



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ**

**ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ**

**ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ**

**ΠΡΟΛΗΠΤΙΚΗ ΣΥΝΤΗΡΗΣΗ ΦΩΤΟΒΟΛΤΑΪΚΩΝ ΜΕ ΤΕΧΝΗΤΗ  
ΝΟΗΜΟΣΥΝΗ**

Διπλωματική Εργασία

**ΚΑΡΥΔΗ ΣΤΑΜΑΤΙΑ**

Επιβλέπουσα

Δασκαλοπούλου Ασπασία

Ιούνιος 2025





**ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ**

**ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ**

**ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ**

**ΠΡΟΛΗΠΤΙΚΗ ΣΥΝΤΗΡΗΣΗ ΦΩΤΟΒΟΛΤΑΪΚΩΝ ΜΕ ΤΕΧΝΗΤΗ  
ΝΟΗΜΟΣΥΝΗ**

Διπλωματική Εργασία


**ΚΑΡΥΔΗ ΣΤΑΜΑΤΙΑ**

Επιβλέπουσα

Δασκαλοπούλου Ασπασία

Ιούνιος 2025





**UNIVERSITY OF THESSALY**

**SCHOOL OF ENGINEERING**

**DEPARTMENT OF ELECTRICAL AND COMPUTER ENGINEERING**

**PREVENTIVE MAINTENANCE OF PVs USING AI**

Diploma Thesis

**KARYDI STAMATIA**

Supervisor

Daskalopulu Aspassia

June 2025



Εγκρίνεται από την Επιτροπή Εξέτασης:

Επιβλέπουσα

**Δασκαλοπούλου Ασπασία**

Αναπληρώτρια Καθηγήτρια, Τμήμα Ηλεκτρολόγων Μηχανικών και  
Μηχανικών Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

Μέλος

**Μπαργιώτας Δημήτριος**

Καθηγητής, Τμήμα Ηλεκτρολόγων Μηχανικών και  
Μηχανικών Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

Μέλος

**Χροναίος Αλέξανδρος**

Καθηγητής, Τμήμα Ηλεκτρολόγων Μηχανικών και Μηχανικών  
Υπολογιστών, Πανεπιστήμιο Θεσσαλίας





## **ΥΠΕΥΘΥΝΗ ΔΗΛΩΣΗ ΠΕΡΙ ΑΚΑΔΗΜΑΪΚΗΣ ΔΕΟΝΤΟΛΟΓΙΑΣ ΚΑΙ ΠΝΕΥΜΑΤΙΚΩΝ ΔΙΚΑΙΩΜΑΤΩΝ**

Με πλήρη επίγνωση των συνεπειών του νόμου περί πνευματικών δικαιωμάτων, δηλώνω ρητά ότι η παρούσα διπλωματική εργασία, καθώς και τα ηλεκτρονικά αρχεία και πηγαίοι κώδικες που αναπτύχθηκαν ή τροποποιήθηκαν στα πλαίσια αυτής της εργασίας, αποτελούν αποκλειστικά προϊόν προσωπικής μου εργασίας, δεν προσβάλλουν οποιασδήποτε μορφής δικαιώματα διανοητικής ιδιοκτησίας, προσωπικότητας και προσωπικών δεδομένων τρίτων, δεν περιέχουν έργα/εισφορές τρίτων για τα οποία απαιτείται άδεια των δημιουργών/δικαιούχων και δεν είναι προϊόν μερικής ή ολικής αντιγραφής, οι πηγές δε που χρησιμοποιήθηκαν περιορίζονται στις βιβλιογραφικές αναφορές και μόνον και πληρούν τους κανόνες της επιστημονικής παράθεσης. Τα σημεία όπου έχω χρησιμοποιήσει ιδέες, κείμενο, αρχεία ή/και πηγές άλλων συγγραφέων αναφέρονται ευδιάκριτα στο κείμενο με την κατάλληλη παραπομπή και η σχετική αναφορά περιλαμβάνεται στο τμήμα των βιβλιογραφικών αναφορών με πλήρη περιγραφή. Δηλώνω επίσης ότι τα αποτελέσματα της εργασίας δεν έχουν χρησιμοποιηθεί για την απόκτηση άλλου πτυχίου. Αναλαμβάνω πλήρως, ατομικά και προσωπικά, όλες τις νομικές και διοικητικές συνέπειες που δύναται να προκύψουν στην περίπτωση κατά την οποία αποδειχθεί, διαχρονικά, ότι η εργασία αυτή ή τμήμα της δεν μου ανήκει διότι είναι προϊόν λογοκλοπής.

Η Δηλούσα

Σταματία Καρύδη



## **DISCLAIMER ON ACADEMIC ETHICS AND INTELLECTUAL PROPERTY RIGHTS**

Being fully aware of the implications of copyright laws, I expressly state that this diploma thesis, as well as the electronic files and source codes developed or modified in the course of this thesis, are solely the product of my personal work and do not infringe any rights of intellectual property, personality and personal data of third parties, do not contain work / contributions of third parties for which the permission of the authors / beneficiaries is required and are not a product of partial or complete plagiarism, while the sources used are limited to the bibliographic references only and meet the rules of scientific citing. The points where I have used ideas, text, files and / or sources of other authors are clearly mentioned in the text with the appropriate citation and the relevant complete reference is included in the bibliographic references section. I also declare that the results of the work have not been used to obtain another degree. I fully, individually and personally undertake all legal and administrative consequences that may arise in the event that it is proven, in the course of time, that this thesis or part of it does not belong to me because it is a product of plagiarism.

The Declarant

Stamatia Karydi



## Ευχαριστίες

Ολοκληρώνοντας τη συγγραφή της διπλωματικής μου εργασίας, θα ήθελα να εκφράσω τις θερμές μου ευχαριστίες στην επιβλέπουσα καθηγήτριά μου, κυρία Ασπασία Δασκαλοπούλου, για την πολύτιμη καθοδήγηση, τη συνεχή υποστήριξη και τις εποικοδομητικές παρατηρήσεις της σε κάθε στάδιο της εργασίας. Η συμβολή της υπήρξε καθοριστική για την ολοκλήρωση της προσπάθειας αυτής.

Ευχαριστώ θερμά την οικογένεια μου για την διαρκή στήριξη και την αμέριστη ενθάρρυνση που μου πρόσφεραν σε κάθε στάδιο των σπουδών μου, καθώς και την αδερφή μου, για την συνεχή συμπαράσταση και την πίστη της στις δυνατότητες μου.

Τέλος, θα ήθελα να ευχαριστήσω τους φίλους μου για την κατανόηση, τη στήριξη και τις όμορφες στιγμές που μοιραστήκαμε καθ' όλη τη διάρκεια της φοιτητικής μου πορείας.



## ΠΡΟΛΗΠΤΙΚΗ ΣΥΝΤΗΡΗΣΗ ΦΩΤΟΒΟΛΤΑΪΚΩΝ ΜΕ ΤΕΧΝΗΤΗ

### ΝΟΗΜΟΣΥΝΗ

Καρύδη Σταματία

#### Περίληψη

Η αυξανόμενη σημασία των φωτοβολταϊκών συστημάτων για τη βιώσιμη ενεργειακή ανάπτυξη καθιστά επιτακτική την ανάγκη για νέες στρατηγικές συντήρησης, που θα διασφαλίζουν τη μακροχρόνια απόδοσή τους. Στο πλαίσιο αυτό, η προληπτική συντήρηση, με τη βοήθεια τεχνικών τεχνητής νοημοσύνης, προσφέρει νέες δυνατότητες για τον έγκαιρο εντοπισμό και την αποτροπή πιθανών δυσλειτουργιών. Η παρούσα διπλωματική εργασία διερευνά τη συμβολή της μηχανικής μάθησης στην προληπτική συντήρηση φωτοβολταϊκών, μέσα από μια ολοκληρωμένη μελέτη θεωρητικού και πρακτικού χαρακτήρα. Αρχικά, παρουσιάστηκαν τα βασικά χαρακτηριστικά των φωτοβολταϊκών συστημάτων, οι κύριοι τύποι βλαβών και οι υπάρχουσες μέθοδοι συντήρησης, με έμφαση στις δυνατότητες που προσφέρουν οι τεχνολογίες τεχνητής νοημοσύνης. Στη συνέχεια, αναπτύχθηκε πειραματικό μοντέλο, βασισμένο σε καθαρισμένα δεδομένα λειτουργίας, με στόχο την πρόβλεψη της ισχύος και τον εντοπισμό τεχνητών βλαβών μέσω τεχνικών ταξινόμησης. Δοκιμάστηκαν διαφορετικοί αλγόριθμοι (Logistic Regression, Random Forest, XGBoost) και μελετήθηκε η επίδραση της ανισορροπίας μεταξύ των φυσιολογικών και δυσλειτουργικών καταστάσεων μέσα από πειράματα με διαφορετικά ποσοστά βλαβών. Τα αποτελέσματα ανέδειξαν τη σημασία της ποιότητας και της σωστής αναλογίας δεδομένων στην απόδοση των μοντέλων και επιβεβαίωσαν ότι ακόμη και απλές τεχνικές μηχανικής μάθησης μπορούν να προσφέρουν αξιόπιστα εργαλεία έγκαιρης διάγνωσης σε φωτοβολταϊκά συστήματα. Παρά τους περιορισμούς που επιβάλλουν τα τεχνητά σενάρια βλαβών, η μελέτη αυτή παρέχει πολύτιμα συμπεράσματα και σταθερή βάση για μελλοντική έρευνα με χρήση πραγματικών δεδομένων λειτουργίας.

**Λέξεις-κλειδιά:**

Φωτοβολταϊκά Συστήματα, Ηλιακή Ενέργεια, Ανανεώσιμες Πηγές Ενέργειας, Προληπτική Συντήρηση, Ανίχνευση Βλαβών, Τεχνητή Νοημοσύνη, Μηχανική Μάθηση, Λογιστική Παλινδρόμηση, Καθαρισμός Δεδομένων, PVGIS, Python.



## **PREVENTIVE MAINTENANCE OF PVs USING AI**

Karydi Stamatia

### **Abstract**

The increasing importance of photovoltaic systems for sustainable energy development highlights the urgent need for new maintenance strategies to ensure their long-term performance. In this context, preventive maintenance, supported by artificial intelligence techniques, offers new possibilities for the timely detection and prevention of potential malfunctions. This thesis investigates the contribution of machine learning to the preventive maintenance of photovoltaic systems through a comprehensive theoretical and practical study. Initially, the fundamental characteristics of photovoltaic systems, the main types of faults, and the existing maintenance methods were presented, with an emphasis on the potential offered by artificial intelligence technologies. Subsequently, an experimental model was developed, based on cleaned operational data, aiming at power prediction and the detection of simulated faults through classification techniques. Different algorithms (Logistic Regression, Random Forest, XGBoost) were tested, and the impact of the imbalance between normal and faulty operating conditions was examined through experiments with different fault rates. The results highlighted the importance of data quality and proper class balance for model performance and confirmed that even simple machine learning techniques can provide reliable tools for early diagnosis in photovoltaic systems. Despite the limitations imposed by simulated fault scenarios, this study offers valuable insights and a solid foundation for future research using real-world operational data.

**Keywords:**

Photovoltaic Systems, Solar Energy, Renewable Energy Sources, Preventive Maintenance, Fault Detection, Artificial Intelligence, Machine Learning, Logistic Regression, Data Cleaning, PVGIS, Python.

## Πίνακας περιεχομένων

|                                                                                                    |              |
|----------------------------------------------------------------------------------------------------|--------------|
| <i>Ευχαριστίες .....</i>                                                                           | <i>xiii</i>  |
| <i>Περίληψη .....</i>                                                                              | <i>xv</i>    |
| <i>Abstract.....</i>                                                                               | <i>xvii</i>  |
| <i>Πίνακας περιεχομένων .....</i>                                                                  | <i>xix</i>   |
| <i>Κατάλογος εικόνων .....</i>                                                                     | <i>xxiii</i> |
| <i>Κατάλογος σχημάτων.....</i>                                                                     | <i>xxv</i>   |
| <i>Κατάλογος πινάκων .....</i>                                                                     | <i>xxvii</i> |
| <i>Συντομογραφίες.....</i>                                                                         | <i>xxix</i>  |
| <b>Κεφάλαιο 1 Εισαγωγή .....</b>                                                                   | <b>1</b>     |
| 1.1 Ενέργεια και η Αναγκαιότητα της Βιώσιμης Ανάπτυξης .....                                       | 1            |
| 1.2 Αντικείμενο της διπλωματικής.....                                                              | 3            |
| 1.2.1 Συνεισφορά.....                                                                              | 3            |
| 1.3 Οργάνωση του τόμου.....                                                                        | 4            |
| <b>Κεφάλαιο 2 Φωτοβολταϊκά Συστήματα.....</b>                                                      | <b>5</b>     |
| 2.1 Βασικές Αρχές Λειτουργίας.....                                                                 | 5            |
| 2.2 Δομή.....                                                                                      | 6            |
| 2.3 Κατηγοριοποίηση φωτοβολταϊκών Συστημάτων.....                                                  | 10           |
| 2.4 Βασικές Βλάβες και Σφάλματα .....                                                              | 11           |
| 2.4.1 Εισαγωγή στα Προβλήματα Λειτουργίας των Φωτοβολταϊκών Συστημάτων.....                        | 11           |
| 2.4.2 Κατηγοριοποίηση των Βλαβών των Φωτοβολταϊκών Συστημάτων .....                                | 13           |
| 2.4.3 Ανάλυση Συγκεκριμένων Βλαβών στα Φωτοβολταϊκά Συστήματα.....                                 | 15           |
| 2.4.4 Κατηγοριοποίηση των Βλαβών με Βάση τα Επιμέρους Εξαρτήματα του Φωτοβολταϊκού Συστήματος..... | 21           |
| <b>Κεφάλαιο 3 Συντήρηση Φωτοβολταϊκών Συστημάτων.....</b>                                          | <b>25</b>    |
| 3.1 Εισαγωγή στη Συντήρηση των Φωτοβολταϊκών Συστημάτων .....                                      | 25           |

|                                                                                    |                  |
|------------------------------------------------------------------------------------|------------------|
| <b>3.2 Κατηγορίες Συντήρησης .....</b>                                             | <b>26</b>        |
| 3.2.1 Διορθωτική Συντήρηση .....                                                   | 26               |
| 3.2.2 Προληπτική Συντήρηση .....                                                   | 27               |
| 3.2.3 Προβλεπτική Συντήρηση .....                                                  | 29               |
| <b>3.3 Μέθοδοι και Τεχνολογίες Συντήρησης.....</b>                                 | <b>31</b>        |
| 3.3.1 Μέθοδοι Ανίχνευσης και Διάγνωσης Βλαβών.....                                 | 31               |
| 3.3.2 Τεχνικές Πρόληψης Βλαβών στα Φωτοβολταϊκά Συστήματα .....                    | 38               |
| 3.3.3 Τεχνικές Μετριάσμου των Βλαβών στα Φωτοβολταϊκά Συστήματα .....              | 40               |
| <b>3.4 Προκλήσεις και Περιορισμοί στη Συντήρηση Φωτοβολταϊκών .....</b>            | <b>40</b>        |
| <b><i>Κεφάλαιο 4 Χρήση της Τεχνητής Νοημοσύνης στη Συντήρηση Φωτοβολταϊκών</i></b> |                  |
| <b><i>Συστημάτων .....</i></b>                                                     | <b><i>43</i></b> |
| <b>4.1 Εισαγωγή στην Τεχνητή Νοημοσύνη και τα Υποσύνολά της.....</b>               | <b>43</b>        |
| 4.1.1 Μηχανική Μάθηση .....                                                        | 44               |
| 4.1.2 Βαθιά μάθηση .....                                                           | 45               |
| <b>4.2 Θεμελιώδεις Τεχνολογίες Βασικές Εφαρμογές .....</b>                         | <b>46</b>        |
| 4.2.1 Ανίχνευση Βλαβών.....                                                        | 47               |
| 4.2.2 Πρόβλεψη Βλαβών .....                                                        | 58               |
| 4.2.3 Βελτιστοποίηση Απόδοσης .....                                                | 62               |
| <b>4.3 Προκλήσεις και Περιορισμοί της Χρήσης της ΑΙ.....</b>                       | <b>63</b>        |
| <b><i>Κεφάλαιο 5 Πειραματικό Μέρος.....</i></b>                                    | <b><i>66</i></b> |
| <b>5.1 Περιγραφή και προέλευση δεδομένων .....</b>                                 | <b>66</b>        |
| <b>5.2 Εργαλεία και Περιβάλλον Εργασίας .....</b>                                  | <b>68</b>        |
| <b>5.3 Καθαρισμός Δεδομένων με βάση τη Μεθοδολογία DQRs .....</b>                  | <b>69</b>        |
| <b>5.4 Εκπαίδευση Μοντέλου Πρόβλεψης Ισχύος (Reference Model) .....</b>            | <b>74</b>        |
| 5.4.1 Δεδομένα και μεταβλητές.....                                                 | 75               |
| 5.4.2 Επιλογή Μεθοδολογίας .....                                                   | 75               |
| 5.4.3 Διαδικασία Εκπαίδευσης .....                                                 | 76               |
| 5.4.4 Αποτελέσματα και αξιολόγηση .....                                            | 77               |
| 5.4.5 Εξαγωγή Γραμμικής Σχέσης Πρόβλεψης.....                                      | 78               |
| 5.4.6 Συμπέρασμα.....                                                              | 79               |
| <b>5.5 Δημιουργία Τεχνικών Βλαβών και προεπεξεργασία για ταξινόμηση .....</b>      | <b>79</b>        |
| <b>5.6 Εκπαίδευση Μοντέλου Πρόβλεψης Βλαβών (Logistic Regression) .....</b>        | <b>81</b>        |

|                                                                                           |            |
|-------------------------------------------------------------------------------------------|------------|
| 5.7 Σύγκριση Αλγορίθμων Πρόβλεψης Βλαβών .....                                            | 83         |
| 5.8 Πειράματα με Εναλλακτικά Ποσοστά Βλαβών .....                                         | 85         |
| 5.9 Εφαρμογή στην Προληπτική Συντήρηση.....                                               | 87         |
| <b>Κεφάλαιο 6 Συμπεράσματα και Μελλοντικές Κατευθύνσεις .....</b>                         | <b>89</b>  |
| 6.1 Σύνοψη και συμπεράσματα.....                                                          | 89         |
| 6.2 Μελλοντικές κατευθύνσεις .....                                                        | 90         |
| <b>Βιβλιογραφία.....</b>                                                                  | <b>93</b>  |
| <b>Παράρτημα Α – Κώδικας Python για το πειραματικό μέρος.....</b>                         | <b>100</b> |
| A.1 Καθαρισμός και Προεπεξεργασία Δεδομένων με τη Μεθοδολογία DQRs (Python Code)<br>..... | 100        |
| A.2 Κώδικας Python για την Εκπαίδευση Μοντέλου Πρόβλεψης Ισχύος (Βήμα 1).....             | 102        |
| A.3 Δημιουργία τεχνητών βλαβών και προεπεξεργασία για ταξινόμηση .....                    | 104        |
| A.4 Εκπαίδευση Μοντέλου Λογιστικής Παλινδρόμησης (Logistic Regression).....               | 105        |
| A.5 Εκπαίδευση Μοντέλου Random Forest και XGBoost.....                                    | 106        |
| A.6 Δημιουργία Τεχνητών Βλαβών με Εναλλακτικά Ποσοστά (5% και 10%) .....                  | 109        |



## Κατάλογος εικόνων

|                                                                                                                                                                                                                                                                                                                                                                                               |                                     |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------|
| Εικόνα 1: Λειτουργία φωτοβολταϊκού στοιχείου: η ηλιακή ακτινοβολία παράγει ρεύμα στη διεπαφή τύπου p-n [5] .....                                                                                                                                                                                                                                                                              | 5                                   |
| Εικόνα 2: Από το ηλιακό κύτταρο στις παράλληλες διατάξεις πάνελ για παραγωγή ενέργειας [9].....                                                                                                                                                                                                                                                                                               | 7                                   |
| Εικόνα 3: Τύποι φωτοβολταϊκών συστημάτων [4].....                                                                                                                                                                                                                                                                                                                                             | 11                                  |
| Εικόνα 4: Τύποι ταξινόμησης των ηλιακών φωτοβολταϊκών συστημάτων [12] .....                                                                                                                                                                                                                                                                                                                   | 14                                  |
| Εικόνα 5: Θερμά σημεία (Hot Spots) σε φωτοβολταϊκά πάνελ [18].....                                                                                                                                                                                                                                                                                                                            | 17                                  |
| Εικόνα 6: Επίδραση σκίασης στη λειτουργία των φωτοβολταϊκών κυψελών: πλήρης, μερική και καθόλου απόδοση [19].....                                                                                                                                                                                                                                                                             | 18                                  |
| Εικόνα 7: Τύποι ρωγμών σε φωτοβολταϊκές κυψέλες: Είδη και προσανατολισμός των ρωγμών που επηρεάζουν την απόδοση [4] .....                                                                                                                                                                                                                                                                     | 19                                  |
| Εικόνα 8: Συσσώρευση χιονιού και πάγου σε φωτοβολταϊκά πάνελ: (Α) χιόνι στο κάτω μέρος των πάνελ, (Β) πάγος στην επιφάνεια, (C) προστατευτική δομή αποφυγής επικάλυψης [20] .....                                                                                                                                                                                                             | 19                                  |
| Εικόνα 9: Φαινόμενα υποβάθμισης φωτοβολταϊκών πάνελ: (α) αποκόλληση υλικών, (b) αποχρωματισμός εγκλειστικών υλικών, (c) τοπικές αλλοιώσεις επιφάνειας [21].....                                                                                                                                                                                                                               | 20                                  |
| Εικόνα 11: Θερμογραφική απεικόνιση φωτοβολταϊκού πάνελ με ανίχνευση θερμού σημείου (hotspot), υποδεικνύοντας πιθανή αστοχία ή υποβάθμιση [29] . <b>Error! Bookmark not defined.</b>                                                                                                                                                                                                           |                                     |
| Εικόνα 12: Ηλεκτροφωταύγεια (EL) για την αξιολόγηση φωτοβολταϊκών κυψελών [30] .....                                                                                                                                                                                                                                                                                                          | <b>Error! Bookmark not defined.</b> |
| Εικόνα 13: Καμπύλες ρεύματος-τάσης (I-V) και ισχύος-τάσης (P-V) . Οι κύκλοι υποδεικνύουν τις βασικές ηλεκτρικές παραμέτρους: το ρεύμα βραχυκυκλώματος ( $I_{sc}$ ), την τάση ανοικτού κυκλώματος ( $V_{oc}$ ) και το σημείο μέγιστης ισχύος ( $P_{max}$ ), οι οποίες χρησιμοποιούνται για την αξιολόγηση της απόδοσης του συστήματος και την ανίχνευση πιθανών αποκλίσεων ή βλαβών [29] ..... | 37                                  |

|                                                                                                                                                                                                                                           |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Εικόνα 14: Επιλογή τοποθεσίας και παραμέτρων συστήματος στο περιβάλλον του PVGIS για εξαγωγή ωριαίων δεδομένων παραγωγής ισχύος και περιβαλλοντικών μεταβλητών (έτος 2023, περιοχή Βόλου) .....                                           | 67 |
| Εικόνα 15: Διάγραμμα των 8 σταδίων της μεθοδολογίας DQRs (Data Quality Routines) για τον καθαρισμό και την προεπεξεργασία δεδομένων φωτοβολταϊκών, από τον αρχικό στατιστικό έλεγχο έως τη σύνοψη και επαλήθευση των δεδομένων [27] ..... | 70 |
| Εικόνα 16: Πίνακας Σύγχυσης για το μοντέλο Λογιστικής Παλινδρόμησης με εφαρμογή της τεχνικής SMOTE .....                                                                                                                                  | 82 |



## Κατάλογος σχημάτων

|                                                                                                                                                                                                                |                                     |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------|
| Σχήμα 1: Εξέλιξη της παραγωγής ηλεκτρικής ενέργειας από ανανεώσιμες πηγές παγκοσμίως (2000-2022) [1] .....                                                                                                     | <b>Error! Bookmark not defined.</b> |
| Σχήμα 2: Αριθμός δημοσιεύσεων που σχετίζονται με τις κύριες βλάβες στα φωτοβολταϊκά συστήματα. [Πηγή: Προσαρμοσμένο από το άρθρο [4]] .....                                                                    | 16                                  |
| Σχήμα 3: Ποσοστιαία κατανομή των δημοσιεύσεων ανά τύπο βλάβης στα φωτοβολταϊκά συστήματα. [Πηγή: Προσαρμοσμένο από το άρθρο [4]] .....                                                                         | 16                                  |
| Σχήμα 4: Σχέση και διαφορές AI, ML και DL [12] .....                                                                                                                                                           | 44                                  |
| Σχήμα 5: Σύγκριση πραγματικής και προβλεπόμενης ισχύος. Η διακεκομμένη γραμμή αναπαριστά την ιδανική πρόβλεψη, ενώ τα σημεία δείχνουν τις προβλέψεις του μοντέλου γραμμικής παλινδρόμησης .....                | 78                                  |
| Σχήμα 6: Βασική ροή λειτουργίας ενός συστήματος προγνωστικής συντήρησης: ανίχνευση απόκλισης από το μοντέλο, αποστολή ειδοποίησης, τεχνικός έλεγχος και – εφόσον χρειάζεται – προγραμματισμένη συντήρηση ..... | 87                                  |



## Κατάλογος πινάκων

|                                                                                                                                                                                                                        |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Πίνακας 1: Σύγκριση βασικών τύπων φωτοβολταϊκών συστημάτων .....                                                                                                                                                       | 9  |
| Πίνακας 2: Σύγκριση Διορθωτικής, Προληπτικής και Προβλεπτικής Συντήρησης .....                                                                                                                                         | 30 |
| Πίνακας 3: Σύγκριση τεχνικών τεχνητής νοημοσύνης για την ανίχνευση ελαττωμάτων σε φωτοβολταϊκά συστήματα, με αξιολόγηση της αποδοτικότητάς τους σε θερμικές εικόνες, καμπύλες I-V και διάφορους τύπους σφαλμάτων ..... | 56 |
| Πίνακας 4: Περιγραφικά Στατιστικά των Ωριαίων Δεδομένων μετά τον Καθαρισμό (DQRs) .....                                                                                                                                | 73 |
| Πίνακας 5: Αποτελέσματα αξιολόγησης αλγορίθμων πρόβλεψης βλαβών .....                                                                                                                                                  | 83 |
| Πίνακας 6: Αποτελέσματα αξιολόγησης του μοντέλου Λογιστικής Παλινδρόμησης για τρία διαφορετικά ποσοστά τεχνητών βλαβών (5%, 8%, 10%) .....                                                                             | 86 |



## Συντομογραφίες

|       |                                              |                                                      |
|-------|----------------------------------------------|------------------------------------------------------|
| ANN   | Artificial Neural Network                    | Τεχνητό Νευρωνικό Δίκτυο                             |
| BBN   | Bayesian Belief Network                      | Δίκτυα Μπεϋζιανής Πεποίθησης                         |
| CBM   | Condition-Based Maintenance                  | Συντήρηση βάσει Κατάστασης                           |
| CNN   | Convolutional Neural Network                 | Συνελικτικό Νευρωνικό Δίκτυο                         |
| DL    | Deep Learning                                | Βαθιά Μάθηση                                         |
| DNNs  | Deep Neural Networks                         | Βαθιά Νευρωνικά Δίκτυα                               |
| DQRs  | Data Quality Routines                        | Ρουτίνες Ποιότητας Δεδομένων                         |
| DSS   | Decision Support System                      | Σύστημα Υποστήριξης Αποφάσεων                        |
| DT    | Decision Trees                               | Δέντρα Απόφασης                                      |
| FDD   | Fault Detection and Diagnosis                | Ανίχνευση και Διάγνωση Βλαβών                        |
| FL    | Fuzzy Logic                                  | Ασαφής Λογική                                        |
| IoT   | Internet of Things                           | Διαδίκτυο των Πραγμάτων                              |
| LR    | Logistic Regression                          | Λογιστική Παλινδρόμηση                               |
| LSTM  | Long Short-Term Memory                       | Μακροχρόνια Βραχυπρόθεσμη Μνήμη                      |
| MAPE  | Mean Absolute Percentage Error               | Μέσο Απόλυτο Ποσοστιαίο Σφάλμα                       |
| ML    | Machine Learning                             | Μηχανική Μάθηση                                      |
| PDM   | Predictive Maintenance                       | Συντήρηση βάσει Πρόγνωσης                            |
| PR    | Performance Ratio                            | Απόδοση Συστήματος                                   |
| PVGIS | Photovoltaic Geographical Information System | Γεωγραφικό Σύστημα Πληροφοριών Φωτοβολταϊκών         |
| Q&M   | Operation & Maintenance                      | Λειτουργία και Συντήρηση                             |
| RF    | Random Forest                                | Τυχαίο Δάσος                                         |
| RNN   | Recurrent Neural Networks                    | Αναδρομικά Νευρωνικά Δίκτυα                          |
| SMOTE | Synthetic Minority Over-sampling Technique   | Τεχνική Συνθετικής Δειγματοληψίας Μειονοτικής Κλάσης |
| SVM   | Support Vector Machine                       | Μηχανή Διανυσμάτων Στήριξης                          |
| ΑΠΕ   | Renewable Energy Sources                     | Ανανεώσιμες Πηγές Ενέργειας                          |
| TN    | Artificial Intelligence                      | Τεχνητή Νοημοσύνη                                    |

Φ/B – PV    Photovoltaic

Φωτοβολταϊκό

xxx

# Κεφάλαιο 1 Εισαγωγή

## 1.1 Ενέργεια και η Αναγκαιότητα της Βιώσιμης Ανάπτυξης


Η ενέργεια αποτελεί βασικό στοιχείο της καθημερινότητάς μας, καθώς επηρεάζει ουσιαστικά την οικονομική, κοινωνική και περιβαλλοντική μας πορεία. Χρησιμοποιείται για τη θέρμανση των κατοικιών μας, τις μεταφορές, τη βιομηχανική παραγωγή και την ηλεκτροπαραγωγή. Με την παγκοσμιοποίηση και την αυξανόμενη ζήτηση ενέργειας, δημιουργούνται ολοένα και πιο πολύπλοκα προβλήματα – από την εξάντληση των παραδοσιακών ενεργειακών πηγών έως τις σοβαρές περιβαλλοντικές επιπτώσεις.

Παραδοσιακά, η ανθρωπότητα στηριζόταν στα ορυκτά καύσιμα για την παραγωγή ενέργειας. Σήμερα, όμως, έχει γίνει εμφανής η στροφή προς τις ανανεώσιμες πηγές ενέργειας (ΑΠΕ), οι οποίες θεωρούνται βιώσιμη και περιβαλλοντικά φιλική εναλλακτική. Οι ΑΠΕ, όπως η ηλιακή και η αιολική ενέργεια, προσφέρουν πηγές ενέργειας ανεξάντλητες, ενισχύοντας την ενεργειακή μας αυτονομία και περιορίζοντας την ανάγκη για εισαγωγές καυσίμων, υπό προϋποθέσεις.

Η στροφή στις Ανανεώσιμες Πηγές Ενέργειας δεν ωφελεί μόνο το περιβάλλον, αλλά συμβάλλει και στην οικονομική ανάπτυξη. Η αυξανόμενη ζήτηση για καθαρές μορφές ενέργειας δημιουργεί νέες επενδυτικές ευκαιρίες, προσελκύοντας κεφάλαια σε καινοτόμες τεχνολογίες, όπως τα προηγμένα φωτοβολταϊκά υλικά, οι έξυπνες ενεργειακές υποδομές και οι λύσεις αποθήκευσης ενέργειας. Αυτό δημιουργεί ευκαιρίες για επενδύσεις και ανάπτυξη στον ενεργειακό τομέα, ενισχύοντας την τεχνολογική πρόοδο και την ενεργειακή αυτονομία

Αξιοποιώντας τις ανανεώσιμες πηγές ενέργειας, μπορούμε επίσης να μειώσουμε την εξάρτησή μας από τα εισαγόμενα καύσιμα, όπως το πετρέλαιο. Χώρες όπως η Ελλάδα, που διαθέτουν πλούσιες φυσικές πηγές, μπορούν να αξιοποιήσουν τον ήλιο και τον άνεμο για να ενισχύσουν την ενεργειακή τους αυτονομία, μειώνοντας τις διακυμάνσεις στο κόστος της ενέργειας και θωρακίζοντας την οικονομία απέναντι στις αυξομειώσεις των τιμών στις διεθνείς αγορές.

Όπως φαίνεται στο Σχήμα 1, η παγκόσμια παραγωγή ηλεκτρικής ενέργειας από ανανεώσιμες πηγές αυξήθηκε από 2,846 TWh το 2000 σε 8,440 TWh το 2022, με το μερίδιο των μεταβλητών ΑΠΕ (αιολική και ηλιακή) να φτάνει το 40,2% της συνολικής παγκόσμιας παραγωγής. Αυτή η αύξηση αποδεικνύει τη δυναμική ανάπτυξη των ανανεώσιμων πηγών ενέργειας σε διεθνές επίπεδο και τη σημαντική συμβολή τους στη βιώσιμη ανάπτυξη.



Σχήμα 1: Εξέλιξη της παραγωγής ηλεκτρικής ενέργειας από ανανεώσιμες πηγές παγκοσμίως (2000-2022) [1]

Η ηλιακή ενέργεια έχει αναδειχθεί σε πρωταγωνιστή στον τομέα των ΑΠΕ, καθώς η τεχνολογία των φωτοβολταϊκών συστημάτων (Φ/Β) (photovoltaic systems – PV) εξελίσσεται ραγδαία. Στην Ελλάδα, η αφθονία ηλιοφάνειας έχει οδηγήσει σε εκτεταμένη εγκατάσταση φωτοβολταϊκών συστημάτων, συμβάλλοντας στην ενέργεια που προέρχεται από καθαρές πηγές. Σύμφωνα με πρόσφατα στοιχεία, το 2023 το 19% της ηλεκτρικής ενέργειας της χώρας προήλθε από φωτοβολταϊκά, κατατάσσοντάς την στη δεύτερη θέση παγκοσμίως σε αυτόν τον τομέα [2]. Αυτά τα στοιχεία καταδεικνύουν τη ραγδαία άνοδο της ηλιακής ενέργειας στη χώρα μας και τη σημαντική συμβολή της στην ενεργειακή μετάβαση.

Καθώς όλο και περισσότερα φωτοβολταϊκά συστήματα εγκαθίστανται, η ανάγκη για σωστή και αποδοτική συντήρηση γίνεται κρίσιμη για τη διασφάλιση της μακροχρόνιας απόδοσής τους. Οι παραδοσιακές προσεγγίσεις συντήρησης, που εστιάζουν στην αντιδραστική αντιμετώπιση βλαβών, έχουν περιορισμένη αποδοτικότητα και συχνά οδηγούν σε απώλειες ενέργειας και αυξημένο κόστος. Σε αυτό το πλαίσιο, η τεχνητή



νοημοσύνη (TN) έρχεται να προσφέρει νέες δυνατότητες για την προληπτική συντήρηση των φωτοβολταϊκών. Χρησιμοποιώντας τεχνικές όπως η μηχανική μάθηση και η ανάλυση μεγάλου όγκου δεδομένων, τα συστήματα μπορούν να εντοπίζουν έγκαιρα πιθανές δυσλειτουργίες, να προβλέπουν μελλοντικά προβλήματα και να συμβάλουν στη βελτιστοποίηση της απόδοσης του εξοπλισμού.

## 1.2 Αντικείμενο της διπλωματικής

Η παρούσα διπλωματική εργασία εστιάζει στη διερεύνηση της εφαρμογής τεχνικών τεχνητής νοημοσύνης για την προληπτική συντήρηση φωτοβολταϊκών συστημάτων. Στόχος είναι η ανάπτυξη ενός πλαισίου που θα επιτρέπει την έγκαιρη ανίχνευση αποκλίσεων από τη φυσιολογική λειτουργία, συμβάλλοντας στην αποφυγή αστοχιών και στη βελτιστοποίηση της απόδοσης των συστημάτων. Ειδικότερα, η εργασία επικεντρώνεται στη δημιουργία ενός μοντέλου μηχανικής μάθησης ικανού να προβλέπει πιθανές βλάβες με βάση ιστορικά περιβαλλοντικά και ενεργειακά δεδομένα, με σκοπό την υποστήριξη αποφάσεων συντήρησης. Η επιλογή του συγκεκριμένου αντικείμενου προέκυψε από την ανάγκη αξιοποίησης νέων τεχνολογιών στη συντήρηση φωτοβολταϊκών, σε συνδυασμό με το έλλειμμα διαθέσιμων πραγματικών δεδομένων από λειτουργούντα συστήματα.

### 1.2.1 Συνεισφορά

Η συνεισφορά της εργασίας συνοψίζεται στα εξής:

1. **Μελετήθηκε** η διεθνής και ελληνική βιβλιογραφία αναφορικά με την λειτουργία και τις βασικές βλάβες των φωτοβολταϊκών, τις σύγχρονες μεθόδους συντήρησης και τη χρήση της τεχνητής νοημοσύνης στον τομέα της προληπτικής συντήρησης.
2. **Συλλέχθηκαν και καθαρίστηκαν** δεδομένα πεδίου από το εργαλείο PVGIS, μέσω της πλατφόρμας Anakoda, εφαρμόζοντας τη μεθοδολογία DQRs για την εξασφάλιση της ποιότητάς τους.
3. **Αναπτύχθηκε μοντέλο πρόβλεψης ισχύος** (reference model) με γραμμική παλινδρόμηση, ώστε να οριστεί η φυσιολογική λειτουργία του συστήματος βάσει περιβαλλοντικών μεταβλητών.

4. **Δημιουργήθηκαν τεχνητές βλάβες** ώστε να εκπαιδευτούν μοντέλα πρόβλεψης που διακρίνουν μεταξύ φυσιολογικής λειτουργίας και δυσλειτουργίας, προσομοιώνοντας σενάρια με ανισόρροπες κατηγορίες.
5. **Δοκιμάστηκαν και συγκρίθηκαν** τρεις αλγόριθμοι ταξινόμησης (Logistic Regression, Random Forest και XGBoost) με στόχο την επιλογή του καταλληλότερου για έγκαιρη ανίχνευση πιθανών αποκλίσεων.
6. **Πραγματοποιήθηκε επιπλέον πειραματική αξιολόγηση** με διαφορετικά ποσοστά τεχνητών βλαβών (5%, 8%, 10%), προκειμένου να διερευνηθεί η επίδραση της αναλογίας μεταξύ φυσιολογικής και προβληματικής λειτουργίας στην απόδοση των μοντέλων ταξινόμησης.
7. **Εφαρμόστηκε το τελικό μοντέλο** στο πλαίσιο ενός συστήματος προληπτικής συντήρησης, αποδεικνύοντας τη δυνατότητα αξιοποίησης προσεγγίσεων μηχανικής μάθησης για την ενίσχυση της απόδοσης και της αξιοπιστίας φωτοβολταϊκών εγκαταστάσεων.

### 1.3 Οργάνωση του τόμου

Ο παρών τόμος αποτελείται από έξι κεφάλαια. Στο Κεφάλαιο 1 εισάγεται το γενικό πλαίσιο της έρευνας, περιγράφεται το αντικείμενο και η συνεισφορά της εργασίας. Το Κεφάλαιο 2 εστιάζει στα φωτοβολταϊκά συστήματα, παρουσιάζοντας την λειτουργία τους και τις συνήθεις βλάβες που μπορεί να εμφανιστούν. Στο Κεφάλαιο 3 εξετάζονται οι τεχνικές συντήρησης, με έμφαση στην προληπτική και προγνωστική συντήρηση. Το Κεφάλαιο 4 επικεντρώνεται στην τεχνητή νοημοσύνη και τη συμβολή της στη διαχείριση της συντήρησης των φωτοβολταϊκών. Στο Κεφάλαιο 5 αναλύεται το πειραματικό μέρος της εργασίας, το οποίο περιλαμβάνει τη συλλογή και επεξεργασία των δεδομένων, την εκπαίδευση μοντέλων και την αξιολόγηση των αποτελεσμάτων. Τέλος, στο Κεφάλαιο 6 συνοψίζονται τα βασικά συμπεράσματα και προτείνονται κατευθύνσεις για μελλοντική έρευνα.


## Κεφάλαιο 2 Φωτοβολταϊκά Συστήματα

### 2.1 Βασικές Αρχές Λειτουργίας

Το φαινόμενο των φωτοβολταϊκών ανακαλύφθηκε το 1839 από τον Γάλλο φυσικό Edmond Becquerel, ο οποίος διαπίστωσε ότι ορισμένα υλικά μπορούν να παράγουν ηλεκτρικό ρεύμα όταν εκτίθενται στο φως. Αυτή η ανακάλυψη αποτέλεσε τη βάση για την ανάπτυξη της σύγχρονης φωτοβολταϊκής τεχνολογίας. Η πρώτη πρακτική εφαρμογή έγινε το 1954 από τα Bell Labs με την ανάπτυξη ηλιακών κυψελών πυριτίου απόδοσης 6% [3].

Η λειτουργία των φωτοβολταϊκών συστημάτων βασίζεται στο φαινόμενο της φωτοβολταϊκής επίδρασης. Όταν η ηλιακή ακτινοβολία χτυπά τα ηλιακά κύτταρα ενός πάνελ, τα ηλεκτρόνια μέσα στο υλικό διεγείρονται και παράγουν ηλεκτρικό ρεύμα. Η διαδικασία αυτή γίνεται στη λεγόμενη επαφή τύπου PN, όπου τα ηλεκτρόνια μετακινούνται από την περιοχή τύπου n στην περιοχή τύπου p, δημιουργώντας τάση και ρεύμα [4], όπως φαίνεται και στην Εικόνα 1.

Το ενεργειακό χάσμα του υλικού, δηλαδή η ελάχιστη ενέργεια που απαιτείται για να φύγουν τα ηλεκτρόνια από τη θέση τους και να δημιουργήσουν ρεύμα, καθορίζει σε μεγάλο βαθμό πόσο αποδοτικά μπορεί το υλικό να μετατρέψει την ηλιακή ενέργεια σε ηλεκτρική. Αν το χάσμα είναι πολύ μικρό, το υλικό δεν μπορεί να απορροφήσει το φως αποτελεσματικά. Αν είναι πολύ μεγάλο, τα ηλεκτρόνια δεν διεγείρονται εύκολα. Έτσι, το ιδανικό ενεργειακό χάσμα επιτρέπει την απορρόφηση της σωστής ποσότητας ενέργειας, μεγιστοποιώντας την απόδοση του φωτοβολταϊκού συστήματος.




Εικόνα 1: Λειτουργία φωτοβολταϊκού στοιχείου: η ηλιακή ακτινοβολία παράγει ρεύμα στη διεπαφή τύπου p-n [5]

Τα βασικά μέρη ενός φωτοβολταϊκού συστήματος περιλαμβάνουν [6, 7]:

- **Φωτοβολταϊκά πάνελ (PV panels):** Αποτελούν το κεντρικό μέρος του συστήματος και είναι φτιαγμένα από ηλιακά κύτταρα, συνήθως κατασκευασμένα από πυρίτιο. Τα πάνελ συνδέονται μεταξύ τους για να σχηματίσουν συστοιχία η οποία συλλέγει την ηλιακή ακτινοβολία και την μετατρέπει σε ηλεκτρική ενέργεια.
- **Μετατροπείς (Inverters):** Μετατρέπουν το συνεχές ρεύμα (DC) που παράγεται από τα πάνελ σε εναλλασσόμενο ρεύμα (AC), το οποίο μπορεί να χρησιμοποιηθεί από ηλεκτρικές συσκευές ή να τροφοδοτηθεί στο δίκτυο.
- **Συστήματα αποθήκευσης:** Συνήθως περιλαμβάνουν μπαταρίες που αποθηκεύουν την παραγόμενη ενέργεια, εξασφαλίζοντας την τροφοδοσία σε περιόδους χαμηλής ηλιοφάνειας ή το βράδυ, ιδιαίτερα σε αυτόνομα ή υβριδικά συστήματα.
- **Καλωδιώσεις και άλλος εξοπλισμός:** Περιλαμβάνουν καλώδια, διακόπτες και άλλους μετατροπείς που εξασφαλίζουν την ομαλή λειτουργία και ασφάλεια του συστήματος.

## 2.2 Δομή

Η δημιουργία ενός φωτοβολταϊκού συστήματος ξεκινά από τα ηλιακά κύτταρα (solar cells), τα οποία είναι η βασική μονάδα που μετατρέπει την ηλιακή ακτινοβολία σε ηλεκτρική ενέργεια. Τα κύτταρα αυτά συνδυάζονται για να σχηματίσουν φωτοβολταϊκές μονάδες (PV modules), οι οποίες στη συνέχεια συγκροτούν τα φωτοβολταϊκά πάνελ. Τα πάνελ συνδέονται σε σειρά ώστε να αυξηθεί η τάση και έπειτα σε παράλληλες διατάξεις, προκειμένου να παραχθεί περισσότερη ηλεκτρική ενέργεια. Με αυτή τη διαδικασία, το σύστημα προσαρμόζεται εύκολα σε διαφορετικές ανάγκες, από μικρές οικιακές εγκαταστάσεις μέχρι μεγάλα έργα παραγωγής ενέργειας. Όπως φαίνεται στην Εικόνα 2, παρουσιάζεται η βασική δομή ενός φωτοβολταϊκού συστήματος, από το ηλιακό κύτταρο έως τις παράλληλες διατάξεις πάνελ.



Εικόνα 2: Από το ηλιακό κύτταρο στις παράλληλες διατάξεις πάνελ για παραγωγή ενέργειας [9]

Ένα από τα βασικά χαρακτηριστικά των υλικών που χρησιμοποιούνται στα φωτοβολταϊκά είναι το ενεργειακό χάσμα (band gap). Το ενεργειακό χάσμα ενός υλικού καθορίζει την ελάχιστη ενέργεια που απαιτείται για να διεγερθούν τα ηλεκτρόνιά του και να παραχθεί ηλεκτρικό ρεύμα. Το κατάλληλο εύρος του ενεργειακού χάσματος είναι κρίσιμο για την αποδοτική μετατροπή της ηλιακής ενέργειας σε ηλεκτρική, καθώς επηρεάζει άμεσα την ικανότητα του υλικού να απορροφά το φως. Αν το ενεργειακό χάσμα είναι πολύ μικρό, το υλικό απορροφά υπερβολικά μεγάλο εύρος φωτός, με αποτέλεσμα σημαντικές απώλειες ενέργειας. Αντίθετα, αν είναι πολύ μεγάλο, τα ηλεκτρόνια δεν διεγείρονται εύκολα, μειώνοντας την παραγωγή ρεύματος. Γι' αυτό, το ιδανικό ενεργειακό χάσμα κυμαίνεται συνήθως μεταξύ 1.1 eV και 1.7 eV, ώστε να επιτυγχάνεται η μέγιστη απόδοση του φωτοβολταϊκού συστήματος [4].

### Κύρια Υλικά Φωτοβολταϊκών [9]:

- **Μονοκρυσταλλικό Πυρίτιο:** Πρόκειται για το πιο αποδοτικό υλικό, με απόδοση που φτάνει το 24.2%. Είναι σταθερό, ανθεκτικό και χρησιμοποιείται κυρίως σε εφαρμογές υψηλών απαιτήσεων, όπως σε σπίτια και βιομηχανικές εγκαταστάσεις. Αν και η παραγωγή του είναι πιο ακριβή, παραμένει μια δημοφιλής επιλογή λόγω της ευρείας χρήσης του στην τεχνολογία.
- **Πολυκρυσταλλικό Πυρίτιο:** Έχει ελαφρώς χαμηλότερη απόδοση (19.2%) σε σχέση με το μονοκρυσταλλικό, αλλά είναι πιο οικονομικό και εύκολο στην παραγωγή. Είναι κατάλληλο για μεσαίας και μεγάλης κλίμακας εγκαταστάσεις.

- **Άμορφο Πυρίτιο:** Παρότι έχει χαμηλή απόδοση (13.4%) και φθείρεται γρήγορα, ξεχωρίζει για το χαμηλό του κόστος και την υψηλή απορροφητικότητα. Χρησιμοποιείται κυρίως σε μικρές εφαρμογές, όπως φορητές συσκευές.
- **Γάλλιο Αρσενικού:** Με κορυφαία απόδοση 28.8%, το υλικό αυτό είναι εξαιρετικά αποδοτικό και ανθεκτικό. Λόγω του υψηλού κόστους παραγωγής, χρησιμοποιείται κυρίως σε διαστημικές εφαρμογές και άλλες εξειδικευμένες χρήσεις.
- **Τελλουριούχο Κάδμιο:** Το CdTe είναι οικονομικό και αποδοτικό (21.5%), αλλά η χρήση του προκαλεί ανησυχίες λόγω της τοξικότητας του καδμίου. Παρόλα αυτά, είναι κατάλληλο για συνθήκες χαμηλού φωτισμού.
- **Οργανικά Υλικά και Κβαντικά Σημεία:** Αυτά τα πειραματικά υλικά, αν και έχουν χαμηλότερη απόδοση (έως 9.9%), προσφέρουν ευελιξία, δυνατότητα χρωματισμού και είναι ιδανικά για φορητές συσκευές ή αρχιτεκτονικές εφαρμογές.

## Τύποι Φωτοβολταϊκών Μονάδων

Οι φωτοβολταϊκές μονάδες κατηγοριοποιούνται σύμφωνα με την τεχνολογία και το υλικό κατασκευής τους, καθορίζοντας τα πλεονεκτήματα, τα μειονεκτήματα και τις ιδανικές εφαρμογές τους [4, 7].

1. **Οργανικές Φωτοβολταϊκές Μονάδες (OPV):** Κατασκευασμένες από οργανικά υλικά, προσφέρουν ευκαμψία και ελαφρύτητα, αλλά έχουν μικρότερη απόδοση (~11.5%) και διάρκεια ζωής. Κατάλληλες για φορητές συσκευές και καμπύλες επιφάνειες.
2. **Κρυσταλλικές Φωτοβολταϊκές Μονάδες:**
  - **Μονοκρυσταλλικές:** Υψηλή απόδοση (24.2%), μεγάλη διάρκεια ζωής, αλλά υψηλότερο κόστος παραγωγής.
  - **Πολυκρυσταλλικές:** Φθηνότερες και πιο εύκολες στην κατασκευή, με απόδοση 19.2%.
3. **Λεπτού Υμενίου (Thin-film):** Ευέλικτες και οικονομικές, με αποδόσεις 13.4%-21.5%. Κατάλληλες για ειδικές εφαρμογές, αλλά πιο ευάλωτες στις περιβαλλοντικές συνθήκες.

Για να κατανοήσουμε καλύτερα τις διάφορες τεχνολογίες φωτοβολταϊκών, στον Πίνακα 1 παρουσιάζεται σύγκριση των βασικών τύπων υλικών και συστημάτων, συνοψίζοντας τα στοιχεία που προαναφέρθηκαν σχετικά με την απόδοση, τα πλεονεκτήματα, τα μειονεκτήματα και τις εφαρμογές κάθε τύπου. Οι πληροφορίες αντλήθηκαν από τη διεθνή βιβλιογραφία και αναφορές όπως των [4, 7, 8, 10, 11]. Αυτή η συνοπτική παρουσίαση διευκολύνει την επιλογή της κατάλληλης τεχνολογίας, ανάλογα με τις ανάγκες κάθε περίπτωσης.

Πίνακας 1: Σύγκριση βασικών τύπων φωτοβολταϊκών συστημάτων

| Υλικό / Μονάδα          | Απόδοση     | Πλεονεκτήματα                                    | Μειονεκτήματα                                             | Εφαρμογές                                  |
|-------------------------|-------------|--------------------------------------------------|-----------------------------------------------------------|--------------------------------------------|
| Μονοκρυσταλλικό πυρίτιο | Έως 24.2%   | Υψηλή απόδοση, σταθερότητα, μεγάλη διάρκεια ζωής | Υψηλό κόστος παραγωγής                                    | Οικιακές/βιομηχανικές εγκαταστάσεις        |
| Πολυκρυσταλλικό πυρίτιο | Έως 19.2%   | Φθηνότερο, εύκολη κατασκευή                      | Ελαφρώς χαμηλότερη απόδοση                                | Μεσαίες και μεγάλες εγκαταστάσεις          |
| Άμορφο πυρίτιο          | Έως 13.4%   | Χαμηλό κόστος, υψηλή απορροφητικότητα            | Ταχεία υποβάθμιση, χαμηλή απόδοση                         | Μικρής κλίμακας εφαρμογές                  |
| Γάλλιο αρσενικού        | Έως 28.8%   | Εξαιρετική απόδοση, ανθεκτικότητα                | Υψηλό κόστος                                              | Διαστημικές εφαρμογές                      |
| Τελλουριούχο κάδμιο     | Έως 21.5%   | Χαμηλό κόστος παραγωγής, καλή απόδοση            | Τοξικότητα καδμίου                                        | Μεγάλες εγκαταστάσεις                      |
| Οργανικές (OPV)         | Έως 11.5%   | Ευκαμψία, χαμηλό κόστος, δυνατότητα χρωματισμού  | Χαμηλή απόδοση, ευαισθησία σε περιβαλλοντικούς παράγοντες | Φορετές συσκευές, καμπύλες επιφάνειες      |
| Thin-film               | 13.4%-21.5% | Ευέλικτες, ελαφριές                              | Ευαισθησία σε περιβαλλοντικές συνθήκες                    | Ειδικές εφαρμογές, ευμετάβλητες επιφάνειες |

## 2.3 Κατηγοριοποίηση φωτοβολταϊκών Συστημάτων

Τα φωτοβολταϊκά συστήματα διακρίνονται σε τρεις κύριους τύπους, ανάλογα με τον τρόπο λειτουργίας τους και τη σύνδεσή τους με το ηλεκτρικό δίκτυο: αυτόνομα, συνδεδεμένα στο δίκτυο και υβριδικά.


**Αυτόνομα συστήματα:** λειτουργούν ανεξάρτητα από το κεντρικό δίκτυο ηλεκτροδότησης και χρησιμοποιούνται κυρίως σε απομακρυσμένες περιοχές, όπως αγροικίες, ορεινά σπίτια ή μικρά νησιά, όπου δεν υπάρχει πρόσβαση στο δίκτυο. Λειτουργούν ανεξάρτητα και διαθέτουν μπαταρίες που αποθηκεύουν την παραγόμενη ενέργεια, με αποτέλεσμα να εξασφαλίζεται ρεύμα ακόμα και τη νύχτα ή σε μέρες με συννεφιά. Εκτός από μεγαλύτερες εφαρμογές, αυτά τα συστήματα χρησιμοποιούνται και σε μικρές συσκευές, όπως αριθμομηχανές και αυτόνομους αισθητήρες.

**Συνδεδεμένα στο δίκτυο συστήματα** είναι η πιο συνηθισμένη επιλογή στις πόλεις. Παρέχουν την ηλιακή ενέργεια απευθείας στο δίκτυο, μειώνοντας το κόστος της ηλεκτρικής ενέργειας. Σε περιπτώσεις όπου παράγεται περισσότερη ενέργεια από την κατανάλωση, η περίσσεια μπορεί να πωληθεί μέσω προγραμμάτων, όπως το net metering. Το πλεονέκτημά τους είναι ότι δεν χρειάζονται μπαταρίες, αφού το ίδιο το δίκτυο λειτουργεί σαν αποθηκευτικός χώρος.

**Υβριδικά συστήματα** συνδυάζουν τα χαρακτηριστικά των δύο προηγούμενων. Διαθέτουν μπαταρίες για αποθήκευση ενέργειας αλλά είναι και συνδεδεμένα στο δίκτυο, εξασφαλίζοντας αξιοπιστία και σταθερότητα. Είναι ιδανικά για περιοχές με συχνά προβλήματα ηλεκτροδότησης, καθώς προσφέρουν μεγαλύτερη ευελιξία και μικρότερη εξάρτηση από μία μόνο πηγή ενέργειας.

Όσον αφορά τη συντήρηση, κάθε τύπος συστήματος έχει διαφορετικές απαιτήσεις. Τα αυτόνομα χρειάζονται συχνότερη συντήρηση στις μπαταρίες, τα συνδεδεμένα επικεντρώνονται στη σωστή λειτουργία των πάνελ και των μετατροπέων, ενώ τα υβριδικά απαιτούν φροντίδα και για τις δύο πλευρές [12, 13]. Η συνολική ταξινόμηση των φωτοβολταϊκών συστημάτων, ανάλογα με τη σύνδεσή τους και τα επιμέρους χαρακτηριστικά, αποτυπώνεται σχηματικά στην Εικόνα 3.





Εικόνα 3: Τύποι φωτοβολταϊκών συστημάτων [4]

## 2.4 Βασικές Βλάβες και Σφάλματα

Στην ενότητα αυτή παρουσιάζονται οι βασικοί τύποι βλαβών και σφαλμάτων που μπορεί να εμφανιστούν σε φωτοβολταϊκά συστήματα, μαζί με τα κύρια αίτια που τα προκαλούν. Γίνεται αναφορά στην κατηγοριοποίησή τους ανάλογα με τη φύση, τον χρόνο και το σημείο εμφάνισης, καθώς και στις επιπτώσεις που έχουν στα επιμέρους εξαρτήματα. Σκοπός είναι να κατανοηθούν οι παράγοντες που επηρεάζουν τη λειτουργία και την απόδοση του συστήματος, ώστε να είναι δυνατή η έγκαιρη διάγνωση και η προληπτική αντιμετώπιση των προβλημάτων.

### 2.4.1 Εισαγωγή στα Προβλήματα Λειτουργίας των Φωτοβολταϊκών Συστημάτων

Η αποδοτικότητα και η ομαλή λειτουργία των φωτοβολταϊκών μπορεί να επηρεαστεί από διάφορες προκλήσεις που προκύπτουν κατά τη χρήση τους. Παρόλο που οι κατασκευαστές προσφέρουν εγγυήσεις που φτάνουν ή ξεπερνούν τα 20 χρόνια, υπάρχουν αρκετοί παράγοντες που μπορεί να προκαλέσουν προβλήματα, είτε στο συνολικό σύστημα είτε σε μεμονωμένα εξαρτήματα. Οι κυριότεροι είναι οι εξής:

**Κλιματικές συνθήκες:** Ακραία καιρικά φαινόμενα, όπως υψηλές θερμοκρασίες, υγρασία και συσσώρευση σκόνης, μπορούν να επηρεάσουν την απόδοση και τη διάρκεια ζωής του συστήματος. Επιπλέον, έντονες καιρικές συνθήκες, όπως καταιγίδες, κεραυνοί, χαλάζι και ισχυροί άνεμοι, ενδέχεται να προκαλέσουν σοβαρές ζημιές, συμπεριλαμβανομένης της πλήρους διακοπής λειτουργίας του συστήματος. Σε τέτοιες περιπτώσεις, απαιτούνται

εκτεταμένες εργασίες επισκευής ή ακόμη και αντικατάσταση βασικών εξαρτημάτων, προκειμένου να αποκατασταθεί η λειτουργικότητα και η αποδοτικότητα του συστήματος.

**Εγκατάσταση:** Η σωστή εγκατάσταση των φωτοβολταϊκών συστημάτων είναι καθοριστικός παράγοντας για τη σωστή και αποδοτική λειτουργία τους. Παράγοντες όπως ο καιρός, η γεωγραφική θέση, η κλίση και ο προσανατολισμός των πάνελ επηρεάζουν σημαντικά την απόδοσή τους. Αν η εγκατάσταση δεν γίνει σωστά για παράδειγμα, αν τα πάνελ δεν ευθυγραμμιστούν σωστά, δεν στηριχθούν επαρκώς ή αν γίνει λάθος στη συνδεσμολογία, το σύστημα μπορεί να αποδίδει λιγότερο, να φθείρεται πιο γρήγορα και να κοστίζει περισσότερο στη συντήρηση. Επίσης, η χρήση εξοπλισμού που δεν είναι συμβατός ή η μη τήρηση των οδηγιών του κατασκευαστή μπορεί να μειώσει τη διάρκεια ζωής και την απόδοση του συστήματος.

**Κατασκευαστικά ελαττώματα:** Η ποιότητα κατασκευής των φωτοβολταϊκών πάνελ και των υπόλοιπων εξαρτημάτων τους, όπως οι αντιστροφείς, οι καλωδιώσεις και οι βάσεις στήριξης, παίζει πολύ σημαντικό ρόλο στη μακροχρόνια απόδοσή τους. Αν κατά την παραγωγή χρησιμοποιηθούν φθηνά υλικά, δεν γίνει σωστή στεγανοποίηση των κυψελών ή παρουσιαστούν μικρορωγμές και κακές κολλήσεις, το σύστημα μπορεί να φθαρεί πιο γρήγορα και να παράγει λιγότερη ενέργεια. Τέτοια προβλήματα μπορεί να οδηγήσουν σε θερμά σημεία (hotspots), άνιση κατανομή της ηλιακής ακτινοβολίας και απώλειες ρεύματος, που με τη σειρά τους επηρεάζουν αρνητικά την απόδοση του συστήματος.

**Σύνδεση στο δίκτυο:** Η σωστή σύνδεση των φωτοβολταϊκών στο ηλεκτρικό δίκτυο είναι πολύ σημαντική για τη μέγιστη αξιοποίηση της παραγόμενης ενέργειας. Αν η σύνδεση δεν γίνει σωστά ή αν οι μετατροπείς δεν ρυθμιστούν όπως πρέπει, μπορεί να υπάρξουν ενεργειακές απώλειες, προβλήματα στην τάση και στη συχνότητα και γενικότερη αστάθεια στο δίκτυο. Επίσης, οι αλλαγές στον καιρό και τυχόν βλάβες του συστήματος μπορεί να προκαλέσουν διακυμάνσεις στην παραγωγή, δημιουργώντας επιπλέον προβλήματα. Ένα σωστά συνδεδεμένο σύστημα που παρακολουθείται τακτικά μπορεί να εξασφαλίσει καλύτερη απόδοση και λιγότερες απώλειες.

Οι λόγοι που μπορεί να οδηγήσουν σε δυσλειτουργίες των φωτοβολταϊκών συστημάτων μπορούν να χωριστούν σε τέσσερις βασικούς τομείς:

**Σχεδίαση:** Περιλαμβάνει λάθη στον αρχικό σχεδιασμό, όπως η ακατάλληλη τοποθέτηση των πάνελ ή η χρήση ασύμβατων εξαρτημάτων, καθώς και εσφαλμένοι υπολογισμοί απόδοσης που δεν λαμβάνουν υπόψη τις πραγματικές συνθήκες.

**Εγκατάσταση:** Η κακή τοποθέτηση των πάνελ μπορεί να προκαλέσει μηχανικές καταπονήσεις και απώλειες ενέργειας. Επιπλέον, λανθασμένες συνδέσεις ή υποστηρίξεις μπορεί να οδηγήσουν σε προβλήματα υπερθέρμανσης και ηλεκτρικές βλάβες.

**Λειτουργία:** Η έλλειψη σωστής διαχείρισης της παραγόμενης ενέργειας μπορεί να προκαλέσει αστάθεια στην απόδοση του συστήματος, ενώ η απουσία συνεχούς παρακολούθησης δυσκολεύει την έγκαιρη αντιμετώπιση προβλημάτων.


**Συντήρηση:** Η έλλειψη τακτικής συντήρησης μπορεί να οδηγήσει στη συσσώρευση ρύπων στα πάνελ και σε φθορές με την πάροδο του χρόνου. Παράλληλα, η ανεπαρκής επιθεώρηση των ηλεκτρονικών μερών, όπως οι μετατροπείς και οι καλωδιώσεις, μπορεί να προκαλέσει διακοπές στη λειτουργία.

Αυτοί οι παράγοντες δεν επηρεάζουν μόνο τους κατασκευαστές και τους τεχνικούς εγκατάστασης, αλλά και τους τελικούς χρήστες, οι οποίοι συχνά βασίζονται σε εξωτερικούς φορείς για την επιθεώρηση και τη συντήρηση των συστημάτων τους. Αυτό μπορεί να οδηγήσει σε αυξημένα κόστη και αβεβαιότητα σχετικά με την απόδοση της επένδυσής τους. [14, 15]

#### 2.4.2 Κατηγοριοποίηση των Βλαβών των Φωτοβολταϊκών Συστημάτων

Οι βλάβες που μπορεί να προκύψουν στα φωτοβολταϊκά συστήματα μπορούν να χωριστούν σε διάφορες κατηγορίες, ανάλογα με τη φύση τους, τη χρονική διάρκεια εμφάνισής τους και το σημείο στο οποίο εντοπίζονται. Η κατανόηση αυτών των βλαβών είναι σημαντική για να εξασφαλίσουμε ότι το σύστημα λειτουργεί σωστά, αποδίδει στο μέγιστο και διαρκεί όσο δυνατόν περισσότερα χρόνια.

Στην Εικόνα 4 παρουσιάζονται οι βασικοί τύποι ταξινόμησης των βλαβών στα φωτοβολταϊκά συστήματα. Συγκεκριμένα, οι βλάβες διακρίνονται με βάση τη φύση τους (φυσικές, ηλεκτρικές, περιβαλλοντικές), τον χρόνο εμφάνισης (προσωρινές, μόνιμες, εξελισσόμενες) και το σημείο στο οποίο εντοπίζονται (πάνελ, ηλεκτρονικά ισχύος, περιφερειακά εξαρτήματα). Παρακάτω αναλύονται αυτές οι κατηγορίες λεπτομερέστερα:



Εικόνα 4: Τύποι ταξινόμησης των ηλιακών φωτοβολταϊκών συστημάτων [12]

**Κατηγοριοποίηση με βάση τη φύση των βλαβών:** Οι βλάβες στα φωτοβολταϊκά συστήματα χωρίζονται σε τρεις βασικές κατηγορίες ανάλογα με τη φύση τους: φυσικές, ηλεκτρικές και περιβαλλοντικές [12]. Οι φυσικές βλάβες περιλαμβάνουν προβλήματα όπως ρωγμές, διάβρωση και αποχρωματισμό των πάνελ, που μπορούν να επηρεάσουν τη δομή τους και να μειώσουν την ικανότητά τους να απορροφούν την ηλιακή ακτινοβολία. Οι ηλεκτρικές βλάβες σχετίζονται με δυσλειτουργίες στα κυκλώματα συνεχούς (DC) και εναλλασσόμενου ρεύματος (AC), όπως βραχυκυκλώματα ή ανοιχτές συνδέσεις, που μπορούν να επηρεάσουν σημαντικά τη λειτουργία του συστήματος. Τέλος, οι περιβαλλοντικές βλάβες, όπως η μερική σκίαση, τα hotspots και η άνιση κατανομή της ηλιακής ακτινοβολίας, οδηγούν σε ενεργειακές απώλειες και χαμηλότερη απόδοση του συστήματος.

**Κατηγοριοποίηση με βάση τον χρόνο εμφάνισης:** Οι βλάβες στα φωτοβολταϊκά συστήματα μπορεί να είναι προσωρινές, μόνιμες ή να εξελίσσονται σταδιακά με τον χρόνο. Οι προσωρινές βλάβες, όπως η συγκέντρωση σκόνης ή η σκίαση από γύρω αντικείμενα, επηρεάζουν προσωρινά την απόδοση και αντιμετωπίζονται εύκολα με καθαρισμό ή μικρές παρεμβάσεις συντήρησης. Οι μόνιμες βλάβες, όπως τα βραχυκυκλώματα και οι αστοχίες υλικών, απαιτούν πιο δραστικές λύσεις, όπως αντικατάσταση εξαρτημάτων. Οι βλάβες που εξελίσσονται με τον χρόνο, όπως η φυσική γήρανση των κυψελών, επιδεινώνονται σταδιακά και χρειάζονται έγκαιρη διάγνωση και προληπτική συντήρηση [13].

**Κατηγοριοποίηση με βάση το σημείο εμφάνισης:** Οι βλάβες στα φωτοβολταϊκά συστήματα μπορούν να εντοπιστούν σε τρία βασικά σημεία: στα πάνελ, στα ηλεκτρονικά ισχύος και στα περιφερειακά εξαρτήματα. Οι βλάβες στα πάνελ συνήθως περιλαμβάνουν φθορές όπως ρωγμές και θερμά σημεία, που προκύπτουν από περιβαλλοντικές συνθήκες και τη φυσική καταπόνηση. Στα ηλεκτρονικά ισχύος, όπως οι μετατροπείς (inverters) και οι ρυθμιστές φόρτισης, μπορεί να εμφανιστούν ηλεκτρικά προβλήματα που επηρεάζουν τη ροή και τη διαχείριση της ενέργειας. Τέλος, τα περιφερειακά εξαρτήματα, όπως καλώδια, συνδέσεις και βάσεις στήριξης, είναι κρίσιμα για τη σταθερότητα του συστήματος και απαιτούν τακτικό έλεγχο για να διασφαλιστεί η απρόσκοπτη λειτουργία του [12].

#### 2.4.3 Ανάλυση Συγκεκριμένων Βλαβών στα Φωτοβολταϊκά Συστήματα


Αφού έχουμε ήδη κάνει μια γενική αναφορά στις βλάβες που μπορεί να παρουσιαστούν στα φωτοβολταϊκά συστήματα, τώρα θα δούμε πιο αναλυτικά τις πιο σημαντικές από αυτές. Σύμφωνα με τη βιβλιογραφία [4, 13, 16, 17], οι βλάβες στα φωτοβολταϊκά συστήματα μπορούν να επηρεάσουν την απόδοσή τους με διαφορετικούς τρόπους. Ορισμένοι εξωτερικοί παράγοντες, όπως η σκίαση και η συσσώρευση ρύπων, καθώς και θέματα κατασκευής και ηλεκτρικών μερών, έχουν μελετηθεί εκτενώς ως αιτίες που μειώνουν την απόδοση και τη διάρκεια ζωής των συστημάτων.

Η ανάγκη για έγκαιρη διάγνωση και αποτελεσματική αντιμετώπιση αυτών των προβλημάτων έχει γίνει ευρέως αποδεκτή με αποτέλεσμα η μελέτη των βλαβών των φωτοβολταϊκών συστημάτων να προσελκύει ολοένα και περισσότερο το ενδιαφέρον της επιστημονικής κοινότητας. Στα διαγράμματα που ακολουθούν (Σχήμα 2, Σχήμα 3) φαίνεται ξεκάθαρα η αυξανόμενη τάση στις σχετικές επιστημονικές δημοσιεύσεις, γεγονός που δείχνει πόσο σημαντική έχει γίνει η ανάγκη για βαθύτερη κατανόηση και αποτελεσματική αντιμετώπιση των προβλημάτων αυτών.


Σύμφωνα με ανάλυση που βασίζεται σε δεδομένα από μεγάλες επιστημονικές βάσεις, όπως SCOPUS, Web of Science, IEEE Xplore και ScienceDirect, οι πιο μελετημένες βλάβες αφορούν τη διάβρωση και την απόθεση χιονιού, με τις δημοσιεύσεις για αυτά τα θέματα να έχουν διπλασιαστεί την τελευταία δεκαετία. Αξιοσημείωτο είναι ότι το φαινόμενο της

ρύπανσης των πάνελ (soiling) καταγράφει τη μεγαλύτερη αύξηση ενδιαφέροντος, καθώς οι σχετικές δημοσιεύσεις έχουν επταπλασιαστεί.

Όπως παρουσιάζεται στο Σχήμα 2, ο συνολικός αριθμός που αφορούν βλάβες και φθορές στα φωτοβολταϊκά συστήματα παρουσιάζει συνεχή αύξηση, ενώ το Σχήμα 3 δείχνει τη σχετική αναλογία μελετών ανά τύπο βλάβης, με τη διάβρωση να αποτελεί τον πιο μελετημένο παράγοντα.



Σχήμα 2: Αριθμός δημοσιεύσεων που σχετίζονται με τις κύριες βλάβες στα φωτοβολταϊκά συστήματα. [Πηγή: Προσαρμοσμένο από το άρθρο [4]]




Σχήμα 3: Ποσοστιαία κατανομή των δημοσιεύσεων ανά τύπο βλάβης στα φωτοβολταϊκά συστήματα. [Πηγή: Προσαρμοσμένο από το άρθρο [4]]

### Θερμά Σημεία (Hot Spots)

Τα θερμά σημεία είναι ένα από τα πιο σοβαρά προβλήματα που μπορεί να εμφανιστούν στα φωτοβολταϊκά συστήματα. Προκαλούνται όταν οι κυψέλες ή τα πάνελ που είναι συνδεδεμένα σε σειρά δεν έχουν τις ίδιες ηλεκτρικές ιδιότητες. Αυτό μπορεί να συμβεί


λόγω σκίασης, ελαττωματικών κυψελών ή κακής συνδεσμολογίας. Όταν κάποιο τμήμα του πάνελ δεν λειτουργεί σωστά, το ρεύμα συνεχίζει να ρέει, με αποτέλεσμα η συγκεκριμένη περιοχή να υπερθερμαίνεται. Τα θερμά σημεία μπορούν να μειώσουν αισθητά την απόδοση του συστήματος, ενώ αν δεν αντιμετωπιστούν εγκαίρως, μπορεί να προκαλέσουν σοβαρές ζημιές ή ακόμα και κίνδυνο πυρκαγιάς. Στην Εικόνα 5 αποτυπώνεται χαρακτηριστικά η εμφάνιση τέτοιων θερμών σημείων (hot spots) μέσω θερμογραφικής απεικόνισης, όπου εντοπίζονται περιοχές με σημαντικά αυξημένη θερμοκρασία στις επιφάνειες των πάνελ.



Εικόνα 5: Θερμά σημεία (Hot Spots) σε φωτοβολταϊκά πάνελ [18]

### Σκίαση (Shading)

Η απόδοση των φωτοβολταϊκών συστημάτων εξαρτάται σε μεγάλο βαθμό από την ποσότητα της ηλιακής ακτινοβολίας που δέχονται. Οτιδήποτε εμποδίζει το φως, ακόμα κι αν πρόκειται για μία μόνο κυψέλη ή πάνελ, μπορεί να προκαλέσει μεγάλες διακυμάνσεις στην ισχύ και την τάση του συστήματος. Όταν ένα μέρος του πάνελ σκιάζεται, οι υπόλοιπες κυψέλες συνεχίζουν να παράγουν ενέργεια, γεγονός που μπορεί να δημιουργήσει θερμά σημεία, αφού η σκιασμένη περιοχή απορροφά θερμότητα αντί να την μετατρέπει σε ηλεκτρική ενέργεια. Στην Εικόνα 6 απεικονίζεται η επίδραση της σκίασης σε μια φωτοβολταϊκή κυψέλη: από πλήρως φωτισμένη (με μέγιστη απόδοση), σε μερικώς σκιασμένη (με μειωμένη ισχύ) και τελικά σε πλήρως σκιασμένη, όπου δεν υπάρχει καθόλου παραγωγή ρεύματος.



Εικόνα 6: Επίδραση σκίασης στη λειτουργία των φωτοβολταϊκών κυψελών: πλήρης, μερική και καθόλου απόδοση [19]

### Συσσώρευση Ρύπων (Soiling)


Η σκόνη, οι ρύποι, η γύρη και τα περιττώματα πτηνών που συγκεντρώνονται πάνω στα πάνελ είναι ένας από τους πιο συνηθισμένους λόγους που μειώνεται η απόδοση των φωτοβολταϊκών συστημάτων. Το πρόβλημα αυτό είναι πιο έντονο σε περιοχές με ξηρό κλίμα, όπου η σκόνη συσσωρεύεται εύκολα και εμποδίζει το φως του ήλιου να φτάσει στις κυψέλες. Αν και πρόκειται για ένα προσωρινό και αναστρέψιμο ζήτημα, η τακτική και σωστή συντήρηση είναι απαραίτητη για να διατηρείται η αποδοτικότητα του συστήματος στο μέγιστο επίπεδο.

### Ρωγμές (Cracks)

Οι ρωγμές είναι από τις πιο συχνές βλάβες που μπορεί να εμφανιστούν στα φωτοβολταϊκά πάνελ. Μπορεί να δημιουργηθούν είτε κατά τη μεταφορά και την εγκατάσταση είτε λόγω των καιρικών συνθηκών και της φυσικής φθοράς κατά τη διάρκεια της λειτουργίας τους. Συνήθως ξεκινούν σε μικρό μέγεθος και σταδιακά μεγαλώνουν, επηρεάζοντας την απόδοση των πάνελ και τη λειτουργία των κυψελών. Υπάρχουν διάφοροι τύποι ρωγμών, όπως οι δενδριτικές (dendritic), οι διαγώνιες, οι παράλληλες και κάθετες προς τους συλλέκτες ρεύματος (busbars), καθώς και οι ρωγμές πολλαπλών κατευθύνσεων. Στην Εικόνα 7 παρουσιάζονται οι βασικοί τύποι ρωγμών με βάση τον προσανατολισμό τους και τον τρόπο με τον οποίο επηρεάζουν τη λειτουργία των κυψελών. Κάθε τύπος ρωγμής έχει διαφορετική επίδραση στην ηλεκτρική απόδοση των κυψελών και μπορεί να οδηγήσει σε τοπική υπερθέρμανση (hot spots) ή ακόμα και σε πλήρη αστοχία των πάνελ. Οι τακτικοί




έλεγχοι είναι σημαντικοί, καθώς μπορούν να αποτρέψουν σοβαρότερες ζημιές και να εξασφαλίσουν την καλή λειτουργία του συστήματος.



Εικόνα 7: Τύποι ρωγμών σε φωτοβολταϊκές κυψέλες: Είδη και προσανατολισμός των ρωγμών που επηρεάζουν την απόδοση [4]

### Απόθεση Χιονιού και Πάγου (Snow and Ice Deposition)


Σε περιοχές με κρύο κλίμα, το χιόνι και ο πάγος που συγκεντρώνονται πάνω στα φωτοβολταϊκά πάνελ μπορούν να μειώσουν σημαντικά την απόδοσή τους, καθώς εμποδίζουν το ηλιακό φως να φτάσει στις κυψέλες. Εκτός από τη μειωμένη παραγωγή ενέργειας, η συσσώρευση αυτή μπορεί να προκαλέσει και μηχανικά προβλήματα, όπως ρωγμές και αποκόλληση των προστατευτικών στρωμάτων των πάνελ λόγω του βάρους και της συνεχούς διαστολής και συστολής από τις μεταβολές της θερμοκρασίας. Στην Εικόνα 8 παρουσιάζονται χαρακτηριστικά παραδείγματα τέτοιων φαινομένων.



Εικόνα 8: Συσσώρευση χιονιού και πάγου σε φωτοβολταϊκά πάνελ: (Α) χιόνι στο κάτω μέρος των πάνελ, (Β) πάγος στην επιφάνεια, (C) προστατευτική δομή αποφυγής επικάλυψης [20]

### Εξωτερικές Συνθήκες: Διάβρωση, Αποκόλληση και Υποβάθμιση (Outdoor Exposure: Corrosion, Delamination, and Degradation)

Τα φωτοβολταϊκά πάνελ βρίσκονται διαρκώς εκτεθειμένα στις εξωτερικές συνθήκες, κάτι που μπορεί να προκαλέσει βλάβες τόσο άμεσα όσο και με την πάροδο του χρόνου. Οι πιο συνηθισμένες μορφές φθοράς που σχετίζονται με την έκθεση στο περιβάλλον είναι η διάβρωση, η αποκόλληση των υλικών και η γενική υποβάθμιση των κυψελών, όπως φαίνεται στην Εικόνα 9.



Εικόνα 9: Φαινόμενα υποβάθμισης φωτοβολταϊκών πάνελ: (a) αποκόλληση υλικών, (b) αποχρωματισμός εγκλειστικών υλικών, (c) τοπικές αλλοιώσεις επιφάνειας [21]

Η διάβρωση είναι ένα σοβαρό ζήτημα, ειδικά σε περιοχές με υψηλή υγρασία ή κοντά στη θάλασσα, όπου το αλάτι και οι ρύποι της ατμόσφαιρας επιταχύνουν τη φθορά. Επηρεάζει τόσο τα κρυσταλλικά όσο και τα πάνελ λεπτού υμενίου, μειώνοντας τη διαφάνεια του προστατευτικού υλικού και μειώνοντας έτσι την απόδοσή τους.

Η αποκόλληση (delamination) συμβαίνει όταν το προστατευτικό στρώμα των πάνελ δεν προσκολλάται σωστά στις φωτοευαίσθητες κυψέλες, επιτρέποντας στην υγρασία να εισχωρήσει και να προκαλέσει περαιτέρω διάβρωση. Δυστυχώς, η αποκόλληση είναι συνήθως μη αναστρέψιμη και μπορεί να επηρεάσει σοβαρά τη λειτουργία του συστήματος.

Η γενική υποβάθμιση περιλαμβάνει φθορές όπως ο αποχρωματισμός των πάνελ, η εμφάνιση φυσαλίδων και η σταδιακή μείωση της απόδοσης λόγω της συνεχούς έκθεσης στην ηλιακή ακτινοβολία και στις καιρικές συνθήκες. Παρόλο που η υποβάθμιση εξελίσσεται αργά, απαιτεί τακτικούς ελέγχους και προληπτική συντήρηση για να διατηρηθεί η αποδοτικότητα του συστήματος.

#### 2.4.4 Κατηγοριοποίηση των Βλαβών με Βάση τα Επιμέρους Εξαρτήματα του Φωτοβολταϊκού Συστήματος

Αφού εξετάσαμε τους κύριους τύπους βλαβών που μπορεί να εμφανιστούν στα φωτοβολταϊκά συστήματα, όπως οι ρωγμές, τα θερμά σημεία, η σκίαση και η διάβρωση, είναι εξίσου σημαντικό να δούμε πώς αυτές επηρεάζουν τα επιμέρους εξαρτήματα του συστήματος όπως το προστατευτικό γυαλί, το υλικό εγκλεισμού, τα φωτοβολταϊκά κύτταρα, η πίσω μεμβράνη, το κιβώτιο συνδέσεων και οι δίοδοι παράκαμψης καθώς η απόδοση και η μακροχρόνια λειτουργία ενός φωτοβολταϊκού συστήματος εξαρτάται από τη σωστή λειτουργία όλων των βασικών του στοιχείων [22].

##### **Προστατευτικό Γυαλί**

Ρωγμές και θραύση: Το γυαλί μπορεί να υποστεί ρωγμές ή να σπάσει, ιδιαίτερα κατά τη μεταφορά και την εγκατάσταση, εάν δεν ακολουθούνται οι σωστές διαδικασίες χειρισμού. Οι μηχανικές καταπονήσεις από λάθος στερέωση ή υπερβολική πίεση στη δομή όπως και οι ακραίες καιρικές συνθήκες (χαλάζι και απότομες διακυμάνσεις της θερμοκρασίας) αυξάνουν τον κίνδυνο θραύσης, θέτοντας σε κίνδυνο τη συνολική λειτουργία του πάνελ.

Μείωση διαπερατότητας: Η διαπερατότητα του γυαλιού είναι καθοριστική για τη σωστή απορρόφηση της ηλιακής ακτινοβολίας από τις κυψέλες. Παράγοντες όπως η συγκέντρωση σκόνης, η υγρασία και η παρατεταμένη έκθεση σε υπεριώδη ακτινοβολία μπορούν να μειώσουν σταδιακά τη διαπερατότητά του, περιορίζοντας έτσι την ποσότητα φωτός που φτάνει στις κυψέλες και οδηγώντας σε απώλειες ενέργειας.

Θερμά σημεία (hotspots): Τυχόν μικροφθορές ή ατέλειες στο γυαλί μπορεί να προκαλέσουν θερμά σημεία. Αυτή η ανισορροπία μπορεί να δημιουργήσει προβλήματα στην απόδοση των κυψελών και να οδηγήσει σε φθορά των υλικών, ακόμα και σε σοβαρότερα ζητήματα, όπως η αποκόλληση της επικάλυψης ή ο κίνδυνος πυρκαγιάς. Τα θερμά σημεία συνήθως σχετίζονται με ελλιπή καθαρισμό ή μικρές ρωγμές στο γυαλί που δεν έχουν εντοπιστεί έγκαιρα.

##### **Το προστατευτικό υλικό εγκλεισμού στα φωτοβολταϊκά πάνελ**

Το υλικό εγκλεισμού (encapsulant) είναι απαραίτητο για την προστασία των ηλιακών κυψελών από εξωτερικούς παράγοντες, διατηρώντας τη διάρκεια ζωής των

φωτοβολταϊκών πάνελ. Παρόλο που τα σύγχρονα υλικά έχουν εξελιχθεί, η φθορά τους παραμένει ένας από τους βασικούς παράγοντες μείωσης της αποδοτικότητας των συστημάτων.

**Υποβάθμιση και φθορά:** Τα συνηθέστερα υλικά εγκλεισμού είναι το αιθυλένιο-οξικό βινύλιο (EVA), το πολυβινυλοβουτυράλη (PVB) και οι πολυολεφίνες (POE). Το EVA είναι η πιο οικονομική επιλογή, αλλά παρουσιάζει προβλήματα όπως αποχρωματισμό, αποκόλληση και διάβρωση των επαφών. Τα PVB και POE έχουν μεγαλύτερη αντοχή στη φθορά, αλλά είναι πιο ακριβά.

**Αποχρωματισμός και μείωση απόδοσης:** Η υπεριώδης ακτινοβολία και οι υψηλές θερμοκρασίες προκαλούν αποχρωματισμό του υλικού, μειώνοντας τη διαφάνειά του και περιορίζοντας την ποσότητα φωτός που φτάνει στις κυψέλες. Αυτό οδηγεί σε απώλειες απόδοσης, με μείωση του ρεύματος βραχυκύκλωσης (ISC) έως και 40%.

**Αποκόλληση και δημιουργία φυσαλίδων:** Η αποκόλληση του υλικού επιτρέπει στη υγρασία να εισχωρήσει, προκαλώντας διάβρωση των επαφών. Οι φυσαλίδες που σχηματίζονται κατά την πλαστικοποίηση δημιουργούν θερμά σημεία (hotspots), αυξάνοντας τη θερμοκρασία του πάνελ και προκαλώντας περαιτέρω βλάβες.

**Επιπτώσεις της υπεριώδους ακτινοβολίας:** Η υπεριώδης ακτινοβολία (UV), ιδιαίτερα η UV-B, διασπά τους πολυμερείς δεσμούς του EVA, επιταχύνοντας τη φθορά του υλικού. Σε συνδυασμό με υψηλή θερμοκρασία και υγρασία, προκαλεί αποχρωματισμό και απελευθέρωση οξικού οξέος, το οποίο συμβάλλει στη διάβρωση και στη μείωση της απόδοσης.

### **Οι ηλιακές κυψέλες στα φωτοβολταϊκά πάνελ**

Οι ηλιακές κυψέλες (solar cells) είναι το βασικό στοιχείο των φωτοβολταϊκών πάνελ, που μετατρέπει το ηλιακό φως σε ηλεκτρική ενέργεια. Συνδέονται σε σειρά και εγκλείονται με υλικά, όπως το EVA, για προστασία και πρόσφυση με το προστατευτικό γυαλί και λόγω της εύθραυστης φύσης τους, είναι επιρρεπείς σε βλάβες.

**Ρωγμές και μικρορωγμές:** Οι μικρορωγμές δημιουργούνται κατά την κατασκευή ή τη μεταφορά και μπορεί να επεκταθούν, επηρεάζοντας τη λειτουργία του πάνελ. Όταν επηρεάζεται πάνω από το 8% της επιφάνειας της κυψέλης, μπορεί να προκληθούν θερμά σημεία (hotspots), μειώνοντας την απόδοση και επιταχύνοντας τη φθορά.

Snail tracks: Οι λεγόμενες «γραμμές σαλιγκαριού» είναι ορατές αλλοιώσεις που συνδέονται με μικρορωγμές στις κυψέλες. Προκαλούν πτώση στην απόδοση, μελέτες δείχνουν απώλειες ισχύος έως και 40%, κυρίως λόγω της μείωσης του ρεύματος βραχυκύκλωσης (ISC).

Δυνητική επαγόμενη διάβρωση (PID): Η PID είναι σοβαρή βλάβη που προκύπτει από τη διαφορά δυναμικού μεταξύ των κυψελών και του πλαισίου του πάνελ, οδηγώντας σε σταδιακή απώλεια ισχύος και πλήρη αποτυχία του συστήματος αν δεν αντιμετωπιστεί έγκαιρα.

Αποσύνδεση των busbars: Τα busbars, λεπτοί αγωγοί από χαλκό ή αλουμίνιο που συλλέγουν και μεταφέρουν το ηλεκτρικό ρεύμα, μπορεί να αποσυνδεθούν λόγω κατασκευαστικών ελαττωμάτων ή υπερθέρμανσης από σκίαση. Η αποσύνδεσή τους μπορεί να οδηγήσει σε απώλεια απόδοσης έως 46% και να προκαλέσει θερμά σημεία, τα οποία μπορεί να προκαλέσουν σοβαρές βλάβες στο EVA και στο προστατευτικό γυαλί.

### **Προστατευτικό πίσω φύλλο (backsheet)**

Το πίσω φύλλο (backsheet) είναι η εξωτερική στρώση του φωτοβολταϊκού πάνελ, που προσφέρει μηχανική στήριξη και προστατεύει από περιβαλλοντικούς παράγοντες, όπως η υγρασία.

Καμένα σημεία (burn marks): Τα θερμά σημεία μπορούν να προκαλέσουν καμένες περιοχές στο πίσω φύλλο, με κίνδυνο πρόκλησης πυρκαγιάς. Τα πολυστρωματικά backsheets παρέχουν καλύτερη αντοχή στη φωτιά, ενώ τα μονοστρωματικά φύλλα από τερεφθαλικό πολυαιθυλένιο με ειδική επίστρωση προσφέρουν ασφαλέστερη επιλογή.

Ρωγμές και αντοχή των υλικών: Τα backsheets από πολυπροπυλένιο (PP) και πολυαιθυλένιο (PET) παρουσιάζουν παρόμοια ανθεκτικότητα, με το PP να ενισχύεται με ίνες άνθρακα για μεγαλύτερη αντοχή και διάρκεια ζωής.

Αποχρωματισμός και αποσύνθεση: Ορισμένα backsheets, όπως αυτά από πολυαμίδιο, είναι επιρρεπή σε υποβάθμιση, που εμφανίζεται με τη μορφή λευκής σκόνης (chalking). Αντίθετα, τα φθοριωμένα backsheets (PVF) είναι πιο ανθεκτικά και διατηρούν την απόδοσή τους για μεγαλύτερο διάστημα.

### **Κουτί σύνδεσης (junction box) και δίοδοι παράκαμψης (bypass diodes)**

Το κουτί σύνδεσης (junction box) είναι ένα βασικό εξάρτημα των φωτοβολταϊκών πάνελ που κατευθύνει τη ροή του ρεύματος και προστατεύει από ηλεκτρικές δυσλειτουργίες. Περιέχει δίοδους παράκαμψης (bypass diodes), οι οποίες βοηθούν στην αποφυγή υπερθέρμανσης παρακάμπτοντας ελαττωματικές ή σκιασμένες κυψέλες.

Οι πιο συνηθισμένες βλάβες περιλαμβάνουν κακής ποιότητας καλωδιώσεις, καμένες δίοδοι, διάβρωση και αποκόλληση λόγω υγρασίας. Αυτά τα προβλήματα μπορεί να οδηγήσουν σε πλήρη διακοπή της παραγωγής ενέργειας ή ακόμα και σε πυρκαγιά.

Επιρροή περιβαλλοντικών συνθηκών: Η υγρασία και οι ακραίες θερμοκρασίες επιταχύνουν τη φθορά του junction box. Σε ψυχρά και υγρά κλίματα υπάρχει αυξημένος κίνδυνος διάβρωσης, ενώ σε υψηλές θερμοκρασίες παρατηρείται αποκόλληση του κουτιού. Σε φωτοβολταϊκά εγκατεστημένα σε υδάτινες επιφάνειες, απαιτείται αυξημένη προστασία από την υγρασία.

Βλάβες δίοδων παράκαμψης: Οι δίοδοι παράκαμψης προστατεύουν το πάνελ από την υπερθέρμανση, όμως μπορεί να καταστραφούν από παρατεταμένη σκίαση ή υπερβολική έκθεση στην ακτινοβολία. Αν δεν αντικατασταθούν εγκαίρως, αυξάνεται ο κίνδυνος σοβαρών βλαβών και πιθανής πυρκαγιάς.

## Κεφάλαιο 3 Συντήρηση Φωτοβολταϊκών Συστημάτων

### 3.1 Εισαγωγή στη Συντήρηση των Φωτοβολταϊκών Συστημάτων

Η αποτελεσματική και απρόσκοπτη λειτουργία των Φ/Β συστημάτων απαιτεί συστηματική συντήρηση, η οποία αποτελεί βασικό στοιχείο για τη συνολική τους διαχείριση. Στο προηγούμενο κεφάλαιο παρουσιάστηκαν οι διάφορες βλάβες και οι παράγοντες που επηρεάζουν την απόδοση των συστημάτων αυτών. Σε αυτό το κεφάλαιο, θα επικεντρωθούμε στη σημασία της συντήρησης, καθώς και στις στρατηγικές που εφαρμόζονται για τη διατήρηση της βέλτιστης λειτουργίας των Φ/Β συστημάτων.

Μελέτες έχουν δείξει ότι η απόδοση των φωτοβολταϊκών μειώνεται κατά 0,5% έως 1% ετησίως, ενώ οι συνολικές απώλειες ενέργειας λόγω βλαβών μπορεί να φτάσουν από 3,6% έως και 18,9% κάθε χρόνο [23]. Επιπλέον, έχει διαπιστωθεί ότι περίπου το 2% των πάνελ παρουσιάζουν βλάβες μέσα σε 11-12 χρόνια λειτουργίας [13]. Αυτά τα στοιχεία καταδεικνύουν τη σημασία της συντήρησης από τα πρώτα στάδια λειτουργίας, προκειμένου να διατηρηθεί η απόδοση και να παραταθεί η διάρκεια ζωής των συστημάτων.

Τα τελευταία χρόνια, οι στρατηγικές συντήρησης των φωτοβολταϊκών συστημάτων γνωστές ως O&M (Operation & Maintenance) έχουν εξελιχθεί σημαντικά. Στο παρελθόν, η συντήρηση ήταν κυρίως αντιδραστική, δηλαδή οι βλάβες αντιμετωπιζόνταν μόνο αφού είχαν εμφανιστεί, ωστόσο, η προσέγγιση σήμερα έχει αλλάξει, με έμφαση στην πρόληψη που βασίζεται στην πρόβλεψη. Η τεχνολογία παίζει καθοριστικό ρόλο σε αυτή την αλλαγή, καθώς σύγχρονα συστήματα επιτρέπουν τη συνεχή παρακολούθηση της λειτουργίας των πάνελ και την έγκαιρη ανίχνευση πιθανών προβλημάτων. Η ενσωμάτωση έξυπνων συστημάτων, όπως οι αισθητήρες και οι πλατφόρμες απομακρυσμένης παρακολούθησης, επιτρέπει τη συνεχή αξιολόγηση της απόδοσης των εγκαταστάσεων και την έγκαιρη ανίχνευση πιθανών προβλημάτων. Έτσι, δίνεται η δυνατότητα άμεσης και αποτελεσματικής λήψης αποφάσεων. Παράλληλα, η αξιοποίηση της τεχνητής νοημοσύνης και της ανάλυσης δεδομένων επιτρέπει την πρόβλεψη βλαβών βασισμένη σε ιστορικά στοιχεία, συμβάλλοντας στη διατήρηση της αποδοτικότητας των συστημάτων και στη μείωση του κόστους συντήρησης.

## 3.2 Κατηγορίες Συντήρησης

Επειδή τα φωτοβολταϊκά συστήματα εκτίθενται συνεχώς σε ποικίλες και συχνά δύσκολες καιρικές συνθήκες, είναι σημαντικό να εφαρμόζονται κατάλληλες στρατηγικές συντήρησης που θα βοηθήσουν στη μείωση του λειτουργικού κόστους και στη διατήρηση της ενεργειακής τους απόδοσης. Η επιλογή της σωστής προσέγγισης στη συντήρηση εξαρτάται από διάφορους παράγοντες, όπως το μέγεθος της εγκατάστασης, οι κλιματολογικές συνθήκες της περιοχής, η τεχνολογία που χρησιμοποιείται στα φωτοβολταϊκά πάνελ, καθώς και οι ιδιαίτερες απαιτήσεις κάθε συστήματος. Η συντήρηση τους δεν είναι μια απλή διαδικασία, αλλά περιλαμβάνει διαφορετικές προσεγγίσεις που στοχεύουν στην πρόληψη και την αντιμετώπιση των προβλημάτων με διαφορετικούς τρόπους. Τα τελευταία χρόνια, οι στρατηγικές συντήρησης έχουν εξελιχθεί σημαντικά, περνώντας από τις παραδοσιακές αντιδραστικές μεθόδους σε πιο προληπτικές και προβλεπτικές λύσεις. Οι βασικές κατηγορίες συντήρησης με βάση τις πηγές [4, 12, 16, 23, 24, 25, 26, 27] περιλαμβάνουν τη διορθωτική, την προληπτική και την προβλεπτική συντήρηση, κάθε μία με ξεχωριστή φιλοσοφία και στόχο. Από την αντιμετώπιση των βλαβών όταν προκύψουν, έως την πρόβλεψη πιθανών αστοχιών πριν αυτές εμφανιστούν, οι στρατηγικές αυτές συμβάλλουν στην αποδοτική λειτουργία και τη μακροχρόνια βιωσιμότητα των φωτοβολταϊκών εγκαταστάσεων.

### 3.2.1 Διορθωτική Συντήρηση

Η διορθωτική συντήρηση (Corrective Maintenance) αποτελεί μια απαραίτητη διαδικασία για τη διατήρηση της αποδοτικότητας των φωτοβολταϊκών συστημάτων, καθώς περιλαμβάνει όλες τις ενέργειες που απαιτούνται για την αποκατάσταση βλαβών ή δυσλειτουργιών που έχουν ήδη παρουσιαστεί. Οι βλάβες αυτές μπορούν να εντοπιστούν είτε μέσω απομακρυσμένης παρακολούθησης είτε κατά τη διάρκεια επιτόπιων ελέγχων από το τεχνικό προσωπικό. Αυτή η μορφή συντήρησης εφαρμόζεται όταν το πρόβλημα έχει ήδη εκδηλωθεί, με σκοπό την αποκατάσταση της ομαλής λειτουργίας του συστήματος, είτε με επισκευές είτε με αντικατάσταση ελαττωματικών εξαρτημάτων. Για να μειωθούν οι ενεργειακές απώλειες κατά τη διάρκεια της διορθωτικής συντήρησης, καλό είναι οι απαραίτητες εργασίες να γίνονται σε ώρες με χαμηλή ηλιακή ακτινοβολία, όπως τη νύχτα ή όταν η ηλιοφάνεια είναι περιορισμένη. Έτσι, το σύστημα μένει εκτός



λειτουργίας για λιγότερο χρόνο και η απώλεια παραγωγής ενέργειας διατηρείται στο ελάχιστο.

Η διορθωτική συντήρηση συχνά αποκαλείται και αντιδραστική συντήρηση, καθώς εφαρμόζεται μόνο όταν παρουσιαστεί κάποιο πρόβλημα. Σε περιπτώσεις σοβαρών βλαβών, η αποκατάσταση γίνεται άμεσα για να αποφευχθούν μεγάλες απώλειες, ενώ σε λιγότερο επείγοντα ζητήματα μπορεί να προγραμματιστεί μαζί με άλλες εργασίες, ώστε να εξοικονομηθούν χρόνος και χρήματα. Αν και αρχικά φαίνεται πιο οικονομική, η διορθωτική συντήρηση μπορεί να δημιουργήσει σοβαρά προβλήματα μακροπρόθεσμα. Το να αντιμετωπίζονται οι βλάβες μόνο όταν εμφανιστούν, συχνά οδηγεί σε απρόοπτες διακοπές στη λειτουργία του φωτοβολταϊκού συστήματος, κάτι που επηρεάζει άμεσα την παραγωγή ενέργειας και μειώνει τα έσοδα της εγκατάστασης. Επιπλέον, οι έκτακτες επισκευές απαιτούν άμεση διαθεσιμότητα ανταλλακτικών και εξοπλισμού, κάτι που μπορεί να αυξήσει το κόστος, ειδικά αν χρειαστεί να παραγγελθούν υλικά με ταχεία αποστολή ή να κληθεί εξειδικευμένο προσωπικό σε σύντομο χρονικό διάστημα.

Συνολικά, ενώ η διορθωτική συντήρηση μπορεί αρχικά να φαίνεται ως η πιο εύκολη και οικονομική λύση, η έλλειψη προγραμματισμού μπορεί τελικά να αυξήσει το συνολικό κόστος και να δημιουργήσει περισσότερα προβλήματα συγκριτικά με πιο οργανωμένες, προληπτικές στρατηγικές συντήρησης.

### 3.2.2 Προληπτική Συντήρηση

Η προληπτική συντήρηση (Preventive Maintenance) είναι μια στρατηγική που εστιάζει στην τακτική επιθεώρηση και φροντίδα του φωτοβολταϊκού συστήματος, με σκοπό την αποφυγή πιθανών προβλημάτων προτού αυτά εμφανιστούν. Περιλαμβάνει δραστηριότητες όπως οπτικούς και λειτουργικούς ελέγχους, μετρήσεις, καθαρισμό των πάνελ και γενικές επιθεωρήσεις, οι οποίες πραγματοποιούνται σε προκαθορισμένα χρονικά διαστήματα, ακολουθώντας ένα συγκεκριμένο πλάνο συντήρησης. Ο κύριος στόχος της προληπτικής συντήρησης είναι η διατήρηση της αποδοτικότητας και η παράταση της διάρκειας ζωής του εξοπλισμού, καθώς η έγκαιρη αντιμετώπιση πιθανών δυσλειτουργιών μπορεί να αποτρέψει πιο σοβαρές βλάβες στο μέλλον.

Επομένως, η εφαρμογή αυτής της στρατηγικής μπορεί να είναι ιδιαίτερα ωφέλιμη, καθώς συμβάλλει στη σταθερή και αποδοτική λειτουργία του συστήματος, μειώνοντας τις

πιθανότητες ξαφνικών διακοπών και μειώσεων στην παραγωγή ενέργειας. Ωστόσο, η προληπτική συντήρηση μπορεί να οδηγήσει σε αυξημένα λειτουργικά κόστη, αφού απαιτεί συχνές επισκέψεις για επιθεωρήσεις και συντήρηση, οι οποίες ίσως δεν είναι πάντα αναγκαίες. Παρόλα αυτά, αποτελεί μια επένδυση που διασφαλίζει τη βέλτιστη απόδοση και προστατεύει τον εξοπλισμό από πρόωρη φθορά.

Σε ορισμένες περιπτώσεις, μέτρα προληπτικής συντήρησης μπορούν να ληφθούν ήδη από το στάδιο σχεδιασμού της εγκατάστασης. Για παράδειγμα, η χρήση ειδικών αντιστατικό-επικαλύψεων στα πάνελ, που μειώνουν τις αντανάκλασεις του ηλιακού φωτός και επιτρέπουν μεγαλύτερη απορρόφηση της ηλιακής ακτινοβολίας, συμβάλλει στη βελτίωση της απόδοσης του συστήματος. Οι επικαλύψεις αυτές βοηθούν στην αποτροπή της συσσώρευσης σκόνης και ρύπων, διευκολύνοντας τη συντήρηση και περιορίζοντας την ανάγκη για συχνό καθαρισμό. Επιπλέον, η βελτιστοποίηση της διάταξης των πάνελ, μέσω της κατάλληλης τοποθέτησής τους σε γωνίες που αξιοποιούν τη φυσική ροή του αέρα και της βροχής, μπορεί να μειώσει τη συγκέντρωση ρύπων και να ενισχύσει την αυτοκαθαριζόμενη λειτουργία των πάνελ. Ένα ακόμα σημαντικό προληπτικό μέτρο είναι η διαχείριση της βλάστησης γύρω από τα πάνελ, η οποία παίζει καθοριστικό ρόλο στη διατήρηση της αποδοτικότητας του συστήματος. Ο σωστός έλεγχος της βλάστησης αποτρέπει τη σκίαση των πάνελ, η οποία μπορεί να επηρεάσει αρνητικά την απόδοσή τους, ενώ συμβάλλει και στη μείωση του κινδύνου πυρκαγιάς, ιδιαίτερα σε περιοχές με υψηλές θερμοκρασίες. Έτσι, η υιοθέτηση τέτοιων προληπτικών μέτρων από το αρχικό στάδιο του σχεδιασμού μπορεί να συμβάλει στη μείωση των λειτουργικών εξόδων και στη διατήρηση της αποδοτικότητας των φωτοβολταϊκών συστημάτων μακροπρόθεσμα.

Ο σχεδιασμός ενός προγράμματος προληπτικής συντήρησης εξαρτάται από διάφορους παράγοντες, όπως τα τεχνικά χαρακτηριστικά του εξοπλισμού, οι περιβαλλοντικές συνθήκες της περιοχής εγκατάστασης, οι οδηγίες των κατασκευαστών και οι όροι της εγγύησης. Για παράδειγμα, φωτοβολταϊκά πάρκα που βρίσκονται σε περιοχές με υψηλή συγκέντρωση σκόνης ή γύρη μπορεί να απαιτούν συχνότερους καθαρισμούς σε σύγκριση με εκείνα που είναι εγκατεστημένα σε καθαρότερα περιβάλλοντα.

Παρότι η προληπτική συντήρηση μπορεί αρχικά να φαίνεται ως ένα επιπλέον κόστος, στην πραγματικότητα βοηθά στην εξοικονόμηση χρημάτων μακροπρόθεσμα. Με την έγκαιρη αντιμετώπιση μικροπροβλημάτων, αποφεύγονται πιο σοβαρές και δαπανηρές επισκευές

στο μέλλον, ενώ παράλληλα διασφαλίζεται η ομαλή και αποδοτική λειτουργία του φωτοβολταϊκού συστήματος.

### 3.2.3 Προβλεπτική Συντήρηση

Η προβλεπτική συντήρηση (Predictive Maintenance) είναι μια σύγχρονη προσέγγιση που βασίζεται στη συνεχή συλλογή και ανάλυση δεδομένων από τη λειτουργία των φωτοβολταϊκών συστημάτων, με στόχο την έγκαιρη αναγνώριση ενδεχόμενων βλαβών προτού αυτές εμφανιστούν. Μέσω της χρήσης προηγμένων τεχνολογιών, όπως αισθητήρες και συστήματα τεχνητής νοημοσύνης, παρακολουθούνται κρίσιμες παράμετροι, όπως η θερμοκρασία, η τάση και το ρεύμα των μονάδων, επιτρέποντας την ανίχνευση τάσεων που μπορεί να υποδηλώνουν πιθανά προβλήματα. Η ανάλυση των δεδομένων, τόσο σε πραγματικό χρόνο όσο και από προηγούμενες καταγραφές, επιτρέπει την έγκαιρη λήψη αποφάσεων για τη συντήρηση των φωτοβολταϊκών συστημάτων με αποτέλεσμα οι εργασίες συντήρησης να μπορούν να γίνουν πιο στοχευμένες και αποτελεσματικές, αποφεύγοντας άσκοπες επιθεωρήσεις και επισκευές.

Στο σημείο αυτό αξίζει να αναφέρουμε ότι η προβλεπτική συντήρηση διαφέρει από την προληπτική, καθώς βασίζεται στην ανάλυση δεδομένων σε πραγματικό χρόνο, αντί να ακολουθεί προκαθορισμένα χρονοδιαγράμματα συντήρησης. Στην προληπτική συντήρηση, οι επιθεωρήσεις πραγματοποιούνται σε τακτά χρονικά διαστήματα, ανεξάρτητα από την κατάσταση του εξοπλισμού. Αντίθετα, η προβλεπτική συντήρηση αξιοποιεί αισθητήρες και προηγμένα εργαλεία ανάλυσης για να εντοπίζει πιθανά προβλήματα πριν αυτά εξελιχθούν σε σοβαρές βλάβες. Έτσι, επιτρέπει στοχευμένες επεμβάσεις τη σωστή στιγμή, αποφεύγοντας περιττές εργασίες και συμβάλλοντας στην καλύτερη αξιοποίηση των πόρων, διατηρώντας παράλληλα την ομαλή λειτουργία του συστήματος.

Η προβλεπτική συντήρηση εφαρμόζεται μέσω σύγχρονων τεχνολογιών που επιτρέπουν την έγκαιρη διάγνωση και αντιμετώπιση προβλημάτων, προτού αυτά εξελιχθούν σε σοβαρές βλάβες. Ένα χαρακτηριστικό παράδειγμα είναι η αντικατάσταση εξοπλισμού βάσει της πραγματικής του απόδοσης, καθώς οι αισθητήρες παρακολούθησης και τα συστήματα ανάλυσης δεδομένων επιτρέπουν τον εντοπισμό πιθανών αποκλίσεων στη λειτουργία των φωτοβολταϊκών συστημάτων. Η προβλεπτική συντήρηση μπορεί να

πραγματοποιηθεί είτε απομακρυσμένα, μέσω συστημάτων που συλλέγουν και αναλύουν δεδομένα σε πραγματικό χρόνο, είτε επιτόπια, με τη χρήση εξειδικευμένου εξοπλισμού που διευκολύνει την ακριβή διάγνωση προβλημάτων. Η πρόοδος στις τεχνολογίες ανάλυσης δεδομένων και τεχνητής νοημοσύνης συμβάλλει στην ανάπτυξη ακόμα πιο αποτελεσματικών στρατηγικών πρόβλεψης, μειώνοντας τον κίνδυνο απρογραμμάτιστων διακοπών και βελτιστοποιώντας τους διαθέσιμους πόρους.

Συγκριτικά, οι διαφορετικές στρατηγικές συντήρησης παρουσιάζουν σημαντικές διαφορές ως προς τη μεθοδολογία εφαρμογής, το κόστος και την αξιοπιστία. Ο Πίνακας 2 συνοψίζει τα κύρια χαρακτηριστικά των τριών κύριων κατηγοριών συντήρησης, διευκολύνοντας την κατανόηση των πλεονεκτημάτων και των περιορισμών κάθε μεθόδου.

Πίνακας 2: Σύγκριση Διορθωτικής, Προληπτικής και Προβλεπτικής Συντήρησης

| Χαρακτηριστικό        | Διορθωτική                                                                                                 | Προληπτική                                                                                           | Προβλεπτική                                                                                                    |
|-----------------------|------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------|
| Προσέγγιση            | Αντιδραστική, εφαρμόζεται μόνο όταν παρουσιαστεί βλάβη.                                                    | Προγραμματισμένη, πραγματοποιείται σε τακτά χρονικά διαστήματα για την αποφυγή βλαβών.               | Βασισμένη σε δεδομένα και ανάλυση για την πρόβλεψη βλαβών πριν αυτές εμφανιστούν.                              |
| Χρονισμός             | Μετά την εμφάνιση της βλάβης.                                                                              | Σε προγραμματισμένα διαστήματα, ανεξάρτητα από την κατάσταση του εξοπλισμού.                         | Μεταβλητή συχνότητα, καθορίζεται από την ανάλυση της κατάστασης του εξοπλισμού.                                |
| Κόστος                | Αρχικά χαμηλό, αλλά μπορεί να οδηγήσει σε υψηλά έξοδα λόγω απρόβλεπτων επισκευών και διακοπών λειτουργίας. | Σταθερό κόστος λόγω τακτικών επιθεωρήσεων, αλλά μειώνει τις πιθανότητες σοβαρών βλαβών.              | Υψηλό αρχικό κόστος για αισθητήρες και ανάλυση δεδομένων, αλλά βελτιστοποιεί τη χρήση των πόρων μακροπρόθεσμα. |
| Απαιτήσεις Εξοπλισμού | Εξαρτάται από τη φύση της βλάβης, συχνά απαιτεί ανταλλακτικά και εξειδικευμένο προσωπικό.                  | Ελάχιστος εξοπλισμός, όπως εργαλεία για καθαρισμό, μετρήσεις και συντήρηση.                          | Αισθητήρες, λογισμικό ανάλυσης δεδομένων, αλγόριθμοι τεχνητής νοημοσύνης και εξειδικευμένο προσωπικό.          |
| Αξιοπιστία Συστήματος | Αυξημένος κίνδυνος απρογραμμάτιστων διακοπών και απώλειας παραγωγής.                                       | Βελτιώνει την αξιοπιστία μέσω προγραμματισμένων ελέγχων, αλλά δεν προλαμβάνει πάντα όλες τις βλάβες. | Βέλτιστη αξιοπιστία, καθώς μειώνει τις αιφνίδιες αστοχίες μέσω ανάλυσης δεδομένων.                             |

Όπως προκύπτει από τα συγκριτικά στοιχεία του Πίνακα 2, η διορθωτική συντήρηση, αν και παρουσιάζει χαμηλό αρχικό κόστος, μπορεί να οδηγήσει σε μεγαλύτερες λειτουργικές διακοπές και απρόβλεπτα έξοδα. Αντίθετα, η προληπτική συντήρηση συμβάλλει στη διατήρηση της αποδοτικότητας μέσω τακτικών επιθεωρήσεων, ενώ η προβλεπτική συντήρηση, παρόλο που απαιτεί αυξημένη επένδυση σε τεχνολογία και δεδομένα, προσφέρει τη βέλτιστη διαχείριση των βλαβών, μειώνοντας τις αιφνίδιες αστοχίες.

### **3.3 Μέθοδοι και Τεχνολογίες Συντήρησης**

Η αποδοτική και αξιόπιστη λειτουργία των φωτοβολταϊκών συστημάτων εξαρτάται σε μεγάλο βαθμό από την υιοθέτηση κατάλληλων στρατηγικών και τεχνολογιών συντήρησης. Πλέον, η συντήρηση δεν περιορίζεται στις παραδοσιακές μεθόδους, αλλά αξιοποιεί προηγμένες τεχνολογίες που επιτρέπουν την απομακρυσμένη παρακολούθηση, την έγκαιρη ανίχνευση πιθανών βλαβών και την αποτελεσματική διαχείριση των παρεμβάσεων. Σε αυτό το κεφάλαιο θα παρουσιαστούν οι βασικές μέθοδοι και τεχνολογίες συντήρησης που εφαρμόζονται στα φωτοβολταϊκά συστήματα.

#### **3.3.1 Μέθοδοι Ανίχνευσης και Διάγνωσης Βλαβών**

Η διατήρηση της αποδοτικής λειτουργίας των φωτοβολταϊκών συστημάτων προϋποθέτει τη συνεχή παρακολούθηση και την έγκαιρη διάγνωση πιθανών βλαβών. Η ανάπτυξη εξελιγμένων συστημάτων παρακολούθησης έχει καταστήσει δυνατή τη συλλογή κρίσιμων δεδομένων, όπως η τάση, το ρεύμα και η θερμοκρασία, που επιτρέπουν την ανίχνευση ανωμαλιών στη λειτουργία και τη λήψη κατάλληλων μέτρων συντήρησης. Η διαδικασία ανίχνευσης και διάγνωσης βλαβών (Fault Detection and Diagnosis - FDD) βασίζεται σε τρία διαδοχικά στάδια: την ανίχνευση, όπου τα δεδομένα του συστήματος αναλύονται και συγκρίνονται με πρότυπα αναφοράς για τον εντοπισμό πιθανών αποκλίσεων, την ταυτοποίηση, κατά την οποία εφαρμόζονται προηγμένοι αλγόριθμοι για τον προσδιορισμό της φύσης και των αιτίων των σφαλμάτων, και τέλος, την τοπικοποίηση και απομόνωση, που αφορά τον ακριβή εντοπισμό της θέσης της βλάβης και τη λήψη των κατάλληλων μέτρων για την αποφυγή περαιτέρω ζημιών [13].

Οι μέθοδοι ανίχνευσης σφαλμάτων [4, 16, 17, 22, 23, 24 26, 28] στα φωτοβολταϊκά συστήματα μπορούν να ταξινομηθούν σε τρεις βασικές κατηγορίες, κάθε μία από τις οποίες συνδέεται με διαφορετικές τεχνικές συντήρησης:


### **1. Χειροκίνητες μέθοδοι**

Οι χειροκίνητες μέθοδοι περιλαμβάνουν τη φυσική επιθεώρηση των φωτοβολταϊκών πάνελ από εξειδικευμένο προσωπικό, το οποίο συχνά απαιτεί την αποσύνδεση των μονάδων από το σύστημα προκειμένου να πραγματοποιηθούν λεπτομερείς έλεγχοι. Αν και οι μέθοδοι αυτές μπορούν να προσφέρουν ακριβή αποτελέσματα, η εφαρμογή τους είναι ιδιαίτερα χρονοβόρα και απαιτεί σημαντικούς πόρους σε ανθρώπινο δυναμικό. Επιπλέον, η χρήση χειροκίνητων μεθόδων σε μεγάλης κλίμακας φωτοβολταϊκές εγκαταστάσεις καθίσταται μη πρακτική, καθώς οι επιθεωρήσεις απαιτούν εκτενή χρόνο και εξειδικευμένη γνώση.

Μία από τις βασικές τεχνικές χειροκίνητης επιθεώρησης είναι η οπτική επιθεώρηση (Visual Inspection), η οποία περιλαμβάνει τον άμεσο έλεγχο των φωτοβολταϊκών πάνελ με σκοπό την ανίχνευση εμφανών ελαττωμάτων. Κατά τη διάρκεια της διαδικασίας, το τεχνικό προσωπικό αναζητά ρωγμές στις κυψέλες, αποχρωματισμούς των υλικών εγκλεισμού, αποκολλήσεις ή άλλες φθορές που μπορεί να επηρεάσουν την απόδοση του συστήματος. Η μέθοδος αυτή είναι απλή και δεν απαιτεί εξειδικευμένο εξοπλισμό, ωστόσο δεν μπορεί να ανιχνεύσει εσωτερικά ελαττώματα που δεν είναι ορατά στην επιφάνεια των πάνελ.


Μία πιο προηγμένη μέθοδος που χρησιμοποιείται συχνά σε χειροκίνητους ελέγχους είναι η θερμογραφία (Infrared Imaging), η οποία βασίζεται στη χρήση θερμικών καμερών για την ανίχνευση των θερμών σημείων (hotspots) στα φωτοβολταϊκά πάνελ. Στην Εικόνα 10, η θερμογραφική απεικόνιση αποκαλύπτει περιοχές με αυξημένη θερμοκρασία, με το μέγιστο καταγεγραμμένο σημείο να φτάνει τους 61.9°C. Η εμφάνιση τέτοιων θερμών σημείων μπορεί να υποδηλώνει προβλήματα, όπως ελαττωματικές κυψέλες, ζημιές στη συνδεσμολογία ή φαινόμενα υποβάθμισης, τα οποία επηρεάζουν την απόδοση του συστήματος. Η θερμογραφία παρέχει πολύτιμες πληροφορίες για την κατάσταση των πάνελ, καθώς εντοπίζει διαφορές στη θερμοκρασία που δεν είναι ορατές με γυμνό μάτι,

επιτρέποντας την έγκαιρη λήψη διορθωτικών μέτρων. Παρά το γεγονός ότι η τεχνική αυτή είναι αποτελεσματική, απαιτεί εξειδικευμένο εξοπλισμό και εμπειρία στην ανάλυση των θερμικών εικόνων για την αποφυγή ψευδών ενδείξεων.



Εικόνα 10: Θερμογραφική απεικόνιση φωτοβολταϊκού πάνελ με ανίχνευση θερμού σημείου (hotspot), υποδεικνύοντας πιθανή αστοχία ή υποβάθμιση [29]

Μια ακόμη εξειδικευμένη μέθοδος χειροκίνητης επιθεώρησης είναι η ηλεκτροφωταύγεια (Electroluminescence Imaging), η οποία χρησιμοποιείται για την ανίχνευση μικρορωγμών και ελαττωμάτων στις ηλιακές κυψέλες των πάνελ. Η μέθοδος αυτή απαιτεί την εφαρμογή ηλεκτρικού ρεύματος στα πάνελ, προκαλώντας την εκπομπή φωτός από τις κυψέλες, το οποίο καταγράφεται με ειδικές κάμερες. Τα ελαττωματικά σημεία εμφανίζονται ως σκοτεινές περιοχές στην εικόνα, υποδεικνύοντας προβλήματα που δεν είναι ορατά με άλλες μεθόδους. Η ηλεκτροφωταύγεια είναι ιδιαίτερα ακριβής για τον εντοπισμό αόρατων ελαττωμάτων, ωστόσο η εφαρμογή της σε μεγάλης κλίμακας εγκαταστάσεις μπορεί να είναι χρονοβόρα και απαιτεί εξειδικευμένο εξοπλισμό και προσωπικό. Η Εικόνα 11 απεικονίζει τη χρήση ηλεκτροφωταύγειας για την αξιολόγηση φωτοβολταϊκών κυψελών. Στην αριστερή εικόνα (α), μια υγιής μονοκρυσταλλική κυψέλη εμφανίζεται ομοιόμορφα φωτεινή, ενώ στη δεξιά εικόνα (β), οι σκοτεινές περιοχές αποκαλύπτουν ρωγμές και αστοχίες, οι οποίες ενδέχεται να επηρεάζουν την απόδοση και τη διάρκεια ζωής του πάνελ.



Εικόνα 11: Ηλεκτροφωταύγεια (EL) για την αξιολόγηση φωτοβολταϊκών κυψελών [30]

Παρότι οι χειροκίνητες μέθοδοι ανίχνευσης σφαλμάτων είναι αξιόπιστες και ευρέως διαδεδομένες, παρουσιάζουν ορισμένα μειονεκτήματα, όπως το υψηλό κόστος εργασίας, την ανάγκη διακοπής της λειτουργίας των συστημάτων και τη δυσκολία εφαρμογής σε εκτεταμένες εγκαταστάσεις. Ως εκ τούτου, στις περισσότερες περιπτώσεις χρησιμοποιούνται συμπληρωματικά με πιο σύγχρονες, αυτοματοποιημένες λύσεις που βελτιώνουν την αποδοτικότητα της συντήρησης των φωτοβολταϊκών συστημάτων.

## 2. Ημιαυτόματες μέθοδοι

Οι ημιαυτόματες μέθοδοι συντήρησης αποτελούν έναν συνδυασμό ανθρώπινης παρέμβασης και προηγμένων τεχνολογικών εργαλείων, προσφέροντας έναν πιο αποδοτικό και ακριβή τρόπο ανίχνευσης και διάγνωσης βλαβών στα φωτοβολταϊκά συστήματα. Σε αντίθεση με τις χειροκίνητες μεθόδους, επιτρέπουν την ταχύτερη επιθεώρηση μεγαλύτερων εκτάσεων, ενώ μειώνουν την ανάγκη για επιτόπια παρουσία τεχνικών. Ένα χαρακτηριστικό παράδειγμα τέτοιων μεθόδων είναι η χρήση drones εξοπλισμένων με θερμικές κάμερες, τα οποία μπορούν να σαρώσουν μεγάλες περιοχές φωτοβολταϊκών εγκαταστάσεων και να εντοπίσουν προβλήματα, όπως υπερθέρμανση πάνελ ή αστοχίες στις συνδέσεις. Τα drones μπορούν να επιθεωρήσουν μεγάλες εγκαταστάσεις ακόμα και σε δυσπρόσιτες περιοχές σε σύντομο χρονικό διάστημα, εντοπίζοντας προβλήματα όπως υπερθέρμανση πάνελ ή αστοχίες στις συνδέσεις, ενώ ταυτόχρονα παρέχουν υψηλής ακρίβειας δεδομένα για την κατάσταση των πάνελ. Σε αντίθεση με τη χειροκίνητη θερμογραφία η οποία απαιτεί εξειδικευμένο προσωπικό για τη φυσική επιθεώρηση και τη λήψη δεδομένων, η ημιαυτόματη μέθοδος μέσω drones επιτρέπει την κάλυψη μεγάλων εκτάσεων με μεγαλύτερη ταχύτητα και χωρίς την ανάγκη φυσικής πρόσβασης στις εγκαταστάσεις.



Επιπλέον, τα Συστήματα Υποστήριξης Αποφάσεων (Decision Support Systems – DSS) αποτελούν ένα σημαντικό εργαλείο στις ημιαυτόματες μεθόδους συντήρησης, καθώς αξιοποιούν δεδομένα πραγματικού χρόνου από τις μονάδες και συνδυάζουν πληροφορίες από διάφορους αισθητήρες [31]. Μέσω της ανάλυσης των δεδομένων, τα DSS μπορούν να παρέχουν προτάσεις για προληπτικές και διορθωτικές ενέργειες, επιτρέποντας στους διαχειριστές να λαμβάνουν τεκμηριωμένες αποφάσεις σχετικά με τη συντήρηση του συστήματος. Με τον τρόπο αυτό, μειώνεται η ανάγκη για συχνές επιθεωρήσεις και ελαχιστοποιούνται οι απρογραμμάτιστες διακοπές λειτουργίας. Οι τεχνολογίες αυτές βασίζονται σε αλγόριθμους ανάλυσης δεδομένων, οι οποίοι συγκρίνουν τις πραγματικές συνθήκες λειτουργίας με τις αναμενόμενες τιμές και εντοπίζουν πιθανές ανωμαλίες που μπορεί να οδηγήσουν σε μελλοντικές αστοχίες.


Ωστόσο, παρά τα σημαντικά πλεονεκτήματα που προσφέρουν οι ημιαυτόματες μέθοδοι, η εφαρμογή τους απαιτεί την ύπαρξη εξειδικευμένου προσωπικού που θα αναλύει και θα ερμηνεύει τα δεδομένα, καθώς και την επένδυση σε τεχνολογικό εξοπλισμό, κάτι που μπορεί να αυξήσει το αρχικό κόστος εγκατάστασης και λειτουργίας. Επιπλέον, οι διαδικασίες ανάλυσης δεδομένων απαιτούν διαρκή ενημέρωση και προσαρμογή στις νέες τεχνολογικές εξελίξεις, ώστε να διασφαλιστεί η αξιοπιστία και η ακρίβεια των αποτελεσμάτων που προκύπτουν από τα συστήματα παρακολούθησης.

### **3. Αυτόματες μέθοδοι**

Οι αυτόματες μέθοδοι συντήρησης αποτελούν την πιο προηγμένη και αποτελεσματική προσέγγιση στη διαχείριση των φωτοβολταϊκών συστημάτων, αξιοποιώντας τεχνολογίες αιχμής για τη συνεχή παρακολούθηση και ανάλυση της απόδοσής τους. Σε αντίθεση με τις χειροκίνητες και ημιαυτόματες μεθόδους, οι αυτόματες τεχνικές βασίζονται αποκλειστικά στη χρήση αισθητήρων και προηγμένων συστημάτων ανάλυσης δεδομένων, τα οποία συλλέγουν και επεξεργάζονται κρίσιμες πληροφορίες σε πραγματικό χρόνο, όπως η τάση, το ρεύμα και η ηλιακή ακτινοβολία. Οι μέθοδοι αυτές επιτρέπουν τη διαρκή παρακολούθηση της λειτουργίας του συστήματος, μειώνοντας την ανάγκη για επιτόπιες επιθεωρήσεις και παρέχοντας ακριβείς προβλέψεις για πιθανές δυσλειτουργίες, βελτιώνοντας έτσι την αποδοτικότητα και την αξιοπιστία της εγκατάστασης.

Ένα από τα βασικά εργαλεία που χρησιμοποιούνται στις αυτόματες μεθόδους συντήρησης είναι η ανάλυση δεδομένων (Data Analytics). Η μέθοδος αυτή επιτρέπει τη συστηματική συλλογή και επεξεργασία ιστορικών και πραγματικών δεδομένων λειτουργίας, εντοπίζοντας αποκλίσεις από τις κανονικές συνθήκες λειτουργίας. Η σύγκριση των δεδομένων αυτών με πρότυπα μοντέλα αναφοράς παρέχει πολύτιμες πληροφορίες για την τρέχουσα κατάσταση του συστήματος και διευκολύνει την έγκαιρη λήψη μέτρων συντήρησης πριν την εμφάνιση σοβαρών προβλημάτων. Η ανάλυση δεδομένων χρησιμοποιείται όχι μόνο για την ανίχνευση υπαρχόντων σφαλμάτων, αλλά και για τη δημιουργία στρατηγικών πρόληψης και βελτιστοποίησης της απόδοσης των φωτοβολταϊκών συστημάτων.

Μια ιδιαίτερα χρήσιμη τεχνική που εφαρμόζεται στις αυτόματες διαδικασίες συντήρησης είναι η ανάλυση της καμπύλης τάσης-ρεύματος (I-V curve analysis). Η μέθοδος αυτή παρέχει λεπτομερείς πληροφορίες για την ηλεκτρική συμπεριφορά των φωτοβολταϊκών πάνελ και επιτρέπει τον εντοπισμό αποκλίσεων στις ηλεκτρικές παραμέτρους, όπως μείωση της απόδοσης, βλάβες στις κυψέλες, υποβαθμίσεις λόγω γήρανσης και προβλήματα στις συνδέσεις των πάνελ. Η τακτική παρακολούθηση των καμπυλών I-V αποτελεί βασικό εργαλείο για την έγκαιρη διάγνωση και την πρόληψη πιο σοβαρών βλαβών που θα μπορούσαν να επηρεάσουν την ενεργειακή απόδοση του συστήματος. Η Εικόνα 12 παρουσιάζει τις καμπύλες ρεύματος-τάσης (I-V) και ισχύος-τάσης (P-V), οι οποίες χρησιμοποιούνται για την αξιολόγηση της ηλεκτρικής συμπεριφοράς των φωτοβολταϊκών πάνελ. Οι κύριες παράμετροι, όπως το ρεύμα βραχυκυκλώματος ( $I_{sc}$ ), η τάση ανοικτού κυκλώματος ( $V_{oc}$ ) και η μέγιστη ισχύς ( $P_{max}$ ), επιτρέπουν τον εντοπισμό αποκλίσεων που μπορεί να σχετίζονται με αστοχίες ή μείωση της απόδοσης του συστήματος.



Εικόνα 12: Καμπύλες ρεύματος-τάσης (I-V) και ισχύος-τάσης (P-V) . Οι κύκλοι υποδεικνύουν τις βασικές ηλεκτρικές παραμέτρους: το ρεύμα βραχυκυκλώματος ( $I_{sc}$ ), την τάση ανοικτού κυκλώματος ( $V_{oc}$ ) και το σημείο μέγιστης ισχύος ( $P_{max}$ ), οι οποίες χρησιμοποιούνται για την αξιολόγηση της απόδοσης του συστήματος και την ανίχνευση πιθανών αποκλίσεων ή βλαβών [29]

Μια ακόμη σημαντική εφαρμογή των αυτόματων μεθόδων συντήρησης είναι η συντήρηση βάσει συνθηκών (Condition-Based Maintenance - CBM), η οποία βασίζεται στη διαρκή παρακολούθηση της πραγματικής κατάστασης του εξοπλισμού και όχι σε προκαθορισμένα χρονικά διαστήματα επιθεώρησης. Η CBM επιτρέπει την εφαρμογή στοχευμένων μέτρων συντήρησης, μειώνοντας τις περιττές επεμβάσεις και το κόστος λειτουργίας, ενώ παράλληλα συμβάλλει στην αποφυγή πιθανών βλαβών πριν αυτές εξελιχθούν σε σοβαρά προβλήματα. Η συντήρηση βάσει συνθηκών αξιοποιεί δεδομένα από αισθητήρες και συστήματα ανάλυσης δεδομένων για την ανίχνευση τάσεων που υποδεικνύουν πιθανές αστοχίες και βελτιστοποιεί τη διάρκεια ζωής των φωτοβολταϊκών συστημάτων.

Η συντήρηση με τη χρήση τεχνητής νοημοσύνης (Artificial Intelligence - AI) και μηχανικής μάθησης (Machine Learning - ML) αποτελεί μια από τις πλέον καινοτόμες και εξελιγμένες προσεγγίσεις στις αυτόματες μεθόδους συντήρησης των φωτοβολταϊκών συστημάτων. Η αξιοποίηση προηγμένων αλγορίθμων AI/ML επιτρέπει την ανάλυση μεγάλων συνόλων δεδομένων που προέρχονται από αισθητήρες και συστήματα παρακολούθησης, εντοπίζοντας μοτίβα και τάσεις που υποδηλώνουν πιθανές αστοχίες ή αποκλίσεις από την ομαλή λειτουργία. Τεχνολογίες όπως τα τεχνητά νευρωνικά δίκτυα (Artificial Neural Networks - ANN) και οι υποστηρικτικές διανυσματικές μηχανές (Support Vector Machines - SVM) έχουν αποδειχθεί ιδιαίτερα αποτελεσματικές στον εντοπισμό σύνθετων

προβλημάτων, όπως η υποβάθμιση των πάνελ, οι βλάβες στις κυψέλες και οι αποτυχίες των μετατροπέων (inverters). Η χρήση drones εξοπλισμένων με θερμικές κάμερες, σε συνδυασμό με αλγορίθμους ανάλυσης εικόνας βασισμένους στην τεχνητή νοημοσύνη, επιτρέπει την ανίχνευση φαινομένων όπως το φαινόμενο της δυναμικά επαγόμενης υποβάθμισης (Potential Induced Degradation - PID), (ένα φαινόμενο που προκαλεί σταδιακή μείωση της απόδοσης των φωτοβολταϊκών πάνελ λόγω διαρροής ρεύματος, η οποία οφείλεται στη διαφορά δυναμικού μεταξύ των κυψελών και της γείωσης του συστήματος), χωρίς να απαιτείται φυσική παρέμβαση στις εγκαταστάσεις. Παρόλο που η εφαρμογή της τεχνητής νοημοσύνης στη συντήρηση των φωτοβολταϊκών απαιτεί σημαντική υπολογιστική ισχύ και υψηλής ποιότητας δεδομένα, τα οφέλη της είναι σημαντικά, καθώς οδηγεί στη μείωση του κόστους λειτουργίας, στη βελτίωση της αποδοτικότητας και στην αύξηση της διάρκειας ζωής των συστημάτων.

Ωστόσο, παρά τα σημαντικά πλεονεκτήματα που προσφέρουν οι αυτόματες μέθοδοι συντήρησης, η εφαρμογή τους συνοδεύεται από ορισμένες προκλήσεις. Η υλοποίηση αυτών των μεθόδων απαιτεί σημαντική αρχική επένδυση σε εξοπλισμό και λογισμικό, ενώ παράλληλα είναι αναγκαία η εκπαίδευση εξειδικευμένου προσωπικού που θα αναλάβει την ανάλυση και τη διαχείριση των δεδομένων. Επιπλέον, η αποτελεσματικότητα αυτών των μεθόδων εξαρτάται σε μεγάλο βαθμό από την ποιότητα και την ακρίβεια των δεδομένων που συλλέγονται, καθώς σφάλματα στη μέτρηση ή την επεξεργασία των δεδομένων μπορεί να οδηγήσουν σε λανθασμένες εκτιμήσεις και λανθασμένες αποφάσεις συντήρησης. Τέλος, η συνεχής εξέλιξη των τεχνολογιών απαιτεί διαρκή αναβάθμιση και προσαρμογή των χρησιμοποιούμενων εργαλείων και μεθόδων, ώστε να διασφαλίζεται η αξιοπιστία των αποτελεσμάτων.

### 3.3.2 Τεχνικές Πρόληψης Βλαβών στα Φωτοβολταϊκά Συστήματα

Η πρόληψη βλαβών είναι απαραίτητη για να διατηρούνται αποδοτικά και αξιόπιστα για πολλά χρόνια. Αντί να περιμένουμε να προκύψουν προβλήματα και να τα διορθώσουμε εκ των υστέρων, η προληπτική συντήρηση στοχεύει στο να τα αποτρέψει από το να συμβούν εξ αρχής. Αυτό επιτυγχάνεται με την εφαρμογή συγκεκριμένων μέτρων που προστατεύουν το σύστημα από φθορές και απρόβλεπτες βλάβες. Βασικές στρατηγικές πρόληψης περιλαμβάνουν τον τακτικό καθαρισμό για την αποφυγή συσσώρευσης ρύπων,

χιονιού ή πάγου στις επιφάνειες των πάνελ, καθώς και τη λήψη μέτρων που ενισχύουν την αντοχή των υλικών απέναντι σε μηχανικές καταπονήσεις.

Μια αποτελεσματική μέθοδος για την πρόληψη της συσσώρευσης ρύπων στα φωτοβολταϊκά πάνελ είναι η εφαρμογή ειδικών επιστρώσεων και επιφανειακών τροποποιήσεων. Αυτές οι τεχνικές βοηθούν στη μείωση των απωλειών απόδοσης που προκαλούνται από τη συγκέντρωση σκόνης και άλλων ρύπων στις επιφάνειες των πάνελ, συμβάλλοντας έτσι στη διατήρηση της υψηλής ενεργειακής παραγωγής. Μελέτες έχουν δείξει ότι η εφαρμογή αυτών των τεχνολογιών μπορεί να αυξήσει την παραγωγή ενέργειας από 1% έως 8%, ενώ η χρήση υδρόφοβων επιστρώσεων μπορεί να μειώσει τις απώλειες ισχύος από 5% έως 12% [4].

Οι επιφανειακές τροποποιήσεις στα φωτοβολταϊκά πάνελ περιλαμβάνουν την τροποποίηση της δομής της επιφάνειας μέσω της χρήσης μικροδομών ή ειδικών υλικών που στοχεύουν στη μείωση της προσκόλλησης ρύπων και νερού. Οι τεχνικές αυτές έχουν αποδειχθεί ιδιαίτερα αποτελεσματικές σε ελεγχόμενες εργαστηριακές συνθήκες, ωστόσο, η απόδοσή τους σε πραγματικές συνθήκες λειτουργίας μπορεί να επηρεαστεί από εξωτερικούς παράγοντες, όπως η υγρασία και η ένταση του ανέμου, οι οποίοι επιδρούν στη συμπεριφορά των ρύπων στην επιφάνεια των πάνελ. Παράλληλα, η εφαρμογή υδρόφοβων επιστρώσεων δημιουργεί ένα προστατευτικό φιλμ που αποτρέπει τη συσσώρευση σκόνης και υγρασίας, συμβάλλοντας στη μείωση της ανάγκης για συχνό καθαρισμό των πάνελ και διατηρώντας την απόδοσή τους σε υψηλά επίπεδα.

Η παρουσία χιονιού και πάγου στις επιφάνειες των φωτοβολταϊκών πάνελ μπορεί να αποτελέσει σημαντικό εμπόδιο στη βέλτιστη απόδοση του συστήματος, καθώς περιορίζει την ποσότητα ηλιακής ακτινοβολίας που φτάνει στις κυψέλες και μειώνει την ενεργειακή παραγωγή. Για την αντιμετώπιση αυτού του προβλήματος, έχουν αναπτυχθεί διάφορες τεχνικές που στοχεύουν στην πρόληψη της συσσώρευσης και στη διευκόλυνση της απομάκρυνσης του χιονιού και του πάγου από τις επιφάνειες των πάνελ. Αυτές οι στρατηγικές περιλαμβάνουν τη χρήση ειδικών επιφανειακών τεχνολογιών και επιστρώσεων που εμποδίζουν τη συσσώρευση και επιτρέπουν την ομαλή απομάκρυνσή τους.

### 3.3.3 Τεχνικές Μετριασμού των Βλαβών στα Φωτοβολταϊκά Συστήματα

Δεδομένου ότι οι περισσότερες βλάβες στα φωτοβολταϊκά συστήματα δεν μπορούν να αναστραφούν, η έρευνα επικεντρώνεται κυρίως στην πρόληψη και την έγκαιρη ανίχνευση, αντί για τον περιορισμό των συνεπειών τους. Παρόλα αυτά, υπάρχουν δύο βασικά προβλήματα που μπορούν να αντιμετωπιστούν αποτελεσματικά: η συσσώρευση ρύπων και η συγκέντρωση χιονιού ή πάγου στις επιφάνειες των πάνελ. Οι τεχνικές μετριασμού σε αυτές τις περιπτώσεις δίνουν έμφαση στον καθαρισμό των πάνελ από τη σκόνη και τους ρύπους, καθώς και στην απομάκρυνση του χιονιού και του πάγου, διασφαλίζοντας έτσι ότι το σύστημα λειτουργεί όσο το δυνατόν πιο αποδοτικά [4].

#### **Καθαρισμός Ρύπων στα Φωτοβολταϊκά**

Οι τεχνικές καθαρισμού περιλαμβάνουν τόσο χειροκίνητες όσο και αυτόνομες μεθόδους, με έμφαση στις υγρές και ξηρές τεχνικές που εξασφαλίζουν αποδοτική απομάκρυνση σκόνης και ρύπων. Σήμερα, σύγχρονα ρομποτικά και υδραυλικά συστήματα αυτοματοποιούν τη διαδικασία, μειώνοντας την ανάγκη για ανθρώπινη παρέμβαση.

#### **Αντιμετώπιση της Συσσώρευσης Χιονιού και Πάγου**

Οι θερμικές τεχνικές είναι από τις πιο αποτελεσματικές λύσεις, καθώς η θέρμανση των πάνελ διευκολύνει την τήξη και απομάκρυνση του χιονιού. Συχνά, χρησιμοποιούνται θερμαντικά στοιχεία που ενεργοποιούνται αυτόματα, ηλεκτρική θέρμανση μέσω αντίστροφης ροής ρεύματος ή κυκλοφορία θερμού νερού. Αυτές οι μέθοδοι συμβάλλουν στη μείωση του χρόνου εκτός λειτουργίας και στη διατήρηση της απόδοσης κατά τον χειμώνα.

### **3.4 Προκλήσεις και Περιορισμοί στη Συντήρηση Φωτοβολταϊκών**

Η συντήρηση των φωτοβολταϊκών συστημάτων αποτελεί ζωτικής σημασίας διαδικασία για τη διασφάλιση της μέγιστης ενεργειακής απόδοσης και της μακροχρόνιας λειτουργίας τους, ωστόσο συνοδεύεται από σημαντικές προκλήσεις και περιορισμούς. Παρόλο που η τεχνολογική πρόοδος και οι εξελιγμένες στρατηγικές συντήρησης έχουν βελτιώσει την αξιοπιστία των συστημάτων, εξακολουθούν να υπάρχουν αρκετές δυσκολίες που πρέπει να αντιμετωπιστούν. Δεν υπάρχει απόλυτη συμφωνία ως προς τα συνηθέστερα τεχνικά προβλήματα που επηρεάζουν την απόδοση των φωτοβολταϊκών εγκαταστάσεων.

Ορισμένες μελέτες υποδεικνύουν ότι το μεγαλύτερο ποσοστό των βλαβών συνδέεται με τα φωτοβολταϊκά πάνελ, ενώ άλλες αναφέρουν ότι οι μετατροπείς αποτελούν το πιο ευπαθές στοιχείο. Αυτή η διαφοροποίηση προκύπτει από τις διαφορετικές μεθοδολογίες παρακολούθησης που εφαρμόζονται, καθώς η ανάλυση στο επίπεδο των μετατροπέων μπορεί να ανιχνεύσει μόνο τις αστοχίες που αφορούν τον συγκεκριμένο εξοπλισμό, αγνοώντας πιθανά προβλήματα που σχετίζονται με τα πάνελ ή τις σειρές τους [23].

Ένα από τα μεγαλύτερα εμπόδια στη συντήρηση των φωτοβολταϊκών είναι η ανάγκη για αξιόπιστα και ακριβή δεδομένα. Για να εντοπιστούν και να διαγνωστούν βλάβες με ακρίβεια, είναι απαραίτητο να συλλέγονται συνεχώς δεδομένα υψηλής ποιότητας, κάτι που δεν είναι πάντα εύκολο. Η διαδικασία αυτή απαιτεί προηγμένους αισθητήρες και συστήματα παρακολούθησης, τα οποία μπορεί να είναι ακριβά και δύσκολα στη διαχείριση. Επιπλέον, ακόμα κι αν τα δεδομένα είναι διαθέσιμα, η ανάλυση και η σωστή ερμηνεία τους αποτελεί άλλη μια πρόκληση. Η χρήση τεχνικών τεχνητής νοημοσύνης και μηχανικής μάθησης έχει βελτιώσει σημαντικά την ακρίβεια της διάγνωσης, αλλά ταυτόχρονα απαιτεί ισχυρό υπολογιστικό εξοπλισμό και εξειδικευμένο προσωπικό, κάτι που αυξάνει το κόστος και τη δυσκολία εφαρμογής τους.

Ένα ακόμη σημαντικό εμπόδιο στη συντήρηση των φωτοβολταϊκών συστημάτων είναι το υψηλό κόστος εφαρμογής προηγμένων τεχνολογιών. Η ενσωμάτωση αυτοματοποιημένων συστημάτων παρακολούθησης και διάγνωσης, όπως η τεχνητή νοημοσύνη και τα ρομποτικά συστήματα, απαιτεί μια σημαντική αρχική επένδυση, η οποία μπορεί να είναι απαγορευτική για μικρότερες εγκαταστάσεις. Παρόλο που αυτές οι τεχνολογίες συμβάλλουν στη μείωση του κόστους λειτουργίας και συντήρησης σε βάθος χρόνου, η απόσβεση της επένδυσης δεν είναι άμεση. Σε πολλές περιπτώσεις, η απόδοση της επένδυσης μπορεί να χρειαστεί αρκετά χρόνια, γεγονός που καθιστά δύσκολη την υιοθέτησή τους από επιχειρήσεις με περιορισμένους πόρους [26].

Παρά τις τεχνολογικές εξελίξεις στις μεθόδους ανίχνευσης και διάγνωσης, η αξιόπιστη συντήρηση των φωτοβολταϊκών συστημάτων χωρίς συχνές επιτόπιες παρεμβάσεις παραμένει μια σημαντική πρόκληση. Τα διαθέσιμα συστήματα διάγνωσης δεν μπορούν πάντα να εντοπίσουν με ακρίβεια όλες τις πιθανές βλάβες, ενώ συχνά δεν παρέχουν σαφή εικόνα για τη σοβαρότητα του προβλήματος ή την ανάγκη άμεσης επισκευής. Για να είναι πραγματικά αποτελεσματικό, ένα προηγμένο σύστημα ανίχνευσης πρέπει να εντοπίζει

βλάβες σε πραγματικό χρόνο, να αξιολογεί τη σοβαρότητά τους, να απομονώνει τα προβληματικά σημεία και να παρέχει αξιόπιστες προβλέψεις για την αποφυγή μελλοντικών αστοχιών [13].

Η συνεχής παρακολούθηση και προσαρμογή των συστημάτων ανίχνευσης αποτελεί μια πρόκληση στη συντήρηση των φωτοβολταϊκών εγκαταστάσεων. Οι περιβαλλοντικές συνθήκες, όπως η σκόνη, η υγρασία και οι μεταβολές της θερμοκρασίας, επηρεάζουν την απόδοση των πάνελ, καθιστώντας απαραίτητη την προσαρμογή των στρατηγικών συντήρησης. Παράλληλα, οι τεχνολογικές εξελίξεις στην τεχνητή νοημοσύνη και την ανάλυση δεδομένων απαιτούν διαρκείς αναβαθμίσεις στα συστήματα παρακολούθησης, αυξάνοντας το κόστος και τις τεχνικές απαιτήσεις για τη συντήρησή τους.

Συμπερασματικά, η συντήρηση των φωτοβολταϊκών συστημάτων συνοδεύεται από σημαντικές προκλήσεις, όπως η διαχείριση και ανάλυση των δεδομένων, το υψηλό κόστος προηγμένων τεχνολογιών και η ανάγκη για συνεχή προσαρμογή στις μεταβαλλόμενες συνθήκες λειτουργίας. Παρά τη ραγδαία εξέλιξη των διαγνωστικών μεθόδων, η πλήρης αυτοματοποίηση της συντήρησης παραμένει δύσκολη, καθιστώντας απαραίτητο τον συνδυασμό νέων τεχνολογιών με αποτελεσματικές στρατηγικές διαχείρισης. Στο μέλλον, η αξιοποίηση καινοτόμων τεχνολογιών όπως τα συστήματα τεχνητής νοημοσύνης και τα ρομποτικά μέσα συντήρησης, αναμένεται να βελτιώσουν τη διαδικασία συντήρησης, ενισχύοντας την αξιοπιστία και τη βιωσιμότητα των φωτοβολταϊκών εγκαταστάσεων.




## **Κεφάλαιο 4 Χρήση της Τεχνητής Νοημοσύνης στη Συντήρηση Φωτοβολταϊκών Συστημάτων**

### **4.1 Εισαγωγή στην Τεχνητή Νοημοσύνη και τα Υποσύνολά της**

Η Τεχνητή Νοημοσύνη (TN) αποτελεί ένα από τα πιο δυναμικά πεδία της σύγχρονης τεχνολογίας, με εφαρμογές που καλύπτουν ένα ευρύ φάσμα τομέων, συμπεριλαμβανομένης της ενέργειας και της διαχείρισης φωτοβολταϊκών συστημάτων. Ο όρος TN αναφέρεται σε ένα σύνολο μεθόδων και αλγορίθμων που επιτρέπουν στους υπολογιστές να εκτελούν εργασίες που παραδοσιακά απαιτούν ανθρώπινη νοημοσύνη, όπως η αναγνώριση προτύπων, η λήψη αποφάσεων και η αυτοματοποίηση διαδικασιών. Στο πλαίσιο των φωτοβολταϊκών εγκαταστάσεων, η TN προσφέρει δυνατότητες όπως η πρόβλεψη ενεργειακής παραγωγής, η ανίχνευση βλαβών, η βελτιστοποίηση της λειτουργίας και η αποδοτικότερη διαχείριση της αποθηκευμένης ενέργειας.

Η Τεχνητή Νοημοσύνη περιλαμβάνει τη Μηχανική Μάθηση και τη Βαθιά Μάθηση, οι οποίες αποτελούν τις κύριες μεθόδους που αξιοποιούνται για την ανάλυση δεδομένων και τη λήψη αποφάσεων σε φωτοβολταϊκά συστήματα. Στο Σχήμα 4 παρουσιάζεται η σχέση και οι διαφορές μεταξύ αυτών των τεχνολογιών. Η Μηχανική Μάθηση αποτελεί υποσύνολο της TN και βασίζεται στην ανάπτυξη αλγορίθμων που μαθαίνουν από δεδομένα και βελτιώνουν την απόδοσή τους μέσω εμπειρίας. Αντίθετα, η Βαθιά Μάθηση, που ανήκει στη Μηχανική Μάθηση, χρησιμοποιεί πολυστρωματικά Νευρωνικά Δίκτυα, επιτρέποντας την επεξεργασία πιο πολύπλοκων δεδομένων χωρίς να απαιτείται ανθρώπινη παρέμβαση στην εξαγωγή χαρακτηριστικών. Η κύρια διαφορά τους έγκειται στο ότι η Μηχανική Μάθηση μπορεί να λειτουργήσει αποτελεσματικά με μικρότερο όγκο δεδομένων, ενώ η Βαθιά Μάθηση απαιτεί μεγάλες ποσότητες πληροφοριών για εκπαίδευση, επιτυγχάνοντας μεγαλύτερη ακρίβεια σε πολύπλοκα προβλήματα.



Σχήμα 4: Σχέση και διαφορές AI, ML και DL [12]

#### 4.1.1 Μηχανική Μάθηση

Η Μηχανική Μάθηση (Machine Learning - ML) είναι ένας από τους βασικούς κλάδους της Τεχνητής Νοημοσύνης (TN) και επικεντρώνεται στην ανάπτυξη αλγορίθμων που επιτρέπουν στους υπολογιστές να μαθαίνουν από δεδομένα, χωρίς να απαιτείται ρητός προγραμματισμός. Οι αλγόριθμοι αυτοί βελτιώνουν συνεχώς την απόδοσή τους μέσω της εμπειρίας και της προσαρμογής σε νέα δεδομένα, καθιστώντας τη μηχανική μάθηση ιδανική για εφαρμογές που απαιτούν αναγνώριση μοτίβων και πρόβλεψη μελλοντικών συμπεριφορών [12].

Στον τομέα της συντήρησης φωτοβολταϊκών συστημάτων, η μηχανική μάθηση χρησιμοποιείται για τη βελτίωση της πρόβλεψης κρίσιμων παραμέτρων, όπως η ηλιακή ακτινοβολία, η θερμοκρασία των κυψελών και η ενεργειακή απόδοση. Μέσω της ανάλυσης ιστορικών δεδομένων, τα μοντέλα μηχανικής μάθησης μπορούν να αναγνωρίσουν περίπλοκα μοτίβα και να προβλέψουν πιθανά σφάλματα ή αποκλίσεις στη λειτουργία των φωτοβολταϊκών πάνελ. Αυτό επιτρέπει την έγκαιρη ανίχνευση προβλημάτων και τη μείωση του χρόνου εκτός λειτουργίας των εγκαταστάσεων [15, 32, 33].

Η μηχανική μάθηση διακρίνεται σε τέσσερις κύριες κατηγορίες: [13]

**Επιβλεπόμενη μάθηση:** Οι αλγόριθμοι εκπαιδεύονται με δεδομένα που περιέχουν προκαθορισμένες ετικέτες εισόδου και εξόδου, ώστε να δημιουργήσουν σχέσεις και να προβλέψουν μελλοντικά αποτελέσματα. Εφαρμογές αυτής της τεχνικής στα

φωτοβολταϊκά συστήματα περιλαμβάνουν την ταξινόμηση βλαβών (όπως αναγνώριση hotspots και μικρορωγμών) μέσω υποστηρικτικών διανυσματικών μηχανών (SVMs), νευρωνικών δικτύων και δέντρων απόφασης. Οι αλγόριθμοι επιβλεπόμενης μάθησης μπορούν να αξιοποιηθούν για τη διάγνωση προβλημάτων, όπως βλάβες στα πάνελ ή στους μετατροπείς ισχύος, με βάση ιστορικά δεδομένα από αισθητήρες.

**Μη επιβλεπόμενη μάθηση:** Οι αλγόριθμοι δεν έχουν προκαθορισμένες ετικέτες εξόδου και χρησιμοποιούνται για την ανίχνευση ανωμαλιών στα δεδομένα των φωτοβολταϊκών, εντοπίζοντας αποκλίσεις από τη φυσιολογική λειτουργία. Οι αλγόριθμοι μη επιβλεπόμενης μάθησης είναι χρήσιμοι για την ανίχνευση ανωμαλιών και τη δημιουργία προτύπων λειτουργίας, χωρίς να απαιτείται προϋπάρχουσα γνώση των πιθανών βλαβών.

**Ημιαυτόνομη μάθηση:** Συνδυάζει δεδομένα με ετικέτες και μη επισημασμένα δεδομένα, βοηθώντας όταν η επισημανση δεδομένων είναι δύσκολη ή χρονοβόρα. Χρησιμοποιείται στη διάγνωση της υποβάθμισης των φωτοβολταϊκών μονάδων και στην ταξινόμηση βλαβών με μειωμένο κόστος δεδομένων.

**Ενισχυτική μάθηση:** Οι αλγόριθμοι μαθαίνουν μέσω δοκιμών και αλληλεπίδρασης με το περιβάλλον, προσαρμόζοντας τις ενέργειές τους βάσει ανταμοιβών. Αυτή η τεχνική μπορεί να βελτιστοποιήσει τη γωνία των πάνελ καθ' όλη τη διάρκεια της ημέρας και να βελτιώσει τη συνολική διαχείριση της παραγόμενης ενέργειας.

#### 4.1.2 Βαθιά μάθηση

Η Βαθιά Μάθηση (Deep Learning - DL) είναι μια προηγμένη μέθοδος της Μηχανικής Μάθησης που χρησιμοποιεί πολυστρωματικά Νευρωνικά Δίκτυα (Deep Neural Networks - DNNs). Σε αντίθεση με τις παραδοσιακές μεθόδους της μηχανικής μάθησης, όπου πρέπει πρώτα να εξάγουμε χαρακτηριστικά από τα δεδομένα πριν ξεκινήσει η εκπαίδευση του μοντέλου, η βαθιά μάθηση δεν χρειάζεται αυτό το στάδιο. Οι αλγόριθμοι της είναι σε θέση να «μαθαίνουν» και να εξάγουν χαρακτηριστικά απευθείας από τα δεδομένα εισόδου, επιτρέποντας έτσι την καλύτερη προσαρμογή σε πιο περίπλοκα δεδομένα και την αναγνώριση μοτίβων με μεγαλύτερη ακρίβεια.

Η βαθιά μάθηση θεωρείται μια εξέλιξη των παραδοσιακών Νευρωνικών Δικτύων (θα γίνει πλήρης αναφορά των Νευρωνικών Δικτύων στο κεφάλαιο 4.3.1), καθώς χρησιμοποιεί πολυεπίπεδες δομές που επιτρέπουν την πιο αποδοτική εκμάθηση και αναπαράσταση

των δεδομένων. Παρά τα πλεονεκτήματα της, όπως και τα κλασικά νευρωνικά δίκτυα, η βαθιά μάθηση αντιμετωπίζει προκλήσεις κατά την εκπαίδευση, όπως η υπερπροσαρμογή (όταν το μοντέλο μαθαίνει πολύ καλά τα δεδομένα εκπαίδευσης, αλλά δυσκολεύεται να τα εφαρμόσει σε νέα δεδομένα, με αποτέλεσμα να αποδίδει άσχημα σε παραδείγματα που δεν έχει ξαναδεί) και η εξασθένιση των βαθμίδων (όταν τα σφάλματα που διορθώνονται κατά την εκπαίδευση του μοντέλου γίνονται πολύ μικρά στα πιο βαθιά επίπεδα του δικτύου, με αποτέλεσμα αυτά τα επίπεδα να μην εκπαιδεύονται σωστά). Ωστόσο, το μεγάλο πλεονέκτημα των DNNs είναι ότι όσο περισσότερα είναι τα δεδομένα, τόσο καλύτερα αποδίδουν, καθιστώντας τα ιδανικά για εφαρμογές σε μεγάλες και πολύπλοκες βάσεις δεδομένων.

Η βαθιά μάθηση αποτελεί ένα από τα πιο ισχυρά εργαλεία για την πρόβλεψη της απόδοσης και τη συντήρηση των φωτοβολταϊκών συστημάτων. Οι εξελιγμένες δυνατότητές της στη διάγνωση βλαβών, την επεξεργασία εικόνας και την πρόγνωση ενεργειακής παραγωγής την καθιστούν απαραίτητη στη βελτιστοποίηση των φωτοβολταϊκών [12, 13, 34].

## **4.2 Θεμελιώδεις Τεχνολογίες Βασικές Εφαρμογές**

Οι βασικές εφαρμογές της τεχνητής νοημοσύνης (TN) περιλαμβάνουν την προγνωστική συντήρηση, τη βελτιστοποίηση της απόδοσης, την πρόβλεψη της παραγωγής, την ανίχνευση βλαβών και τη διαχείριση ενέργειας.

Η TN αναλύει ιστορικά δεδομένα από αισθητήρες και μετρήσεις, αναγνωρίζοντας μοτίβα που υποδεικνύουν επικείμενες αστοχίες σε κρίσιμα εξαρτήματα, όπως μετατροπείς και πάνελ. Με αυτόν τον τρόπο, οι βλάβες μπορούν να προβλεφθούν και να προληφθούν πριν οδηγήσουν σε σοβαρά προβλήματα, διασφαλίζοντας τη συνεχή και αποδοτική λειτουργία του συστήματος.

Η βελτιστοποίηση της απόδοσης αποτελεί μια ακόμη κρίσιμη εφαρμογή της TN. Μέσω αλγορίθμων δυναμικής προσαρμογής, η γωνία των πάνελ μπορεί να ρυθμίζεται ανάλογα με τις εποχιακές αλλαγές και τον προσανατολισμό του ήλιου, διασφαλίζοντας ότι τα φωτοβολταϊκά λειτουργούν υπό τις βέλτιστες συνθήκες. Παράλληλα, η ανάλυση μετεωρολογικών δεδομένων, όπως η ηλιοφάνεια και η θερμοκρασία, επιτρέπει την ακριβή πρόβλεψη της παραγωγής ηλιακής ενέργειας, συμβάλλοντας στη βέλτιστη

διαχείριση των ενεργειακών πόρων και στην αποτελεσματική ένταξή τους στο ηλεκτρικό δίκτυο.

Ένας άλλος κρίσιμος τομέας είναι η ανίχνευση και διάγνωση βλαβών. Η ΤΝ χρησιμοποιεί αισθητήρες, θερμικές εικόνες και ηλεκτροφωταυγείς απεικονίσεις για την αναγνώριση πιθανών ανωμαλιών στα φωτοβολταϊκά πάνελ και τους μετατροπείς. Με την επεξεργασία αυτών των δεδομένων μέσω τεχνικών βαθιάς μάθησης, είναι δυνατή η αυτόματη και ακριβής ανίχνευση hotspots, ρωγμών και βλαβών, συμβάλλοντας στη μείωση του χρόνου συντήρησης και την πρόληψη σοβαρών αστοχιών.

Επιπλέον, η ΤΝ διαδραματίζει σημαντικό ρόλο στη διαχείριση ενέργειας και αποθήκευσης. Μέσω εξελιγμένων αλγορίθμων, επιτυγχάνει την εξισορρόπηση της προσφοράς και της ζήτησης, ρυθμίζοντας δυναμικά τη ροή της ενέργειας μεταξύ των φωτοβολταϊκών συστημάτων, των μπαταριών αποθήκευσης και του δικτύου. Με αυτόν τον τρόπο, οι διακυμάνσεις στη ζήτηση και την παραγωγή μπορούν να αντιμετωπιστούν αποτελεσματικά, διατηρώντας τη σταθερότητα του δικτύου.

Τέλος, η ΤΝ βελτιώνει τον σχεδιασμό φωτοβολταϊκών εγκαταστάσεων μέσω προσομοιώσεων. Χρησιμοποιώντας προχωρημένες τεχνικές μοντελοποίησης, μπορεί να προβλέψει την απόδοση διαφορετικών διατάξεων πάνελ σε ποικίλες καιρικές συνθήκες, επιτρέποντας τη βελτιστοποίηση του σχεδιασμού για τη μέγιστη δυνατή απόδοση [12].

#### 4.2.1 Ανίχνευση Βλαβών

Η εξέλιξη της Τεχνητής Νοημοσύνης (ΤΝ) έχει φέρει σημαντικές αλλαγές στην ανίχνευση βλαβών στα φωτοβολταϊκά συστήματα, καθιστώντας τη διαδικασία πιο ακριβή και αποδοτική. Οι αλγόριθμοι ΤΝ χρησιμοποιούν δεδομένα από αισθητήρες που παρακολουθούν τη λειτουργία των πάνελ και άλλων κρίσιμων μονάδων, επιτρέποντας την ανάλυση σε πραγματικό χρόνο και τη μείωση του χρόνου διακοπής λειτουργίας. Παράλληλα, η ΤΝ βοηθά στην κατανόηση των αιτίων των βλαβών, διευκολύνοντας πιο στοχευμένες ενέργειες συντήρησης.

Για την ανίχνευση βλαβών χρησιμοποιούνται διάφορες τεχνικές, όπως Νευρωνικά Δίκτυα (ANN), Δίκτυα Μπεϋζιανής Πεποίθησης (BBN), Ασαφή Λογική (Fuzzy Logic), Υποστηρικτικοί Διανυσματικοί Ταξινομητές (SVM), Δέντρα Απόφασης (DT), Τυχαία Δάση (Random Forest) και άλλες στατιστικές μέθοδοι, όπως η Λογιστική Παλινδρόμηση και ο Αφελής

Ταξινομητής Bayes [35, 36, 37]. Στα επόμενα τμήματα, θα εξετάσουμε αναλυτικά τις βασικές τεχνικές ανίχνευσης βλαβών και τα πλεονεκτήματα που προσφέρουν στην προληπτική συντήρηση των φωτοβολταϊκών συστημάτων.

### **Νευρωνικά Δίκτυα (Artificial Neural Networks - ANN)**

Τα Τεχνητά Νευρωνικά Δίκτυα (ANN) είναι μια από τις πιο εξελιγμένες μεθόδους τεχνητής νοημοσύνης για την ανίχνευση βλαβών στα φωτοβολταϊκά συστήματα. Βασισμένα στη λειτουργία του ανθρώπινου εγκεφάλου, τα ANN χρησιμοποιούν πολλαπλά επίπεδα τεχνητών νευρώνων για να αναγνωρίσουν μοτίβα σε μεγάλες και σύνθετες βάσεις δεδομένων [3].

Η εφαρμογή τους σε δικτυωμένα φωτοβολταϊκά συστήματα (Grid-Connected Photovoltaic Systems - GCPVS) έχει αποδώσει καλά στην ανίχνευση ανωμαλιών, όπως υπερθέρμανση εξαρτημάτων, μείωση της παραγόμενης ισχύος και ασυνήθιστες μετρήσεις τάσης. Εξειδικευμένα ANN μπορούν να εντοπίσουν και να καταγράψουν βραχυκυκλώματα σε μια σειρά φωτοβολταϊκών μονάδων με υψηλή ακρίβεια και ανάλυση σε πραγματικό χρόνο. Επιπλέον, τα ANN έχουν καταφέρει να επιτύχουν ακρίβεια έως 100% στην ταξινόμηση βλαβών μέσω ανάλυσης θερμικών εικόνων και δεδομένων ρεύματος-τάσης (I-V), όπως η ανίχνευση hotspots, ρωγμών και συσσώρευσης ρύπων [12].

Τα ANN περιλαμβάνουν τρία βασικά επίπεδα: το επίπεδο εισόδου, τα κρυφά επίπεδα και το επίπεδο εξόδου. Στο επίπεδο εισόδου, τα δεδομένα προέρχονται από αισθητήρες που μετρούν την ηλιακή ακτινοβολία, τη θερμοκρασία των πάνελ και τα ηλεκτρικά χαρακτηριστικά του συστήματος. Στη συνέχεια, στα κρυφά επίπεδα, πραγματοποιείται η επεξεργασία αυτών των δεδομένων μέσω των νευρώνων, που επιτρέπει την αναγνώριση σχέσεων και μοτίβων που σχετίζονται με βλάβες. Τέλος, το επίπεδο εξόδου παρέχει τις τελικές προβλέψεις ή ταξινομήσεις, όπως η αναγνώριση δυσλειτουργιών ή η εκτίμηση της απόδοσης του συστήματος [26].

Υπάρχουν διάφοροι τύποι Νευρωνικών Δικτύων που χρησιμοποιούνται στην ανίχνευση βλαβών στα φωτοβολταϊκά συστήματα. Τα Πολυστρωματικά Νευρωνικά Δίκτυα (MLP) χρησιμοποιούνται για την πρόβλεψη της διάρκειας ζωής των εξαρτημάτων, αξιοποιώντας δεδομένα από αισθητήρες που καταγράφουν δονήσεις, θερμοκρασία και ροή ρεύματος.

Τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNN), και συγκεκριμένα τα Δίκτυα Long Short-Term Memory (LSTM), είναι ιδανικά για την ανάλυση χρονοσειρών και την πρόβλεψη της απόδοσης των φωτοβολταϊκών συστημάτων σε βάθος χρόνου. Από την άλλη, τα Συνελικτικά Νευρωνικά Δίκτυα (CNN) χρησιμοποιούνται κυρίως για την επεξεργασία εικόνων, επιτρέποντας την ανίχνευση βλαβών στα φωτοβολταϊκά πάνελ μέσω της ανάλυσης θερμικών εικόνων και εικόνων υψηλής ανάλυσης. Αυτή η τεχνική εντοπίζει με μεγάλη ακρίβεια ελαττώματα όπως ρωγμές, hotspots και αλλοιώσεις [26].

Ωστόσο, για να λειτουργήσουν αποδοτικά, τα νευρωνικά δίκτυα απαιτούν μεγάλο όγκο δεδομένων για εκπαίδευση, καθώς και σημαντικούς υπολογιστικούς πόρους, γεγονός που καθιστά την εφαρμογή τους απαιτητική. Επιπλέον, λόγω της πολύπλοκης δομής τους, τα Νευρωνικά Δίκτυα λειτουργούν ως ένα είδος «μαύρου κουτιού», καθώς δεν είναι εύκολο να κατανοηθεί ο τρόπος με τον οποίο λαμβάνουν τις αποφάσεις τους. Αυτό σημαίνει ότι, παρόλο που μπορούν να ανιχνεύσουν βλάβες με υψηλή ακρίβεια, δεν παρέχουν πάντα ξεκάθαρες εξηγήσεις για το πώς κατέληξαν σε ένα συγκεκριμένο συμπέρασμα. Αυτή η έλλειψη διαφάνειας τα καθιστά λιγότερο πρακτικά για μικρές εγκαταστάσεις, όπου είναι σημαντικό να γνωρίζουμε ακριβώς ποιοι παράγοντες οδήγησαν σε μια διάγνωση. Αντίθετα, χρησιμοποιούνται κυρίως σε μεγάλης κλίμακας φωτοβολταϊκά πάρκα, όπου η προτεραιότητα είναι η ακρίβεια της ανίχνευσης και όχι τόσο η ερμηνεία της διαδικασίας [12]. Παρόλα αυτά, η έρευνα στον τομέα των ANN συνεχίζεται, με νεότερες τεχνικές, όπως τα συνελικτικά νευρωνικά δίκτυα (CNN) και η βαθιά μάθηση, να βελτιώνουν συνεχώς την αποτελεσματικότητά τους στην ανίχνευση και διάγνωση βλαβών.

### **Δίκτυα Μπεϋζιανής Πεποίθησης (Bayesian Belief Networks – BBN)**

Τα Δίκτυα Μπεϋζιανής Πεποίθησης (BBN) αποτελούν μια στατιστική μέθοδο που βασίζεται στη θεωρία πιθανοτήτων και χρησιμοποιείται για τη λήψη αποφάσεων υπό συνθήκες αβεβαιότητας. Η δομή τους περιλαμβάνει κατευθυνόμενα μη κυκλικά γραφήματα, όπου οι κόμβοι αντιπροσωπεύουν τυχαίες μεταβλητές και οι συνδέσεις τους δείχνουν τις πιθανολογικές σχέσεις μεταξύ τους. Αυτή η προσέγγιση επιτρέπει την εξαγωγή συμπερασμάτων ακόμα και όταν οι διαθέσιμες πληροφορίες είναι ελλιπείς ή ασαφείς, καθιστώντας τα ιδιαίτερα χρήσιμα στην ανίχνευση βλαβών σε φωτοβολταϊκά συστήματα.

Στην ανίχνευση βλαβών, τα BBN χρησιμοποιούνται για την ταυτοποίηση των πιθανών αιτίων δυσλειτουργιών μέσω της ανάλυσης δεδομένων αισθητήρων και της συσχέτισής τους με πρότυπα απόδοσης. Έρευνες έχουν δείξει ότι μοντέλα BBN μπορούν να επικυρώσουν μετρήσεις και να τις αντιστοιχίσουν σε πιθανές αιτίες βλαβών, χρησιμοποιώντας πιθανολογική συλλογιστική [3]. Παράλληλα, έχουν εφαρμοστεί σε GCPVS για την ανίχνευση προσωρινών και μόνιμων βλαβών, επιτρέποντας την εκτίμηση της πιθανότητας εμφάνισης προβλημάτων βάσει ιστορικών δεδομένων και τρεχουσών μετρήσεων. Αν και προσφέρουν αξιόπιστες εκτιμήσεις, δεν είναι πάντα σε θέση να διαγνώσουν με ακρίβεια συγκεκριμένους τύπους βλαβών [13].

Το βασικό πλεονέκτημα των BBN είναι η ικανότητά τους να λειτουργούν ακόμα και σε συνθήκες αβεβαιότητας, καθώς και η δυνατότητα συνδυασμού πληροφοριών από διαφορετικές πηγές, όπως αισθητήρες και ιστορικά δεδομένα, για μια πιο ολοκληρωμένη ανάλυση. Ωστόσο, η αποτελεσματικότητά τους εξαρτάται από τη σωστή εκπαίδευση του μοντέλου, που απαιτεί μεγάλο όγκο δεδομένων, ενώ η ακρίβειά τους μπορεί να περιοριστεί αν δεν υποστηρίζονται από άλλες διαγνωστικές τεχνικές.

### **Ασαφής λογική (Fuzzy Logic - FL)**

Η ασαφής λογική (Fuzzy Logic - FL) αποτελεί μια ευέλικτη προσέγγιση για την ανίχνευση βλαβών στα φωτοβολταϊκά συστήματα, ειδικά σε περιπτώσεις όπου τα διαθέσιμα δεδομένα περιέχουν αβεβαιότητα ή θόρυβο. Βασίζεται σε ένα σύστημα κανόνων και λεκτικών μεταβλητών που επιτρέπουν την επεξεργασία ασαφών δεδομένων, χωρίς την ανάγκη αυστηρής μαθηματικής μοντελοποίησης. Μια από τις κύριες εφαρμογές της είναι η μέθοδος Takagi-Sugeno-Kahn (TSKFR), η οποία συγκρίνει τη μετρούμενη και την εκτιμώμενη ισχύ του συστήματος, εντοπίζοντας και ταξινομώντας πάνω από το 90% των βλαβών, ακόμα και σε συνθήκες θορύβου ή ελλιπών δεδομένων. Μέσω αυτής της τεχνικής, μπορούν να ανιχνευθούν βλάβες όπως σπασμένα κελιά, σκίαση και βραχυκυκλώματα, που επηρεάζουν αρνητικά την απόδοση των φωτοβολταϊκών πάνελ [3].

Παράλληλα, η FL έχει εφαρμοστεί και στην ανίχνευση ελαττωματικών διόδων, διείσδυσης νερού και σκίασης, επιτυγχάνοντας εξίσου υψηλή ακρίβεια. Ένα από τα μεγαλύτερα πλεονεκτήματά της είναι η ευελιξία της, καθώς μπορεί να προσαρμοστεί εύκολα σε



διαφορετικά φωτοβολταϊκά συστήματα, χωρίς να απαιτείται η δημιουργία πολύπλοκων μαθηματικών μοντέλων. Αντί να βασίζεται αποκλειστικά σε αριθμητικούς υπολογισμούς, χρησιμοποιεί ένα σύνολο κανόνων που αντικατοπτρίζουν τη λειτουργία του συστήματος.

Η ασαφής λογική παρουσιάζει σημαντικά πλεονεκτήματα, καθώς αντιμετωπίζει την αβεβαιότητα στα δεδομένα, προσαρμόζεται εύκολα και επιτυγχάνει υψηλή ακρίβεια στην ανίχνευση προβλημάτων, όπως σκίαση και βραχυκυκλώματα. Ωστόσο, η αποτελεσματικότητά της εξαρτάται από την ποιότητα των κανόνων που έχουν οριστεί, καθώς εσφαλμένοι ή ελλιπείς κανόνες μπορεί να μειώσουν την ακρίβεια της διάγνωσης. Επιπλέον, σε πιο σύνθετες περιπτώσεις, όπου απαιτείται ανάλυση μεγάλου όγκου δεδομένων, η FL συνήθως συνδυάζεται με άλλες τεχνικές, όπως τα νευρωνικά δίκτυα και οι υποστηρικτικοί διανυσματικοί ταξινομητές (SVM), για μεγαλύτερη ακρίβεια και αποτελεσματικότητα [13].

#### **Υβριδικές Μέθοδοι: Συνδυασμός SVM και k-NN στην Ανίχνευση Βλαβών**

Ο συνδυασμός Υποστηρικτικών Διανυσματικών Ταξινομητών (SVM) και K-Πλησιέστερων Γειτόνων (k-NN) αποτελεί μια ισχυρή υβριδική μέθοδο για την ανίχνευση βλαβών στα φωτοβολταϊκά συστήματα. Τα SVM προσφέρουν υψηλή ακρίβεια στη διάκριση διαφορετικών τύπων βλαβών, αξιοποιώντας πυρηνικές συναρτήσεις για την ανάλυση μη γραμμικών δεδομένων. Ειδικότερα, τα SVMs θεωρούνται από τους πιο αξιόπιστους αλγορίθμους για την ταξινόμηση και την ανάλυση δεδομένων συντήρησης, καθώς είναι σε θέση να εντοπίζουν μη γραμμικές σχέσεις μεταξύ μεταβλητών. Χρησιμοποιούνται για τη διάγνωση σφαλμάτων και την πρόβλεψη της υποβάθμισης εξαρτημάτων [23]. Από την άλλη πλευρά, η μέθοδος k-NN συγκρίνει νέες περιπτώσεις με ήδη γνωστές, χωρίς την ανάγκη εκπαίδευσης μοντέλου, επιτρέποντας γρήγορη ταξινόμηση. Ο συνδυασμός αυτών των τεχνικών βελτιώνει την ακρίβεια και τη σταθερότητα της διάγνωσης, ιδιαίτερα σε θορυβώδη δεδομένα [3].

Η υβριδική προσέγγιση έχει εφαρμοστεί στην ανίχνευση συγκεκριμένων βλαβών, όπως βραχυκυκλώματα, δυσλειτουργίες διόδων bypass, δηλαδή βλαβών στις διόδους που επιτρέπουν την παράκαμψη σκιασμένων ή κατεστραμμένων κυψελών, καθώς και προβλήματα στις διόδους μπλοκαρίσματος, οι οποίες αποτρέπουν την αντίστροφη ροή

ρεύματος και μειώνουν τις ενεργειακές απώλειες, επιτυγχάνοντας ακρίβεια ταξινόμησης έως και 99.64% [3]. Αυτό καθιστά τη μέθοδο ιδανική για την προγνωστική συντήρηση φωτοβολταϊκών εγκαταστάσεων, μειώνοντας τις πιθανότητες ψευδών διαγνώσεων και επιτρέποντας έγκαιρη παρέμβαση.

Παρόλο που τα SVM-kNN παρουσιάζουν υψηλή αποτελεσματικότητα, απαιτούν σημαντικούς υπολογιστικούς πόρους, ιδιαίτερα σε μεγάλα σύνολα δεδομένων. Επιπλέον, η απόδοσή τους εξαρτάται από την κατάλληλη επιλογή παραμέτρων, όπως ο αριθμός K στο k-NN, που καθορίζει πόσους γειτονικούς πόντους θα εξετάζει το μοντέλο για την ταξινόμηση, και η πυρηνική συνάρτηση στα SVM, η οποία μετασχηματίζει τα δεδομένα σε υψηλότερη διάσταση για καλύτερο διαχωρισμό. Παρά τις προκλήσεις αυτές, η χρήση αυτής της υβριδικής μεθόδου συμβάλλει σημαντικά στη βελτίωση της αξιοπιστίας και της αποδοτικότητας των φωτοβολταϊκών συστημάτων, καθιστώντας την μια πολλά υποσχόμενη τεχνική στον τομέα της προγνωστικής συντήρησης [3, 12].

### **Δέντρα Απόφασης (Decision Trees - DT)**

Τα Δέντρα Απόφασης (Decision Trees - DT) είναι μια τεχνική μηχανικής μάθησης που η λειτουργία τους βασίζεται στη διαίρεση των δεδομένων σε διαδοχικά επίπεδα, όπου κάθε κόμβος εξετάζει ένα συγκεκριμένο χαρακτηριστικό του συστήματος και οδηγεί σε μια απόφαση. Με αυτόν τον τρόπο, τα DT μπορούν να αναγνωρίσουν μοτίβα που σχετίζονται με βλάβες και να ταξινομήσουν τις δυσλειτουργίες με βάση τα δεδομένα αισθητήρων.

Η μέθοδος αυτή έχει εφαρμοστεί για τον εντοπισμό συνηθισμένων προβλημάτων, όπως τα βραχυκυκλώματα στις φωτοβολταϊκές μονάδες, η σκίαση των πάνελ και τα ανοικτά κυκλώματα που επηρεάζουν την απόδοση του συστήματος. Έρευνες έχουν δείξει ότι η χρήση DT μπορεί να επιτύχει υψηλά ποσοστά ακρίβειας στη διάγνωση τέτοιων προβλημάτων, παρέχοντας αξιόπιστες προβλέψεις για την κατάσταση του εξοπλισμού.

Ένα από τα βασικά πλεονεκτήματα των Δέντρων Απόφασης είναι η ευκολία κατανόησης και ερμηνείας τους. Οι αποφάσεις τους βασίζονται σε σαφείς κανόνες, γεγονός που επιτρέπει στους τεχνικούς να κατανοούν πώς κατέληξε το μοντέλο σε μια συγκεκριμένη διάγνωση. Επιπλέον, είναι ιδιαίτερα γρήγορα στην εκτέλεση, κάτι που τα καθιστά κατάλληλα για ανίχνευση βλαβών σε πραγματικό χρόνο.

Ωστόσο, η απόδοσή τους μπορεί να επηρεαστεί από την υπερπροσαρμογή, δηλαδή την τάση να απομνημονεύουν τα δεδομένα εκπαίδευσης χωρίς να γενικεύουν σωστά σε νέες περιπτώσεις. Επίσης, όταν οι βλάβες παρουσιάζουν πολύπλοκες αλληλεπιδράσεις, ένα απλό Δέντρο Απόφασης μπορεί να μην είναι αρκετά ακριβές, γι' αυτό και συχνά συνδυάζεται με πιο προηγμένες τεχνικές, όπως τα Τυχαία Δάση (Random Forest), για καλύτερη απόδοση [12,13].

### **Τυχαία Δάση (Random Forest - RF)**

Τα Τυχαία Δάση (Random Forest - RF) είναι μια εξελιγμένη τεχνική μηχανικής μάθησης που χρησιμοποιεί πολλά Δέντρα Απόφασης (Decision Trees - DT) για την ταξινόμηση και ανάλυση δεδομένων. Σε κάθε δέντρο εκχωρούνται διαφορετικά τυχαία υποσύνολα δεδομένων, ενώ η τελική απόφαση προκύπτει από το συνδυασμό των επιμέρους προβλέψεων. Αυτή η προσέγγιση μειώνει τον κίνδυνο υπερπροσαρμογής και βελτιώνει την ακρίβεια, καθιστώντας τα RF ιδανικά για εφαρμογές όπου η ακρίβεια και η ανθεκτικότητα είναι κρίσιμες.

Στον τομέα των φωτοβολταϊκών συστημάτων, τα RF χρησιμοποιούνται για την ανίχνευση και ταξινόμηση βλαβών, όπως η σκίαση που επηρεάζει την απόδοση, τα βραχυκυκλώματα που προκαλούν δυσλειτουργίες και η υποβάθμιση των πάνελ, η οποία μπορεί να οδηγήσει σε υπερθέρμανση και hotspots. Μέσω ανάλυσης δεδομένων από αισθητήρες και θερμικές εικόνες, έχουν αποδειχθεί ιδιαίτερα αποτελεσματικά, επιτυγχάνοντας ακρίβεια σχεδόν 99,98% στην ταξινόμηση προβλημάτων.

Ένα από τα βασικά πλεονεκτήματα των RF είναι η ικανότητά τους να διαχειρίζονται πολύπλοκα και μεγάλα σύνολα δεδομένων, προσφέροντας σταθερότητα και υψηλή ακρίβεια. Επίσης, μπορούν να ενσωματώσουν δεδομένα από διαφορετικές πηγές, όπως μετεωρολογικές μετρήσεις και ιστορικά στοιχεία, βελτιώνοντας τη συνολική αξιοπιστία των διαγνώσεων. Ωστόσο, το υψηλό υπολογιστικό κόστος και η δυσκολία ερμηνείας των αποτελεσμάτων τους είναι δύο βασικοί περιορισμοί, ειδικά όταν εφαρμόζονται σε μεγάλης κλίμακας φωτοβολταϊκές εγκαταστάσεις.

Παρά τις προκλήσεις, τα Τυχαία Δάση αποτελούν μια από τις πιο αξιόπιστες μεθόδους για την ανίχνευση βλαβών στα φωτοβολταϊκά συστήματα. Η συνδυαστική τους χρήση με

άλλες τεχνικές, όπως τα Νευρωνικά Δίκτυα και η Ανάλυση Θερμικών Εικόνων, μπορεί να βελτιώσει ακόμα περισσότερο την ακρίβεια και την αποτελεσματικότητα της διάγνωσης, καθιστώντας τα ένα πολύτιμο εργαλείο για την προγνωστική συντήρηση και την αποδοτική λειτουργία των φωτοβολταϊκών εγκαταστάσεων [12].

### **Λογιστική παλινδρόμηση (Logistic Regression)**

Η λογιστική παλινδρόμηση (Logistic Regression) είναι μια στατιστική μέθοδος ταξινόμησης που χρησιμοποιείται για την ανίχνευση βλαβών στα φωτοβολταϊκά συστήματα, καθώς επιτρέπει την πρόβλεψη της πιθανότητας εμφάνισης μιας δυσλειτουργίας. Χρησιμοποιεί τη συνάρτηση logistic (sigmoid) για να μετατρέψει τα δεδομένα εισόδου σε πιθανότητες, διευκολύνοντας έτσι τη διάκριση μεταξύ κανονικής και μη φυσιολογικής λειτουργίας. Η μέθοδος αυτή στηρίζεται στην υπόθεση ότι υπάρχει μια γραμμική σχέση μεταξύ των ανεξάρτητων μεταβλητών και της πιθανότητας εμφάνισης μιας βλάβης, γεγονός που την καθιστά αποτελεσματική για πιο απλές περιπτώσεις διάγνωσης.

Η λογιστική παλινδρόμηση έχει χρησιμοποιηθεί για την ανίχνευση δυσλειτουργιών σε φωτοβολταϊκά συστήματα, αναλύοντας δεδομένα από καμπύλες ρεύματος-τάσης (I-V) και μεταβολές ισχύος. Με βάση αυτά τα δεδομένα, μπορεί να εντοπίσει βλάβες στους μετατροπείς, οι οποίες εκδηλώνονται ως απότομη πτώση της DC παραγωγής, καθώς και υποβάθμιση των πάνελ λόγω σκίασης ή φθοράς υλικών. Επιπλέον, μπορεί να αναγνωρίσει βραχυκυκλώματα και απώλειες απόδοσης που σχετίζονται με αστοχίες κυψελών, συμβάλλοντας έτσι στην έγκαιρη διάγνωση προβλημάτων. Έρευνες δείχνουν ότι η συγκεκριμένη τεχνική μπορεί να επιτύχει ακρίβεια έως 97,11% στην αναγνώριση βλαβών, καθιστώντας την ιδιαίτερα χρήσιμη για μικρότερες εγκαταστάσεις [12].

Ένα από τα μεγαλύτερα πλεονεκτήματά της είναι η απλότητα και η αποδοτικότητά της, καθώς απαιτεί λιγότερους υπολογιστικούς πόρους συγκριτικά με πιο σύνθετες μεθόδους. Επιπλέον, μπορεί να λειτουργήσει αποτελεσματικά σε περιπτώσεις όπου υπάρχουν περιορισμένα δεδομένα εκπαίδευσης, ενώ η ικανότητά της να εντοπίζει πρόωρες βλάβες τη καθιστά χρήσιμο εργαλείο για την προγνωστική συντήρηση. Ωστόσο, η κύρια αδυναμία της είναι ότι υποθέτει γραμμική σχέση μεταξύ των μεταβλητών, γεγονός που την καθιστά λιγότερο κατάλληλη για πιο σύνθετα φωτοβολταϊκά συστήματα με μη γραμμικές

αλληλεπιδράσεις. Επίσης, όταν εφαρμόζεται σε μεγάλα και πολύπλοκα δεδομένα, η απόδοσή της είναι περιορισμένη σε σχέση με πιο εξελιγμένες τεχνικές, όπως τα Νευρωνικά Δίκτυα ή οι Υποστηρικτικοί Διανυσματικοί Ταξινομητές (SVM).

Η λογιστική παλινδρόμηση είναι ιδιαίτερα χρήσιμη σε μικρής κλίμακας φωτοβολταϊκά συστήματα, όπου οι βλάβες μπορούν να ανιχνευθούν μέσω απλών μοτίβων δεδομένων. Ωστόσο, σε μεγαλύτερες εγκαταστάσεις με πιο περίπλοκα σενάρια λειτουργίας, συνήθως συνδυάζεται με πιο προηγμένες μεθόδους ταξινόμησης για μεγαλύτερη ακρίβεια και αξιοπιστία στην ανίχνευση βλαβών [12].

### **Αφελής ταξινομητής Bayes (Naive Bayes)**

Ο αφελής ταξινομητής Bayes (Naive Bayes) είναι μια απλή, αλλά αποδοτική μέθοδος ταξινόμησης που βασίζεται στο θεώρημα του Bayes και χρησιμοποιείται ευρέως στην ανίχνευση βλαβών στα φωτοβολταϊκά συστήματα. Η κύρια υπόθεση του Naive Bayes είναι ότι τα χαρακτηριστικά των δεδομένων είναι ανεξάρτητα μεταξύ τους, κάτι που στην πράξη σπάνια ισχύει. Παρόλα αυτά, αυτή η μέθοδος είναι αποτελεσματική για την ανάλυση μεγάλου όγκου δεδομένων και προσφέρει γρήγορη ταξινόμηση.

Ο Naive Bayes χρησιμοποιείται για την ανίχνευση ανωμαλιών στα φωτοβολταϊκά συστήματα, όπως βραχυκυκλώματα, ανοικτά κυκλώματα και ανωμαλίες στην τάση ή το ρεύμα, καθώς και τη διάγνωση προβλημάτων από περιβαλλοντικούς παράγοντες ή φθορές του συστήματος. Η μέθοδος αυτή αναλύει δεδομένα από αισθητήρες, όπως η ηλιακή ακτινοβολία, η θερμοκρασία των πάνελ και οι μετρήσεις ρεύματος και τάσης, προσδιορίζοντας μοτίβα που υποδεικνύουν βλάβες. Είναι ιδιαίτερα χρήσιμη για τη γρήγορη ανίχνευση σφαλμάτων σε μικρής κλίμακας φωτοβολταϊκές εγκαταστάσεις, ενώ η απόδοσή της παραμένει αξιόπιστη ακόμα και με περιορισμένα δεδομένα.

Πλεονεκτήματα του Naive Bayes περιλαμβάνουν την ταχύτητα ταξινόμησης και τις χαμηλές απαιτήσεις σε υπολογιστικούς πόρους, κάνοντάς τον κατάλληλο για εφαρμογές με περιορισμένη επεξεργαστική ισχύ. Επίσης, είναι αποτελεσματικός όταν τα δεδομένα είναι περιορισμένα και προσφέρει αξιόπιστα αποτελέσματα σε γρήγορη ανίχνευση βλαβών. Ωστόσο, η υπόθεση της ανεξαρτησίας των χαρακτηριστικών μπορεί να μειώσει την ακρίβεια της μεθόδου, ειδικά όταν οι σχέσεις μεταξύ των παραμέτρων είναι πιο

περίπλοκες. Επιπλέον, σε πολύπλοκα δεδομένα, οι πιο προηγμένες μέθοδοι, όπως τα Νευρωνικά Δίκτυα ή τα Τυχαία Δάση, προσφέρουν καλύτερη απόδοση.

Ο Naive Bayes είναι κατάλληλος για γρήγορη και αποδοτική ανίχνευση βλαβών σε μικρής κλίμακας φωτοβολταϊκά συστήματα, όπου τα δεδομένα είναι πιο απλά και οι βλάβες μπορεί να ανιχνευθούν μέσω ξεκάθαρων μοτίβων. Σε πιο πολύπλοκα συστήματα, η χρήση του σε συνδυασμό με άλλες μεθόδους μπορεί να βελτιώσει την ακρίβεια και την αξιοπιστία της διάγνωσης [12].

Η επιλογή της κατάλληλης τεχνικής εξαρτάται από τη φύση του προβλήματος, την ποσότητα των διαθέσιμων δεδομένων, την πολυπλοκότητα της υλοποίησης και την απαιτούμενη ακρίβεια. Δεν υπάρχουν προκαθορισμένοι κανόνες για την επιλογή του σωστού αλγορίθμου, καθώς κάθε μέθοδος έχει τα δικά της πλεονεκτήματα και μειονεκτήματα [13]. Ο Πίνακας 3 παρέχει μια συνοπτική σύγκριση των μεθόδων τεχνητής νοημοσύνης που αναλύθηκαν, αξιολογώντας την αποτελεσματικότητά τους σε διάφορους τύπους δεδομένων και σφαλμάτων στα φωτοβολταϊκά συστήματα. Οι πληροφορίες προέρχονται από [12] καθώς και από την παραπάνω ανάλυση των τεχνικών που πραγματοποιήθηκε στο παρόν κείμενο.

Πίνακας 3: Σύγκριση τεχνικών τεχνητής νοημοσύνης για την ανίχνευση ελαττωμάτων σε φωτοβολταϊκά συστήματα, με αξιολόγηση της αποδοτικότητάς τους σε θερμικές εικόνες, καμπύλες I-V και διάφορους τύπους σφαλμάτων

| Μέθοδος ΤΝ                                                           | Θερμικές Εικόνες                                                                               | Καμπύλες I-V                                                 | Τύποι Ελαττωμάτων                                                       |
|----------------------------------------------------------------------|------------------------------------------------------------------------------------------------|--------------------------------------------------------------|-------------------------------------------------------------------------|
| <b>Νευρωνικά Δίκτυα (Artificial Neural Networks - ANN)</b>           | Πολύ αποτελεσματικά στην ανίχνευση σύνθετων προτύπων και ελαττωμάτων σε θερμικές εικόνες.      | Ικανά να μάθουν σύνθετες σχέσεις στις καμπύλες I-V.          | Hotspots, ρωγμές, σκίαση, συσσώρευση ρύπων, υποβάθμιση πάνελ.           |
| <b>Δίκτυα Μπεϋζιανής Πεποίθησης (Bayesian Belief Networks - BBN)</b> | Κατάλληλα για περιβάλλοντα με αβεβαιότητα· χρησιμοποιούνται για την πιθανή εκτίμηση σφαλμάτων. | Ανιχνεύουν τάσεις και πιθανότητες σφαλμάτων σε δεδομένα I-V. | Διάγνωση πιθανών αιτιών δυσλειτουργιών, υποβάθμιση φωτοβολταϊκών πάνελ. |

|                                                                                             |                                                                                                                               |                                                                                                              |                                                                                     |
|---------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|
| <b>Ασαφής Λογική<br/>(Fuzzy Logic - FL)</b>                                                 | Ικανή να διαχειριστεί δεδομένα με αβεβαιότητα· αποδοτική στην ταξινόμηση βλαβών μέσω λογικών κανόνων.                         | Χρησιμοποιείται σε συνδυασμό με άλλες μεθόδους για πιο ακριβή ανάλυση.                                       | Σκίαση, υποβάθμιση, δυσλειτουργία διόδων, σφάλματα από περιβαλλοντικούς παράγοντες. |
| <b>Υποστηρικτικές<br/>Διανυσματικές<br/>Μηχανές (Support<br/>Vector Machines -<br/>SVM)</b> | Αποτελεσματικές σε δεδομένα υψηλών διαστάσεων· ιδανικές για τη διάκριση μεταξύ κανονικών και ελαττωματικών περιπτώσεων.       | Λειτουργούν καλά για τη διάκριση μεταξύ διαφορετικών καμπυλών I-V με σαφή όρια.                              | Ρωγμές, hotspots, μικρορωγμές, σκίαση, εκτίμηση απωλειών ισχύος.                    |
| <b>Αλγόριθμος K-<br/>Nearest Neighbors<br/>(KNN)</b>                                        | Εφαρμόζεται σε απλές εργασίες ταξινόμησης θερμικών εικόνων, αλλά έχει περιορισμένη απόδοση σε περίπλοκα σενάρια.              | Χρησιμοποιείται σπανιότερα για δεδομένα I-V· αποτελεσματικός σε απλές περιπτώσεις ανίχνευσης ελαττωμάτων.    | Απλή ταξινόμηση hotspots, σκίασης και άλλων εμφανών ελαττωμάτων.                    |
| <b>Δέντρα Απόφασης<br/>(Decision Trees - DT)</b>                                            | Εύκολα στην ερμηνεία· χρήσιμα όταν τα χαρακτηριστικά είναι σαφώς ορισμένα, αλλά λιγότερο αποτελεσματικά σε περίπλοκα σενάρια. | Αποτελεσματικά για απλές ταξινομήσεις και λήψη αποφάσεων· απαιτούν κλάδεμα για αποφυγή υπερπροσαρμογής.      | Σκίαση, συσσώρευση σκόνης, βλάβες διόδων, σφάλματα γραμμής προς γραμμή.             |
| <b>Τυχαία Δάση<br/>(Random Forest - RF)</b>                                                 | Ανθεκτικά σε υπερπροσαρμογή, με υψηλή απόδοση στην ανάλυση χαρακτηριστικών από θερμικές εικόνες.                              | Κατάλληλα για ταξινομήσεις βάσει χαρακτηριστικών που εξάγονται από τις καμπύλες I-V.                         | Hotspots, σκίαση, μερική σκίαση, βραχυκυκλώματα, υποβάθμιση συστήματος.             |
| <b>Λογιστική<br/>Παλινδρόμηση<br/>(Logistic Regression)</b>                                 | Χρησιμοποιείται λιγότερο σε θερμικές εικόνες· επικεντρώνεται στην ανάλυση ηλεκτρικών χαρακτηριστικών.                         | Κατάλληλη για απλές ταξινομήσεις (δυαδικές ή πολυκατηγορικές)· λιγότερο αποτελεσματική σε περίπλοκα σενάρια. | Σφάλματα ανοικτού και βραχυκυκλωμένου κυκλώματος, ασυμφωνίες, μη ορισμένα σφάλματα. |
| <b>Αφελής Ταξινομητής<br/>Bayes (Naive Bayes)</b>                                           | Λιγότερο αποδοτικός λόγω της υπόθεσης ανεξαρτησίας χαρακτηριστικών, η οποία συχνά δεν ισχύει σε σύνθετα δεδομένα.             | Δεν εφαρμόζεται συχνά σε καμπύλες I-V· έχει περιορισμούς λόγω των απλοποιημένων υποθέσεων που υιοθετεί.      | Ανίχνευση hotspots· γενικά λιγότερο αποδοτικός σε σύνθετες περιπτώσεις ελαττωμάτων. |

#### 4.2.2 Πρόβλεψη Βλαβών

Η πρόβλεψη βλαβών στα φωτοβολταϊκά συστήματα βασίζεται στην ανάλυση της απόδοσής τους υπό φυσιολογικές συνθήκες λειτουργίας, επιτρέποντας την έγκαιρη ανίχνευση πιθανών δυσλειτουργιών και τη λήψη προληπτικών μέτρων. Τα μοντέλα προγνωστικής συντήρησης (Predictive Maintenance - PdM) διαδραματίζουν καθοριστικό ρόλο στη βελτίωση της διαχείρισης του εξοπλισμού, συμβάλλοντας στην αποφυγή σοβαρών ή ανεπανόρθωτων βλαβών και στη μείωση του κόστους επισκευών και ανταλλακτικών.

Για την επίτευξη αξιόπιστων προβλέψεων, αξιοποιούνται προηγμένες τεχνικές μηχανικής μάθησης και στατιστικής μοντελοποίησης. Τα στατιστικά μοντέλα ARIMA και SARIMA προσφέρουν ισχυρές βάσεις στην ανάλυση χρονοσειρών, ενώ τα πολυεπίπεδα νευρωνικά δίκτυα (MLP) και τα προσαρμοστικά νευρο-ασαφή συστήματα (ANFIS) επιτρέπουν τη μοντελοποίηση πολύπλοκων μη γραμμικών σχέσεων. Επιπλέον, η αξιοποίηση δεδομένων εικόνας και μετεωρολογικών συνθηκών ενισχύει την ακρίβεια της πρόβλεψης της ηλιακής ακτινοβολίας και της θερμοκρασίας των κυψελών, μειώνοντας τον κίνδυνο απόδοσης σφαλμάτων και την πιθανότητα υποβάθμισης των φωτοβολταϊκών εγκαταστάσεων [15].

#### **Αξιοποίηση Συστημάτων IoT και Μηχανικής Μάθησης**

Οι σύγχρονες τεχνικές πρόβλεψης βασίζονται στη συλλογή δεδομένων αισθητήρων μέσω συστημάτων IoT (Internet of Things) και την εφαρμογή αλγορίθμων μηχανικής μάθησης που αναγνωρίζουν πρότυπα δυσλειτουργιών στα δεδομένα. Η χρήση συστημάτων παρακολούθησης χαμηλού κόστους, όπως οι μικροελεγκτές Arduino και οι πλατφόρμες Raspberry Pi, επιτρέπει τη συνεχή παρακολούθηση βασικών λειτουργικών παραμέτρων των φωτοβολταϊκών συστημάτων, ενισχύοντας την αξιοπιστία τους.

Η ανάλυση ιστορικών δεδομένων μέσω τεχνητής νοημοσύνης διευκολύνει την ανίχνευση πρώιμων ενδείξεων αστοχίας, επιτρέποντας τη σύγκριση της πραγματικής απόδοσης ενός φωτοβολταϊκού συστήματος με την αναμενόμενη απόδοση. Μία από τις πιο σημαντικές παραμέτρους σε αυτή τη διαδικασία είναι ο δείκτης απόδοσης (Performance Ratio - PR), ο οποίος χρησιμοποιείται για τον εντοπισμό πιθανών προβλημάτων λαμβάνοντας υπόψη τις περιβαλλοντικές συνθήκες και άλλους παράγοντες.



Στο πλαίσιο αυτό, εφαρμόζονται τεχνικές όπως τα Support Vector Machines (SVMs), τα νευρωνικά δίκτυα και οι τεχνικές βαθιάς μάθησης (LSTM). Ιδιαίτερα, τα LSTM δίκτυα είναι εξαιρετικά χρήσιμα στην ανάλυση μεγάλων και πολύπλοκων συνόλων δεδομένων, επιτρέποντας την ακριβή πρόβλεψη βλαβών ακόμη και σε δυναμικά και μη σταθερά περιβάλλοντα [13]. Παράλληλα, στατιστικές μέθοδοι, όπως το Kalman Filter και τα Κρυφά Μαρκοβιανά Μοντέλα (HMMs), χρησιμοποιούνται για την εκτίμηση της πιθανότητας σφαλμάτων μέσω της ανάλυσης των τάσεων υποβάθμισης του συστήματος. Ο συνδυασμός αυτών των τεχνικών με δεδομένα σε πραγματικό χρόνο μειώνει το λειτουργικό κόστος και περιορίζει τον κίνδυνο αιφνίδιων διακοπών [32].

Εκτός από σύνθετες μεθόδους, αξιοποιούνται επίσης και απλούστερες τεχνικές πρόβλεψης, όπως η γραμμική παλινδρόμηση (Linear Regression), η οποία επιτρέπει τη μοντελοποίηση της εξαρτημένης μεταβλητής – δηλαδή της παραγόμενης ισχύος – βάσει επιλεγμένων περιβαλλοντικών παραμέτρων. Η μέθοδος αυτή στηρίζεται στην υπόθεση ότι υπάρχει μια γραμμική (δηλαδή ευθύγραμμη) σχέση μεταξύ των εισόδων και της εξόδου, γεγονός που την καθιστά ιδανική για ερμηνεύσιμα και σχετικά απλά προβλήματα πρόβλεψης.

Η αξιολόγηση της ακρίβειας τέτοιων μοντέλων γίνεται συνήθως με στατιστικούς δείκτες, όπως ο MAPE (Mean Absolute Percentage Error), που εκφράζει το μέσο ποσοστιαίο σφάλμα των προβλέψεων σε σχέση με τις πραγματικές τιμές – όσο μικρότερη η τιμή του, τόσο καλύτερη η ακρίβεια.

Αντίστοιχα, ο συντελεστής προσδιορισμού  $R^2$  δείχνει το ποσοστό της διακύμανσης των δεδομένων που εξηγείται από το μοντέλο. Τιμή του  $R^2$  κοντά στο 1 υποδηλώνει ότι το μοντέλο περιγράφει πολύ καλά τη σχέση μεταξύ εισόδων και εξόδου, ενώ χαμηλές τιμές υποδηλώνουν ανεπαρκή προσαρμογή [23].

### **Αξιοποίηση των Συστημάτων Υποστήριξης Αποφάσεων (DSS) στην Πρόβλεψη Βλαβών**

Ένας ακόμη σημαντικός παράγοντας στην πρόβλεψη βλαβών είναι η χρήση Συστημάτων Υποστήριξης Αποφάσεων (Decision Support Systems - DSS). Αυτά τα συστήματα ενσωματώνουν μετεωρολογικά και ηλεκτρικά δεδομένα και τα συνδυάζουν με αλγορίθμους πρόβλεψης, εντοπίζοντας εγκαίρως ανωμαλίες που ενδέχεται να οδηγήσουν

σε βλάβες. Με αυτόν τον τρόπο, επιτυγχάνεται συνεχής παρακολούθηση της απόδοσης των φωτοβολταϊκών συστημάτων και αποτρέπονται αιφνίδιες διακοπές λειτουργίας [38].

Τα DSS λειτουργούν σε πραγματικό χρόνο, γεγονός που αυξάνει την ακρίβεια των προβλέψεων και συμβάλλει στη μείωση του κόστους συντήρησης. Ένα από τα βασικά τους πλεονεκτήματα είναι η ενσωμάτωση διαδικασιών καθαρισμού δεδομένων (Data Quality Routines - DQRs), που διασφαλίζουν την αξιοπιστία των προβλέψεων απομακρύνοντας ελλιπή ή εσφαλμένα δεδομένα [23]. Παράλληλα, αλγόριθμοι όπως ο XGBoost εφαρμόζονται για την εκτίμηση της αναμενόμενης απόδοσης του συστήματος. Τα DSS συγκρίνουν αυτή την προβλεπόμενη απόδοση με την πραγματική, εντοπίζοντας αποκλίσεις που μπορεί να υποδεικνύουν πιθανές βλάβες. Επιπλέον, υπολογίζουν ενεργειακές απώλειες και προτείνουν στοχευμένες ενέργειες συντήρησης, όπως καθαρισμό ή αντικατάσταση εξοπλισμού.

Η αρχιτεκτονική των DSS βασίζεται στην ανάλυση χρονοσειρών μετεωρολογικών και ηλεκτρικών δεδομένων, αξιοποιώντας τεχνικές όπως το Extreme Gradient Boosting (XGBoost). Παράλληλα, εφαρμόζεται η μέθοδος FMECA (Failure Mode, Effects, and Criticality Analysis), η οποία ταξινομεί τις βλάβες με βάση την κρισιμότητά τους και προτείνει στοχευμένες ενέργειες για την αντιμετώπισή τους [15].

Η συνεχής βελτίωση των αλγορίθμων πρόβλεψης και η αξιοποίηση δεδομένων σε πραγματικό χρόνο επιτρέπουν την πρόληψη πιθανών δυσλειτουργιών, διασφαλίζοντας τη βέλτιστη λειτουργία των φωτοβολταϊκών συστημάτων. Η θερμοκρασία αποτελεί έναν από τους σημαντικότερους παράγοντες που επηρεάζουν την απόδοση και τη διάρκεια ζωής των πάνελ. Για την ακριβή πρόβλεψή της, εφαρμόζονται τεχνικές μηχανικής μάθησης, όπως τα τεχνητά νευρωνικά δίκτυα (ANN), τα αυτοπαλίνδρομα μοντέλα με εξωγενείς μεταβλητές (ARMAX) και τα υποστηρικτικά διανυσματικά μηχανήματα (SVM) [15].

**Τεχνητά Νευρωνικά Δίκτυα (ANN):** Τα ANN μπορούν να αναλύσουν πολύπλοκες μη γραμμικές σχέσεις και να παρέχουν ακριβείς προβλέψεις θερμοκρασίας. Τα Radial Basis Function Neural Networks (RBFNN) είναι ιδιαίτερα αποδοτικά για βραχυπρόθεσμες εκτιμήσεις, ενώ η χρήση εξελικτικών αλγορίθμων βελτιώνει περαιτέρω την απόδοση των μοντέλων.

**Μοντέλα ARMAX:** Τα ARMAX ενσωματώνουν εξωτερικές μεταβλητές, όπως η ηλιακή ακτινοβολία, βελτιώνοντας τη διαχείριση μη στάσιμων χρονοσειρών. Η εφαρμογή τεχνικών όπως τα εκθετικά κινούμενα μέσα (EWMA) και τα φίλτρα Kalman συμβάλλει στη μείωση του σφάλματος στις προβλέψεις.

**Υποστηρικτικά Διανυσματικά Μηχανήματα (SVM):** Τα SVM διαχειρίζονται μη γραμμικές σχέσεις μεταξύ δεδομένων, ενώ η χρήση Wavelet Transformations βελτιώνει την ακρίβεια των προβλέψεων. Παρά την υψηλή υπολογιστική απαίτηση, τα SVM είναι εξαιρετικά αποτελεσματικά κυρίως για βραχυπρόθεσμες προβλέψεις θερμοκρασίας (έως 12 ώρες νωρίτερα).

Η πρόβλεψη της θερμοκρασίας αλλά και της ηλιακής ακτινοβολίας και αποτελεί κρίσιμο στοιχείο για τη δυναμική προσαρμογή των φωτοβολταϊκών συστημάτων. Οι τεχνικές πρόβλεψης βασίζονται σε αριθμητικά μοντέλα καιρού (NWP), όπως το Global Forecast System (GFS) και το Integrated Forecast System (IFS), τα οποία χρησιμοποιούνται ευρέως για την πρόβλεψη της παγκόσμιας οριζόντιας και της άμεσης κανονικής ακτινοβολίας.

Ωστόσο, αυτά τα μοντέλα έχουν περιορισμένη ακρίβεια σε συνθήκες μεταβαλλόμενης νεφοκάλυψης, κάτι που αντιμετωπίζεται με τη χρήση στατιστικών τεχνικών επεξεργασίας δεδομένων (MOS) και νευρωνικών δικτύων, τα οποία μειώνουν το σφάλμα πρόβλεψης και επιτρέπουν την καλύτερη διαχείριση της παραγόμενης ενέργειας.

Παράλληλα, η τεχνική nowcasting, δηλαδή η πρόβλεψη της ηλιακής ακτινοβολίας σε πραγματικό χρόνο, συμβάλλει στη βελτίωση της εκτίμησης των κλιματικών παραγόντων που επηρεάζουν την παραγωγή ενέργειας. Η χρήση δορυφορικών εικόνων επιτρέπει την ακριβή πρόβλεψη της ακτινοβολίας για έως και 6 ώρες, ενσωματώνοντας επίσης ιστορικά δεδομένα για τον προσδιορισμό της θέσης και της κίνησης των νεφών. Επιπλέον, η πρόβλεψη βασισμένη σε εικόνες του ουρανού χρησιμοποιεί αλγορίθμους μηχανικής όρασης για την ανίχνευση και κατηγοριοποίηση των νεφών, επιτρέποντας την πιο αξιόπιστη εκτίμηση της ακτινοβολίας που φτάνει στα φωτοβολταϊκά πάνελ [15].

Η ενσωμάτωση αυτών των τεχνικών στην προληπτική συντήρηση των φωτοβολταϊκών συστημάτων διασφαλίζει τη σταθερή λειτουργία, την αποφυγή αστοχιών και τη βελτιστοποίηση της απόδοσης.

#### 4.2.3 Βελτιστοποίηση Απόδοσης

Η ικανότητα πρόβλεψης βλαβών δεν αποτελεί μόνο εργαλείο για την πρόληψη δυσλειτουργιών, αλλά και βασικό μηχανισμό για τη συνολική βελτιστοποίηση της απόδοσης ενός φωτοβολταϊκού συστήματος. Μέσω της προγνωστικής ανάλυσης, είναι δυνατός ο έγκαιρος εντοπισμός τάσεων υποβάθμισης και η λήψη προληπτικών μέτρων που διασφαλίζουν την αποδοτικότερη λειτουργία του συστήματος. Για παράδειγμα, η πρόβλεψη της απόδοσης των πάνελ με βάση τις κλιματικές συνθήκες και τα ιστορικά δεδομένα επιτρέπει τη βέλτιστη ρύθμιση κρίσιμων παραμέτρων, όπως η γωνία κλίσης και η διαχείριση της αποθηκευμένης ενέργειας.

Αξιοποιώντας αυτά τα δεδομένα, η Τεχνητή Νοημοσύνη μπορεί να προσαρμόζει δυναμικά τις συνθήκες λειτουργίας των φωτοβολταϊκών συστημάτων, διασφαλίζοντας τη μέγιστη ενεργειακή απόδοση. Η ανάλυση σε πραγματικό χρόνο μέσω αισθητήρων και προηγμένων αλγορίθμων επιτρέπει όχι μόνο τη βελτίωση της απόδοσης των πάνελ, αλλά και την αποδοτικότερη διαχείριση της παραγόμενης ενέργειας. Συγκεκριμένα, τα δεδομένα που συλλέγονται, όπως ηλιακή ακτινοβολία, θερμοκρασία και τάση, αξιοποιούνται για την προσαρμογή της γωνίας των πλαισίων, καθώς και για τη βέλτιστη ένταξη της ενέργειας στο δίκτυο. Μέσω αυτής της δυναμικής ρύθμισης και της έξυπνης διαχείρισης των ενεργειακών ροών, επιτυγχάνεται η μέγιστη απορρόφηση ηλιακής ακτινοβολίας, η ελαχιστοποίηση των απωλειών και η συνολική βελτίωση της απόδοσης του συστήματος [13, 32].

#### **Ρύθμιση της Γωνίας των Φωτοβολταϊκών Πάνελ μέσω TN**

Η δυναμική ρύθμιση της γωνίας των ηλιακών πάνελ είναι ένας από τους βασικούς τρόπους βελτίωσης της ενεργειακής απόδοσης. Με τη χρήση αλγορίθμων μηχανικής μάθησης, τα φωτοβολταϊκά συστήματα μπορούν να προσαρμόζουν τη γωνία των πάνελ σε πραγματικό χρόνο, λαμβάνοντας υπόψη τις συνθήκες φωτισμού, τις ατμοσφαιρικές συνθήκες και την εποχή του έτους. Έτσι, εξασφαλίζεται η μέγιστη δυνατή απορρόφηση ηλιακής ενέργειας καθ' όλη τη διάρκεια της ημέρας.

Η προσέγγιση αυτή είναι ιδιαίτερα αποτελεσματική σε περιοχές με μεταβαλλόμενες καιρικές συνθήκες ή μερική σκίαση, καθώς τα συστήματα μπορούν να προσαρμόζονται άμεσα στις αλλαγές του φωτισμού. Παράλληλα, αλγόριθμοι βαθιάς μάθησης αναλύουν

ιστορικά και πραγματικού χρόνου δεδομένα για την απόδοση των πάνελ, εντοπίζοντας μοτίβα που επιτρέπουν τη βελτιστοποίηση των παραμέτρων λειτουργίας και τη μείωση των ενεργειακών απωλειών λόγω σκίασης ή ρύπανσης [32].

### **Έξυπνη Διαχείριση της Παραγόμενης Ενέργειας**

Η Τεχνητή Νοημοσύνη δεν βελτιώνει μόνο την αποδοτικότητα των πάνελ, αλλά επιτρέπει και την έξυπνη εξισορρόπηση των φορτίων, μεγιστοποιώντας τη χρήση της παραγόμενης ενέργειας. Αναλύοντας δεδομένα σε πραγματικό χρόνο σχετικά με την κατανάλωση, την παραγωγή και τις συνθήκες του δικτύου, η ΤΝ μπορεί να κατευθύνει την ενέργεια είτε προς άμεση κατανάλωση, είτε προς αποθήκευση σε μπαταρίες, είτε προς εξαγωγή στο δίκτυο, ανάλογα με τη ζήτηση. Με αυτόν τον τρόπο, μειώνεται η σπατάλη ενέργειας, αυξάνεται η ενεργειακή αυτονομία και μειώνεται η εξάρτηση από το ηλεκτρικό δίκτυο [13].

Στις μεγάλες φωτοβολταϊκές εγκαταστάσεις, η διαχείριση της κατανομής ενέργειας αποκτά ακόμα μεγαλύτερη σημασία. Οι αλγόριθμοι μηχανικής μάθησης καθορίζουν πότε είναι προτιμότερο να αποθηκεύεται η ενέργεια και πότε να διοχετεύεται στο δίκτυο, λαμβάνοντας υπόψη τη ζήτηση, τις τιμές ενέργειας και τις συνθήκες της αγοράς. Αυτή η στρατηγική μειώνει το λειτουργικό κόστος και βελτιώνει τη μακροπρόθεσμη οικονομική βιωσιμότητα των φωτοβολταϊκών έργων [32].

### **4.3 Προκλήσεις και Περιορισμοί της Χρήσης της AI**

Παρά τα σημαντικά πλεονεκτήματα που προσφέρει η Τεχνητή Νοημοσύνη (ΤΝ) στη συντήρηση των φωτοβολταϊκών συστημάτων, η εφαρμογή της συνοδεύεται από προκλήσεις και περιορισμούς που επηρεάζουν την αξιοπιστία και την αποτελεσματικότητά της. Οι κυριότερες δυσκολίες αφορούν τη διαθεσιμότητα και ποιότητα δεδομένων, την πολυπλοκότητα των αλγορίθμων, το αρχικό κόστος υλοποίησης και τις κυβερνοαπειλές.

Ένα από τα βασικά εμπόδια στην αξιοποίηση της ΤΝ στη συντήρηση φωτοβολταϊκών είναι η περιορισμένη διαθεσιμότητα πραγματικών δεδομένων σφαλμάτων. Τα περισσότερα μοντέλα εκπαιδεύονται χρησιμοποιώντας συνθετικά δεδομένα από εργαστηριακές

προσομοιώσεις, τα οποία δεν αντικατοπτρίζουν με ακρίβεια τις συνθήκες λειτουργίας των φωτοβολταϊκών εγκαταστάσεων. Αυτό μπορεί να μειώσει την ικανότητα των αλγορίθμων να προβλέπουν και να διαχειρίζονται ασυνήθιστες ή μη καταγεγραμμένες δυσλειτουργίες [32]. Επιπλέον, τα δεδομένα που συλλέγονται από αισθητήρες SCADA (Supervisory Control and Data Acquisition – σύστημα εποπτικού ελέγχου και συλλογής δεδομένων που χρησιμοποιείται για την παρακολούθηση και τον έλεγχο βιομηχανικών διεργασιών σε πραγματικό χρόνο) συχνά περιέχουν θόρυβο ή ελλιπείς μετρήσεις, καθιστώντας απαραίτητη τη χρήση τεχνικών επεξεργασίας και καθαρισμού δεδομένων (Data Auditing).

Η εφαρμογή των συστημάτων ΤΝ στη συντήρηση φωτοβολταϊκών απαιτεί επίσης μεγάλο όγκο δεδομένων και σημαντική υπολογιστική ισχύ. Τα νευρωνικά δίκτυα και οι αλγόριθμοι βαθιάς μάθησης απαιτούν υψηλής ποιότητας δεδομένα και υπολογιστικούς πόρους, αυξάνοντας το κόστος εφαρμογής, ιδιαίτερα για μικρότερες εγκαταστάσεις. Παράλληλα, η ανάλυση μεγάλων ποσοτήτων δεδομένων από φωτοβολταϊκά πάρκα απαιτεί εξειδικευμένες ομάδες ανάλυσης δεδομένων, γεγονός που αυξάνει περαιτέρω τις απαιτήσεις σε ανθρώπινο δυναμικό και τεχνογνωσία.

Ένα ακόμη σημαντικό πρόβλημα αφορά την ερμηνευσιμότητα (explainability) των αλγορίθμων ΤΝ. Οι κλασικές μέθοδοι μηχανικής μάθησης (ML) επιτρέπουν στους χρήστες να κατανοήσουν τη διαδικασία λήψης αποφάσεων, ωστόσο οι πιο σύγχρονες τεχνικές, όπως τα βαθιά νευρωνικά δίκτυα (DNNs), χαρακτηρίζονται από πολύπλοκες εσωτερικές διεργασίες που καθιστούν δύσκολη την κατανόηση του τρόπου με τον οποίο καταλήγουν σε ένα αποτέλεσμα. Αυτή η έλλειψη διαφάνειας μπορεί να δυσχεράνει την εμπιστοσύνη των χρηστών στις προβλέψεις και να περιορίσει την υιοθέτηση της ΤΝ στη βιομηχανία των φωτοβολταϊκών συστημάτων.

Παράλληλα, η ενσωμάτωση της ΤΝ και του Διαδικτύου των Πραγμάτων (IoT) στις ενεργειακές εγκαταστάσεις τις καθιστά πιο ευάλωτες σε κυβερνοαπειλές (κακόβουλες επιθέσεις που στοχεύουν στην αλλοίωση, την υποκλοπή ή τη διακοπή της ροής δεδομένων των συστημάτων, θέτοντας σε κίνδυνο τη λειτουργία τους). Οι χάκερ μπορούν να εκμεταλλευτούν ευπάθειες στο λογισμικό ή το δίκτυο, επηρεάζοντας τη λειτουργία των αλγορίθμων ML, αλλοιώνοντας τα δεδομένα εισόδου ή εκμεταλλευόμενοι κενά ασφαλείας στο cloud computing (υπολογιστικό νέφος – μοντέλο παροχής υπηρεσιών πληροφορικής, όπου οι υπολογιστικοί πόροι και τα δεδομένα αποθηκεύονται και

επεξεργάζονται απομακρυσμένα μέσω του διαδικτύου, αντί σε τοπικά συστήματα). Η ανάγκη για ανάπτυξη ανθεκτικών συστημάτων κυβερνοασφάλειας και αλγορίθμων που μπορούν να ανιχνεύουν επιθέσεις είναι επιτακτική [26].

Τέλος, οι αλγόριθμοι ML στη συντήρηση φωτοβολταϊκών πρέπει να διαχειρίζονται πολλαπλές και ταυτόχρονες βλάβες, κάτι που αποτελεί υπολογιστικά απαιτητική διαδικασία. Οι υπάρχουσες τεχνικές ανίχνευσης βλαβών (FDD) επικεντρώνονται συνήθως στην ανίχνευση μεμονωμένων δυσλειτουργιών, γεγονός που περιορίζει την αποτελεσματικότητά τους σε σύνθετα σενάρια βλαβών [13].

## Κεφάλαιο 5 Πειραματικό Μέρος

Το παρόν κεφάλαιο επικεντρώνεται στην υλοποίηση της πειραματικής διαδικασίας που σχεδιάστηκε στο πλαίσιο της εργασίας, με στόχο τη διερεύνηση της δυνατότητας πρόβλεψης και έγκαιρης ανίχνευσης πιθανών βλαβών σε φωτοβολταϊκά συστήματα μέσω τεχνικών μηχανικής μάθησης. Η προσέγγιση εντάσσεται στη λογική της προληπτικής συντήρησης και βασίζεται σε πραγματικά περιβαλλοντικά δεδομένα, πάνω στα οποία εφαρμόστηκαν μέθοδοι καθαρισμού, ανάλυσης και μοντελοποίησης. Μέσα από τη σταδιακή εφαρμογή απλών αλλά τεκμηριωμένων βημάτων, επιχειρείται η αξιολόγηση της ικανότητας των μοντέλων να εντοπίζουν έγκαιρα ενδείξεις δυσλειτουργίας, με τελικό στόχο την ενίσχυση της λειτουργικής αξιοπιστίας των φωτοβολταϊκών εγκαταστάσεων.

### 5.1 Περιγραφή και προέλευση δεδομένων

Για τις ανάγκες της παρούσας εργασίας χρησιμοποιήθηκαν δεδομένα από το εργαλείο PVGIS (Photovoltaic Geographical Information System) της Ευρωπαϊκής Επιτροπής, το οποίο παρέχει δωρεάν πρόσβαση σε δεδομένα ηλιακής ακτινοβολίας, περιβαλλοντικές παραμέτρους και προβλεπόμενη απόδοση φωτοβολταϊκών συστημάτων για οποιοδήποτε σημείο στην Ευρώπη. Η ανάλυση βασίστηκε σε δεδομένα που αντλήθηκαν από την ιστοσελίδα του PVGIS ([https://re.jrc.ec.europa.eu/pvg\\_tools/en/](https://re.jrc.ec.europa.eu/pvg_tools/en/)) με τελευταία πρόσβαση στις 13/03/2025.

Η τοποθεσία που επιλέχθηκε βρίσκεται στον Βόλο και χρησιμοποιείται ενδεικτικά, με στόχο την παρουσίαση της μεθοδολογίας σε ρεαλιστικό περιβάλλον, με γεωγραφικές συντεταγμένες γεωγραφικό πλάτος  $39.364^{\circ}$  και γεωγραφικό μήκος  $22.938^{\circ}$ , υψόμετρο 6 μέτρα, και μελέτη για το έτος 2023. Ο προσανατολισμός και η κλίση του συστήματος ορίστηκαν σε κλίση  $35^{\circ}$  και προσανατολισμό  $0^{\circ}$ , που αντιστοιχεί σε νότια κατεύθυνση. Ως βάση δεδομένων ηλιακής ακτινοβολίας επιλέχθηκε η PVGIS-SARAH3, που παρέχει αναλυτικά ωριαία δεδομένα για τη συγκεκριμένη χρονική περίοδο.

Η τεχνολογία φωτοβολταϊκών που χρησιμοποιήθηκε στο μοντέλο είναι ο τύπος Crystalline Silicon, ο οποίος αποτελεί την συνηθέστερη τεχνολογία τόσο στην Ελλάδα όσο και διεθνώς, προσφέροντας ικανοποιητική απόδοση και αξιοπιστία, με μερίδιο αγοράς που ξεπερνά το 98% [39]. Το μοντέλο υπολογισμού βασίζεται σε φωτοβολταϊκό σύστημα




ονομαστικής ισχύος 1 kWp, που αποτελεί καθιερωμένο σημείο αναφοράς για τη σύγκριση ενεργειακής απόδοσης ανεξαρτήτως του αριθμού ή της διάταξης των πάνελ.

Επιπλέον, στο σύστημα ενσωματώνονται εκτιμώμενες απώλειες 14%, οι οποίες περιλαμβάνουν απώλειες σε καλώδια, inverters, ρύπους, σκιάσεις και σταδιακή υποβάθμιση της απόδοσης των φωτοβολταϊκών με την πάροδο του χρόνου, όπως προτείνεται από την τεκμηρίωση του PVGIS.

Το αρχείο εξόδου από το PVGIS περιλαμβάνει τις εξής μεταβλητές:

- **G(i)**: Ηλιακή ακτινοβολία στην κεκλιμένη επιφάνεια ( $\text{W/m}^2$ )
- **H\_sun**: Ύψος ήλιου (μοίρες)
- **T2m**: Θερμοκρασία αέρα στα 2 μέτρα ( $^{\circ}\text{C}$ )
- **WS10m**: Ταχύτητα ανέμου στα 10 μέτρα ( $\text{m/s}$ )
- **P**: Προβλεπόμενη ισχύς εξόδου (W)

Στην Εικόνα 13 παρουσιάζεται το γραφικό περιβάλλον του PVGIS και τις επιλογές που καθορίστηκαν για τη δημιουργία του αρχείου εισόδου.



Εικόνα 13: Επιλογή τοποθεσίας και παραμέτρων συστήματος στο περιβάλλον του PVGIS για εξαγωγή ωριαίων δεδομένων παραγωγής ισχύος και περιβαλλοντικών μεταβλητών (έτος 2023, περιοχή Βόλου)

Η επιλογή του PVGIS ως πηγής δεδομένων δεν βασίστηκε μόνο στην αξιοπιστία και τη διαθεσιμότητά του, αλλά και στην ανάγκη αντιμετώπισης ενός βασικού περιορισμού που αναδεικνύεται συστηματικά στη διεθνή βιβλιογραφία: την έλλειψη δημόσια

προσβάσιμων συνόλων δεδομένων λειτουργίας φωτοβολταϊκών συστημάτων με καταγεγραμμένες πραγματικές βλάβες. Δεδομένου ότι το PVGIS παρέχει αποκλειστικά περιβαλλοντικά και ενεργειακά δεδομένα υπό κανονικές συνθήκες λειτουργίας, κρίθηκε σκόπιμο να δημιουργηθούν τεχνητές βλάβες στο σύνολο δεδομένων εκπαίδευσης, ώστε να προσομοιωθούν πιθανές δυσλειτουργίες. Με τον τρόπο αυτό, κατέστη εφικτή η δημιουργία ενός ελεγχόμενου συνόλου δεδομένων, κατάλληλου για την πειραματική εφαρμογή αλγορίθμων μηχανικής μάθησης στο πλαίσιο προληπτικής συντήρησης.

## 5.2 Εργαλεία και Περιβάλλον Εργασίας

Η ανάπτυξη και υλοποίηση του πειραματικού μέρους της παρούσας εργασίας πραγματοποιήθηκε με τη χρήση του προγραμματιστικού περιβάλλοντος Python σε συνδυασμό με το Jupyter Notebook, ένα ιδιαίτερα δημοφιλές εργαλείο για ανάλυση δεδομένων και πειραματισμό με αλγορίθμους μηχανικής μάθησης. Το Jupyter Notebook επέτρεψε την ευέλικτη επεξεργασία κώδικα, την ενσωμάτωση σχολίων και την άμεση οπτικοποίηση των αποτελεσμάτων, διευκολύνοντας σημαντικά τη διαδικασία τεκμηρίωσης.

Η γλώσσα Python επελέγη λόγω της εκτενούς βιβλιοθήκης εργαλείων για επεξεργασία δεδομένων, μοντελοποίηση και στατιστική ανάλυση, καθώς και της μεγάλης υποστήριξης που παρέχει η κοινότητα. Για τις ανάγκες της παρούσας μελέτης χρησιμοποιήθηκαν οι ακόλουθες βασικές βιβλιοθήκες:

- **pandas**: για τη φόρτωση, διαχείριση και καθαρισμό των δεδομένων (σε όλα τα στάδια, αλλά κυρίως στο Παράρτημα Α.1).
- **NumPy**: για αριθμητικές πράξεις και δημιουργία τεχνητών βλαβών (Παραρτήματα Α.2, Α.3, Α.6).
- **matplotlib**: για την οπτικοποίηση αποτελεσμάτων (διαγράμματα διασποράς, πίνακες σύγχυσης).
- **scikit-learn (sklearn)**: για την υλοποίηση των αλγορίθμων Linear Regression, Logistic Regression, Random Forest, καθώς και για την αξιολόγηση των μοντέλων με δείκτες όπως accuracy, recall, precision,  $R^2$  και MAPE.
- **imblearn (imbalanced-learn)**: για την εφαρμογή της τεχνικής SMOTE (Synthetic Minority Over-sampling Technique), η οποία χρησιμοποιήθηκε για την


εξισορρόπηση του συνόλου εκπαίδευσης στα προβλήματα ταξινόμησης (Παραρτήματα Α.4, Α.5, Α.6).

- **xgboost**: για την υλοποίηση του αλγορίθμου XGBoost (Παράρτημα Α.5), στο πλαίσιο της συγκριτικής αξιολόγησης.

Η εργασία αξιοποίησε ένα πλήρως ανοικτό και επαναχρησιμοποιήσιμο τεχνολογικό περιβάλλον, βασισμένο σε δωρεάν και ευρέως διαδεδομένα εργαλεία, τα οποία υποστηρίζουν την αναπαραγωγή των πειραμάτων και την εύκολη προσαρμογή της μεθοδολογίας σε άλλα σύνολα δεδομένων.

### 5.3 Καθαρισμός Δεδομένων με βάση τη Μεθοδολογία DQRs

Η διαδικασία καθαρισμού των δεδομένων βασίστηκε στη μεθοδολογία Data Quality Routines (DQRs), όπως προτείνεται στη βιβλιογραφία [23, 40, 41]. Πρόκειται για μια πολυβηματική προσέγγιση, η οποία έχει ως στόχο να εντοπίσει και να διαχειριστεί τιμές που είναι μη έγκυρες ή προβληματικές, είτε αφαιρώντας τις είτε ανακατασκευάζοντάς τις κατά περίπτωση. Ο καθαρισμός των δεδομένων είναι απαραίτητο στάδιο πριν από οποιαδήποτε επεξεργασία, ειδικά όταν αυτά πρόκειται να χρησιμοποιηθούν για την ανάπτυξη μοντέλων τεχνητής νοημοσύνης στο πλαίσιο προληπτικής συντήρησης φωτοβολταϊκών συστημάτων. Παρακάτω παρουσιάζονται τα 8 βασικά βήματα της μεθοδολογίας, όπως εφαρμόστηκαν στην παρούσα εργασία. Στην Εικόνα 14 παρουσιάζεται συνοπτικά η πλήρης ροή αυτής της διαδικασίας, από την αρχική συλλογή μετρήσεων μέχρι και τη λήψη αποφάσεων για διορθωτικές ή προληπτικές ενέργειες συντήρησης.



Εικόνα 14: Διάγραμμα των 8 σταδίων της μεθοδολογίας DQRs (Data Quality Routines) για τον καθαρισμό και την προεπεξεργασία δεδομένων φωτοβολταϊκών, από τον αρχικό στατιστικό έλεγχο έως τη σύνοψη και επαλήθευση των δεδομένων [27]

### Βήμα 1 – Αρχικά Στατιστικά Δεδομένων (Initial Data Statistics)

Αρχικά, πραγματοποιήθηκε η φόρτωση του αρχείου PVGIS που περιλαμβάνει ωριαίες μετρήσεις για την περιοχή του Βόλου για ολόκληρο το έτος 2023. Το αρχείο περιλάμβανε συνολικά 8756 εγγραφές, με σταθερή συχνότητα καταγραφής ανά μία ώρα, γεγονός που επιβεβαιώθηκε από τον υπολογισμό της χρονικής διαφοράς μεταξύ διαδοχικών εγγραφών. Το χρονικό διάστημα καλύπτει πλήρως το ημερολογιακό έτος, από 01/01/2023 έως 31/12/2023, προσφέροντας μια συνεπή και πλήρη χρονοσειρά, κρίσιμη για τη μελλοντική αξιολόγηση απόδοσης του φωτοβολταϊκού συστήματος.

Κατά την ανάγνωση του αρχείου, αφαιρέθηκαν οι πρώτες και τελευταίες γραμμές που περιείχαν πληροφορίες μη σχετικές με τις μετρήσεις (π.χ. σχόλια), ενώ οι στήλες μετονομάστηκαν αυτόματα ώστε να περιλαμβάνουν:

- time – χρονική σήμανση της μέτρησης
- P – προβλεπόμενη ισχύς παραγωγής (W)

- $G(i)$  – ολική ηλιακή ακτινοβολία στην κεκλιμένη επιφάνεια ( $W/m^2$ )
- $H_{sun}$  – ύψος του ήλιου (μοίρες)
- $T_{2m}$  – θερμοκρασία αέρα σε ύψος 2m ( $^{\circ}C$ )
- $WS_{10m}$  – ταχύτητα ανέμου σε ύψος 10m (m/s)
- $Int$  – δείκτης που δηλώνει εάν η μέτρηση ακτινοβολίας έχει ανακατασκευαστεί ή όχι

## **Βήμα 2 – Έλεγχος Συνοχής (Consistency Examination)**

Προκειμένου να διασφαλιστεί η χρονολογική συνοχή, υπολογίστηκε η χρονική διαφορά μεταξύ των διαδοχικών μετρήσεων (στήλη *time\_diff*). Το αναμενόμενο διάστημα ήταν 1 ώρα. Δεν εντοπίστηκαν χρονικά κενά ούτε διπλότυπες εγγραφές, γεγονός που επιβεβαιώνει την αξιοπιστία του ρυθμού καταγραφής.

## **Βήμα 3 – Φιλτράρισμα Ωρών Ημέρας (Daylight Filtering)**

Αποφασίστηκε να κρατηθούν μόνο οι μετρήσεις που πραγματοποιούνται κατά τη διάρκεια της ημέρας. Αυτό επιτεύχθηκε φιλτράροντας τις τιμές της  $G(i)$  και κρατώντας μόνο όσες κυμαίνονται από 20 έως  $1300 W/m^2$ . Τιμές εκτός αυτού του εύρους θεωρούνται είτε μη έγκυρες (νυχτερινές ώρες, σφάλματα) είτε ακραίες και αποκλείστηκαν. Μετά την εφαρμογή του φίλτρου, το σύνολο δεδομένων περιορίστηκε σε 4094 έγκυρες εγγραφές, οι οποίες αντιστοιχούν αποκλειστικά σε ώρες με αξιοποιήσιμη ηλιακή ακτινοβολία.

## **Βήμα 4 – Εντοπισμός Μη Έγκυρων Τιμών (Invalid Value Detection)**

Εφαρμόστηκαν φυσικά όρια για τις βασικές μετεωρολογικές μεταβλητές, βάσει βιβλιογραφικών τιμών και φυσικών περιορισμών:

- $P$ : 0 – 1500 W
- $G(i)$ : 0 –  $1300 W/m^2$
- $H_{sun}$ :  $0^{\circ}$  –  $90^{\circ}$
- $T_{2m}$ :  $-20^{\circ}C$  –  $60^{\circ}C$
- $WS_{10m}$ : 0 – 40 m/s

Παράλληλα, εφαρμόστηκε η μέθοδος των τεταρτημορίων (boxplot rule) για τον εντοπισμό και την αφαίρεση στατιστικά ακραίων τιμών στις μεταβλητές T2m (θερμοκρασία) και WS10m (ταχύτητα ανέμου), με χρήση του εύρους IQR (Interquartile Range):

- Κάτω όριο =  $Q1 - 1.5 \times IQR$
- Άνω όριο =  $Q3 + 1.5 \times IQR$

Η T2m δεν παρουσίασε ακραίες τιμές, ενώ στη WS10m εντοπίστηκαν 98 τιμές άνω του ορίου των 6.76 m/s, οι οποίες αφαιρέθηκαν.

Η διπλή αυτή διαδικασία καθαρισμού ενίσχυσε την ποιότητα και ομοιογένεια του συνόλου δεδομένων. Μετά την ολοκλήρωση του Βήματος 4, επιβεβαιώθηκε ότι δεν υπάρχουν ελλείπουσες τιμές (NaN) και το σύνολο δεδομένων περιορίστηκε σε 3996 έγκυρες εγγραφές, πλήρως κατάλληλες για την επόμενη φάση της ανάλυσης.

#### **Βήμα 5 – Έλεγχος Ποσοστού και Τύπου Απουσιών (Missing Data Identification)**

Εξετάστηκαν όλες οι στήλες για ελλείποντα δεδομένα. Δεν εντοπίστηκαν NaN ή NaT τιμές, εκτός από τη στήλη *time\_diff* στην πρώτη γραμμή (αναμενόμενο). Δεν υπήρχαν γραμμές με πολλαπλά NaN. Άρα, το σύνολο δεδομένων χαρακτηρίζεται από πλήρη πληρότητα.

#### **Βήμα 6 – Διαχείριση Μη Έγκυρων Τιμών και Ανακατασκευή Συνόλου**

Εφόσον δεν εντοπίστηκαν μη έγκυρες τιμές ή NaN στις βασικές στήλες, δεν χρειάστηκε να εφαρμοστεί κάποια τεχνική διαγραφής ή συμπλήρωσης τιμών (όπως διαγραφή γραμμών ή τεχνητή πρόβλεψη τιμών). Το σύνολο δεδομένων κρίθηκε ήδη καθαρό και κατάλληλο προς χρήση.

#### **Βήμα 7 – Ομαδοποίηση Δεδομένων (Data Aggregation)**

Για λόγους εποχιακής ανάλυσης και συγκριτικής αξιολόγησης, τα δεδομένα ομαδοποιήθηκαν σε μηνιαίες μέσες τιμές. Σημειώνεται ότι, παρόλο που το εργαλείο PVGIS παρέχει και μηνιαία δεδομένα, επιλέχθηκε η χρήση των ωριαίων τιμών ώστε να είναι δυνατός ο λεπτομερής καθαρισμός, ο οποίος απαιτεί υψηλή χρονική ανάλυση. Η ομαδοποίηση σε μηνιαίες μέσες τιμές διευκολύνει την παρακολούθηση των τάσεων απόδοσης του φωτοβολταϊκού συστήματος και την εξαγωγή συμπερασμάτων σε μακροχρόνιο επίπεδο. Κάθε γραμμή στο νέο σύνολο δεδομένων αντιπροσωπεύει τον μέσο όρο των τιμών ανά μήνα.

## Βήμα 8 – Σύνοψη και Επαλήθευση Στατιστικών (Data Statistics Summary & Verification)

Πραγματοποιήθηκε στατιστική ανάλυση τόσο για το ωριαίο όσο και για το μηνιαίο σύνολο δεδομένων. Για κάθε βασική μεταβλητή υπολογίστηκαν βασικοί περιγραφικοί δείκτες όπως ο μέσος όρος (mean), η ελάχιστη και μέγιστη τιμή (min/max), η τυπική απόκλιση (std) και τα ποσοστημόρια (25%, 50%, 75%), τα οποία προσφέρουν σαφή εικόνα της κατανομής των τιμών και της μεταβλητότητας των δεδομένων.

Τα αποτελέσματα της ανάλυσης έδειξαν ότι όλες οι μεταβλητές παρουσιάζουν τιμές εντός των φυσιολογικών και αναμενόμενων ορίων για την περιοχή μελέτης, χωρίς ασυνέπειες ή ανεξήγητες αποκλίσεις. Το γεγονός αυτό επιβεβαιώνει ότι η διαδικασία καθαρισμού ήταν αποτελεσματική και ότι το σύνολο δεδομένων είναι ποιοτικά αξιόπιστο για τη συνέχεια της ανάλυσης.

Η παρακάτω σύνοψη βασίζεται στο τελικό καθαρισμένο σύνολο των ωριαίων δεδομένων, όπως αυτό διαμορφώθηκε μετά την εφαρμογή φυσικών ορίων και την απομάκρυνση ακραίων τιμών με βάση τον κανόνα του boxplot. Ο Πίνακας 4 παρουσιάζει τα περιγραφικά στατιστικά των βασικών μεταβλητών του συνόλου και προέκυψε μέσω ανάλυσης που πραγματοποιήθηκε στο Βήμα 8 της διαδικασίας DQRs, με χρήση Python (βλ. Παράρτημα A.1).

Πίνακας 4: Περιγραφικά Στατιστικά των Ωριαίων Δεδομένων μετά τον Καθαρισμό (DQRs)

| Στατιστικό | P (W)   | G(i) (W/m <sup>2</sup> ) | H_sun (°) | T2m (°C) | WS10m (m/s) |
|------------|---------|--------------------------|-----------|----------|-------------|
| count      | 3996.00 | 3996.00                  | 3996.00   | 3996.00  | 3996.00     |
| mean       | 372.29  | 479.31                   | 33.30     | 18.89    | 2.90        |
| std        | 255.26  | 321.63                   | 18.30     | 6.52     | 1.37        |
| min        | 6.04    | 20.11                    | 2.76      | 1.95     | 0.07        |
| 25%        | 114.46  | 162.58                   | 18.63     | 13.48    | 1.86        |
| 50%        | 365.02  | 449.19                   | 30.30     | 19.15    | 2.76        |
| 75%        | 612.40  | 780.99                   | 46.47     | 24.31    | 3.79        |
| max        | 896.00  | 1085.77                  | 73.55     | 36.34    | 6.69        |

Παράλληλα, υπολογίστηκαν και στατιστικά χαρακτηριστικά για τα μηνιαία δεδομένα, με σκοπό την εποχιακή αποτύπωση των μεταβολών και την ενίσχυση της συνολικής αξιολόγησης του συνόλου.

Η ανάλυση έδειξε ότι όλες οι μεταβλητές εμφανίζουν τιμές συμβατές με τις αναμενόμενες καιρικές συνθήκες και τα φυσικά όρια, χωρίς ασυνέπειες ή ακραίες αποκλίσεις. Συνεπώς, το τελικό σύνολο δεδομένων κρίνεται πλήρες, ποιοτικό και αξιόπιστο, κατάλληλο για χρήση στη συνέχεια της εργασίας.

Ο αναλυτικός κώδικας για την εφαρμογή των βημάτων 1–8 της μεθοδολογίας DQRs παρατίθεται στο Παράρτημα Α.1.

#### **5.4 Εκπαίδευση Μοντέλου Πρόβλεψης Ισχύος (Reference Model)**

Στο παρόν στάδιο επιχειρείται η ανάπτυξη ενός μοντέλου πρόβλεψης της παραγόμενης ηλεκτρικής ισχύος ( $P$ ) ενός φωτοβολταϊκού συστήματος, με βάση επιλεγμένες περιβαλλοντικές μεταβλητές. Στόχος είναι η δημιουργία ενός αξιόπιστου μοντέλου αναφοράς (reference model), το οποίο θα περιγράφει τη φυσιολογική συμπεριφορά του συστήματος υπό κανονικές συνθήκες λειτουργίας, δηλαδή χωρίς την παρουσία βλαβών ή άλλων λειτουργικών αποκλίσεων.

Η επιλογή αυτής της προσέγγισης βασίζεται στην ανάγκη για έγκαιρη ανίχνευση πιθανών δυσλειτουργιών μέσω προληπτικής συντήρησης. Ένα μοντέλο το οποίο αναπαριστά με ακρίβεια την κανονική λειτουργία μπορεί, εφόσον εφαρμοστεί σε πραγματικά δεδομένα πεδίου, να χρησιμοποιηθεί για τη σύγκριση προβλεπόμενης και μετρούμενης ισχύος. Αποκλίσεις μεταξύ των δύο ενδέχεται να υποδεικνύουν την ύπαρξη προβλήματος, όπως μείωση της απόδοσης ή εμφάνιση σφάλματος στο σύστημα.

Το σύνολο δεδομένων που χρησιμοποιήθηκε για την εκπαίδευση του μοντέλου προέρχεται από το εργαλείο PVGIS και περιλαμβάνει ωριαίες προσομοιωμένες τιμές ισχύος, υπολογισμένες βάσει μετεωρολογικών παραμέτρων. Τα δεδομένα αυτά θεωρούνται αντιπροσωπευτικά της ομαλής λειτουργίας ενός φωτοβολταϊκού συστήματος, καθώς δεν περιλαμβάνουν πραγματικά περιστατικά βλαβών ή εξωτερικές παρεμβολές.



Συνεπώς, το μοντέλο που προκύπτει από την ανάλυση αυτή αποτελεί το θεμέλιο για την επόμενη φάση της μελέτης, καθώς μπορεί να λειτουργήσει ως σημείο αναφοράς για την ανίχνευση αποκλίσεων σε μελλοντικές εφαρμογές, όπου θα είναι διαθέσιμα δεδομένα πραγματικής λειτουργίας

#### 5.4.1 Δεδομένα και μεταβλητές

Για την εκπαίδευση του μοντέλου χρησιμοποιήθηκε το αρχείο `cleaned_data_after_step4.xlsx`, το οποίο περιλαμβάνει καθαρισμένα περιβαλλοντικά δεδομένα και ισχύ για το έτος 2023, με χρονική ανάλυση ανά ώρα. Οι μεταβλητές που χρησιμοποιήθηκαν για την ανάπτυξη του μοντέλου ταξινομούνται σε εισόδους (predictors) και στόχο πρόβλεψης (target).

#### 5.4.2 Επιλογή Μεθοδολογίας

Για την πρόβλεψη της παραγόμενης ισχύος του φωτοβολταϊκού συστήματος επιλέχθηκε η μέθοδος της Γραμμικής Παλινδρόμησης (Linear Regression), μία από τις πιο θεμελιώδεις τεχνικές της επιβλεπόμενης μηχανικής μάθησης. Η επιλογή της συγκεκριμένης μεθοδολογίας βασίστηκε τόσο στη φύση του προβλήματος όσο και στα χαρακτηριστικά των διαθέσιμων δεδομένων.

Η γραμμική παλινδρόμηση θεωρείται κατάλληλη όταν στόχος είναι η πρόβλεψη συνεχών αριθμητικών τιμών, όπως συμβαίνει στην περίπτωση της παραγόμενης ισχύος  $P$ . Το μοντέλο προσπαθεί να περιγράψει μια γραμμική σχέση ανάμεσα στις ανεξάρτητες μεταβλητές ( $G(i)$ ,  $H_{\text{sun}}$ ,  $T2m$ ,  $WS10m$ ) και την εξαρτημένη μεταβλητή  $P$ , μέσω της εκτίμησης των κατάλληλων συντελεστών.

Η συγκεκριμένη τεχνική επιλέχθηκε για τους εξής λόγους:

- **Ερμηνευσιμότητα:** Η γραμμική παλινδρόμηση παρέχει έναν απλό και ξεκάθαρο μαθηματικό τύπο, ο οποίος επιτρέπει την κατανόηση της συνεισφοράς κάθε μεταβλητής στο τελικό αποτέλεσμα. Αυτό είναι ιδιαίτερα σημαντικό για την ανάλυση φυσικών συστημάτων, όπως τα φωτοβολταϊκά.
- **Υπολογιστική αποδοτικότητα:** Πρόκειται για μία εξαιρετικά απλή υπολογιστικά μέθοδο, η οποία απαιτεί ελάχιστους πόρους και χρόνο εκπαίδευσης. Παρότι απλή, συχνά αποδίδει εξαιρετικά καλά όταν τα δεδομένα παρουσιάζουν περίπου

γραμμική συσχέτιση — συνθήκη που ισχύει εν μέρει στην περίπτωση φωτοβολταϊκών, όπου η ισχύς εξαρτάται έντονα από την ηλιακή ακτινοβολία και άλλες περιβαλλοντικές παραμέτρους.

- **Συμβατότητα με τον τύπο των δεδομένων:** Δεδομένου ότι η παραγόμενη ισχύς  $P$  αποτελεί συνεχή αριθμητική μεταβλητή (μετρημένη σε Watt), η γραμμική παλινδρόμηση είναι απολύτως κατάλληλη για το συγκεκριμένο πρόβλημα πρόβλεψης. Αντίθετα, τεχνικές ταξινόμησης, όπως η λογιστική παλινδρόμηση ή τα δέντρα απόφασης, εφαρμόζονται συνήθως σε κατηγορικά δεδομένα — δηλαδή σε περιπτώσεις όπου η έξοδος χωρίζεται σε διακριτές κατηγορίες, όπως "βλάβη" ή "μη-βλάβη".
- **Χρήση ως μοντέλο αναφοράς (baseline):** Η διαφάνεια και η σταθερότητα της γραμμικής παλινδρόμησης την καθιστούν κατάλληλη για τη δημιουργία μοντέλων βάσης (baseline models), τα οποία μπορούν να αξιοποιηθούν στη συνέχεια για την ανίχνευση αποκλίσεων από τη φυσιολογική λειτουργία.

Συνοψίζοντας, η επιλογή της γραμμικής παλινδρόμησης δεν έγινε μόνο για λόγους απλότητας, αλλά κυρίως λόγω της καλής ισορροπίας μεταξύ ερμηνευσιμότητας, ακρίβειας και υπολογιστικής αποδοτικότητας, ιδίως στο πλαίσιο μιας πρώτης προσέγγισης δημιουργίας reference μοντέλου για προληπτική συντήρηση φωτοβολταϊκών συστημάτων.

#### 5.4.3 Διαδικασία Εκπαίδευσης

Για την εκπαίδευση του μοντέλου γραμμικής παλινδρόμησης, το καθαρισμένο σύνολο δεδομένων χωρίστηκε σε δύο επιμέρους υποσύνολα:

- **σύνολο εκπαίδευσης (training set)**, το οποίο περιλάμβανε το 80% των εγγραφών και χρησιμοποιήθηκε για να "μάθει" το μοντέλο τα μοτίβα και τις σχέσεις ανάμεσα στις μεταβλητές, και
- **σύνολο δοκιμής (test set)**, το οποίο αντιστοιχούσε στο υπόλοιπο 20% και χρησιμοποιήθηκε αποκλειστικά για την αξιολόγηση της απόδοσης του μοντέλου σε δεδομένα που δεν είχε "δει" κατά την εκπαίδευση.

Ως ανεξάρτητες μεταβλητές (features) χρησιμοποιήθηκαν οι  $G(i)$ ,  $H_{sun}$ ,  $T2m$ ,  $WS10m$ . Η εξαρτημένη μεταβλητή (στόχος) ήταν η  $P$ , δηλαδή η παραγόμενη ηλεκτρική ισχύς του φωτοβολταϊκού συστήματος, όπως υπολογίζεται από το εργαλείο PVGIS.

Η υλοποίηση πραγματοποιήθηκε σε περιβάλλον Python, με τη χρήση της βιβλιοθήκης `scikit-learn`, η οποία παρέχει αξιόπιστα εργαλεία για την κατασκευή, εκπαίδευση και αξιολόγηση μοντέλων μηχανικής μάθησης.

#### 5.4.4 Αποτελέσματα και αξιολόγηση


Η αξιολόγηση της απόδοσης του μοντέλου γραμμικής παλινδρόμησης πραγματοποιήθηκε με βάση δύο βασικούς στατιστικούς δείκτες: τον Συντελεστή Προσδιορισμού ( $R^2$ ) και το Μέσο Απόλυτο Σχετικό Σφάλμα (MAPE).

Η τιμή του  $R^2$  ανήλθε σε 0.9976, γεγονός που υποδεικνύει ότι το μοντέλο εξηγεί το 99.76% της διακύμανσης της παραγόμενης ισχύος, σε συνάρτηση με τις περιβαλλοντικές μεταβλητές. Αυτό συνεπάγεται ότι υπάρχει πολύ ισχυρή συσχέτιση μεταξύ των εισόδων και της προβλεπόμενης τιμής της ισχύος, και ότι το μοντέλο έχει εξαιρετική προσαρμογή στα δεδομένα.

Αντίστοιχα, ο δείκτης MAPE εκτιμήθηκε σε 9.88%, που σημαίνει ότι η μέση απόκλιση των προβλέψεων του μοντέλου από τις πραγματικές τιμές ισχύος είναι μικρότερη του 10%. Τιμές MAPE κάτω του 10% θεωρούνται ιδιαιτέρως ικανοποιητικές στη βιβλιογραφία, ειδικά όταν πρόκειται για περιβαλλοντικά δεδομένα και χρονοσειρές [42, 43].

Οι τιμές αυτές υποδεικνύουν εξαιρετική ακρίβεια πρόβλεψης και πολύ καλή προσαρμογή του μοντέλου στα δεδομένα, γεγονός που επιβεβαιώνεται και από το γράφημα σύγκρισης της πραγματικής με την προβλεπόμενη ισχύ (Σχήμα 5). Η συγκέντρωση των σημείων γύρω από τη διαγώνιο του γραφήματος δείχνει ότι οι προβλέψεις του μοντέλου είναι πολύ κοντά στις πραγματικές τιμές, γεγονός που επιβεβαιώνει την ακρίβεια της εκπαίδευσης.

Το τελικό μοντέλο μπορεί να αξιοποιηθεί ως βάση αναφοράς (reference model), καθώς περιγράφει με αξιοπιστία τη φυσιολογική συμπεριφορά του συστήματος. Σε μελλοντικές εφαρμογές, η σύγκριση της προβλεπόμενης ισχύος με πραγματικά μετρούμενες τιμές μπορεί να χρησιμοποιηθεί για την ανίχνευση αποκλίσεων ή πιθανών βλαβών, ενισχύοντας την εφαρμογή στρατηγικών προληπτικής συντήρησης.



Σχήμα 5: Σύγκριση πραγματικής και προβλεπόμενης ισχύος. Η διακεκομμένη γραμμή αναπαριστά την ιδανική πρόβλεψη, ενώ τα σημεία δείχνουν τις προβλέψεις του μοντέλου γραμμικής παλινδρόμησης

#### 5.4.5 Εξαγωγή Γραμμικής Σχέσης Πρόβλεψης

Μετά την εκπαίδευση του μοντέλου γραμμικής παλινδρόμησης, εξήχθη η μαθηματική σχέση που εκφράζει την παραγόμενη ισχύ  $P$  ως συνάρτηση των περιβαλλοντικών παραμέτρων. Ο τύπος που προέκυψε έχει τη μορφή:

$$P = 0.8103 \cdot G(i) - 0.2691 \cdot H_{\text{sun}} - 1.8744 \cdot T_{2m} + 2.7393 \cdot WS_{10m} + 20.3548$$

Η εξίσωση αυτή αποτυπώνει τη γραμμική συσχέτιση μεταξύ της εξαρτημένης μεταβλητής (ισχύος παραγωγής) και των μεταβλητών εισόδου και επιτρέπει την ερμηνεία της επιρροής κάθε παράγοντα στην ισχύ. Πιο συγκεκριμένα:

- Η ηλιακή ακτινοβολία  $G(i)$  παρουσιάζει τη μεγαλύτερη θετική συνεισφορά, γεγονός αναμενόμενο, καθώς αποτελεί τον κύριο παράγοντα παραγωγής ενέργειας.
- Η θερμοκρασία του αέρα  $T_{2m}$  έχει αρνητικό συντελεστή, αντανακλώντας το γνωστό φαινόμενο μείωσης της απόδοσης των φωτοβολταϊκών πάνελ με την αύξηση της θερμοκρασίας.

- Η ταχύτητα ανέμου WS10m έχει θετική επίδραση, πιθανώς λόγω της δροσιστικής της δράσης που περιορίζει τις απώλειες λόγω υπερθέρμανσης.
- Το ηλιακό ύψος Hsun εμφανίζει ήπια αρνητική επίδραση, η οποία μπορεί να σχετίζεται με γεωμετρικά φαινόμενα πρόσπτωσης ακτινοβολίας ή με τη χρονική κατανομή των τιμών εντός της ημέρας.

Η παραπάνω εξίσωση προσφέρει ένα ερμηνεύσιμο και χρήσιμο εργαλείο για την αναπαράσταση της φυσιολογικής συμπεριφοράς του συστήματος με βάση παρατηρήσιμες μεταβλητές.

#### 5.4.6 Συμπέρασμα

Το μοντέλο γραμμικής παλινδρόμησης που αναπτύχθηκε πέτυχε πολύ υψηλή ακρίβεια στην πρόβλεψη της ισχύος, βασισμένο σε περιβαλλοντικά δεδομένα. Με MAPE  $\approx 9.88\%$  και  $R^2 \approx 0.998$ , μπορεί να χρησιμοποιηθεί ως αξιόπιστο σημείο αναφοράς για την κανονική λειτουργία του φωτοβολταϊκού συστήματος, διευκολύνοντας την ανίχνευση αποκλίσεων ή πιθανών βλαβών στο μέλλον. Ο πλήρης σχολιασμένος κώδικας Python για την εκπαίδευση του μοντέλου παρατίθεται στο Παράρτημα Α.2, προκειμένου να διατηρηθεί η ροή του κυρίως κειμένου.

### 5.5 Δημιουργία Τεχνικών Βλαβών και προεπεξεργασία για ταξινόμηση

Αφού ολοκληρώθηκε η πρόβλεψη της ισχύος με χρήση γραμμικής παλινδρόμησης, το επόμενο στάδιο ήταν η δημιουργία τεχνητών βλαβών στο σύνολο δεδομένων, προκειμένου να εκπαιδευτεί ένα μοντέλο ταξινόμησης για την ανίχνευσή τους. Δεδομένου ότι το αρχικό σύνολο δεδομένων δεν περιλάμβανε πραγματικά περιστατικά βλαβών, κρίθηκε απαραίτητη η δημιουργία τεχνητών labels προκειμένου να είναι δυνατή η εποπτευόμενη εκπαίδευση ενός μοντέλου ταξινόμησης. Η προσέγγιση αυτή εφαρμόζεται συχνά σε συνθήκες όπου δεν υπάρχουν καταγεγραμμένα περιστατικά πραγματικών βλαβών, και αποσκοπεί στη δημιουργία ενός ελεγχόμενου σεναρίου, όπου οι βλάβες έχουν οριστεί με σαφήνεια.

Η διαδικασία βασίστηκε στην παραδοχή ότι μια σημαντική και ξαφνική μείωση της παραγόμενης ισχύος μπορεί να αποτελεί ένδειξη δυσλειτουργίας. Με βάση αυτή την

υπόθεση, επιλέχθηκε τυχαία το 8% των παρατηρήσεων του συνόλου δεδομένων και, σε αυτές, η τιμή της μεταβλητής ισχύος (P) μειώθηκε κατά 70%. Στη συνέχεια, προστέθηκε νέα στήλη με την ονομασία `fault_label`, η οποία πήρε τιμή 1 για τις γραμμές με τεχνητή βλάβη και τιμή 0 για τη φυσιολογική λειτουργία.

Η μείωση της ισχύος κατά 70% επιλέχθηκε ώστε οι τεχνητές βλάβες να παράγουν σαφώς διακριτή απόκλιση από τη φυσιολογική συμπεριφορά του συστήματος. Στόχος ήταν να διασφαλιστεί η αποτελεσματική εκπαίδευση των μοντέλων, χωρίς να απαιτούνται περίπλοκες συνθήκες ανίχνευσης στο αρχικό στάδιο πειραματισμού. Η δημιουργία απλής και ελεγχόμενης μορφής βλάβης κρίθηκε απαραίτητη, προκειμένου να αξιολογηθεί η βασική ικανότητα των ταξινομητών να εντοπίζουν αποκλίσεις στην ισχύ. Αντίστοιχα, το ποσοστό των τεχνητών βλαβών (8%) επιλέχθηκε ώστε να προσομοιάζει ρεαλιστικά την φυσική λειτουργία των φωτοβολταϊκών, όπου τα περιστατικά βλαβών είναι σχετικά σπάνια. Η επιλογή αυτή ακολουθεί τη συνήθη πρακτική που περιγράφεται στην σχετική βιβλιογραφία, ειδικά σε περιπτώσεις όπου δεν υπάρχουν διαθέσιμα πραγματικά δεδομένα βλαβών.

Η τυχαία επιλογή των γραμμών έγινε με χρήση σταθερού seed (`random_state=42`), ώστε η διαδικασία να είναι επαναλήψιμη. Συνολικά, δημιουργήθηκαν 319 παρατηρήσεις με ετικέτα βλάβης (`fault_label = 1`) επί συνόλου 3996 εγγραφών, ενώ οι υπόλοιπες 3677 παρέμειναν ως φυσιολογικά σημεία (`fault_label = 0`). Η διαδικασία υλοποιήθηκε με τη βοήθεια της γλώσσας Python και των βιβλιοθηκών NumPy και Pandas. Το αρχείο που προέκυψε ονομάστηκε `data_with_simulated_faults.xlsx`.

Η προσέγγιση αυτή, παρόλο που βασίζεται σε τεχνητά δεδομένα, αποτελεί κοινή πρακτική στη σχετική βιβλιογραφία όταν δεν υπάρχουν πραγματικά δεδομένα βλαβών. Στόχος είναι να αξιολογηθεί η δυνατότητα ενός μοντέλου να εντοπίσει αποκλίσεις από την κανονική λειτουργία, οι οποίες ενδέχεται να υποδεικνύουν βλάβες. Η διαδικασία αυτή βασίστηκε στη μεθοδολογία που προτείνεται στα άρθρα [23, 40, 44, 45, 46] και ο αναλυτικός κώδικας που χρησιμοποιήθηκε για τη δημιουργία των τεχνητών βλαβών παρατίθεται στο Παράρτημα Α.3.

## 5.6 Εκπαίδευση Μοντέλου Πρόβλεψης Βλαβών (Logistic Regression)

Αφού ολοκληρώθηκε η διαδικασία δημιουργίας τεχνητών βλαβών, το επόμενο βήμα ήταν η εκπαίδευση ενός μοντέλου ταξινόμησης με σκοπό την πρόβλεψη της εμφάνισης πιθανής δυσλειτουργίας στο φωτοβολταϊκό σύστημα. Η ενέργεια αυτή εντάσσεται στο ευρύτερο πλαίσιο της προληπτικής συντήρησης, καθώς στοχεύει στον έγκαιρο εντοπισμό αποκλίσεων από τη φυσιολογική λειτουργία που ενδέχεται να υποδεικνύουν μελλοντικές βλάβες.


Για την υλοποίηση του μοντέλου επιλέχθηκε η Λογιστική Παλινδρόμηση (Logistic Regression), μια απλή αλλά θεμελιώδης τεχνική επιβλεπόμενης μάθησης για προβλήματα δυαδικής ταξινόμησης. Σε αντίθεση με τη γραμμική παλινδρόμηση που προβλέπει συνεχή μεγέθη όπως η ισχύς, η λογιστική παλινδρόμηση επιτρέπει την κατηγοριοποίηση των σημείων σε "κανονική λειτουργία" (`fault_label = 0`) ή "πιθανή βλάβη" (`fault_label = 1`), υπολογίζοντας την πιθανότητα ένταξης σε μία από τις δύο κατηγορίες..

Η επιλογή της συγκεκριμένης μεθόδου βασίστηκε σε τεχνικά και μεθοδολογικά κριτήρια που την καθιστούν ιδιαίτερα κατάλληλη για την παρούσα εφαρμογή. Πρώτον, είναι από τη φύση της κατάλληλη για προβλήματα δυαδικής ταξινόμησης, όπως αυτό της πρόβλεψης βλάβης. Παράλληλα, παρέχει τη δυνατότητα ερμηνείας των αποτελεσμάτων, δηλαδή βοηθά να κατανοηθεί πώς επηρεάζει κάθε μεταβλητή (όπως η θερμοκρασία ή η ακτινοβολία) την πιθανότητα εμφάνισης βλάβης – ένα στοιχείο ιδιαίτερα χρήσιμο σε εφαρμογές που συνδέονται με την τεχνική αξιολόγηση και τη λήψη αποφάσεων. Επιπλέον, η Λογιστική Παλινδρόμηση είναι απλή στην υλοποίηση, με χαμηλές απαιτήσεις σε υπολογιστικούς πόρους, κάτι που την καθιστά πρακτική επιλογή στα πρώτα στάδια ανάλυσης. Συχνά χρησιμοποιείται και ως baseline μοντέλο, ώστε να λειτουργήσει ως σημείο αναφοράς για τη σύγκριση με πιο σύνθετους αλγορίθμους, όπως τα Random Forest ή τα μοντέλα Boosting. Τέλος, η ευκολία κατανόησης της μεθοδολογίας την καθιστά κατάλληλη για ερευνητικά έργα με εκπαιδευτικό χαρακτήρα, καθώς συμβάλλει στη σταδιακή εξοικείωση με πιο σύνθετες τεχνικές.

Η εκπαίδευση του μοντέλου πραγματοποιήθηκε με χρήση των περιβαλλοντικών μεταβλητών  $G(i)$ ,  $H_{sun}$ ,  $T2m$  και  $WS10m$  ως χαρακτηριστικών εισόδου και της μεταβλητής `fault_label` ως στόχου. Ωστόσο, λόγω της έντονης ανισορροπίας μεταξύ των

δύο κατηγοριών (με τις τεχνητές βλάβες να αποτελούν μόλις το 8% του συνόλου), εφαρμόστηκε η τεχνική SMOTE (Synthetic Minority Over-sampling Technique). Με τον τρόπο αυτό δημιουργήθηκαν επιπλέον δείγματα για την κατηγορία «βλάβη», εξισορροπώντας το σύνολο εκπαίδευσης και επιτρέποντας στο μοντέλο να εκπαιδευτεί πιο αποτελεσματικά [47, 48, 49, 50].

Ο Πίνακας Σύγχυσης της Εικόνας 15 παρουσιάζει την ικανότητα του μοντέλου να διαχωρίζει μεταξύ φυσιολογικής λειτουργίας και πιθανής βλάβης, βάσει των τεχνητών ετικετών που δημιουργήθηκαν στο προηγούμενο στάδιο. Σύμφωνα με τα αποτελέσματα, το μοντέλο κατάφερε να εντοπίσει σωστά 34 περιπτώσεις βλάβης (True Positives), ενώ παρέλειψε 30 (False Negatives), δηλαδή σημεία που αντιστοιχούσαν σε βλάβες αλλά προβλέφθηκαν ως κανονική λειτουργία. Παράλληλα, εντοπίστηκαν 381 ψευδώς θετικές προβλέψεις (False Positives), δηλαδή περιπτώσεις όπου το μοντέλο θεώρησε εσφαλμένα ότι υπήρχε βλάβη, ενώ το σύστημα λειτουργούσε κανονικά.



Εικόνα 15: Πίνακας Σύγχυσης για το μοντέλο Λογιστικής Παλινδρόμησης με εφαρμογή της τεχνικής SMOTE

Η παραπάνω κατανομή οδήγησε σε δείκτη ανάκλησης (recall) για την κατηγορία «βλάβη» της τάξης του 53%, γεγονός που δείχνει ότι το μοντέλο κατάφερε να εντοπίσει πάνω από τις μισές περιπτώσεις δυσλειτουργίας. Αντίστοιχα, ο δείκτης ακρίβειας της κατηγορίας «βλάβη» (precision) ανήλθε μόλις στο 8%, γεγονός που αποκαλύπτει αυξημένο ποσοστό ψευδών συναγερμών. Παρά τις αδυναμίες αυτές, τα αποτελέσματα είναι ενθαρρυντικά, καθώς υποδεικνύουν ότι το μοντέλο έχει τη δυνατότητα να αναγνωρίσει πρότυπα που



σχετίζονται με την εμφάνιση ανωμαλιών, προσφέροντας έτσι ένα πρώτο λειτουργικό υπόβαθρο για την ανάπτυξη συστημάτων προληπτικής συντήρησης. Ο αναλυτικός κώδικας που χρησιμοποιήθηκε για την εκπαίδευση του μοντέλου Λογιστικής Παλινδρόμησης και την αξιολόγηση της απόδοσής του παρατίθεται στο Παράρτημα Α.4.

## 5.7 Σύγκριση Αλγορίθμων Πρόβλεψης Βλαβών

Καθώς η Λογιστική Παλινδρόμηση παρουσίασε περιορισμένη ικανότητα εντοπισμού των τεχνητών βλαβών, κρίθηκε σκόπιμο να διερευνηθεί αν πιο σύνθετοι αλγόριθμοι ταξινόμησης θα μπορούσαν να προσφέρουν καλύτερα αποτελέσματα. Για τον σκοπό αυτό επιλέχθηκαν δύο ευρέως χρησιμοποιούμενες μέθοδοι, το Random Forest και το XGBoost, οι οποίες έχουν αποδείξει στην πράξη υψηλή απόδοση σε προβλήματα δυαδικής ταξινόμησης με ανισόρροπες κατηγορίες. Η διαδικασία εκπαίδευσης και αξιολόγησης των αλγορίθμων Random Forest και XGBoost ακολούθησε τα ίδια βήματα με τη Λογιστική Παλινδρόμηση: χρήση των ίδιων χαρακτηριστικών εισόδου ( $G(i)$ ,  $H_{sun}$ ,  $T2m$ ,  $WS10m$ ), εφαρμογή της τεχνικής SMOTE για την εξισορρόπηση των κατηγοριών στο σύνολο εκπαίδευσης. Οι αναλυτικοί κώδικες παρατίθενται στο Παράρτημα Α.5 (Εκπαίδευση Μοντέλου Random Forest και XGBoost). Οι δείκτες που εξετάστηκαν ήταν η ακρίβεια (accuracy), η ακρίβεια κατηγορίας (precision), η ανάκληση (recall) και το f1-score, με ιδιαίτερη έμφαση στην επίδοση του μοντέλου στην κατηγορία «βλάβη» ( $fault\_label = 1$ ). Αναλυτικά, τα αποτελέσματα των τριών αλγορίθμων παρουσιάζονται στον Πίνακα 5 :

Πίνακας 5: Αποτελέσματα αξιολόγησης αλγορίθμων πρόβλεψης βλαβών

| Αλγόριθμος          | Accuracy | Precision | Recall s | F1-score |
|---------------------|----------|-----------|----------|----------|
| Logistic Regression | 49%      | 8%        | 53%      | 14%      |
| Random Forest       | 79%      | 7%        | 14%      | 10%      |
| XGBoost             | 81%      | 8%        | 12%      | 9%       |

Από τη σύγκριση των τριών αλγορίθμων που δοκιμάστηκαν – Λογιστική Παλινδρόμηση, Random Forest και XGBoost – προκύπτει ένα σημαντικό συμπέρασμα: παρόλο που οι Random Forest και XGBoost παρουσίασαν υψηλότερη συνολική ακρίβεια (accuracy) στην πρόβλεψη όλων των κατηγοριών, η Λογιστική Παλινδρόμηση εμφάνισε αισθητά καλύτερη

ανάκληση (recall) για την κατηγορία «βλάβη». Αυτό σημαίνει ότι εντόπισε μεγαλύτερο ποσοστό των σημείων που είχαν χαρακτηριστεί ως βλάβες, γεγονός ιδιαίτερα κρίσιμο στο πλαίσιο της προγνωστικής συντήρησης, όπου προέχει η ικανότητα εντοπισμού των περιστατικών που ενδέχεται να εξελιχθούν σε δυσλειτουργίες.

Η αξιολόγηση βασίστηκε σε δίκαιη σύγκριση, καθώς και οι τρεις αλγόριθμοι εφαρμόστηκαν στο ίδιο σύνολο δεδομένων, με κοινή τεχνική προσομοίωσης βλαβών (μείωση ισχύος στο 8% των γραμμών) και ενιαία διαδικασία προεπεξεργασίας. Αν και θεωρητικά οι Random Forest και XGBoost διαθέτουν μεγαλύτερη μαθησιακή ισχύ, στην πράξη αποδείχθηκε ότι η απόδοσή τους στην κατηγορία «βλάβη» ήταν ισοδύναμη ή και χαμηλότερη από εκείνη της Λογιστικής Παλινδρόμησης.

Το παραπάνω αποτέλεσμα υποδηλώνει ότι το πρόβλημα δεν σχετίζεται αποκλειστικά με την επιλογή του αλγορίθμου, αλλά και με τη φύση των δεδομένων. Το συγκεκριμένο σύνολο δεδομένων παρουσιάζει έντονη ανισορροπία, καθώς οι περιπτώσεις βλάβης αντιστοιχούν σε μόλις 8% των συνολικών παρατηρήσεων. Επιπλέον, οι βλάβες που περιλαμβάνονται στο σύνολο δεν προέρχονται από καταγεγραμμένα περιστατικά, αλλά έχουν δημιουργηθεί τεχνητά με βάση μια υπόθεση (απότομη μείωση της ισχύος). Σε τέτοιου είδους σενάρια, όπου η μειοψηφική κατηγορία δεν διαφοροποιείται με σαφήνεια από τη φυσιολογική λειτουργία, ακόμη και προηγμένοι αλγόριθμοι ταξινόμησης, όπως το XGBoost, ενδέχεται να δυσκολευτούν να «μάθουν» επαρκώς τα μοτίβα της μειοψηφίας.

Παρόλο που η Λογιστική Παλινδρόμηση παρουσίασε χαμηλότερο δείκτη ακρίβειας κατηγορίας (precision) και υψηλό αριθμό ψευδών θετικών προβλέψεων, η σημαντικά αυξημένη της ανάκληση (recall) για την κατηγορία «βλάβη» αποτελεί καθοριστικό πλεονέκτημα. Αυτό σημαίνει ότι εντόπισε μεγαλύτερο ποσοστό των σημείων που είχαν χαρακτηριστεί ως βλάβες, γεγονός ιδιαίτερα κρίσιμο στο πλαίσιο της προγνωστικής συντήρησης, όπου προέχει η ικανότητα έγκαιρου εντοπισμού πιθανών αποκλίσεων από τη φυσιολογική λειτουργία, ακόμη και με κόστος την παραγωγή ορισμένων ψευδών συναγερμών.

Με βάση όλα τα παραπάνω, η Λογιστική Παλινδρόμηση επιλέγεται ως το τελικό μοντέλο αναφοράς για την παρούσα εργασία. Αν και αποτελεί μεθοδολογικά απλούστερη προσέγγιση, αποδείχθηκε πιο αποτελεσματική ως προς τον βασικό στόχο της εφαρμογής:

την προσεγγιστική ανίχνευση ενδεχόμενων δυσλειτουργιών με σκοπό την έγκαιρη παρέμβαση στο πλαίσιο της προληπτικής συντήρησης. Το μοντέλο αυτό μπορεί να αξιοποιηθεί ως βάση για μελλοντική επέκταση και βελτιστοποίηση, είτε με την εφαρμογή προηγμένων τεχνικών επεξεργασίας και ταξινόμησης, είτε – ιδανικά – με τη χρήση πραγματικών δεδομένων από φωτοβολταϊκά συστήματα .

Η παρούσα προσέγγιση προσφέρει ένα ελεγχόμενο και σταθερό περιβάλλον αξιολόγησης, στο οποίο μπορούν να εξεταστούν διαφορετικοί αλγόριθμοι και να διερευνηθούν εναλλακτικές στρατηγικές πρόγνωσης. Αν και η συνολική ακρίβεια δεν κρίνεται ακόμη ικανοποιητική, η ικανότητα του μοντέλου να εντοπίζει έγκαιρα ενδείξεις πιθανών ανωμαλιών αποτελεί ένα ουσιαστικό πρώτο βήμα. Στο πλαίσιο της προγνωστικής συντήρησης, ακόμη και μια μερική ικανότητα ανίχνευσης αποκλίσεων μπορεί να αποδειχθεί πολύτιμη, ιδίως σε πρώιμο στάδιο ανάλυσης. Η εργασία αυτή, επομένως, μπορεί να θεωρηθεί ως αφετηρία για περαιτέρω πειραματισμό και βελτιστοποίηση, με στόχο τη μελλοντική εφαρμογή πιο προηγμένων μεθόδων σε ρεαλιστικά δεδομένα λειτουργίας φωτοβολταϊκών συστημάτων.

## **5.8 Πειράματα με Εναλλακτικά Ποσοστά Βλαβών**

Στο πλαίσιο της διερεύνησης της επίδρασης της ποιότητας και ποσότητας των δεδομένων στην απόδοση των μοντέλων πρόβλεψης βλαβών, σχεδιάστηκε και υλοποιήθηκε ένα σύνολο συμπληρωματικών πειραμάτων. Συγκεκριμένα, μεταβλήθηκε το ποσοστό των τεχνητών βλαβών στο σύνολο δεδομένων, με στόχο να αξιολογηθεί κατά πόσο η αναλογία μειοψηφικής κατηγορίας ( $\text{fault\_label} = 1$ ) επηρεάζει τη συμπεριφορά του μοντέλου Λογιστικής Παλινδρόμησης. Η επιλογή αυτή κρίθηκε απαραίτητη, καθώς η αρχική μελέτη βασίστηκε σε δεδομένα με τεχνητές βλάβες που κάλυπταν το 8% του συνόλου, και υπήρχε η ανάγκη να επιβεβαιωθεί ή να αναθεωρηθεί η καταλληλότητα αυτής της αναλογίας.

Για τον σκοπό αυτό, δημιουργήθηκαν δύο επιπλέον σενάρια τεχνητών βλαβών: ένα με ποσοστό 5% και ένα με 10%. Σε όλα τα σενάρια εφαρμόστηκε η ίδια προσέγγιση δημιουργίας βλάβης, δηλαδή μείωση της παραγόμενης ισχύος ( $P$ ) κατά 70% σε τυχαία επιλεγμένα σημεία. Η εκπαίδευση του μοντέλου ακολούθησε τα ίδια βήματα όπως και στην αρχική περίπτωση: χρήση των ίδιων μεταβλητών εισόδου, εφαρμογή της τεχνικής

SMOTE για εξισορρόπηση των κατηγοριών και αξιολόγηση με βάση τους δείκτες precision, recall και F1-score για την κατηγορία «βλάβη». Η διαδικασία δημιουργίας περιγράφεται αναλυτικά στο Παράρτημα Α.6, όπου παρουσιάζεται ο σχετικός κώδικας Python.

Τα αποτελέσματα της Λογιστικής Παλινδρόμησης με τα νέα σύνολα δεδομένων συνοψίζονται παρακάτω στον Πίνακα 6 :

Πίνακας 6: Αποτελέσματα αξιολόγησης του μοντέλου Λογιστικής Παλινδρόμησης για τρία διαφορετικά ποσοστά τεχνητών βλαβών (5%, 8%, 10%)

| Ποσοστό Βλαβών | Accuracy | Precision | Recall | F1-score |
|----------------|----------|-----------|--------|----------|
| 5%             | 52%      | 5%        | 50%    | 9%       |
| 8%             | 49%      | 8%        | 53%    | 14%      |
| 10%            | 50%      | 9%        | 43%    | 15%      |

Όπως φαίνεται, το καλύτερο αποτέλεσμα ως προς το recall της κατηγορίας «βλάβη» επιτεύχθηκε με ποσοστό τεχνητών βλαβών 8%, όπου το μοντέλο κατάφερε να αναγνωρίσει το 53% των σημείων που ανήκαν στη μειοψηφική κατηγορία. Το 5% βλαβών, παρόλο που οδήγησε σε ελαφρώς υψηλότερο accuracy (52% έναντι 49%), συνοδεύτηκε από πολύ χαμηλό precision (μόλις 5%), γεγονός που δείχνει ότι το μοντέλο δυσκολεύτηκε ιδιαίτερα να εντοπίσει σωστά τις βλάβες. Στην περίπτωση του 10%, παρατηρήθηκε ελαφριά αύξηση του F1-score (15%), όμως συνοδεύτηκε από μείωση της ανάκλησης (recall) σε 43%, γεγονός που υποδηλώνει ότι η αύξηση του ποσοστού βλαβών δεν βελτίωσε ουσιαστικά την ικανότητα ανίχνευσης αποκλίσεων.


Με βάση τα παραπάνω, το ποσοστό των 8% φαίνεται να αποτελεί την πιο ισορροπημένη επιλογή για το συγκεκριμένο πειραματικό πλαίσιο, καθώς προσέφερε τον καλύτερο συμβιβασμό μεταξύ ανάκλησης και ακρίβειας. Αν και πρόκειται για τεχνητές βλάβες και όχι για πραγματικά καταγεγραμμένα περιστατικά, η προσέγγιση αυτή αποδείχθηκε χρήσιμη για να μελετηθεί η συμπεριφορά του μοντέλου υπό διαφορετικές συνθήκες ανισορροπίας. Παρά τα περιορισμένα συνολικά αποτελέσματα, το πείραμα ανέδειξε με σαφήνεια τις προκλήσεις που προκύπτουν στην ανίχνευση σπάνιων γεγονότων, ιδίως όταν αυτά προσομοιώνονται τεχνητά. Επιβεβαιώθηκε έτσι ότι η απόδοση των μοντέλων δεν

εξαρτάται μόνο από τον αλγόριθμο που χρησιμοποιείται, αλλά επηρεάζεται καθοριστικά από τη φύση, την ποιότητα και την ισορροπία των δεδομένων εκπαίδευσης.

## 5.9 Εφαρμογή στην Προληπτική Συντήρηση.

Η εφαρμογή μοντέλων μηχανικής μάθησης στην προγνωστική συντήρηση φωτοβολταϊκών βασίζεται στην έγκαιρη αναγνώριση αποκλίσεων από τη φυσιολογική λειτουργία. Αντί να περιμένει κανείς την εκδήλωση μιας πραγματικής βλάβης, η προσέγγιση αυτή επιδιώκει να εντοπίσει σημεία που παρουσιάζουν ύποπτα μοτίβα συμπεριφοράς, τα οποία ενδέχεται να υποδηλώνουν επικείμενη δυσλειτουργία.

Η Λογιστική Παλινδρόμηση, όπως εφαρμόστηκε στην παρούσα εργασία, μπορεί να χρησιμοποιηθεί ως πυρήνας ενός συστήματος έγκαιρης ειδοποίησης. Ένα τέτοιο σύστημα δεν λειτουργεί αυτόνομα αλλά ενσωματώνεται σε μια ευρύτερη διαδικασία συντήρησης, η οποία συνοψίζεται στο Σχήμα 6: ανίχνευση απόκλισης από το μοντέλο, αποστολή ειδοποίησης, τεχνικός έλεγχος και – εφόσον χρειάζεται – προγραμματισμένη συντήρηση.



Σχήμα 6: Βασική ροή λειτουργίας ενός συστήματος προγνωστικής συντήρησης: ανίχνευση απόκλισης από το μοντέλο, αποστολή ειδοποίησης, τεχνικός έλεγχος και – εφόσον χρειάζεται – προγραμματισμένη συντήρηση

Η ικανότητα εντοπισμού πιθανών αποκλίσεων από τη φυσιολογική λειτουργία ενός φωτοβολταϊκού συστήματος αποτελεί κρίσιμο στοιχείο για την εφαρμογή στρατηγικών προγνωστικής συντήρησης. Η ανάλυση που προηγήθηκε στο πλαίσιο της παρούσας μελέτης ανέδειξε ότι, παρόλο που οι συνολικές επιδόσεις των μοντέλων ταξινόμησης ήταν μέτριες, η Λογιστική Παλινδρόμηση παρουσίασε συγκριτικά υψηλότερη ικανότητα ανάκλησης (recall) στην κατηγορία «βλάβη». Το γεγονός αυτό υποδεικνύει ότι το μοντέλο είναι σε θέση να εντοπίζει με σχετική αξιοπιστία τις περιπτώσεις που ενδέχεται να υποκρύπτουν δυσλειτουργίες.

Σε εφαρμογές προγνωστικής συντήρησης, το ζητούμενο δεν είναι απαραίτητα η πρόβλεψη όλων των βλαβών με απόλυτη ακρίβεια, αλλά η έγκαιρη αναγνώριση σημείων που παρουσιάζουν απόκλιση από τη φυσιολογική συμπεριφορά. Η εντοπισμένη απόκλιση μπορεί να μην αντιστοιχεί άμεσα σε μια αποδεδειγμένη βλάβη, ωστόσο αποτελεί χρήσιμο σήμα για περαιτέρω διερεύνηση από τεχνικούς. Μέσω μιας τέτοιας προσέγγισης, το μοντέλο μπορεί να ενσωματωθεί σε ένα ευρύτερο σύστημα ειδοποίησης και παρακολούθησης, παρέχοντας προειδοποιήσεις για πιθανές δυσλειτουργίες πριν αυτές εξελιχθούν σε σοβαρά προβλήματα. Ένα τέτοιο σύστημα θα μπορούσε να ενεργοποιεί επιθεωρήσεις ή ελέγχους συντήρησης σε επιλεγμένα σημεία, μειώνοντας τον χρόνο εκτός λειτουργίας και το κόστος αποκατάστασης.

Η χρήση τεχνητών δεδομένων σε αυτό το στάδιο επιτρέπει την ελεγχόμενη αξιολόγηση της προσέγγισης, παρέχοντας ένα ασφαλές περιβάλλον πειραματισμού και εξαγωγής πρώτων συμπερασμάτων. Ωστόσο, το επόμενο φυσικό βήμα για την εξέλιξη της παρούσας εργασίας είναι η εφαρμογή της ίδιας μεθοδολογίας σε πραγματικά δεδομένα λειτουργίας φωτοβολταϊκών συστημάτων, τα οποία περιλαμβάνουν καταγεγραμμένες περιπτώσεις βλαβών, ρυθμούς φθοράς και ιστορικό συντήρησης.

Συνολικά, η προσέγγιση που υλοποιήθηκε αποτελεί ένα πρώτο βήμα προς την κατεύθυνση της έξυπνης συντήρησης. Μέσα από την αξιοποίηση αλγορίθμων μηχανικής μάθησης, δίνεται η δυνατότητα δημιουργίας συστημάτων που δεν περιορίζονται στην παθητική παρακολούθηση, αλλά αποκτούν την ικανότητα να «προβλέπουν» τη μελλοντική συμπεριφορά του εξοπλισμού. Με τη σταδιακή ενσωμάτωση ρεαλιστικών δεδομένων και τη συνεχή εκπαίδευση των μοντέλων, η προσέγγιση αυτή μπορεί να εξελιχθεί σε ένα πλήρως λειτουργικό σύστημα υποστήριξης αποφάσεων για τη συντήρηση φωτοβολταϊκών εγκαταστάσεων.

## Κεφάλαιο 6 Συμπεράσματα και Μελλοντικές Κατευθύνσεις

### 6.1 Σύνοψη και συμπεράσματα

Συνοψίζοντας τα παραπάνω και λαμβάνοντας υπόψη τα αποτελέσματα της μελέτης, η παρούσα διπλωματική εργασία επικεντρώθηκε στη διερεύνηση της δυνατότητας αξιοποίησης της τεχνητής νοημοσύνης για την υποστήριξη της προληπτικής συντήρησης φωτοβολταϊκών συστημάτων. Στο θεωρητικό μέρος παρουσιάστηκαν τα βασικά χαρακτηριστικά και η λειτουργία των φωτοβολταϊκών, οι συνηθέστερες κατηγορίες βλαβών, καθώς και οι υπάρχουσες στρατηγικές συντήρησης, με έμφαση στην προληπτική και προγνωστική προσέγγιση. Επίσης, αναλύθηκαν οι κύριες τεχνικές τεχνητής νοημοσύνης – και ιδιαίτερα η μηχανική μάθηση – καθώς και οι εφαρμογές τους στην ανίχνευση, την πρόβλεψη και τη βελτιστοποίηση της λειτουργίας των φωτοβολταϊκών εγκαταστάσεων.

Το πειραματικό μέρος σχεδιάστηκε με στόχο να διερευνηθεί αν απλές μέθοδοι μηχανικής μάθησης μπορούν να συμβάλουν στην έγκαιρη ανίχνευση πιθανών δυσλειτουργιών. Η μεθοδολογία που ακολουθήθηκε περιλάμβανε τον καθαρισμό των δεδομένων με τη μεθοδολογία DQRs, την εκπαίδευση μοντέλου πρόβλεψης ισχύος (reference model), τη δημιουργία τεχνητών βλαβών μέσω μείωσης της ισχύος κατά 70%, την εκπαίδευση και τη σύγκριση τριών ταξινομητών (Logistic Regression, Random Forest και XGBoost), καθώς και επιπλέον πειράματα με διαφορετικά ποσοστά βλαβών (5%, 8%, 10%), ώστε να μελετηθεί η επίδραση της ανισορροπίας κατηγοριών στην απόδοση των μοντέλων.

Τα αποτελέσματα έδειξαν ότι, παρά την απλότητά της η Logistic Regression πέτυχε την υψηλότερη ανάκληση για την κατηγορία «βλάβη», γεγονός ιδιαίτερα κρίσιμο στο πλαίσιο της προληπτικής συντήρησης, όπου η έγκαιρη ανίχνευση έχει μεγαλύτερη σημασία από τη συνολική ακρίβεια. Αντίθετα, οι πιο σύνθετοι αλγόριθμοι Random Forest και XGBoost εμφάνισαν υψηλότερη συνολική ακρίβεια, αλλά δυσκολεύτηκαν να ανιχνεύσουν αποτελεσματικά τις βλάβες. Επιπλέον, η ανάλυση των διαφορετικών ποσοστών τεχνητών βλαβών έδειξε ότι το σύνολο εκπαίδευσης με ποσοστό βλαβών 8% παρείχε την καλύτερη ισορροπία μεταξύ recall και precision, ενώ ποσοστά βλαβών 5% και 10% επιδείνωσαν

αντίστοιχα την ικανότητα ανίχνευσης ή την ακρίβεια των ταξινομητών. Τα πειράματα αυτά επιβεβαίωσαν τη σημασία της σωστής αναλογίας κατηγοριών αλλά και της ποιότητας των δεδομένων εκπαίδευσης στην τελική απόδοση ενός μοντέλου. Διαπιστώθηκε ότι ακόμη και οι καλύτεροι αλγόριθμοι δεν μπορούν να αποδώσουν σωστά αν τα δεδομένα δεν είναι ισορροπημένα ή επαρκώς αντιπροσωπευτικά των πραγματικών περιστατικών.

Συνολικά, η εργασία αυτή ανέδειξε τόσο τις δυνατότητες όσο και τις προκλήσεις της χρήσης τεχνητής νοημοσύνης στη συντήρηση φωτοβολταϊκών εγκαταστάσεων. Παρά το γεγονός ότι χρησιμοποιήθηκαν τεχνητά δεδομένα και απλουστευμένες συνθήκες, το πειραματικό μέρος έθεσε μία σταθερή βάση για περαιτέρω ανάπτυξη πιο ρεαλιστικών και αποδοτικών μεθοδολογιών πρόγνωσης και έγκαιρης ανίχνευσης βλαβών στο μέλλον.

## **6.2 Μελλοντικές κατευθύνσεις**

Με βάση τα αποτελέσματα και τα συμπεράσματα που προέκυψαν, αρκετά σημεία μπορούν να αποτελέσουν κατευθύνσεις για μελλοντική έρευνα. Αρχικά, η συλλογή και χρήση πραγματικών δεδομένων λειτουργίας και καταγεγραμμένων βλαβών θεωρείται καθοριστικής σημασίας, ώστε να βελτιωθεί η αξιοπιστία και η γενίκευση των μοντέλων μηχανικής μάθησης. Τα πειράματα με τεχνητές βλάβες αποτέλεσαν ένα χρήσιμο πρώτο βήμα, όμως η εφαρμογή σε πραγματικές συνθήκες θα επέτρεπε πιο ολοκληρωμένη αξιολόγηση.

Παράλληλα, η βελτίωση της διαχείρισης της ανισορροπίας των δεδομένων, με τη χρήση πιο εξελιγμένων τεχνικών υπερδειγματοληψίας ή δημιουργίας συνθετικών παραδειγμάτων, θα μπορούσε να ενισχύσει την απόδοση των ταξινομητών. Η διερεύνηση πιο σύνθετων αλγορίθμων, όπως υβριδικών μοντέλων που συνδυάζουν κλασικές τεχνικές μηχανικής μάθησης με βαθιά μάθηση, αποτελεί επίσης ενδιαφέρουσα προοπτική. Επιπλέον, η ανάπτυξη αλγορίθμων που να προσαρμόζονται δυναμικά στις μεταβαλλόμενες συνθήκες λειτουργίας των φωτοβολταϊκών συστημάτων, αποτελεί κρίσιμο πεδίο εξέλιξης.

Τέλος, μελλοντική έρευνα θα πρέπει να επικεντρωθεί στη βελτίωση της επεξηγησιμότητας των μοντέλων, ώστε οι προβλέψεις τους να είναι κατανοητές και τεκμηριωμένες. Παράλληλα, θα πρέπει να ενισχυθεί η ανθεκτικότητα των συστημάτων πρόβλεψης



απέναντι σε σφάλματα ή απρόβλεπτες μεταβολές των συνθηκών λειτουργίας. Οι κατευθύνσεις αυτές είναι κρίσιμες για την ανάπτυξη ολοκληρωμένων, αξιόπιστων και ασφαλών λύσεων προληπτικής συντήρησης στο μέλλον.



## Βιβλιογραφία

- [1] International Renewable Energy Agency (IRENA), "Renewable Energy Statistics 2024," Jul. 2024. [Online]. Available: <https://www.irena.org/Publications/2024/Jul/Renewable-energy-statistics-2024>.
- [2] "Τη δεύτερη μεγαλύτερη παραγωγή ενέργειας από φωτοβολταϊκά στον κόσμο είχε η Ελλάδα το 2023 - Ember," *World Energy News*, Jan. 2024. [Online]. Available: <https://www.worldenergynews.gr/ananeosimes/articles/559008/ti-deyteri-megalyteri-paragogi-energeias-apo-fotovoltaika-ston-kosmo-eixe-i-ellada-to-2023-ember>
- [3] Συνεισφέροντες στα εγχειρήματα Wikimedia. Φωτοβολταϊκά. *Wikipedia.org*, Dec. 09, 2005. [Online]. Available: <https://el.wikipedia.org/wiki/%CE%A6%CF%89%CF%84%CE%BF%CE%B2%CE%BF%CE%BB%CF%84%CE%B1%CF%8A%CE%BA%CE%AC>
- [4] A. P. Gonzalo, A. P. Marugán, and F. P. García Márquez. Survey of maintenance management for photovoltaic power systems. *Renewable and Sustainable Energy Reviews*, vol. 134, p. 110347, Dec. 2020, doi: 10.1016/j.rser.2020.110347.
- [5] Μ. Βαρβαγιάννη, *Εναλλακτικές Μορφές Ενέργειας: Ηλιακή Ενέργεια – 2ο Μέρος*, Πανεπιστήμιο Θεσσαλίας, Διαφάνειες μαθήματος
- [6] M. Victoria, *Fundamentals of Solar Cells and Photovoltaic Systems Engineering*, 1st ed., Cambridge, MA: Academic Press, 2024, doi: 10.1016/C2021-0-01799-5.
- [7] Ι. Ν. Κιοσκερίδης, *Ανανεώσιμες Πηγές Ενέργειας και εφαρμογές των Ηλεκτρονικών Ισχύος*, 2η έκδ., Αθήνα: Τζιόλα, 2019.
- [8] S. Silvestre, A. Boronat, and A. Chouder, "Study of bypass diodes configuration on PV modules," *Solar Energy*, vol. 83, no. 9, pp. 1409–1416, Sep. 2009, doi: 10.1016/j.solener.2009.05.010.

- [9] A. Goetzberger and C. Hebling, "Photovoltaic materials, past, present, future," *Solar Energy Materials and Solar Cells*, vol. 62, no. 1–2, pp. 1–19, Apr. 2000, doi: 10.1016/S0927-0248(99)00131-2.
- [10] A. Luque and S. Hegedus, Eds., *Handbook of Photovoltaic Science and Engineering*, 1st ed., Chichester, UK: Wiley, 2003.
- [11] Fraunhofer Institute for Solar Energy Systems (ISE), *Photovoltaics Report*, Freiburg, Germany, Jul. 2024. [Online]. Available: <https://www.ise.fraunhofer.de/en/publications/studies/photovoltaics-report.html>.
- [12] A. Thakfan and Y. Bin Salamah. Artificial-Intelligence-Based Detection of Defects and Faults in Photovoltaic Systems: A Survey. *Energies*, vol. 17, no. 19, pp. 4807–4807, Sep. 2024, doi: 10.3390/en17194807.
- [13] A. Mellit and S. Kalogirou. Artificial intelligence and internet of things to improve efficacy of diagnosis and remote sensing of solar photovoltaic systems: Challenges, recommendations and future directions. *Renewable and Sustainable Energy Reviews*, vol. 143, p. 110889, Jun. 2021, doi: 10.1016/j.rser.2021.110889
- [14] M. W. Akram, G. Li, Y. Jin, and X. Chen, "Failures of Photovoltaic modules and their Detection: A Review," *Applied Energy*, vol. 313, p. 118822, May 2022, doi: 10.1016/j.apenergy.2022.118822.
- [15] J. Ramirez-Vergara, L. B. Bosman, E. Wollega, and W. D. Leon-Salas, "Review of forecasting methods to support photovoltaic predictive maintenance," *Cleaner Engineering and Technology*, vol. 8, p. 100460, Jun. 2022, doi: 10.1016/j.clet.2022.100460.
- [16] A. Abubakar, C. Frederico, and M. Gemignani, "A Review of Solar Photovoltaic System Maintenance Strategies," in *Proc. INDUSCON 2021*, Aug. 2021, doi: 10.1109/induscon51756.2021.9529669.
- [17] A. Mellit, G. M. Tina, and S. A. Kalogirou, "Fault detection and diagnosis methods for photovoltaic systems: A review," *Renew. Sustain. Energy Rev.*, vol. 91, pp. 1–17, Aug. 2018, doi: 10.1016/j.rser.2018.03.062.

- [18] Maysun Solar, "Hot Spot Effects: Causes and Solutions," Maysun Solar Blog, Dec. 8, 2023. [Online]. Available: <https://www.maysunsolar.com/blog-hot-spot-effects-causes-and-solutions/>.
- [19] MCI Solutions, "The Effect of Shade on Solar Panels," MCI Solutions, 2015. [Online]. Available: <https://mcisolutions.ca/effect-of-shade-on-solar-panels/>.
- [20] A. H. Abou Yassine, E. Khoshbakhtnejad, and H. Sojoudi, "Economics of Snow Accumulation on Photovoltaic Modules," *Energies*, vol. 17, no. 12, p. 2962, Jun. 2024, doi: 10.3390/en17122962.
- [21] N. C. Park, J.-S. Jeong, B. J. Kang, and D. H. Kim, "The effect of encapsulant discoloration and delamination on the electrical characteristics of photovoltaic module," *Microelectronics Reliability*, vol. 53, no. 9–11, pp. 1818–1822, Sep.–Nov. 2013, doi: 10.1016/j.microrel.2013.07.062.
- [22] A. Alrashidi, A. Alhajri, and A. Al-Othman, "A Review of Photovoltaic Module Failure and Degradation Mechanisms: Causes and Detection Techniques," *Solar*, vol. 4, no. 1, p. 3, Jan. 2024, doi: 10.3390/solar4010003.
- [23] A. Livera, M. Theristis, L. Micheli, E. F. Fernández, J. S. Stein, and G. E. Georghiou, "Operation and Maintenance Decision Support System for Photovoltaic Systems," *IEEE Access*, vol. 10, pp. 42481–42496, Jan. 2022, doi: 10.1109/access.2022.3168140.
- [24] G. J.-P. Tevi, M. E. Faye, M. Sene, I. Faye, U. Blieske, and A. S. Maiga, "Solar Photovoltaic Panels Failures Causing Power Losses: A Review," in *Proc. 7th Int. Energy and Sustainability Conf. (IESC)*, May 2018, doi: 10.1109/iesc.2018.8439986.
- [25] H. Abdulla, A. Slepchenko, and A. Nayfeh, "Photovoltaic systems operation and maintenance: A review and future directions," *Renewable and Sustainable Energy Reviews*, vol. 195, p. 114342, May 2024, doi: 10.1016/j.rser.2024.114342.
- [26] Y. S. Afridi, K. Ahmad, and L. Hassan, "Artificial intelligence based prognostic maintenance of renewable energy systems: A review of techniques, challenges, and future research directions," *Int. J. Energy Res.*, Jul. 2021, doi: 10.1002/er.7100.
- [27] M. S. I. Sajo, I. Ahmed, and Q. S. Mahmud, "Synthetic Minority Oversampling Technique Enhanced Machine Learning Models for Energy Theft Detection," in *Proc.*

2024 IEEE Kansas Power and Energy Conference (KPEC), Manhattan, KS, USA, Apr. 2024, doi: 10.1109/KPEC61529.2024.10676105.

- [28] S. Silvestre, "Chapter 7 – Strategies for Fault Detection and Diagnosis of PV Systems," in *Advances in Renewable Energies and Power Technologies*, vol. 1: Solar and Wind Energies, 1st ed., A. Lecuona-Neumann and V. Bermúdez (Eds.), Amsterdam: Elsevier, 2018, pp. 231–255, doi: 10.1016/B978-0-12-812959-3.00007-1.
- [29] M. A. Eltawil and Z. Zhao, "A review of faults, diagnostics, and monitoring techniques for large-scale photovoltaic systems," *Energy Conversion and Management*, vol. 80, pp. 280–291, Apr. 2014, doi: 10.1016/j.enconman.2014.01.039.
- [30] H. Al Mahdi, P. G. Leahy, M. Alghoul, and A. P. Morrison, "A Review of Photovoltaic Failure and Degradation Mechanisms," *Preprints*, Nov. 2023. [Online]. Available: <https://www.preprints.org/manuscript/202311.0761/v1>.
- [31] B. Azzopardi, E. A. Martínez-Ceseña, and J. Mutale, "Decision support system for ranking photovoltaic technologies," *IET Renewable Power Generation*, vol. 7, no. 6, pp. 669–679, Nov. 2013, doi: 10.1049/iet-rpg.2012.0174.
- [32] A. Mohammad and F. Mahjabeen, "Revolutionizing Solar Energy: The Impact of Artificial Intelligence on Photovoltaic Systems," *Int. J. Multidiscip. Sci. Arts*, vol. 2, no. 3, Jul. 2023, doi: 10.47709/ijmdsa.v2i1.2599.
- [33] J. F. Gaviria, G. Narváez, C. Guillen, L. F. Giraldo, and M. Bressan, "Machine learning in photovoltaic systems: A review," *Renewable Energy*, vol. 196, pp. 298–318, Aug. 2022, doi: 10.1016/j.renene.2022.06.105.
- [34] K. Hopf, M. Kormann, M. Sodenkamp, and T. Staake, "A decision support system for photovoltaic potential estimation," in *Proc. 1st Int. Conf. on Internet of Things and Machine Learning (IML '17)*, Article no. 3, pp. 1–10, Oct. 2017, doi: 10.1145/3109761.3109764.
- [35] M. Mansouri, M. Trabelsi, H. Nounou, and M. Nounou, "Deep Learning-Based Fault Diagnosis of Photovoltaic Systems: A Comprehensive Review and Enhancement Prospects," *IEEE Access*, vol. 9, pp. 126286–126306, Sep. 2021, doi: 10.1109/ACCESS.2021.3110947.

- [36] C. Scott, M. Ahsan, and A. Albarbar, "Machine learning for forecasting a photovoltaic (PV) generation system," *Energy*, vol. 278, p. 127807, Sep. 2023, doi: 10.1016/j.energy.2023.127807.
- [37] S. Theocharides, G. Makrides, G. E. Georghiou, and A. Kyprianou, "Machine learning algorithms for photovoltaic system power output prediction," in *Proc. 2018 IEEE Int. Energy Conf. (ENERGYCON)*, Limassol, Cyprus, Jun. 2018, pp. 1–6, doi: 10.1109/ENERGYCON.2018.8398737.
- [38] B. Zazoum, "Solar photovoltaic power prediction using different machine learning methods," *Energy Reports*, vol. 8, Suppl. 1, pp. 19–25, Apr. 2022, doi: 10.1016/j.egyr.2021.11.183.
- [39] International Energy Agency (IEA), "Solar PV," IEA, 2024. Διαθέσιμο: <https://www.iea.org/energy-system/renewables/solar-pv>
- [40] J. Montes-Romero, N. Heinzle, A. Livera, S. Theocharides, G. Makrides, J. Sutterlueti, S. Ransome, και G. E. Georghiou, "Novel data-driven health-state architecture for photovoltaic system failure diagnosis," *Solar Energy*, τομ. 279, σελ. 112820, Σεπ. 2024, doi: 10.1016/j.solener.2024.112820.
- [41] A. Livera, M. Theristis, E. Koumpli, S. Theocharides, G. Makrides, J. Sutterlueti, J. S. Stein, and G. E. Georghiou, "Data processing and quality verification for improved photovoltaic performance and reliability analytics," *Progress in Photovoltaics: Research and Applications*, vol. 29, no. 2, pp. 143–158, Feb. 2021, doi: 10.1002/pip.3349.
- [42] D. Emang, M. Shitan, A. N. Abd. Ghani, and K. M. Noor, "Forecasting with Univariate Time Series Models: A Case of Export Demand for Peninsular Malaysia's Moulding and Chipboard," *Journal of Sustainable Development*, vol. 3, no. 3, pp. 157–161, Sep. 2010.
- [43] E. Vivas, H. Alliende-Cid, and R. Salas, "A systematic review of statistical and machine learning methods for electrical power forecasting with reported MAPE score," *Entropy*, vol. 22, no. 12, p. 1412, Dec. 2020, doi: 10.3390/e22121412.
- [44] A. Syamsuddin, A. C. Adhi, A. Kusumawardhani, T. Prahasto, and A. Widodo, "Predictive maintenance based on anomaly detection in photovoltaic system using

SCADA data and machine learning," *Results in Engineering*, vol. 24, Dec. 2024, Art. no. 103589, doi: 10.1016/j.rineng.2024.103589.

- [45] B. Ali, M. A. Mohammed, A. S. Al-Janabi, M. A. Mostafa, S. S. Zubaidi, and S. Kadry, "Fault detection in photovoltaic systems using machine learning technique," in 2021 IEEE 11th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS), 2021, pp. 682–687, doi: 10.1109/IDAACS53288.2021.9660786.
- [46] S. Pelland, J. Remund, J. Kleissl, T. Oozeki, and K. De Brabandere, "Advanced PV performance modelling based on different levels of irradiance data accuracy," *Energies*, vol. 13, no. 9, p. 2166, May 2020, doi: 10.3390/en13092166.
- [47] M. J. Smith, L. T. Johnson, and K. L. Davis, "Correcting for the effects of class imbalance improves the performance of species distribution models," *Ecological Modelling*, vol. 456, p. 109678, 2023, doi: 10.1016/j.ecolmodel.2023.109678.
- [48] K. Osmani, A. Haddad, T. Lemenand, B. Castanier, and M. Ramadan, "A review on maintenance strategies for PV systems," *Science of The Total Environment*, vol. 746, p. 141753, Dec. 2020, doi: 10.1016/j.scitotenv.2020.141753.
- [49] A. Smith, B. Johnson, and C. Lee, "A review of ensemble learning and data augmentation models for addressing class imbalance in machine learning," *Expert Systems with Applications*, vol. 215, p. 119456, 2023, doi: 10.1016/j.eswa.2023.119456.
- [50] B. Zazoum, "Solar photovoltaic power prediction using different machine learning methods," *Energy Reports*, vol. 8, Suppl. 1, pp. 19–25, Apr. 2022, doi: 10.1016/j.egyr.2021.11.183.





## Παράρτημα Α – Κώδικας Python για το πειραματικό μέρος

Το παρόν παράρτημα περιλαμβάνει τον αναλυτικό και σχολιασμένο κώδικα Python που υλοποιήθηκε στο πλαίσιο του πειραματικού μέρους της εργασίας. Ο κώδικας έχει οργανωθεί σε ενότητες, σύμφωνα με τα στάδια της ανάλυσης που περιγράφονται στο Κεφάλαιο 5.

Συγκεκριμένα:

- **Παράρτημα Α.1:** Κώδικας καθαρισμού δεδομένων βάσει της μεθοδολογίας DQRs
- **Παράρτημα Α.2:** Εκπαίδευση μοντέλου πρόβλεψης ισχύος
- **Παράρτημα Α.3:** Δημιουργία τεχνητών βλαβών και προεπεξεργασία για ταξινόμηση
- **Παράρτημα Α.4:** Εκπαίδευση μοντέλου πρόβλεψης βλαβών (Logistic Regression)
- **Παράρτημα Α.5:** Εκπαίδευση Μοντέλου Random Forest και XGBoost
- **Παράρτημα Α.6:** Δημιουργία τεχνητών βλαβών με εναλλακτικά ποσοστά (5% και 10%)

Κάθε ενότητα συνοδεύεται από σχόλια στον κώδικα, ώστε να τεκμηριώνεται η λογική και η λειτουργία των επιμέρους βημάτων.

### **A.1 Καθαρισμός και Προεπεξεργασία Δεδομένων με τη Μεθοδολογία DQRs (Python Code)**

Το παρόν παράρτημα περιλαμβάνει τον αναλυτικό κώδικα που χρησιμοποιήθηκε για την εφαρμογή της μεθοδολογίας Data Quality Routines (DQRs), όπως αυτή εφαρμόστηκε στο πλαίσιο της παρούσας εργασίας. Περιλαμβάνονται όλα τα απαραίτητα βήματα καθαρισμού, φιλτραρίσματος, ελέγχου και ομαδοποίησης των δεδομένων, σύμφωνα με τα 8 στάδια της μεθοδολογίας DQRs.

```
import pandas as pd

# ΒΗΜΑ 1 - Φόρτωση δεδομένων και μετατροπή της χρονικής στήλης
column_names = ["time", "P", "G(i)", "H_sun", "T2m", "WS10m", "Int"]
```

```

df =
pd.read_csv("Timeseries_39.364_22.938_SA3_1kWp_crystSi_14_35deg_0deg_2023
_2023.csv",
            skiprows=11,
            skipfooter=15,
            engine="python",
            names=column_names,
            sep=",")

df["time"] = pd.to_datetime(df["time"], format="%Y%m%d:%H%M")

# BHMA 2 - Έλεγχος χρονικής συνέπειας
df["time_diff"] = df["time"].diff()
gaps = df[df["time_diff"] > pd.Timedelta(hours=1)]
duplicates = df[df.duplicated(subset="time", keep=False)]

# BHMA 3 - Φιλτράρισμα ωρών ημέρας (G(i) από 20 έως 1300)
df_filtered = df[(df["G(i)"] >= 20) & (df["G(i)"] <= 1300)].copy()

# BHMA 4 - Έλεγχος φυσικών ορίων & αφαίρεση ακραίων τιμών (Boxplot rule)
limits = {
    "P": (0, 1500),
    "G(i)": (0, 1300),
    "H_sun": (0, 90),
    "T2m": (-20, 60),
    "WS10m": (0, 40)
}
for col, (low, high) in limits.items():
    df_filtered = df_filtered[(df_filtered[col] >= low) &
(df_filtered[col] <= high)]

def remove_outliers_iqr(data, column):
    Q1 = data[column].quantile(0.25)
    Q3 = data[column].quantile(0.75)
    IQR = Q3 - Q1
    lower = Q1 - 1.5 * IQR
    upper = Q3 + 1.5 * IQR
    return data[(data[column] >= lower) & (data[column] <= upper)]

df_filtered = remove_outliers_iqr(df_filtered, "T2m")
df_filtered = remove_outliers_iqr(df_filtered, "WS10m")

# Αποθήκευση του καθαρισμένου dataset (προαιρετικό)
df_filtered.to_excel("cleaned_data_after_step4.xlsx", index=False)

# BHMA 5 - Έλεγχος για απουσίες (NaN / NaT)
missing_counts = df_filtered.isna().sum()
missing_percent = (missing_counts / len(df_filtered)) * 100
missing_report = pd.DataFrame({
    "Missing Values": missing_counts,
    "Missing %": missing_percent.round(2)
})
rows_with_multiple_nans = df_filtered[df_filtered.isna().sum(axis=1) > 1]

```

```

if "time_diff" not in df_filtered.columns:
    df_filtered["time"] = pd.to_datetime(df_filtered["time"])
    df_filtered["time_diff"] = df_filtered["time"].diff()

# BHMA 6 - Επιβεβαίωση εγκυρότητας βασικών στηλών
essential_cols = ["time", "P", "G(i)", "H_sun", "T2m", "WS10m", "Int"]
print("Missing values στις βασικές στήλες:
")
print(df_filtered[essential_cols].isna().sum())

# BHMA 7 - Ομαδοποίηση σε μηνιαία βάση
df_filtered["time"] = pd.to_datetime(df_filtered["time"])
df_filtered.set_index("time", inplace=True)
columns_to_aggregate = ["P", "G(i)", "H_sun", "T2m", "WS10m", "Int"]
monthly_data = df_filtered[columns_to_aggregate].resample("M").mean()
monthly_data.reset_index(inplace=True)
monthly_data.to_excel("monthly_data_after_step7.xlsx", index=False)

# BHMA 8 - Περιγραφική στατιστική ανάλυση (ωριαία και μηνιαία)
hourly_stats = df_filtered[columns_to_aggregate[:-1]].describe().round(2)
hourly_stats.to_excel("hourly_stats_output.xlsx")

monthly_stats = monthly_data[columns_to_aggregate[:-1]].describe().round(2)
monthly_stats.to_excel("monthly_stats_output.xlsx")

```

## A.2 Κώδικας Python για την Εκπαίδευση Μοντέλου Πρόβλεψης Ισχύος (Βήμα 1)

Το παρόν παράρτημα περιλαμβάνει τον πλήρη σχολιασμένο κώδικα Python που χρησιμοποιήθηκε για την ανάπτυξη και αξιολόγηση του μοντέλου γραμμικής παλινδρόμησης (Linear Regression), στο πλαίσιο του Βήματος 1 της παρούσας εργασίας. Σκοπός της διαδικασίας ήταν η πρόβλεψη της παραγόμενης ηλεκτρικής ισχύος (P) ενός φωτοβολταϊκού συστήματος βάσει περιβαλλοντικών μεταβλητών, με στόχο τη δημιουργία ενός αξιόπιστου μοντέλου αναφοράς (reference model).

```

# Φόρτωση απαραίτητων βιβλιοθηκών
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.linear_model import LinearRegression

```

```

from sklearn.model_selection import train_test_split
from sklearn.metrics import r2_score, mean_absolute_percentage_error

# Φόρτιση του καθαρισμένου dataset
df = pd.read_excel("cleaned_data_after_step4.xlsx")

# Επιλογή μεταβλητών εισόδου και εξόδου
X = df[["G(i)", "H_sun", "T2m", "WS10m"]] # Ανεξάρτητες μεταβλητές
y = df["P"] # Εξαρτημένη μεταβλητή (ισχύς)

# Διαχωρισμός σε σύνολο εκπαίδευσης (80%) και δοκιμής (20%)
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2,
random_state=42)

# Δημιουργία και εκπαίδευση μοντέλου γραμμικής παλινδρόμησης
model = LinearRegression()
model.fit(X_train, y_train)

# Πρόβλεψη ισχύος στο test set
y_pred = model.predict(X_test)

# Υπολογισμός στατιστικών δεικτών απόδοσης
r2 = r2_score(y_test, y_pred)
mape = mean_absolute_percentage_error(y_test, y_pred) * 100

# Εμφάνιση αποτελεσμάτων
print(f" Μέσο Απόλυτο Σχετικό Σφάλμα (MAPE): {mape:.2f}%")
print(f" Συντελεστής Προσδιορισμού (R²): {r2:.4f}")

# Γράφημα: Πραγματική vs Προβλεπόμενη Ισχύς
plt.figure(figsize=(10, 6))
plt.scatter(y_test, y_pred, alpha=0.5, label="Προβλέψεις")
plt.plot([y_test.min(), y_test.max()], [y_test.min(), y_test.max()], 'r--',
label="Ιδανική Πρόβλεψη")
plt.xlabel("Πραγματική Ισχύς P (W)")
plt.ylabel("Προβλεπόμενη Ισχύς P_pred (W)")
plt.title("Σύγκριση Πραγματικής και Προβλεπόμενης Ισχύος")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()

```

```
# Εμφάνιση γραμμικής εξίσωσης πρόβλεψης
print("\n Γραμμική Σχέση Μοντέλου:")
for feature, coef in zip(X.columns, model.coef_):
    print(f"{feature}: {coef:.4f}")
print(f"Σταθερός Όρος (Intercept): {model.intercept_:.4f}")
```

### A.3 Δημιουργία τεχνητών βλαβών και προεπεξεργασία για ταξινόμηση

Το παρακάτω script υλοποιήθηκε σε γλώσσα Python και χρησιμοποιεί τις βιβλιοθήκες NumPy και Pandas για τη δημιουργία ενός σεναρίου τεχνητών βλαβών. Η διαδικασία βασίστηκε στην τυχαία επιλογή του 8% των παρατηρήσεων του dataset, στις οποίες η τιμή της παραγόμενης ισχύος μειώθηκε κατά 70%, υποδηλώνοντας πιθανή δυσλειτουργία. Οι αντίστοιχες γραμμές χαρακτηρίστηκαν με ετικέτα `fault_label = 1`, ενώ οι υπόλοιπες διατηρήθηκαν ως `fault_label = 0`, ώστε να μπορούν να χρησιμοποιηθούν στη συνέχεια για την εκπαίδευση μοντέλου ταξινόμησης. Η τυχαία επιλογή έγινε με χρήση σταθερού seed (42) για λόγους επαναληψιμότητας.

```
import pandas as pd
import numpy as np

# 1. Φόρτωση του αρχείου με τα καθαρισμένα δεδομένα
df = pd.read_excel("cleaned_data_after_step4.xlsx")

# 2. Δημιουργία αντιγράφου για να μην τροποποιηθεί το αρχικό dataset
df_faults = df.copy()

# 3. Δημιουργία νέας στήλης με όνομα fault_label, με αρχική τιμή 0
(φυσιολογική λειτουργία)
df_faults["fault_label"] = 0

# 4. Υπολογισμός του πλήθους των παρατηρήσεων που θα αλλοιωθούν (8% του συνόλου)
n_faults = int(len(df_faults) * 0.08)

# 5. Επιλογή τυχαίων γραμμών για δημιουργία τεχνητών βλαβών, με χρήση σταθερού seed
np.random.seed(42)
fault_indices = np.random.choice(df_faults.index, size=n_faults,
replace=False)

# 6. Μείωση της ισχύος P κατά 70% στις επιλεγμένες γραμμές
```

```

df_faults.loc[fault_indices, "P"] *= 0.3

# 7. Αντικατάσταση της τιμής στη στήλη fault_label με 1 για τις
αλλοιωμένες γραμμές
df_faults.loc[fault_indices, "fault_label"] = 1

# 8. Αποθήκευση του νέου αρχείου σε Excel για χρήση σε επόμενα βήματα
df_faults.to_excel("data_with_simulated_faults.xlsx", index=False)

# 9. Εμφάνιση συνοπτικής πληροφορίας για έλεγχο ορθότητας
print("Ολοκληρώθηκε η εισαγωγή τεχνητών βλαβών.")
print(f"Κανονικά σημεία: {(df_faults['fault_label'] == 0).sum()}")
print(f"Τεχνητές βλάβες: {(df_faults['fault_label'] == 1).sum()}")

```

## A.4 Εκπαίδευση Μοντέλου Λογιστικής Παλινδρόμησης (Logistic Regression)

Ο παρακάτω κώδικας υλοποιεί τη διαδικασία εκπαίδευσης του μοντέλου Λογιστικής Παλινδρόμησης, το οποίο χρησιμοποιήθηκε για την πρόβλεψη πιθανών βλαβών στο φωτοβολταϊκό σύστημα. Περιλαμβάνει τα βήματα φόρτωσης των δεδομένων, επιλογής μεταβλητών, εξισορρόπησης των κατηγοριών μέσω της τεχνικής SMOTE, εκπαίδευσης του μοντέλου, πρόβλεψης και αξιολόγησης των αποτελεσμάτων με χρήση πίνακα σύγχυσης και δεικτών απόδοσης.

```

import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LogisticRegression
from sklearn.metrics import classification_report, confusion_matrix,
ConfusionMatrixDisplay
from imblearn.over_sampling import SMOTE
import matplotlib.pyplot as plt

# Φόρτωση δεδομένων
df = pd.read_excel("data_with_simulated_faults.xlsx")

# Επιλογή χαρακτηριστικών και ετικέτας
X = df[["G(i)", "H_sun", "T2m", "WS10m"]]
y = df["fault_label"]

# Διαχωρισμός σε training και test set με αναλογίες κατηγοριών
X_train, X_test, y_train, y_test = train_test_split(
    X, y, test_size=0.2, random_state=42, stratify=y
)

# Εξισορρόπηση κατηγοριών με SMOTE (τεχνητά δείγματα)
smote = SMOTE(random_state=42)

```

```

X_train_resampled, y_train_resampled = smote.fit_resample(X_train,
y_train)

# Εκπαίδευση μοντέλου λογιστικής παλινδρόμησης
model = LogisticRegression(max_iter=1000, random_state=42)
model.fit(X_train_resampled, y_train_resampled)

# Προβλέψεις στο test set
y_pred = model.predict(X_test)

# Αξιολόγηση - Αναφορά & Πίνακας Σύγχυσης
print("Classification Report:\n")
print(classification_report(y_test, y_pred, target_names=["Κανονικό",
"Βλάβη"]))

conf_matrix = confusion_matrix(y_test, y_pred)
disp = ConfusionMatrixDisplay(conf_matrix, display_labels=["Κανονικό",
"Βλάβη"])
disp.plot(cmap="Blues")
plt.title("Πίνακας Σύγχυσης (με SMOTE)")
plt.show()

```

## A.5 Εκπαίδευση Μοντέλου Random Forest και XGBoost

Παρακάτω παρατίθεται ο αναλυτικός κώδικας που χρησιμοποιήθηκε για την εκπαίδευση και αξιολόγηση των μοντέλων Random Forest και XGBoost, στο πλαίσιο της συγκριτικής δοκιμής ταξινομητών για την πρόβλεψη τεχνητών βλαβών σε φωτοβολταϊκά δεδομένα. Η υλοποίηση πραγματοποιήθηκε σε περιβάλλον Python, με χρήση των βιβλιοθηκών Scikit-learn, Imbalanced-learn και XGBoost.

### Random Forest:

```

import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import classification_report, confusion_matrix,
ConfusionMatrixDisplay
from imblearn.over_sampling import SMOTE
import matplotlib.pyplot as plt

# 1. Φόρτωση δεδομένων
df = pd.read_excel("data_with_simulated_faults.xlsx")

# 2. Επιλογή χαρακτηριστικών και ετικέτας
X = df[["G(i)", "H_sun", "T2m", "WS10m"]]
y = df["fault_label"]

```



```

# 3. Διαχωρισμός σε training και test set με αναλογίες κατηγοριών
X_train, X_test, y_train, y_test = train_test_split(
    X, y, test_size=0.2, random_state=42, stratify=y
)

# 4. Εξισορρόπηση κατηγοριών με SMOTE
smote = SMOTE(random_state=42)
X_train_resampled, y_train_resampled = smote.fit_resample(X_train,
y_train)

# 5. Εκπαίδευση Random Forest
rf_model = RandomForestClassifier(n_estimators=100, random_state=42)
rf_model.fit(X_train_resampled, y_train_resampled)

# 6. Προβλέψεις
y_pred_rf = rf_model.predict(X_test)

# 7. Αξιολόγηση
print("Classification Report:\n")
print(classification_report(y_test, y_pred_rf, target_names=["Κανονικό",
"Βλάβη"]))
conf_matrix = confusion_matrix(y_test, y_pred_rf)
disp = ConfusionMatrixDisplay(conf_matrix, display_labels=["Κανονικό",
"Βλάβη"])
disp.plot(cmap="Blues")
plt.title("Πίνακας Σύγχυσης - Random Forest")
plt.show()

```

### **XGBoost:**

```

import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.metrics import classification_report, confusion_matrix,
ConfusionMatrixDisplay
from imblearn.over_sampling import SMOTE
from xgboost import XGBClassifier
import matplotlib.pyplot as plt

# 1. Φόρτωση δεδομένων
df = pd.read_excel("data_with_simulated_faults.xlsx")

```

```

# 2. Επιλογή χαρακτηριστικών εισόδου και ετικέτας στόχου
X = df[["G(i)", "H_sun", "T2m", "WS10m"]]
y = df["fault_label"]

# 3. Διαχωρισμός σε training και test set με διατήρηση της αναλογίας
(stratify)
X_train, X_test, y_train, y_test = train_test_split(
    X, y, test_size=0.2, random_state=42, stratify=y
)

# 4. Εξισορρόπηση training set με SMOTE
smote = SMOTE(random_state=42)
X_train_resampled, y_train_resampled = smote.fit_resample(X_train,
y_train)

# 5. Δημιουργία και εκπαίδευση μοντέλου XGBoost
model = XGBClassifier(random_state=42, use_label_encoder=False,
eval_metric='logloss')
model.fit(X_train_resampled, y_train_resampled)

# 6. Πρόβλεψη στο test set
y_pred = model.predict(X_test)

# 7. Αξιολόγηση απόδοσης
print("Classification Report:\n")
print(classification_report(y_test, y_pred, target_names=["Κανονικό",
"Βλάβη"]))

# 8. Πίνακας Σύγχυσης
conf_matrix = confusion_matrix(y_test, y_pred)
disp = ConfusionMatrixDisplay(conf_matrix, display_labels=["Κανονικό",
"Βλάβη"])
disp.plot(cmap="Blues")
plt.title("Πίνακας Σύγχυσης - XGBoost (με SMOTE)")
plt.show()

```

## A.6 Δημιουργία Τεχνητών Βλαβών με Εναλλακτικά Ποσοστά (5% και 10%)

Στο παρόν παράρτημα παρατίθεται ο κώδικας Python που χρησιμοποιήθηκε για τη δημιουργία νέων σεναρίων τεχνητών βλαβών, με ποσοστά 5% και 10% αντί του αρχικού 8%. Η διαδικασία υλοποιείται με την ίδια μεθοδολογία (μείωση της ισχύος κατά 70% σε τυχαία σημεία του συνόλου δεδομένων), με σκοπό τη διερεύνηση του τρόπου με τον οποίο η αναλογία των κατηγοριών επηρεάζει την απόδοση των μοντέλων ταξινόμησης.

### # Δημιουργία τεχνητών βλαβών - 5%

```
import pandas as pd
import numpy as np

df = pd.read_excel("cleaned_data_after_step4.xlsx")
df_faults_5 = df.copy()
df_faults_5["fault_label"] = 0

n_faults = int(len(df_faults_5) * 0.05)
np.random.seed(42)
fault_indices = np.random.choice(df_faults_5.index, size=n_faults,
replace=False)

df_faults_5.loc[fault_indices, "P"] *= 0.3
df_faults_5.loc[fault_indices, "fault_label"] = 1

df_faults_5.to_excel("data_with_simulated_faults_5.xlsx", index=False)

print("Ολοκληρώθηκε η εισαγωγή τεχνητών βλαβών (5%).")
print(f"Κανονικά σημεία: {(df_faults_5['fault_label'] == 0).sum()}")
print(f"Τεχνητές βλάβες: {(df_faults_5['fault_label'] == 1).sum()}")
```

### # Δημιουργία τεχνητών βλαβών - 10%

```
import pandas as pd
import numpy as np

df = pd.read_excel("cleaned_data_after_step4.xlsx")
df_faults_10 = df.copy()
df_faults_10["fault_label"] = 0

n_faults = int(len(df_faults_10) * 0.10)
```

```

np.random.seed(42)
fault_indices = np.random.choice(df_faults_10.index, size=n_faults,
replace=False)

df_faults_10.loc[fault_indices, "P"] *= 0.3
df_faults_10.loc[fault_indices, "fault_label"] = 1

df_faults_10.to_excel("data_with_simulated_faults_10.xlsx", index=False)

print("Ολοκληρώθηκε η εισαγωγή τεχνητών βλαβών (10%).")
print(f"Κανονικά σημεία: {(df_faults_10['fault_label'] == 0).sum()}")
print(f"Τεχνητές βλάβες: {(df_faults_10['fault_label'] == 1).sum()}")

```