικές παράμετροι όπως ηλιακή ακτινοβολία, θερμοκρασία και ταχύτητα ανέμου. Σύμφωνα με τα αποτελέσματα, το μοντέλο Δέντρου Αποφάσεων πέτυχε nRMSE της τάξης του 17.11% για μεγαλύτερα σύνολα δεδομένων, ενώ το

υβριδικό μοντέλο που συνδυάζει SVM και Δέντρο Αποφάσεων έδειξε την καλύτερη απόδοση με nRMSE 15.56%.

Η χρησιμότητα και πρωτίστως η ακρίβεια πρόβλεψης του ANFIS αποτυπώνεται και στην εργασία των Lara-Cerecedo et al. (2023), οι οποίοι ανέπτυξαν και βελτιστοποίησαν ένα μοντέλο ANFIS χρησιμοποιώντας τον αλγόριθμο βελτιστοποίησης σμήνους σωματιδίων (PSO) για την πρόβλεψη της παραγωγής ηλεκτρικής ενέργειας από ένα φωτοβολταϊκό σύστημα 60 kW. Η μελέτη χρησιμοποίησε μεταβλητές εισόδου όπως ηλιακή ακτινοβολία, θερμοκρασία πάνελ, θερμοκρασία περιβάλλοντος και ταχύτητα ανέμου, καθώς και δεδομένα παραγωγής ηλεκτρικής ισχύος. Το μοντέλο ANFIS πέτυχε RMSE 1.79 kW, RMSPE 3.075, MAE 0.864 kW, και MAPE 1.47%, ενώ το βελτιστοποιημένο μοντέλο ANFIS-PSO βελτίωσε αυτά τα αποτελέσματα με RMSE 0.754 kW, RMSPE 1.29, MAE 0.325 kW, και MAPE 0.556%.

Οι Rajasundrapandiyan et al. (2023) ανασκόπησαν τις τεχνικές πρόβλεψης ενέργειας από Φ/Β χρησιμοποιώντας μεθόδους μηχανικής μάθησης (ML) και βαθιάς μάθησης (DL). Η μελέτη επικεντρώθηκε σε μοντέλα όπως τεχνητά νευρωνικά δίκτυα (ANN), μηχανές διανυσμάτων υποστήριξης (SVM) και δίκτυα μακροπρόθεσμης-βραχυπρόθεσμης μνήμης (LSTM). Τα δεδομένα εισόδου περιλάμβαναν παγκόσμια ηλιακή ακτινοβολία, θερμοκρασία, ταχύτητα ανέμου καθώς και άλλες μετεωρολογικές παραμέτρους. Η ανασκόπηση κατέληξε ότι τα μοντέλα βαθιάς μάθησης (DL) συναγωνίζονται και σε κάποιες περιπτώσεις ξεπερνούν όλες τις άλλες παραδοσιακές τεχνικές πρόβλεψης, παράγοντας ακριβή και υποσχόμενα αποτελέσματα για την πρόβλεψη της ηλεκτρικής ενέργειας με βέλτιστη ακρίβεια.

Οι Andrianajaiana et al. (2023) ανέλυσαν και πρόβλεψαν την παραγωγή ηλεκτρικής ενέργειας χρησιμοποιώντας τεχνικές μηχανικής μάθησης σε έναν φωτοβολταϊκό σταθμό 1MW στη Miroslava, Iasi, της Ρουμανίας. Η μελέτη χρησιμοποίησε τις μεθόδους Απλής Εκθετικής Εξομάλυνσης (SES), Αυτοπαλινδρόμησης (AR), Εποχικής Αυτοπαλινδρόμησης Ολοκληρωμένου Κινούμενου Μέσου Όρου με Εξωγενείς Παράγοντες (SARIMAX), Εκθετικής Εξομάλυνσης Holt Winter (HWES), Νευρωνικού Δικτύου Long Short-Term Memory (LSTM) και Συνελικτικού Νευρωνικού Δικτύου (CNN). Τα δεδομένα εισόδου περιλάμβαναν ηλιακή ακτινοβολία, θερμοκρασία και

ταχύτητα ανέμου. Τελικά, το SARIMAX και τα νευρωνικά δίκτυα, συγκεκριμένα τα LSTM και CNN, παρήγαγαν τα καλύτερα αποτελέσματα από όλες τις εξεταζόμενες τεχνικές της παρούσας μελέτης.

Οι Sivaneasan et al. (2017) πρότειναν έναν αλγόριθμο πρόβλεψης ενέργειας από μονάδες ηλιακής, βασισμένο σε ένα μοντέλο τεχνητού νευρωνικού δικτύου (ANN) με προεπεξεργασία ασαφούς λογικής. Η μελέτη στόχευε στη βελτίωση της ακρίβειας της πολύ βραχυπρόθεσμης πρόβλεψης ενέργειας με την ενσωμάτωση μετεωρολογικών δεδομένων και ενός συντελεστή διόρθωσης σφάλματος. Το μοντέλο ANN εκπαιδεύτηκε χρησιμοποιώντας ιστορικά δεδομένα, και ένα εργαλείο προεπεξεργασίας ασαφούς λογικής εισήχθη για να διαχειριστεί πολύπλοκες εισόδους όπως η νέφωση, η θερμοκρασία και η ταχύτητα του ανέμου. Τα αποτελέσματα έδειξαν ότι το βελτιωμένο μοντέλο ANN με ασαφή λογική και διόρθωση σφάλματος πέτυχε μέσο απόλυτο ποσοστό σφάλματος (MAPE) 29.6%, σε σύγκριση με 43.1% με μόνο ασαφή λογική και 46.3% με το καθαρό μοντέλο ANN.

Οι Παναπακίδης και Χριστοφορίδης (2017) ανέπτυξαν ένα υβριδικό μοντέλο που συνδυάζει Τεχνητά Νευρωνικά Δίκτυα (ANN), Γενετικό Αλγόριθμο (GA) και ANFIS για την πολύ βραχυπρόθεσμη πρόβλεψη της ισχύος φωτοβολταϊκών συστημάτων, στοχεύοντας στη βελτίωση της ακρίβειας των προβλέψεων ισχύος των PV μέσω της χρήσης συνδυασμού ιστορικών τιμών ισχύος PV, ηλιακής ακτινοβολίας και δεδομένων θερμοκρασίας πάνελ. Το υβριδικό μοντέλο δοκιμάστηκε σε ένα σύστημα PV 20 kWp στην Ίο, Ελλάδα, χρησιμοποιώντας δεδομένα από τον Ιανουάριο 2012 έως τον Απρίλιο 2014. Το μοντέλο πέτυχε Μέσο Απόλυτο Σφάλμα (MAE) 0.4400 kW, Κανονικοποιημένο Τετραγωνικό Μέσο Σφάλμα (NRMSE) 6.3625% και Κανονικοποιημένο Μέσο Απόλυτο Σφάλμα (MARNE) 2.6497%, υπερέχοντας των αυτόνομων μοντέλων.

Οι Sujidha et al. (2024) επικεντρώθηκαν στην ανάπτυξη ενός controler ANFIS για την ανίχνευση του σημείου μέγιστης ισχύος (GMPPT) σε φωτοβολταϊκά συστήματα υπό συνθήκες μερικής σκίασης (PSC). Τα δεδομένα εισόδου περιλάμβαναν ηλιακή ακτινοβολία, θερμοκρασία και πρότυπα μερικής σκίασης. Η μελέτη αντιμετώπισε την πρόκληση των πολλαπλών τοπικών μεγίστων στην καμπύλη χαρακτηριστικών P-V που προκαλούνται από τις διόδους παράκαμψης, οι οποίες δυσκολεύουν την

παρακολούθηση του παγκόσμιου μέγιστου σημείου ισχύος (GMPP). Ο προτεινόμενος έξυπνος controller ενσωματώνει το ANFIS με την συμβατική μέθοδο Perturb and Observe (P&O) και τον Αλγόριθμο Πυροτεχνημάτων (FWA) για τη βελτίωση της ακρίβειας και της αποδοτικότητας της παρακολούθησης, κάτι που εν τέλει επιτυγχάνει.

Οι Mateo-Romero et al. (2024) ανέπτυξαν ένα μοντέλο ANFIS για την πρόβλεψη της παραγωγής ισχύος από φωτοβολταϊκά κύτταρα, χρησιμοποιώντας εικόνες ηλεκτροφωταύγειας (EL) και καμπύλες IV. Οι είσοδοι του μοντέλου περιλάμβαναν τον αριθμό μαύρων, γκρι και λευκών pixel στις εικόνες EL. Το ANFIS, που συνδυάζει τις δυνατότητες εκμάθησης των νευρωνικών δικτύων με τους κατανοητούς κανόνες της ασαφούς λογικής, έδειξε ανώτερη απόδοση με Μέσο Απόλυτο Σφάλμα (MAE) 0.064 και Μέσο Τετραγωνικό Σφάλμα (MSE) 0.009, υπερέχοντας άλλων μεθόδων όπως τα Υποστηρικτικά Διανύσματα Μηχανής και η Γραμμική Παλινδρόμηση.

Η Pawar (2022) ανέπτυξε ένα μοντέλο ANFIS για την πρόβλεψη της παραγωγής ενέργειας από φωτοβολταϊκά, χρησιμοποιώντας δεδομένα όπως η ηλιακή ακτινοβολία, η θερμοκρασία περιβάλλοντος, η σχετική υγρασία και η ημέρα του έτους. Το μοντέλο έδειξε ανώτερη απόδοση σε σύγκριση με την ανάλυση παλινδρόμησης, επιτυγχάνοντας ποσοστό σφάλματος 6.14%, σημαντικά καλύτερο από το ποσοστό σφάλματος 16% του μοντέλου παλινδρόμησης.

Οι Dawan et al. (2020) συνέκριναν την αποτελεσματικότητα του ANFIS και του ANN με PSO (PSO-ANN) για την πρόβλεψη παραγωγής ισχύος από φωτοβολταϊκά (PV) συστήματα. Η μελέτη χρησιμοποίησε δεδομένα εισόδου όπως ηλιακή ακτινοβολία, θερμοκρασία πάνελ, θερμοκρασία περιβάλλοντος και μετρήσεις παραγωγής ισχύος από ένα ηλιακό εργοστάσιο 14 MW στην περιοχή Nakhon Ratchasima, Ταϊλάνδη. Οι μετρικές σφάλματος που χρησιμοποιήθηκαν για την επαλήθευση περιλάμβαναν τα MSE, RMSE, MAE και MAPE. Τα αποτελέσματα έδειξαν ότι το ANFIS πέτυχε ακρίβεια 99.8532%, ξεπερνώντας το PSO-ANN που είχε ακρίβεια 98.9157% και ενισχύοντας εν τέλει τη λήψη επενδυτικών αποφάσεων για συστήματα Φ/Β.

Οι Kaloop et al. (2021) συνέκριναν διάφορες παραλλαγές του ANFIS και συγκεκριμένα τα ANFIS-PSO (Βελτιστοποίηση Σμήνους Σωματιδίων), ANFIS-APSO (Προσαρμοστική PSO), ANFIS-IPSO (Βελτιωμένη PSO), ANFIS-BBO (Βελτιστοποίηση Βιογεωγραφίας), ANFIS-GA (Γενετικός Αλγόριθμος), και ANFIS-

GWO (Βελτιστοποίηση Γκρίζου Λύκου). Τα δεδομένα εισόδου περιλάμβαναν ηλιακή ακτινοβολία, θερμοκρασία περιβάλλοντος και θερμοκρασία μονάδων από ένα σύστημα PV 960 kWP στη νότια Ιταλία. Η μελέτη βρήκε ότι το μοντέλο ANFIS-APSO πέτυχε τη μεγαλύτερη ακρίβεια με $R^2 = 0.835$ και $RMSE = 0.088$ kW σε ορίζοντα πρόβλεψης 12 ωρών, και $R^2 = 0.657$ και $RMSE = 0.081$ kW σε ορίζοντα πρόβλεψης 24 ωρών.

Οι Patel et al. (2022) διεξήγαγαν μια εκτενή και συστηματική μελέτη για την εκτίμηση της ηλιακής ακτινοβολίας και της ενέργειας χρησιμοποιώντας Τεχνητά Νευρωνικά Δίκτυα (ANN) και την Ασαφή Λογική. Η μελέτη έκανε ανασκόπηση σε διάφορα μοντέλα ANN, συμπεριλαμβανομένων των feed-forward back-propagation, multi-layer feed-forward, linear regression με ANN και GNN-based models, καθώς και μοντέλα Ασαφούς λογικής και ANFIS. Οι παράμετροι εισόδου περιλάμβαναν ηλιακή ακτινοβολία, θερμοκρασία και σχετική υγρασία. Η μελέτη βρήκε ότι τα μοντέλα ANFIS είχαν καλύτερη απόδοση σε σύγκριση με άλλες τεχνικές, αποτυπώνοντας έτσι την αποτελεσματικότητα των μοντέλων ANN και Ασαφούς λογικής στην προκειμένη περίπτωση.

Πίνακας 2: Συνοπτικός πίνακας διαφορετικών ερευνών με σύγκριση μεθόδων πρόβλεψης παραγωγής ενέργειας (Ελληνική και Διεθνής Βιβλιογραφία)

Βιβλιογραφική Αναφορά	Δεδομένα Εισόδου	Τεχνικές Πρόβλεψης	Αποτελέσματα - Ευρήματα	Συμπεράσματα
(Sivaneasan et al., 2017)	historical data, cloud cover, temperature, wind speed	ANN, Fuzzy Logic	MAPE: 29.6%	Βελτίωση ακρίβειας πρόβλεψης με χρήση ANN και ασαφούς λογικής
Panapakidis & Christoforidis, 2017)	Historical PV power data, solar irradiance, panel temperature	ANN, GA, ANFIS	MAE: 0.44 kW, NRMSE: 6.3625%, MARNE: 2.6497%	Βελτίωση ακρίβειας πρόβλεψης ισχύος PV με υβριδικό μοντέλο ANN/GA/ANFIS
(Yadav et al., 2019)	Solar irradiance, temperature, historical PV power production	PSO-ANFIS, BPNN, ANFIS	Χαμηλότερο RMSE, MAPE, sMAPE σε σύγκριση με BPNN και standard ANFIS	Βελτίωση ακρίβειας πρόβλεψης με PSO-ANFIS
(Viswavandya et al., 2019)	Solar irradiance, temperature, relative humidity, wind speed	Fuzzy Logic, ANFIS	Χαμηλότερα MAPE και nRMSE για ANFIS	Ανώτερη ακρίβεια ANFIS σε σύγκριση με Fuzzy Logic
(Abdullah et al., 2019)	Solar irradiance, panel temperature, solar energy data	WT-ANFIS-HFPSO	Χαμηλότερα RMSE, MSE, NRMSE σε κάθε καιρική συνθήκη έναντι οκτώ άλλων μεθόδων πρόβλεψης	Υπεροχή WT-ANFIS-HFPSO σε πρόβλεψη ηλιακής ενέργειας
(Pitalúa-Díaz et al., 2019)	Solar irradiance, temperature, wind speed, sunshine hours, PV power	ANFIS, MLR, GDO	MAPE: 5.8% (Hermosillo), 1.6% (Πόλη του Μεξικού)	Ανώτερη ακρίβεια ANFIS σε σύγκριση με MLR και GDO
(Perveen et al., 2019)	Ambient temperature, relative humidity, dew point	ANFIS, SVM, FFNN, MARS, GRNN, LNN, MLR	Χαμηλότερο MAPE και nRMSE για ANFIS	Ανώτερη ακρίβεια ANFIS σε σύγκριση με άλλες τεχνικές
(Perveen et al., 2020)	Solar irradiance, ambient temperature, wind speed, relative humidity	RBFNN, Feedforward ANN	Χαμηλότερα MAPE για RBFNN για κάθε καιρική συνθήκη	Υψηλή ακρίβεια ANN γενικά στην πρόβλεψη ΦΒ ισχύος

Βιβλιογραφική Αναφορά	Δεδομένα Εισόδου	Τεχνικές Πρόβλεψης	Αποτελέσματα - Ευρήματα	Συμπεράσματα
(Lai et al., 2020)	Various data depending on renewable energy source	ANN, LSTM, ANFIS	Βελτιωμένη ακρίβεια πρόβλεψης	Καίρια η σημασία προεπεξεργασίας δεδομένων και επιλογής παραμέτρων
(Dawan et al., 2020)	Solar irradiance, panel temperature, ambient temperature, power production	ANFIS, PSO-ANN	Ακρίβεια ANFIS: 99.8532%, PSO-ANN: 98.9157%	Ανώτερη ακρίβεια ANFIS σε σύγκριση με PSO-ANN
(Kaloop et al., 2021)	Solar irradiance, ambient temperature, module temperature	ANFIS-PSO, ANFIS-APSO, ANFIS-IPSO, ANFIS-BBO, ANFIS-GA, ANFIS-GWO	Ακρίβεια ANFIS-APSO: $R^2 = 0.835$, RMSE = 0.088 kW (12 ώρες), $R^2 = 0.657$, RMSE = 0.081 kW (24 ώρες)	Ανώτερη ακρίβεια ANFIS-APSO σε σύγκριση με άλλες τεχνικές
(Νταφαλιάς, 2021)	Meteorological data, historical power production data	ANN, MLR	MSE: 0.57% - 13.75%, μέσο σφάλμα 5.13%	Ανώτερη απόδοση μοντέλου σε ηλιόλουστες ημέρες
(Pawar, 2022)	Solar irradiance, ambient temperature, relative humidity, day of the year	ANFIS, Regression	Ποσοστό σφάλματος: 6.14%	Ανώτερη απόδοση ANFIS σε σύγκριση με παλινδρόμηση
(Patel et al., 2022)	Solar irradiance, temperature, relative humidity	Feed-forward back-propagation, multi-layer feed-forward, linear regression with ANN, GNN-based models, Fuzzy Logic, ANFIS	Ανώτερη απόδοση ANFIS σε σύγκριση με άλλες τεχνικές	Αποτελεσματικότητα ANFIS, ως αποτέλεσμα συνδυασμού ANN και Fuzzy Logic
(Χουστουλάκης, 2022)	Historical production data, solar irradiance, temperature, wind speed	Decision Trees, SVM, Linear Regression, Hybrid Models	nRMSE: 17.11% (Decision Trees), 15.56% (Hybrid SVM and Decision Tree)	Ανώτερη απόδοση υβριδικού μοντέλου

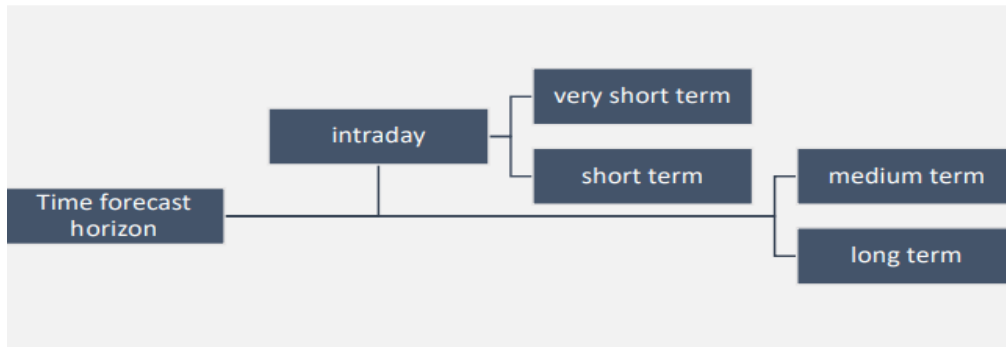
Βιβλιογραφική Αναφορά	Δεδομένα Εισόδου	Τεχνικές Πρόβλεψης	Αποτελέσματα - Ευρήματα	Συμπεράσματα
(Lara-Cerecedo et al., 2023)	Solar irradiance, panel temperature, ambient temperature, wind speed	ANFIS, ANFIS-PSO	ANFIS: RMSE: 1.79 kW, RMSPE 3.075, MAE 0.864 kW, MAPE 1.47%, ANFIS-PSO: RMSE 0.754 kW, RMSPE 1.29, MAE 0.325 kW, MAPE 0.556%	Ανώτερη ακρίβεια ANFIS-PSO
(Andrianajaiana et al., 2023)	Solar irradiance, temperature, wind speed	SES, AR, SARIMAX, HWES, LSTM, CNN	SARIMAX, LSTM, CNN παρήγαγαν τα καλύτερα αποτελέσματα	Ανώτερη απόδοση SARIMAX, LSTM και CNN
(Οικονόμου, 2023)	Historical power production, solar irradiance, meteorological data	LSTM, ARIMA, (Combined) Hybrid Model	Ανώτερη απόδοση LSTM, βελτίωση από υβριδικό μοντέλο	Αποτελεσματικότητα τεχνικών Machine Learning
(Rajasundrapandiyan et al., 2023)	Solar irradiance, temperature, wind speed, other meteorological parameters	Machine Learning & Deep Learning Techniques, incl. ANN, SVM, LSTM	Ανώτερη απόδοση Deep Learning σε σύγκριση με παραδοσιακές τεχνικές	Βέλτιστη ακρίβεια Deep Learning
(Τσαγαλάς, 2023)	Historical energy production values	ARIMA, Box-Jenkins	Αυξανόμενη τάση παραγωγής ενέργειας από Φ/Β	Ανάγκη επενδύσεων στις ΑΠΕ
(Mateo-Romero et al., 2024)	Electroluminescence (EL) images, IV curves	ANFIS, SVM, Linear Regression	ANFIS ανώτερο με: MAE: 0.064, MSE: 0.009	Ανώτερη απόδοση ANFIS σε σύγκριση με SVM και γραμμική παλινδρόμηση
(Sujidha et al., 2024)	Solar irradiance, temperature, partial shading patterns	ANFIS, Fuzzy Logic, P&O, Fireworks Algorithm	Βελτιωμένη αποδοτικότητα ANFIS-GMPPT υπό μερική σκίαση	Εφαρμογή ANFIS-GMPPT σε πραγματικές συνθήκες
(Perveen et al., 2024)	Solar irradiance, temperature, historical power production data	ANN-ANFIS, Fuzzy Models	MAPE: 0.0031% (ANN-ANFIS), 0.011% (ANN), 0.089% (Fuzzy Models)	Ανώτερη ακρίβεια ANN-ANFIS

3.2 Ταξινόμηση των προβλέψεων παραγωγής ενέργειας

Οι τύποι προβλέψεων ποικίλουν ανάλογα με τις διαφορετικές χρήσεις και ανάγκες που προκύπτουν για τα φωτοβολταϊκά (Φ/Β) συστήματα, καθώς μπορεί να εφαρμόζονται είτε σε μεμονωμένα Φ/Β συστήματα είτε στη συγκέντρωση μεγάλου αριθμού συστημάτων που είναι καταναμημένα σε μια εκτεταμένη γεωγραφική περιοχή. Ένα εξίσου σημαντικό σημείο που πρέπει να αναφερθεί είναι ότι οι μέθοδοι πρόβλεψης εξαρτώνται από τα εργαλεία και τις πληροφορίες που διατίθενται στους αναλυτές, όπως δεδομένα από μετεωρολογικούς σταθμούς και δορυφόρους, ιστορικά δεδομένα Φ/Β σταθμών και αποτελέσματα από μοντέλα αριθμητικής πρόβλεψης καιρού. Σε γενικές γραμμές, δεν υπάρχουν καθορισμένα κριτήρια για την κατηγοριοποίηση της πρόβλεψης ενέργειας από Φ/Β. Η πλειοψηφία των ερευνητών ταξινομεί την πρόβλεψη φωτοβολταϊκής ενέργειας βάσει των ιστορικών δεδομένων, του ορίζοντα πρόβλεψης, άλλων μετεωρολογικών δεδομένων και των μεθόδων που χρησιμοποιούνται για την πρόβλεψη (Das et al., 2018). Στα ακόλουθα εδάφια παρουσιάζονται γενικές κατηγορίες ταξινόμησης, όπως έχουν προκύψει από τη μελέτη σχετικών άρθρων.

3.2.1 Ταξινόμηση με βάση τον ορίζοντα πρόβλεψης

Η ταξινόμηση των μοντέλων πρόβλεψης με βάση τον χρονικό ορίζοντα δεν ακολουθεί συγκεκριμένα κριτήρια. Ωστόσο, οι προβλέψεις που αφορούν διάφορους χρονικούς ορίζοντες είναι κρίσιμες για πολλές πτυχές της λειτουργίας του δικτύου, όπως η διασφάλιση της σταθερότητας και ο προγραμματισμός των αποθεματικών πόρων. Σύμφωνα με πληθώρα επιστημονικών μελετών, υπάρχει μια γενικά αποδεκτή κατηγοριοποίηση, η οποία απεικονίζεται στην εικόνα 11.



Εικόνα 11: Ταξινόμηση πρόβλεψης φωτοβολταϊκής ισχύος με βάση τον χρονικό ορίζοντα

A. Πολύ βραχυπρόθεσμη πρόβλεψη (now-cast):

Η πολύ βραχυπρόθεσμη πρόβλεψη, επίσης γνωστή ως πρόβλεψη του παρόντος, αφορά χρονικούς ορίζοντες από λίγα δευτερόλεπτα έως μία ώρα και χρησιμοποιείται για την εξομάλυνση της ισχύος σε πραγματικό χρόνο. Αυτή η πρόβλεψη είναι καθοριστική για την αποτελεσματική ενσωμάτωση των φωτοβολταϊκών συστημάτων σε συστήματα διαχείρισης ενέργειας που είναι προηγμένα και που επικεντρώνονται στη δέσμευση μονάδων και τον προγραμματισμό ισχύος (Antonanzas et al., 2016).

B. Βραχυπρόθεσμη πρόβλεψη (short-term forecasts):

Η βραχυπρόθεσμη πρόβλεψη της παραγωγής φωτοβολταϊκής ισχύος αφορά χρονικούς ορίζοντες από μία ώρα έως μία εβδομάδα. Αυτού του είδους η πρόβλεψη είναι πολύτιμη για τον σχεδιασμό ενός ολοκληρωμένου συστήματος διαχείρισης ενέργειας φωτοβολταϊκών, καθώς και για την ενίσχυση της ασφάλειας του δικτύου. Τα μοντέλα αυτά συνήθως χρησιμοποιούνται για την προσαρμογή της παραγωγής και της ζήτησης, διευκολύνοντας έτσι τις προσφορές στην αγορά ηλεκτρικής ενέργειας (Hernandez et al., 2014).

Γ. Μεσοπρόθεσμη πρόβλεψη (medium-term forecasts):

Η μεσοπρόθεσμη πρόβλεψη της φωτοβολταϊκής ισχύος καλύπτει χρονικά διαστήματα από μία εβδομάδα έως έναν μήνα. Αυτός ο τύπος πρόβλεψης είναι χρήσιμος για τον προγραμματισμό του συστήματος ισχύος και τον σχεδιασμό της συντήρησης, καθώς επιτρέπει την πρόβλεψη της μελλοντικής διαθεσιμότητας ηλεκτρικής ενέργειας (Hossain et al., 2017).

Δ. Μακροπρόθεσμη πρόβλεψη (long-term forecasts):

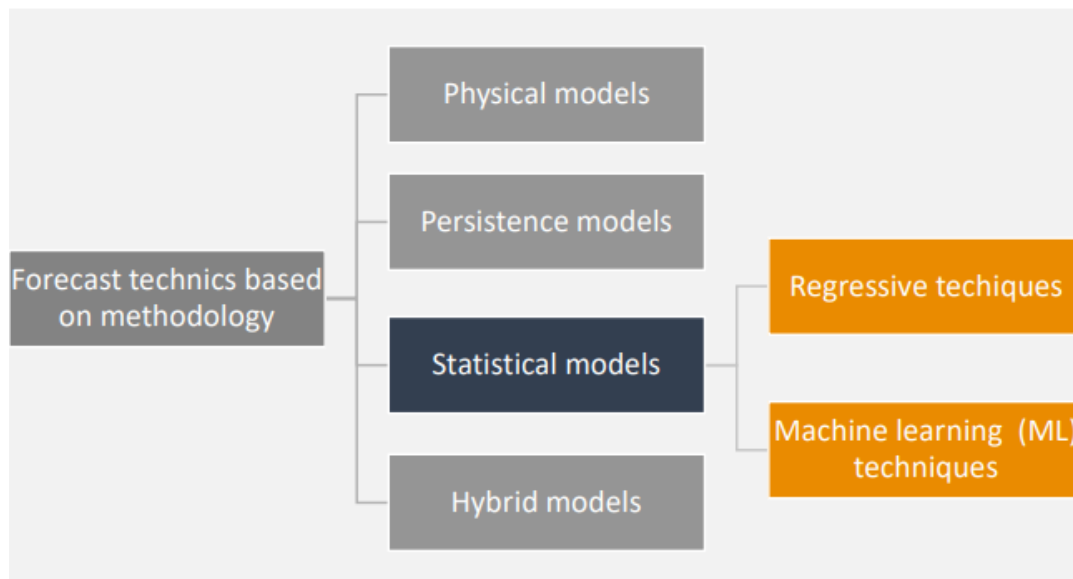
Η μακροπρόθεσμη πρόβλεψη της παραγωγής από φωτοβολταϊκά καλύπτει χρονικά διαστήματα από έναν μήνα έως ένα έτος. Αυτή η πρόβλεψη διευκολύνει τον προγραμματισμό της παραγωγής, της μεταφοράς και της διανομής ηλεκτρικής ενέργειας, εξασφαλίζοντας την ασφαλή λειτουργία του δικτύου και την οργάνωση εκτός των διαδικασιών υποβολής προσφορών. Επιπλέον, είναι πολύτιμη για χρηματοοικονομικές ασκήσεις και μοντελοποιήσεις από τους ιδιοκτήτες σταθμών παραγωγής ενέργειας.

Η παρούσα εργασία επικεντρώνεται στην πολύ βραχυπρόθεσμη πρόβλεψη της παραγωγής ενέργειας από μονάδες ηλιακής ενέργειας.

3.2.2 Ταξινόμηση με βάση τις μεθόδους πρόβλεψης

Οι μέθοδοι πρόβλεψης παραγωγής ενέργειας από φωτοβολταϊκά συστήματα δύνανται να διακριθούν με βάση την αξιοποίηση ιστορικών δεδομένων παραγωγής και σχετικών μετεωρολογικών παραμέτρων.

Οι βασικές προσεγγίσεις σε αυτές τις μεθόδους είναι δύο. Η πρώτη προσέγγιση περιλαμβάνει τη χρήση αναλυτικών εξισώσεων για τη μοντελοποίηση του φωτοβολταϊκού συστήματος. Αυτές οι μέθοδοι, γνωστές ως φυσικές ή παραμετρικές μέθοδοι, στηρίζονται κυρίως σε προβλέψεις ηλιακής ακτινοβολίας, που είναι ο κυριότερος παράγοντας παραγωγής ηλεκτρικής ενέργειας. Η δεύτερη προσέγγιση επικεντρώνεται στην άμεση πρόβλεψη της εξόδου ισχύος μέσω μεθόδων στατιστικής και μηχανικής μάθησης. Εκτός αυτού, μπορεί να χρησιμοποιηθεί και ένας συνδυασμός των δύο προσεγγίσεων, γνωστός ως υβριδικό μοντέλο. Σε αυτή την ενότητα, θα αναλυθούν οι πιο σημαντικές και διαδεδομένες τεχνικές που αναφέρονται στη βιβλιογραφία, όπως φαίνεται στην Εικόνα 12.



Εικόνα 12: Ταξινόμηση πρόβλεψης φωτοβολταϊκής ισχύος με βάση την προσέγγιση

A. Φυσικά μοντέλα (Physical models)

Τα φυσικά μοντέλα βασίζονται στα χαρακτηριστικά της φωτοβολταϊκής εγκατάστασης, όπως η γεωγραφική τοποθεσία, οι μετεωρολογικές μεταβλητές (numerical weather predictions - NWP) και τα ιστορικά δεδομένα προσανατολισμού. Αυτά τα μοντέλα μπορεί να κυμαίνονται από πολύ απλά (χρησιμοποιώντας μόνο τη συνολική ηλιακή ακτινοβολία) έως πολύπλοκα (συμπεριλαμβάνοντας επιπλέον παραμέτρους). Ωστόσο, δεν θεωρούνται ως άμεσες τεχνικές πρόβλεψης, καθώς η πρόβλεψη της ακτινοβολίας και των άλλων απαραίτητων μεταβλητών πραγματοποιείται σε προηγούμενο στάδιο. Η ακρίβεια αυτών των μοντέλων είναι υψηλότερη όταν οι καιρικές συνθήκες είναι σταθερές. Παρόλα αυτά, οι απότομες μεταβολές στις μετεωρολογικές παραμέτρους μπορούν να επηρεάσουν σημαντικά την ακρίβεια των προβλέψεων, και αυτό αποτελεί μια από τις κύριες πηγές σφάλματος για αυτήν τη μέθοδο.

B. Μοντέλα επιμονής (Persistence models)

Τα μοντέλα επιμονής αποτελούν τις πιο βασικές μεθόδους πρόβλεψης και χρησιμοποιούνται συχνά ως σημείο αναφοράς για την αξιολόγηση πιο εξελιγμένων μοντέλων, λόγω της απλότητάς τους. Η επιμονή βασίζεται στην υπόθεση ότι οι μελλοντικές τιμές των χρονοσειρών θα παραμείνουν ίδιες με τις τρέχουσες,

λαμβάνοντας υπόψη ότι παράμετροι όπως η ηλιακή ακτινοβολία και η θερμοκρασία του εδάφους δεν θα αλλάξουν από τον παρόντα στο μελλοντικό χρόνο. Ωστόσο, φαινόμενα όπως η ηλιακή ακτινοβολία και άλλες ατμοσφαιρικές συνθήκες παρουσιάζουν σαφή μη στασιμότητα λόγω των ημερήσιων και εποχικών κύκλων. Πληθώρα μελετών παρουσιάζουν τα αποτελέσματά τους κάνοντας χρήση της συγκριτικής βαθμολογίας τους, για να φανεί η βελτίωση ή η υποβάθμιση συγκριτικά με τα εν λόγω μοντέλα επιμονής. Εντούτοις, είναι σημαντικό να σημειωθεί ότι οι συγκρίσεις μεταξύ διαφορετικών μελετών πρέπει να γίνονται προσεκτικά λόγω της πληθώρας των μοντέλων αναφοράς, και μπορούν να πραγματοποιηθούν μόνο όταν τα μοντέλα επιμονής χρησιμοποιούν την ίδια μεταβλητή «εμμονής» (Antonanzas et al., 2016).

Η προβλεπόμενη παραγωγή ισχύος από φωτοβολταϊκά για τις επόμενες 24 ώρες δίνεται από την εξίσωση: $P_{f(t)} = P_{PD(t)}$,

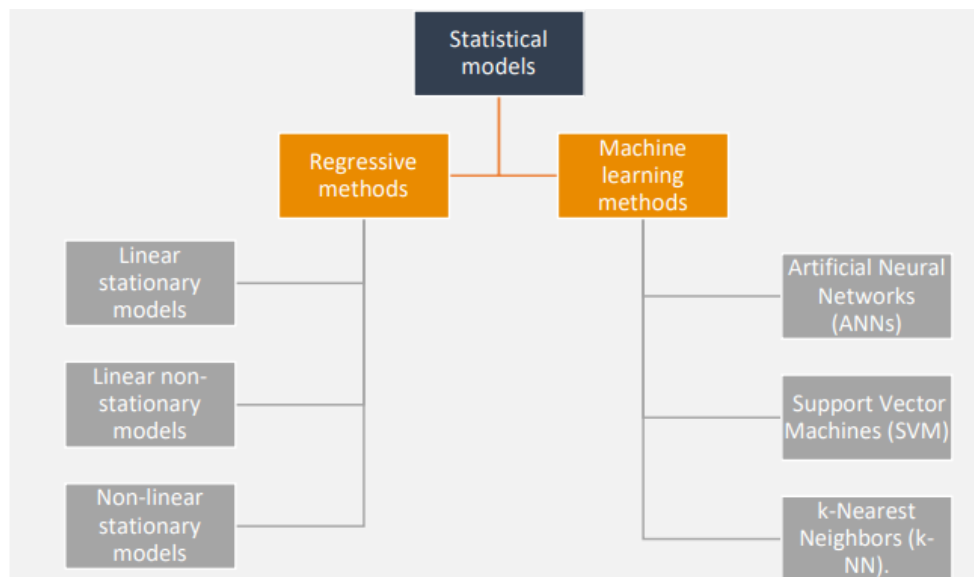
όπου $P_{f(t)}$ είναι η προβλεπόμενη ισχύς και $P_{PD(t)}$ είναι η ισχύς εξόδου της προηγούμενης ημέρας, την ίδια ώρα (X. Yang, Ren, & Yue, 2016).

Το μοντέλο επιμονής είναι συνήθως κατάλληλο για βραχυπρόθεσμη πρόβλεψη, ιδιαίτερα για προβλέψεις μίας ώρας μπροστά. Η ακρίβεια της πρόβλεψης αυτού του μοντέλου εξαρτάται από τη σταθερότητα των καιρικών συνθηκών. Όταν οι καιρικές συνθήκες είναι σταθερές, η ισχύς της προηγούμενης ημέρας μπορεί να είναι μια καλή ένδειξη για την ισχύ της επόμενης ημέρας. Ωστόσο, για χρονικά διαστήματα που περιλαμβάνουν σημαντικές μεταβολές στον ημερήσιο κύκλο, τα μοντέλα επιμονής τείνουν να αποδίδουν μετριότατα.

Γ. Στατιστικά μοντέλα (Statistical models)

Εστιάζοντας στην αναγνώριση σχέσεων ή μοτίβων από τα ιστορικά δεδομένα, αυτά τα μοντέλα έχουν αποδειχθεί πιο αποτελεσματικά από τα μοντέλα επιμονής στην προσομοίωση μιας φωτοβολταϊκής εγκατάστασης (Graditi, Ferlito, & Adinolfi, 2016). Συχνά χρησιμοποιούν χρονοσειρές, όπως την προσαρμογή καμπύλης, τον κινητό μέσο όρο (moving average - MA) και τα αυτόματα επεμβατικά μοντέλα (autoregressive - AR) (Ahmed & Khalid, 2019).

Τα στατιστικά μοντέλα αποτελούν μια προσέγγιση που βασίζεται στα δεδομένα, εξάγοντας σχέσεις από τα ιστορικά δεδομένα για την πρόβλεψη της μελλοντικής συμπεριφοράς του φωτοβολταϊκού πάρκου. Η ποιότητα αυτών των δεδομένων είναι κρίσιμη για την ακρίβεια των προβλέψεων. Σε αντίθεση με τις παραμετρικές μεθόδους, τα στατιστικά μοντέλα απαιτούν συνήθως ένα μεγάλο σύνολο ιστορικών δεδομένων (μετεωρολογικές μετρήσεις ή/και μετρήσεις ισχύος), προϋποθέτοντας ότι το φωτοβολταϊκό πάρκο λειτουργεί ήδη για κάποιο χρονικό διάστημα.



Εικόνα 13: Διαφορετικές Τεχνικές Στατιστικών Μοντέλων

Η επιλογή ενός κατάλληλου συνόλου δεδομένων για την εκπαίδευση είναι καθοριστικής σημασίας για την ακρίβεια του μοντέλου που θα δημιουργηθεί. Πολλές μελέτες έχουν διερευνήσει τη σχέση μεταξύ της επιλογής των εισροών και της τελικής απόδοσης του μοντέλου, αποκαλύπτοντας ενδιαφέροντα ευρήματα σχετικά με τον πιο αποδοτικό συνδυασμό εκμάθησης και συσχέτισης μετεωρολογικών συνθηκών (Almeida, Perpiñán, & Narvarte, 2015; Shi, Lee, Liu, Yang, & Wang, 2012). Η βελτιστοποίηση του συνόλου των εισόδων είναι δυνατόν να πραγματοποιηθεί μέσω της εφαρμογής ποικίλων τεχνικών που καθορίζουν τον συνδυασμό μεταβλητών που αποδίδει τα βέλτιστα αποτελέσματα, επιτυγχάνοντας μια ισορροπία μεταξύ πολυπλοκότητας και ακρίβειας.

Γ1. Παλινδρομικά Μοντέλα (Regressive Models)

Τα παλινδρομικά μοντέλα εκτιμούν τη σχέση μεταξύ μιας εξαρτημένης μεταβλητής, όπως η παραγωγή ενέργειας, και ορισμένων ανεξάρτητων μεταβλητών, όπως οι προβλέψεις. Η ανάλυση παλινδρόμησης αποτελεί μια επαναλαμβανόμενη διαδικασία που χρησιμοποιείται για ανάλυση, επαλήθευση, κριτική και τροποποίηση της εισόδου (Sobri, Koohi-Kamali, & Rahim, 2018).

Ανάλογα με τον τρόπο διαχείρισης των χρονοσειρών (γραμμική ή μη και στατική ή μη), προκύπτει μια περαιτέρω ταξινόμηση.

Γ1.1 Γραμμικά Στατικά Μοντέλα (Linear stationery models)

Τα μοντέλα αυτοπαλινδρόμησης (AutoRegressive - AR) χρησιμοποιούν τις προηγούμενες τιμές της διαδικασίας για να εκτιμήσουν την τρέχουσα τιμή (Inman, Pedro, & Coimbra, 2013). Ο συνδυασμός των μοντέλων AR και κινητού μέσου όρου (Moving Average - MA), γνωστός ως ARMA, είναι ιδιαίτερα δημοφιλής για βραχυπρόθεσμες προβλέψεις λόγω της επιτυχίας του σε πολλές περιπτώσεις (Yang, Huang, Huang, & Pai, 2014). Το μοντέλο ARMA είναι αποτελεσματικό στην εξαγωγή στατιστικών ιδιοτήτων όπως το ελάχιστο μέσο τετραγωνικό σφάλμα και η χαμηλή διακύμανση (Casaca de Rocha Vaz, 2014).

Γ1.2 Γραμμικά Μη Στατικά Μοντέλα (Linear Non-Stationary Models)

Οι μη στατικές διαδικασίες δεν έχουν σταθερό μέσο όρο, αλλά παρουσιάζουν κάποια ομοιογένεια μεταξύ των διαφορετικών τμημάτων τους. Μπορούν να μοντελοποιηθούν με την εφαρμογή κατάλληλων διαφορών, όπως της τιμής του επιπέδου ή της κλίσης, ώστε να γίνουν στατικές. Το μοντέλο AutoRegressive Integrated Moving Average (ARIMA) χρησιμοποιείται ευρέως για προβλέψεις λόγω της ικανότητάς του να αφαιρεί την αστάθεια από τα δεδομένα και να συνδυάζει τα στοιχεία AR και MA για ακριβείς προβλέψεις. Ωστόσο, απαιτεί στατικά δεδομένα χρονοσειρών για να λειτουργήσει αποτελεσματικά.

Το μοντέλο Seasonal AutoRegressive Integrated Moving Average (SARIMA) είναι μια επέκταση του ARIMA που προσθέτει εποχιακούς όρους, επιτρέποντας την ανάλυση δεδομένων με εποχιακές διακυμάνσεις. Είναι ιδιαίτερα χρήσιμο για προβλέψεις σε

τομείς με έντονες εποχιακές επιρροές, όπως η παραγωγή ενέργειας, βελτιώνοντας την ακρίβεια των προβλέψεων σε μακροπρόθεσμο και εποχιακό πλαίσιο.

Οι μη γραμμικές μέθοδοι μπορούν να περιγράψουν με ακρίβεια πολύπλοκες μη γραμμικές συμπεριφορές, όπως χάος, υστέρηση και φαινόμενα κορεσμού ή συνδυασμό πολλών μη γραμμικών προβλημάτων.

Γ2. Μοντέλα Εκμάθησης (Machine Learning)

Τα ευφυή μοντέλα πρόβλεψης είναι προτιμητέα σε σχέση με τα παραδοσιακά μοντέλα επειδή μπορούν να ανιχνεύουν πολύπλοκες σχέσεις χωρίς τη χρήση σύνθετων μαθηματικών υπολογισμών. Οι τεχνικές τεχνητής νοημοσύνης (AI) είναι ιδιαίτερα δημοφιλείς στον επιστημονικό χώρο για εφαρμογές πρόβλεψης, προσφέροντας σημαντικά πλεονεκτήματα όσον αφορά την ακρίβεια και την αποδοτικότητα των προβλέψεων.

Γ2.1 Νευρωνικά Δίκτυα Νοημοσύνης (Artificial Neural Networks - ANNs)

Μεταξύ των τεχνικών μηχανικής μάθησης (ML), τα Τεχνητά Νευρωνικά Δίκτυα είναι ιδιαίτερα δημοφιλή και χρησιμοποιούνται επιτυχώς σε διάφορες εφαρμογές πρόβλεψης. Τα ANNs μπορούν να παράγουν ακριβείς προβλέψεις λόγω της ικανότητάς τους να συλλαμβάνουν απότομες αλλαγές στην έξοδο μέσω μιας έξυπνης διαδικασίας εκπαίδευσης. Μια προσαρμοστική και ανθεκτική μέθοδος εκπαίδευσης μπορεί να βελτιώσει την ικανότητα του δικτύου να μάθει τις περίπλοκες σχέσεις μεταξύ των εισόδων και των εξόδων.

Η ακρίβεια των προβλέψεων υπολογίζεται με δεδομένα πραγματικού χρόνου και προβλεπόμενες τιμές, ενώ μπορεί να βελτιωθεί περαιτέρω μέσω της προσεκτικής επιλογής παραμέτρων όπως ο αριθμός εισόδων, ο αλγόριθμος εκπαίδευσης, τα κατάλληλα δεδομένα εκπαίδευσης και η βελτιστοποιημένη δομή του δικτύου (Raza, Nadarajah, & Ekanayake, 2016). Τα βήματα της διαδικασίας των νευρωνικών δικτύων αναλύονται εκτενώς στο κεφάλαιο 4 της εργασίας.

Γ2.1.2 Support Vector Machine (SVM)

Η μέθοδος μηχανικής υποστήριξης διανύσματος (Support Vector Machine - SVM) αποτελεί μια τεχνική μηχανικής μάθησης που βασίζεται στην αρχή της ελαχιστοποίησης των δομικών κινδύνων (Structural Risk Minimization - SRM) για τη

μείωση του ανώτατου ορίου του αναμενόμενου κινδύνου, ελαχιστοποιώντας έτσι το σφάλμα των δεδομένων εκπαίδευσης. Στην παλινδρόμηση διανύσματος υποστήριξης (Support Vector Regression - SVR), τα δεδομένα χρονοσειρών εισόδου χαρτογραφούνται σε χώρο υψηλότερων διαστάσεων, όπου εκτελείται γραμμική παλινδρόμηση.

Η απόδοση του μοντέλου SVR εξαρτάται από τρεις κύριες παραμέτρους: την κύρωση (C), που καθορίζει τις ποινές για σφάλματα εκτίμησης, την ακτίνα αγωγού (ϵ), που καθορίζει ποια δεδομένα αγνοούνται κατά την παλινδρόμηση, και την παράμετρο της λειτουργίας του πυρήνα (kernel). Ο περιορισμός αυτής της μεθόδου είναι ότι η απόδοση εξαρτάται σε μεγάλο βαθμό από την κατάλληλη επιλογή αυτών των παραμέτρων (Cherkassky & Ma, 2004).

Γ2.3 k-Nearest Neighbours (k-NN)

Το μοντέλο k-Nearest Neighbors (kNN) αποτελεί μία από τις πιο απλές μεθόδους μηχανικής μάθησης. Συγκεκριμένα, ταξινομεί μοτίβα συγκρίνοντας ένα τρέχον μοτίβο με δείγματα εκπαίδευσης από τον χώρο των χαρακτηριστικών (Pedro & Coimbra, 2012). Στις εφαρμογές πρόβλεψης, το kNN προσδιορίζει τα στοιχεία από τα δείγματα εκπαίδευσης που είναι τα πιο κοντινά στις τρέχουσες συνθήκες, με βάση ορισμένα προκαθορισμένα χαρακτηριστικά, γνωστά ως γειτονικά. Στη συνέχεια, η τιμή της πρόβλεψης καθορίζεται από τις επόμενες τιμές αυτών των γειτόνων.


3.2.3 Υβριδικά μοντέλα (Hybrid models)

Η ιδιαίτερη μεθοδολογία που εφαρμόζει κάθε τεχνική στη μετατροπή των δεδομένων μπορεί να οδηγήσει στην απώλεια πληροφοριών στα μεμονωμένα μοντέλα. Για αυτόν τον λόγο, συχνά συνδυάζονται διάφορες τεχνικές για να ενισχυθούν οι δυνατότητές τους και να βελτιωθεί η ακρίβεια τους. Ο συνδυασμός δύο ή περισσότερων τεχνικών ονομάζεται υβριδικό μοντέλο. Τα υβριδικά μοντέλα μπορούν να εξασφαλίσουν καλύτερη απόδοση πρόβλεψης αξιοποιώντας τα πλεονεκτήματα κάθε μεμονωμένης μεθόδου και έχουν αποδειχθεί πιο αποτελεσματικά από τις αυτόνομες τεχνικές στην πρόβλεψη φωτοβολταϊκής ισχύος (Mora-López et al., 2011).

Ωστόσο, η υιοθέτηση ενός υβριδικού μοντέλου αυξάνει την υπολογιστική πολυπλοκότητα, λόγω της συνδυαστικής χρήσης πολλαπλών τεχνικών. Η αποτελεσματικότητα ενός υβριδικού μοντέλου εξαρτάται από την απόδοση κάθε επιμέρους μοντέλου. Τελικά, η ακρίβεια του υβριδικού μοντέλου επηρεάζεται από την απόδοση των επιμέρους τεχνικών, γεγονός που θέτει έναν εσωτερικό περιορισμό σε αυτά τα μοντέλα.


Κεφάλαιο 4: Τεχνητά Νευρωνικά Δίκτυα

4.1 Εισαγωγή στα Τεχνητά Νευρωνικά Δίκτυα



Εικόνα 14: Εικόνα ενός Φυσικού Νευρώνα

Η μελέτη των Τεχνητών Νευρωνικών Δικτύων (ΤΝΔ) αποτελεί έναν από τους θεμέλιους λίθους της προσπάθειας της επιστημονικής κοινότητας να προσομοιώσει την ανθρώπινη νοημοσύνη μέσω της χρήσης μηχανών. Στόχος αυτών των προσπαθειών είναι η ανάπτυξη της τεχνητής νοημοσύνης (ΤΝ), η οποία φιλοδοξεί να αναπαράγει την πολυπλοκότητα και την ικανότητα επεξεργασίας πληροφοριών του ανθρώπινου εγκεφάλου.



Εικόνα 15: Μορφή ενός Νευρωνικού Δικτύου

Αναλυτικότερα, τα Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ) έχουν αναπτυχθεί ως προσαρμοστικά μαθηματικά μοντέλα που βασίζονται στη δομή ενός βιολογικού νευρώνα, ο οποίος περιλαμβάνει το κυτταρικό σώμα, τους δένδριτες και τον άξονα. Αυτή η δομή έχει αναπαραχθεί με τη μορφή των τεχνητών νευρωνικών κυττάρων στα ΤΝΔ.

Τα ΤΝΔ, έχοντας ως πρότυπο την πολυπλοκότητα και την ικανότητα επεξεργασίας πληροφοριών του ανθρώπινου εγκεφάλου, αποτελούν έναν βασικό πυλώνα στην προσπάθεια αυτή. Η ικανότητα του εγκεφάλου να μαθαίνει και να θυμάται εξαρτάται από την ικανότητα των συνάψεων να αλλάζουν την ηλεκτρική τους αγωγιμότητα. Τα ηλεκτρικά σήματα που εισέρχονται στο σώμα μέσω των δένδριτών συνδυάζονται και εάν το αποτέλεσμα υπερβαίνει μια ορισμένη τιμή, το σήμα διαδίδεται σε άλλους νευρώνες μέσω αξόνων. Ο ανθρώπινος εγκέφαλος αποτελείται από περίπου 100 δισεκατομμύρια νευρώνες και λειτουργεί μέσω της διαδικασίας σύνοψης, επεξεργασίας και μετάδοσης των εισερχόμενων σημάτων, διαδικασία που έχει εμπνεύσει τη δημιουργία των ΤΝΔ.

Η ανάπτυξη και η εφαρμογή των ΤΝΔ είναι το αποτέλεσμα δεκαετιών ερευνητικών προσπαθειών για την κατανόηση της λειτουργίας του εγκεφάλου και της μίμησης της ανθρώπινης συμπεριφοράς (Mohanty et al., 2022; Muhammad Ibrahim et al., 2024).

4.2 Ορισμός

Ο πιο πλήρης, ακριβής και λεπτομερής ορισμός των τεχνητών νευρωνικών δικτύων παρέχεται από την Laurene Fausett (1994), η οποία περιγράφει ότι: "Ένα τεχνητό νευρωνικό δίκτυο αποτελεί ένα σύστημα επεξεργασίας πληροφοριών, το οποίο μιμείται πολλές από τις λειτουργικές ιδιότητες ενός βιολογικού νευρωνικού δικτύου. Τα τεχνητά νευρωνικά δίκτυα έχουν αναπτυχθεί ως προσαρμοστικά μαθηματικά μοντέλα που αποσκοπούν στη μίμηση της ανθρώπινης νοημοσύνης και της νευροβιολογίας, βασισμένα στις εξής παραδοχές:

- Η επεξεργασία πληροφοριών πραγματοποιείται μέσα σε πολυάριθμα απλά στοιχεία που αποκαλούνται νευρώνες.
- Τα σήματα διαδίδονται μεταξύ των νευρώνων μέσω των συνδετικών ινών.

- Κάθε συνδετικός δεσμός διαθέτει ένα συγκεκριμένο βάρος που συσχετίζεται με αυτόν, το οποίο σε ένα τυπικό νευρωνικό δίκτυο πολλαπλασιάζει το σήμα που μεταδίδεται.
- Κάθε νευρώνας υλοποιεί μια συνάρτηση ενεργοποίησης, συχνά μη-γραμμική για να επεξεργαστεί τα εισερχόμενα δεδομένα (το άθροισμα των σημάτων με τα αντίστοιχα βάρη) με στόχο τον προσδιορισμό του εξερχόμενου σήματος" (Mohanty et al., 2022; Muhammad Ibrahim et al., 2024).

4.3 Απομνημόνευση και Γενίκευση

Για την επίτευξη της μίμησης της νοημοσύνης από τα αναφερόμενα συστήματα, απαιτείται η ενσωμάτωση ουσιαστών χαρακτηριστικών όπως η μνήμη και η ικανότητα μάθησης και αποθήκευσης πληροφοριών, καθώς και η γενίκευση, δηλαδή η δυνατότητα δημιουργίας γενικών κανόνων και συμπερασμάτων από ειδικά και λεπτομερή δεδομένα ή εμπειρίες. Η διαδικασία της μάθησης, η οποία βασίζεται στη μνήμη, επιτυγχάνεται μέσω της καταγραφής δεδομένων ή της αναγνώρισης και αποθήκευσης των κανόνων που προκύπτουν από τα δεδομένα που λαμβάνονται (Καλαμαράς, 2013).

Η δυνατότητα γενίκευσης δίνει στο σύστημα την ικανότητα να κάνει προβλέψεις βασιζόμενο σε δεδομένα που δεν έχουν προηγουμένως εισαχθεί. Παρά την προφανή αντίφαση αυτής της μεθόδου, η διαδικασία της εξαγωγής γενικευμένων συμπερασμάτων από ειδικά δεδομένα και δείγματα είναι κάτι που συναντάται συχνά στην ανθρώπινη διαδικασία μάθησης. Επιπλέον, η γενίκευση δεν απαιτεί την αποθήκευση εκτεταμένων όγκων δεδομένων, καθώς το σύστημα πρέπει να αναγνωρίζει ποια χαρακτηριστικά ανήκουν στο δειγματικό σύνολο, μειώνοντας έτσι σημαντικά τον απαιτούμενο όγκο μνήμης (Mohanty et al., 2022; Muhammad Ibrahim et al., 2024).

4.4 Απόκτηση γνώσης μέσω της μάθησης

Η εκμάθηση και απόκτηση γνώσης μέσω των Τεχνητών Νευρωνικών Δικτύων (ΤΝΔ) αποτελεί μία διακριτή δυνατότητα που τα ξεχωρίζει από άλλα υπολογιστικά


συστήματα, όπου η γνώση συνήθως αποθηκεύεται και χρησιμοποιείται με προκαθορισμένους αλγόριθμους και κανόνες. Τα ΤΝΔ μπορούν να εκπαιδευτούν για να αναγνωρίζουν το επιθυμητό αποτέλεσμα μέσω μιας σειράς δεδομένων και παραδειγμάτων, ενσωματώνοντας δύο βασικούς τύπους μάθησης: την επιβλεπόμενη και τη μη επιβλεπόμενη (Mohanty et al., 2022) (Muhammad Ibrahim et al., 2024)

Η **επιβλεπόμενη μάθηση** είναι μια διαδικασία στην οποία παρέχονται και οι πληροφορίες για το περιβάλλον και η επιθυμητή απόκριση του συστήματος, παρόμοια με την διαδικασία της ανθρώπινης μάθησης που διενεργείται υπό την καθοδήγηση ενός παιδαγωγού. Σε αυτή την περίπτωση, τα ΤΝΔ εκπαιδεύονται μέσω της αναγνώρισης ζευγαριών διανυσμάτων, εισόδου και εξόδου. Μια ειδική μορφή επιβλεπόμενης μάθησης αποτελεί η **ενισχυτική μάθηση**, στην οποία το αναμενόμενο αποτέλεσμα δεν είναι προκαθορισμένο, και η ανατροφοδότηση σχετίζεται με την ορθότητα ή την ακρίβεια της απόκρισης. Η βασική δυσκολία σε αυτή τη μέθοδο είναι η ο προσδιορισμός του τερματισμού της εκπαιδευτικής διαδικασίας, με το φαινόμενο του overfitting να αποτελεί ένα διαπιστευμένο πρόβλημα προς διαχείριση (Mohanty et al., 2022) (Muhammad Ibrahim et al., 2024)

Από την άλλη πλευρά, η **μη επιβλεπόμενη μάθηση**, βασίζεται αποκλειστικά στα διανύσματα εισόδου, χωρίς προκαθορισμένα διανύσματα εξόδου. Αυτή η μορφή μάθησης συχνά συγκρίνεται με την διαδικασία κατηγοριοποίησης, καθώς τα δεδομένα ομαδοποιούνται βάσει των αποστάσεων των διανυσμάτων εισόδου. Είναι σημαντικό η ομαδοποίηση να αντικατοπτρίζει την ορθή προσέγγιση για το πρόβλημα.

Τα Τεχνητά Νευρωνικά Δίκτυα χωρίζονται σε δύο κύριες κατηγορίες:

- Τα στατικά, που δεν διαθέτουν στοιχεία μνήμης όμως δύνανται να δεχθούν προηγούμενες εισόδους ως δεδομένα, και
- Τα δυναμικά, που ενσωματώνουν στοιχεία μνήμης και είναι ιδανικά για την προσομοίωση δυναμικών συστημάτων (Mohanty et al., 2022) (Muhammad Ibrahim et al., 2024).



Εικόνα 16: Αναπαράσταση του προβλήματος εκπαίδευσης overfitting (Voudris, 2006)

4.5 Ένας τεχνητός νευρώνας

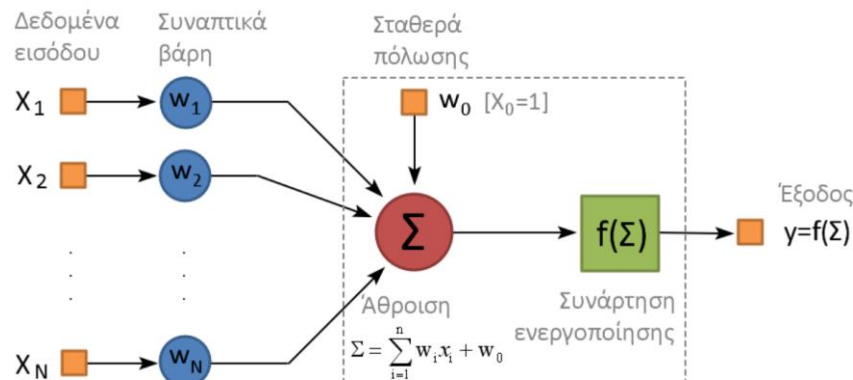
Ένας τεχνητός νευρώνας, όπως αυτός που απεικονίζεται στην Εικόνα 17, αποτελεί μία βασική μονάδα επεξεργασίας. Αυτός ο νευρώνας δέχεται πολλαπλές εισόδους, καθεμία από τις οποίες είναι συνδεδεμένη με τον νευρώνα μέσω ενός συγκεκριμένου βάρους w_i . Ο νευρώνας πραγματοποιεί την άθροιση των γινομένων των εισόδων και των αντίστοιχων βαρών τους για τον υπολογισμό της εξόδου, που αναπαρίσταται μέσω της παρακάτω εξίσωσης ή με τη μορφή του παρακάτω διανυσματικού γινομένου:

$$\sum_{i=1}^n x_i \cdot w_i$$

$$\vec{x}^T \cdot \vec{w}$$

Στη συνέχεια, για τον υπολογισμό της τελικής εξόδου, εφαρμόζεται μια συνάρτηση ενεργοποίησης $f(y)$, που μπορεί να είναι είτε μία απλή συνάρτηση ορίου είτε μία πιο πολύπλοκη μη-γραμμική συνεχής συνάρτηση. Δύο συνηθισμένες συναρτήσεις ενεργοποίησης που χρησιμοποιούνται είναι η συνάρτηση ορίου, όπως η συνάρτηση

βήματος (step function) με τύπο: $\begin{cases} 1 & \text{αν } y \geq \theta \\ 0 & \text{αν } y < \theta \end{cases}$, και η συνεχής συνάρτηση, όπως η σιγμοειδής (sigmoid function) με τύπο: $f(y) = \frac{1}{1+e^{-y}}$ ή η υπερβολική εφαπτομένη (hyperbolic tangent) με τύπο: $f(y) = \tanh(y)$.



Εικόνα 17: Ένας τεχνητός νευρώνας (Χασιακός & Τσίκας, 2019)

Ο τεχνητός νευρώνας λειτουργεί ως ένα αφηρημένο μοντέλο του βιολογικού νευρώνα. Καταρχάς, η ισχύς των συνδέσεων μεταξύ των νευρώνων εκφράζεται μέσω των βαρών. Επίσης, η ένταση του εισερχόμενου σήματος αναπαρίσταιται κάνοντας χρήση ενός πραγματικού αριθμού αντί να χρησιμοποιείται το άθροισμα προσωρινών «ακίδων» (spikes). Επιπλέον, ο τεχνητός νευρώνας λειτουργεί σε διακριτά χρονικά βήματα, επεξεργαζόμενος τα δεδομένα κατά τη στιγμή που τα λαμβάνει.

Η εκπαίδευση των τεχνητών νευρώνων βασίζεται στην προσαρμογή των βαρών ώστε να μειωθεί η διαφορά μεταξύ των υπολογισμένων και των επιθυμητών εξόδων. Παραδείγματα μεθόδων εκπαίδευσης περιλαμβάνουν τη μέθοδο βαθμωτής καθόδου (Gradient Descent Learning Rule) και τους κανόνες μάθησης Perceptron και Widrow-Hoff.


Το αποτέλεσμα του σταθμισμένου αθροίσματος των εισόδων περνά μέσα από μια συνάρτηση ενεργοποίησης, που τις περισσότερες φορές είναι μη γραμμική. Ένα από τα πιο διαδεδομένα είδη αυτής της συνάρτησης είναι η μονάδα λογικής κατωφλίου (Threshold Logic Unit, TLU). Σε αυτή την περίπτωση, η έξοδος ενεργοποιείται όταν το σταθμισμένο άθροισμα ξεπερνά μια καθορισμένη τιμή κατωφλίου (bias): $\begin{cases} 1 & \text{αν } y \geq \theta \\ 0 & \text{αν } y < \theta \end{cases}$

4.6 Μονοστρωματικά Δίκτυα

Η βασική μορφή ενός μονοστρωματικού δικτύου περιλαμβάνει m νευρώνες, με κάθε νευρώνα να έχει n εισόδους. Αυτό το δίκτυο είναι υπεύθυνο για την αντιστοίχιση μεταβλητών εισόδου από έναν n -διάστατο χώρο σε αποτελέσματα εξόδου σε ένα χώρο m -διάστασης. Η διαδικασία εκπαίδευσης για αυτό το δίκτυο ακολουθεί τον ίδιο αλγόριθμο που χρησιμοποιείται και για την εκπαίδευση ενός μεμονωμένου νευρώνα. Αν και τα δίκτυα ενός επιπέδου χρησιμοποιούνται συνήθως σε γραμμικά διαχωρίσιμα μοντέλα, έχουν τον ίδιο περιορισμό με έναν μεμονωμένο νευρώνα, καθώς δεν μπορούν να ταξινομήσουν αποτελεσματικά σύνολα δεδομένων που είναι μη γραμμικά διαχωρίσιμα. Για να αντιμετωπιστεί αυτός ο περιορισμός, χρησιμοποιούνται δίκτυα πολυστρωματικής αρχιτεκτονικής ως λύση.


4.7 Πολυστρωματικά Δίκτυα

Τα πολυστρωματικά δίκτυα επιλύουν το πρόβλημα της ταξινόμησης μη γραμμικών δεδομένων μέσω της χρήσης κρυμμένων επιπέδων, όπου οι νευρώνες τους δεν συνδέονται άμεσα με τα εξερχόμενα αποτελέσματα. Από γεωμετρική άποψη, αυτά μπορούν να θεωρηθούν ως υπέρ-επίπεδα που ενισχύουν τις δυνατότητες διαχωρισμού του δικτύου. Παρακάτω παρουσιάζεται μια τυπική αρχιτεκτονική πολυστρωματικών δικτύων:



Εικόνα 18: Παραδείγματα αρχιτεκτονικής πολυστρωματικών νευρωνικών δικτύων (Voudris, 2006)

Ο αλγόριθμος οπισθοδρόμησης (backpropagation) χρησιμοποιείται για την εκπαίδευση πολυστρωματικών δικτύων. Η βασική του αρχή είναι η παρουσίαση του διανύσματος εισόδου στο δίκτυο και ο υπολογισμός του εξαγόμενου αποτελέσματος κάθε στρώματος με κατεύθυνση προς τα εμπρός, έως ότου παραχθεί το τελικό εξαγόμενο αποτέλεσμα του δικτύου. Στο επίπεδο εξόδου, οι επιθυμητές τιμές είναι γνωστές και τα βάρη μπορούν να προσαρμοστούν με τον ίδιο τρόπο όπως στα μονοστρωματικά δίκτυα. Στον αλγόριθμο οπισθοδρόμησης, η εκπαίδευση στηρίζεται στον κανόνα βαθμωτής καθόδου (gradient descent rule). Για να υπολογιστούν οι μεταβολές στα βάρη των κρυμμένων επιπέδων, το σφάλμα στο επίπεδο εξόδου οπισθοδρομείται στα επίπεδα αυτά. Η διαδικασία αυτή επαναλαμβάνεται για κάθε δείγμα των δεδομένων εκπαίδευσης. Εξάλλου, ένας πλήρης κύκλος εκπαίδευσης αποκαλείται εποχή (epoch). Ο απαραίτητος και απαιτούμενος αριθμός εποχών για να εκπαιδευτούν τα δίκτυα εξαρτάται από διάφορες παραμέτρους, κυρίως από το σφάλμα, το οποίο υπολογίζεται στο επίπεδο εξόδου.



Εικόνα 19: Δίκτυο Οπισθοδρόμησης (Back Propagation Network) (Voudris, 2006)

Στην Εικόνα 19 παρουσιάζεται ένα παράδειγμα ενός δικτύου οπισθοδρόμησης. Το διάνυσμα εισόδου διαθέτει n διαστάσεις, ενώ το διάνυσμα εξόδου έχει m διαστάσεις. Η πόλωση, η οποία αναφέρεται στα σταθερά χρησιμοποιούμενα δεδομένα εισόδου, είναι -1 . Υπάρχει επίσης ένα κρυφό στρώμα που αποτελείται από g νευρώνες. Ο

πίνακας V περιέχει τα βάρη των νευρώνων στο κρυφό αυτό στρώμα, ενώ ο πίνακας W καθορίζει τα βάρη που έχουν οι νευρώνες στο επίπεδο εξόδου. Η παράμετρος εκπαίδευσης είναι η και η παράμετρος ορμής (momentum) είναι α . Οι εξισώσεις που αποτυπώνουν τη μονοπολική συνάρτηση ενεργοποίησης και την παράγωγό της δίνονται παρακάτω:

$$f(net) = \frac{1}{1 + e^{-\lambda \cdot net}}$$
$$f'(net) = \frac{e^{-\lambda \cdot net}}{(1 + e^{-\lambda \cdot net})^2}$$

Η εκπαίδευση τερματίζεται όταν το σφάλμα μειωθεί σε αποδεκτά μικρό επίπεδο.


4.8 Αρχιτεκτονική Νευρωνικών Δικτύων

Η αρχιτεκτονική των νευρωνικών δικτύων αφορά την τοπολογική διάταξη και τη μέθοδο δόμησης των πολλαπλών νευρώνων. Η αρχιτεκτονική αυτή διέπεται από τα εξής βασικά χαρακτηριστικά: τον αριθμό των στρωμάτων και τις συνδέσεις μεταξύ των νευρώνων. Ένα επιπλέον χαρακτηριστικό, άμεσα σχετιζόμενο με τη δομή των νευρώνων, είναι ο αλγόριθμος μάθησης που χρησιμοποιείται για να εκπαιδευτεί το νευρωνικό δίκτυο (Mohanty et al., 2022; Muhammad Ibrahim et al., 2024).

4.8.1 Νευρωνικά Δίκτυα Πρωστοτροφοδότησης

Τα νευρωνικά δίκτυα προώθησης (ή πρώσο-τροφοδότησης – Feedforward Neural Networks - FNN) αποτελούνται από νευρώνες οργανωμένους σε επίπεδα. Αποτελούνται από ένα στρώμα εισόδου από κόμβους πηγής (source nodes), το οποίο συνδέεται σε ένα στρώμα νευρώνων εξόδου (output nodes), χωρίς αναδρομικές συνδέσεις. Το δίκτυο αυτό αναφέρεται ως νευρωνικό δίκτυο προώθησης ενός μοναδικού στρώματος, με το μοναδικό στρώμα να είναι το αυτό των νευρώνων εξόδου. Ένα τυπικό νευρωνικό δίκτυο προώθησης περιέχει γενικά ένα ή περισσότερα κρυφά-

ενδιάμεσα επίπεδα, με τους υπολογιστικούς κόμβους (hidden nodes) να παρεμβάλλονται μεταξύ των εξωτερικών εισόδων και εξόδων του ΝΔ.



Εικόνα 20: Πολυστρωματικό Νευρωνικό Δίκτυο πρώστροφοδότησης (μερικώς διασυνδεδεμένο) (Κούρους, 2012)

Σε αυτά τα πολυστρωματικά νευρωνικά δίκτυα προώθησης, τα στοιχεία του διανύσματος εισόδου που είναι στους κόμβους εισόδου, εισέρχονται στο πρώτο κρυμμένο επίπεδο ή στρώμα υπολογιστικών κόμβων και οι έξοδοι του πρώτου κρυφού επιπέδου λειτουργούν ως εισοδοί για το δεύτερο κρυφό επίπεδο. Αυτή η διαδικασία συνεχίζεται μέχρι το τελευταίο επίπεδο, το οποίο παρέχει την τελική απόκριση στα πρότυπα εισόδου.


Εξάλλου, ένα νευρωνικό δίκτυο θεωρείται πλήρως διασυνδεδεμένο αν κάθε κόμβος οποιουδήποτε στρώματος συνδέεται με όλους τους κόμβους του γειτονικού προς τα εμπρός στρώματος. Στην περίπτωση που κάτι τέτοιο δεν ισχύει, και υπάρχουν μία ή περισσότερες διαδοχικές συνδέσεις που λείπουν, τότε το νευρωνικό δίκτυο χαρακτηρίζεται ως μερικώς διασυνδεδεμένο.

4.8.2 Νευρωνικά Δίκτυα Ανατροφοδότησης

Εφόσον ένα νευρωνικό δίκτυο περιέχει τουλάχιστον έναν βρόχο ανατροφοδότησης που ανακυκλώνει πληροφορίες μέσω του ιδίου ή προηγούμενων στρωμάτων, τότε το δίκτυο ονομάζεται αναδρομικό ΝΔ.

Στην περίπτωση που το νευρωνικό δίκτυο είναι ευσταθές, μπορεί να παρατηρηθούν ταλαντώσεις για ένα χρονικό διάστημα πριν φτάσει σε σταθερή κατάσταση, όπου οι ενεργοποιήσεις των νευρώνων δεν αλλάζουν και παράγεται μια σταθερή έξοδος.

Αντίθετα, στην περίπτωση ενός ασταθούς δικτύου, οι ταλαντώσεις θα συνεχιστούν χωρίς σταματημό. Επομένως, η εκπαίδευση του εν λόγω αναδρομικού νευρωνικού δικτύου στοχεύει στον προσδιορισμό των συνοπτικών βαρών που του επιτρέπουν να σταθεροποιηθεί στις επιθυμητές τιμές εξόδου.



Εικόνα 21: Πολυστρωματικό ΝΔ Ανατροφοδότησης (Κουρούς, 2012)

4.9 Τα Τεχνητά Νευρωνικά Δίκτυα ως εργαλεία πρόβλεψης, Πλεονεκτήματα & Μειονεκτήματα

Η χρήση των τεχνητών νευρωνικών δικτύων (ΤΝΔ) ως εργαλεία πρόβλεψης παρουσιάζει τόσο πλεονεκτήματα, όσο και μειονεκτήματα συγκριτικά με άλλες μεθόδους πρόβλεψης. Αναλυτικότερα, τα ΤΝΔ εκπαιδεύονται με βάση ιστορικά δεδομένα, κάνοντας χρήση χρονοσειρών ως δεδομένα εισόδου, και παρέχουν ως αποτέλεσμα την επιθυμητή πρόβλεψη της χρονοσειράς. Ουσιαστικά, τα ΤΝΔ επιχειρούν να εντοπίζουν πόσο σημαντικές είναι ορισμένες ιστορικές τιμές, αποσκοπώντας στην πρόβλεψη μελλοντικών τιμών μέσα από την υποστήριξη μη γραμμικών συναρτήσεων.

Εξάλλου, τα ΤΝΔ είναι μη-γραμμικά, ενώ η πρόβλεψη παραδοσιακά βασιζόταν σε γραμμικές στατιστικές μεθόδους. Οι παραδοσιακές προσεγγίσεις για την πρόγνωση χρονοσειρών, όπως οι μέθοδοι Box-Jenkins και ARMA, προϋποθέτουν ότι οι χρονοσειρές που ερευνώνται, προέρχονται από γραμμικές διαδικασίες. Τα γραμμικά μοντέλα υπερτερούν όσον αφορά την κατανόηση, την λεπτομερή ανάλυσή τους, την εύκολη εξήγηση και την υλοποίησή τους. Εντούτοις, μπορεί να είναι πλήρως ακατάλληλα εάν ο υποκείμενος μηχανισμός είναι μη γραμμικός. Η υπόθεση εκ των

προτέρων πως οι συγκεκριμένες χρονοσειρές παράγονται από γραμμικές διαδικασίες δεν είναι ορθή.

Στην ουσία, τα σύγχρονα συστήματα, ειδικά τα μακροοικονομικά, είναι κατά κύριο λόγο μη γραμμικά. Παρ' όλα αυτά, τα μη γραμμικά μοντέλα συναντούν ορισμένους περιορισμούς, καθώς απαιτείται η υπόθεση μιας ρητής σχέσης για τα ερευνώμενα δεδομένα, όταν υπάρχει ελάχιστη γνώση του υποκείμενου κανόνα. Η διαμόρφωση ενός μη γραμμικού μοντέλου για ένα συγκεκριμένο σύνολο δεδομένων αποτελεί αναμφίβολα πρόκληση, λόγω της ύπαρξης πληθώρας πιθανών μη γραμμικών προτύπων. Έτσι, ένα προκαθορισμένο μη γραμμικό μοντέλο ενδέχεται να μην είναι αρκετά γενικό ώστε να ενσωματώσει όλα τα σημαντικά χαρακτηριστικά, γεγονός που δυσχεραίνει το εγχείρημα. Τα ΤΝΔ, ως μη γραμμικές προσεγγίσεις που καθοδηγούνται από τα δεδομένα, σε πλήρη αντιδιαστολή με τα μη-γραμμικά μοντέλα, μπορούν να εκτελούν μη γραμμική μοντελοποίηση, δίχως πρέπει να γνωρίζουν από πριν τη σχέση μεταξύ των μεταβλητών εισόδου και εξόδου. Ως εκ τούτου, αποτελούν ένα πιο γενικό και ευέλικτο εργαλείο μοντελοποίησης για την εκτέλεση προβλέψεων.

4.9.1 Πλεονεκτήματα Τεχνητών Νευρωνικών Δικτύων

Η κατασκευή ενός τεχνητού νευρωνικού δικτύου πρόβλεψης αποτελεί μια αυτοματοποιημένη διαδικασία. Συγκεκριμένα, το δίκτυο τροφοδοτείται με μια προσαρμοσμένη βάση δεδομένων και εκπαιδεύεται αυτόνομα χρησιμοποιώντας Η/Υ. Το μόνο που πρέπει να κάνει ο χρήστης είναι απλώς να ορίσει τις απαιτούμενες παραμέτρους του δικτύου. Επιπλέον, ένα ΤΝΔ μπορεί να παραμείνει ανεπηρέαστο από στοιχεία της βάσης δεδομένων που, σε άλλες μεθόδους πρόβλεψης, θα οδηγούσαν σε παραπλανητικά αποτελέσματα. Για παράδειγμα, μια ασυνήθιστη συμπεριφορά που εμφανίστηκε στο παρελθόν σε μία από τις χρονοσειρές, θα έχει ελάχιστη επίδραση στην εκπαίδευση του δικτύου, εξαιτίας της μη γραμμικής επεξεργασίας των δεδομένων.

4.9.2 Μειονεκτήματα Τεχνητών Νευρωνικών Δικτύων

Τα ΤΝΔ παρουσιάζουν ορισμένες αδυναμίες όσον αφορά τον προσδιορισμό του ιδανικού μεγέθους και της βέλτιστης αρχιτεκτονικής του νευρωνικού ιστού. Αρχικά, απαιτείται αισθητά μεγαλύτερη βάση δεδομένων συγκριτικά με άλλες μεθόδους πρόβλεψης ώστε να επιτευχθεί επαρκής εκπαίδευση ενός δικτύου. Επιπλέον, είναι εξαιρετικά δύσκολο να ερμηνευτούν οι αιτίες πίσω από τυχόν λανθασμένες προβλέψεις, καθώς οι σχέσεις των συντελεστών βαρύτητας μεταξύ εισόδου και εξόδου μεταβάλλονται κατά τη διάρκεια της εκπαίδευσης. Επιπλέον, μία πολύπλοκη διαδικασία στην κατανόηση της αποτελεί η χρήση του εκπαιδευμένου συστήματος για την παραγωγή σωστών αποτελεσμάτων, μέσω των τελεστών βαρύτητας. Επιπρόσθετα, η διαχείριση των εκπαιδευόμενων παραμέτρων για εκπαίδευση και σύγκλιση είναι ιδιαίτερα απαιτητική, επειδή στηρίζεται στις αρχές των δικτύων που περιγράφονται από τον Geman [1], όπου η υπερεκτίμηση ή η υποτίμηση των παραμέτρων είναι αδύνατες. Τέλος, η εφαρμογή των νευρωνικών δικτύων απαιτεί σημαντικούς υλικούς πόρους (hardware resources), κάτι που την καθιστά κοστοβόρα.

Κεφάλαιο 5: Ασαφής Λογική

5.1 Η έννοια της ασαφούς λογικής

Η ασαφής λογική (fuzzy logic) αποτελεί μια επέκταση της κλασικής Αριστοτελικής λογικής. Μια πρόταση μπορεί να είναι αληθής "με κάποιο βαθμό αληθείας" και όχι απλά αληθής ή ψευδής (Λέκου, 2011). Ουσιαστικά, η ασαφής λογική υποστηρίζει ότι τα πράγματα συχνά δεν είναι «άσπρο-μαύρο» αλλά «αποχρώσεις του γκρι». Αυτή η ιδέα αποτέλεσε επανάσταση στη θεωρία της λογικής, καθώς ξέφυγε από το παραδοσιακό μοντέλο που κυριαρχούσε για χιλιάδες χρόνια, και συγκεκριμένα αυτό του «0-1», «αληθές-ψευδές» (Λέκου, 2011).

Η ασαφής λογική βασίζεται στη θεωρία των ασαφών συνόλων που θεμελιώθηκε από τον L. A. Zadeh το 1965. Η Ραουζαίου (2008) αναφέρει, πως, «ανάλογη με τη θεωρία της ασαφούς λογικής είναι η ίδια η ανθρώπινη συμπεριφορά, επειδή η ασάφεια είναι μια πολύ συνηθισμένη έννοια της ανθρώπινης φύσης, είτε αυτή αναφέρεται σε έννοιες, είτε σε ποσότητες». Τα συστήματα απόφασης ή ελέγχου που λειτουργούν σε ένα περιβάλλον αβεβαιότητας και βασίζονται στη θεωρία της ασαφούς λογικής, καλούνται ασαφή συστήματα και έχουν βρει ποικίλες εφαρμογές στις επιστήμες που χρησιμοποιούν την τεχνητή νοημοσύνη.

Αυτή η θεωρία χρησιμοποιεί την έννοια του βαθμού συμμετοχής ή αλήθειας (degrees of membership/truth) και όχι τον απόλυτο διαχωρισμό του αληθούς και του ψευδούς, και ασχολείται με την ασάφεια της γνώσης (θεωρία δυνατοτήτων), όχι με την τυχαιότητα (randomness) της θεωρίας πιθανοτήτων (Λέκου, 2011).

5.1.1 Πλεονεκτήματα Ασαφούς Λογικής

Η ασαφής λογική δύναται να εξηγήσει τη συμπεριφορά της λειτουργίας ενός συστήματος χρησιμοποιώντας κανόνες και έχει το μεγάλο πλεονέκτημα ότι δεν απαιτεί ακρίβεια της πληροφορίας (Ατσαλάκης, 2006).

Από εννοιολογική άποψη, ο ασαφής κανόνας είναι ένας τρόπος αναπαράστασης της γνώσης, που προσιδιάζει στον ανθρώπινο τρόπο σκέψης. Τα ασαφή συστήματα έχουν την ικανότητα να λειτουργούν σε περιβάλλοντα με ασάφεια και αβεβαιότητα,

παρέχοντας αποτελέσματα που κατανοητά για τον άνθρωπο καθώς προσεγγίζουν την ανθρώπινη λογική.

Χαρακτηριστικό πλεονέκτημα της ασαφούς λογικής είναι ότι μπορεί να λειτουργήσει και να αναλύσει συστήματα που διέπονται από μεγάλη πολυπλοκότητα, καθιστώντας την ένα ιδανικό εργαλείο για τη λήψη αποφάσεων.

Ένα ασαφές σύστημα μπορεί να δημιουργηθεί έτσι, ώστε να ενσωματώνει τις "ειδικές γνώσεις" που απαιτούνται για την αξιολόγηση ενός αντικειμένου. «Ουσιαστικά, η "ειδική γνώση" κωδικοποιείται μέσα στο σύστημα ασαφούς λογικής, και γι' αυτό το λόγο τα ασαφή συστήματα καλούνται επίσης «έμπειρα συστήματα» (Expert systems) (Κουρούς, 2012).

5.1.2 Μειονεκτήματα Ασαφούς Λογικής

Τα ασαφή συστήματα είναι κατάλληλα όταν υπάρχει επαρκής εξειδικευμένη γνώση για την εξεταζόμενη διαδικασία. Ωστόσο, η αποτελεσματικότητά τους περιορίζεται σε περιπτώσεις όπου δεν υπάρχει διαθέσιμη εξωτερική γνώση. Μια άλλη δυσκολία είναι ότι «εμφανίζουν δυσκολίες στον ακριβή διαμερισμό του χώρου εισόδων και εξόδων ενός προβλήματος σε ασαφή σύνολα, στις τιμές των παραμέτρων των συναρτήσεων συμμετοχής και στον ακριβή αριθμό των ασαφών κανόνων. Αυτό έχει ως αποτέλεσμα τον περιορισμό της σημαντικής ισχύος που χαρακτηρίζει την ασαφή λογική» (Ατσαλάκης, 2006).

5.2 Ασαφή Σύνολα

Ένα ασαφές σύνολο (fuzzy set) A ορίζεται μέσω της λεγόμενης συνάρτησης συμμετοχής (membership function) $\mu_A(x)$ ως εξής:

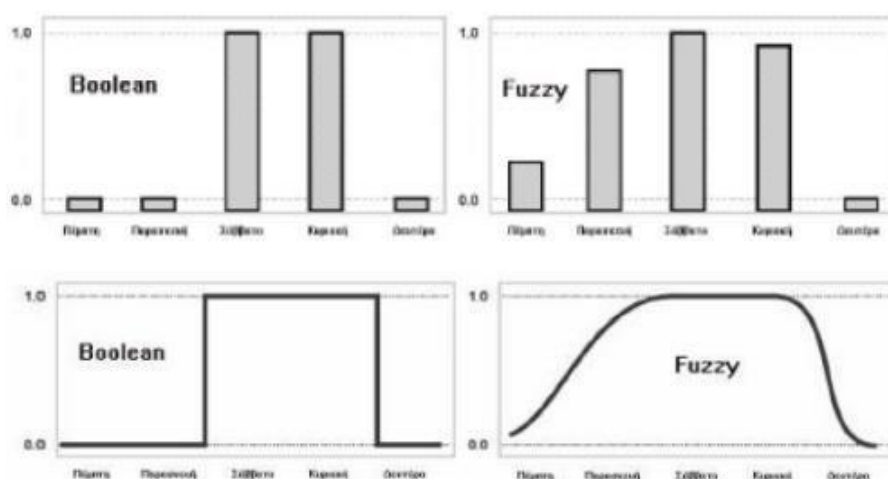
$$\mu_A(x): X \rightarrow [0,1]$$
$$\mu_A(x) = \begin{cases} 1 & \text{αν } x \text{ ολικά στο } A \\ 0 & \text{αν } x \text{ καθόλου στο } A \\ (0,1) & \text{αν } x \text{ μερικώς στο } A \end{cases}$$

Η $\mu_A(x)$ είναι ουσιαστικά ένας πραγματικός αριθμός ($0 \leq \mu_A(x) \leq 1$) που αντιπροσωπεύει τον βαθμό στον οποίο το x είναι στοιχείο του A και καλείται βαθμός

συμμετοχής (degree of membership) ή τιμή συμμετοχής (membership value) ή βαθμός αλήθειας (degree of truth).

Για την κατανοηθεί περαιτέρω η διαφορά μεταξύ της κλασικής και της ασαφούς λογικής, θα αναφερθεί το ακόλουθο παράδειγμα: Θεωρείται το σύνολο των ημερών που ανήκουν στο Σαββατοκύριακο (ΣΚ). Σύμφωνα με την κοινή αποδοχή, οι ημέρες Σάββατο και Κυριακή είναι μέλη αυτού του συνόλου. Ωστόσο, η ημέρα Παρασκευή ανήκει ή όχι στο ΣΚ; Ενώ διαισθητικά μπορεί να θεωρηθεί μέρος του Σαββατοκύριακου, λογικά δεν περιλαμβάνεται. Στην ασαφή λογική, μπορεί να θεωρηθεί η Παρασκευή ως μερικώς ανήκουσα τόσο στο σύνολο "Ημέρες που ανήκουν στο ΣΚ" όσο και στο σύνολο "Ημέρες που δεν ανήκουν στο ΣΚ", αναγνωρίζοντας έτσι την Παρασκευή ως στοιχείο και των δύο συνόλων με διαφορετικούς βαθμούς συμμετοχής.

Στην παρακάτω εικόνα απεικονίζονται οι αληθείς τιμές των ημερών που θεωρούνται ότι ανήκουν στο ΣΚ, λαμβάνοντας υπόψη ότι ο χρόνος παίρνει διακεκριμένες τιμές, αρχικά με απαντήσεις τύπου «Ναι-Όχι» και στη συνέχεια με απαντήσεις τύπου ασαφούς λογικής που περιλαμβάνουν ενδιάμεσες τιμές. Η ασαφής λογική αποτελεί ουσιαστικά μια διεύρυνση της Boolean λογικής. Συγκεκριμένα, αν η κατάσταση «αληθές» αντιστοιχίζεται στη λογική τιμή 1 και η κατάσταση «ψευδές» στη λογική τιμή 0, τότε η ασαφής λογική επιτρέπει την ύπαρξη ενδιάμεσων τιμών όπως 0.5, 0.6, 0.7, 0.8, 0.9. Με αυτόν τον τρόπο μπορεί να καθοριστεί και ο βαθμός στον οποίο κάθε στιγμή ανήκει στο ΣΚ, αντί να θεωρείται ολόκληρη η ημέρα ως μία ενιαία μονάδα.



Εικόνα 22: Ημέρες που θεωρούμε ότι ανήκουν στο Σ/Κ κατά Boolean και ασαφή λογική (Λέκκου, 2011)

5.3 Ασαφής Κανόνας και Ασαφή Συστήματα

Τα ασαφή σύνολα που εκφράζουν λεκτικούς όρους συνδυάζονται μεταξύ τους και δημιουργούν ασαφείς κανόνες, οι οποίοι αναπαριστούν τη διατιθέμενη γνώση για το σύστημα. Σύμφωνα με τον Κούρου (2012), «ένας ασαφής κανόνας αποτελείται από δύο βασικά μέρη:

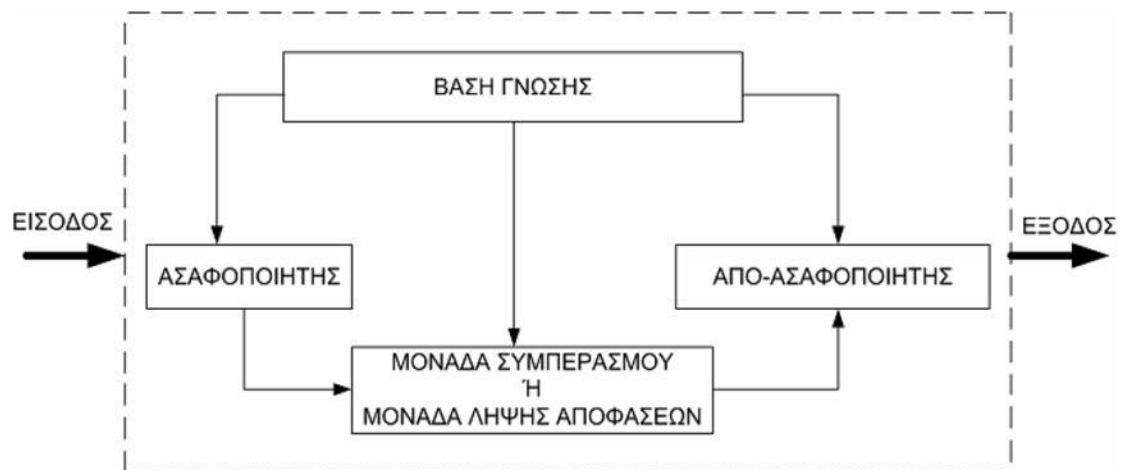
- α) το τμήμα υπόθεσης (premise part) και
- β) το τμήμα απόδοσης ή απόφασης (consequent part)».

5.3.1 Ασαφή Συστήματα Συμπερασμού (Fuzzy Inference Systems- FIS)


Η γενική αρχιτεκτονική των ασαφών συστημάτων περιλαμβάνει τέσσερις μονάδες επεξεργασίας:

- **Μονάδα Ασαφοποίησης (fuzzification):** Μετατρέπει τα δεδομένα εισόδου σε ασαφή σύνολα.
- **Βάση Ασαφών Κανόνων (Knowledge Base):** Περιλαμβάνει τους κανόνες της μορφής EAN-TOTE (if-then). Στη βάση γνώσης είναι καταχωρημένοι με τη μορφή κώδικα οι κανόνες ελέγχου και τα ασαφή σύνολα, με άλλα λόγια η «γνώση του συστήματος».
- **Ασαφής Συνεπαγωγή (fuzzy implication):** Αποτελεί μια ασαφή συλλογιστική μηχανή που εξάγει τα ασαφή συμπεράσματα (Μονάδα Λήψης Αποφάσεων - Inference Unit). Η μονάδα λήψης αποφάσεων εκτελεί τους κανόνες, λαμβάνοντας ως είσοδο τις ασαφοποιημένες εισόδους και παραδίδει το ασαφές αποτέλεσμα στον αποασαφοποιητή.
- **Μονάδα Αποασαφοποίησης (defuzzification):** Μετατρέπει τα ασαφή συμπεράσματα σε σαφώς καθορισμένη μορφή.

Τα παραπάνω παρουσιάζονται σχηματικά στις ακόλουθες εικόνες:

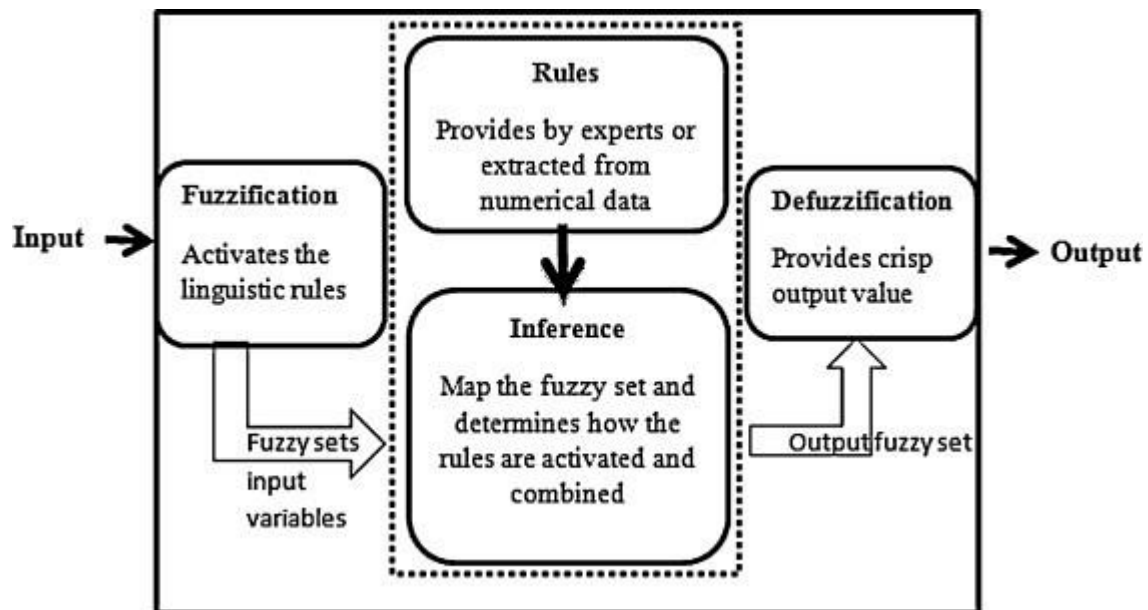


Εικόνα 23: Δομή του ασαφούς συστήματος εξαγωγής συμπερασμάτων (Ζερβουδάκης, 2008)



Εικόνα 24: Σχηματικό διάγραμμα ενός ασαφούς συστήματος συμπερασμού (Fuzzy Inference System-FIS) (Kiran και Rajput, 2011)

Οι τεχνικές των ΤΝΔ, των ασαφών συστημάτων συμπερασμού και των ασαφών συνόλων έχουν συνδυαστεί με διάφορους τρόπους, συμβάλλοντας σημαντικά στη συνεχή ανάπτυξη της τεχνητής νοημοσύνης σε όλες τις πτυχές της καθημερινής ζωής.



Εικόνα 25: Ένα απλό σύστημα συμπερασμού (Singh et.al, 2012)

5.3.2 Ασαφείς Κανόνες

Οι συναρτήσεις συμμετοχής μπορεί να έχουν διάφορες μορφές, όπως Γκαουσιανές, συνδυασμός Γκαουσιανών, τραπεζοειδείς, γενικευμένες τύπου καμπύλης Bell, τριγωνικές, μορφής Π και διαφορά ή παράγωγο μεταξύ δύο σιγμοειδών συναρτήσεων. Η επιλογή της κατάλληλης συνάρτησης συμμετοχής γίνεται με βάση την εκάστοτε εφαρμογή τους.

Πίνακας 3: Μορφές συναρτήσεων συμμετοχής (Sadrmomtazi et.al, 2012)

Type	Formula
Triangular	$\max \left(\min \left(\frac{x-a}{b-a}, \frac{c-x}{c-b} \right), 0 \right)$
Trapezoidal	$\max \left(\min \left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c} \right), 0 \right)$
Bell-shape	$\frac{1}{\left(1 + \left \frac{x-c}{a} \right ^{2b} \right)}$
Gaussian	$e^{-\frac{(x-c)^2}{2\sigma}}$

Η ασαφής λογική διαθέτει τις δικές της λογικές λειτουργίες με τους όρους «και-AND», «ή-OR και «είτε-OR». Κάθε μία από αυτές τις λειτουργίες ορίζεται με βάσει το είδος των εισαγόμενων τιμών. Οι ασαφείς κανόνες είναι καίριοι παράγοντες της ασαφούς λογικής, αφού συνδέουν τα ασαφή σύνολα μεταξύ τους. Στην παρούσα εργασία, θα

μελετηθεί το σύστημα κανόνων “EAN-TOTE, IF-THEN” που δηλώνει ότι «αν ο πρόγονος του κανόνα ισχύει σε κάποιο βαθμό συμμετοχής, τότε μπορεί να συναχθεί το συμπέρασμα ότι το επακόλουθο αποτέλεσμα θα ισχύει επίσης στον ίδιο βαθμό» (Talei et al., 2010).

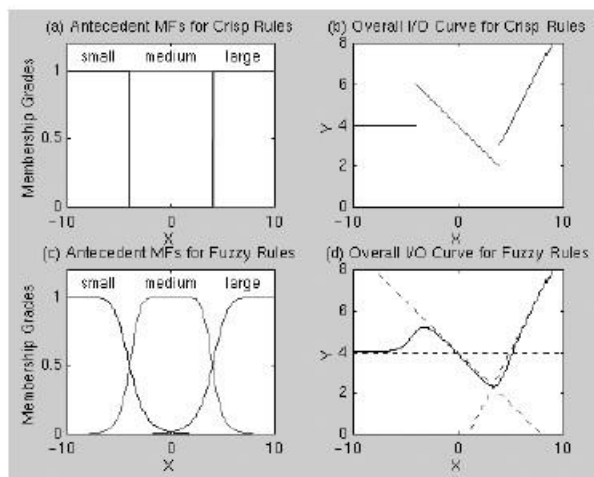
5.3.2.1 Ασαφές Σύστημα Συμπερασμού Takagi-Sugeno-Kang (TSK)

Το σύστημα κανόνων που χρησιμοποιείται για τα ασαφή συστήματα συμπερασμού χωρίζεται σε τέσσερις κύριες κατηγορίες: ασαφή σχεσιακά μοντέλα (Fuzzy Relational Models), μοντέλα βασισμένα σε νευρωνικά δίκτυα, γλωσσικά μοντέλα, και τέλος μοντέλα που ονομάζονται Takagi-Sugeno-Kang (TSK) (Takami and Sugeno, 1985; Sugeno and Kang, 1988).

Takagi-Sugeno (TS) Model

- Combines fuzzy sets in antecedents with **crisp** function in output:
- IF (x_1 is A) AND (x_2 is B) THEN $y = f(x_1, x_2)$

Συναρτήσεις με μη γραμμικές και ακανόνιστες εισόδους



IF X is *small*
THEN $Y_1=4$
IF X is *medium*
THEN $Y_2=-0.5X+4$
IF X is *large*
THEN $Y_3=X-1$

$$Y = \frac{\sum_{j=1}^n Y_j w_j}{\sum_{j=1}^n w_j}$$

Εικόνα 26: Λειτουργία Ασαφούς Συστήματος Takagi-Sugeno-Kang (TSK) (Bonissone, 2002)

Τα μοντέλα Takagi-Sugeno-Kang, καθώς και τα ασαφή συστήματα συμπερασμού τύπου Mamdani, είναι τα πλέον διαδεδομένα. Στην παρούσα έρευνα, ο ερευνητής κάνει χρήση του μοντέλου TSK.

Ο τύπος Mamdani προϋποθέτει τόσο η παραδοχή (EAN-IF) όσο και το συνακόλουθο μέρος (TOTE-THEN) του κανόνα «EAN-TOTE, IF-THEN» να είναι ασαφείς προτάσεις. Αντίθετα, η μέθοδος TSK προϋποθέτει η παραδοχή να είναι ασαφής πρόταση, αλλά το συνακόλουθο να είναι μία μαθηματική συνάρτηση, συνήθως πολυώνυμο μηδενικού ή πρώτου βαθμού. Το TSK μοντέλο είναι αρκετά πιο απλό στην αναγνώρισή του, καθώς απαιτεί λιγότερους κανόνες, ενώ οι παράμετροί του μπορούν να υπολογιστούν από αριθμητικά δεδομένα, κάνοντας χρήση μεθόδων βελτιστοποίησης όπως ο αλγόριθμος των ελαχίστων τετραγώνων. Εκτός αυτού, το TSK μοντέλο υπερέχει ως προς την ευελιξία, αφού λειτουργεί όχι μόνο με γραμμικές τεχνικές, αλλά και με προσαρμοστικές τεχνικές και τεχνικές βελτιστοποίησης.

Όπως αναφέρθηκε προηγουμένως, ο ερευνητής χρησιμοποιεί το πιο ευρέως διαδεδομένο ασαφές μοντέλο, το Takagi-Sugeno-Kang. Στο μοντέλο αυτό, ο ασαφής κανόνας αποτελείται από ένα σταθμισμένο γραμμικό συνδυασμό μη γραμμικών ή ακανόνιστων δεδομένων, και όχι από ένα ασαφές σύνολο.


Ένας τυπικός κανόνας TSK έχει την εξής μορφή:

$$\text{IF } (x \text{ is } A_1) \text{ AND } (y \text{ is } B_1) \text{ THEN } (f_1 = p_1 x + q_1 y + r_1)$$

$$\text{IF } (x \text{ is } A_2) \text{ AND } (y \text{ is } B_2) \text{ THEN } (f_2 = p_2 x + q_2 y + r_2)$$

όπου A_1 , A_2 , και B_1 , B_2 είναι οι τιμές συμμετοχής των εισερχόμενων μεταβλητών x και y . Από την άλλη, οι p_1 , q_1 , r_1 και p_2 , q_2 , r_2 είναι παράμετροι των συναρτήσεων f_1 και f_2 αντίστοιχα. Ένα τέτοιο σύστημα, το οποίο παράγει αποτελέσματα από τη συνάρτηση

f για τις μεταβλητές x και y από τριγωνικές συναρτήσεις συμμετοχής, παρουσιάζεται στην Εικόνα 27 που ακολουθεί:



Εικόνα 27: Σχηματική απεικόνιση συναρτήσεων συμμετοχής στο FIS μοντέλο τύπου Takagi-Sugeno-Kang (Talei et.al, 2010)

5.3.3 Ασαφές Σύστημα Συμπερασμού Τύπου 2 (Type-2 Fuzzy Inference System) με Χρήση Βελτιστοποίησης Σμήνους Σωματιδίων (Particle Swarm Optimization - PSO)

Η πρόβλεψη ενέργειας από Φ/Β μονάδες με τη χρήση ασαφών συστημάτων τύπου 2 (Fuzzy Type-2) αποτελεί μια εξελιγμένη μεθοδολογία που αντιμετωπίζει τις αβεβαιότητες και την πολυπλοκότητα των μη γραμμικών συστημάτων με αποτελεσματικό τρόπο. Τα ασαφή σύνολα τύπου 2, σε αντίθεση με τα σύνολα τύπου 1, επιτρέπουν την αναπαράσταση και διαχείριση της αβεβαιότητας στην ίδια τη συνάρτηση συμμετοχής, προσφέροντας ένα ευρύτερο πλαίσιο για τη μοντελοποίηση πολύπλοκων και αβέβαιων συστημάτων.

Η εφαρμογή της βελτιστοποίησης σμήνους σωματιδίων (PSO) στο πλαίσιο αυτό έρχεται να ενισχύσει την απόδοση των ασαφών συστημάτων τύπου 2. Η PSO είναι μια μέθοδος βελτιστοποίησης εμπνευσμένη από τη συμπεριφορά των σμηνών, όπου

κάθε σωματίδιο αντιπροσωπεύει μια πιθανή λύση και κινείται στο χώρο αναζήτησης επηρεαζόμενο από την εμπειρία του ίδιου και των γειτονικών του σωματιδίων.

Στην περίπτωση της πρόβλεψης ενέργειας, η PSO χρησιμοποιείται για τη βελτιστοποίηση των παραμέτρων των ασαφών συνόλων τύπου 2, όπως είναι οι συναρτήσεις συμμετοχής και οι κανόνες που διέπουν το σύστημα. Η διαδικασία περιλαμβάνει τα ακόλουθα βήματα:

1. **Αρχικοποίηση των σωματιδίων:** Κάθε σωματίδιο αντιπροσωπεύει μια πιθανή λύση με συγκεκριμένες τιμές για τις παραμέτρους του ασαφούς συστήματος τύπου 2.
2. **Αξιολόγηση της απόδοσης:** Η απόδοση κάθε σωματιδίου αξιολογείται βάσει ενός προκαθορισμένου κριτηρίου, όπως το σφάλμα πρόβλεψης της παραγόμενης ενέργειας.
3. **Ενημέρωση των σωματιδίων:** Τα σωματίδια προσαρμόζουν τις θέσεις τους στο χώρο αναζήτησης, επηρεαζόμενα από την εμπειρία τους και την εμπειρία των γειτονικών τους σωματιδίων.
4. **Επανάληψη της διαδικασίας:** Η διαδικασία επαναλαμβάνεται για ένα προκαθορισμένο αριθμό επαναλήψεων ή μέχρι να επιτευχθεί μια ικανοποιητική λύση.

Αυτή η συνδυαστική προσέγγιση επιτρέπει την αποτελεσματική πρόβλεψη της παραγόμενης ενέργειας, λαμβάνοντας υπόψη την αβεβαιότητα και την πολυπλοκότητα των δεδομένων, και βελτιστοποιώντας ταυτόχρονα τις παραμέτρους του συστήματος μέσω της μεθόδου PSO.

Συμπερασματικά, η εφαρμογή αυτής της μεθόδου έχει αποδειχθεί ότι παρέχει αξιόπιστα αποτελέσματα, καθιστώντας την μια σημαντική προσέγγιση για την αντιμετώπιση των προκλήσεων που σχετίζονται με την πρόβλεψη παραγωγής ενέργειας από ΑΠΕ (Muhammad Ibrahim et al., 2024; Lai et al., 2020).

Κεφάλαιο 6: Προσαρμοστικό Νευρο-Ασαφές Σύστημα Συμπερασμού (Adaptive Neuro-Fuzzy Inference System – ANFIS)

6.1 Εισαγωγή / Νευροασαφή Συστήματα

Ο νευρο-ασαφής υβριδισμός οδηγεί στη δημιουργία ενός συστήματος υβριδικής νοημοσύνης που συνδυάζει τις δυνατότητες ενός τεχνητού νευρωνικού δικτύου με την ασαφή λογική. Με τον τρόπο αυτό, το σύστημα συνδυάζει τη συλλογιστική προσέγγιση των ασαφών συστημάτων συμπερασμού, εμπνευσμένη από τον ανθρώπινο τρόπο σκέψης, με τη δομή μάθησης/εκπαίδευσης και τη σύνδεση των κόμβων/νευρώνων των νευρωνικών δικτύων.

Στον συνδυασμό αυτό, τα νευρωνικά δίκτυα προσαρμόζουν τις συναρτήσεις συμμετοχής των ασαφών συστημάτων ακόμη και για πολύπλοκα συστήματα, μεταφέροντας τα βάρη του νευρωνικού ιστού μέσα από τη χρήση ασαφών κανόνων. Ταυτόχρονα, προσφέρεται βαθιά κατανόηση και γνώση μέσα στο νευρωνικό δίκτυο, διευκολύνοντας και καθιστώντας πιο αποδοτική τη διαδικασία σχεδιασμού ενός νευρωνικού δικτύου. Οι μη γραμμικές συναρτήσεις συμμετοχής της νευρο-ασαφούς προσέγγισης μειώνουν το πλήθος κανόνων που απαιτούνται και επιτυγχάνουν εξοικονόμηση της μνήμης του συστήματος, ελαχιστοποιώντας έτσι το κόστος εφαρμογής.

Τα νευρο-ασαφή υβριδικά συστήματα επιτυγχάνουν τον συνδυασμό των πλεονεκτημάτων των ασαφών συστημάτων στην αξιοποίηση, τον χειρισμό και την κατανόηση της υφιστάμενης γνώσης, με την ικανότητα των νευρωνικών δικτύων να εκμεταλλεύονται τη γνώση που αποκτάται μέσω της διαδικασίας μάθησης και εκπαίδευσης.

Το μοντέλο ANFIS (Adaptive Neuro-Fuzzy Inference System) είναι μια από τις πιο διαδεδομένες κατηγορίες υβριδικών νευρο-ασαφών ελεγκτών. Το μοντέλο αυτό ενσωματώνει μια διαδικασία εκπαίδευσης παρόμοια με εκείνη των τεχνητών νευρωνικών δικτύων, επιτρέποντας τη χρήση πληροφοριών από ένα σύνολο δεδομένων για τη διαμόρφωση των συναρτήσεων μεταφοράς ενός ασαφούς συστήματος. Το ANFIS βασίζεται κυρίως στο σύστημα τύπου Sugeno, αν και μπορούν να χρησιμοποιηθούν και άλλα μοντέλα όπως το μοντέλο Mamdani.

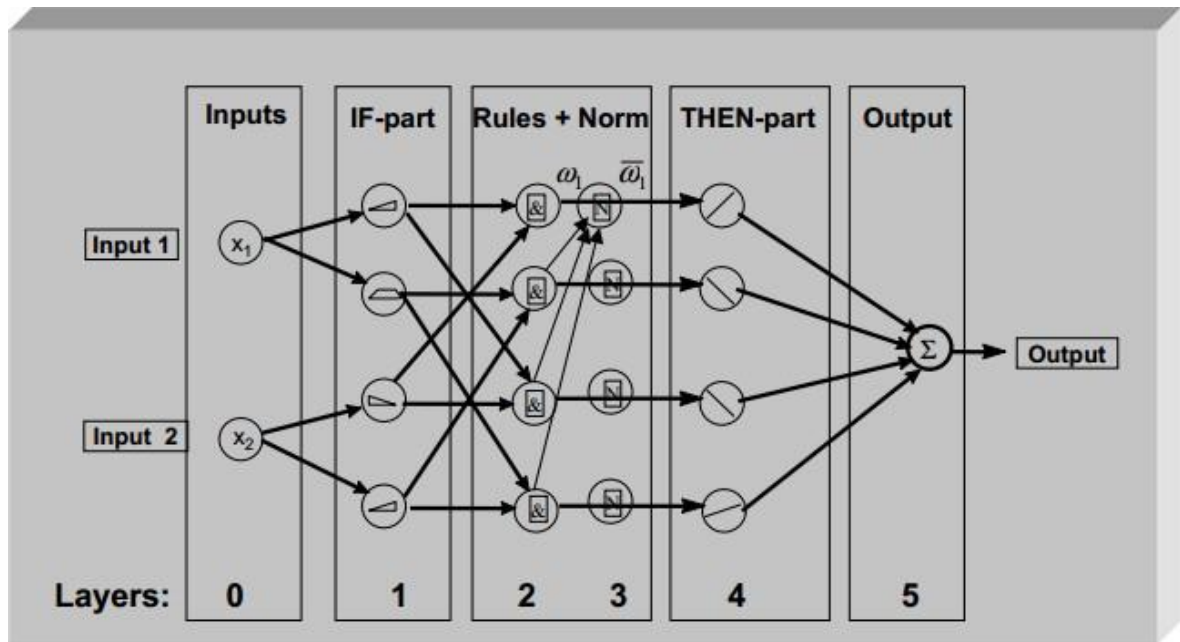
Είναι σημαντικό να τονιστεί ότι το μοντέλο αποδίδει αποτελεσματικά όταν τα δεδομένα εκπαίδευσης αντιπροσωπεύουν επαρκώς τα χαρακτηριστικά που πρόκειται να μοντελοποιηθούν, κάτι που απαιτεί ένα σχετικά μεγάλο δείγμα δεδομένων.

Στη συνέχεια του κεφαλαίου θα παρουσιαστούν τα χαρακτηριστικά του ANFIS, η δομή του και ο αλγόριθμος εκπαίδευσης που χρησιμοποιείται, ο οποίος συνδυάζει τη μέθοδο εκτίμησης ελαχίστων τετραγώνων και τον αλγόριθμο οπισθόδρομης διάδοσης.

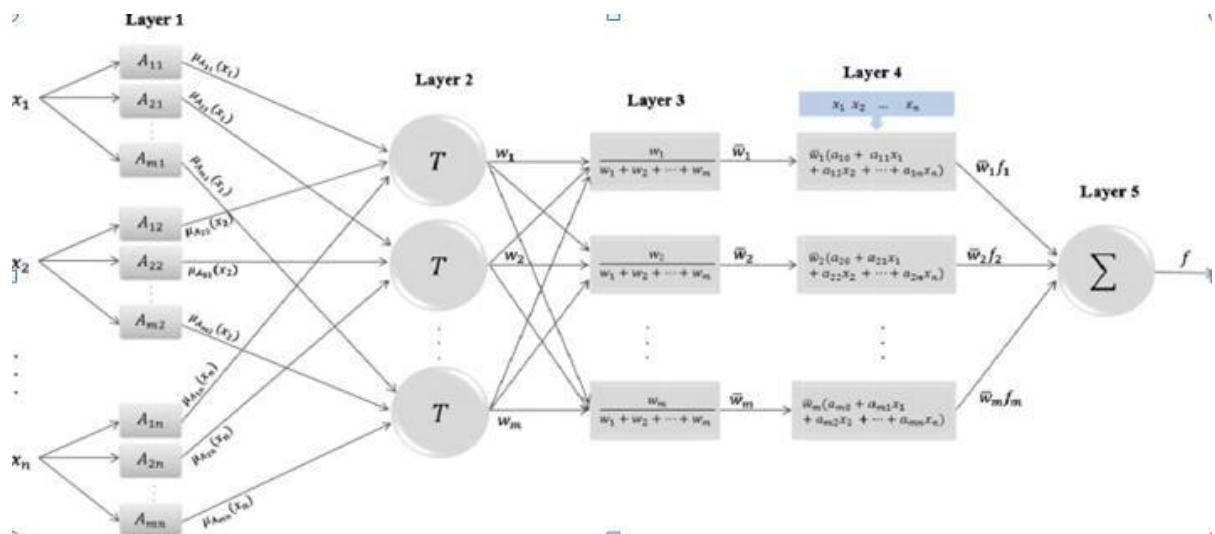
6.2 Δίκτυο ANFIS και νευρώνες

Στην Εικόνα 28 παρουσιάζεται ο συλλογιστικός μηχανισμός (reasoning) του μοντέλου τύπου Sugeno, καθώς και η αντίστοιχη αρχιτεκτονική του ANFIS, όπου οι κόμβοι του ίδιου επιπέδου εκτελούν παρόμοιες λειτουργίες. Στη συνέχεια, παρουσιάζεται πιο αναλυτικά η διεργασία που λαμβάνει χώρα σε κάθε επίπεδο. Τονίζεται ότι οι νευρώνες στην περίπτωση αυτή, έχουν διαφορετικές δομές (Καλαμαράς, 2013), όπως:

- Αξίες-Τιμές (συναρτήσεις συμμετοχής ορισμένες με γενικευμένες συναρτήσεις τύπου Gauss)
- Κανόνες (διαφορίσιμες T-Νόρμες [1])
- Κανονικοποίηση (αθροίσματα και αριθμητικές διαιρέσεις)
- Συναρτήσεις (γραμμικές παλινδρομήσεις και πολλαπλασιασμός με σταθμισμένα, κανονικοποιημένα βάρη)
- Αποτέλεσμα (αλγεβρικό άθροισμα)



Εικόνα 28: Δίκτυο ANFIS (Bonissone, 2002)



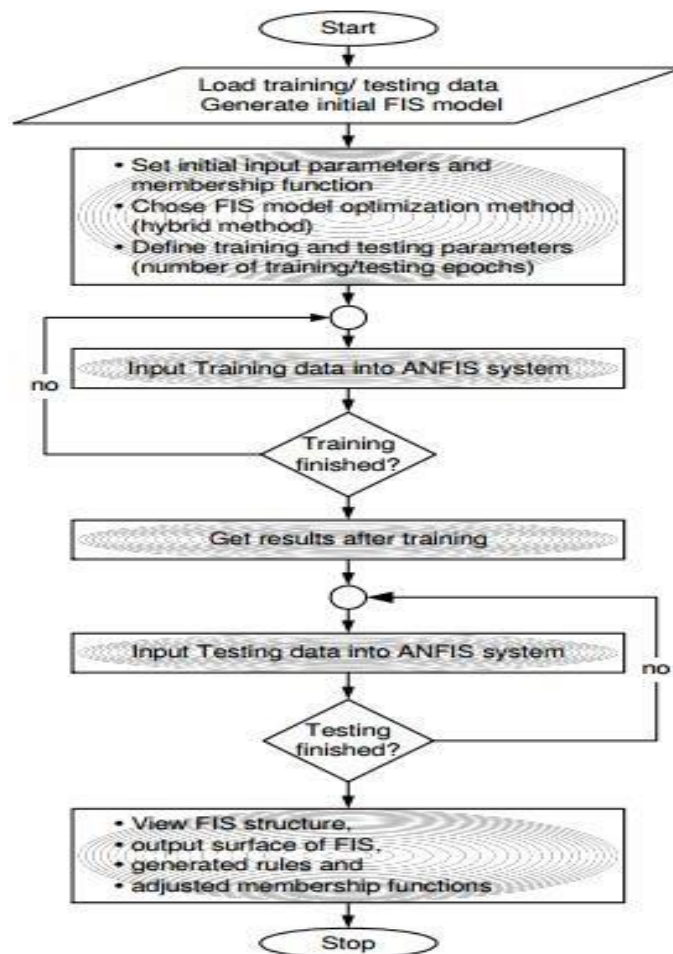
Εικόνα 29: Σχηματική αναπαράσταση της δομής ενός ANFIS μοντέλου για κάθε στρώμα/επίπεδο (Mesbah et.al, 2012)

Η πρώτη φορά που αναπτύχθηκε ο αλγόριθμος ANFIS ήταν το 1992 από τον J.-S. Roger Jang. Ο αλγόριθμος αυτός ουσιαστικά δημιουργεί ένα δέντρο ασαφούς απόφασης για να ταξινομήσει τα δεδομένα σε μοντέλα γραμμικής παλινδρόμησης της μορφής 2^n (ή γενικότερα p^n), με σκοπό τη μείωση του αθροίσματος των τετραγωνικών σφαλμάτων. Η μαθηματική σχέση που περιγράφει αυτό το άθροισμα είναι η εξής:

sum of squared errors (SSE):
$$SSE = \sum_j e_j^2$$
,

όπου e_j αποτελεί το σφάλμα μεταξύ επιθυμητού και πραγματικού αποτελέσματος, p είναι ο αριθμός των ασαφών διχοτομήσεων κάθε μεταβλητής και n είναι το πλήθος των εισερχόμενων μεταβλητών.

Η γενική δομή ενός μοντέλου ANFIS, που χρησιμοποιείται για την παραγωγή προβλέψεων, παρουσιάζεται γραφικά στο παρακάτω διάγραμμα ροής.



Εικόνα 30: Διάγραμμα Ροής της μεθόδου πρόβλεψης ενός μοντέλου ANFIS (Cus et .al, 2006)

Το μοντέλο λαμβάνει ένα σύνολο δεδομένων, αποτελούμενο από ζεύγη εισερχόμενων και εξερχόμενων τιμών, και τα διαχωρίζει σε σύνολα δεδομένων για εκπαίδευση και έλεγχο.

Τα δεδομένα εκπαίδευσης σχηματίζουν ένα σύνολο διανυσμάτων εισόδου και εξόδου, τα οποία κανονικοποιούνται ώστε να είναι κατάλληλα για τη διαδικασία της εκπαίδευσης. Αυτό επιτυγχάνεται αποδίδοντας σε κάθε όρο μία τιμή μεταξύ 0 και 1, χρησιμοποιώντας τη μέθοδο Max-Min. Τα κανονικοποιημένα δεδομένα στη συνέχεια χρησιμοποιούνται ως τιμές εισόδου και εξόδου για την εκπαίδευση του μοντέλου ANFIS. Έτσι, δημιουργούνται δύο διανύσματα για την εκπαίδευση του ANFIS: ένα διάνυσμα εισόδου και ένα διάνυσμα εξόδου.

Τα δεδομένα εκπαίδευσης χρησιμοποιούνται για να προσδιοριστούν οι αρχικές παράμετροι των συναρτήσεων συμμετοχής. Οι παράμετροι αυτές υπολογίζονται μέσω της μεθόδου των ελαχίστων τετραγώνων (least squares method).

Στη συνέχεια, υπολογίζεται το σφάλμα για κάθε ζεύγος δεδομένων. Στην περίπτωση που το σφάλμα υπερβαίνει μια προκαθορισμένη τιμή, οι αρχικές παράμετροι ενημερώνονται μέσω της μεθόδου βαθμωτής καθόδου (gradient descent method). Η διαδικασία επαναλαμβάνεται μέχρι το σφάλμα να γίνει μικρότερο από την επιθυμητή τιμή.

6.3 Αρχιτεκτονική μοντέλου ANFIS

Τα πέντε επίπεδα ή αλλιώς στρώματα του αλγορίθμου ANFIS περιγράφονται ως εξής:

Επίπεδο 1: Κάθε κόμβος i σε αυτό το επίπεδο συνιστά έναν προσαρμοστικό (adaptive) κόμβο, ο οποίος διαθέτει μια συνάρτηση κόμβου όπως η ακόλουθη:

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x), & \text{for } i &= 1, 2, \text{ or} \\ O_{1,i} &= \mu_{B_{i-2}}(y), & \text{for } i &= 3, 4, \end{aligned}$$

όπου x (ή y) είναι η είσοδος στον κόμβο και A_i (or B_{i-2}) είναι η γλωσσική μεταβλητή (π.χ. small, medium, κλπ.) η οποία σχετίζεται με αυτή τη συνάρτηση του κόμβου.

Εν ολίγοις, το $O_{1,i}$, είναι ουσιαστικά ο βαθμός συμμετοχής του A ($= A_1, A_2, B_1$ or B_2)


και καθορίζει το βαθμό που η είσοδος x ή y ικανοποιεί τον ποσοτικοποιητή A . Όσον αφορά τη συνάρτηση συμμετοχής για το A , αυτή μπορεί να είναι οποιαδήποτε κατάλληλη παραμετρική συνάρτηση συμμετοχής. Ένα παράδειγμα είναι η καμπανοειδής συνάρτηση, με τύπο:

$$\mu_A(x_i) = \frac{1}{1 + \left| \frac{x_i - c_i}{a_i} \right|^{2b}}$$

όπου $\{a_i, b_i, c_i\}$ είναι το σύνολο των παραμέτρων.

Καθώς οι τιμές αυτών των παραμέτρων μεταβάλλονται, οι συναρτήσεις ποικίλλουν αντίστοιχα, εμφανίζοντας διάφορες μορφές της συνάρτησης συμμετοχής για το ασαφές σύνολο A . Οι παράμετροι σε αυτό το επίπεδο ονομάζονται αρχικές παράμετροι (premise parameters).

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b}}$$



Εικόνα 31: Γραφική αναπαράσταση της επίδρασης που έχει η αλλαγή των παραμέτρων a , b και c της καμπανοειδούς συνάρτησης (Bonissone, 2002)

Επίπεδο 2: Σε αυτό το δεύτερο επίπεδο, κάθε κόμβος είναι σταθερός και συμβολίζεται με Π, με την έξοδό του να είναι το γινόμενο όλων των εισερχόμενων σημάτων:

$$O_{2,i} = w_i = \mu_{A_i}(x_1)\mu_{B_i}(x_2) \quad (\text{for } i=1,2)$$

Κάθε κόμβος-έξοδος αντιπροσωπεύει το βαθμό ενεργοποίησης ενός κανόνα (firing strength). Γενικά, μπορούν να χρησιμοποιηθούν άλλες T-norm (τελεστές) που αντιπροσωπεύουν τον ασαφή τελεστή AND ως συνάρτηση κόμβων σε αυτό το επίπεδο.

Επίπεδο 3: Σε αυτό το στάδιο, γίνεται η κανονικοποίηση των βαθμών ενεργοποίησης. Κάθε κόμβος σε αυτό το επίπεδο είναι σταθερός και συμβολίζεται με N. Ο i-οστός κόμβος υπολογίζει το λόγο του βαθμού ενεργοποίησης του i-οστού κανόνα προς το άθροισμα των βαθμών ενεργοποίησης του συνόλου των κανόνων:

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad (\text{for } i=1,2)$$

Οι έξοδοι αυτού του επιπέδου ονομάζονται (χάριν ευκολίας) κανονικοποιημένοι βαθμοί ενεργοποίησης (normalized firing strengths).

Επίπεδο 4: Εδώ πραγματοποιείται η αξιολόγηση του δεξιού μέρους των πολυωνύμων. Κάθε κόμβος σε αυτό το επίπεδο είναι προσαρμόσιμος και διαθέτει μια συνάρτηση κόμβου:

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i)$$

όπου \bar{w}_i είναι ο κανονικοποιημένος βαθμός ενεργοποίησης από το επίπεδο 3, και $\{p_i, q_i, r_i\}$ είναι το σύνολο των παραμέτρων. Οι παράμετροι σε αυτό το επίπεδο ονομάζονται επακόλουθοι (consequent parameters).

Επίπεδο 5: Ο μοναδικός κόμβος στο πέμπτο επίπεδο είναι ένας σταθερός κόμβος Σ ο οποίος υπολογίζει τη συνολική έξοδο ως το ολικό άθροισμα όλων των εισερχόμενων σημάτων:

$$O_{5,1} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

$$\begin{aligned} &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ &= \bar{w}_1 (p_1 x_1 + q_1 x_2 + r_1) + \bar{w}_2 (p_2 x_1 + q_2 x_2 + r_2) \\ &= (\bar{w}_1 x_1) p_1 + (\bar{w}_1 x_2) q_1 + (\bar{w}_1) r_1 + (\bar{w}_2 x_1) p_2 + (\bar{w}_2 x_2) q_2 + (\bar{w}_2) r_2 \end{aligned}$$

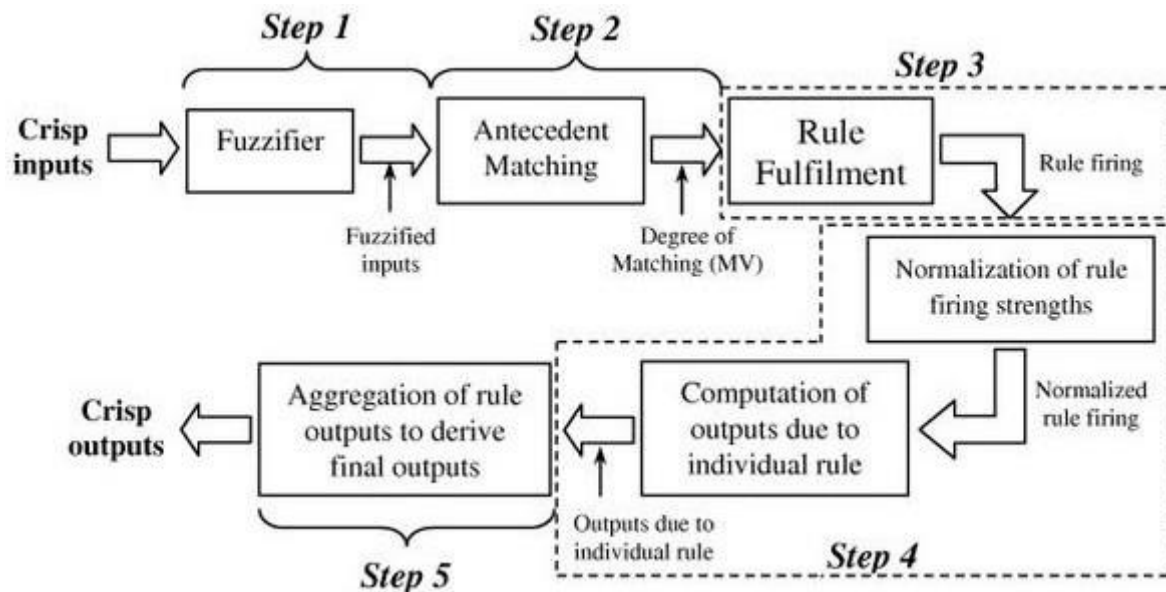
Το αποτέλεσμα είναι ένας γραμμικός συνδυασμός των παραμέτρων που προκύπτουν, όταν οι τιμές των εισαγωγικών παραμέτρων είναι δεδομένες.

Από τα παραπάνω, διαπιστώνεται ότι η αρχιτεκτονική του μοντέλου ANFIS έχει δύο προσαρμοστικά στρώματα – επίπεδα, το 1^ο και το 4^ο. Το 1^ο στρώμα έχει παραμέτρους (a_i, b_i, c_i) και (a_j, b_j, c_j) που είναι τροποποιήσιμες και σχετίζονται με τις συναρτήσεις συμμετοχής εισαγωγής. Από την πλευρά του, το 4^ο στρώμα διαθέτει τροποποιήσιμες παραμέτρους (p_{ij}, q_{ij}, r_{ij}), οι οποίες ανήκουν στο πολυώνυμο πρώτου βαθμού.

Ο πίνακας 5 παρακάτω παρουσιάζει αναλυτικά τους κόμβους, τις παραμέτρους και τους βαθμούς των παραμέτρων που χρησιμοποιούνται σε κάθε επίπεδο του συστήματος ANFIS.

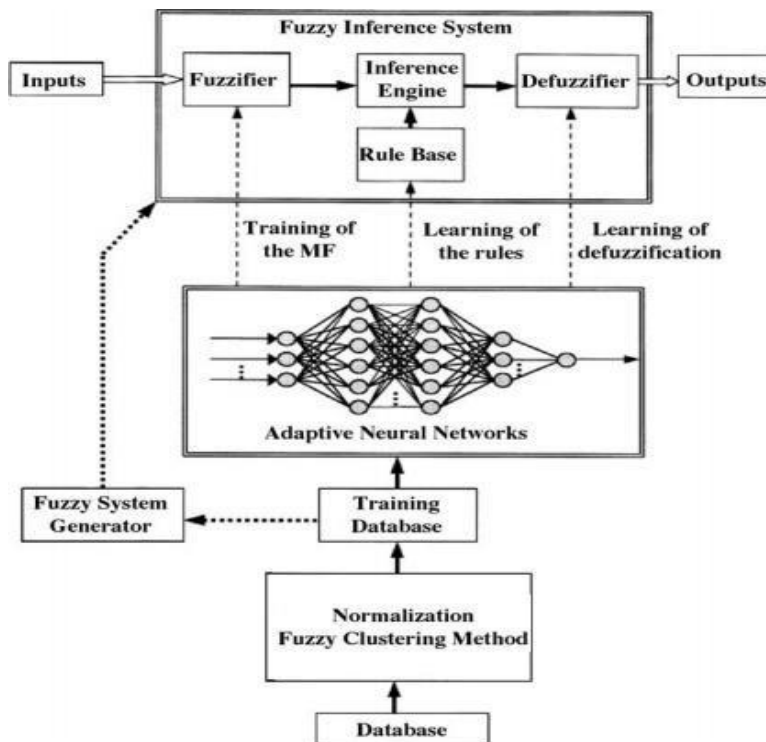
Πίνακας 4: Υπολογιστική πολυπλοκότητα του συστήματος ANFIS (Bonissone, 2002)

Layer #	L-Type	# Nodes	# Param
L ₀	Inputs	n	0
L ₁	Values	(p•n)	3•(p•n)= S1
L ₂	Rules	p ⁿ	0
L ₃	Normalize	p ⁿ	0
L ₄	Lin. Funct.	p ⁿ	(n+1)•p ⁿ = S2
L ₅	Sum	1	0




Εικόνα 32: Προσαρμοστικό Νεύρο-ασαφές Σύστημα υιοθετεί το ασαφές σύστημα TSK. Γραφική παράσταση της διαδικασίας συμπερασμού βασισμένη στο μοντέλο TSK (Tan et.al, 2011)

Το μοντέλο περιλαμβάνει πέντε κύρια στοιχεία: τα εισερχόμενα δεδομένα, τα παραγόμενα αποτελέσματα, τον προ-επεξεργαστή, μία γεννήτρια ασαφούς συστήματος, ένα ασαφές σύστημα συμπερασμού, και ένα προσαρμοστικό νευρωνικό δίκτυο. Το ασαφές σύστημα συμπερασμού (ΑΣΣ) είναι τύπου Sugeno, ενώ το προσαρμοστικό δίκτυο βασίζεται στο σύστημα ANFIS. Τα δεδομένα εισόδου και εξόδου επιλέγονται από τις μεταβλητές που περιγράφουν το σύστημα. Μια βάση δεδομένων, η οποία περιέχει πληροφορίες σχετικά με τη λειτουργία και την απόδοση του συστήματος, είναι απαραίτητη για την ανάπτυξη του μοντέλου. Η ποιότητα και η ακρίβεια των δεδομένων στη βάση αυτή καθορίζουν την αποτελεσματικότητα της διαδικασίας εκπαίδευσης.



Εικόνα 33: Αρχιτεκτονική μοντέλου ANFIS, όπως αναπτύχθηκε από τον Jang το 1992 (Wanb et.al, 2011)



Εικόνα 34: Γενική αρχιτεκτονική ενός μοντέλου ANFIS (Bey και Benhammadi, 2010)

6.4 Εκπαίδευση μοντέλου ANFIS

Το ασαφές σύστημα που προκύπτει από την προαναφερθείσα διαδικασία παρέχει ένα αρχικό ασαφές μοντέλο, για το οποίο έχουν καθοριστεί ο αριθμός των κανόνων και η αρχική τους θέση. Εισάγοντας τις τιμές εισόδου στο μοντέλο αυτό, παρατηρούνται αποκλίσεις από τις επιθυμητές τιμές, οι οποίες ενδέχεται να είναι μη αποδεκτές. Με μικρές μετακινήσεις των ασαφών συνόλων στις εισόδους και εξόδους, μπορεί να επιτευχθεί βελτίωση της κατάστασης. Η τελική φάση του σχεδιασμού του συστήματος είναι ο ακριβής προσδιορισμός των παραμέτρων του, δηλαδή των κέντρων και των αποκλίσεων των ασαφών συνόλων, ώστε να προσαρμοστεί όσο το δυνατόν πιο πιστά στις καθορισμένες προδιαγραφές. Αυτή η προσαρμογή, γνωστή ως εκπαίδευση του συστήματος, πραγματοποιείται με μεθόδους μη γραμμικής βελτιστοποίησης, με εξέχουσα τη χρήση γενετικών αλγορίθμων.

Η διαδικασία εκπαίδευσης του αλγορίθμου για την αρχιτεκτονική του μοντέλου ANFIS περιλαμβάνει τη ρύθμιση όλων των τροποποιήσιμων παραμέτρων, ώστε το αποτέλεσμα του ANFIS να εναρμονίζεται με τα δεδομένα εκπαίδευσης. Η εκπαίδευση ή προσαρμογή των τροποποιήσιμων μεταβλητών είναι μια διαδικασία δύο βημάτων, γνωστή ως υβριδικός αλγόριθμος εκπαίδευσης. Αυτός ο αλγόριθμος συνδυάζει τη μέθοδο βαθμωτής καθόδου με τη μέθοδο ελαχίστων τετραγώνων για την ενημέρωση των παραμέτρων του προσαρμοστικού δικτύου. Κάθε εποχή της υβριδικής διαδικασίας εκπαίδευσης περιλαμβάνει ένα εμπρόσθιο και ένα οπισθόδρομο πέρασμα.

Όπως αναφέρθηκε, οι παράμετροι του ANFIS που μπορούν να μεταβληθούν κατά τη μάθηση είναι οι παράμετροι των μη γραμμικών κόμβων του πρώτου επιπέδου και οι παράμετροι των γραμμικών κόμβων του τετάρτου επιπέδου. Αν S είναι το σύνολο των παραμέτρων, τότε ισχύει: $S = S1 \cup S2$, όπου $S1$ είναι το σύνολο των μη γραμμικών και $S2$ είναι το σύνολο των γραμμικών παραμέτρων.

Για την εκπαίδευση του δικτύου χρησιμοποιείται ένας υβριδικός αλγόριθμος, ο οποίος χωρίζεται σε δύο μέρη με διάδοση προς τα εμπρός και οπισθοδρόμηση για πρώσο-τροφοδοτούμενα δίκτυα.

6.4.1 Διάδοση προς τα εμπρός (forward pass)

Οι μη γραμμικές παράμετροι διατηρούνται σταθερές και το δίκτυο παράγει εξόδους μέχρι το τέταρτο στρώμα, όπου οι γραμμικές παράμετροι προσδιορίζονται χρησιμοποιώντας τη μέθοδο των ελαχίστων τετραγώνων

6.4.2 Οπισθοδρόμηση για Πρώσο-Τροφοδοτούμενα Δίκτυα (backward pass)

Αυτή η ενότητα παρουσιάζει έναν θεμελιώδη κανόνα εκμάθησης για προσαρμοστικά δίκτυα, που είναι ουσιαστικά η πιο απλή μέθοδος βαθμωτής ελαχιστοποίησης. Το βασικό στοιχείο αυτού του κανόνα εκμάθησης αφορά στην επαναληπτική επιλογή ενός διανύσματος κλίσης, όπου κάθε στοιχείο ορίζεται ως η παράγωγος ενός σφάλματος ως προς μία παράμετρο. Η διαδικασία αυτή πραγματοποιείται με τη βοήθεια του κανόνα της αλυσίδας, ενός θεμελιώδους τύπου για τον υπολογισμό των παραγώγων σύνθετων συναρτήσεων, ο οποίος αναλύεται εκτενώς σε κάθε μαθηματικό εγχειρίδιο.

Η διαδικασία υπολογισμού ενός διανύσματος κλίσης σε ένα δίκτυο αναφέρεται γενικά ως οπισθοδρόμηση (backpropagation), επειδή το διάνυσμα κλίσης υπολογίζεται σε κατεύθυνση που είναι αντίθετη από τη ροή της εξόδου κάθε κόμβου. Μετά τον υπολογισμό της κλίσης, διάφορες τεχνικές βελτιστοποίησης και παλινδρόμησης που βασίζονται στις παραγώγους μπορούν να χρησιμοποιηθούν για την ενημέρωση των παραμέτρων. Συγκεκριμένα, εάν το διάνυσμα κλίσης χρησιμοποιείται σε μια απλή μέθοδο βαθμωτής ελαχιστοποίησης, η διαδικασία μάθησης που προκύπτει, αναφέρεται συχνά ως κανόνας οπισθόδρομης μάθησης.

Για κάθε παράμετρο a_i , η εξίσωση που προκύπτει δίνεται από τον τύπο:

$$n = \frac{\kappa}{\sqrt{\sum_i (\frac{\partial E}{\partial a_i})^2}}$$

όπου $\Delta a_i = -n \frac{\partial^+ E}{\partial a_i}$ είναι ο ρυθμός εκπαίδευσης και κ είναι το μέγεθος βήματος.

6.4.3 Εκτιμητής Ελαχίστων Τετραγώνων (Least Squares (LSE) Batch Algorithm)

Στο γενικό πρόβλημα ελαχίστων τετραγώνων, η έξοδος του γραμμικού μοντέλου y εκφράζεται από την παραμετροποιημένη γραμμική εξίσωση:

$$y = \theta_1 f_1(u) + \theta_2 f_2(u) + \dots + \theta_n f_n(u),$$

όπου $\mathbf{u} = [u_1, \dots, u_p]^T$ είναι το διάνυσμα εισόδου του μοντέλου, f_1, \dots, f_n είναι γνωστές συναρτήσεις του \mathbf{u} και $\theta_1, \dots, \theta_n$ είναι οι άγνωστες παράμετροι που θα προσδιοριστούν. Η παραπάνω εξίσωση ονομάζεται συνάρτηση παλινδρόμησης, και οι παράμετροι θ_i ονομάζονται συντελεστές παλινδρόμησης.

Για να προσδιοριστούν οι άγνωστες παράμετροι θ_i , συνήθως πρέπει να γίνουν πολλές δοκιμές, για να βρεθεί ένα σύνολο δεδομένων εκπαίδευσης, αποτελούμενο από τα ζευγάρια δεδομένων (\mathbf{u}_i, y_i) , $i = 1, \dots, m$ τα οποία αντιπροσωπεύουν τα επιθυμητά ζεύγη εισόδου-εξόδου του συστήματος που θα μοντελοποιηθεί.

Ο στόχος είναι να βρεθεί το $\theta = \hat{\theta}$ που ελαχιστοποιεί το άθροισμα του τετραγωνικού σφάλματος, το οποίο δίνεται από την εξίσωση:

$$E(\theta) = \sum_{i=1}^m (y_i - \mathbf{a}_i^T \theta)^2 = \mathbf{e}^T \mathbf{e} = (\mathbf{y} - \mathbf{A}\theta)^T (\mathbf{y} - \mathbf{A}\theta)$$

όπου $\mathbf{e} = \mathbf{y} - \mathbf{A}\theta$ είναι το διάνυσμα λάθους που προκύπτει από μια συγκεκριμένη επιλογή του θ .

Ο αλγόριθμος έχει ως εξής:

- Σύνολο παραμέτρων: $\mathbf{S} = \{\mathbf{S}_1 \cup \mathbf{S}_2\}$ και $\{\mathbf{S}_1 \cap \mathbf{S}_2 = \emptyset\}$
Αποτέλεσμα = $\mathbf{F}(\bar{\mathbf{I}}, \mathbf{S})$, όπου $\bar{\mathbf{I}}$ εισερχόμενο διάνυσμα
Η έξοδος (**output**) = $\mathbf{H} \circ \mathbf{F}(\bar{\mathbf{I}}, \mathbf{S})$, όπου $\mathbf{H} \circ \mathbf{F}$ είναι γραμμικό στο \mathbf{S}_2
- Για δεδομένες τιμές του \mathbf{S}_1 , χρησιμοποιώντας δεδομένα εκπαίδευσης \mathbf{K} , η παραπάνω εξίσωση μπορεί να μετατραπεί στη μορφή $\mathbf{B} = \mathbf{A}\mathbf{X}$, όπου το \mathbf{X} περιέχει τα στοιχεία του \mathbf{S}_2 .
- Η εξίσωση αυτή λύνεται ως εξής: $(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{B} = \mathbf{X}^*$ όπου $(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{B} = \mathbf{X}^*$ είναι μία ψευδοαντιστροφή του \mathbf{A} (εάν το $\mathbf{A}^T \mathbf{A}$ είναι δεν είναι μοναδικό).

- Η μέθοδος των ελαχίστων τετραγώνων (LSE) ελαχιστοποιεί το σφάλμα $\| \mathbf{AX} - \mathbf{B} \|^2$ υπολογίζοντας κατά προσέγγιση το \mathbf{X} μέσω \mathbf{X}^* . Αντί να λυθεί απευθείας η εξίσωση $(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{B} = \mathbf{X}^*$, λύνεται επαναληπτικά με αριθμητικές μεθόδους όπως παρακάτω:

$$\left. \begin{aligned} S_{i+1} &= S_i - \frac{S_i a_{(i+1)} a_{(i+1)}^T S_i}{1 + a_{(i+1)}^T S_i a_{(i+1)}}, \\ X_{i+1} &= X_i + S_{(i+1)} a_{(i+1)} (b_{(i+1)}^T - a_{(i+1)}^T X_i) \end{aligned} \right\} \text{for } i = 0, 1, \dots, K-1$$

όπου $\mathbf{X}_0 = \mathbf{0}$, $\mathbf{S}_0 = \gamma \mathbf{I}$ (όπου γ ένας μεγάλος αριθμός), $\mathbf{a}_i^T = i$ -οστή γραμμή του πίνακα \mathbf{A} , $\mathbf{b}_i^T = i$ -οστό στοιχείο του διανύσματος \mathbf{B} και $\mathbf{X}^* = \mathbf{X}_K$.

Το σφάλμα E_k για την k -οστή είσοδο ($1 \leq k \leq K$) των δεδομένων εκπαίδευσης υπολογίζεται ως:

$$E_k = \sum_{i=1}^{N(L)} (d_i - x_{L,i})^2$$

Όπου $N(L)$ είναι ο αριθμός των κόμβων στο στρώμα L , $\mathbf{d}_i = i$ -οστό στοιχείο του επιθυμητού διανύσματος εξόδου και $\mathbf{x}_{L,i} = i$ -οστό στοιχείο του πραγματικού διανύσματος εξόδου.

Το συνολικό σφάλμα E δίνεται από τον τύπο:

$$E = \sum_{k=1}^K E_k$$

6.5 Υβριδικός Αλγόριθμος μοντέλου ANFIS

Ο συγκερασμός των προαναφερθέντων παραμέτρων του ασαφούς συστήματος ελέγχου επιτυγχάνεται είτε με τη χρήση μόνο του αλγορίθμου οπισθόδρομης διάδοσης (Backpropagation Algorithm) είτε σε συνδυασμό με τη μέθοδο των ελαχίστων τετραγώνων, δημιουργώντας έτσι ένα υβριδικό μοντέλο. Αρχικά, ορίζονται οι τιμές των παραμέτρων και τα αποτελέσματα προκύπτουν μέσω της εφαρμογής της μεθόδου των ελαχίστων τετραγώνων. Στη συνέχεια, υπολογίζεται το σφάλμα βάσει των

παραμέτρων που προέκυψαν και ο αλγόριθμος οπισθόδρομης διάδοσης επαναφέρει το σφάλμα στο επίπεδο εισόδου, ενημερώνοντας τις παραμέτρους μέσω της μεθόδου βαθμωτής κατάβασης (gradient descent method). Αυτό οδηγεί σε προσαρμογή των συναρτήσεων συμμετοχής.

Κατά τη διάρκεια του οπισθόδρομου περάσματος, οι παράμετροι που προέκυψαν παραμένουν σταθερές, τα σήματα σφάλματος διαδίδονται προς τα πίσω και οι παράμετροι εισόδου ενημερώνονται μέσω της μεθόδου βαθμωτής κατάβασης (gradient descent method). Η τεχνική που περιγράφηκε, παρουσιάζεται και στον Πίνακα 6 που ακολουθεί:

Πίνακας 5: Τα δύο περάσματα στη διαδικασία εκπαίδευσης του αλγορίθμου σε ένα μοντέλο ANFIS (Cruz, 2009)

	Forward Pass	Backward Pass
Premise Parameters	Fixed	Gradient Descent
Consequent Parameters	Least-squares estimator	Fixed
Signals	Node outputs	Error signals

	εμπροσθόδρομο πέρασμα	οπισθόδρομο πέρασμα
παράμετροι των προϋποθέσεων	Προκαθορισμένες (αμετάβλητες)	βαθμωτή φθίνουσα μέθοδος
παράμετροι των συμπερασμάτων	εκτιμήτρια ελαχίστων τετραγώνων	προκαθορισμένες (αμετάβλητες)
σήματα	έξοδοι των κόμβων	σήματα σφάλματος

Συγκεκριμένα, με ένα σύνολο δεδομένων εισόδου/εξόδου, το μοντέλο ANFIS δημιουργεί ένα ασαφές σύστημα λήψης αποφάσεων. Οι παράμετροι αυτού του συστήματος ενσωματώνονται με τις συναρτήσεις συμμετοχής και μεταβάλλονται κατά τη διάρκεια της εκπαίδευσης. Αυτές οι παράμετροι λειτουργούν παρόμοια με τα βάρη στα νευρωνικά δίκτυα.

Το δίκτυο ANFIS χωρίζει το σύνολο των παραμέτρων του σε δύο υποσύνολα: Από τη μία πλευρά, το ένα αποτελεί γραμμικό σύνολο παραμέτρων που μπορεί να εκπαιδευτεί με γραμμικούς αλγόριθμους, όπως η μέθοδος των ελαχίστων τετραγώνων. Οι

γραμμικοί αλγόριθμοι μάθησης επιτυγχάνουν συνολικά ελάχιστα (global minimums) της συνάρτησης κόστους στον χώρο των παραμέτρων τους και είναι αποδοτικοί από άποψη υπολογιστικού χρόνου. Από την άλλη πλευρά, το δεύτερο υποσύνολο παραμέτρων εκπαιδεύεται με αλγόριθμους, οι οποίοι μπορούν να δημιουργήσουν μη-γραμμικές απεικονίσεις, όπως η βαθμωτή κατάβαση (gradient descent). Αυτοί οι αλγόριθμοι είναι απαιτητικοί από άποψη χρόνου εκπαίδευσης και δεν εγγυώνται την επίτευξη συνολικού ελαχίστου της συνάρτησης κόστους στον χώρο των παραμέτρων τους.

Ο αλγόριθμος μάθησης του ANFIS συνδυάζει περάσματα προς τα εμπρός και προς τα πίσω. Στο εμπρόσθιο πέρασμα γίνεται η μάθηση του συνόλου των γραμμικών παραμέτρων, ενώ στο οπισθόδρομο πέρασμα προσαρμόζονται οι μη γραμμικές παράμετροι.

Το μοντέλο ANFIS που μελετά ο ερευνητής κάνει χρήση ενός υβριδικού αλγορίθμου εκμάθησης με στόχο να προσδιορίσει τις παραμέτρους του ασαφούς συστήματος τύπου Sugeno. Συγκεκριμένα, εφαρμόζει έναν συνδυασμό της μεθόδου των ελαχίστων τετραγώνων και της μεθόδου οπισθόδρομης βαθμωτής ελαχιστοποίησης (Backpropagation Gradient Descent) για την εκπαίδευση των παραμέτρων των συναρτήσεων συμμετοχής του FIS, ώστε να αναπαράγει ένα δοσμένο σύνολο δεδομένων εκπαίδευσης.

Το πλεονέκτημα της μεθόδου είναι η ικανότητά του να συνδυάζει γραμμικές και μη-γραμμικές τεχνικές, καθιστώντας την ταχύτερη από τα κλασικά νευρωνικά δίκτυα. Οι παράμετροι των συμπερασμάτων που βρίσκονται με αυτόν τον τρόπο είναι οι βέλτιστες, δεδομένου ότι οι παράμετροι των προϋποθέσεων είναι προκαθορισμένες και αμετάβλητες. Η υβριδική προσέγγιση συγκλίνει γρηγορότερα, καθώς μειώνει τις διαστάσεις του διαστήματος αναζήτησης της αρχικής μεθόδου οπισθόδρομης διάδοσης. Αυτός ο συνδυασμός επιτρέπει στο ασαφές σύστημα να μαθαίνει και να εκπαιδεύεται από τα ίδια τα δεδομένα που χρησιμοποιεί.

Το ANFIS λοιπόν συγκλίνει γρηγορότερα από τα συνηθισμένα νευρωνικά δίκτυα. Τέλος, ένα πολύ σημαντικό πλεονέκτημα αυτού του μοντέλου είναι ότι μπορεί να εκφράσει τους ασαφείς κανόνες που χρησιμοποιεί για την εξαγωγή συμπερασμάτων με γλωσσικούς όρους. Αυτό δεν συμβαίνει με τα νευρωνικά δίκτυα, τα οποία

λειτουργούν ως "μαύρα κουτιά" και δεν επιτρέπουν την αποκωδικοποίηση της πληροφορίας που είναι ενσωματωμένη στα βάρη.

6.6 Περιορισμοί ενός μοντέλου ANFIS

Σύμφωνα με τη διεθνή βιβλιογραφία, οι κυριότεροι περιορισμοί των μοντέλων ANFIS περιλαμβάνουν τα εξής:

- 1) Βασίζονται σε ένα Ασαφές Σύστημα Συμπερασμού τύπου Sugeno.
- 2) Παρέχουν μόλις μια έξοδο, η οποία υπολογίζεται με τη μέθοδο αποσαφήνισης σταθμισμένου μέσου.
- 3) Όλες οι συναρτήσεις συμμετοχής εξόδου πρέπει να είναι του ίδιου τύπου, είτε γραμμικές (linear) είτε σταθερές (constant).
- 4) Οι κανόνες δεν μπορούν να μοιράζονται κοινές συναρτήσεις συμμετοχής εξόδου. Διαφορετικοί κανόνες δεν επιτρέπεται να έχουν την ίδια συνάρτηση συμμετοχής εξόδου.
- 5) Πρέπει να υπάρχουν βάρη σε κάθε κανόνα.
- 6) Μπορούν να χρησιμοποιηθούν μόνο προκαθορισμένοι τύποι συναρτήσεων συμμετοχής, όπως ορίζονται από το μοντέλο ANFIS.

Κεφάλαιο 7: Μεθοδολογία του μοντέλου ANFIS

7.1 Εισαγωγή στη Μεθοδολογία

Σε αυτήν την ενότητα της διπλωματικής εργασίας κατασκευάστηκε ο αλγόριθμος του μοντέλου ANFIS, κάνοντας χρήση της γλώσσας προγραμματισμού Matlab. Άλλωστε, η Matlab εδώ και πολλά χρόνια συνιστά αποδεδειγμένα την πλέον κατάλληλη λύση για τον προγραμματισμό μοντέλων ANFIS, παρέχοντας «έτοιμες», κατάλληλες συναρτήσεις γέννησης ασαφών συστημάτων (Tay, J. and Zhang, X. 1999) και συγχρονισμού των ρυθμίσεών τους. Αναλυτικότερα, χρησιμοποιήθηκε κατά κύριο λόγο το Fuzzy Logic Toolbox, το οποίο περιλαμβάνει όλα τα απαιτούμενα εργαλεία για την εξ' ολοκλήρου ανάπτυξη, καθώς και χρήση ενός Προσαρμοστικού Νεύρο-Ασαφούς Συστήματος Συμπερασμού (Adaptive Neuro-Fuzzy Inference System, ANFIS) με τον πλέον αναλυτικό τρόπο, για την πρόβλεψη της παραγόμενης ενέργειας από Φ/Β συστήματα, στο επιθυμητό χρονικό διάστημα.

Στο κεφάλαιο αυτό θα παρουσιαστεί βήμα-βήμα η μεθοδολογία που ακολουθήθηκε στο πρακτικό μέρος αυτής της διπλωματικής εργασίας, για την κατασκευή του μοντέλου ANFIS σε περιβάλλον λειτουργίας προγράμματος Matlab.

7.2 Συλλογή Δεδομένων

Ο αλγόριθμος του μοντέλου ANFIS στο παρόν ερευνητικό έργο λαμβάνει δεδομένα από μία χρονοσειρά, η οποία περιέχει ιστορικές τιμές ωριαίας παραγωγής ηλεκτρικής ενέργειας, και βάσει αυτών των παρελθοντικών τιμών, προβλέπει τις αναμενόμενες ωριαίες μελλοντικές τιμές για επιλεγμένο χρονικό διάστημα. Πιο συγκεκριμένα, η χρονοσειρά αυτή περιέχει εγγραφές ηλεκτρικής ενέργειας (σε MWh) για το γαλλικό δίκτυο από τις 4 Ιανουαρίου 2020 00:00 έως και τις 16 Μαρτίου 2023 00:00. Τα επιθυμητά δεδομένα συλλέχθηκαν έπειτα από κατάλληλη επεξεργασία των αρχικών ακατέργαστων δεδομένων (raw data) και εισήχθησαν σε ένα φύλλο του προγράμματος Microsoft Excel®, όπου και δημιουργήθηκε η χρονοσειρά που εντέλει χρησιμοποιήθηκε. Εξάλλου, οι μετρήσεις αυτές μπορούν να θεωρηθούν καθόλα αξιόπιστες, επειδή το dataset λήφθηκε από τον ιστότοπο ODRE (Open Data Réseaux

Énergies) και είναι αδειοδοτημένο από την Ευρωπαϊκή Ένωση (EU ODP Legal Notice).

7.3 Προεπεξεργασία Δεδομένων

7.3.1 Καθαρισμός και Διαχείριση Δεδομένων

Μετά την αρχική συλλογή και εισαγωγή των δεδομένων, ακολούθησε η κατάλληλη προεπεξεργασία τους για τη μετέπειτα χρήση τους ως προς τις ανάγκες του μοντέλου. Αυτή περιλάμβανε τον έλεγχο για ελλιπείς τιμές - τιμές NaN (Not a Number), που πιθανώς οφείλονταν σε διάφορους παράγοντες, όπως γενικές διακοπές ρεύματος ή αστοχίες στη μέτρηση, καθώς και την κατάλληλη αντικατάστασή τους με μηδενικές τιμές για την βέλτιστη διατήρηση της συνοχής των δεδομένων.

7.3.2 Διαμοιρασμός Δεδομένων

Στη συνέχεια, πραγματοποιήθηκε ο κατάλληλος διαχωρισμός των δεδομένων για την εκπαίδευση (training) και την αξιολόγηση (evaluation) του μοντέλου. Πειραματικές μελέτες έχουν δείξει ότι τα μοντέλα μηχανικής μάθησης που χρησιμοποιούν το 70-80% των δεδομένων για εκπαίδευση και το 20-30% των δεδομένων για αξιολόγηση, παράγουν τα καλύτερα αποτελέσματα (Gholamy et al., 2018; Thien et al., 2022; Tao et al., 2020; Vrigazona et al., 2021).

Από τη μία πλευρά, τα δεδομένα αξιολόγησης χρησιμοποιούνται για τον προσδιορισμό της ακρίβειας πρόβλεψης του μοντέλου. Από την άλλη πλευρά, τα δεδομένα εκπαίδευσης αποσκοπούν στο να μαθαίνει το μοντέλο από τα παρεχόμενα δεδομένα με χαμηλή απόκλιση και χαμηλό σφάλμα εκπαίδευσης, αλλά δύναται να γενικεύει νέα δεδομένα με χαμηλή διακύμανση και χαμηλό σφάλμα κατά τη φάση αξιολόγησής του, με άλλα λόγια να αποφεύγονται φαινόμενα overfitting και underfitting. Αυτό είναι γνωστό ως η διχοτόμηση απόκλισης και διακύμανσης (bias and variance dichotomy) Reitermanova et al., 2010; Belkin et al., 2019).

7.4 Δημιουργία Ασαφούς Συστήματος Συμπερασμού (FIS)

Αφού ολοκληρώθηκε η προεπεξεργασία των δεδομένων άρχισε η δόμηση του Προσαρμοστικού Νεύρο-Ασαφούς Συστήματος Συμπερασμού (Neuro-Fuzzy Inference System - ANFIS).

Πρώτο βήμα αποτέλεσε η κατασκευή του Ασαφούς Συστήματος Συμπερασμού (Fuzzy Inference System – FIS), το οποίο χρησιμοποιείται με σκοπό την παροχή αρχικών συνθηκών για την μεταγενέστερη εκπαίδευση του μοντέλου ANFIS. Το σύστημα FIS στην προκειμένη περίπτωση, αποτελείται από δύο εισόδους και μία έξοδο.

Η δημιουργία του συστήματος αυτού περιλάμβανε μεταξύ άλλων τον καθορισμό των εισόδων και εξόδων, του αριθμού και του τύπου των συναρτήσεων συμμετοχής, καθώς και την επιλογή της μεθόδου ομαδοποίησης (Clustering Method).

Η συνάρτηση της Matlab που χρησιμοποιήθηκε για την δημιουργία του FIS, είναι η `genfis`. Υπάρχουν διάφοροι τρόποι χρήσης αυτής της συνάρτησης/λειτουργίας. Στην εργασία αυτή υλοποιήθηκε η ακόλουθη δομή:

```
In_fismat = genfis(inputData, outputData, opt)
```

κατά την οποία δημιουργούνται οι αρχικές συναρτήσεις συμμετοχής και οι κανόνες του συστήματος, χρησιμοποιώντας τα δεδομένα εισόδου `inputData` και εξόδου `outputData`, καθώς και τις ρυθμίσεις που καθορίζονται από το αντικείμενο `opt`.

Το αποτέλεσμα της συνάρτησης είναι το αρχικό ασαφές σύστημα `in_fismat`, το οποίο περιλαμβάνει τις καθορισμένες συναρτήσεις συμμετοχής και κανόνες.

7.4.1 Καθορισμός εισόδων - εξόδων

7.4.1.1 Δημιουργία χρονικών υστερήσεων

Πρώτο βήμα αποτέλεσε ο καθορισμός των εισόδων και των εξόδων, που όπως προαναφέρθηκε επιλέχθηκαν να είναι δύο και μία αντίστοιχα. Η λογική πίσω από την επιλογή αυτή έγκειται στο γεγονός ότι, για να προβλεφθεί η τιμή της ενέργειας που παράγεται τη χρονική στιγμή (k), θα χρησιμοποιηθούν από το εξεταζόμενο μοντέλο ANFIS ως είσοδοι οι τιμές της παραγόμενης ενέργειας τις χρονικές στιγμές ($k-1$) και ($k-2$).

Έτσι, έγινε κατάλληλη επεξεργασία των δεδομένων εκπαίδευσης και συγκεκριμένα ο διαχωρισμός τους σε τρεις χρονικές υστερήσεις (time-lags): $(k-2)$, $(k-1)$ και (k) .

Έπειτα, τα διαχωρισμένα σε χρονικές υστερήσεις δεδομένα εκπαίδευσης διαμοιράστηκαν σε δεδομένα εισόδου και εξόδου, με σκοπό να εισαχθούν στο Ασαφές Σύστημα Συμπερασμού.

Από τη μία πλευρά, τα δεδομένα εισόδου περιλάμβαναν τις τιμές ωριαίας παραγωγής ενέργειας τις χρονικές στιγμές $(k-2)$ και $(k-1)$ και συνιστούσαν έναν πίνακα με δύο στήλες, μία για κάθε είσοδο του FIS. Η πρώτη στήλη περιλάμβανε τις τιμές της παραγόμενης ωριαίας ενέργειας τη χρονική στιγμή $(k-2)$ και η δεύτερη στήλη περιείχε τις τιμές τη χρονική στιγμή $(k-1)$. Από την άλλη πλευρά, τα δεδομένα εξόδου εμπεριείχαν τις τιμές παραγόμενης ενέργειας, αποτελώντας έναν πίνακα με μία μόνο στήλη, που αντιπροσώπευε την παραγωγή τη χρονική στιγμή (k) .

7.4.1.2 Καθορισμός των Συναρτήσεων Συμμετοχής (Membership Functions – MFs)

Παράλληλα, επιλέχθηκε ο αριθμός και ο τύπος των συναρτήσεων συμμετοχής για κάθε μία από τις συνολικά δύο εισόδους του συστήματος.

Οι δύο αυτές παράμετροι, αν και έχουν προκαθορισμένες επιλογές από την Matlab, μπορούν και πρέπει να καθοριστούν από τον εκάστοτε ερευνητή, ανάλογα με τα δεδομένα εισόδου και τις ανάγκες του συστήματος.

Στην προκειμένη περίπτωση, οι συναρτήσεις συμμετοχής και στις δύο εισόδους καθορίστηκαν ως γενικές καμπανοειδείς συναρτήσεις τύπου Bell (generalized bell-shaped membership function). Ο λόγος που επιλέχθηκε ο συγκεκριμένος τύπος συνάρτησης συμμετοχής έγκειται μεταξύ άλλων στην ευελιξία του να προσαρμόζεται σε διάφορα σχήματα δεδομένων και την ικανότητά του – λόγω της ομαλότητάς του - να αποφεύγει αιχμές (spikes) και απότομες αλλαγές, κάτι που είναι αναμφίβολα κρίσιμο όσον αφορά την πρόβλεψη ωριαίων δεδομένων παραγωγής ενέργειας από Φ/Β.

Ταυτόχρονα, ο αριθμός των συναρτήσεων αυτών ορίστηκε με τη βοήθεια και της μεθοδολογίας «δοκιμής και λάθους» («trial and error») σε τέσσερις, ώστε να επιτυγχάνεται ισορροπία μεταξύ της απλότητας του μοντέλου και της ακρίβειας στην ανάλυση των εισόδων. Έτσι, οι τέσσερις συναρτήσεις συμμετοχής κρίνονται αρκετές για να διακρίνουν και να προβλέψουν με ακρίβεια τις διάφορες μεταβολές στην παραγωγή ηλιακής ενέργειας, διατηρώντας παράλληλα το μοντέλο υπολογιστικά αποδοτικό.

7.4.2 Καθορισμός μεθόδου ομαδοποίησης

Για την ομαδοποίηση των δεδομένων εισόδου, επιλέχθηκε η μέθοδος διαχωρισμού πλέγματος (Grid Partitioning), λόγω της απλότητας, της υπολογιστικής αποδοτικότητας και της ευκολίας της. Αυτή η μέθοδος περιλαμβάνει τη κατάτμηση του εύρους των δεδομένων εισόδου σε μικρότερα, ομοιόμορφα υποσύνολα, τα δεδομένα πλέγματος (grid data), με βάση τον τύπο της συνάρτησης συμμετοχής (MFS) σε κάθε διάσταση (Muhammad Ibrahim et al., 2024). Κατά την έναρξη της εκπαίδευσής του, το ANFIS με χρήση διαχωρισμού πλέγματος ξεκινά με μηδενική έξοδο και σταδιακά μαθαίνει διακριτούς κανόνες και συναρτήσεις ασαφούς συνόλου μέσω της διαδικασίας εκπαίδευσης (Wang L et al., 2017).

Για τον προσδιορισμό των αρχικών ασαφών συνόλων και παραμέτρων, χρησιμοποιείται η μέθοδος των ελαχίστων τετραγώνων, λαμβάνοντας υπόψη τις κατατμήσεις και τους τύπους MF (Yaseen et al., 2018). Έτσι, με την δυνατότητα που παρέχει αυτή η μέθοδος ομαδοποίησης για αποτελεσματική προσαρμογή των συναρτήσεων συμμετοχής στα δεδομένα, παρέχονται αξιόπιστα και ακριβή αποτελέσματα.

7.4.3 Δημιουργία Κανόνων Βάσης

Παράλληλα, δημιουργήθηκαν και οι κανόνες βάσης του FIS. Οι κανόνες αυτοί, μορφής "If-Then", δημιουργήθηκαν και διαμορφώθηκαν βάσει των δύο εισόδων (ιστορικές τιμές παραγωγής ηλεκτρικής ενέργειας από ηλιακή ενέργεια στις χρονικές στιγμές (k-

2) και $(k-1)$) και της μίας εξόδου (η προβλεπόμενη τιμή παραγωγής ενέργειας τη χρονική στιγμή k) του συστήματος.

Οι κανόνες αυτοί καθορίζουν τη σχέση μεταξύ των τιμών των εισόδων και της προβλεπόμενης εξόδου, επιτρέποντας στο σύστημα να κατανοήσει και να αναπαραγάγει τις περίπλοκες σχέσεις που υπάρχουν στα δεδομένα παραγωγής ενέργειας.

Η μέθοδος εξαγωγής του κανόνα καθορίζει πρώτα τον αριθμό των κανόνων και των προγενέστερων συναρτήσεων συμμετοχής και κατόπιν κάνει χρήση της μεθόδου ελαχίστων τετραγώνων για να καθορίσει τις εξισώσεις που προκύπτουν για κάθε κανόνα. Κάθε κανόνας που προκύπτει, συνιστά μία συνάρτηση συμμετοχής ως έξοδος/αποτέλεσμα, η οποία έξοδος είναι από προεπιλογή γραμμικού τύπου ("linear type output"). Μέσα από την παρατήρηση των κανόνων αυτών, ο χρήστης μπορεί να κατανοήσει πλήρως τη διαδικασία με την οποία το μοντέλο λαμβάνει τις αποφάσεις.

7.5 Δημιουργία και εκπαίδευση του ANFIS

Κατόπιν, κατασκευάστηκε και τέθηκε προς εκπαίδευση το σύστημα ANFIS με χρήση του υβριδικού αλγορίθμου εκμάθησης (hybrid algorithm), με στόχο να πραγματοποιεί προβλέψεις τιμών τύπου ενός βήματος μπροστά (one-step-ahead forecasting).

Το μοντέλο ANFIS εκπαιδεύτηκε για καθορισμένο αριθμό εποχών (epochs) και αρχικό βήμα εκπαίδευσης (Initial Step Size), χρησιμοποιώντας παράλληλα τις παραμέτρους που ορίστηκαν στο προηγούμενο στάδιο, καθώς και τις προεπιλεγμένες ρυθμίσεις της συνάρτησης ANFIS.

Οι παράμετροι που εξετάστηκαν συνολικά για την τελική δημιουργία και εκπαίδευση του ANFIS μοντέλου είναι οι εξής:

- Μέθοδος ομαδοποίησης
- Αριθμός συναρτήσεων συμμετοχής (Membership Functions - MFs) για κάθε μία από τις δύο εισόδους
- Τύπος συνάρτησης συμμετοχής για κάθε μία από τις δύο εισόδους
- Τύπος Συνάρτησης Συμμετοχής εξόδου

- Εποχές εκπαίδευσης (training epochs)
- Αρχική τιμή μεγέθους βήματος (Initial step size)
- Στόχος σφάλματος εκπαίδευσης
- Ρυθμός μείωσης μεγέθους βήματος
- Ρυθμός αύξησης μεγέθους βήματος
- Μέθοδος βελτιστοποίησης

Η συνάρτηση της Matlab που χρησιμοποιήθηκε για την εκπαίδευση του ANFIS, είναι η **anfis**. Υπάρχουν ποικίλοι τρόποι χρήσης αυτής της συνάρτησης/λειτουργίας. Στην παρούσα εργασία χρησιμοποιήθηκε η ακόλουθη δομή:

```
[m_anfis, trn_error, step_size] = anfis(trn_data, anfis_opt);
```

Κατά την οποία το μοντέλο ANFIS εκπαιδεύεται με δεδομένα εκπαίδευσης *trn_data* και με τις επιλογές εκπαίδευσης που καθορίζονται από το αντικείμενο *anfis_opt*. Τα δεδομένα αποτελούν ουσιαστικά έναν πίνακα με N+1 στήλες, όπου οι N πρώτες στήλες περιέχουν δεδομένα για κάθε εισερχόμενη παράμετρο στο Προσαρμοστικό Νευρο-Ασαφές Σύστημα Συμπερασμού, ενώ η τελευταία στήλη περιέχει τα δεδομένα εξόδου.

Η έξοδος της συνάρτησης περιλαμβάνει το εκπαιδευμένο μοντέλο *m_anfis*, το σφάλμα εκπαίδευσης σε κάθε εποχή *trn_error*, και το μέγεθος βήματος κατά τη διάρκεια της εκπαίδευσης *step_size*.

7.5.1 Εξαγωγή και Απεικόνιση των πληροφοριών του τελικού ANFIS

Για την περαιτέρω πληροφόρηση του χρήστη, έγινε εξαγωγή και απεικόνιση των πληροφοριών του τελικού ANFIS συστήματος με τη χρήση των συναρτήσεων 'showfis' 'getfis':

- Με τη χρήση της συνάρτησης ‘*showfis*’, δίνεται η δυνατότητα οπτικής απεικόνισης της συνολικής δομής του εκπαιδευμένου FIS. Ουσιαστικά, παρουσιάζεται η συνολική αρχιτεκτονική του συστήματος, συμπεριλαμβανομένων των εισόδων, των εξόδων, των κανόνων, καθώς και άλλων παραμέτρων του συστήματος που έχουν δημιουργηθεί.
- Με τη βοήθεια της συνάρτησης ‘*getfis*’, δίνεται η δυνατότητα εξαγωγής των παραμέτρων και των διαθέσιμων πληροφοριών για το ασαφές σύστημα σε μορφή δομής. Αυτή η δομή περιλαμβάνει λεπτομερείς πληροφορίες για το όνομα, τον τύπο, τις συναρτήσεις συμμετοχής, τους κανόνες και τις παραμέτρους του συστήματος, επιτρέποντας την περαιτέρω ανάλυση και επεξεργασία τους.

Η διαφορά μεταξύ των δύο συναρτήσεων είναι ότι η *showfis* παρέχει μια οπτική αναπαράσταση του FIS, ενώ η *getfis* επιστρέφει μια λεπτομερή δομή δεδομένων με όλες τις παραμέτρους του συστήματος. Ωστόσο, και οι δύο συναρτήσεις είναι ιδιαίτερα χρήσιμες για την αξιολόγηση και κατανόηση του μοντέλου και πώς αυτό επεξεργάζεται τις εισόδους και λαμβάνει αποφάσεις μετά την εκπαίδευσή του.

7.5.2 Προβλέψεις με δεδομένα εκπαίδευσης και αξιολόγησης

Μετά την εκπαίδευση του συστήματος ANFIS, πραγματοποιήθηκαν οι προβλέψεις του μοντέλου, η απόδοση του οποίου αξιολογήθηκε με βάση τα δεδομένα εκπαίδευσης (in-sample / training data) και τα δεδομένα δοκιμής (out-of-sample / evaluation data).

Εφαρμόζοντας αντίστοιχη συλλογιστική με αυτή της παραγράφου 7.4.1.1 που έγκειται στο ότι, για την πρόβλεψη της τιμής της παραγόμενης ενέργειας τη χρονική στιγμή (k), θα χρησιμοποιηθούν από το εξεταζόμενο μοντέλο ANFIS ως είσοδοι οι μετρήσεις της παραγόμενης ενέργειας τις χρονικές στιγμές ($k-1$) και ($k-2$), έγινε κατάλληλη επεξεργασία των δεδομένων αξιολόγησης και συγκεκριμένα ο διαχωρισμός τους σε τρεις χρονικές υστερήσεις (time-lags): ($k-2$), ($k-1$) και (k).

Η συνάρτηση της Matlab “*evalfis*” χρησιμοποιήθηκε για την αξιολόγηση του FIS συστήματος.

Η συνάρτηση που χρησιμοποιήθηκε για την αξιολόγηση του ANFIS, είναι η **evalfis**, υλοποιώντας την ακόλουθη δομή:

```
yhat_anfis = evalfis(m_anfis, input);
```

κατά την οποία εφαρμόζεται το εκπαιδευμένο μοντέλο *m_anfis* στα δεδομένα εισόδου *input* και παράγει τις προβλέψεις *yhat_anfis*. Το αποτέλεσμα της συνάρτησης είναι οι προβλεπόμενες τιμές *yhat_anfis*, οι οποίες μπορούν να συγκριθούν με τις πραγματικές τιμές για να αξιολογηθεί η ακρίβεια του μοντέλου.

Παράλληλα, μέσα από την αξιολόγηση των αποτελεσμάτων των προβλέψεων του ANFIS κατά την φάση εκπαίδευσης αλλά και αυτή της δοκιμής, εξετάζοταν και διασφαλιζόταν ότι το μοντέλο δεν παρουσιάζει φαινόμενα υπερ- ή υποεκπαίδευσης.

Από τη μία πλευρά, υπερεκπαίδευση (*overtraining*) γενικά παρουσιάζεται όταν υπάρχει ανεπαρκής γενίκευση από τα δεδομένα. Εάν το μοντέλο υπερεκπαιδευτεί, απομνημονεύει μόνο τη συμπεριφορά των δεδομένων εκπαίδευσης και δεν μπορεί να δώσει σωστά αποτελέσματα στην έξοδο. Η διαφορά μεταξύ των σφαλμάτων εκπαίδευσης και αξιολόγησης είναι πολύ υψηλή.

Στον αντίποδα, μπορεί το σύστημα να παρουσιάσει υποεκπαίδευση (*undertraining*). Σε αυτή την περίπτωση, το μοντέλο δεν μπορεί να λάβει αποδεκτά χαμηλή τιμή σφάλματος στη φάση εκπαίδευσης. Επομένως, το μοντέλο δεν μπορεί να μάθει αρκετά καλά κατά την εκπαίδευσή του, γεγονός που θα οδηγήσει σε χαμηλά επίπεδα ακρίβειας όσον αφορά την πρόβλεψη (Zhang et al., 2019).

7.6 Αξιολόγηση της απόδοσης του Μοντέλου Πρόβλεψης

Για την αξιολόγηση των προβλέψεων του ANFIS, χρησιμοποιήθηκαν τέσσερις ευρέως αναγνωρισμένες μαθηματικές μετρήσεις σφάλματος (Error Metrics) (Jensen et al., 2016):

το μέσο τετραγωνικό σφάλμα (Mean Squared Error – MSE),

η ρίζα του μέσου τετραγωνικού σφάλματος (Root Mean Squared Error – RMSE),

το μέσο απόλυτο σφάλμα (Mean Absolute Error – MAE) και

ο συντελεστής προσδιορισμού (Coefficient of Determination – DC or R-squared - R²).

7.6.1 Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error - MSE)

Το Μέσο Τετραγωνικό Σφάλμα (MSE), αξιολογεί το μέσο όρο των τετραγώνων των διαφορών (σφαλμάτων) μεταξύ των προβλεπόμενων και των πραγματικών τιμών. Είναι μια βασική μέτρηση που δείχνει πόσο κοντά βρίσκονται οι προβλέψεις στις πραγματικές τιμές. Χαμηλότερες τιμές MSE υποδεικνύουν καλύτερη απόδοση του μοντέλου.

$$MSE = \frac{1}{N} \cdot \sum_{t=1}^N (y_t - \hat{y}_t)^2$$

Όπου y_t είναι η πραγματική τιμή, \hat{y}_t είναι η προβλεπόμενη τιμή και N είναι το πλήθος των σημείων πρόβλεψης.

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

Η Ρίζα Μέσου Τετραγωνικού Σφάλματος (RMSE) συνιστά μία ευρέως χρησιμοποιούμενη μετρική σφάλματος για την αξιολόγηση της ακρίβειας ενός στατιστικού μοντέλου ή αλγορίθμου πρόβλεψης. Η μετρική αυτή ποσοτικοποιεί τη διαφορά μεταξύ των αναμενόμενων και των παρατηρούμενων τιμών σε ένα σύνολο δεδομένων (Lawan SM et al., 2014). Για τον υπολογισμό του RMSE, λαμβάνεται η τετραγωνική ρίζα του μέσου όρου των τετραγωνικών διαφορών (σφαλμάτων) μεταξύ των προβλεπόμενων και των πραγματικών τιμών, δίνοντας έτσι μια αίσθηση του μέσου μεγέθους των σφαλμάτων σε σχέση με τα δεδομένα. Ερμηνεύεται πιο εύκολα από το MSE καθώς είναι στην ίδια μονάδα μέτρησης με τα δεδομένα.

$$RMSE = \sqrt{\frac{1}{N} \cdot \sum_{t=1}^N (y_t - \hat{y}_t)^2}$$

όπου y_t είναι η πραγματική τιμή, \hat{y}_t είναι η προβλεπόμενη τιμή και N είναι το πλήθος των σημείων πρόβλεψης.

7.6.3 Μέσο Απόλυτο Σφάλμα (Mean Absolute Error - MAE)

Το Μέσο Απόλυτο Σφάλμα (MAE) μετρά τη μέση απόκλιση μεταξύ των προβλεπόμενων και των πραγματικών τιμών σε ένα σύνολο δεδομένων, χωρίς να λαμβάνει υπόψη την κατεύθυνση των σφαλμάτων, δηλαδή αν αυτά είναι θετικά ή αρνητικά. Υπολογίζεται με την εύρεση του μέσου όρου των απόλυτων διαφορών μεταξύ των προβλεπόμενων και των πραγματικών τιμών [Dalianis H. Et al., 2018). Σε αντίθεση με το MSE, το MAE δεν μεγιστοποιεί τα μεγαλύτερα σφάλματα, και γι' αυτό είναι πιο ανθεκτικό στις ακραίες τιμές.

$$MAE = \frac{1}{N} \cdot \sum_{t=1}^N |y_t - \hat{y}_t|$$

όπου y_t είναι η πραγματική τιμή, \hat{y}_t είναι η προβλεπόμενη τιμή και N είναι το πλήθος των σημείων πρόβλεψης.

7.6.4 Συντελεστής Προσδιορισμού (Coefficient of Determination – DC / R-squared - R^2)

Το R^2 είναι ένας στατιστικός δείκτης που αξιολογεί πόσο αποτελεσματικά προσαρμόζεται ένα μοντέλο παλινδρόμησης στα σημεία δεδομένων (Teke A. et al., 2015). Είναι μια τιμή που κυμαίνεται από 0 έως 1 και αντιπροσωπεύει το ποσοστό της διακύμανσης στην εξαρτημένη μεταβλητή που είναι δυνατό να προβλεφθεί από την/τις ανεξάρτητη/ες μεταβλητή/ές. Μια τιμή R^2 ίση με 1 υποδηλώνει τέλεια προσαρμογή των προβλέψεων παλινδρόμησης, ενώ μια τιμή DC ίση με 0 υποδεικνύει ότι το μοντέλο δεν αντιπροσωπεύει καμία από τις διακυμάνσεις της εξαρτημένης μεταβλητής. Τιμές κοντά στο 1 υποδηλώνουν καλύτερη προσαρμογή του μοντέλου στα δεδομένα.

$$DC = R^2 = 1 - \frac{\sum_{t=1}^N (y_t - \hat{y}_t)^2}{\sum_{t=1}^N (y_t - \bar{y})^2}$$

όπου y_t είναι η πραγματική τιμή, \hat{y}_t είναι η προβλεπόμενη τιμή, N είναι το πλήθος των σημείων πρόβλεψης και \bar{y} είναι ο μέσος όρος (μ.ό.) των πραγματικών τιμών, με τύπο $\sum_{t=1}^N y_t$

Επιπλέον, για την καλύτερη κατανόηση των παραπάνω μετρικών σφάλματος, πραγματοποιήθηκε κανονικοποίηση των μετρικών αυτών σε σχέση με την τυπική απόκλιση των δεδομένων πραγματικής ενέργειας. Η κανονικοποιημένη με την τυπική απόκλιση εκδοχή των μετρικών σφάλματος χρησιμοποιήθηκε με στόχο να παρέχει μια πιο ακριβή και ρεαλιστική εικόνα της απόδοσης του μοντέλου, διότι λαμβάνει υπόψη τις διακυμάνσεις των δεδομένων.

Συμπερασματικά, οι παραπάνω μετρικές παρέχουν μια συνολική εικόνα της απόδοσης του μοντέλου, επιτρέποντας έτσι την ακριβή αξιολόγηση της ακρίβειας και της αξιοπιστίας των προβλέψεων του ANFIS.

7.7 Σύγκριση με άλλα Μοντέλα Πρόβλεψης

Για την περαιτέρω αξιολόγηση του μοντέλου ANFIS πραγματοποιήθηκε σύγκριση με άλλα τρία καθιερωμένα μοντέλα πρόβλεψης, ένα μοντέλο αυτοπαλινδρόμησης (AutoRegressive model - AR model), ένα μοντέλο αυτοπαλινδρόμησης κινούμενου μέσου (AutoRegressive Moving Average model - ARMA model) και ένα Νευρωνικό Δίκτυο - ΤΝΔ (Artificial Neural Network, ANN), τα οποία κωδικοποιήθηκαν επίσης σε γλώσσα προγραμματισμού MATLAB.

7.7.1 Μοντέλο Αυτοπαλινδρόμησης - Autoregressive (AR) Model

Το μοντέλο αυτοπαλινδρόμησης (AR) χρησιμοποιείται για την πρόβλεψη μιας χρονικής σειράς βασιζόμενο στις προηγούμενες τιμές της. Η γενική μορφή του μοντέλου AR(p) είναι:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

όπου Y_t είναι η τιμή της σειράς στο χρόνο t , ϕ_i είναι οι παράμετροι του μοντέλου, p είναι η τάξη του μοντέλου (ή με άλλα λόγια το πλήθος των προηγούμενων τιμών που χρησιμοποιούνται) και ε_t είναι το σφάλμα (λευκός θόρυβος).

7.7.2 Μοντέλο Αυτοπαλινδρόμησης Κινούμενου Μέσου - Autoregressive Moving Average (ARMA) Model

Το μοντέλο αυτοπαλινδρόμησης κινούμενου μέσου (ARMA) συνδυάζει τα μοντέλα AR και MA για την πρόβλεψη στάσιμων χρονικών σειρών.

Το AR μέρος χρησιμοποιεί προηγούμενες τιμές της σειράς, όπως φαίνεται στο AR μοντέλο:

$$Y_t = \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + \varepsilon_t$$

Το MA μέρος χρησιμοποιεί προηγούμενα σφάλματα για να εξομαλύνει τη σειρά:

$$Y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

όπου q είναι η τάξη του μοντέλου MA (ο αριθμός των προηγούμενων σφαλμάτων που χρησιμοποιούνται).

Συνδυάζοντας αυτά τα δύο, το ARMA(p, q) μοντέλο έχει τη μορφή:

$$Y_t = \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

όπου Φ_i και θ_i είναι οι παράμετροι του μοντέλου, ε_t είναι το σφάλμα, p είναι η τάξη του μοντέλου αυτοπαλινδρόμησης και q είναι η τάξη του κινητού μέσου.

7.7.3 Τεχνητό Νευρωνικό Δίκτυο - Artificial Neural Networks (ANN)

Τα τεχνητά νευρωνικά δίκτυα (ANN), όπως αναλύθηκε εκτενώς και στο κεφάλαιο 4, είναι μοντέλα εμπνευσμένα από τη βιολογία που χρησιμοποιούνται για την πρόβλεψη και την ταξινόμηση. Αποτελούνται από στρώματα νευρώνων που συνδέονται μεταξύ τους. Η λειτουργία ενός απλού νευρώνα μπορεί να περιγραφεί ως:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right)$$

όπου x_i είναι οι εισόδους, w_i είναι τα βάρη, b είναι η προκατάληψη και f είναι η συνάρτηση ενεργοποίησης.

7.7.4 Ασαφές Σύστημα Συμπερασμού Τύπου-2 με Βελτιστοποίηση Σμήνους Σωματιδίων - Type-2 Fuzzy Inference System (Type-2 FIS) with Particle Swarm Optimization (PSO)

Τα Ασαφή Συστήματα Συμπερασμού Τύπου-2 (Type-2 FIS) είναι συστήματα ασαφούς λογικής που χειρίζονται την αβεβαιότητα και την ασάφεια καλύτερα από τα Type-1 FIS. Η γενική μορφή ενός Type-2 FIS είναι:

$$y = \sum_{i=1}^M \frac{w_i \cdot f_i(x)}{\sum_{j=1}^M w_j}$$

όπου w_i είναι τα βάρη των κανόνων και $f_i(x)$ είναι οι συναρτήσεις των κανόνων.

Το Particle Swarm Optimization (PSO) είναι μια μέθοδος βελτιστοποίησης εμπνευσμένη από τη συμπεριφορά των σμήνων και των κοπαδιών. Χρησιμοποιείται για την εύρεση του βέλτιστου συνόλου παραμέτρων. Το PSO λειτουργεί ως εξής:

1. **Αρχικοποίηση:** Δημιουργία πληθυσμού (σωματίδια) με τυχαίες θέσεις και ταχύτητες.
2. **Αξιολόγηση:** Υπολογισμός της συνάρτησης καταλληλότητας (fitness) για κάθε σωματίδιο.
3. **Ενημέρωση:** Προσαρμογή των θέσεων και ταχυτήτων των σωματιδίων με βάση την καλύτερη ατομική και συνολική θέση.
4. **Επανάληψη:** Η διαδικασία επαναλαμβάνεται μέχρι να επιτευχθεί σύγκλιση σε μια βέλτιστη λύση.

Κεφάλαιο 8: Αποτελέσματα από τη χρήση του μοντέλου ANFIS

8.1 Εισαγωγή

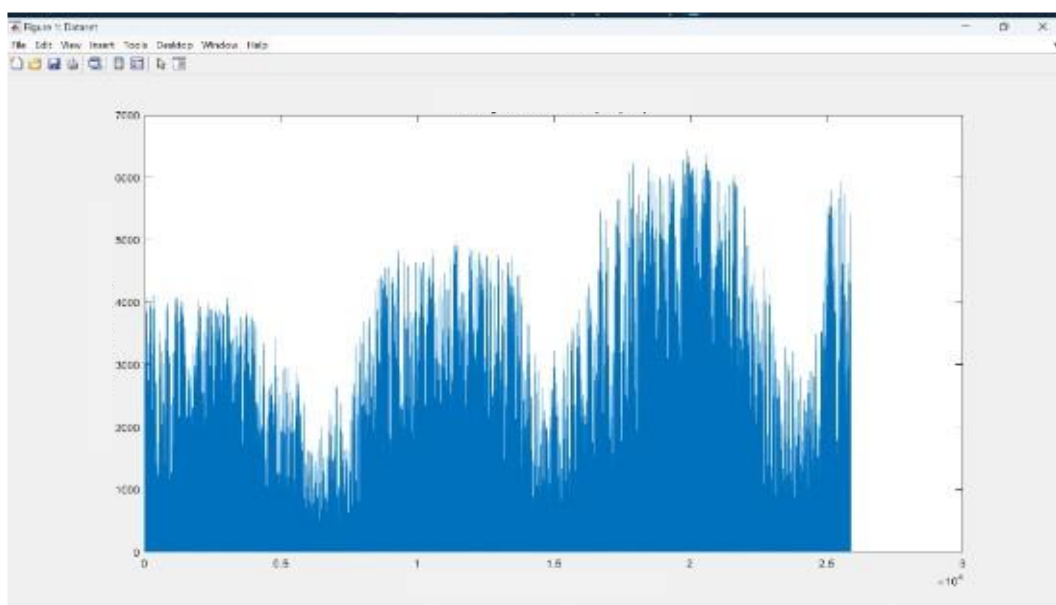
Στο κεφάλαιο αυτό της διπλωματικής παρουσιάζονται και επεξηγούνται τα αποτελέσματα που προέκυψαν από την υλοποίηση της μεθοδολογίας για την εφαρμογή του μοντέλου ANFIS που αναλύθηκε στο προηγούμενο κεφάλαιο.

Αρχικά, θα αναλυθούν τα δεδομένα και η προεπεξεργασία τους, στη συνέχεια θα παρουσιαστούν τα αποτελέσματα της εκπαίδευσης και της αξιολόγησης του μοντέλου, και τέλος θα γίνει σύγκριση με άλλα μοντέλα πρόβλεψης.

8.2 Προεπεξεργασία των Δεδομένων

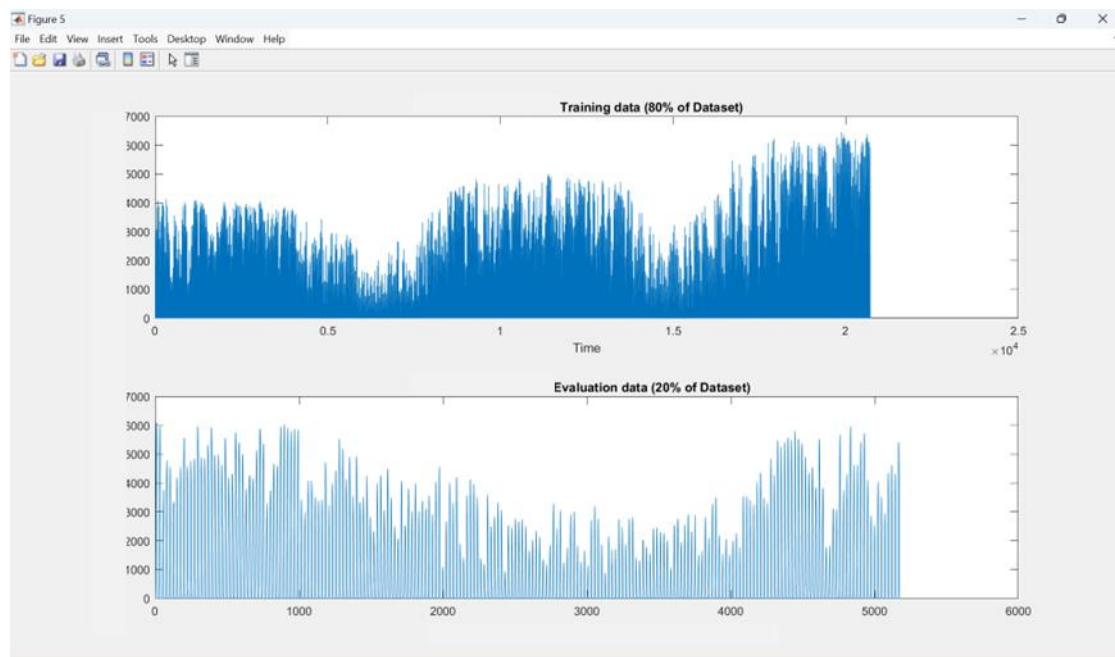
Η προεπεξεργασία των εισαχθέντων δεδομένων ήταν – όπως αναλύθηκε και παραπάνω - απαραίτητη για την ορθή λειτουργία του μοντέλου ANFIS.

Αρχικά, τα δεδομένα ελέγχθηκαν για ακραίες τιμές και τιμές NaN (Not a Number), και διαχειρίστηκαν κατάλληλα ώστε να διατηρηθεί η συνοχή τους. Η τελική χρονοσειρά που δημιουργήθηκε, αποτελούνταν από 25896 γραμμές μετρήσεων παραγωγής ενέργειας σε ωριαία βάση, και η διακύμανση των τιμών της χρονοσειράς αυτής παρουσιάζεται παρακάτω:



Εικόνα 35: Το Dataset - Διακύμανση παραγόμενης ενέργειας (σε MWh)

Στη συνέχεια ακολούθησε ο κατάλληλος διαμοιρασμός σε δεδομένα εκπαίδευσης (training data) του μοντέλου αξιολόγησης (evaluation data) της αξιοπιστίας του. Από τις συνολικά 25896 τιμές, το 80% χρησιμοποιήθηκε για την εκπαίδευση του μοντέλου, ενώ το εναπομείναν 20% των τιμών αξιοποιήθηκε για να διαπιστωθεί η αξιοπιστία των προβλέψεων του εξεταζόμενου συστήματος.

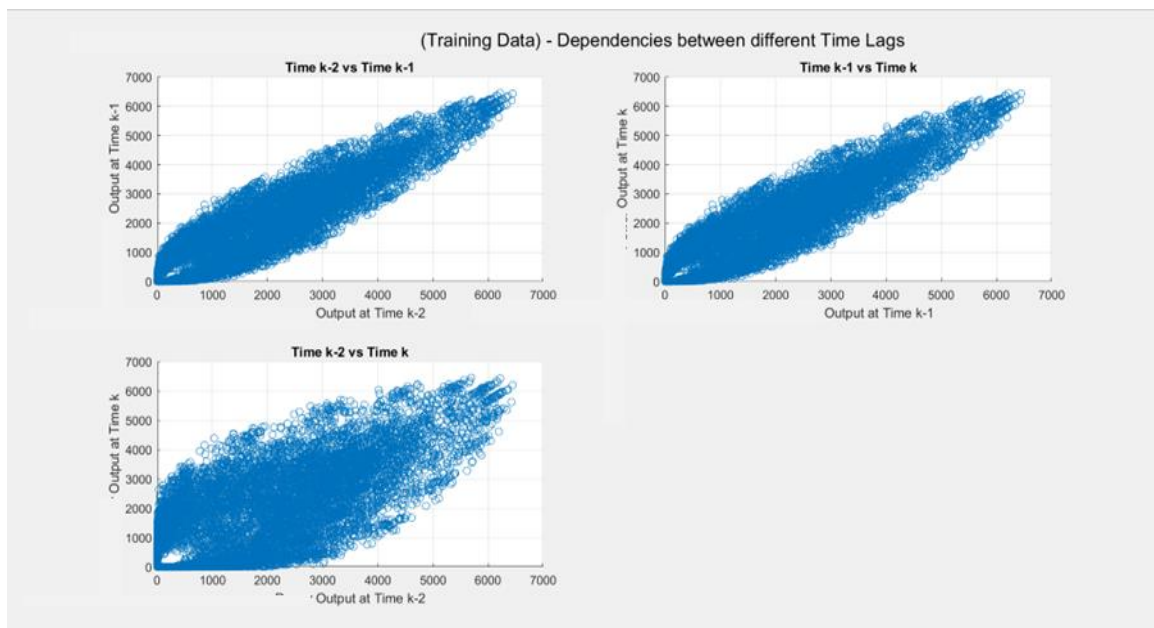


Εικόνα 36: Δεδομένα εκπαίδευσης - αξιολόγησης (Training - Evaluation Data)


8.3 Δημιουργία και εκπαίδευση του ANFIS

Η δημιουργία και εκπαίδευση του μοντέλου ANFIS πραγματοποιήθηκε χρησιμοποιώντας τα δεδομένα εκπαίδευσης που είχαν προεπεξεργαστεί και διαμοιραστεί σε τρεις χρονικές υστερήσεις: $(k-2)$, $(k-1)$, και (k) .

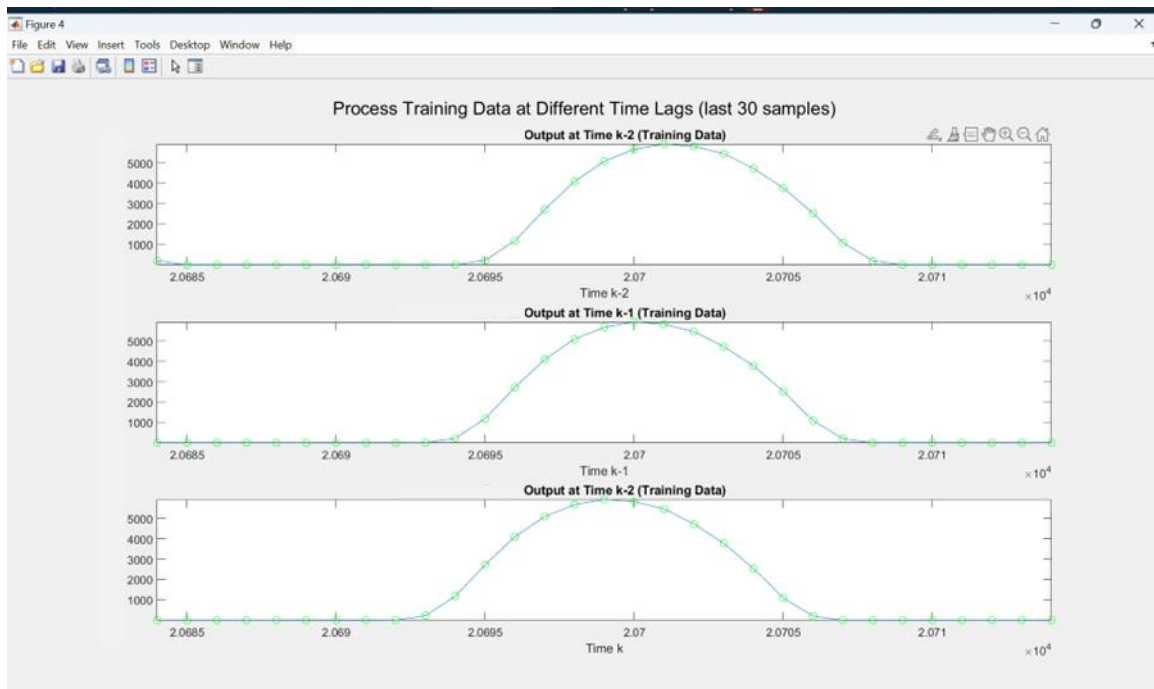
Τα γραφήματα διασποράς (scatterplots) των δεδομένων εκπαίδευσης σε δισδιάστατη και τρισδιάστατη μορφή, αλλά και ως διασπορά ανά χρονική υστέρηση, αποσκοπούν στην καλύτερη κατανόηση των σχέσεων των τιμών παραγόμενης ενέργειας μεταξύ των διαφορετικών χρονικών υστερήσεων και παρουσιάζονται παρακάτω:



Εικόνα 37: Δεδομένα εκπαίδευσης σε γραφικές παραστάσεις διασποράς 2-Δ



Εικόνα 38: Δεδομένα εκπαίδευσης σε γραφική παράσταση διασποράς 3-Δ



Εικόνα 39: Δεδομένα εκπαίδευσης ως διασπορά, ταξινομημένα ανά χρονική υστέρηση

Οι παράμετροι που επιλέχθηκαν συνολικά για την τελική δημιουργία και εκπαίδευση του ANFIS μοντέλου είναι οι εξής:

- Μέθοδος ομαδοποίησης: **Διαχωρισμός Πλέγματος (Grid Partitioning)**
- Αριθμός συναρτήσεων συμμετοχής (Membership Functions - MFs) για κάθε μία από τις δύο εισόδους : **4**
- Τύπος συνάρτησης συμμετοχής για κάθε μία από τις δύο εισόδους: **τύπου γενικευμένης καμπανοειδούς (Generalized bell-shaped membership function – ‘gbellmf’)**
- Τύπος Συνάρτησης Συμμετοχής εξόδου: **Γραμμική (linear)**
- Εποχές εκπαίδευσης (training epochs): **400**
- Αρχική τιμή μεγέθους βήματος (Initial step size): **0.8**
- Στόχος για **μηδενικό** σφάλμα εκπαίδευσης
- Ρυθμός μείωσης μεγέθους βήματος: **0.9**

- Ρυθμός αύξησης μεγέθους βήματος: 1.1
- Μέθοδος βελτιστοποίησης: **Υβριδικός αλγόριθμος εκμάθησης (hybrid algorithm)**

Οι πληροφορίες σχετικά με το σύστημα ANFIS κατά την εκκίνηση της εκπαίδευσής του φαίνονται παρακάτω:

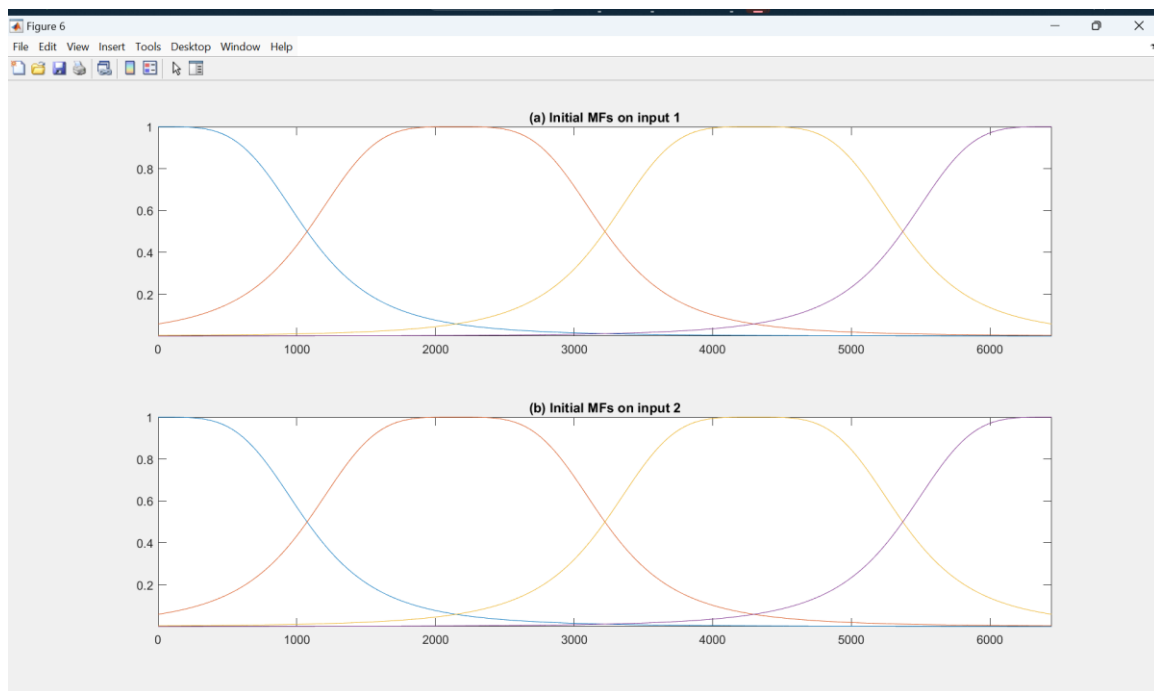
```
ANFIS info:
Number of nodes: 53
Number of linear parameters: 48
Number of nonlinear parameters: 24
Total number of parameters: 72
Number of training data pairs: 20714
Number of checking data pairs: 0
Number of fuzzy rules: 16
```

Εικόνα 40: Πληροφορίες ANFIS κατά την εκκίνηση της εκπαίδευσής του


Στη συνέχεια παρουσιάζονται οι αρχικές και οι τελικές συναρτήσεις συμμετοχής του Ασαφούς Συστήματος Συμπερασμού για κάθε είσοδο, καθώς και το ίδιο το FIS πριν και μετά την μετατροπή του σε ANFIS.

Οι αρχικές συναρτήσεις συμμετοχής σε κάθε είσοδο έχουν προκαθορισμένες τιμές και σχηματίζουν συμμετρικές καμπύλες, βασισμένες σε αρχικές υποθέσεις, και μέσω του Grid Partitioning το εύρος των δεδομένων είναι διαχωρισμένο σε μικρότερα, ομοιόμορφα υποσύνολα. Κατά την εκπαίδευση, οι παράμετροι προσαρμόζονται, οδηγώντας τελικά σε ασύμμετρες, πιο σύνθετες και βελτιστοποιημένες καμπύλες, που βελτιώνουν την ακρίβεια πρόβλεψης.

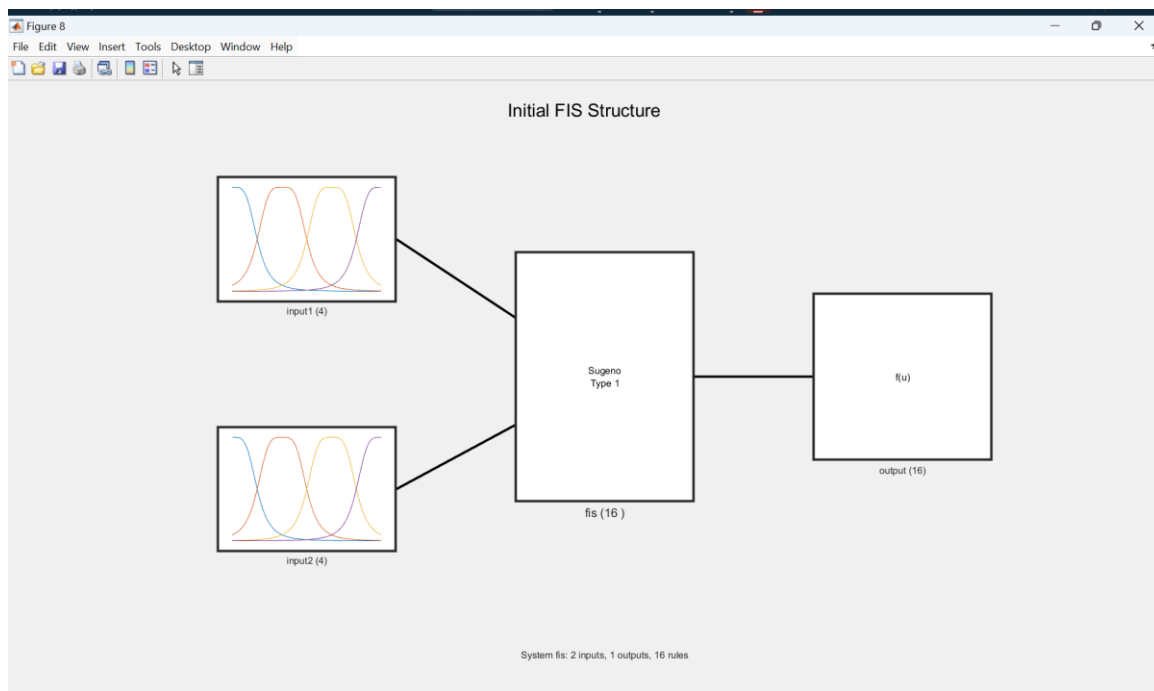
Όσον αφορά το FIS, η αρχική δομή του αποτελείται από 2 εισόδους με προκαθορισμένες συναρτήσεις συμμετοχής (gbellmfs), αρχικούς κανόνες τύπου If-Then και γραμμικές συναρτήσεις εξόδου. Μετά την εκπαίδευση, η τελική δομή του ANFIS (πλέον) έχει προσαρμοσμένες συναρτήσεις συμμετοχής, βελτιστοποιημένους κανόνες If-Then και γραμμικές συναρτήσεις εξόδου.



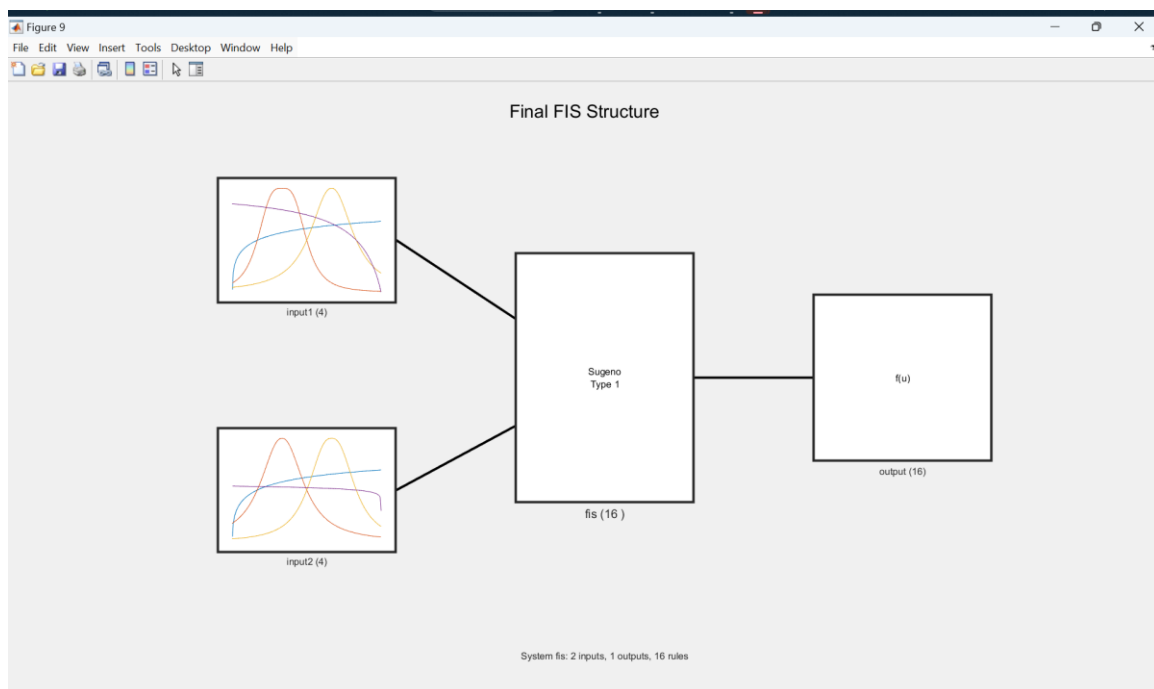
Εικόνα 41: Αρχικές Συναρτήσεις Συμμετοχής σε κάθε είσοδο



Εικόνα 42: Τελικές Συναρτήσεις Συμμετοχής σε κάθε είσοδο



Εικόνα 43: Αρχική δομή Ασαφούς Συστήματος Συμπερασμού




Εικόνα 44: Δομή Προσαρμοστικού Νεύρο-ασαφούς Συστήματος Συμπερασμού

Στη συνέχεια παρουσιάζεται το γράφημα με τις δύο ξεχωριστές γραφικές παραστάσεις που προέκυψαν με το πέρας της εκπαίδευσης του ANFIS:

Η πρώτη απεικονίζει την καμπύλη σφάλματος εκπαίδευσης / ελέγχου και εκφράζεται με τη μορφή της ρίζας του μέσου τετραγωνικού σφάλματος (Root Mean Square Error – RMSE) σε συνάρτηση με τον αριθμό εποχών εκπαίδευσης (training epochs). Παρατηρείται πως το σφάλμα εκπαίδευσης λαμβάνει την τελική ελάχιστη τιμή του και σταθεροποιείται περίπου στην 70^η επανάληψη, κάτι που υποδηλώνει πως ο συνολικός αριθμός επαναλήψεων που επιλέχθηκε για να εκπαιδευτεί το σύστημα είναι απόλυτα επαρκής.

Η δεύτερη γραφική παράσταση απεικονίζει την καμπύλη του μεγέθους βήματος (step size) σε συνάρτηση του αριθμού εποχών εκπαίδευσης (training epochs). Διαπιστώνεται ότι, έπειτα από μία σταθερή καμπυλοειδή πτώση στην τιμή του μεγέθους βήματος, η τιμή του ελαχιστοποιείται λίγο πριν τη 200^η επανάληψη.

Σημειώνεται ότι και οι δύο γραφικές παραστάσεις χρησιμοποιήθηκαν εκτενώς για την προσαρμογή και τον καθορισμό του βέλτιστου αριθμού τόσο των επαναλήψεων όσο και του αρχικού μεγέθους βήματος (initial step size).



Εικόνα 45: Σφάλμα εκπαίδευσης – ελέγχου ανά επανάληψη / Μέγεθος Βήματος ανά επανάληψη

Οι τελικοί κανόνες βάσης, τύπου “If – Then” παρατίθενται παρακάτω, παρέχοντας μια σαφή εικόνα των σχέσεων και των κανόνων που διαμορφώθηκαν κατά την εκπαίδευση:

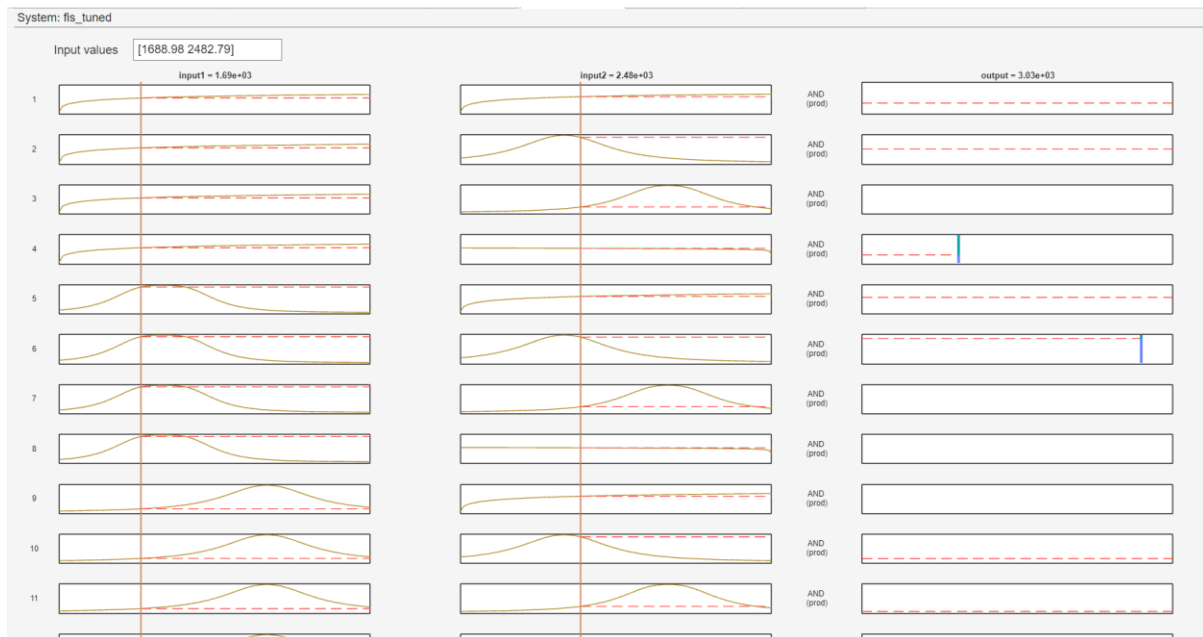
```
ans =
```

```
16×78 char array
```

```
'1. If (input1 is inlmf1) and (input2 is in2mf1) then (output is outlmf1) (1) '
'2. If (input1 is inlmf1) and (input2 is in2mf2) then (output is outlmf2) (1) '
'3. If (input1 is inlmf1) and (input2 is in2mf3) then (output is outlmf3) (1) '
'4. If (input1 is inlmf1) and (input2 is in2mf4) then (output is outlmf4) (1) '
'5. If (input1 is inlmf2) and (input2 is in2mf1) then (output is outlmf5) (1) '
'6. If (input1 is inlmf2) and (input2 is in2mf2) then (output is outlmf6) (1) '
'7. If (input1 is inlmf2) and (input2 is in2mf3) then (output is outlmf7) (1) '
'8. If (input1 is inlmf2) and (input2 is in2mf4) then (output is outlmf8) (1) '
'9. If (input1 is inlmf3) and (input2 is in2mf1) then (output is outlmf9) (1) '
'10. If (input1 is inlmf3) and (input2 is in2mf2) then (output is outlmf10) (1) '
'11. If (input1 is inlmf3) and (input2 is in2mf3) then (output is outlmf11) (1) '
'12. If (input1 is inlmf3) and (input2 is in2mf4) then (output is outlmf12) (1) '
'13. If (input1 is inlmf4) and (input2 is in2mf1) then (output is outlmf13) (1) '
'14. If (input1 is inlmf4) and (input2 is in2mf2) then (output is outlmf14) (1) '
'15. If (input1 is inlmf4) and (input2 is in2mf3) then (output is outlmf15) (1) '
'16. If (input1 is inlmf4) and (input2 is in2mf4) then (output is outlmf16) (1) '
```

Εικόνα 46: Τελικοί κανόνες μοντέλου ANFIS

Επίσης παρατίθεται το παρακάτω διάγραμμα, το οποίο απεικονίζει μέρος του συντονισμένου ασαφούς συστήματος συμπερασμού μετά την εκπαίδευση:

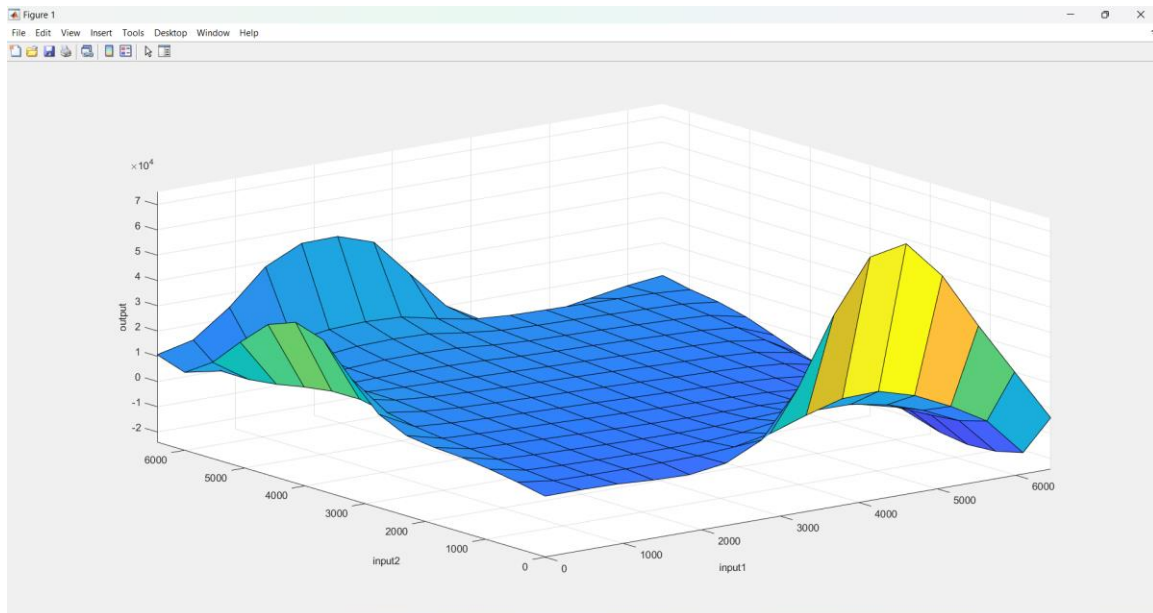


Εικόνα 47: Συντονισμένο Ασαφές Σύστημα Συμπερασμού μετά την εκπαίδευση

Από το παραπάνω γράφημα προκύπτει ότι η πρώτη στήλη δείχνει τις συναρτήσεις συμμετοχής για την πρώτη είσοδο (input1), δηλαδή τις τιμές παραγόμενης ενέργειας σε ωριαία βάση τη χρονική στιγμή ($k-2$), ενώ η δεύτερη στήλη παρουσιάζει τις συναρτήσεις συμμετοχής για τη δεύτερη είσοδο (input2), δηλαδή τις μετρήσεις παραγωγής ενέργειας τη χρονική στιγμή ($k-1$). Κάθε πλαίσιο περιέχει μια συνάρτηση συμμετοχής (MF) που δείχνει πώς τα δεδομένα εισόδου αντιστοιχίζονται σε ένα βαθμό συμμετοχής. Η τρίτη στήλη δείχνει τις συναρτήσεις συμμετοχής για την έξοδο του συστήματος (output), η οποία αναπαριστά την προβλεπόμενη τιμή της ηλεκτρικής ενέργειας, δηλαδή την τιμή της την χρονική στιγμή (k).

Κάθε κανόνας περιγράφει πώς οι συνδυασμοί των βαθμών συμμετοχής των εισόδων οδηγούν σε μια συγκεκριμένη έξοδο. Οι κόκκινες διακεκομμένες γραμμές αναπαριστούν τις άνω και κάτω συναρτήσεις συμμετοχής για κάθε κανόνα, ενώ οι μπλε και πράσινες γραμμές υποδεικνύουν τη θέση των τρεχουσών τιμών των εισόδων και της αντίστοιχης εξόδου. Οι τιμές εισόδου που έχουν επιλεγεί στο γράφημα είναι 1688.98 MWh για την πρώτη είσοδο και 2482.79 MWh για τη δεύτερη είσοδο, με την αντίστοιχη έξοδο να είναι περίπου 3030 MWh.

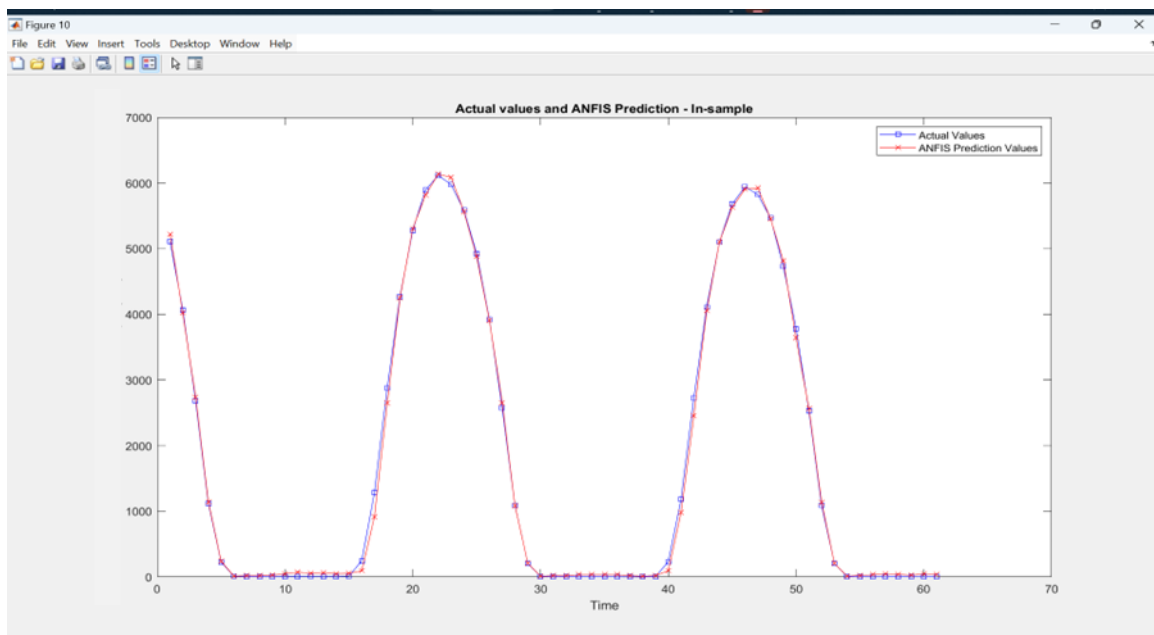
Ταυτόχρονα, δημιουργήθηκε με τη βοήθεια του Surface Viewer της MATLAB ένα τρισδιάστατο γράφημα που αναπαριστά τη σχέση μεταξύ των εισόδων και της εξόδου του εκπαιδευμένου πλέον συστήματος συμπερασμού. Το γράφημα αυτό είναι ιδιαίτερα χρήσιμο για την κατανόηση από τον χρήστη, πώς διαφορετικοί συνδυασμοί εισόδων επηρεάζουν την έξοδο του συστήματος.




Εικόνα 48: Surface Viewer για το εκπαιδευμένο FIS

8.4 Αξιολόγηση του ANFIS


Σε αυτό το σημείο πραγματοποιήθηκαν οι προβλέψεις του μοντέλου, η απόδοση του οποίου αξιολογήθηκε με βάσει τα δεδομένα εκπαίδευσης (in-sample / training data) και τα δεδομένα δοκιμής (out-of-sample / evaluation data). Οι προβλέψεις αυτές, καθώς και τα σφάλματα των προβλέψεων του ANFIS για κάθε περίπτωση, που προκύπτουν από τη διαφορά των πραγματικών τιμών με των προβλεπόμενων, παρουσιάζονται παρακάτω:




Εικόνα 49: Πραγματικές τιμές και τιμές μεθόδου πρόβλεψης ANFIS ανά ώρα - Δεδομένα Εκπαίδευσης (Last 60 samples)



Εικόνα 50: Σφάλματα Πρόβλεψης ANFIS ανά ώρα – Δεδομένα εκπαίδευσης (Last 60 samples)




Εικόνα 51: Πραγματικές τιμές και τιμές μεθόδου πρόβλεψης ANFIS ανά ώρα - Δεδομένα Αξιολόγησης (Last 60 samples)



Εικόνα 52: Σφάλματα Πρόβλεψης ANFIS ανά ώρα – Δεδομένα αξιολόγησης (Last 60 samples)

Μέσα από τα παραπάνω γραφήματα γίνεται αντιληπτό ότι οι προβλέψεις του μοντέλου ANFIS, τόσο σε επίπεδο εκπαίδευσης όσο και σε επίπεδο αξιολόγησης, ακολουθούν σχεδόν πιστά τις πραγματικές τιμές, έχοντας σημαντικά χαμηλή απόκλιση, ειδικά αν αναλογιστεί κανείς και το εύρος των τιμών του εξεταζόμενου dataset, που κυμαίνεται από 0 έως 6446 MWh.

Τέλος, παρουσιάζεται η διασπορά των σφαλμάτων πρόβλεψης του μοντέλου ANFIS. Οι άξονες εισόδου (input1 και input2) αναπαριστούν τις τιμές των δύο εισόδων του μοντέλου, ενώ η χρωματική κλίμακα απεικονίζει το σφάλμα πρόβλεψης της εξόδου (output error). Κάθε σημείο αντιπροσωπεύει μια παρατήρηση από τα δεδομένα αξιολόγησης, με το χρώμα του να δείχνει την απόκλιση της πρόβλεψης από την πραγματική τιμή. Τα χρώματα κυμαίνονται από μπλε (χαμηλά σφάλματα) έως κίτρινο (υψηλά σφάλματα), υποδεικνύοντας κυρίως καλή απόδοση του μοντέλου με περιορισμένες μόνο περιοχές μεγαλύτερων σφαλμάτων.



Εικόνα 53: Διασπορά σφαλμάτων πρόβλεψης μοντέλου ANFIS

Σε αυτό το σημείο, εξετάστηκε και αξιολογήθηκε η ακρίβεια του μοντέλου με τη χρήση τεσσάρων διαφορετικών μετρικών σφάλματος, του μέσου τετραγωνικού σφάλματος (Mean Squared Error – MSE), της ρίζας του μέσου τετραγωνικού σφάλματος (Root Mean Squared Error – RMSE), του μέσου απόλυτου σφάλματος (Mean Absolute Error – MAE) και του συντελεστή προσδιορισμού (Coefficient of Determination – DC or R-squared - R²).

Τα αποτελέσματα των μετρικών που προέκυψαν για το μοντέλο ANFIS είναι τα ακόλουθα:

Πίνακας 6: Ρίζα Μέσου Τετραγωνικού Σφάλματος για το μοντέλο ANFIS πάνω στα δεδομένα εκπαίδευσης (σε MWh)

	RMSE
ANFIS	90.477

Πίνακας 7: Σφάλματα Μέτρησης για το μοντέλο ANFIS πάνω στα δεδομένα αξιολόγησης (σε MWh)

	MSE	RMSE	MAE	R ²
ANFIS	10,764.541	103.752	60.532	0.9951

Πίνακας 8: Κανονικοποιημένα Σφάλματα Μέτρησης για το μοντέλο ANFIS

	nMSE	nRMSE	nMAE	R ²
ANFIS	7.222	0.0696	0.0406	0.9951

Οι παραπάνω πίνακες αποτυπώνουν την εξαιρετική πρόβλεψη που πραγματοποιεί το μοντέλο ANFIS όσον αφορά και τα δεδομένα εκπαίδευσης και αυτά της αξιολόγησης. Επιπλέον, επιβεβαιώνεται η αποφυγή υπο- ή και υπερεκπαίδευσης, αφού αφενός το σφάλμα εκπαίδευσης RMSE έχει πολύ ικανοποιητική τιμή (όπως φαίνεται και από τις καμπύλες παραπάνω), αφετέρου η διαφορά των σφαλμάτων RMSE εκπαίδευσης και αξιολόγησης είναι πολύ μικρή (περίπου 13.4 MWh).


8.5 Σύγκριση με άλλες μεθόδους πρόβλεψης

Παρακάτω παρατίθενται τα αποτελέσματα από την περαιτέρω αξιολόγηση του μοντέλου ANFIS, συγκρίνοντας τα αποτελέσματά του με άλλα τρία μοντέλα πρόβλεψης:

- ένα μοντέλο αυτοπαλινδρόμησης (AutoRegressive model - AR model),
- ένα μοντέλο αυτοπαλινδρόμησης κινούμενου μέσου (AutoRegressive Moving Average model - ARMA model)
- ένα ασαφές σύστημα συμπερασμού τύπου-2, με χρήση της μεθόδου βελτιστοποίησης Σμήνους Σωματιδίων (Particle Swarm Optimization – PSO) και
- ένα Τεχνητό Νευρωνικό Δίκτυο - ΤΝΔ (Artificial Neural Network, ANN), εμπροσθοτροφοδοτούμενο (feed-forward), με ένα κρυφό επίπεδο (hidden layer), εκπαιδευμένο με οπισθοδιάδοση (backpropagation).

Κάθε ένα από αυτά τα μοντέλα κωδικοποιήθηκε επίσης σε γλώσσα προγραμματισμού MATLAB, εφαρμόστηκε στα ίδια δεδομένα με τον ίδιο διαχωρισμό (80% εκπαίδευση – 20% αξιολόγηση) και τα αποτελέσματά τους συγκρίθηκαν με τα αποτελέσματα του ANFIS, χρησιμοποιώντας τις ίδιες μετρικές σφάλματος που προαναφέρθηκαν (MSE, RMSE, MAE, R^2).

8.5.1 Μοντέλο Αυτοπαλινδρόμησης (AutoRegressive Model - AR)



Εικόνα 54: Πραγματικές τιμές και τιμές μεθόδου πρόβλεψης AR ανά ώρα (Last 60 samples)


Πίνακας 9: Σφάλματα Μέτρησης για το μοντέλο AR (σε MWh)

	MSE	RMSE	MAE	R^2
AR	27,385.097	165.484	88.643	0.9877

Πίνακας 10: Κανονικοποιημένα Σφάλματα Μέτρησης για το μοντέλο AR

	MSE	RMSE	MAE	R^2
AR	18.373	0.111	0.059	0.9877

8.5.2 Μοντέλο Αυτοπαλινδρόμησης Κινούμενου Μέσου (AutoRegressive Moving Average Model – ARMA)



Εικόνα 55: Πραγματικές τιμές και τιμές μεθόδου πρόβλεψης ARMA ανά ώρα (Last 60 samples)


Πίνακας 11: Σφάλματα Μέτρησης για το μοντέλο ARMA (σε MWh)

	MSE	RMSE	MAE	R²
ARMA	23,316.353	152.697	97.789	0.9895

Πίνακας 12: Κανονικοποιημένα Σφάλματα Μέτρησης για το μοντέλο ARMA

	nMSE	nRMSE	nMAE	R²
ARMA	15.643	0.102	0.0656	0.9895

8.5.3 Μοντέλο Ασαφούς Συστήματος Συμπερασμού Τύπου-2 με Βελτιστοποίηση Σμήνους Σωματιδίων (Fuzzy Inference System Type-2 Model with Particle Swarm Optimization- FT2-PSO)



Εικόνα 56: Πραγματικές τιμές και τιμές μεθόδου πρόβλεψης FT2-PSO ανά ώρα (Last 60 samples)

Πίνακας 13: Σφάλματα Μέτρησης για το μοντέλο FT2-PSO (σε MWh) – Δεδομένα Εκπαίδευσης

	RMSE
FT2-PSO	104.3


Πίνακας 14: Σφάλματα Μέτρησης για το μοντέλο FT2-PSO (σε MWh) – Δεδομένα Αξιολόγησης

	MSE	RMSE	MAE	R ²
FT2-PSO	14,000.4708	118.3236	71.1426	0.9937

Πίνακας 15: Κανονικοποιημένα Σφάλματα Μέτρησης για το μοντέλο FT2-PSO

	MSE	RMSE	MAE	R²
FT2-PSO	9.393	0.0794	0.0477	0.9937

8.5.4 Μοντέλο Τεχνητού Νευρωνικού Δικτύου (Artificial Neural Network Model – ANN)



Εικόνα 57: Πραγματικές τιμές και τιμές μεθόδου πρόβλεψης ΤΝΔ ανά ώρα (Last 60 samples)


Πίνακας 16: Σφάλματα Μέτρησης για το μοντέλο ΤΝΔ (σε MWh)

	MSE	RMSE	MAE	R²
ANN	13,519.948	116.275	65.269	0.9939

Πίνακας 17: Κανονικοποιημένα Σφάλματα Μέτρησης για το μοντέλο ΤΝΔ

	nMSE	nRMSE	nMAE	R ²
ANN	9.07	0.078	0.0438	0.9939

Τέλος, παρουσιάζεται το γράφημα που περιλαμβάνει τις προβλέψεις όλων των μοντέλων πάνω στα δεδομένα αξιολόγησης και συγκεκριμένα στις τελευταίες 60 τιμές για να εξασφαλιστεί η ευκρίνεια των αποτελεσμάτων:



Εικόνα 58: Σύγκριση συνολικών αποτελεσμάτων μοντέλων πρόβλεψης με πραγματικές τιμές ανά ώρα (Last 60 samples)

8.6 Αποτελέσματα Σύγκρισης

Με τη βοήθεια των πολυποίκιλων Toolboxes που παρέχει η MATLAB, και κυρίως του System Identification Toolbox, κωδικοποιήθηκαν οι μαθηματικοί τύποι των επιθυμητών σφαλμάτων μέτρησης για κάθε μοντέλο πρόβλεψης (ANFIS, AR, ARMA, FT2-PSO, ANN) και εξήχθησαν τα αποτελέσματά τους. Τα επιμέρους σφάλματα για κάθε μοντέλο πρόβλεψης παρουσιάζονται στον ακόλουθο πίνακα:

Πίνακας 18: Σφάλματα Πρόβλεψης για κάθε Μοντέλο (σε MWh)

	MSE	RMSE	MAE	R²
ANFIS	10,764.541	103.752	60.532	0.9951
ANN	13,519.948	116.275	65.269	0.9939
FT2-PSO	14,000.4708	118.3236	71.1426	0.9937
ARMA	23,316.353	152.697	97.789	0.9895
AR	27,385.097	165.484	88.643	0.9877

Πίνακας 19: Κανονικοποιημένα Σφάλματα Πρόβλεψης για κάθε Μοντέλο

	nMSE	nRMSE	nMAE	R²
ANFIS	7.222	0.0696	0.0406	0.9951
ANN	9.07	0.078	0.0438	0.9939
FT2-PSO	9.393	0.0794	0.0477	0.9937
ARMA	15.643	0.102	0.0656	0.9895
AR	18.373	0.111	0.059	0.9877

Για τις μετρικές σφάλματος που χρησιμοποιήθηκαν (RMSE, MSE, MAE, R²), ισχύει ότι:

- Όσο μικρότερες είναι οι τιμές των σφαλμάτων RMSE, MSE και MAE, τόσο καλύτερη είναι η απόδοση του μοντέλου (Jensen et al., 2016).
- Αντίθετα, για τον συντελεστή προσδιορισμού R², όσο μεγαλύτερη και πιο κοντά στο 1 είναι η τιμή, τόσο καλύτερο είναι το μοντέλο.

Επίσης, όπως επεξηγήθηκε και στην υποενότητα 7.6.4, έγινε κανονικοποίηση των μετρικών σφάλματος RMSE, MSE και MAE χρησιμοποιώντας την τυπική απόκλιση των δεδομένων πραγματικής (actual) παραγόμενης ενέργειας. Αυτή η κανονικοποιημένη εκδοχή επιτρέπει μια πιο ακριβή και ρεαλιστική εκτίμηση της απόδοσης των μοντέλων, καθώς λαμβάνει υπόψη τις διακυμάνσεις των δεδομένων.

Τα αποτελέσματα των παραπάνω πινάκων φανερώνουν ότι το μοντέλο ANFIS που αναπτύχθηκε είναι πολύ πιο αξιόπιστο σε σχέση με τα υπόλοιπα μοντέλα πρόβλεψης, αφού παρουσίασε τα μικρότερα επιμέρους σφάλματα σε όλες τις περιπτώσεις. Δεύτερο καλύτερο μοντέλο όσον αφορά την αξιοπιστία στις προβλέψεις του έρχεται το Τεχνητό Νευρωνικό Δίκτυο (ANN), το οποίο έχει παρόμοια δομή (όπως έχει αναλυθεί προγενέστερα) με αυτή του ANFIS. Τρίτο ακολουθεί το μοντέλο ασαφούς λογικής τύπου 2 με βελτιστοποίηση σμήνους σωματιδίων (Type-2 FIS with PSO / FT2-PSO), το οποίο αν και γενικά είναι αρκετά αξιόπιστο και ακριβές, στην προκειμένη περίπτωση υστερεί έναντι του ΤΝΔ και του ANFIS.

Αναλυτικότερα, αξιολογώντας τα μοντέλα βάσει του RMSE, παρατηρείται ότι το ANFIS παρουσιάζει την χαμηλότερη τιμή με κανονική και κανονικοποιημένη εκδοχή 103.752 MWh και 0.070 αντίστοιχα. Το ANN ακολουθεί με τιμές RMSE 116.275 MWh και nRMSE 0.078, ενώ το FT2-PSO παρουσιάζει ελαφρώς μεγαλύτερες τιμές RMSE, 118.324 MWh και nRMSE 0.079. Τέλος, τα μοντέλα ARMA και AR, με RMSE 152.697 MWh και 165.484 MWh αντίστοιχα, και nRMSE 0.102 και 0.111, δείχνουν σημαντικά χαμηλότερη απόδοση συγκριτικά με τα υπόλοιπα μοντέλα.

Ωστόσο, κρίνοντας τόσο από τα σφάλματα πρόβλεψης, όσο και από τις καμπύλες πρόβλεψης που προέκυψαν και παρουσιάστηκαν στην ενότητα 8.6, διαπιστώνεται πως και οι τέσσερις μέθοδοι είναι αρκετά αξιόπιστες, μιας και παρουσιάζουν αρκετά μικρά σφάλματα και οι τιμές των προβλέψεών τους σχεδόν συμπίπτουν με τις πραγματικές τιμές παραγόμενης ενέργειας (σε MWh).

8.7 Εναλλακτικοί τρόποι εκπαίδευσης και αξιολόγησης του ANFIS σε περιβάλλον Matlab

Στη MATLAB, εκτός από την δημιουργία κώδικα και τη χρήση κατάλληλων συναρτήσεων για την εκπαίδευση και αξιολόγηση ενός Προσαρμοστικού Νευρο-Ασαφούς Συστήματος Συμπερασμού, όπως έγινε στην παρούσα διπλωματική εργασία, υφίσταται επίσης η δυνατότητα χρήσης των εφαρμογών Fuzzy Logic Designer και Neuro-Fuzzy Designer.

Αυτές οι εφαρμογές μπορούν να χρησιμοποιηθούν είτε για την επιβεβαίωση της ορθότητας των αποτελεσμάτων που προέκυψαν από τον κώδικα ή ακόμη και για την πλήρη εκπαίδευση και αξιολόγηση του ANFIS εξολοκλήρου από τις εφαρμογές αυτές.

Η εφαρμογή Fuzzy Logic Designer επιτρέπει τη δημιουργία, επεξεργασία και ανάλυση συστημάτων ασαφούς λογικής, προσφέροντας γραφικά εργαλεία για τη σχεδίαση ασαφών συστημάτων και τη δοκιμή τους με τα επιθυμητά δεδομένα. Η εφαρμογή Neuro-Fuzzy Designer εξειδικεύεται στην κατασκευή και εκπαίδευση συστημάτων ANFIS, χρησιμοποιώντας το επιθυμητό dataset.

Κεφάλαιο 9: Συμπεράσματα, Περιορισμοί και Μελλοντικές Έρευνες

9.1 Συμπεράσματα

Τα τελευταία χρόνια, η στροφή προς τις ανανεώσιμες πηγές ενέργειας (ΑΠΕ) αποτελεί έναν από τους κεντρικούς στόχους της παγκόσμιας ενεργειακής πολιτικής. Η αυξανόμενη ανάγκη για καθαρές και βιώσιμες μορφές ενέργειας, σε συνδυασμό με τις τεχνολογικές εξελίξεις, έχουν καταστήσει τη χρήση των ΑΠΕ ζωτικής σημασίας για την αντιμετώπιση των περιβαλλοντικών προκλήσεων και την προώθηση της βιώσιμης ανάπτυξης.

Η παρούσα διπλωματική εργασία ανέλυσε την εφαρμογή των νευρο-ασαφών συστημάτων, και συγκεκριμένα του προσαρμοστικού νευρο-ασαφούς συστήματος εξαγωγής συμπερασμάτων (ANFIS), στην εκτίμηση της παραγωγής ηλεκτρικής ενέργειας από φωτοβολταϊκά συστήματα. Το σύστημα αυτό καλύπτει την επιτακτική ανάγκη που υφίσταται για ακριβή πρόβλεψη της παραγωγής ενέργειας από ΑΠΕ, λόγω της απρόβλεπτης και διακοπτόμενης φύσης τους, με απώτερο σκοπό τη σταθερή και αξιόπιστη ενσωμάτωσή τους στα ηλεκτρικά δίκτυα.

Μέσα από την ενδελεχή ανασκόπηση της βιβλιογραφίας και την ανάλυση των τεχνητών νευρωνικών δικτύων, της ασαφούς λογικής και του συνδυασμού τους σε θεωρητικό πλαίσιο, αναπτύχθηκε ένα μοντέλο ANFIS το οποίο εκπαιδεύτηκε και αξιολογήθηκε με χρήση ιστορικών δεδομένων παραγόμενης ενέργειας (σε MWh). Τα αποτελέσματα έδειξαν ότι το μοντέλο ANFIS υπερέχει σε ακρίβεια και αξιοπιστία σε σύγκριση με άλλες μεθόδους πρόβλεψης, όπως το Αυτοπαλινδρομικό (AR) και το Αυτοπαλινδρομικό μοντέλο Κινούμενου Μέσου (ARMA), το Τεχνητό Νευρωνικό Δίκτυο (ANN) και το Ασαφές Σύστημα Συμπερασμού Τύπου-2 με Βελτιστοποίηση Σμήνους Σωματιδίων (Fuzzy Type-2 PSO).

Συμπερασματικά, η υψηλή ακρίβεια που προσφέρει το μοντέλο ANFIS επιβεβαιώνει την αποτελεσματικότητα των νευρο-ασαφών συστημάτων στην πρόβλεψη της παραγωγής ενέργειας από ΑΠΕ και εν προκειμένω από Φ/Β, καθιστώντας τα μια βιώσιμη λύση για την ενσωμάτωση των ΑΠΕ στα ηλεκτρικά δίκτυα.

9.2 Περιορισμοί

Παρά την επιτυχημένη εφαρμογή του μοντέλου ANFIS στην πρόβλεψη της παραγόμενης ηλεκτρικής ενέργειας, υπάρχουν ορισμένοι περιορισμοί που πρέπει να επισημανθούν. Σε αντίθεση με το κεφάλαιο 6.6, στο οποίο παρουσιάστηκαν τεχνικοί περιορισμοί του ANFIS, παρακάτω αναφέρονται γενικότεροι περιορισμοί και αφορούν τη συνολική εφαρμογή και απόδοση της εξεταζόμενης μεθοδολογίας πρόβλεψης σε πραγματικές συνθήκες:

- **Δεδομένα Εκπαίδευσης:** Η ποιότητα και η ποσότητα των ιστορικών δεδομένων επηρεάζουν άμεσα την ακρίβεια των προβλέψεων. Δηλαδή, η έλλειψη επαρκών και αξιόπιστων δεδομένων μπορεί να περιορίσει την απόδοση του μοντέλου.
- **Προσαρμοστικότητα:** Αν και το ANFIS είναι σχεδιασμένο για να προσαρμόζεται σε διαφορετικά δεδομένα, η αποτελεσματικότητά του μπορεί να μειωθεί όταν εφαρμόζεται σε γεωγραφικές περιοχές ή κλιματικές συνθήκες που διαφέρουν σημαντικά από αυτές που χρησιμοποιήθηκαν για την εκπαίδευσή του. Αυτό συμβαίνει γιατί το μοντέλο βασίζεται στα χαρακτηριστικά των δεδομένων εκπαίδευσης, και αν αυτά δεν είναι αντιπροσωπευτικά των νέων συνθηκών, η γενίκευση του μοντέλου μπορεί να είναι περιορισμένη.
- **Υπολογιστική Πολυπλοκότητα:** Αν και το μοντέλο ANFIS προσφέρει γενικά υψηλή ακρίβεια στις προβλέψεις και σε μικρό χρόνο, η διαδικασία εκπαίδευσης και βελτιστοποίησής του ενδεχομένως να απαιτήσει σημαντικούς υπολογιστικούς πόρους. Αυτό μπορεί να καταστήσει δύσκολη την εφαρμογή του σε πραγματικό χρόνο ή σε περιβάλλοντα με περιορισμένους υπολογιστικούς πόρους. Ωστόσο, τα τελευταία χρόνια, με την ραγδαία εξέλιξη της τεχνολογίας, το πρόβλημα αυτό έχει σχεδόν περιοριστεί.

9.3 Μελλοντικές Έρευνες

Για την περαιτέρω βελτίωση της πρόβλεψης παραγωγής ενέργειας από ΑΠΕ, οι μελλοντικές έρευνες μπορούν να εστιάσουν – αν δεν το πράττουν ήδη - στους ακόλουθους τομείς:

- **Ενσωμάτωση Νέων Αλγορίθμων:** Η ενσωμάτωση προηγμένων αλγορίθμων μηχανικής μάθησης και βαθιάς μάθησης μπορεί να βελτιώσει ακόμα περισσότερο την ακρίβεια και την απόδοση των προβλέψεων.
- **Διευρυμένα Δεδομένα:** Η συλλογή και χρήση μεγαλύτερων και πιο αντιπροσωπευτικών συνόλων δεδομένων από διάφορες γεωγραφικές περιοχές και κλιματικές συνθήκες θα είχε ως αποτέλεσμα το μοντέλο να κάνει καλύτερη γενίκευση των δεδομένων.
- **Κεντριοποιημένα Συστήματα ANFIS:** Η ανάπτυξη ενός κεντριοποιημένου συστήματος ANFIS που θα δέχεται δεδομένα από όλο τον κόσμο και θα προσαρμόζεται ανάλογα με τις ανάγκες κάθε περιοχής, μπορεί να βελτιώσει την απόδοση και την ευελιξία των προβλέψεων. Ένα τέτοιο σύστημα θα μπορούσε να συνδυάσει δεδομένα από διαφορετικές πηγές και να προσφέρει ακριβείς προβλέψεις για διάφορες γεωγραφικές περιοχές και κλιματικές συνθήκες.
- **Υβριδικά Μοντέλα:** Η ανάπτυξη υβριδικών μοντέλων που συνδυάζουν τις καλύτερες τεχνικές από διάφορους αλγορίθμους πρόβλεψης μπορεί να προσφέρει ακόμα καλύτερα αποτελέσματα.
- **Πραγματικός Χρόνος:** Η βελτίωση της υπολογιστικής αποδοτικότητας των μοντέλων ώστε να μπορούν να λειτουργούν σε πραγματικό χρόνο είναι ένας σημαντικός τομέας έρευνας.
- **Εφαρμογή σε Άλλες Μορφές ΑΠΕ:** Η εφαρμογή παρόμοιων τεχνικών πρόβλεψης και σε διαφορετικές μορφές ανανεώσιμων πηγών ενέργειας, όπως η υδροηλεκτρική, μπορεί αναμφίβολα να επεκτείνει και να αποτυπώσει περαιτέρω τη χρησιμότητα αυτών των μοντέλων.

Εν κατακλείδι, η παρούσα εργασία αποτελεί ένα σημαντικό βήμα προς την κατεύθυνση της ακριβούς και αξιόπιστης πρόβλεψης της παραγωγής ενέργειας από ΑΠΕ, ανοίγοντας τον δρόμο για περαιτέρω έρευνα και ανάπτυξη στον τομέα αυτό.

Κεφάλαιο 10: Βιβλιογραφία

Ατσαλάκης, Γ. (2006) Σύστημα πρόβλεψης της βραχυχρόνιας τάσης της τιμής των μετοχών με χρήση νευρο-ασαφών μεθόδων. Διδακτορική Διατριβή. Πολυτεχνείο Κρήτης. Τμήμα Μηχανικών Παραγωγής και Διοίκησης. Τομέας Οργάνωσης και Διοίκησης. Doi: 10.12681/eadd/14420

Ενεργειακή δέσμη για την Ευρώπη - Ελεύθερη εκλογή των καταναλωτών. (n.d.). Ευρωπαϊκό Κοινοβούλιο. Retrieved from <https://www.europarl.europa.eu/highlights/el/1205.html>

Ζερβουδάκης, Ι. (2008) Πρόβλεψη της θερμοκρασίας για τη λήψη αποφάσεων μέσω εφαρμογής νευρο-ασαφούς μοντέλου ANFIS. Διπλωματική Εργασία. Τμήμα Μηχανικών Παραγωγής και Διοίκησης, Πολυτεχνείο Κρήτης.

Ιψάκης, Δ. (2011). Διατριβή: Σχεδιασμός βέλτιστης λειτουργίας ενεργειακών συστημάτων με χρήση ανανεώσιμων και εναλλακτικών πηγών - Κωδικός: 24029. Retrieved February 30, 2024, from AUTH website: <https://thesis.ekt.gr/thesisBookReader/id/24029?lang=el#page/1/mode/2up>

Καλαμαράς, Χ. (2013) Πρόβλεψη τιμών του ναυτιλιακού Βαλτικού Δείκτη Ξηρού Φορτίου (Baltic Dry Index), μέσω χρήσης προσαρμοστικού νευρο-ασαφούς συστήματος (Adaptive Neuro-Fuzzy System), Ερευνητικό Έργο-Πτυχιακή Εργασία. Τμήμα Μηχανικών Παραγωγής και Διοίκησης, Πολυτεχνείο Κρήτης

Κουρούς, Ν. (2012) Δυναμικός Αρθρωτός Νευροασαφής Ταξινομητής. Διπλωματική Εργασία. Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης. Τμήμα Ηλεκτρολόγων Μηχανικών & Μηχανικών Υπολογιστών, Τομέας Ηλεκτρονικής & Υπολογιστών.

Λέκου, Α. (2011) Πρόβλεψη Εισαγόμενης Διασυνδεδεμένης Ενέργειας. Ερευνητικό Έργο, Πολυτεχνείο Κρήτης, Μεταπτυχιακό Τμήμα Μηχανικών Παραγωγής και Διοίκησης, Τομέας: Οργάνωση και Διοίκηση Επιχειρήσεων.

Νικολάου, Β. (2020). Πρόβλεψη παραγωγής ενέργειας από φωτοβολταϊκά πάρκα με χρήση τεχνητών νευρωνικών δικτύων.

Νταφαλιάς, Α. Πρόβλεψη παραγωγής ενέργειας από φωτοβολταϊκά πάρκα βάση ανάλυσης μετεωρολογικών δεδομένων και χρήση σύγχρονων υπολογιστικών εργαλείων.

Οικονόμου, Δ. (2024). Βραχυπρόθεσμη πρόβλεψη φωτοβολταϊκής παραγωγής με χρήση τεχνητών νευρωνικών δικτύων τύπου μακράς βραχείας μνήμης (long-short term memory).

Ραουζαίου, Ν-Μ.Θ. (2008) Διαχείριση Δομής Νευροασαφών Συστημάτων με Ανάλυση Ευαισθησίας. Διπλωματική Εργασία. Εθνικό Μετσόβιο Πολυτεχνείο. Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών, Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών.

Τσαγαλάς, Ι. (2023). Οι ανανεώσιμες πηγές ενέργειας και τα φωτοβολταϊκά συστήματα (Master's thesis, Πανεπιστήμιο Πειραιώς).

Χασιακός, Α., & Τσίκας, Π. (2019, 1 Οκτωβρίου). Εξελικτικοί Αλγόριθμοι Βελτιστοποίησης & Τεχνητά Νευρωνικά Δίκτυα [Παρουσίαση PowerPoint].

Χουστουλάκης, Ι. (2022). Πρόβλεψη παραγωγής ενέργειας σε φωτοβολταϊκά χρησιμοποιώντας Ανάλυση Δεδομένων και Μηχανική Μάθηση. *Εθνικό Μετσόβιο Πολυτεχνείο*.

Abdullah, N. A., Rahim, N. A., Gan, C. K., & Adzman, N. N. (2019). Forecasting Solar Power Using Hybrid Firefly and Particle Swarm Optimization (HFPSO) for Optimizing the Parameters in a Wavelet Transform-Adaptive Neuro Fuzzy Inference System (WT-ANFIS). *Applied Sciences*, 9(16), 3214. <https://doi.org/10.3390/app9163214>

Ahmed, A., & Khalid, M. (2019). A review on the selected applications of forecasting models in renewable power systems. *Renewable and Sustainable Energy Reviews*, 100(March 2018), 9-21. <https://doi.org/10.1016/j.rser.2018.09.046>

Almeida, M. P., Perpiñán, O., & Narvarte, L. (2015). PV power forecast using a nonparametric PV model. *Solar Energy*, 115, 354-368. <https://doi.org/10.1016/j.solener.2015.03.006>

Andrianajaiana, T., Razafimahefa, T. D., Haba, C.-G., & Lucache, D. D. (2023). Analysis and Forecasting of Solar Power Generation using Machine Learning. *Information Fusion Research*, 1(1).

Antonanzas, J., Osorio, N., Escobar, R., Urraca, R., Martinez-de-Pison, F. J., & Antonanzas-Torres, F. (2016). Review of photovoltaic power forecasting. *Solar Energy*, 136, 78-111. <https://doi.org/10.1016/j.solener.2016.06.069>

Belkin, M.; Hsu, D.; Ma, S.; Mandal, S. Reconciling modern machine-learning practice and the classical bias–variance trade-off. *Proc. Natl. Acad. Sci. USA* 2019, 116, 15849–15854. [CrossRef]

Bey, K.B. and Benhammadi, F. (2010) Mixture of ANFIS systems for CPU load prediction in metacomputing environment. *Future Generation Computer Systems*. Vol.26, no.7, 1003-1011

Bharathi, S. L., Manjula, A., Thillainayagi, M., Sujidha, M. P., & Radha, M. P. (2023). An ANFIS based Global Maximum Power Point Tracking Approach for PV Modules under Partial Shading Condition. *power*, 3(1).

Bonissone, P. P. (2002). Adaptive neural fuzzy inference systems (anfis): Analysis and applications. Online available from <https://www.researchgate.net/file.PostFileLoader.html>.

Casaca de Rocha Vaz, A. G. (2014). Photovoltaic forecasting with artificial neural network. *Faculdade de Ciências, Departamento de Engenharia Geográfica, Geofísica e Energia*, 86. Retrieved from http://repositorio.ul.pt/bitstream/10451/11405/1/ulfc107351_tm_Andre_Vaz.pdf

Cherkassky, V., & Ma, Y. (2004). Practical selection of SVM parameters and noise estimation for SVM regression. *Neural Networks*, 17(1), 113-126. [https://doi.org/10.1016/S0893-6080\(03\)00169-2](https://doi.org/10.1016/S0893-6080(03)00169-2)

Cherp, A., Vinichenko, V., Tosun, J. et al. National growth dynamics of wind and solar power compared to the growth required for global climate targets. *Nat Energy* 6, 742–754 (2021). <https://doi.org/10.1038/s41560-021-00863-0>

Couture, T. D., Cory, K., Kreycik, C., & Williams, E. (2010). Policymaker's guide to feed-in tariff policy design (No. NREL/TP-6A2-44849). National Renewable Energy Lab.(NREL), Golden, CO (United States). Cruz, A., & Mestrado, N. (2009). ANFIS: Adaptive neuro-fuzzy inference systems. IM, UFRJ, Mestrado NCE.

Cus, F, Zuperl, U., Milfelner, M. and Mursec, B. (2006) An adaptive neuro-fuzzy inference system for modelling of end-milling. Retrieved from: <https://www.yumpu.com/s/zNnieQa8cRBSZRVi>

Dalianis H. Evaluation metrics and evaluation Clinical Text Mining. 2018;1967:45-53. DOI: 10.1007/978-3-319-78503-5_6

Das, U. K., Tey, K. S., Seyedmahmoudian, M., Mekhilef, S., Idris, M. Y. I., Van Deventer, W., & Stojcevski, A. (2018). Forecasting of photovoltaic power generation and model optimization: A review. *Renewable and Sustainable Energy Reviews*, 81(April 2017), 912-928. <https://doi.org/10.1016/j.rser.2017.08.017>

Dawan, P., Sriprapha, K., Kittisontirak, S., Boonraksa, T., Junhuathon, N., Titiroongruang, W., & Niemcharoen, S. (2020). Comparison of Power Output Forecasting on the Photovoltaic System Using Adaptive Neuro-Fuzzy Inference Systems and Particle Swarm Optimization-Artificial Neural Network Model. *Energies*, 13(351). <https://doi.org/10.3390/en13020351>

Erdiwansyah, E., Mahidin, M., Husin, H. et al. Investigation of availability, demand, targets, and development of renewable energy in 2017–2050: a case study in Indonesia. *Int J Coal Sci Technol* 8, 483–499 (2021). <https://doi.org/10.1007/s40789-020-00391-4>

European Commission. (n.d.). 2050 long-term strategy. Retrieved from https://climate.ec.europa.eu/eu-action/climate-strategies-targets/2050-long-term-strategy_en

Ferrari J. (2020), 'Influx of variable renewable energy sources, the way things are going', Electric Utility Resource Planning, Elsevier, 2, 39–72.

Gesley, J. (2022) Germany: Tax Relief Measures Adopted to Offset High Energy Costs Due to War in Ukraine. [Web Page] Retrieved from the Library of Congress, <https://www.loc.gov/item/global-legal-monitor/2022-05-23/germany-tax-relief-measures-adopted-to-offset-high-energy-costs-due-to-war-in-ukraine/>.

Gholamy, A.; Kreinovich, V.; Kosheleva, O. Why 70/30 or 80/20 Relation between Training and Testing Sets: A Pedagogical Explanation. Departmental Technical Reports (CS). 1209. 2018. Available online: https://scholarworks.utep.edu/cs_techrep/1209 (accessed on 22 April 2024).

Global Temperature | Vital Signs – Climate Change: Vital Signs of the Planet. (n.d.). Retrieved April 19, 2024, from <https://climate.nasa.gov/vital-signs/global-temperature/>

Graditi, G., Ferlito, S., & Adinolfi, G. (2016). Comparison of photovoltaic plant power production prediction methods using a large measured dataset. *Renewable Energy*, 90, 513-519. <https://doi.org/10.1016/j.renene.2016.01.027>

Hernandez, L., Baladron, C., Aguiar, J. M., Carro, B., Sanchez-Esguevillas, A. J., Lloret, J., & Massana, J. (2014). A survey on electric power demand forecasting: Future trends in smart grids, microgrids and smart buildings. *IEEE Communications Surveys and Tutorials*, 16(3), 1460–1495. <https://doi.org/10.1109/SURV.2014.032014.00094>

Hosenuzzaman, M., Rahim, N. A., Selvaraj, J., Hasanuzzaman, M., Malek, A. B. M. A., & Nahar, A. (2015). Global prospects, progress, policies, and environmental impact of solar photovoltaic power generation. *Renewable and Sustainable Energy Reviews*, 41, 284–297. <https://doi.org/10.1016/j.rser.2014.08.046>

Hossain, M., Mekhilef, S., Danesh, M., Olatomiwa, L., & Shamshirband, S. (2017). Application of extreme learning machine for short term output power forecasting of three grid-connected PV systems. *Journal of Cleaner Production*, 167, 395-405. <https://doi.org/10.1016/j.jclepro.2017.08.081>

IEA (2024), Renewables 2023, IEA, Paris <https://www.iea.org/reports/renewables-2023>, Licence: CC BY 4.0

Inman, R. H., Pedro, H. T. C., & Coimbra, C. F. M. (2013). Solar forecasting methods for renewable energy integration. *Progress in Energy and Combustion Science*, 39(6), 535-576. <https://doi.org/10.1016/j.pecs.2013.06.002>

International Renewable Energy Agency. (2022). Renewable energy statistics 2022. Retrieved from <https://www.irena.org/publications/2022/Jul/Renewable-Energy-Statistics-2022>

International Renewable Energy Agency. (2023). Renewable energy statistics 2023. Retrieved from Renewable energy statistics 2023 (irena.org).

Jang, J. S. R., Sun, C. T., & Mizutani, E. (1997). *Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence*. Englewood Cliffs, NJ: Prentice-Hall.

Jensen, T. L., Fowler, T. L., Brown, B. G., Lazo, J. K., & Haupt, S. E. (2016). Metrics for evaluation of solar energy forecasts. *NCAR Technical Note (National Science Foundation, 2016)*, 1-60.

Kalooop, M. R., Bardhan, A., Kardani, N., Samui, P., Hu, J. W., & Ramzy, A. (2021). Novel application of adaptive swarm intelligence techniques coupled with adaptive network-based fuzzy inference system in predicting photovoltaic power. *Renewable and Sustainable Energy Reviews*, 148, 111315. <https://doi.org/10.1016/j.rser.2021.111315>

Kiran, T.R. and Rajput, S.P.S. (2011) An effectiveness model for an indirect evaporative cooling (IEC) system: Comparison of artificial neural networks (ANN),

adaptive neuro-fuzzy inference system (ANFIS) and fuzzy inference system (FIS) approach. *Applied Soft Computing*. Vol.11, no.4, 3525-3533.

Lai, J.-P., Chang, Y.-M., Chen, C.-H., & Pai, P.-F. (2020). A survey of machine learning models in renewable energy predictions. *Applied Sciences*, 10(17), 5975. <https://doi.org/10.3390/app10175975>

Lara-Cerecedo, L. O., Hinojosa, J. F., Pitalúa-Díaz, N., Matsumoto, Y., & González-Angeles, A. (2023). Prediction of the Electricity Generation of a 60-kW Photovoltaic System with Intelligent Models ANFIS and Optimized ANFIS-PSO. *Energies*, 16(16), 6050. <https://doi.org/10.3390/en16166050>

Lawan SM, Abidin WAWZ, Chai WY, Baharun A, Masri T. Different models of wind speed prediction: A comprehensive review. 2014;5(1)

Madlener, R., & Sunak, Y. (2011). Impacts of urbanization on urban structures and energy demand: What can we learn for urban energy planning and urbanization management? *Sustainable Cities and Society*, 1(1), 45–53. <https://doi.org/10.1016/j.scs.2010.08.006>

Mateo-Romero, H. F., Rosa, M. E. C. D., Hernández-Callejo, L., González-Rebollo, M. Á., Cardeñoso-Payo, V., Alonso-Gómez, V., ... & Gallardo-Saavedra, S. (2023, November). Estimation of the performance of Photovoltaic Cells by means of an Adaptative Neural Fuzzy Inference model. In *Ibero-American Congress of Smart Cities* (pp. 174-188). Cham: Springer Nature Switzerland.

Mesbahi, A.H., Semnani, D. and Khorasani, S.N. (2012) Performance prediction of a specific wear rate in epoxy nanocomposites with various composition content of polytetrafluoroethylen (PTFE), graphite, short carbon fibers (CF) and nano-TiO₂ using adaptive neuro-fuzzy inference system (ANFIS). *Composites Part B: Engineering*. Vol.43, no.2, 549-558

Mohanty, S., Patra, P. K., Mohanty, A., Harrag, A., & Rezk, H. (2022). Adaptive Neuro-Fuzzy Approach for Solar Radiation Forecasting in Cyclone Ravaged Indian

Cities: A Review. In *Frontiers in Energy Research* (Vol. 10). Frontiers Media S.A. <https://doi.org/10.3389/fenrg.2022.828097>

Mora-López, L., Martínez-Marchena, I., Piliouline, M., & Sidrach-Decardona, M. (2011). Machine learning approach for next day energy production forecasting in grid connected photovoltaic plants.

Muhammad Ibrahim, A., Muhammad Lawan, S., Abdulkadir, R., Sani Shuaibu, N., Uzair, M., Garba Indabawa, M., ... Mahmoud Aliyu, A. (2024). Solar Radiation Prediction Using an Improved Adaptive Neuro-Fuzzy Inference System (ANFIS) Optimization Ensemble. IntechOpen. Doi: 10.5772/intechopen.1003891

National Renewable Energy Laboratory. (2021). Solar Energy Basics. Retrieved from <https://www.nrel.gov>

ODRE. (n.d.). Monthly production curves for wind and solar energy with remuneration supplement [Data set]. Retrieved 20 December 2023 from <https://odre.opendatasoft.com/explore/dataset/courbes-de-production-mensuelles-eolien-solaire-complement-de-remuneration/information/?disjunctive.filiere>

Panapakidis, I. P., & Christoforidis, G. C. (2017). A hybrid ANN/GA/ANFIS model for very short-term PV power forecasting. In *2017 11th IEEE International Conference on Compatibility, Power Electronics and Power Engineering (CPE-POWERENG)*. <https://doi.org/10.1109/CPE.2017.7915207>

Patel, D., Patel, S., Patel, P., & Shah, M. (2022). Solar radiation and solar energy estimation using ANN and Fuzzy logic concept: A comprehensive and systematic study. *Environmental Science and Pollution Research*, 29, 32428–32442. <https://doi.org/10.1007/s11356-022-19185-z>

Pawar, N. (2022). Development of Photovoltaic Power Generation Prediction Model using ANFIS. *International Journal of Engineering and Management Research*, 12(4), 206-208. <https://doi.org/10.31033/ijemr.12.4.26>

Pedro, H. T. C., & Coimbra, C. F. M. (2012). Assessment of forecasting techniques for solar power production with no exogenous inputs. *Solar Energy*, 86(7), 2017-2028. <https://doi.org/10.1016/j.solener.2012.04.004>

Perveen, G., Anand, P., & Kumar, A. (2024). Application of ANN–ANFIS Model for Forecasting Solar Power. In M. A. Husain, M. W. Ahmad, F. I. Bakhsh, P. Sanjeevikumar, & H. Malik (Eds.), *Photovoltaic Systems Technology* (pp. 151-176). Scrivener Publishing LLC. <https://doi.org/10.1002/9781394167678.ch8>

Perveen, G., Rizwan, M., & Goel, N. (2019). An ANFIS-based model for solar energy forecasting and its smart grid application. *Engineering Reports*, 1(1), e12070. <https://doi.org/10.1002/eng2.12070>

Perveen, G., Rizwan, M., Goel, N., & Anand, P. (2020). Artificial neural network models for global solar energy and photovoltaic power forecasting over India. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*. <https://doi.org/10.1080/15567036.2020.1826017>

Phil, C. (2011). Solar energy perspectives. In 30th ISES Biennial Solar World Congress 2011, SWC 2011 (Vol. 1).

Pitalúa-Díaz, N., Arellano-Valmaña, F., Ruz-Hernandez, J. A., Matsumoto, Y., Alazki, H., Herrera-López, E. J., ... & Velázquez-Contreras, E. F. (2019). An ANFIS-based modeling comparison study for photovoltaic power at different geographical places in Mexico. *Energies*, 12(14), 2662.

Rajaguru, V., Vedanjali, N., & Rajasri, P. (2023). Solar forecasting for a PV-battery powered DC system. *Heliyon*, 9(10).

Rajasundrapandiyan, T., Kumaresan, K., Murugan, S., Subathra, M. S. P., & Sivakumar, M. (2023). Solar Energy Forecasting Using Machine Learning and Deep Learning Techniques. *Archives of Computational Methods in Engineering*, 30(3), 3059–3079. <https://doi.org/10.1007/s11831-023-09893-1>

Raza, M. Q., Nadarajah, M., & Ekanayake, C. (2016). On recent advances in PV output power forecast. *Solar Energy*, 136, 125-144.
<https://doi.org/10.1016/j.solener.2016.06.073>

Reitermanova, Z. Data splitting. In WDS; Matfyzpress: Prague, Czechia, 2010; Volume 10, pp. 31–36. ISBN 978-80-7378-139-2.

Ruz-Hernandez, J. A., Matsumoto, Y., Arellano-Valmaña, F., Pitalúa-Díaz, N., Cabanillas-López, R. E., Abril-García, J. H., ... & Velázquez-Contreras, E. F. (2019). Meteorological variables' influence on electric power generation for photovoltaic systems located at different geographical zones in Mexico. *applied sciences*, 9(8), 1649.

Sadrmomtazi, A., Sobhani, J. and Mirgozar, M.A. (2013) Modeling compressive strength of EPS lightweight concrete using regression, neural network and ANFIS. *Construction and Building Materials*. Vol.42, 205-216.

Shi, J., Lee, W. J., Liu, Y., Yang, Y., & Wang, P. (2012). Forecasting power output of photovoltaic systems based on weather classification and support vector machines. *IEEE Transactions on Industry Applications*, 48(3), 1064-1069.
<https://doi.org/10.1109/TIA.2012.2190816>

Singh, R., Kainthola, A. and Singh, T.N. (2012) Estimation of elastic constant of rocks using an ANFIS approach. *Applied Soft Computing*. Vol.12, no.1, 40-45

Sivaneasan, B., Yu, C. Y., & Goh, K. P. (2017). Solar Forecasting using ANN with Fuzzy Logic Pre-processing. *Energy Procedia*, 143, 727-732.
<https://doi.org/10.1016/j.egypro.2017.12.753>

Smirnova, E., Kot, S., Kolpak, E., & Shestak, V. (2021). Governmental support and renewable energy production: A cross-country review. *Energy*, 230, 120903.
<https://doi.org/10.1016/J.ENERGY.2021.120903>

Sobri, S., Koohi-Kamali, S., & Rahim, N. A. (2018). Solar photovoltaic generation forecasting methods: A review. *Energy Conversion and Management*, 156(November 2017), 459-497. <https://doi.org/10.1016/j.enconman.2017.11.019>

SolarPower Europe. (2023). 2023: A milestone year for renewable energy in Europe - Unveiling Ember's electricity review. Retrieved from <https://www.solarpowereurope.org/news/2023-a-milestone-year-for-renewable-energy-in-europe-unveiling-ember-s-electricity-review>

Sujidha, M. P., kanthan Bharthi, S. L., Devi, M. S., Manjula, A., & Usha, M. A. An Implementation ANFIS Controller based GMPPT for Photovoltaic Systems.

Sugeno, M. and Kang, G.T. (1988) Structure identification of fuzzy models. *Fuzzy Sets and Systems*. Vol.28, no.1, 15-33

Takami, T. and Sugeno, M. (1985) Fuzzy identification of systems and its applications to modelling and control. *IEEE Transactions on Systems, Man and Cybernetics*. Vol.15, no.1. 116-132

Talei, A., Chye Chua, L.H and Wong, T.S.W. (2010) Evaluation of rainfall and discharge inputs used by Adaptive Network-based Fuzzy Inference Systems (ANFIS) in rainfall–runoff modelling. *Journal of Hydrology*. Vol.391, no.3-4, 248-263

Tan, Z., Quek C. and Cheng, P.Y.K. (2011) Stock trading with cycles: A financial application of ANFIS and reinforcement learning. *Expert Systems with Applications*. Vol.38, no.5, 4741-4755.

Tao, H.; Al-Sulttani, A.O.; Salih Ameen, A.M.; Ali, Z.H.; Al-Ansari, N.; Salih, S.Q.; Mostafa, R.R. Training, and testing data division influence on hybrid machine learning model process: Application of river flow forecasting. *Complexity* 2020, 2020, 8844367. [CrossRef]

Tay, J. and Zhang, X. (1999) Neural Fuzzy Modeling of Anaerobic Biological Wastewater Treatment Systems. Journal of Environmental Engineering. Vol.125, no.12, 1149-1159.

Teke A, Ba H, Çelik Ö. Evaluation and performance comparison of different models for the estimation of solar radiation. 2015;50:1097-1107. DOI: 10.1016/j.rser.2015.05.049

The European Commission , "Digital Green Certificate," European Commission, (2021). Retrieved online on 16 June 2024.

The Kyoto Protocol - Status of Ratification | UNFCCC. (n.d.). Retrieved June 5, 2024, from <https://unfccc.int/process/the-kyoto-protocol/status-of-ratification>

United Nations (1998). Kyoto protocol of the United Nations Framework Convention on Climate Change.

United Nations, Department of Economic and Social Affairs, P. D. (2018). The World 's Cities in 2018. The World's Cities in 2018 - Data Booklet (ST/ESA/SER.A/417), 34.

United Nations, Department of Economic and Social Affairs. (2018). 2018 revision of world urbanization prospects. Retrieved from <https://www.un.org/development/desa/en/news/population/2018-revision-of-world-urbanization-prospects.html>

United Nations. (2015). Framework Convention on Climate Change: Adoption of the Paris Agreement. In 21st Conference of the Parties.

Voudris, A.V. (2006), Analysis and forecast of the capsize bulk carriers shipping market using Artificial Neural Networks. Thesis (S.M. in Ocean Systems Management. Massachusetts Institute of Technology. Dept. of Mechanical Engineering.

Viswavandya, M., Sarangi, B., Mohanty, S., & Mohanty, A. (2019). An ANFIS-based model for solar energy forecasting and its smart grid application. In H. S.

Behera, J. K. Mandal, & D. P. Mohapatra (Eds.), *Computational Intelligence in Data Mining* (pp. 751-765). Springer. https://doi.org/10.1007/978-981-13-8676-3_63

Vrigazova, B. The proportion for splitting data into training and test set for the bootstrap in classification problems. *Bus. Syst. Res. Int. J. Soc. Adv. Innov. Res. Econ.* 2021, 12, 228–242. [CrossRef]

Wanb, J., Huanga, M., Maa,Y., Guoa, W., Zhangc, H., Lia W, Sun,X. (2011) Prediction of effluent quality of a paper mill wastewater treatment using an adaptive network-based fuzzy inference system. *Applied Soft Computing*. Vol.11, no.3, 3238–3246

Wang L et al. Prediction of solar radiation in China using different adaptive neuro-fuzzy methods and M5 model tree. *International Journal of Climatology*. 2017;37(3):1141-1155. DOI: 10.1002/joc.4762

World energy consumption by energy source 2050 | Statista. (n.d.). Retrieved January 15, 2021, from <https://www.statista.com/statistics/222066/projected-global-energy-consumption-by-source/>

Yadav, H. K., Pal, Y., & Tripathi, M. M. (2019). PSO-tuned ANFIS model for short-term photovoltaic power forecasting. *International Journal of Recent Technology and Engineering*, 7(6S), 937-942.

Yang, H. T., Huang, C. M., Huang, Y. C., & Pai, Y. S. (2014). A weather-based hybrid method for 1-day ahead hourly forecasting of PV power output. *IEEE Transactions on Sustainable Energy*, 5(3), 917-926. <https://doi.org/10.1109/TSTE.2014.2313600>

Yang, X., Ren, J., & Yue, H. (2016). Photovoltaic power forecasting with a rough set combination method. In *2016 UKACC International Conference on Control, UKACC Control 2016*. <https://doi.org/10.1109/CONTROL.2016.7737652>

Yaseen, Zaher & Ramal, Majeed & Diop, Lamine & Jaafar, Othman & Demir, Vahdettin & Kisi, Ozgur. (2018). Hybrid Adaptive Neuro-Fuzzy Models for Water

Quality Index Estimation. Water Resources Management. 32. 1-19.
10.1007/s11269-018-1915-7.


Zhang, H.; Zhang, L.; Jiang, Y. Overfitting and underfitting analysis for deep learning based end-to-end communication systems. In Proceedings of the 2019 11th International Conference on Wireless Communications and Signal Processing (WCSP), Xi'an, China, 23–25 October 2019; pp. 1–6. [CrossRef]

Κεφάλαιο 11: Παραρτήματα

11.1 Μπεϊσιανά (Bayesian) Δίκτυα

Τα μπεϊσιανά δίκτυα, γνωστά και ως δίκτυα Bayes, μοντέλο Bayes ή πιθανολογικά κατευθυνόμενα άκυκλα γραφικά μοντέλα, αποτελούν έναν τύπο στατιστικών μοντέλων (πιθανολογικά γραφικά μοντέλα) που αναπαριστούν μια ομάδα τυχαίων μεταβλητών και τις υποθετικές εξαρτήσεις τους μέσω ενός κατευθυνόμενου άκυκλου γραφήματος (Directed Acyclic Graph, DAG). Για παράδειγμα, ένα Bayesian δίκτυο μπορεί να αναπαριστά τις πιθανολογικές σχέσεις μεταξύ μιας ασθένειας και των συμπτωμάτων της. Με δεδομένα τα συμπτώματα, το δίκτυο μπορεί να χρησιμοποιηθεί για τον υπολογισμό των πιθανοτήτων ύπαρξης διαφόρων ασθενειών.

Το ακόλουθο παράδειγμα ενός Bayesian δικτύου δείχνει πώς η βροχή επηρεάζει το αν το ποτιστικό θα είναι ανοιχτό και πώς η βροχή και το ποτιστικό μαζί επηρεάζουν την κατάσταση του γκαζόν, δηλαδή αν θα είναι βρεγμένο.



Εικόνα 59: Παράδειγμα Μπεϊσιανού Δικτύου

11.2 T-Νόρμες

Στα μαθηματικά, οι T-νόρμες (συντομογραφία του «Τριγωνικές Νόρμες») αποτελούν ένα είδος δυαδικής λειτουργίας που χρησιμοποιείται κυρίως στην ασαφή λογική. Μια T-νόρμα γενικεύει τη λειτουργία τομής σε ένα πλέγμα και συμβάλλει στη γενίκευση της λογικής, η οποία αποτελεί βασική επιδίωξη των ασαφών συστημάτων συμπερασμού.