

**ΕΛΛΗΝΙΚΟ ΑΝΟΙΚΤΟ ΠΑΝΕΠΙΣΤΗΜΙΟ**

**Σχολή Θετικών Επιστημών & Τεχνολογίας**

Συστήματα Κινητού και Διάχυτου Υπολογισμού

**Διπλωματική Εργασία**

**Πλατφόρμα Προγνωστικής Συντήρησης Βιομηχανικών  
Συμπιεστών Φυσικού Αερίου με Τεχνολογίες Industrial IoT και  
Μηχανική Μάθηση**

Predictive Maintenance Platform for Industrial Natural Gas Compressors Using  
Industrial IoT Technologies and Machine Learning

**Γρηγόρης Τσαγρής**

Επιβλέπων καθηγητής: Πέτρος Νικοπολιτίδης



Αθήνα, Σεπτέμβριος 2026

Η παρούσα εργασία αποτελεί πνευματική ιδιοκτησία του φοιτητή («συγγραφέας/δημιουργός») που την εκπόνησε. Στο πλαίσιο της πολιτικής ανοικτής πρόσβασης ο συγγραφέας/δημιουργός εκχωρεί στο ΕΑΠ, μη αποκλειστική άδεια χρήσης του δικαιώματος αναπαραγωγής, προσαρμογής, δημόσιου δανεισμού, παρουσίασης στο κοινό και ψηφιακής διάχυσής τους διεθνώς, σε ηλεκτρονική μορφή και σε οποιοδήποτε μέσο, για διδακτικούς και ερευνητικούς σκοπούς, άνευ ανταλλάγματος και για όλο το χρόνο διάρκειας των δικαιωμάτων πνευματικής ιδιοκτησίας. Η ανοικτή πρόσβαση στο πλήρες κείμενο για μελέτη και ανάγνωση δεν σημαίνει καθ' οιονδήποτε τρόπο παραχώρηση δικαιωμάτων διανοητικής ιδιοκτησίας του συγγραφέα/δημιουργού ούτε επιτρέπει την αναπαραγωγή, αναδημοσίευση, αντιγραφή, αποθήκευση, πώληση, εμπορική χρήση, μετάδοση, διανομή, έκδοση, εκτέλεση, «μεταφόρτωση» (downloading), «ανάρτηση» (uploading), μετάφραση, τροποποίηση με οποιονδήποτε τρόπο, τμηματικά ή περιληπτικά της εργασίας, χωρίς τη ρητή προηγούμενη έγγραφη συναίνεση του συγγραφέα/δημιουργού. Ο συγγραφέας/δημιουργός διατηρεί το σύνολο των ηθικών και περιουσιακών του δικαιωμάτων.



**Πλατφόρμα Προγνωστικής Συντήρησης Βιομηχανικών Συμπιεστών  
Φυσικού Αερίου με Τεχνολογίες Industrial IoT και Μηχανική Μάθηση**

**Γρηγόρης Τσαγρής**

**Επιτροπή Επίβλεψης Διπλωματικής Εργασίας**

Επιβλέπων Καθηγητής:

Πέτρος Νικοπολιτίδης

Καθηγητής ΑΠΘ

Συν-Επιβλέπων Καθηγητής:

Νικόλαος Σκλάβος

Καθηγητής Πανεπιστημίου Πατρών

Αθήνα, Σεπτέμβριος 2026

## Ευχαριστίες

Θα ήθελα να ευχαριστήσω το Ελληνικό Ανοικτό Πανεπιστήμιο και το σύνολο των καθηγητών του Προγράμματος Μεταπτυχιακών Σπουδών «Συστήματα Κινητού και Διάχυτου Υπολογισμού» για τις γνώσεις και την υποστήριξη που μου προσέφεραν καθ' όλη τη διάρκεια των σπουδών μου.

Ιδιαίτερα θα ήθελα να ευχαριστήσω τον Κοσμήτορα της Σχολής Θετικών Επιστημών, κ. Καμέα, για τη συμβολή του στην ποιότητα και την οργάνωση του προγράμματος σπουδών.

Θερμές ευχαριστίες οφείλω στον επιβλέποντα καθηγητή μου, κ. Πέτρο Νικοπολιτίδη, για την πολύτιμη καθοδήγηση, τις εύστοχες παρατηρήσεις και τη συνεχή υποστήριξή του κατά την εκπόνηση της παρούσας διπλωματικής εργασίας.

Τέλος, θα ήθελα να ευχαριστήσω τους γονείς μου και τους φίλους μου για την αμέριστη υπομονή, κατανόηση και συμπαράσταση που μου προσέφεραν καθ' όλη τη διάρκεια αυτής της προσπάθειας.

## Περίληψη

Η παρούσα διπλωματική εργασία εστιάζει στον σχεδιασμό και την υλοποίηση μιας ολοκληρωμένης πλατφόρμας προγνωστικής συντήρησης (Predictive Maintenance) για βιομηχανικούς συμπιεστές φυσικού αερίου, αξιοποιώντας τεχνολογίες Industrial Internet of Things (IIoT) και μεθόδους μηχανικής μάθησης.

Η σύγχρονη βιομηχανία στρέφεται ολοένα και περισσότερο από τις παραδοσιακές πρακτικές διορθωτικής και προληπτικής συντήρησης σε στρατηγικές που βασίζονται στη συνεχή παρακολούθηση της πραγματικής κατάστασης του εξοπλισμού. Στο πλαίσιο αυτό, αναπτύχθηκε μια αρχιτεκτονική η οποία συνδυάζει ασύρματους αισθητηριακούς κόμβους, δίκτυο επικοινωνίας LoRaWAN, πρωτόκολλο MQTT, επεξεργασία ροής δεδομένων μέσω Node-RED, αποθήκευση χρονοσειρών στην InfluxDB και οπτικοποίηση σε πραγματικό χρόνο μέσω Grafana, με τη συνολική υποδομή να υλοποιείται με containerized (Docker) υπηρεσίες.

Για την πρόβλεψη κρίσιμων λειτουργικών παραμέτρων -θερμοκρασίας εξόδου, πίεσης κατάθλιψης και κραδασμών σε τρεις άξονες- αναπτύχθηκαν ανεξάρτητα μοντέλα Ridge Regression για δύο βιομηχανικούς συμπιεστές, με χρήση τεχνικών feature engineering σε δεδομένα χρονοσειρών. Τα μοντέλα εκπαιδεύτηκαν με ιστορικά δεδομένα του 2021, ενώ τα δεδομένα του 2022 χρησιμοποιήθηκαν για την προσομοίωση της online λειτουργίας του συστήματος και τον υπολογισμό residuals, ώστε να καταστεί δυνατή η έγκαιρη ανίχνευση αποκλίσεων από την αναμενόμενη συμπεριφορά του εξοπλισμού.

Η αξιολόγηση των μοντέλων, με βάση τις μετρικές MAE, RMSE και  $R^2$ , έδειξε ιδιαίτερα υψηλή προβλεπτική ακρίβεια και για τους δύο συμπιεστές. Στον Compressor #1 ο συντελεστής προσδιορισμού κυμάνθηκε μεταξύ 0,9802 και 0,9926, ενώ στον Compressor #2 όλες οι μεταβλητές ξεπέρασαν  $R^2$  ίσο με 0,999, με τη μεταβλητή HPC Forward X Vibration να καταγράφει τη βέλτιστη επίδοση ( $R^2=0,9999$ ). Τα αποτελέσματα επιβεβαιώνουν την καταλληλότητα της Ridge Regression σε συνδυασμό με κατάλληλη μηχανική χαρακτηριστικών για την περιγραφή της συμπεριφοράς βιομηχανικών χρονοσειρών.

Η εργασία καταδεικνύει ότι ο συνδυασμός ανοικτών τεχνολογιών IIoT με τεχνικές μηχανικής μάθησης μπορεί να αποτελέσει μια οικονομικά αποδοτική και τεχνικά εφικτή λύση προγνωστικής συντήρησης, με άμεση δυνατότητα εφαρμογής σε πραγματικές ενεργειακές και βιομηχανικές εγκαταστάσεις.

## Λέξεις – Κλειδιά

προγνωστική συντήρηση, Industrial IoT, LoRaWAN, MQTT, InfluxDB, Grafana,  
Ridge Regression, μηχανική μάθηση, βιομηχανικοί συμπιεστές

## Predictive Maintenance Platform for Industrial Natural Gas Compressors Using Industrial IoT Technologies and Machine Learning

Grigoris Tsagris

### Abstract

This thesis focuses on the design and implementation of an integrated Predictive Maintenance platform for industrial natural gas compressors, leveraging Industrial Internet of Things (IIoT) technologies and machine learning methods.

Modern industry is increasingly shifting from traditional corrective and preventive maintenance practices towards strategies based on continuous monitoring of the actual condition of equipment. In this context, an architecture was developed combining wireless sensor nodes, a LoRaWAN communication network, the MQTT protocol, data-stream processing through Node-RED, time-series storage in InfluxDB, and real-time visualization through Grafana, with the overall infrastructure implemented as containerized (Docker) services.

To predict critical operating parameters - outlet temperature, discharge pressure, and vibration along three axes - independent Ridge Regression models were developed for two industrial compressors, using feature engineering techniques on time-series data. The models were trained on historical 2021 data, while 2022 data was used to simulate the platform's online operation and compute residuals, enabling early detection of deviations from expected equipment behaviour.

Model evaluation, based on MAE, RMSE and  $R^2$  metrics, showed particularly high predictive accuracy for both compressors. For Compressor #1, the coefficient of determination ranged between 0.9802 and 0.9926, while for Compressor #2 all variables exceeded an  $R^2$  of 0.999, with the HPC Forward X Vibration variable achieving the best performance ( $R^2=0.9999$ ). The results confirm the suitability of Ridge Regression, combined with appropriate feature engineering, for describing the behaviour of industrial time series.

The thesis demonstrates that combining open-source IIoT technologies with machine learning techniques can constitute a cost-effective and technically feasible predictive maintenance solution, with direct applicability to real energy and industrial facilities.

## Keywords

predictive maintenance, Industrial IoT, LoRaWAN, MQTT, InfluxDB, Grafana,  
Ridge Regression, machine learning, industrial compressors

## Πίνακας Περιεχομένων

|                                                                                                                                        |      |
|----------------------------------------------------------------------------------------------------------------------------------------|------|
| Ευχαριστίες .....                                                                                                                      | 4    |
| Περίληψη .....                                                                                                                         | iv   |
| Λέξεις – Κλειδιά.....                                                                                                                  | v    |
| Predictive Maintenance Platform for Industrial Natural Gas Compressors Using<br>Industrial IoT Technologies and Machine Learning ..... | vi   |
| Abstract .....                                                                                                                         | vi   |
| Keywords .....                                                                                                                         | vii  |
| Πίνακας Περιεχομένων.....                                                                                                              | viii |
| Κατάλογος Εικόνων / Σχημάτων .....                                                                                                     | xi   |
| Κατάλογος Πινάκων.....                                                                                                                 | xiii |
| Κατάλογος Συντμήσεων .....                                                                                                             | xiv  |
| 1. Εισαγωγή .....                                                                                                                      | 1    |
| 1.1 Βιομηχανική Συντήρηση στις Ενεργειακές Υποδομές .....                                                                              | 1    |
| 1.2 Η Έννοια της προγνωστικής Συντήρησης .....                                                                                         | 3    |
| 1.3 Στόχοι της Διπλωματικής Εργασίας.....                                                                                              | 5    |
| 1.4 Δομή της Διπλωματικής Εργασίας .....                                                                                               | 7    |
| 1. Θεωρητικό Υπόβαθρο .....                                                                                                            | 9    |
| 2. Θεωρητικό Υπόβαθρο και Τεχνολογίες Υλοποίησης .....                                                                                 | 11   |
| 2.1 Industrial Internet of Things (IIoT).....                                                                                          | 11   |
| 2.2 Τεχνολογία LoRa και LoRaWAN .....                                                                                                  | 13   |
| 2.3 Πρωτόκολλο MQTT .....                                                                                                              | 16   |
| 2.4 Βάσεις Δεδομένων Χρονοσειρών .....                                                                                                 | 18   |
| 2.5 Προγνωστική Συντήρηση και Μηχανική Μάθηση.....                                                                                     | 20   |
| 2.6 Ridge Regression .....                                                                                                             | 21   |
| 2.7 Feature Engineering σε Χρονοσειρές.....                                                                                            | 23   |
| 3. Αρχιτεκτονική και Υλοποίηση του Συστήματος .....                                                                                    | 25   |
| 3.1 Συνολική Αρχιτεκτονική Συστήματος .....                                                                                            | 25   |
| 3.2 Αισθητηριακοί Κόμβοι.....                                                                                                          | 27   |

|       |                                                              |    |
|-------|--------------------------------------------------------------|----|
| 3.3   | Πύλη Επικοινωνίας LoRaWAN .....                              | 30 |
| 3.4   | ChirpStack LoRaWAN Server .....                              | 32 |
| 3.5   | Επίπεδο Επικοινωνίας MQTT .....                              | 34 |
| 3.6   | Επεξεργασία Δεδομένων με Node-RED .....                      | 35 |
| 3.7   | Αποθήκευση Δεδομένων με InfluxDB .....                       | 36 |
| 3.8   | Οπτικοποίηση Δεδομένων με Grafana .....                      | 37 |
| 3.9   | Containerized Υποδομή και Docker .....                       | 39 |
| 4.    | Διαχείριση και Επεξεργασία Δεδομένων .....                   | 40 |
| 4.1   | Δεδομένα Βιομηχανικού Συμπιεστή .....                        | 40 |
| 4.2   | Προεπεξεργασία Δεδομένων και Feature Engineering .....       | 41 |
| 4.3   | Εκπαίδευση Μοντέλων Πρόβλεψης .....                          | 43 |
| 4.4   | Υποδομή Τηλεμετρίας LoRaWAN .....                            | 45 |
| 4.5   | Συλλογή Δεδομένων μέσω ChirpStack και MQTT .....             | 46 |
| 4.6   | Επεξεργασία Δεδομένων στο Node-RED .....                     | 47 |
| 4.7   | Υλοποίηση Predictive Service και Υπολογισμός Residuals ..... | 48 |
| 4.8   | Αποθήκευση και Οπτικοποίηση Δεδομένων .....                  | 50 |
| 5.    | Αποτελέσματα και Αξιολόγηση Μοντέλων Πρόβλεψης .....         | 52 |
| 5.1   | Μεθοδολογία Αξιολόγησης .....                                | 52 |
| 5.2   | Αποτελέσματα Compressor #1 .....                             | 53 |
| 5.2.1 | Outlet Temperature .....                                     | 53 |
| 5.2.2 | Discharge Pressure .....                                     | 53 |
| 5.2.3 | HPC Aft X Vibration .....                                    | 53 |
| 5.2.4 | HPC Aft Y Vibration .....                                    | 54 |
| 5.2.5 | HPC Forward X Vibration .....                                | 54 |
| 5.3   | Αποτελέσματα Compressor #2 .....                             | 54 |
| 5.3.1 | Outlet Temperature .....                                     | 55 |
| 5.3.2 | Discharge Pressure .....                                     | 55 |
| 5.3.3 | HPC Aft X Vibration .....                                    | 55 |
| 5.3.4 | HPC Aft Y Vibration .....                                    | 55 |
| 5.3.5 | HPC Forward X Vibration .....                                | 55 |
| 5.4   | Συνολική Συζήτηση Αποτελεσμάτων .....                        | 56 |

|     |                                                                      |    |
|-----|----------------------------------------------------------------------|----|
| 6.  | Υλοποίηση και Λειτουργία της Πλατφόρμας Προγνωστικής Συντήρησης .... | 57 |
| 6.1 | Υποδομή LoRaWAN και Συλλογή Δεδομένων .....                          | 57 |
| 6.2 | Ροή Δεδομένων στην Πλατφόρμα.....                                    | 59 |
| 6.3 | Επεξεργασία Δεδομένων και Πρόβλεψη.....                              | 59 |
| 6.4 | Αποθήκευση Δεδομένων στην InfluxDB .....                             | 61 |
| 6.5 | Οπτικοποίηση και Παρακολούθηση μέσω Grafana.....                     | 61 |
| 6.6 | Παρακολούθηση Compressor #1.....                                     | 62 |
| 6.7 | Παρακολούθηση Compressor #2.....                                     | 66 |
| 6.8 | Συνολική Λειτουργία της Πλατφόρμας .....                             | 66 |
| 7.  | Συζήτηση Αποτελεσμάτων και Τεχνικές Προκλήσεις .....                 | 67 |
| 7.1 | Περιορισμοί των Διαθέσιμων Δεδομένων .....                           | 67 |
| 7.2 | Περιορισμοί της Προσομοίωσης Πραγματικού Χρόνου .....                | 68 |
| 7.3 | Τεχνικές Προκλήσεις Υλοποίησης.....                                  | 68 |
| 7.4 | Αξιολόγηση της Προτεινόμενης Αρχιτεκτονικής.....                     | 69 |
| 7.5 | Δυνατότητα Βιομηχανικής Εφαρμογής.....                               | 70 |
| 8.  | Συμπεράσματα και Μελλοντικές Επεκτάσεις.....                         | 70 |
| 8.1 | Συμπεράσματα .....                                                   | 70 |
| 8.2 | Συνεισφορά της Εργασίας .....                                        | 71 |
| 8.3 | Μελλοντικές Επεκτάσεις .....                                         | 72 |
| 8.4 | Τελική Αποτίμηση .....                                               | 73 |
|     | Κατάλογος Βιβλιογραφίας .....                                        | 75 |

## Κατάλογος Εικόνων / Σχημάτων

|                                                                                                                                       |    |
|---------------------------------------------------------------------------------------------------------------------------------------|----|
| Εικόνα 1 - Γενική μεθοδολογία προσέγγισης προβλημάτων σε ψηφιοποιημένη βιομηχανία. ....                                               | 2  |
| Εικόνα 2 - Γενική αρχιτεκτονική συστήματος προγνωστικής συντήρησης. ....                                                              | 4  |
| Εικόνα 3 - Ενδεικτική εικόνα βιομηχανικού συμπιεστή. ....                                                                             | 9  |
| Εικόνα 4 - Ενδεικτική αρχιτεκτονική Industrial IoT συστήματος. ....                                                                   | 13 |
| Εικόνα 5 - Βασική αρχιτεκτονική δικτύου LoRaWAN. ....                                                                                 | 15 |
| Εικόνα 6 - Publish/Subscribe αρχιτεκτονική MQTT. ....                                                                                 | 17 |
| Εικόνα 7 - Γενική διαδικασία ανάπτυξης μοντέλου μηχανικής μάθησης. ....                                                               | 21 |
| Εικόνα 8 - Αρχιτεκτονική Συστήματος Predictive Maintenance ....                                                                       | 27 |
| Εικόνα 9 - Αισθητηριακός κόμβος LoRaWAN βασισμένος σε Raspberry Pi Pico RP2040 και SX1262. ....                                       | 27 |
| Εικόνα 10 - LoRaWAN gateway της εφαρμογής. ....                                                                                       | 30 |
| Εικόνα 11 - Περιβάλλον διαχείρισης ChirpStack. ....                                                                                   | 33 |
| Εικόνα 12 - Flow επεξεργασίας δεδομένων στο Node-RED. ....                                                                            | 35 |
| Εικόνα 13 - Dashboard παρακολούθησης λειτουργικών δεδομένων στο Grafana. ....                                                         | 38 |
| Εικόνα 14 - Παράδειγμα δημιουργίας χαρακτηριστικών χρονικής καθυστέρησης και στατιστικών χαρακτηριστικών από ιστορικές μετρήσεις .... | 42 |
| Εικόνα 15 - Διαδικασία προεπεξεργασίας και δημιουργίας χαρακτηριστικών για την ανάπτυξη των μοντέλων πρόσβησης. ....                  | 43 |
| Εικόνα 16 - Αρχιτεκτονική LoRaWAN δικτύου ....                                                                                        | 46 |
| Εικόνα 17 - Ροή δεδομένων από κόμβο αισθητήρων έως node-red ....                                                                      | 47 |
| Εικόνα 18 - Dashboard παρακολούθησης πραγματικών και προβλεπόμενων μεταβλητών του Compressor #1. ....                                 | 54 |
| Εικόνα 19 - Dashboard παρακολούθησης πραγματικών και προβλεπόμενων μεταβλητών του Compressor #2. ....                                 | 56 |
| Εικόνα 20 - Καταχωρημένες LoRaWAN συσκευές στην πλατφόρμα ChirpStack. ....                                                            | 58 |
| Εικόνα 21 - Data packages που μεταδίδονται μέσω LoRaWAN συσκευής στο ChirpStack. ....                                                 | 58 |

|                                                                                                                                |    |
|--------------------------------------------------------------------------------------------------------------------------------|----|
| Εικόνα 22 - Συνολική αρχιτεκτονική της πλατφόρμας προγνωστικής συντήρησης.<br>.....                                            | 59 |
| Εικόνα 23 - Συνολική ροή επεξεργασίας δεδομένων στο Node-RED.....                                                              | 60 |
| Εικόνα 24 - Τμήμα της ροής Node-RED που υλοποιεί την επικοινωνία με το<br>Predictive Service και τον υπολογισμό residuals..... | 61 |
| Εικόνα 25 - Χρονοσειρές δεδομένων που αποθηκεύονται στην InfluxDB.....                                                         | 61 |
| Εικόνα 26 - Κεντρικό dashboard παρακολούθησης της πλατφόρμας. ....                                                             | 62 |
| Εικόνα 27 - Σύγκριση πραγματικών και προβλεπόμενων τιμών θερμοκρασίας<br>εξόδου για τον Compressor #1.....                     | 63 |
| Εικόνα 28 - Σύγκριση πραγματικών και προβλεπόμενων τιμών πίεσης κατάθλιψης<br>για τον Compressor #1. ....                      | 63 |
| Εικόνα 29 - Παρακολούθηση residuals για τον Compressor #1.....                                                                 | 66 |
| Εικόνα 30 - Dashboard παρακολούθησης του Compressor #2. ....                                                                   | 66 |

## Κατάλογος Πινάκων

|                                              |    |
|----------------------------------------------|----|
| Πίνακας 1 - Αποτελέσματα Compressor #1 ..... | 53 |
| Πίνακας 2 - Αποτελέσματα Compressor #2 ..... | 55 |

## Κατάλογος Συντμήσεων

|                      |                                                          |
|----------------------|----------------------------------------------------------|
| <b>IIoT</b>          | Industrial Internet of Things                            |
| <b>IoT</b>           | Internet of Things                                       |
| <b>PdM</b>           | Predictive Maintenance – Προγνωστική Συντήρηση           |
| <b>ML</b>            | Machine Learning – Μηχανική Μάθηση                       |
| <b>LPWAN</b>         | Low Power Wide Area Network                              |
| <b>MQTT</b>          | Message Queuing Telemetry Transport                      |
| <b>TSDB</b>          | Time-Series Database – Βάση Δεδομένων Χρονοσειρών        |
| <b>MAE</b>           | Mean Absolute Error                                      |
| <b>RMSE</b>          | Root Mean Square Error                                   |
| <b>R<sup>2</sup></b> | Coefficient of Determination – Συντελεστής Προσδιορισμού |
| <b>HPC</b>           | High Pressure Compressor                                 |
| <b>LoRa</b>          | Long Range                                               |
| <b>LoRaWAN</b>       | Long Range Wide Area Network                             |

# 1. Εισαγωγή

## 1.1 Βιομηχανική Συντήρηση στις Ενεργειακές Υποδομές

Οι σύγχρονες ενεργειακές και βιομηχανικές εγκαταστάσεις χαρακτηρίζονται από αυξημένες απαιτήσεις διαθεσιμότητας, αξιοπιστίας και επιχειρησιακής συνέχειας. Εγκαταστάσεις όπως σταθμοί συμπίεσης φυσικού αερίου, θερματικοί σταθμοί LNG, διυλιστήρια, μονάδες παραγωγής ηλεκτρικής ενέργειας και γενικότερα κρίσιμες ενεργειακές υποδομές βασίζονται στη συνεχή λειτουργία σύνθετου ηλεκτρομηχανολογικού εξοπλισμού, του οποίου η αστοχία μπορεί να επηρεάσει άμεσα τόσο την παραγωγική διαδικασία όσο και την ασφαλή λειτουργία της εγκατάστασης.


Σε τέτοιου είδους βιομηχανικά περιβάλλοντα, ακόμη και μία μερική δυσλειτουργία μπορεί να οδηγήσει σε σημαντικές επιχειρησιακές και οικονομικές επιπτώσεις, όπως απώλεια παραγωγής, μείωση απόδοσης, αύξηση λειτουργικού κόστους ή ακόμη και μη προγραμματισμένη παύση λειτουργίας κρίσιμων συστημάτων. Παράλληλα, λόγω της φύσης των ενεργειακών εγκαταστάσεων, ζητήματα ασφαλείας και προστασίας εξοπλισμού αποκτούν ιδιαίτερη βαρύτητα, καθιστώντας τη στρατηγική συντήρησης βασικό παράγοντα του συνολικού σχεδιασμού και λειτουργίας της εγκατάστασης.

Μεταξύ των σημαντικότερων στοιχείων εξοπλισμού στις υποδομές φυσικού αερίου συγκαταλέγονται οι συμπιεστές φυσικού αερίου, οι οποίοι χρησιμοποιούνται για τη διατήρηση της απαιτούμενης πίεσης και ροής στο δίκτυο μεταφοράς. Οι συμπιεστές λειτουργούν συνήθως σε συνεχή βάση και υπό ιδιαίτερα απαιτητικές συνθήκες λειτουργίας, που περιλαμβάνουν υψηλές πιέσεις, μεταβολές θερμοκρασίας, έντονες μηχανικές καταπονήσεις και αυξημένα επίπεδα κραδασμών. Η εύρυθμη λειτουργία τους εξαρτάται από την ομαλή συνεργασία πολλών επιμέρους συστημάτων, όπως μηχανικά μέρη, ηλεκτρολογικός εξοπλισμός, συστήματα αυτοματισμού και παρακολούθησης και όργανα μέτρησης και ελέγχου.

Για τον λόγο αυτό, η συνεχής παρακολούθηση λειτουργικών παραμέτρων όπως θερμοκρασία, πίεση, κραδασμοί και λειτουργική κατάσταση του εξοπλισμού αποτελεί ιδιαίτερα σημαντικό μέρος της λειτουργίας και της συντήρησης τέτοιων εγκαταστάσεων. Αποκλίσεις από τις φυσιολογικές συνθήκες λειτουργίας ενδέχεται να αποτελούν πρώιμες ενδείξεις φθοράς, αστοχίας ή υποβάθμισης της απόδοσης του εξοπλισμού. Η έγκαιρη αναγνώριση αυτών των αποκλίσεων επιτρέπει τον καλύτερο προγραμματισμό επεμβάσεων συντήρησης και μειώνει την πιθανότητα εμφάνισης σοβαρών βλαβών.

Παραδοσιακά, η βιομηχανική συντήρηση βασιζόταν κυρίως είτε στη διορθωτική συντήρηση (corrective maintenance), όπου η επέμβαση πραγματοποιείται μετά την εμφάνιση βλάβης, είτε στην προληπτική συντήρηση (preventive maintenance), κατά την οποία οι εργασίες συντήρησης εκτελούνται σε προκαθορισμένα χρονικά διαστήματα ανεξάρτητα από την πραγματική κατάσταση του εξοπλισμού. Αν και οι πρακτικές αυτές εξακολουθούν να χρησιμοποιούνται εκτενώς στη βιομηχανία, παρουσιάζουν σημαντικούς περιορισμούς. Η διορθωτική συντήρηση συνδέεται συχνά με αυξημένο downtime και υψηλό κόστος αποκατάστασης, ενώ η προληπτική συντήρηση μπορεί να οδηγήσει σε περιττές επεμβάσεις, μη βέλτιστη αξιοποίηση πόρων και ανταλλακτικών και περιττά έξοδα.

Η αυξανόμενη ψηφιοποίηση των βιομηχανικών εγκαταστάσεων τα τελευταία χρόνια δημιούργησε τη δυνατότητα μετάβασης σε πιο εξελιγμένες στρατηγικές διαχείρισης εξοπλισμού. Η ανάπτυξη τεχνολογιών Industrial Internet of Things (IIoT), ασύρματων δικτύων αισθητήρων, συστημάτων αποθήκευσης δεδομένων χρονοσειρών και εργαλείων ανάλυσης δεδομένων επέτρεψε την υλοποίηση συστημάτων συνεχούς παρακολούθησης και αξιολόγησης της κατάστασης του εξοπλισμού σε πραγματικό χρόνο.



**Εικόνα 1** - Γενική μεθοδολογία προσέγγισης προβλημάτων σε ψηφιοποιημένη βιομηχανία.

Στο πλαίσιο αυτό, η προγνωστική συντήρηση (Predictive Maintenance – PdM) αποκτά ολοένα και μεγαλύτερη σημασία στη σύγχρονη βιομηχανία. Μέσω της συλλογής και επεξεργασίας λειτουργικών δεδομένων, καθίσταται δυνατή η εκτίμηση της κατάστασης του εξοπλισμού και η έγκαιρη ανίχνευση πιθανών προβλημάτων πριν αυτά οδηγήσουν σε πραγματική αστοχία. Η προσέγγιση αυτή ευθυγραμμίζεται με τη γενικότερη φιλοσοφία των σύγχρονων βιομηχανικών συστημάτων, τα οποία βασίζονται increasingly σε διασυνδεδεμένες, επεκτάσιμες και βασισμένες στην αξιοποίηση λειτουργικών δεδομένων αρχιτεκτονικές παρακολούθησης και αυτοματισμού.

## 1.2 Η Έννοια της προγνωστικής Συντήρησης


Η Προγνωστική Συντήρηση (Predictive Maintenance – PdM) αποτελεί μία σύγχρονη στρατηγική διαχείρισης και συντήρησης βιομηχανικού εξοπλισμού, η οποία βασίζεται στη συνεχή παρακολούθηση λειτουργικών δεδομένων και στην αξιολόγηση της πραγματικής κατάστασης λειτουργίας ενός συστήματος. Σε αντίθεση με τις παραδοσιακές πρακτικές προληπτικής συντήρησης, όπου οι εργασίες εκτελούνται σε προκαθορισμένα χρονικά διαστήματα ανεξάρτητα από την κατάσταση του εξοπλισμού, η προγνωστική συντήρηση στοχεύει στην έγκαιρη αναγνώριση ενδείξεων φθοράς ή δυσλειτουργίας πριν αυτές εξελιχθούν σε πραγματική αστοχία (Carvalho et al. 2019, Zhu et al. 2019).

Η βασική φιλοσοφία της προγνωστικής συντήρησης στηρίζεται στη λογική της condition-based monitoring προσέγγισης, σύμφωνα με την οποία οι αποφάσεις συντήρησης λαμβάνονται με βάση τη συμπεριφορά και τα πραγματικά δεδομένα λειτουργίας του εξοπλισμού. Με τον τρόπο αυτό καθίσταται δυνατή η καλύτερη αξιοποίηση των διαθέσιμων πόρων συντήρησης, η μείωση μη προγραμματισμένων διακοπών λειτουργίας και η αύξηση της συνολικής αξιοπιστίας της εγκατάστασης.

Σε βιομηχανικά περιβάλλοντα, η εφαρμογή predictive maintenance βασίζεται συνήθως στη συνεχή συλλογή κρίσιμων λειτουργικών μεγεθών, όπως:

- θερμοκρασίες,
- πιέσεις,
- κραδασμοί,
- στροφές περιστροφής,
- ηλεκτρικά μεγέθη,

Τα δεδομένα αυτά προέρχονται είτε από υπάρχοντα συστήματα ελέγχου και instrumentation είτε από επιπλέον αισθητήρες που εγκαθίστανται ειδικά για σκοπούς condition monitoring. Η συνεχής παρακολούθηση των παραμέτρων αυτών επιτρέπει την ανίχνευση αποκλίσεων από τη φυσιολογική λειτουργία και τη δημιουργία μοντέλων εκτίμησης της κατάστασης του εξοπλισμού.



**Εικόνα 2** - Γενική αρχιτεκτονική συστήματος προγνωστικής συντήρησης.

Η εξέλιξη των τεχνολογιών Industrial Internet of Things (IIoT) τα τελευταία χρόνια συνέβαλε σημαντικά στην ευρύτερη εφαρμογή συστημάτων προγνωστικής συντήρησης στη βιομηχανία. Η δυνατότητα εγκατάστασης κατακευκτωμένων αισθητήρων χαμηλού κόστους, σε συνδυασμό με την ανάπτυξη ασύρματων πρωτοκόλλων επικοινωνίας και σύγχρονων εργαλείων επεξεργασίας δεδομένων, επέτρεψε την υλοποίηση ολοκληρωμένων αρχιτεκτονικών παρακολούθησης ακόμη και σε εγκαταστάσεις με αυξημένες απαιτήσεις ή περιορισμούς υποδομών (Krupitzer et al. 2020, Çinar et al. 2020).

Ιδιαίτερο ενδιαφέρον παρουσιάζουν οι τεχνολογίες ασύρματης επικοινωνίας χαμηλής κατανάλωσης ισχύος, όπως το LoRaWAN, οι οποίες επιτρέπουν την ανάπτυξη ευέλικτων Industrial IoT υποδομών με σχετικά μικρές απαιτήσεις εγκατάστασης και συντήρησης. Η δυνατότητα μετάδοσης δεδομένων σε μεγάλες αποστάσεις, με χαμηλή κατανάλωση ενέργειας και περιορισμένες απαιτήσεις δικτύου, καθιστά τέτοιες τεχνολογίες ιδιαίτερα κατάλληλες για εφαρμογές βιομηχανικής παρακολούθησης και ενεργειακών εγκαταστάσεων. Για τον λόγο αυτόν, αποτελεί και μια από τις βασικότερες τεχνολογίες ασύρματης επικοινωνίας που χρησιμοποιείται στην βιομηχανία, όσον αφορά γνωστά εμπορικά πρωτόκολλα.

Τα τελευταία χρόνια, η ανάπτυξη open-source Industrial IoT εργαλείων έχει διευκολύνει σημαντικά την υλοποίηση συστημάτων συλλογής και επεξεργασίας βιομηχανικών δεδομένων. Τεχνολογίες όπως το MQTT για χαμηλών υπολογιστικών απαιτήσεων messaging, η InfluxDB για αποθήκευση χρονοσειρών και το Grafana για real-time visualization χρησιμοποιούνται ολοένα και περισσότερο σε εφαρμογές παρακολούθησης και ανάλυσης δεδομένων. Παράλληλα, εργαλεία όπως το Node-RED προσφέρουν ευελιξία στην ανάπτυξη data flows και στην ενοποίηση ετερογενών συστημάτων και πρωτοκόλλων επικοινωνίας, ιδιαίτερα σε περιβάλλοντα Industrial IoT και edge computing όπου παρουσιάζεται και ανάγκη διαλειτουργικότητας.

Σημαντικό ρόλο στην προγνωστική συντήρηση διαδραματίζουν επίσης οι τεχνικές μηχανικής μάθησης και ανάλυσης δεδομένων (Serradilla et al. 2020). Μέσω αλγορίθμων machine learning καθίσταται δυνατή η επεξεργασία μεγάλου όγκου ιστορικών δεδομένων και η αναγνώριση προτύπων λειτουργίας που δύσκολα μπορούν να εντοπιστούν με συμβατικές μεθόδους. Η χρήση predictive models επιτρέπει την εκτίμηση της αναμενόμενης συμπεριφοράς του εξοπλισμού και τη σύγκριση αυτής με τις πραγματικές μετρήσεις λειτουργίας, διευκολύνοντας την έγκαιρη ανίχνευση ανωμαλιών ή μη φυσιολογικών καταστάσεων.

Η προγνωστική συντήρηση συνιστά βασικό συστατικό του Industry 4.0 και του ψηφιακού μετασχηματισμού της βιομηχανίας, αξιοποιώντας τις δυνατότητες που προσφέρει η εκτεταμένη διασύνδεση εξοπλισμού, αισθητήρων και πληροφοριακών συστημάτων. Η συνεχής συλλογή και επεξεργασία λειτουργικών δεδομένων επιτρέπει την ανάπτυξη προηγμένων μοντέλων παρακολούθησης και πρόβλεψης της κατάστασης του εξοπλισμού, με στόχο την έγκαιρη αναγνώριση επικείμενων αστοχιών. Η προσέγγιση αυτή οδηγεί στη μείωση των απρογραμμάτιστων διακοπών λειτουργίας, στη βελτιστοποίηση των ενεργειών συντήρησης και στη συνολική αναβάθμιση της αποδοτικότητας και αξιοπιστίας των βιομηχανικών εγκαταστάσεων.

### 1.3 Στόχοι της Διπλωματικής Εργασίας

Βασικός στόχος της παρούσας διπλωματικής εργασίας είναι ο σχεδιασμός και η υλοποίηση ενός ολοκληρωμένου συστήματος προγνωστικής συντήρησης για εφαρμογές βιομηχανικής παρακολούθησης, με έμφαση στη δημιουργία μιας αρθρωτής λογικής και επεκτάσιμης Industrial IoT αρχιτεκτονικής. Η εργασία επικεντρώνεται στην ανάπτυξη ενός ολοκληρωμένου συστήματος συλλογής, μετάδοσης, αποθήκευσης, επεξεργασίας και ανάλυσης λειτουργικών δεδομένων βιομηχανικού συμπίεστη, αξιοποιώντας τεχνολογίες ασύρματης

επικοινωνίας, open-source λογισμικά για τις παραπάνω λειτουργίες και τεχνικές machine learning.

Πιο συγκεκριμένα, στόχος της εργασίας είναι η ανάπτυξη μιας ολοκληρωμένης υποδομής ικανής να:

- συλλέγει λειτουργικά δεδομένα από κατανεμημένους αισθητηριακούς κόμβους,
- μεταδίδει τις μετρήσεις ασύρματα μέσω δικτύου LoRaWAN,
- διαχειρίζεται και δρομολογεί τα δεδομένα μέσω Industrial IoT communication layers,
- αποθηκεύει χρονοσειρές λειτουργικών δεδομένων,
- παρέχει δυνατότητες real-time monitoring και visualization,
- και εφαρμόζει αλγορίθμους μηχανικής μάθησης για predictive analysis και anomaly detection.

Η συνολική αρχιτεκτονική σχεδιάστηκε με βάση φιλοσοφία αντίστοιχη πραγματικών βιομηχανικών συστημάτων παρακολούθησης, δίνοντας έμφαση στη διασυνδεσιμότητα/διαλειτουργικότητα, την επεκτασιμότητα και τη δυνατότητα μελλοντικής ενσωμάτωσης σε μεγαλύτερες υποδομές ελέγχου και βιομηχανικής παρακολούθησης.

Για την υλοποίηση των αισθητηριακών κόμβων χρησιμοποιήθηκαν μικροελεγκτές Raspberry Pi Pico RP2040 σε συνδυασμό με LoRa communication modules, ενώ ως LoRaWAN gateway χρησιμοποιήθηκε Raspberry Pi 4 εξοπλισμένο με SX1302 LoRaWAN Gateway HAT. Η επιλογή της συγκεκριμένης αρχιτεκτονικής βασίστηκε στη δυνατότητα δημιουργίας μιας ευέλικτης και χαμηλού κόστους υποδομής Industrial IoT, με χρήση widely available hardware και open-source τεχνολογιών.

Η υποδομή επικοινωνίας υλοποιήθηκε μέσω του ChirpStack LoRaWAN Network Server και του πρωτοκόλλου MQTT, επιτρέποντας την αξιόπιστη διαχείριση και προώθηση των δεδομένων μεταξύ των επιμέρους επιπέδων του συστήματος. Για την επεξεργασία, αποκωδικοποίηση και δρομολόγηση των δεδομένων χρησιμοποιήθηκε το Node-RED, το οποίο προσέφερε ευελιξία στην ανάπτυξη data flows και στη διασύνδεση διαφορετικών υπηρεσιών και πρωτοκόλλων επικοινωνίας.

Για την αποθήκευση των δεδομένων χρησιμοποιήθηκε η βάση δεδομένων χρονοσειρών InfluxDB, ενώ για την οπτικοποίηση και παρακολούθηση των μετρήσεων αναπτύχθηκαν dashboards στο Grafana. Η χρήση open-source εργαλείων επέτρεψε τη δημιουργία ενός ολοκληρωμένου περιβάλλον

παρακολούθησης με δυνατότητες real-time visualization, ιστορικής ανάλυσης και εύκολης επέκτασης.

Παράλληλα, στο πλαίσιο της εργασίας αναπτύχθηκαν μοντέλα μηχανικής μάθησης σε περιβάλλον Python, με σκοπό την εκτίμηση της αναμενόμενης συμπεριφοράς του εξοπλισμού και την ανίχνευση αποκλίσεων από τις φυσιολογικές συνθήκες λειτουργίας. Η επεξεργασία των δεδομένων περιλάμβανε τεχνικές feature engineering και time-series analysis, με στόχο τη δημιουργία predictive models κατάλληλων για εφαρμογές condition monitoring.

Τέλος, η εργασία επιδιώκει να αναδείξει τη δυνατότητα αξιοποίησης open-source Industrial IoT τεχνολογιών για την ανάπτυξη ολοκληρωμένων συστημάτων βιομηχανικής παρακολούθησης και predictive maintenance, παρουσιάζοντας μία αρχιτεκτονική που μπορεί να αποτελέσει βάση για μελλοντική επέκταση και εφαρμογή σε πραγματικές ενεργειακές και βιομηχανικές εγκαταστάσεις.

## 1.4 Δομή της Διπλωματικής Εργασίας

Η παρούσα διπλωματική εργασία οργανώνεται σε οκτώ κεφάλαια και ακολουθεί μια σταδιακή προσέγγιση ανάπτυξης και παρουσίασης του προτεινόμενου συστήματος προγνωστικής συντήρησης. Η δομή της εργασίας σχεδιάστηκε με στόχο τη σταδιακή μετάβαση από το θεωρητικό υπόβαθρο και τις τεχνολογίες Industrial IoT, στην ανάλυση της αρχιτεκτονικής, την υλοποίηση της πλατφόρμας και την αξιολόγηση των αποτελεσμάτων.

Στο Κεφάλαιο 1 παρουσιάζονται οι βασικές έννοιες της βιομηχανικής συντήρησης και της προγνωστικής συντήρησης, καθώς και το γενικό πλαίσιο μέσα στο οποίο αναπτύσσεται η εργασία. Επιπλέον, περιγράφονται οι στόχοι της διπλωματικής εργασίας και η φιλοσοφία σχεδιασμού του προτεινόμενου συστήματος.

Στο Κεφάλαιο 2 αναλύεται το θεωρητικό υπόβαθρο που σχετίζεται με τις τεχνολογίες και τις μεθόδους που αξιοποιούνται στην παρούσα εργασία. Πιο συγκεκριμένα, παρουσιάζονται βασικά στοιχεία σχετικά με τους βιομηχανικούς συμπιεστές και τα συστήματα φυσικού αερίου, τις τεχνολογίες Industrial IoT, το πρωτόκολλο LoRaWAN, το MQTT, τις βάσεις δεδομένων χρονοσειρών και τις βασικές τεχνικές μηχανικής μάθησης που χρησιμοποιούνται σε εφαρμογές predictive maintenance.

Στο Κεφάλαιο 3 παρουσιάζεται η συνολική αρχιτεκτονική του συστήματος και αναλύεται η υλοποίηση της προτεινόμενης Industrial IoT πλατφόρμας παρακολούθησης. Περιγράφονται οι αισθητηριακοί κόμβοι, η υποδομή

LoRaWAN επικοινωνίας, το gateway, ο LoRaWAN Network Server, καθώς και τα επιμέρους επίπεδα επεξεργασίας, αποθήκευσης και οπτικοποίησης των δεδομένων. Παράλληλα, αναλύεται η χρήση open-source εργαλείων και η συνολική φιλοσοφία σχεδιασμού της αρχιτεκτονικής.

Στο Κεφάλαιο 4 παρουσιάζεται η διαδικασία ανάπτυξης των μοντέλων μηχανικής μάθησης που χρησιμοποιούνται για την πρόβλεψη κρίσιμων λειτουργικών παραμέτρων των βιομηχανικών συμπιεστών. Περιγράφεται η συλλογή και προεπεξεργασία των ιστορικών δεδομένων, η επιλογή των μεταβλητών εισόδου και εξόδου, η διαδικασία εκπαίδευσης των μοντέλων Random Forest και η αξιολόγηση της απόδοσής τους μέσω κατάλληλων δεικτών σφάλματος και στατιστικών μεγεθών.

Στο Κεφάλαιο 5 αναλύεται η ενσωμάτωση των εκπαιδευμένων μοντέλων στην προτεινόμενη Industrial IoT πλατφόρμα και η υλοποίηση της διαδικασίας πρόβλεψης σε πραγματικό χρόνο. Παρουσιάζεται η ανάπτυξη της υπηρεσίας πρόβλεψης, η διασύνδεσή της με το Node-RED, η παραγωγή των αναμενόμενων τιμών των παραμέτρων και ο υπολογισμός των residuals, τα οποία αποτελούν τη βάση για την ανίχνευση αποκλίσεων και πιθανών ανωμαλιών στη λειτουργία του εξοπλισμού.

Στο Κεφάλαιο 6 παρουσιάζονται τα αποτελέσματα της λειτουργίας του ολοκληρωμένου συστήματος και η αξιολόγηση της απόδοσής του. Αναλύονται τα δεδομένα που συλλέγονται μέσω της πλατφόρμας, παρουσιάζονται οι δυνατότητες οπτικοποίησης μέσω Grafana και εξετάζεται η συμπεριφορά των residuals ως δείκτες έγκαιρης ανίχνευσης πιθανών βλαβών ή αποκλίσεων από τη φυσιολογική λειτουργία των συμπιεστών.


Στο Κεφάλαιο 7 πραγματοποιείται συνολική συζήτηση των αποτελεσμάτων και αξιολόγηση της προτεινόμενης προσέγγισης. Εξετάζονται τα πλεονεκτήματα και οι περιορισμοί της υλοποίησης, αναλύεται η συνεισφορά των τεχνολογιών Industrial IoT και της μηχανικής μάθησης στην προγνωστική συντήρηση και διατυπώνονται προτάσεις για περαιτέρω βελτίωση και επέκταση του συστήματος.

Τέλος, στο Κεφάλαιο 8 παρουσιάζονται τα βασικά συμπεράσματα της διπλωματικής εργασίας. Συνοψίζονται τα κύρια αποτελέσματα που προέκυψαν από την ανάπτυξη και αξιολόγηση της πλατφόρμας, αναδεικνύεται η συμβολή της εργασίας στον τομέα της προγνωστικής συντήρησης βιομηχανικού εξοπλισμού και προτείνονται κατευθύνσεις για μελλοντική έρευνα και εφαρμογή της προτεινόμενης μεθοδολογίας σε πραγματικά βιομηχανικά περιβάλλοντα μεγαλύτερης κλίμακας.

## 1. Θεωρητικό Υπόβαθρο

### 2.1 Βιομηχανικοί Συμπιεστές και Συστήματα Φυσικού Αερίου

Οι βιομηχανικοί συμπιεστές αποτελούν έναν από τους σημαντικότερους τύπους εξοπλισμού στις εγκαταστάσεις φυσικού αερίου και γενικότερα στον ενεργειακό και βιομηχανικό τομέα. Χρησιμοποιούνται για την αύξηση της πίεσης του αερίου, επιτρέποντας τη μεταφορά του μέσω αγωγών μεγάλων αποστάσεων, την αποθήκευση υπό πίεση, καθώς και την τροφοδοσία βιομηχανικών διεργασιών και μονάδων παραγωγής ενέργειας. Η λειτουργία τους είναι άμεσα συνδεδεμένη με τη σταθερότητα και τη διαθεσιμότητα των ενεργειακών υποδομών, γεγονός που τους καθιστά κρίσιμο εξοπλισμό για τη συνολική λειτουργία ενός συστήματος μεταφοράς ή επεξεργασίας φυσικού αερίου.



Εικόνα 3 – Ενδεικτική εικόνα βιομηχανικού συμπιεστή.

Στα δίκτυα μεταφοράς φυσικού αερίου, οι σταθμοί συμπίεσης εγκαθίστανται κατά μήκος των αγωγών προκειμένου να αντισταθμίζουν τις απώλειες πίεσης που εμφανίζονται κατά τη μεταφορά του αερίου. Καθώς το φυσικό αέριο κινείται μέσα στον αγωγό, εμφανίζονται απώλειες λόγω τριβών και μεταβολών των συνθηκών λειτουργίας, με αποτέλεσμα να απαιτείται περιοδική επανασυμπίεση ώστε να διατηρείται η απαιτούμενη πίεση και παροχή του δικτύου. Για τον λόγο αυτό, η συνεχής και αξιόπιστη λειτουργία των συμπιεστών είναι ιδιαίτερα σημαντική, καθώς πιθανή δυσλειτουργία ή παύση λειτουργίας μπορεί να

επηρεάσει άμεσα τη λειτουργία του συστήματος μεταφοράς και τη διαθεσιμότητα του δικτύου.

Οι βιομηχανικοί συμπιεστές λειτουργούν συνήθως υπό απαιτητικές συνθήκες, με συνεχή ή σχεδόν συνεχή λειτουργία, υψηλές πιέσεις και σημαντικές μηχανικές και θερμικές καταπονήσεις. Η λειτουργία τους εξαρτάται από τη συνεργασία πολλών επιμέρους συστημάτων, όπως:

- μηχανικά μέρη περιστροφικού εξοπλισμού,
- ηλεκτροκινητήρες ή αεριοστροβίλους,
- συστήματα λίπανσης και ψύξης,
- instrumentation και αισθητήρες,
- συστήματα αυτοματισμού και ελέγχου.

Λόγω της πολυπλοκότητας αυτών των συστημάτων, η παρακολούθηση της κατάστασης λειτουργίας του εξοπλισμού αποτελεί κρίσιμο παράγοντα τόσο για τη διασφάλιση της αξιοπιστίας όσο και για την πρόληψη πιθανών αστοχιών.

Η λειτουργία ενός βιομηχανικού συμπιεστή συνοδεύεται από τη συνεχή παρακολούθηση μεγάλου αριθμού λειτουργικών παραμέτρων, οι οποίες χρησιμοποιούνται τόσο για operational monitoring όσο και για condition assessment του εξοπλισμού. Μεταξύ των σημαντικότερων παραμέτρων περιλαμβάνονται:

- η πίεση αναρρόφησης και κατάθλιψης,
- η θερμοκρασία εισόδου και εξόδου,
- τα επίπεδα κραδασμών,
- οι στροφές περιστροφής,
- οι αξονικές μετατοπίσεις,
- καθώς και ηλεκτρικά μεγέθη που σχετίζονται με τη λειτουργία κινητήρων και μετατροπένων ισχύος.

Οι παράμετροι αυτές παρέχουν σημαντικές πληροφορίες σχετικά με τη λειτουργική κατάσταση του εξοπλισμού και χρησιμοποιούνται για την ανίχνευση αποκλίσεων από τη φυσιολογική λειτουργία. Για παράδειγμα, αυξημένα επίπεδα κραδασμών μπορεί να υποδηλώνουν φθορά εδράνων ή προβλήματα ευθυγράμμισης, ενώ μεταβολές στις θερμοκρασίες και στις πιέσεις λειτουργίας μπορεί να σχετίζονται με μείωση απόδοσης ή δυσλειτουργία επιμέρους υποσυστημάτων.

Στις σύγχρονες βιομηχανικές εγκαταστάσεις, η παρακολούθηση αυτών των μεγεθών πραγματοποιείται συνήθως μέσω συστημάτων SCADA/DCS, τα οποία επιτρέπουν τη συνεχή συλλογή και εποπτεία λειτουργικών δεδομένων. Ωστόσο, η αυξανόμενη διαθεσιμότητα Industrial IoT τεχνολογιών και συστημάτων edge monitoring δημιουργεί νέες δυνατότητες για πιο ευέλικτες και επεκτάσιμες αρχιτεκτονικές condition monitoring, με δυνατότητα αξιοποίησης δεδομένων σε πραγματικό χρόνο.

Η ανάγκη για συνεχή επιτήρηση, έγκαιρη ανίχνευση προβλημάτων και περιορισμό μη προγραμματισμένων διακοπών λειτουργίας καθιστά τους βιομηχανικούς συμπιεστές ιδιαίτερα κατάλληλη εφαρμογή για την ανάπτυξη συστημάτων προγνωστικής συντήρησης. Η αξιοποίηση αισθητήρων, ασύρματων δικτύων επικοινωνίας και εργαλείων ανάλυσης δεδομένων επιτρέπει τη δημιουργία ολοκληρωμένων συστημάτων condition monitoring, τα οποία μπορούν να υποστηρίξουν πιο αποδοτικές στρατηγικές λειτουργίας και συντήρησης σε ενεργειακές και βιομηχανικές εγκαταστάσεις.

## 2. Θεωρητικό Υπόβαθρο και Τεχνολογίες Υλοποίησης

### 2.1 Industrial Internet of Things (IIoT)

Το Industrial Internet of Things (IIoT) αποτελεί εξέλιξη της έννοιας του Internet of Things (IoT) και αναφέρεται στην εφαρμογή διασυνδεδεμένων αισθητήρων, συσκευών και πληροφοριακών συστημάτων σε βιομηχανικά περιβάλλοντα. Σε αντίθεση με τις κλασικές εφαρμογές IoT που συναντώνται κυρίως σε καταναλωτικές ή οικιακές εφαρμογές, το IIoT επικεντρώνεται σε εφαρμογές αυξημένων απαιτήσεων αξιοπιστίας, διαθεσιμότητας και επιχειρησιακής συνέχειας, όπως βιομηχανικές εγκαταστάσεις, ενεργειακές υποδομές, δίκτυα μεταφοράς και συστήματα αυτοματισμού (Xu, He & Li 2014).

Η βασική φιλοσοφία ενός IIoT συστήματος στηρίζεται στη συνεχή συλλογή λειτουργικών δεδομένων από φυσικό εξοπλισμό και στη μεταφορά των δεδομένων αυτών σε πληροφοριακά συστήματα επεξεργασίας και ανάλυσης. Στο πλαίσιο αυτό, συσκευές όπως αισθητήρες, controllers και edge devices χρησιμοποιούνται για την παρακολούθηση κρίσιμων λειτουργικών μεγεθών και τη διασύνδεση του φυσικού εξοπλισμού με ψηφιακές πλατφόρμες διαχείρισης δεδομένων (Boyes et al. 2018).

Τα δεδομένα που συλλέγονται μπορούν να μεταδοθούν είτε μέσω ενσύρματων είτε μέσω ασύρματων δικτύων επικοινωνίας, ανάλογα με τις απαιτήσεις της εφαρμογής και τις ιδιαιτερότητες της εγκατάστασης. Στη συνέχεια, τα δεδομένα αποθηκεύονται, επεξεργάζονται και αξιοποιούνται για:

- operational monitoring,
- condition monitoring,
- βελτιστοποίηση λειτουργίας,
- υποστήριξη λήψης αποφάσεων,
- αυτοματοποιημένες λειτουργίες.

Οι βασικές λειτουργίες μιας ολοκληρωμένης IIoT αρχιτεκτονικής περιλαμβάνουν:

- συλλογή δεδομένων από αισθητήρες και μετρητικά όργανα,
- μετάδοση δεδομένων μέσω communication layers,
- επεξεργασία και μετασχηματισμό δεδομένων,
- αποθήκευση δεδομένων σε τοπικές βάσεις χρονοσειρών ή cloud υποδομές,
- οπτικοποίηση και ανάλυση λειτουργικών μεγεθών,
- καθώς και διασύνδεση με ανώτερα πληροφοριακά ή βιομηχανικά συστήματα.


Η ανάπτυξη των τεχνολογιών IIoT έχει οδηγήσει σταδιακά στη μετάβαση από παραδοσιακές isolated industrial υποδομές σε περισσότερο διασυνδεδεμένα και βασισμένες στην αξιοποίηση λειτουργικών δεδομένων συστήματα λειτουργίας (Sisinni et al. 2018). Η δυνατότητα συνεχούς συλλογής και αξιοποίησης δεδομένων σε πραγματικό χρόνο επιτρέπει την ανάπτυξη εφαρμογών όπως:

- predictive maintenance,
- remote monitoring,
- energy management,
- industrial automation,
- asset performance monitoring,
- digital twins.

Ιδιαίτερα στον ενεργειακό τομέα και στις εγκαταστάσεις φυσικού αερίου, οι IIoT τεχνολογίες αποκτούν ολοένα και μεγαλύτερη σημασία λόγω της ανάγκης συνεχούς επιτήρησης κρίσιμου εξοπλισμού και της απαίτησης για αυξημένη αξιοπιστία λειτουργίας. Η δυνατότητα εγκατάστασης καταναμεμένων αισθητήρων και edge monitoring συστημάτων επιτρέπει την παρακολούθηση λειτουργικών παραμέτρων σε πραγματικό χρόνο ακόμη και σε εγκαταστάσεις μεγάλης γεωγραφικής έκτασης ή σε σημεία όπου η ανάπτυξη συμβατικών υποδομών είναι δύσκολη ή κοστοβόρα.

Παράλληλα, η ανάπτυξη open-source εργαλείων και Industrial IoT πλατφορμών έχει επιτρέψει τη δημιουργία ευέλικτων αρχιτεκτονικών με σχετικά χαμηλό κόστος υλοποίησης. Πλατφόρμες και τεχνολογίες όπως MQTT, Node-RED, InfluxDB και Grafana μπορούν να χρησιμοποιηθούν σε συστήματα Industrial IoT για τη δημιουργία ολοκληρωμένων data pipelines, επιτρέποντας τη διασύνδεση αισθητήρων, communication layers, βάσεων δεδομένων και εργαλείων visualization μέσα σε ενιαία περιβάλλον παρακολούθησης.

Στις εφαρμογές προγνωστικής συντήρησης, οι IIoT τεχνολογίες λειτουργούν ως το βασικό επίπεδο συλλογής και διαχείρισης δεδομένων. Μέσω της συνεχούς καταγραφής λειτουργικών μεγεθών από κρίσιμο εξοπλισμό καθίσταται δυνατή η ανάπτυξη predictive analytics και condition monitoring εφαρμογών, με στόχο την έγκαιρη αναγνώριση αποκλίσεων και τη βελτιστοποίηση της λειτουργίας και της συντήρησης των βιομηχανικών εγκαταστάσεων.



**Εικόνα 4** - Ενδεικτική αρχιτεκτονική Industrial IoT συστήματος.

## 2.2 Τεχνολογία LoRa και LoRaWAN

Το LoRa (Long Range) αποτελεί τεχνολογία ασύρματης επικοινωνίας χαμηλής κατανάλωσης ισχύος και μεγάλης εμβέλειας, σχεδιασμένη κυρίως για εφαρμογές Internet of Things και Industrial IoT (Raza, Kulkarni & Sooriyabandara 2017). Η τεχνολογία βασίζεται σε τεχνική διαμόρφωσης spread spectrum και επιτρέπει τη μετάδοση μικρών ποσοτήτων δεδομένων σε μεγάλες αποστάσεις, διατηρώντας παράλληλα ιδιαίτερα χαμηλή κατανάλωση ενέργειας στις τελικές συσκευές.

Η ανάπτυξη του LoRa συνδέεται κυρίως με εφαρμογές όπου απαιτείται:


- περιοδική αποστολή μικρού όγκου δεδομένων,
- λειτουργία αισθητήρων με χαμηλή ενεργειακή κατανάλωση,
- κάλυψη μεγάλων γεωγραφικών περιοχών,
- και περιορισμένες απαιτήσεις υποδομών επικοινωνίας.

Τα χαρακτηριστικά αυτά καθιστούν την τεχνολογία ιδιαίτερα κατάλληλη για εφαρμογές βιομηχανικής παρακολούθησης, ενεργειακών εγκαταστάσεων, smart metering και condition monitoring.

Πάνω από το φυσικό επίπεδο επικοινωνίας LoRa αναπτύχθηκε το πρωτόκολλο LoRaWAN, το οποίο καθορίζει την αρχιτεκτονική του δικτύου, τον τρόπο επικοινωνίας μεταξύ των συσκευών και τη διαχείριση της ανταλλαγής δεδομένων (LoRa Alliance 2020). Το LoRaWAN αποτελεί ένα LPWAN (Low Power Wide Area Network) πρωτόκολλο σχεδιασμένο ώστε να υποστηρίζει μεγάλο αριθμό συσκευών με χαμηλές απαιτήσεις ισχύος και bandwidth (Ertürk et al. 2019, Sundaram, Du & Zhao 2020).

Ένα τυπικό δίκτυο LoRaWAN αποτελείται από:

- τελικές συσκευές (end devices),
- gateways,
- network server,
- application server.



**Εικόνα 5 - Βασική αρχιτεκτονική δικτύου LoRaWAN.**

Οι αισθητήρες ή οι edge συσκευές λειτουργούν ως end devices και μεταδίδουν περιοδικά δεδομένα προς τα gateways μέσω LoRa επικοινωνίας. Τα gateways λειτουργούν ως ενδιάμεσοι κόμβοι και προωθούν τα πακέτα δεδομένων προς τον LoRaWAN Network Server μέσω IP δικτύου. Ο network server αναλαμβάνει τη διαχείριση των συσκευών, τη δρομολόγηση των πακέτων, τη διαδικασία authentication και τον έλεγχο της συνολικής λειτουργίας του δικτύου.

Στη συνέχεια, τα δεδομένα προωθούνται στον application server ή σε εξωτερικές εφαρμογές επεξεργασίας και αποθήκευσης δεδομένων μέσω κατάλληλων communication interfaces, όπως MQTT ή HTTP APIs.

Βασικά πλεονεκτήματα του LoRaWAN αποτελούν:

- η μεγάλη εμβέλεια επικοινωνίας,
- η χαμηλή κατανάλωση ενέργειας,
- το σχετικά χαμηλό κόστος ανάπτυξης υποδομών,
- η δυνατότητα υποστήριξης μεγάλου αριθμού συσκευών,
- καθώς και η ευελιξία ανάπτυξης private Industrial IoT δικτύων.

Σε αντίθεση με άλλες τεχνολογίες ασύρματης επικοινωνίας, όπως Wi-Fi ή Bluetooth, το LoRaWAN δεν στοχεύει σε υψηλούς ρυθμούς μετάδοσης δεδομένων αλλά στη σταθερή και ενεργειακά αποδοτική μεταφορά μικρού όγκου μετρήσεων σε μεγάλες αποστάσεις. Η φιλοσοφία αυτή το καθιστά ιδιαίτερα κατάλληλο για εφαρμογές condition monitoring και predictive maintenance, όπου συνήθως απαιτείται περιοδική αποστολή τηλεμετρικών δεδομένων και όχι συνεχής μεταφορά μεγάλου όγκου πληροφορίας (Paul 2020).

Στον βιομηχανικό και ενεργειακό τομέα, η χρήση LoRaWAN παρουσιάζει ιδιαίτερο ενδιαφέρον σε εγκαταστάσεις μεγάλης γεωγραφικής έκτασης ή σε περιβάλλοντα όπου η ανάπτυξη εκτεταμένων ενσύρματων υποδομών είναι δύσκολη ή οικονομικά μη αποδοτική. Επιπλέον, η δυνατότητα ανάπτυξης

private LoRaWAN δικτύων επιτρέπει μεγαλύτερο έλεγχο της υποδομής επικοινωνίας και ευκολότερη ενσωμάτωση με Industrial IoT αρχιτεκτονικές και open-source monitoring πλατφόρμες.


Στην παρούσα εργασία, το LoRaWAN χρησιμοποιείται ως βασικό επίπεδο ασύρματης επικοινωνίας μεταξύ των αισθητηριακών κόμβων και του συστήματος διαχείρισης δεδομένων, υποστηρίζοντας τη μετάδοση λειτουργικών μετρήσεων προς την υπόλοιπη Industrial IoT υποδομή της εφαρμογής. Η επιλογή του συγκεκριμένου πρωτοκόλλου βασίστηκε κυρίως στη δυνατότητα ανάπτυξης δικτύων μεγάλης εμβέλειας με περιορισμένες απαιτήσεις ισχύος και υποδομών, χαρακτηριστικά ιδιαίτερα σημαντικά σε ενεργειακές και βιομηχανικές εγκαταστάσεις.

## 2.3 Πρωτόκολλο MQTT

Το MQTT (Message Queuing Telemetry Transport) αποτελεί πρωτόκολλο επικοινωνίας τύπου publish/subscribe, σχεδιασμένο για εφαρμογές ανταλλαγής τηλεμετρικών δεδομένων με περιορισμένες απαιτήσεις bandwidth και χαμηλή επιβάρυνση δικτύου (Banks & Gupta 2014). Το πρωτόκολλο αναπτύχθηκε αρχικά για εφαρμογές βιομηχανικής τηλεμετρίας και σήμερα χρησιμοποιείται εκτενώς σε IoT και Industrial IoT υποδομές λόγω της απλής αρχιτεκτονικής και της ευκολίας ενσωμάτωσης με διαφορετικά πληροφοριακά συστήματα.

Σε αντίθεση με τα κλασικά μοντέλα point-to-point επικοινωνίας, το MQTT βασίζεται σε αρχιτεκτονική publish/subscribe μέσω ενός κεντρικού broker. Οι συσκευές ή εφαρμογές που αποστέλλουν δεδομένα λειτουργούν ως publishers, ενώ οι εφαρμογές που λαμβάνουν δεδομένα λειτουργούν ως subscribers.

Η ανταλλαγή πληροφοριών πραγματοποιείται μέσω θεματικών καναλιών επικοινωνίας, γνωστών ως topics. Ένας αισθητήρας ή μια εφαρμογή μπορεί να δημοσιεύει δεδομένα σε συγκεκριμένο topic, ενώ πολλαπλές εφαρμογές μπορούν να εγγράφονται στο ίδιο topic και να λαμβάνουν τα δεδομένα σε πραγματικό χρόνο.



**Εικόνα 6 - Publish/Subscribe αρχιτεκτονική MQTT.**

Η συγκεκριμένη αρχιτεκτονική προσφέρει σημαντική ευελιξία στη διασύνδεση διαφορετικών συστημάτων και επιτρέπει την ανάπτυξη αρθρωτής λογικής data pipelines, ιδιαίτερα σε εφαρμογές Industrial IoT και distributed monitoring systems.

Το MQTT χρησιμοποιείται ευρέως σε IIoT εφαρμογές λόγω:

- της μικρής επιβάρυνσης δικτύου,
- της χαμηλής κατανάλωσης πόρων,
- της υποστήριξης near real-time ανταλλαγής δεδομένων,
- της απλής αρχιτεκτονικής publish/subscribe,
- και της εύκολης διασύνδεσης με cloud, edge και monitoring συστήματα.

Επιπλέον, το πρωτόκολλο υποστηρίζει την εύκολη διασύνδεση αισθητήρων, databases, dashboards και analytics εφαρμογών μέσα σε ενιαίες αρχιτεκτονικές Industrial IoT, επιτρέποντας τη δημιουργία επεκτάσιμων και loosely-coupled συστημάτων επεξεργασίας δεδομένων.

Στην παρούσα εργασία, το MQTT χρησιμοποιείται ως βασικός μηχανισμός ανταλλαγής δεδομένων μεταξύ του ChirpStack LoRaWAN Network Server και του επιπέδου επεξεργασίας δεδομένων. Τα uplink δεδομένα των αισθητήρων δημοσιεύονται σε MQTT topics και στη συνέχεια δρομολογούνται προς το Node-RED για αποκωδικοποίηση, επεξεργασία και αποθήκευση.

Η χρήση MQTT επέτρεψε την υλοποίηση μιας ευέλικτης και αρθρωτής λογικής αρχιτεκτονικής επικοινωνίας, όπου τα επιμέρους components του συστήματος μπορούν να λειτουργούν ανεξάρτητα αλλά ταυτόχρονα να διασυνδέονται εύκολα μέσω κοινών communication layers.

## 2.4 Βάσεις Δεδομένων Χρονοσειρών

Οι βάσεις δεδομένων χρονοσειρών (Time-Series Databases – TSDB) αποτελούν εξειδικευμένα συστήματα αποθήκευσης δεδομένων σχεδιασμένα για τη διαχείριση πληροφοριών που συνοδεύονται από χρονική σήμανση (timestamp). Σε αντίθεση με τις κλασικές σχεσιακές βάσεις δεδομένων, οι TSDB είναι βελτιστοποιημένες για εφαρμογές όπου τα δεδομένα παράγονται συνεχώς σε χρονική ακολουθία και απαιτείται γρήγορη αποθήκευση, αναζήτηση και ανάλυση ιστορικών μετρήσεων.

Σε βιομηχανικά και ενεργειακά περιβάλλοντα, μεγάλος αριθμός αισθητήρων και instrumentation συστημάτων παράγει συνεχώς δεδομένα λειτουργίας σε συγκεκριμένα χρονικά διαστήματα. Μετρήσεις όπως θερμοκρασίες, πιέσεις, κραδασμοί, ηλεκτρικά μεγέθη και λειτουργικές καταστάσεις εξοπλισμού δημιουργούν μεγάλους όγκους χρονοσειρών, οι οποίοι πρέπει να αποθηκεύονται με αποδοτικό τρόπο και να παραμένουν διαθέσιμοι για real-time monitoring και ιστορική ανάλυση.

Οι βάσεις δεδομένων χρονοσειρών σχεδιάστηκαν ώστε να καλύπτουν ακριβώς αυτές τις απαιτήσεις, παρέχοντας:

- υψηλή ταχύτητα εισαγωγής δεδομένων,
- αποδοτική αποθήκευση χρονοσειρών,
- γρήγορη εκτέλεση χρονικών queries,
- δυνατότητες aggregation και filtering,
- καθώς και μηχανισμούς διαχείρισης ιστορικών δεδομένων.

Η χρήση TSDB είναι ιδιαίτερα σημαντική σε εφαρμογές Industrial IoT και predictive maintenance, όπου απαιτείται συνεχής συλλογή και επεξεργασία δεδομένων από βιομηχανικό εξοπλισμό. Η δυνατότητα ανάλυσης ιστορικών μετρήσεων επιτρέπει την παρακολούθηση της συμπεριφοράς ενός συστήματος σε βάθος χρόνου και υποστηρίζει την ανάπτυξη condition monitoring και predictive analytics εφαρμογών.

Μία από τις πιο διαδεδομένες βάσεις δεδομένων χρονοσειρών σε εφαρμογές IoT και monitoring είναι η InfluxDB (InfluxData n.d.). Η συγκεκριμένη

πλατφόρμα χρησιμοποιείται ευρέως σε εφαρμογές συλλογής και οπτικοποίησης telemetry δεδομένων λόγω της απλής αρχιτεκτονικής, της υψηλής απόδοσης σε time-series workloads και της εύκολης διασύνδεσης με εργαλεία visualization και analytics.

Η InfluxDB υποστηρίζει:

- αποθήκευση δεδομένων σε πραγματικό χρόνο,
- χρονικά queries,
- aggregation functions,
- filtering και grouping δεδομένων,
- data retention policies,
- καθώς και εύκολη ενσωμάτωση με dashboards και monitoring εργαλεία.

Η δομή αποθήκευσης δεδομένων στην InfluxDB βασίζεται κυρίως στα ακόλουθα στοιχεία:

- measurements,
- tags,
- fields,
- timestamps.

Τα measurements χρησιμοποιούνται ως λογικές κατηγορίες δεδομένων, τα tags αποθηκεύουν metadata και πληροφορίες κατηγοριοποίησης, ενώ τα fields περιλαμβάνουν τις πραγματικές τιμές των μετρήσεων. Το timestamp αποτελεί βασικό στοιχείο κάθε εγγραφής, επιτρέποντας τη χρονική ταξινόμηση και ανάλυση των δεδομένων.

Στις εφαρμογές predictive maintenance, η δυνατότητα αποδοτικής διαχείρισης ιστορικών χρονοσειρών είναι ιδιαίτερα σημαντική, καθώς τα μοντέλα ανάλυσης και machine learning βασίζονται συχνά στη μελέτη της εξέλιξης λειτουργικών παραμέτρων σε βάθος χρόνου. Η συνεχής αποθήκευση δεδομένων λειτουργίας επιτρέπει τη δημιουργία datasets κατάλληλων για trend analysis, anomaly detection και predictive modeling.

Στην παρούσα εργασία, η InfluxDB χρησιμοποιείται ως το βασικό επίπεδο αποθήκευσης των λειτουργικών δεδομένων του συστήματος παρακολούθησης. Οι μετρήσεις που λαμβάνονται από τους αισθητηριακούς κόμβους αποθηκεύονται σε μορφή χρονοσειρών και στη συνέχεια αξιοποιούνται τόσο για real-time visualization μέσω Grafana όσο και για την ανάπτυξη και αξιολόγηση των predictive models της εφαρμογής.

## 2.5 Προγνωστική Συντήρηση και Μηχανική Μάθηση

Η μηχανική μάθηση (Machine Learning – ML) χρησιμοποιείται ολοένα και περισσότερο σε εφαρμογές προγνωστικής συντήρησης, καθώς προσφέρει τη δυνατότητα ανάλυσης μεγάλου όγκου λειτουργικών δεδομένων και αναγνώρισης προτύπων που σχετίζονται με τη συμπεριφορά του εξοπλισμού (Carvalho et al. 2019). Η αυξημένη διαθεσιμότητα βιομηχανικών δεδομένων μέσω συστημάτων Industrial IoT και condition monitoring έχει δημιουργήσει τις προϋποθέσεις για την αξιοποίηση τεχνικών machine learning σε εφαρμογές βιομηχανικής παρακολούθησης και predictive analytics.

Σε παραδοσιακά συστήματα monitoring, η αξιολόγηση της κατάστασης του εξοπλισμού βασίζεται συνήθως σε προκαθορισμένα alarm thresholds ή σε εμπειρικούς κανόνες λειτουργίας. Αντίθετα, οι τεχνικές μηχανικής μάθησης επιτρέπουν τη δημιουργία μοντέλων που μπορούν να “μάθουν” τη φυσιολογική συμπεριφορά ενός συστήματος μέσω ιστορικών δεδομένων και να εντοπίζουν αποκλίσεις ή μη φυσιολογικές συνθήκες λειτουργίας με πιο δυναμικό τρόπο.

Στις εφαρμογές predictive maintenance, οι αλγόριθμοι machine learning χρησιμοποιούνται κυρίως για:

- πρόβλεψη μελλοντικών τιμών λειτουργικών παραμέτρων,
- ανίχνευση ανωμαλιών (anomaly detection),
- εκτίμηση της κατάστασης εξοπλισμού,
- αναγνώριση τάσεων υποβάθμισης,
- και πρόβλεψη πιθανών αστοχιών.

Η βασική λογική πίσω από τις εφαρμογές predictive maintenance είναι ότι η συμπεριφορά ενός βιομηχανικού συστήματος μεταβάλλεται σταδιακά πριν από την εμφάνιση μιας σοβαρής δυσλειτουργίας. Μέσω της συνεχούς ανάλυσης λειτουργικών δεδομένων, τα μοντέλα machine learning μπορούν να αναγνωρίζουν τέτοιες μεταβολές και να παρέχουν έγκαιρες ενδείξεις πιθανής υποβάθμισης της λειτουργίας.

Οι μέθοδοι μηχανικής μάθησης διακρίνονται γενικά σε:

- supervised learning,
- unsupervised learning,

Στις supervised learning εφαρμογές, το μοντέλο εκπαιδεύεται χρησιμοποιώντας ιστορικά δεδομένα όπου είναι γνωστές οι επιθυμητές έξοδοι ή οι αναμενόμενες


τιμές (James et al. 2021, Géron 2022). Η προσέγγιση αυτή χρησιμοποιείται συχνά σε predictive modeling και regression προβλήματα, όπου στόχος είναι η πρόβλεψη συγκεκριμένων λειτουργικών μεγεθών.

Αντίθετα, οι unsupervised learning μέθοδοι χρησιμοποιούνται κυρίως για clustering και anomaly detection σε περιπτώσεις όπου δεν υπάρχουν προκαθορισμένες ετικέτες ή γνωστές καταστάσεις λειτουργίας. Οι reinforcement learning τεχνικές βασίζονται σε μηχανισμούς αλληλεπίδρασης και βελτιστοποίησης μέσω ανταμοιβής και χρησιμοποιούνται κυρίως σε πιο σύνθετα adaptive control συστήματα.

Στην παρούσα εργασία χρησιμοποιείται supervised learning προσέγγιση, όπου το μοντέλο εκπαιδεύεται με ιστορικά δεδομένα λειτουργίας του συστήματος ώστε να προβλέπει την αναμενόμενη συμπεριφορά συγκεκριμένων λειτουργικών παραμέτρων. Η διαδικασία αυτή επιτρέπει τη σύγκριση των predicted values με τις πραγματικές μετρήσεις λειτουργίας και τη μετέπειτα ανίχνευση αποκλίσεων ή ανωμαλιών.

Η αξιοποίηση machine learning σε εφαρμογές Industrial IoT και predictive maintenance παρουσιάζει ιδιαίτερο ενδιαφέρον, καθώς επιτρέπει τη μετάβαση από στατικά monitoring συστήματα σε περισσότερο “έξυπνες” και βασισμένες στην αξιοποίηση λειτουργικών δεδομένων αρχιτεκτονικές παρακολούθησης. Παράλληλα, η ενσωμάτωση predictive analytics σε Industrial IoT υποδομές δημιουργεί τη δυνατότητα ανάπτυξης πιο αποδοτικών στρατηγικών συντήρησης, με στόχο τη μείωση downtime, τη βελτίωση της αξιοπιστίας και τη βελτιστοποίηση της λειτουργίας βιομηχανικού εξοπλισμού.

## The Machine Learning Process



**Εικόνα 7** - Γενική διαδικασία ανάπτυξης μοντέλου μηχανικής μάθησης.

## 2.6 Ridge Regression

Η Ridge Regression αποτελεί μέθοδο γραμμικής παλινδρόμησης με regularization και χρησιμοποιείται ευρέως σε εφαρμογές machine learning για τη βελτίωση της σταθερότητας και της γενίκευσης των μοντέλων (Hoerl & Kennard 1970). Η τεχνική αυτή ανήκει στις supervised learning μεθόδους και εφαρμόζεται κυρίως σε προβλήματα regression, όπου στόχος είναι η πρόβλεψη συνεχών αριθμητικών μεγεθών με βάση ένα σύνολο δεδομένων εισόδου.

Στη βασική γραμμική παλινδρόμηση, το μοντέλο επιχειρεί να προσεγγίσει τη σχέση μεταξύ μεταβλητών εισόδου και εξόδου μέσω ενός γραμμικού συνδυασμού χαρακτηριστικών. Η πρόβλεψη προκύπτει από κατάλληλους συντελεστές βαρύτητας, οι οποίοι υπολογίζονται κατά τη διαδικασία εκπαίδευσης του μοντέλου.

Ωστόσο, σε πραγματικά βιομηχανικά datasets εμφανίζονται συχνά προβλήματα όπως:

- υψηλή συσχέτιση μεταξύ χαρακτηριστικών,
- παρουσία θορύβου στις μετρήσεις,
- μεγάλες διακυμάνσεις δεδομένων,
- και περιορισμένη δυνατότητα γενίκευσης του μοντέλου.

Σε τέτοιες περιπτώσεις, η απλή γραμμική παλινδρόμηση μπορεί να οδηγήσει σε overfitting, δηλαδή σε υπερβολική προσαρμογή του μοντέλου στα δεδομένα εκπαίδευσης, με αποτέλεσμα μειωμένη απόδοση σε νέα δεδομένα λειτουργίας.

Η Ridge Regression αντιμετωπίζει το πρόβλημα αυτό μέσω της προσθήκης ενός όρου regularization στη συνάρτηση κόστους (Hoerl, Kennard & Baldwin 1975, Hastie, Tibshirani & Friedman 2009). Ο επιπλέον αυτός όρος περιορίζει τις πολύ μεγάλες τιμές των συντελεστών του μοντέλου, οδηγώντας σε πιο σταθερές και πιο “ομαλές” λύσεις.

Η βασική σχέση της Ridge Regression δίνεται από:

$$\min_{\beta} \|y - X\beta\|^2 + \alpha \|\beta\|^2$$

όπου:

- $X$  είναι το σύνολο χαρακτηριστικών εισόδου,
- $y$  είναι η μεταβλητή στόχος,
- $\beta$  είναι οι συντελεστές του μοντέλου,
- και  $\alpha$  είναι η παράμετρος regularization.

Η παράμετρος  $\alpha$  καθορίζει τον βαθμό regularization του μοντέλου. Μεγαλύτερες τιμές οδηγούν σε ισχυρότερο περιορισμό των συντελεστών, μειώνοντας την

πιθανότητα overfitting αλλά ταυτόχρονα επηρεάζοντας την ευαισθησία του μοντέλου στις μεταβολές των δεδομένων.

Η Ridge Regression παρουσιάζει ιδιαίτερο ενδιαφέρον σε εφαρμογές βιομηχανικών χρονοσειρών και predictive maintenance, καθώς τα λειτουργικά δεδομένα αισθητήρων εμφανίζουν συχνά υψηλή συσχέτιση μεταξύ μεταβλητών. Για παράδειγμα, μεταβολές πίεσης, θερμοκρασίας και λειτουργικών φορτίων ενός συμπιεστή μπορεί να επηρεάζονται ταυτόχρονα από κοινές συνθήκες λειτουργίας του συστήματος.

Η χρήση regularized regression επιτρέπει την ανάπτυξη πιο σταθερών predictive models και συμβάλλει στη μείωση της επίδρασης θορύβου ή ακραίων τιμών στις προβλέψεις. Επιπλέον, η σχετικά απλή δομή του μοντέλου προσφέρει μειωμένες υπολογιστικές απαιτήσεις και ευκολότερη ερμηνεία των αποτελεσμάτων σε σχέση με πιο σύνθετες τεχνικές machine learning.

Στην παρούσα εργασία, η Ridge Regression χρησιμοποιείται για την εκτίμηση της αναμενόμενης συμπεριφοράς λειτουργικών παραμέτρων του συστήματος, με στόχο τη σύγκριση predicted και πραγματικών τιμών και την υποστήριξη της διαδικασίας ανίχνευσης ανωμαλιών. Η επιλογή της συγκεκριμένης μεθόδου βασίστηκε τόσο στη σταθερότητά της σε time-series δεδομένα όσο και στη δυνατότητα ανάπτυξης ενός χαμηλών υπολογιστικών απαιτήσεων και computationally efficient predictive model κατάλληλου για Industrial IoT εφαρμογές.

## 2.7 Feature Engineering σε Χρονοσειρές

Το feature engineering αποτελεί ιδιαίτερα σημαντικό στάδιο στην ανάπτυξη μοντέλων μηχανικής μάθησης για εφαρμογές χρονοσειρών και predictive maintenance (Kuhn & Johnson 2019, Zheng & Casari 2018). Στόχος της διαδικασίας είναι η δημιουργία νέων χαρακτηριστικών (features) από τα αρχικά δεδομένα, ώστε το μοντέλο να μπορεί να αναγνωρίζει αποτελεσματικότερα πρότυπα λειτουργίας και χρονικές συσχετίσεις του συστήματος.

Σε εφαρμογές βιομηχανικής παρακολούθησης, τα δεδομένα αισθητήρων δεν αποτελούν απλές ανεξάρτητες μετρήσεις αλλά συνδέονται άμεσα με τη χρονική εξέλιξη της λειτουργίας του εξοπλισμού. Για τον λόγο αυτό, η αξιοποίηση μόνο της στιγμιαίας τιμής μιας μεταβλητής συχνά δεν είναι επαρκής για την περιγραφή της συνολικής λειτουργικής κατάστασης ενός συστήματος.

Το feature engineering επιτρέπει τη μετατροπή των αρχικών χρονοσειρών σε πιο “πλούσια” datasets, τα οποία περιλαμβάνουν πληροφορία σχετική με:

- τη χρονική συμπεριφορά του συστήματος,
- τις μεταβολές λειτουργίας,
- τις τάσεις εξέλιξης,
- καθώς και τη στατιστική συμπεριφορά των μετρήσεων.

Σε εφαρμογές predictive maintenance χρησιμοποιούνται συχνά τεχνικές όπως:

- lag features,
- rolling averages,
- rolling standard deviations,
- rate of change,
- moving windows.

Τα lag features επιτρέπουν στο μοντέλο να λαμβάνει υπόψη προηγούμενες χρονικές τιμές μιας μεταβλητής, εισάγοντας έτσι πληροφορία σχετική με την ιστορική κατάσταση του συστήματος (Brownlee 2019). Για παράδειγμα, η τρέχουσα θερμοκρασία λειτουργίας ενός συμπιεστή μπορεί να επηρεάζεται σημαντικά από τις προηγούμενες συνθήκες φόρτισης και λειτουργίας του.

Οι rolling averages και rolling standard deviations χρησιμοποιούνται για την αποτύπωση της βραχυχρόνιας τάσης και της μεταβλητότητας των δεδομένων μέσα σε συγκεκριμένα χρονικά παράθυρα. Οι τεχνικές αυτές βοηθούν στη μείωση του θορύβου των μετρήσεων και επιτρέπουν την καλύτερη αναγνώριση σταδιακών μεταβολών στη συμπεριφορά του εξοπλισμού.

Αντίστοιχα, οι δείκτες rate of change χρησιμοποιούνται για την εκτίμηση του ρυθμού μεταβολής μιας παραμέτρου, στοιχείο ιδιαίτερα χρήσιμο σε εφαρμογές condition monitoring όπου απότομες μεταβολές λειτουργικών μεγεθών μπορεί να αποτελούν ένδειξη μη φυσιολογικής λειτουργίας.

Η χρήση moving windows επιτρέπει την ανάλυση της συμπεριφοράς των δεδομένων μέσα σε συγκεκριμένα χρονικά διαστήματα, διευκολύνοντας την εξαγωγή στατιστικών χαρακτηριστικών και την ανάπτυξη predictive models με καλύτερη κατανόηση της χρονικής δυναμικής του συστήματος.

Εκτός από τη δημιουργία νέων χαρακτηριστικών, ιδιαίτερα σημαντικό στάδιο στην επεξεργασία δεδομένων αποτελεί και η κανονικοποίηση (normalization) ή τυποποίηση (standardization) των μεταβλητών. Σε βιομηχανικά datasets, διαφορετικές παράμετροι μπορεί να εμφανίζουν πολύ διαφορετικές κλίμακες τιμών, γεγονός που μπορεί να επηρεάσει τη διαδικασία εκπαίδευσης των μοντέλων machine learning.

Για τον λόγο αυτό, χρησιμοποιείται συχνά standardization μέσω z-score normalization, ώστε οι μεταβλητές να αποκτούν συγκρίσιμη κλίμακα και μηδενικό μέσο όρο.

Ο υπολογισμός του z-score δίνεται από τη σχέση:

$$z = (x - \mu) / \sigma$$

όπου:

- $x$  είναι η αρχική τιμή,
- $\mu$  είναι ο μέσος όρος,
- $\sigma$  είναι η τυπική απόκλιση.

Η διαδικασία standardization συμβάλλει στη σταθερότερη εκπαίδευση των μοντέλων και μειώνει την επίδραση των διαφορετικών κλιμάκων μεταξύ των μεταβλητών. Η χρήση κατάλληλων feature engineering τεχνικών αποτελεί κρίσιμο μέρος της ανάπτυξης predictive maintenance εφαρμογών, καθώς επηρεάζει άμεσα την ποιότητα των δεδομένων εισόδου και κατά συνέπεια την απόδοση των μοντέλων μηχανικής μάθησης.

### 3. Αρχιτεκτονική και Υλοποίηση του Συστήματος

#### 3.1

##### Συνολική Αρχιτεκτονική Συστήματος

Η παρούσα εργασία βασίζεται στην ανάπτυξη μιας ολοκληρωμένης αρχιτεκτονικής Industrial IoT για εφαρμογές προγνωστικής συντήρησης βιομηχανικού εξοπλισμού. Η συνολική υποδομή σχεδιάστηκε με στόχο τη δημιουργία ενός αρθρωτής λογικής και επεκτάσιμου συστήματος ικανού να συλλέγει, να μεταδίδει, να επεξεργάζεται, να αποθηκεύει και να αναλύει λειτουργικά δεδομένα σε πραγματικό χρόνο.

Η φιλοσοφία σχεδιασμού της αρχιτεκτονικής βασίστηκε σε λογική αντίστοιχη πραγματικών industrial monitoring systems, όπου διαφορετικά επίπεδα λειτουργίας συνεργάζονται μεταξύ τους μέσω σαφώς ορισμένων communication layers. Η προσέγγιση αυτή επιτρέπει ευκολότερη επεκτασιμότητα, καλύτερη διαχείριση των επιμέρους υπηρεσιών και δυνατότητα μελλοντικής ενσωμάτωσης πρόσθετων αισθητήρων, analytics modules ή συστημάτων αυτοματισμού.

Η συνολική αρχιτεκτονική του συστήματος διαχωρίζεται στα ακόλουθα επίπεδα:

- επίπεδο συλλογής δεδομένων και αισθητήρων,

- επίπεδο ασύρματης επικοινωνίας LoRaWAN,
- επίπεδο διαχείρισης και δρομολόγησης δεδομένων,
- επίπεδο επεξεργασίας δεδομένων,
- επίπεδο αποθήκευσης χρονοσειρών,
- επίπεδο οπτικοποίησης και predictive analytics.


Οι αισθητηριακοί κόμβοι προσομοιώνουν την συλλογή λειτουργικών δεδομένων του βιομηχανικού συμπιεστή και τα μεταδίδουν μέσω LoRaWAN προς το gateway. Στη συνέχεια, τα δεδομένα προωθούνται μέσω του ChirpStack LoRaWAN Network Server και του MQTT communication layer προς το Node-RED, όπου πραγματοποιείται η επεξεργασία, αποκωδικοποίηση και δρομολόγηση των μετρήσεων.

Μετά την επεξεργασία τους, τα δεδομένα αποθηκεύονται στη βάση δεδομένων χρονοσειρών InfluxDB και χρησιμοποιούνται τόσο για real-time visualization μέσω Grafana όσο και για την ανάπτυξη predictive models και μηχανισμών anomaly detection.

Η αρχιτεκτονική σχεδιάστηκε με κριτήριο την φιλοσοφία των πραγματικών Industrial IoT deployments, όπου η ανεξαρτησία των επιμέρους επιπέδων αποτελεί σημαντικό στοιχείο αξιοπιστίας και επεκτασιμότητας. Επίσης η αρχιτεκτονική που χρησιμοποιήθηκε στοχεύει σε:

- αρθρωτή λογική ανάπτυξης,
- χρήση open-source τεχνολογιών,
- δυνατότητα εύκολης διασύνδεσης επιμέρους συστημάτων,
- δημιουργία ενός ευέλικτου Industrial IoT environment κατάλληλου για monitoring εφαρμογές.

Η συνολική υποδομή μπορεί να θεωρηθεί ως ένα ολοκληρωμένου Industrial IoT pipeline, στο οποίο τα λειτουργικά δεδομένα μεταφέρονται από το επίπεδο του αισθητήρα μέχρι το επίπεδο predictive analytics μέσω διακριτών αλλά πλήρως διασυνδεδεμένων υποσυστημάτων.




**Εικόνα 8 - Αρχιτεκτονική Συστήματος Predictive Maintenance**

### 3.2 Αισθητηριακοί Κόμβοι

Για την υλοποίηση των αισθητηριακών κόμβων χρησιμοποιήθηκαν μικροελεγκτές Raspberry Pi Pico RP2040 σε συνδυασμό με LoRa communication modules SX1262. Η επιλογή της συγκεκριμένης πλατφόρμας βασίστηκε κυρίως στη χαμηλή κατανάλωση ισχύος, στη διαθεσιμότητα open-source εργαλείων ανάπτυξης και στη δυνατότητα εύκολης ενσωμάτωσης σε εφαρμογές Industrial IoT.

Ο Raspberry Pi Pico RP2040 αποτελεί μία compact και χαμηλού κόστους πλατφόρμα μικροελεγκτή, κατάλληλη για εφαρμογές embedded συστημάτων και Industrial IoT. Διαθέτει δυνατότητες διασύνδεσης με αισθητήρες και modules επικοινωνίας, ενώ υποστηρίζει ανάπτυξη εφαρμογών μέσω open-source εργαλείων και περιβαλλόντων προγραμματισμού. Στην παρούσα εργασία χρησιμοποιήθηκε ως βασική edge συσκευή των αισθητηριακών κόμβων για τη συλλογή και ασύρματη μετάδοση λειτουργικών δεδομένων μέσω LoRaWAN.



**Εικόνα 9 – Αισθητηριακός κόμβος LoRaWAN βασισμένος σε Raspberry Pi Pico RP2040 και SX1262.**

### **Βασικά Χαρακτηριστικά Raspberry Pi Pico RP2040**

| Χαρακτηριστικό          | Περιγραφή                       |
|-------------------------|---------------------------------|
| Μικροελεγκτής           | RP2040                          |
| Αρχιτεκτονική CPU       | Dual-core ARM Cortex-M0+        |
| Συχνότητα λειτουργίας   | Έως 133 MHz                     |
| SRAM                    | 264 KB                          |
| Flash Memory            | 2 MB onboard                    |
| GPIO Pins               | 26                              |
| ADC Inputs              | 3                               |
| Πρωτόκολλα επικοινωνίας | UART, SPI, I2C                  |
| USB Support             | USB 1.1                         |
| Τάση λειτουργίας GPIO   | 3.3 V                           |
| Περιβάλλον ανάπτυξης    | C/C++, MicroPython, Arduino IDE |

Το SX1262 αποτελεί RF communication module τεχνολογίας LoRa, σχεδιασμένο για εφαρμογές ασύρματης επικοινωνίας μεγάλης εμβέλειας και χαμηλής κατανάλωσης ισχύος. Χρησιμοποιείται ευρέως σε εφαρμογές IoT και Industrial IoT λόγω της δυνατότητας αξιόπιστης μετάδοσης μικρού όγκου δεδομένων σε μεγάλες αποστάσεις. Το module υποστηρίζει επικοινωνία μέσω πρωτοκόλλου LoRaWAN και μπορεί να διασυνδεθεί εύκολα με μικροελεγκτές μέσω SPI interface. Στην παρούσα εργασία χρησιμοποιήθηκε για την ασύρματη μετάδοση των δεδομένων των αισθητηριακών κόμβων προς το LoRaWAN gateway της αρχιτεκτονικής.

### **Βασικά Χαρακτηριστικά SX1262 LoRa Module**

| Χαρακτηριστικό          | Περιγραφή     |
|-------------------------|---------------|
| RF Chip                 | SX1262        |
| Τεχνολογία επικοινωνίας | LoRa / (G)FSK |

| Χαρακτηριστικό            | Περιγραφή     |
|---------------------------|---------------|
| Συχνότητα λειτουργίας     | 150 – 960 MHz |
| Μέγιστη ισχύς εκπομπής    | +22 dBm       |
| Ευαισθησία δέκτη          | Έως -148 dBm  |
| Communication Interface   | SPI           |
| Μέγιστο LoRa Data Rate    | 62.5 kbps     |
| Μέγιστο FSK Data Rate     | 300 kbps      |
| Κατανάλωση RX             | ~4.6 mA       |
| Υποστηριζόμενα πρωτόκολλα | LoRaWAN       |

Κάθε κόμβος λειτουργεί ως edge συσκευή συλλογής και μετάδοσης δεδομένων. Στην παρούσα εργασία δεν χρησιμοποιήθηκαν φυσικοί αισθητήρες πεδίου, αλλά πραγματοποιήθηκε προσομοίωση λειτουργικών δεδομένων βιομηχανικού συμπίεστή μέσω ιστορικών datasets. Η προσέγγιση αυτή επέτρεψε την ανάπτυξη και αξιολόγηση της συνολικής Industrial IoT αρχιτεκτονικής χωρίς την ανάγκη πραγματικής εγκατάστασης instrumentation εξοπλισμού, κάτι το οποίο θα ήταν αδύνατο να πραγματοποιηθεί καθώς θα απαιτούσε παρέμβαση σε εξοπλισμό κρίσιμης υποδομής.

Τα δεδομένα που χρησιμοποιήθηκαν περιλάμβαναν:

- θερμοκρασίες λειτουργίας,
- πιέσεις αναρρόφησης και κατάθλιψης,
- επίπεδα κραδασμών,
- αξονικές μετατοπίσεις,
- καθώς και επιμέρους λειτουργικές μεταβλητές του συμπίεστή.

Οι αισθητηριακοί κόμβοι αναπτύχθηκαν σε περιβάλλον Arduino IDE και προγραμματίστηκαν ώστε:

- να διαβάζουν δεδομένα από προκαθορισμένα datasets,
- να δημιουργούν telemetry payloads,
- να μεταδίδουν περιοδικά uplink μηνύματα μέσω LoRaWAN,

- και να προσομοιώνουν λειτουργία πραγματικών Industrial IoT edge devices.

Για την υλοποίηση της LoRaWAN επικοινωνίας χρησιμοποιήθηκε η βιβλιοθήκη RadioLib, ενώ η διαδικασία σύνδεσης των συσκευών στο δίκτυο βασίστηκε σε μηχανισμό OTAA (Over-The-Air Activation). Η συγκεκριμένη προσέγγιση επιλέχθηκε λόγω της αυξημένης ευελιξίας και της ασφαλέστερης διαχείρισης των credentials των συσκευών.

Η περιοδικότητα αποστολής των δεδομένων ορίστηκε σε διαστήματα ενός λεπτού, προσομοιώνοντας typical industrial monitoring εφαρμογές condition monitoring και telemetry collection.

### 3.3 Πύλη Επικοινωνίας LoRaWAN

Ως LoRaWAN gateway χρησιμοποιήθηκε Raspberry Pi 4 εξοπλισμένο με WaveShare SX1302 LoRaWAN Gateway HAT. Το gateway λειτουργεί ως το βασικό σημείο διασύνδεσης μεταξύ των αισθητηριακών συσκευών LoRaWAN και της υπόλοιπης IP-based υποδομής του συστήματος.

Ο Raspberry Pi 4 αποτελεί μία single-board υπολογιστική πλατφόρμα μικρού μεγέθους, η οποία χρησιμοποιείται ευρέως σε εφαρμογές edge computing, αυτοματισμών και Industrial IoT. Παρέχει αυξημένες δυνατότητες επεξεργασίας και δικτύωσης σε σχέση με κλασικούς μικροελεγκτές, υποστηρίζοντας λειτουργικά συστήματα Linux και μεγάλο αριθμό open-source εφαρμογών και υπηρεσιών. Στην παρούσα εργασία χρησιμοποιήθηκε ως η βασική υπολογιστική μονάδα του LoRaWAN gateway και της συνολικής υποδομής διαχείρισης δεδομένων.



**Εικόνα 10-** LoRaWAN gateway της εφαρμογής.

### **Βασικά Χαρακτηριστικά Raspberry Pi 4**

| Χαρακτηριστικό        | Περιγραφή                 |
|-----------------------|---------------------------|
| Μοντέλο               | Raspberry Pi 4 Model B    |
| Επεξεργαστής          | Quad-core ARM Cortex-A72  |
| Συχνότητα λειτουργίας | 1.5 GHz                   |
| Μνήμη RAM             | 2 GB / 4 GB / 8 GB        |
| Λειτουργικό σύστημα   | Linux-based               |
| Δίκτυο                | Ethernet, Wi-Fi           |
| Θύρες επικοινωνίας    | USB, GPIO, SPI, I2C, UART |
| Τροφοδοσία            | 5V USB-C                  |

Το Waveshare SX1302 LoRaWAN Gateway HAT αποτελεί LoRaWAN gateway module βασισμένο στο chipset SX1302 και σχεδιασμένο για χρήση με πλατφόρμες όπως το Raspberry Pi. Υποστηρίζει ταυτόχρονη διαχείριση πολλαπλών LoRa καναλιών και χρησιμοποιείται για τη λήψη και προώθηση δεδομένων από LoRa end devices προς τον LoRaWAN Network Server. Η πλατφόρμα είναι κατάλληλη για ανάπτυξη private LoRaWAN δικτύων και εφαρμογών Industrial IoT monitoring. Στην παρούσα εργασία χρησιμοποιήθηκε ως το βασικό gateway interface μεταξύ των αισθητηριακών κόμβων και της υπόλοιπης IP-based υποδομής του συστήματος.

### **Βασικά Χαρακτηριστικά 1302**

| Χαρακτηριστικό            | Περιγραφή             |
|---------------------------|-----------------------|
| RF Chipset                | SX1302                |
| Τεχνολογία επικοινωνίας   | LoRaWAN               |
| Συχνότητα λειτουργίας     | 868 MHz (EU)          |
| Interface με Raspberry Pi | SPI                   |
| Υποστήριξη καναλιών       | Multi-channel LoRaWAN |
| Υποστηριζόμενα πρωτόκολλα | LoRa / LoRaWAN        |
| Κατανάλωση ισχύος         | Χαμηλή                |

| Χαρακτηριστικό | Περιγραφή                    |
|----------------|------------------------------|
| Χρήση          | LoRaWAN Gateway Applications |

Ο ρόλος του gateway είναι η λήψη των LoRa packets από τους αισθητηριακούς κόμβους και η προώθησή τους προς τον LoRaWAN Network Server μέσω IP δικτύου. Με τον τρόπο αυτό επιτυγχάνεται ο διαχωρισμός μεταξύ του wireless communication layer και του επιπέδου διαχείρισης και επεξεργασίας δεδομένων.


Το λειτουργικό περιβάλλον του gateway βασίστηκε σε Linux, ενώ εγκαταστάθηκε ChirpStack Gateway OS για την υποστήριξη packet forwarding και τη διαχείριση της LoRaWAN επικοινωνίας. Η επιλογή open-source λογισμικού επέτρεψε μεγαλύτερη ευελιξία παραμετροποίησης και καλύτερη κατανόηση της λειτουργίας του communication stack.

Η χρήση gateway πολλαπλών καναλιών επιτρέπει την ταυτόχρονη εξυπηρέτηση πολλών end devices και προσομοιώνει περισσότερο πραγματικές συνθήκες ανάπτυξης Industrial IoT δικτύων μεγάλης κλίμακας.

### 3.4 ChirpStack LoRaWAN Server

Για τη διαχείριση του δικτύου LoRaWAN χρησιμοποιήθηκε το ChirpStack, ένα open-source LoRaWAN Network Server ιδιαίτερα διαδεδομένο σε εφαρμογές private LoRaWAN deployments και Industrial IoT υποδομών.

Το ChirpStack OS εγκαταστάθηκε στο Raspberry Pi 4 και χρησιμοποιήθηκε ως η βασική πλατφόρμα διαχείρισης του LoRaWAN δικτύου της εφαρμογής. Η πλατφόρμα περιλαμβάνει τα βασικά επίπεδα λειτουργίας ενός LoRaWAN συστήματος, όπως το Network Server και το Application Server, επιτρέποντας τη διαχείριση των end devices, τη δρομολόγηση των δεδομένων και την επικοινωνία με εξωτερικές εφαρμογές επεξεργασίας και αποθήκευσης δεδομένων. Μέσω του ChirpStack πραγματοποιείται η παρακολούθηση της κατάστασης των συσκευών, η διαχείριση των uplink μηνυμάτων και η προώθηση των δεδομένων μέσω MQTT προς το υπόλοιπο Industrial IoT pipeline της αρχιτεκτονικής.



**Εικόνα 11** - Περιβάλλον διαχείρισης ChirpStack.

Το ChirpStack αναλαμβάνει:

- τη διαχείριση των end devices,
- τη διαδικασία authentication,
- τη διαχείριση OTAA joins,
- τη δρομολόγηση uplink και downlink μηνυμάτων,
- καθώς και τη διασύνδεση με εξωτερικά συστήματα μέσω MQTT interfaces.

Στο περιβάλλον του ChirpStack δημιουργήθηκαν applications και end devices, ενώ κάθε αισθητηριακός κόμβος αντιστοιχίστηκε σε μοναδικό DevEUI. Η πλατφόρμα χρησιμοποιήθηκε ως το βασικό επίπεδο διαχείρισης της LoRaWAN υποδομής και παρέιχε δυνατότητες:

- monitoring της κατάστασης των συσκευών,
- παρακολούθησης uplink traffic,
- debugging συνδέσεων,
- καθώς και ελέγχου παραμέτρων επικοινωνίας όπως RSSI και SNR.

Η επιλογή του ChirpStack βασίστηκε κυρίως:

- στη δυνατότητα ανάπτυξης private LoRaWAN δικτύου,
- στη χρήση open-source τεχνολογιών,
- στην εύκολη ενσωμάτωση με MQTT infrastructures,
- και στη δυνατότητα πλήρους παραμετροποίησης της πλατφόρμας.

### 3.5 Επίπεδο Επικοινωνίας MQTT

Η ανταλλαγή δεδομένων μεταξύ του ChirpStack και του επιπέδου επεξεργασίας πραγματοποιήθηκε μέσω του πρωτοκόλλου MQTT. Το MQTT αποτέλεσε το βασικό communication layer μεταξύ των διαφορετικών components της αρχιτεκτονικής, επιτρέποντας τη δημιουργία ενός αρθρωτής λογικής και loosely-coupled data pipeline.

Το MQTT (Message Queuing Telemetry Transport) αποτελεί χαμηλών υπολογιστικών απαιτήσεων πρωτόκολλο επικοινωνίας τύπου publish/subscribe, σχεδιασμένο για εφαρμογές ανταλλαγής τηλεμετρικών δεδομένων με χαμηλές απαιτήσεις bandwidth και περιορισμένη επιβάρυνση δικτύου. Στην αρχιτεκτονική MQTT, οι συσκευές και οι εφαρμογές επικοινωνούν μέσω ενός κεντρικού broker χρησιμοποιώντας topics για τη δημοσίευση και λήψη δεδομένων. Η απλή δομή και η ευκολία ενσωμάτωσης του πρωτοκόλλου το καθιστούν ιδιαίτερα κατάλληλο για εφαρμογές Industrial IoT και real-time monitoring. Στην παρούσα εργασία το MQTT χρησιμοποιήθηκε ως το βασικό communication layer μεταξύ του ChirpStack και του συστήματος επεξεργασίας δεδομένων, επιτρέποντας τη δρομολόγηση των telemetry δεδομένων προς το Node-RED και τις υπόλοιπες υπηρεσίες της αρχιτεκτονικής.

Το ChirpStack δημοσίευε τα uplink δεδομένα σε MQTT topics ακολουθώντας τη μορφή:

application/+/device/+/event/up

Τα δεδομένα μεταφέρονταν σε μορφή JSON και περιλάμβαναν:

- metadata επικοινωνίας,
- timestamps,
- πληροφορίες συσκευών,
- encoded payloads,
- καθώς και στοιχεία σχετικά με την κατάσταση του δικτύου.

Η χρήση MQTT επέτρεψε:


- ασύγχρονη ανταλλαγή δεδομένων,
- εύκολη επεκτασιμότητα του συστήματος,
- μικρή επιβάρυνση δικτύου,
- και απλοποιημένη διασύνδεση μεταξύ διαφορετικών υπηρεσιών και εφαρμογών.

Για τον έλεγχο και debugging της επικοινωνίας χρησιμοποιήθηκαν εργαλεία όπως το mosquitto\_sub, επιτρέποντας την παρακολούθηση των MQTT μηνυμάτων σε πραγματικό χρόνο και τον έλεγχο της σωστής ροής των δεδομένων μέσα στο σύστημα.

### 3.6 Επεξεργασία Δεδομένων με Node-RED

Το Node-RED χρησιμοποιήθηκε ως το βασικό περιβάλλον επεξεργασίας, αποκωδικοποίησης και διαχείρισης των δεδομένων της εφαρμογής. Η επιλογή του συγκεκριμένου εργαλείου βασίστηκε κυρίως στη δυνατότητα γρήγορης ανάπτυξης Industrial IoT data flows και στην ευκολία διασύνδεσης διαφορετικών communication protocols και υπηρεσιών.

Το Node-RED αποτελεί open-source πλατφόρμα ανάπτυξης και διαχείρισης data flows, σχεδιασμένη για εφαρμογές IoT, αυτοματισμών και Industrial IoT (OpenJS Foundation n.d.). Βασίζεται σε περιβάλλον οπτικού προγραμματισμού (flow-based programming), επιτρέποντας τη διασύνδεση διαφορετικών συσκευών, πρωτοκόλλων επικοινωνίας και υπηρεσιών μέσω έτοιμων ή custom nodes. Η πλατφόρμα υποστηρίζει εύκολη ενσωμάτωση με MQTT, βάσεις δεδομένων, APIs και συστήματα επεξεργασίας δεδομένων, καθιστώντας την ιδιαίτερα κατάλληλη για εφαρμογές real-time monitoring και telemetry processing.



**Εικόνα 12** – Flow επεξεργασίας δεδομένων στο Node-RED.

Στην παρούσα εργασία το Node-RED χρησιμοποιήθηκε για τη λήψη των MQTT δεδομένων από το ChirpStack, την αποκωδικοποίηση και επεξεργασία των

payloads, καθώς και τη δρομολόγηση των δεδομένων προς τη βάση δεδομένων και τα υπόλοιπα επίπεδα της αρχιτεκτονικής.

Στο Node-RED αναπτύχθηκαν flows τα οποία:

- λαμβάνουν MQTT μηνύματα,
- πραγματοποιούν parsing JSON δεδομένων,
- αποκωδικοποιούν τα encoded payloads,
- μετατρέπουν τις τιμές σε πραγματικές φυσικές μονάδες,
- και δρομολογούν τις μετρήσεις προς τη βάση δεδομένων.

Η επεξεργασία των δεδομένων πραγματοποιήθηκε μέσω Function nodes σε JavaScript, επιτρέποντας την ανάπτυξη custom logic για decoding, validation και preprocessing των telemetry δεδομένων.

Επιπλέον, δημιουργήθηκαν διαφορετικές ροές επεξεργασίας για κάθε αισθητηριακό κόμβο, με βάση το DevEUI των συσκευών. Το Node-RED χρησιμοποιήθηκε επίσης για:

- debugging των δεδομένων,
- monitoring των data flows,
- validation payloads,
- και real-time έλεγχο των μετασχηματισμών των δεδομένων.

Η χρήση του Node-RED επέτρεψε τη δημιουργία ενός ευέλικτου processing layer, κατάλληλου για Industrial IoT εφαρμογές και εύκολα επεκτάσιμου με επιπλέον services ή analytics modules.

### 3.7 Αποθήκευση Δεδομένων με InfluxDB

Η αποθήκευση των δεδομένων πραγματοποιήθηκε μέσω της βάσης δεδομένων χρονοσειρών InfluxDB, η οποία χρησιμοποιήθηκε ως το βασικό storage layer της εφαρμογής.

Η InfluxDB αποτελεί open-source βάση δεδομένων χρονοσειρών (Time-Series Database – TSDB), σχεδιασμένη για την αποθήκευση και διαχείριση δεδομένων που συνοδεύονται από χρονική σήμανση (InfluxData n.d.). Χρησιμοποιείται ευρέως σε εφαρμογές monitoring, telemetry και Industrial IoT λόγω της δυνατότητας αποδοτικής διαχείρισης μεγάλου όγκου χρονοσειρών και της γρήγορης εκτέλεσης χρονικών queries. Η πλατφόρμα υποστηρίζει real-time αποθήκευση δεδομένων, aggregation functions και εύκολη ενσωμάτωση με εργαλεία visualization και analytics. Στην παρούσα εργασία η InfluxDB

χρησιμοποιήθηκε ως το βασικό επίπεδο αποθήκευσης των λειτουργικών δεδομένων του συστήματος, επιτρέποντας την καταγραφή, ιστορική παρακολούθηση και αξιοποίηση των telemetry δεδομένων για visualization και predictive analytics εφαρμογές.

Η βάση δεδομένων εγκαταστάθηκε σε Docker container και οργανώθηκε ώστε να υποστηρίζει:

- αποθήκευση measurements,
- tags ανά συσκευή,
- χρονικές σημάνσεις,
- γρήγορα historical queries,
- και efficient time-series data handling.

Τα δεδομένα που αποθηκεύονταν περιλάμβαναν:

- outlet temperature,
- suction pressure,
- discharge pressure,
- vibration values,
- predicted values,
- anomaly indicators.

Η επιλογή της InfluxDB βασίστηκε στη βελτιστοποίησή της για time-series δεδομένα και στην εύκολη ενσωμάτωσή της με visualization και analytics εργαλεία όπως το Grafana.

### 3.8 Οπτικοποίηση Δεδομένων με Grafana

Για την οπτικοποίηση και παρακολούθηση των δεδομένων χρησιμοποιήθηκε η πλατφόρμα Grafana. Μέσω του Grafana αναπτύχθηκαν dashboards πραγματικού χρόνου για την παρακολούθηση της κατάστασης λειτουργίας του συστήματος και την ανάλυση των ιστορικών χρονοσειρών.



**Εικόνα 13** - Dashboard παρακολούθησης λειτουργικών δεδομένων στο Grafana.

Το Grafana αποτελεί open-source πλατφόρμα οπτικοποίησης και παρακολούθησης δεδομένων, σχεδιασμένη για εφαρμογές monitoring, telemetry και Industrial IoT (Grafana Labs n.d.). Παρέχει δυνατότητες δημιουργίας δυναμικών dashboards και real-time visualization δεδομένων από διαφορετικές πηγές, όπως βάσεις δεδομένων χρονοσειρών και monitoring systems. Μέσω του Grafana μπορούν να παρουσιαστούν γραφήματα, χρονοσειρές, alarms και δείκτες λειτουργίας εξοπλισμού, διευκολύνοντας την παρακολούθηση και ανάλυση βιομηχανικών δεδομένων. Στην παρούσα εργασία το Grafana χρησιμοποιήθηκε για την ανάπτυξη dashboards παρακολούθησης των λειτουργικών δεδομένων του συστήματος και την οπτικοποίηση τόσο των πραγματικών μετρήσεων όσο και των αποτελεσμάτων των predictive models.

Τα dashboards περιλάμβαναν:

- λειτουργικές μετρήσεις συμπιεστή,
- ιστορικές χρονοσειρές,
- predicted vs actual values,
- καθώς και indicators ανίχνευσης ανωμαλιών.

Η πλατφόρμα παρείχε δυνατότητες:

- real-time visualization,
- zoom σε χρονικές περιόδους,

- συγκριτική ανάλυση μεταβλητών,
- και παρακολούθηση της χρονικής εξέλιξης της συμπεριφοράς του συστήματος.

Η χρήση Grafana επέτρεψε τη δημιουργία ενός περιβάλλον παρακολούθησης αντίστοιχου με σύγχρονες industrial monitoring εφαρμογές και διευκόλυνε σημαντικά τόσο την αξιολόγηση της λειτουργίας του συστήματος όσο και τη διαδικασία debugging και validation των δεδομένων.

### 3.9 Containerized Υποδομή και Docker

Για την ανάπτυξη και εκτέλεση των επιμέρους υπηρεσιών χρησιμοποιήθηκε containerized αρχιτεκτονική μέσω Docker και Docker Compose.

Η containerized υποδομή σημαίνει ότι οι βασικές υπηρεσίες του συστήματος δεν εγκαταστάθηκαν απευθείας ως ανεξάρτητα προγράμματα στο λειτουργικό σύστημα, αλλά εκτελέστηκαν μέσα σε απομονωμένα περιβάλλοντα, τα οποία ονομάζονται containers. Με τον τρόπο αυτό, κάθε υπηρεσία λειτουργεί με τις δικές της ρυθμίσεις και εξαρτήσεις, χωρίς να επηρεάζει άμεσα τις υπόλοιπες υπηρεσίες ή το βασικό λειτουργικό σύστημα.

Στην παρούσα εργασία, η containerized αρχιτεκτονική υλοποιήθηκε με χρήση Docker και Docker Compose. Οι υπηρεσίες Node-RED, InfluxDB και Grafana οργανώθηκαν σε ένα ενιαίο Docker stack, ώστε να μπορούν να εκκινούν, να σταματούν και να παραμετροποιούνται με πιο ελεγχόμενο και επαναλήψιμο τρόπο. Το Node-RED χρησιμοποιήθηκε για την επεξεργασία των δεδομένων, η InfluxDB για την αποθήκευση των χρονοσειρών και το Grafana για την οπτικοποίηση των μετρήσεων.

Η χρήση Docker προσέφερε καλύτερη οργάνωση της υποδομής, ευκολότερη διαχείριση των υπηρεσιών και μεγαλύτερη φορητότητα του συστήματος. Παράλληλα, διευκόλυνε την ανάπτυξη μιας αρθρωτής λογικής Industrial IoT αρχιτεκτονικής, καθώς κάθε επιμέρους υπηρεσία μπορούσε να λειτουργεί ανεξάρτητα, αλλά ταυτόχρονα να συνεργάζεται με τις υπόλοιπες μέσω του κοινού δικτύου και των κατάλληλων interfaces.

Οι βασικές υπηρεσίες που εκτελούνταν σε containers ήταν:

- Node-RED,
- InfluxDB,
- Grafana.

Η χρήση Docker επέτρεψε:

- απομόνωση υπηρεσιών,
- ευκολότερη ανάπτυξη και παραμετροποίηση,
- portability της εφαρμογής,
- reproducibility του περιβάλλοντος ανάπτυξης,
- καθώς και απλοποιημένη διαχείριση εξαρτήσεων.

Η συνολική Industrial IoT υποδομή οργανώθηκε σε ενιαίο Docker stack, επιτρέποντας καλύτερη διαχείριση των επιμέρους components και ευκολότερη επαναληψιμότητα της εγκατάστασης και της ανάπτυξης του συστήματος.

## 4. Διαχείριση και Επεξεργασία Δεδομένων

### 4.1 Δεδομένα Βιομηχανικού Συμπιεστή

Η ανάπτυξη ενός συστήματος προγνωστικής συντήρησης βασίζεται στην ύπαρξη αξιόπιστων ιστορικών δεδομένων λειτουργίας του εξοπλισμού. Για τις ανάγκες της παρούσας εργασίας αξιοποιήθηκαν πραγματικά λειτουργικά δεδομένα βιομηχανικών συμπιεστών φυσικού αερίου που λειτουργούν σε σύστημα μεταφοράς φυσικού αερίου. Τα δεδομένα προήλθαν από περιοδικές αναφορές λειτουργίας οι οποίες εξάγονται από το σύστημα εποπτείας και ελέγχου της εγκατάστασης και αποτυπώνουν τη λειτουργική κατάσταση του εξοπλισμού σε ωριαία βάση.

Στο πλαίσιο της εργασίας εξετάστηκαν δύο διαφορετικοί συμπιεστές, οι οποίοι αντιμετωπίστηκαν ως ανεξάρτητες μονάδες παρακολούθησης και ανάλυσης. Για κάθε συμπιεστή ήταν διαθέσιμο ιστορικό αρχείο λειτουργίας που περιλάμβανε βασικές μεταβλητές σχετικές με τη θερμοδυναμική και μηχανική συμπεριφορά του συστήματος. Οι μεταβλητές που επιλέχθηκαν για την ανάπτυξη των μοντέλων πρόβλεψης ήταν η θερμοκρασία εξόδου (Outlet Temperature), η πίεση κατάθλιψης (Discharge Pressure), καθώς και τρεις μεταβλητές κραδασμών του τμήματος υψηλής πίεσης του συμπιεστή (HPC Aft X Vibration, HPC Aft Y Vibration και HPC Forward X Vibration).

Οι συγκεκριμένες μεταβλητές επιλέχθηκαν καθώς αποτελούν βασικούς δείκτες της λειτουργικής κατάστασης ενός φυγοκεντρικού συμπιεστή. Η πίεση κατάθλιψης και η θερμοκρασία εξόδου συνδέονται άμεσα με την απόδοση της διεργασίας συμπίεσης, ενώ οι μετρήσεις κραδασμών χρησιμοποιούνται ευρέως για την παρακολούθηση της μηχανικής κατάστασης περιστρεφόμενου εξοπλισμού και την έγκαιρη αναγνώριση ενδεχόμενων αποκλίσεων ή αστοχιών.

Για κάθε συμπιεστή ήταν διαθέσιμες περίπου 8.700 ωριαίες καταγραφές λειτουργίας. Τα δεδομένα του έτους 2021 χρησιμοποιήθηκαν για την ανάπτυξη και εκπαίδευση των μοντέλων μηχανικής μάθησης. Για τον σκοπό αυτό εφαρμόστηκε διαχωρισμός του συνόλου δεδομένων σε σύνολο εκπαίδευσης και σύνολο ελέγχου, ακολουθώντας τον κανόνα 80%-20%. Το 80% των δεδομένων χρησιμοποιήθηκε για την εκπαίδευση των μοντέλων, ενώ το υπόλοιπο 20% χρησιμοποιήθηκε για την αξιολόγηση της απόδοσής τους.

Μετά την ολοκλήρωση της διαδικασίας εκπαίδευσης, τα παραγόμενα μοντέλα ενσωματώθηκαν στην πλατφόρμα προγνωστικής συντήρησης που αναπτύχθηκε στο πλαίσιο της εργασίας. Για την αξιολόγηση της λειτουργίας του συνολικού συστήματος χρησιμοποιήθηκαν δεδομένα του έτους 2022, τα οποία δεν είχαν συμμετάσχει στη διαδικασία εκπαίδευσης. Οι συγκεκριμένες καταγραφές χρησιμοποιήθηκαν για την προσομοίωση της online λειτουργίας του συστήματος μέσω της υποδομής LoRaWAN, επιτρέποντας την αξιολόγηση των μοντέλων σε ανεξάρτητα δεδομένα λειτουργίας και σε συνθήκες που προσεγγίζουν πραγματικό περιβάλλον παρακολούθησης βιομηχανικού εξοπλισμού.

## 4.2 Προεπεξεργασία Δεδομένων και Feature Engineering

Πριν από την εκπαίδευση των μοντέλων μηχανικής μάθησης, τα διαθέσιμα ιστορικά δεδομένα υποβλήθηκαν σε διαδικασία προεπεξεργασίας με στόχο τη δημιουργία ενός αξιόπιστου συνόλου δεδομένων κατάλληλου για ανάπτυξη μοντέλων πρόβλεψης. Η διαδικασία αυτή ήταν απαραίτητη τόσο για τη βελτίωση της ποιότητας των δεδομένων όσο και για την καλύτερη αναπαράσταση της πραγματικής συμπεριφοράς του συμπιεστή.


Αρχικά πραγματοποιήθηκε έλεγχος των ιστορικών καταγραφών ως προς τη χρονική τους ακολουθία και τη συνοχή των μετρήσεων. Καθώς τα δεδομένα προέρχονταν από πραγματική βιομηχανική εγκατάσταση, κρίθηκε απαραίτητο να διασφαλιστεί ότι οι χρονοσειρές ήταν σωστά ταξινομημένες και μπορούσαν να χρησιμοποιηθούν χωρίς να αλλοιώνεται η χρονική σχέση μεταξύ των διαδοχικών καταγραφών.

Η ανάπτυξη μοντέλων πρόβλεψης για βιομηχανικό εξοπλισμό δεν μπορεί να βασιστεί αποκλειστικά στην τρέχουσα τιμή μιας μεταβλητής. Μεταβολές σε παραμέτρους όπως η πίεση, η θερμοκρασία ή οι κραδασμοί συνήθως εξελίσσονται σταδιακά και επηρεάζονται από την προηγούμενη κατάσταση λειτουργίας του συστήματος. Για τον λόγο αυτό εφαρμόστηκαν τεχνικές feature engineering με σκοπό την ενσωμάτωση χρονικής πληροφορίας στο σύνολο δεδομένων.

Συγκεκριμένα δημιουργήθηκαν χαρακτηριστικά χρονικής καθυστέρησης (lag features), τα οποία περιείχαν τιμές της ίδιας μεταβλητής από προηγούμενες

χρονικές στιγμές. Στην παρούσα εργασία χρησιμοποιήθηκαν τα χαρακτηριστικά lag1 και lag2, τα οποία αντιστοιχούν στις τιμές της μεταβλητής μία και δύο ώρες πριν από την τρέχουσα καταγραφή αντίστοιχα.


Παράλληλα δημιουργήθηκαν επιπλέον χαρακτηριστικά μέσω κινούμενου παραθύρου τριών καταγραφών (rolling window). Για κάθε μεταβλητή υπολογίστηκε ο κινούμενος μέσος όρος (rolling mean) καθώς και η κινούμενη τυπική απόκλιση (rolling standard deviation). Με τον τρόπο αυτό το μοντέλο αποκτούσε πληροφορία όχι μόνο για την τρέχουσα τιμή μιας μεταβλητής αλλά και για τη βραχυχρόνια τάση και μεταβλητότητα της λειτουργίας του συμπιεστή.



**Εικόνα 14 - Παράδειγμα δημιουργίας χαρακτηριστικών χρονικής καθυστέρησης και στατιστικών χαρακτηριστικών από ιστορικές μετρήσεις**

Η προσθήκη των παραπάνω χαρακτηριστικών αποδείχθηκε ιδιαίτερα χρήσιμη, καθώς επέτρεψε στα μοντέλα να λαμβάνουν υπόψη τη δυναμική συμπεριφορά του συστήματος και όχι μόνο μεμονωμένες μετρήσεις. Η προσέγγιση αυτή είναι ιδιαίτερα σημαντική σε εφαρμογές προγνωστικής συντήρησης, όπου οι αποκλίσεις στη λειτουργία του εξοπλισμού εμφανίζονται συνήθως προοδευτικά και όχι στιγμιαία.

Μετά την ολοκλήρωση της διαδικασίας δημιουργίας χαρακτηριστικών, εφαρμόστηκε κανονικοποίηση των δεδομένων με χρήση της μεθόδου StandardScaler. Η διαδικασία αυτή μετασχηματίζει κάθε μεταβλητή ώστε να έχει μηδενικό μέσο όρο και μοναδιαία τυπική απόκλιση, επιτρέποντας στα μοντέλα να επεξεργάζονται αποτελεσματικότερα μεταβλητές με διαφορετικές κλίμακες τιμών.



**Εικόνα 15** - Διαδικασία προεπεξεργασίας και δημιουργίας χαρακτηριστικών για την ανάπτυξη των μοντέλων πρόσβεσης

Το τελικό σύνολο δεδομένων που προέκυψε από την προεπεξεργασία και το feature engineering χρησιμοποιήθηκε για την εκπαίδευση των μοντέλων Ridge Regression που παρουσιάζονται στο επόμενο υποκεφάλαιο.

### 4.3 Εκπαίδευση Μοντέλων Πρόβλεψης

Μετά την ολοκλήρωση της διαδικασίας προεπεξεργασίας και δημιουργίας χαρακτηριστικών, το τελικό σύνολο δεδομένων χρησιμοποιήθηκε για την ανάπτυξη μοντέλων πρόβλεψης της λειτουργικής συμπεριφοράς των συμπιεστών. Στόχος των μοντέλων ήταν η εκτίμηση της αναμενόμενης τιμής κρίσιμων λειτουργικών παραμέτρων, ώστε οι προβλέψεις αυτές να μπορούν στη συνέχεια να συγκριθούν με τις πραγματικές μετρήσεις κατά τη λειτουργία του συστήματος.

Για κάθε συμπιεστή αναπτύχθηκαν ξεχωριστά μοντέλα πρόβλεψης για πέντε βασικές μεταβλητές λειτουργίας:

- Θερμοκρασία εξόδου (Outlet Temperature)
- Πίεση κατάθλιψης (Discharge Pressure)
- HPC Aft X Vibration
- HPC Aft Y Vibration
- HPC Forward X Vibration

Η επιλογή των συγκεκριμένων μεταβλητών βασίστηκε στη σημασία τους για την παρακολούθηση της λειτουργικής κατάστασης του συμπιεστή. Οι μεταβλητές πίεσης και θερμοκρασίας σχετίζονται άμεσα με τη διεργασία συμπίεσης και την ενεργειακή απόδοση του εξοπλισμού, ενώ οι μετρήσεις κραδασμών αποτελούν βασικούς δείκτες της μηχανικής κατάστασης περιστρεφόμενων μηχανών.

Για την ανάπτυξη των μοντέλων χρησιμοποιήθηκε η μέθοδος Ridge Regression. Η συγκεκριμένη τεχνική αποτελεί επέκταση της γραμμικής παλινδρόμησης και περιλαμβάνει όρο κανονικοποίησης (regularization), ο οποίος συμβάλλει στη βελτίωση της γενίκευσης του μοντέλου και στον περιορισμό φαινομένων υπερπροσαρμογής. Η επιλογή της Ridge Regression πραγματοποιήθηκε λόγω της απλότητας, της υπολογιστικής αποδοτικότητας και της καλής συμπεριφοράς της σε προβλήματα πρόβλεψης βιομηχανικών χρονοσειρών.

Πριν από την εκπαίδευση των μοντέλων εφαρμόστηκε κανονικοποίηση των δεδομένων με χρήση της μεθόδου StandardScaler. Η κανονικοποίηση πραγματοποιήθηκε χρησιμοποιώντας αποκλειστικά τα δεδομένα εκπαίδευσης και στη συνέχεια εφαρμόστηκε στα δεδομένα ελέγχου με τις ίδιες παραμέτρους μετασχηματισμού. Με τον τρόπο αυτό διασφαλίστηκε η ομοιομορφία των δεδομένων που εισάγονταν στα μοντέλα και αποφεύχθηκαν πιθανές αποκλίσεις λόγω διαφορετικών κλιμάκων μέτρησης.

Για κάθε μεταβλητή δημιουργήθηκε ανεξάρτητο μοντέλο πρόβλεψης. Συνεπώς, για κάθε συμπιεστή αναπτύχθηκαν πέντε διαφορετικά μοντέλα, ενώ συνολικά για το σύστημα δημιουργήθηκαν δέκα μοντέλα πρόβλεψης. Μετά την ολοκλήρωση της διαδικασίας εκπαίδευσης, τα μοντέλα αποθηκεύτηκαν σε μορφή αρχείων .pkl, ώστε να μπορούν να χρησιμοποιηθούν από την online πλατφόρμα προγνωστικής συντήρησης χωρίς να απαιτείται επανεκπαίδευση.

Η προσέγγιση αυτή επέτρεψε τον διαχωρισμό της διαδικασίας ανάπτυξης των μοντέλων από τη διαδικασία λειτουργίας του συστήματος. Τα μοντέλα εκπαιδεύτηκαν offline χρησιμοποιώντας ιστορικά δεδομένα του έτους 2021 και

στη συνέχεια ενσωματώθηκαν στην πλατφόρμα παρακολούθησης, όπου χρησιμοποιήθηκαν για την επεξεργασία δεδομένων λειτουργίας του έτους 2022 σε σχεδόν πραγματικό χρόνο.

#### 4.4 Υποδομή Τηλεμετρίας LoRaWAN


Η μετάβαση από την offline ανάπτυξη των μοντέλων στην online λειτουργία του συστήματος απαιτούσε τη δημιουργία μιας υποδομής ικανής να μεταφέρει δεδομένα λειτουργίας από το επίπεδο πεδίου προς τα συστήματα επεξεργασίας και παρακολούθησης. Για τον σκοπό αυτό αναπτύχθηκε μια υποδομή ασύρματης μετάδοσης δεδομένων βασισμένη στην τεχνολογία LoRaWAN, η οποία χρησιμοποιήθηκε για τη μετάδοση δεδομένων από τους αισθητηριακούς κόμβους προς την κεντρική πλατφόρμα επεξεργασίας.

Καθώς η εργασία βασίστηκε σε ιστορικά δεδομένα λειτουργίας, αναπτύχθηκε μηχανισμός αναπαραγωγής των καταγραφών με τρόπο που να προσομοιώνει τη λειτουργία ενός πραγματικού συστήματος online παρακολούθησης. Οι ιστορικές μετρήσεις του έτους 2022 μετατράπηκαν σε ροή δεδομένων και μεταδίδονταν περιοδικά από τους κόμβους LoRaWAN προς το δίκτυο.

Στην πραγματική λειτουργία ενός βιομηχανικού συστήματος οι συγκεκριμένες μετρήσεις καταγράφονταν σε ωριαία βάση. Ωστόσο, για τις ανάγκες της πειραματικής αξιολόγησης και της επίδειξης της πλατφόρμας επιλέχθηκε η αποστολή ενός πακέτου δεδομένων κάθε 20 δευτερόλεπτα. Η προσέγγιση αυτή επέτρεψε την ταχύτερη αναπαραγωγή μεγάλου όγκου ιστορικών δεδομένων και τη δημιουργία ενός περιβάλλοντος που προσομοίαζε συνεχή ροή μετρήσεων σε σχεδόν πραγματικό χρόνο.

Κάθε πακέτο δεδομένων περιλάμβανε τις βασικές λειτουργικές μεταβλητές που χρησιμοποιήθηκαν και κατά την ανάπτυξη των μοντέλων πρόβλεψης, δηλαδή τη θερμοκρασία εξόδου, την πίεση κατάθλιψης και τις τρεις μεταβλητές κραδασμών του τμήματος υψηλής πίεσης του συμπιεστή. Οι τιμές μετατρέπονταν σε κατάλληλη μορφή για μετάδοση μέσω LoRaWAN και ενσωματώνονταν στο payload κάθε uplink μηνύματος.

Η συγκεκριμένη αρχιτεκτονική επέτρεψε τη δημιουργία ενός ολοκληρωμένου περιβάλλοντος Industrial IoT, στο οποίο τα ιστορικά δεδομένα μετατρέπονταν σε τηλεμετρικά δεδομένα πεδίου και ακολουθούσαν την ίδια διαδρομή που θα ακολουθούσαν και σε μια πραγματική εγκατάσταση παρακολούθησης εξοπλισμού.



**Εικόνα 16** - Αρχιτεκτονική LoRaWAN δικτύου

## 4.5 Συλλογή Δεδομένων μέσω ChirpStack και MQTT

Η επικοινωνία μεταξύ των αισθητηριακών κόμβων και των εφαρμογών επεξεργασίας δεδομένων υλοποιήθηκε μέσω της πλατφόρμας ChirpStack και του πρωτοκόλλου MQTT. Ο συνδυασμός των δύο τεχνολογιών επέτρεψε τη λήψη, δρομολόγηση και διανομή των δεδομένων προς τα επόμενα επίπεδα της αρχιτεκτονικής.


Κάθε αισθητηριακός κόμβος LoRaWAN μεταδίδει περιοδικά τα δεδομένα λειτουργίας του αντίστοιχου συμπιεστή μέσω uplink μηνυμάτων. Τα μηνύματα αυτά λαμβάνονταν από το LoRaWAN Gateway και προωθούνται στο ChirpStack Network Server, το οποίο ήταν εγκατεστημένο στο Raspberry Pi 4.

Το ChirpStack αναλαμβάνει τη διαχείριση των LoRaWAN συσκευών, την αποκωδικοποίηση των πακέτων επικοινωνίας και τη δρομολόγηση των δεδομένων προς το επίπεδο εφαρμογής. Μετά την παραλαβή ενός uplink μηνύματος, το περιεχόμενο του πακέτου δημοσιεύεται αυτόματα σε κατάλληλο MQTT topic, ώστε να είναι διαθέσιμο σε οποιαδήποτε εφαρμογή είναι εγγεγραμμένη ως subscriber.

Η ανταλλαγή δεδομένων βασίζεται στην αρχιτεκτονική publish/subscribe του MQTT. Στο πλαίσιο της εργασίας, το ChirpStack λειτουργεί ως publisher των δεδομένων, ενώ το Node-RED λειτουργεί ως subscriber, λαμβάνοντας σε πραγματικό χρόνο τα δεδομένα που δημοσιεύονται στα αντίστοιχα topics.

Η χρήση του MQTT προσέφερε σημαντικά πλεονεκτήματα για την ανάπτυξη της πλατφόρμας. Η ανταλλαγή δεδομένων πραγματοποιείται με μικρή επιβάρυνση δικτύου, ενώ παράλληλα διατηρείται πλήρης διαχωρισμός μεταξύ του επιπέδου επικοινωνίας και του επιπέδου επεξεργασίας δεδομένων. Η προσέγγιση αυτή επιτρέπει την εύκολη ενσωμάτωση πρόσθετων εφαρμογών ή υπηρεσιών χωρίς να απαιτούνται τροποποιήσεις στην υποδομή LoRaWAN.

Στην παρούσα υλοποίηση, το MQTT αποτέλεσε το βασικό μέσο μεταφοράς δεδομένων μεταξύ της υποδομής LoRaWAN και της πλατφόρμας επεξεργασίας. Κάθε νέο μήνυμα που παραλαμβάνεται από το ChirpStack προωθείται άμεσα στο Node-RED, όπου ακολουθεί η διαδικασία αποκωδικοποίησης, επεξεργασίας και αποστολής προς τα μοντέλα πρόβλεψης.



**Εικόνα 17** - Ροή δεδομένων από κόμβο αισθητήρων έως node-red

Με τον τρόπο αυτό δημιουργήθηκε μια συνεχής ροή δεδομένων από το επίπεδο πεδίου έως το επίπεδο ανάλυσης, επιτρέποντας την αξιοποίηση των μετρήσεων σε σχεδόν πραγματικό χρόνο.

## 4.6 Επεξεργασία Δεδομένων στο Node-RED

Το Node-RED αποτέλεσε τον κεντρικό μηχανισμό επεξεργασίας και δρομολόγησης δεδομένων της πλατφόρμας. Μέσω αυτού υλοποιήθηκε η διασύνδεση μεταξύ της υποδομής LoRaWAN, των μοντέλων μηχανικής μάθησης και των συστημάτων αποθήκευσης και οπτικοποίησης δεδομένων.

Μετά τη δημοσίευση ενός νέου uplink μηνύματος από το ChirpStack στο αντίστοιχο MQTT topic, το Node-RED λαμβάνει τα δεδομένα μέσω MQTT

subscription και ξεκινάει τη διαδικασία επεξεργασίας τους. Κάθε μήνυμα περιέχει τις λειτουργικές μεταβλητές του αντίστοιχου συμπιεστή σε μορφή δυαδικού payload, κατάλληλα διαμορφωμένου για μετάδοση μέσω LoRaWAN.

Αρχικά πραγματοποιείται αποκωδικοποίηση του payload και ανακατασκευή των αρχικών μετρήσεων. Οι μεταβλητές μεταδίδονται ως ακέραιες τιμές με εφαρμογή κατάλληλων συντελεστών κλιμάκωσης, προκειμένου να μειωθεί το μέγεθος του πακέτου δεδομένων. Κατά την επεξεργασία, το Node-RED μετατρέπει τις τιμές αυτές στις αντίστοιχες φυσικές μονάδες μέτρησης.

Οι μεταβλητές που εξάγονται από κάθε μήνυμα είναι:

- Outlet Temperature
- Discharge Pressure
- HPC Aft X Vibration
- HPC Aft Y Vibration
- HPC Forward X Vibration

Μετά την αποκωδικοποίηση, οι μετρήσεις οργανώνονται σε μορφή JSON ώστε να μπορούν να χρησιμοποιηθούν από τις επόμενες εφαρμογές της πλατφόρμας. Ένα τυπικό μήνυμα που δημιουργείται στο Node-RED έχει τη μορφή:

```
{  
  "outletTemp": 54.8,  
  "dischPres": 42.1,  
  "vibHPCAftX": 0.122,  
  "vibHPCAftY": 0.118,  
  "vibHPCForwX": 0.095  
}
```

Στη συνέχεια το Node-RED αναλαμβάνει την αποστολή των δεδομένων προς το σύστημα πρόβλεψης μέσω HTTP requests. Για κάθε μεταβλητή καλείται το αντίστοιχο endpoint του Predictive Service, το οποίο επιστρέφει την προβλεπόμενη τιμή που υπολογίζεται από το αντίστοιχο μοντέλο Ridge Regression.

## 4.7 Υλοποίηση Predictive Service και Υπολογισμός Residuals

Για την ενσωμάτωση των μοντέλων μηχανικής μάθησης στην πλατφόρμα προγνωστικής συντήρησης αναπτύχθηκε ανεξάρτητο service πρόβλεψης (Predictive Service) σε περιβάλλον Python. Η υπηρεσία αυτή λειτουργεί ως

ενδιάμεσο επίπεδο μεταξύ του Node-RED και των μοντέλων πρόβλεψης, επιτρέποντας την εκτέλεση προβλέψεων σε σχεδόν πραγματικό χρόνο.

Η υλοποίηση βασίζεται στο πλαίσιο ανάπτυξης Flask, μέσω του οποίου δημιουργείται REST API για την παροχή υπηρεσιών πρόβλεψης. Κατά την εκκίνηση της εφαρμογής φορτώνονται τα εκπαιδευμένα μοντέλα Ridge Regression καθώς και τα αντίστοιχα αντικείμενα κανονικοποίησης (StandardScaler), τα οποία έχουν αποθηκευτεί σε μορφή αρχείων .pkl κατά τη φάση της εκπαίδευσης.

Για κάθε μεταβλητή και για κάθε συμπιεστή δημιουργείται ξεχωριστό endpoint πρόβλεψης. Συνολικά αναπτύσσονται δέκα endpoints, πέντε για κάθε συμπιεστή, τα οποία αντιστοιχούν στις ακόλουθες μεταβλητές:

- Outlet Temperature
- Discharge Pressure
- HPC Aft X Vibration
- HPC Aft Y Vibration
- HPC Forward X Vibration

Η χρήση ανεξάρτητων endpoints απλοποιεί τη διασύνδεση με το Node-RED και επιτρέπει την ανεξάρτητη διαχείριση κάθε μεταβλητής. Για κάθε νέο σύνολο μετρήσεων που λαμβάνεται από την πλατφόρμα, αποστέλλεται HTTP request προς το αντίστοιχο endpoint και επιστρέφεται η προβλεπόμενη τιμή της μεταβλητής.

Τα μοντέλα εκπαιδεύτηκαν offline χρησιμοποιώντας τα ιστορικά δεδομένα του έτους 2021 και στη συνέχεια ενσωματώνονται στο Predictive Service, όπου χρησιμοποιούνται για την επεξεργασία δεδομένων λειτουργίας του έτους 2022. Με τον τρόπο αυτό διαχωρίζεται πλήρως η φάση ανάπτυξης των μοντέλων από τη φάση λειτουργίας και αξιολόγησης της πλατφόρμας, προσεγγίζοντας περισσότερο τον τρόπο με τον οποίο θα λειτουργούσε ένα αντίστοιχο σύστημα σε πραγματικές βιομηχανικές συνθήκες.

Μετά τη λήψη των προβλέψεων πραγματοποιείται σύγκριση μεταξύ πραγματικών και προβλεπόμενων τιμών. Για κάθε μεταβλητή υπολογίζεται η τιμή residual σύμφωνα με τη σχέση:

$$Residual = Actual - Predicted$$

Το residual εκφράζει το σφάλμα πρόβλεψης του μοντέλου για τη συγκεκριμένη χρονική στιγμή. Όσο η λειτουργία του εξοπλισμού παραμένει κοντά στη συμπεριφορά που έχει μάθει το μοντέλο κατά την εκπαίδευση, οι τιμές residual

διατηρούνται σε χαμηλά επίπεδα. Αντίθετα, αυξημένες αποκλίσεις μεταξύ πραγματικών και προβλεπόμενων τιμών οδηγούν σε μεγαλύτερες τιμές residual, οι οποίες μπορούν να αποτελέσουν ένδειξη μεταβολής της λειτουργικής κατάστασης του εξοπλισμού.

Η χρήση των residuals αποτελεί βασικό στοιχείο της φιλοσοφίας της προγνωστικής συντήρησης. Αντί να παρακολουθούνται αποκλειστικά οι απόλυτες τιμές των μετρήσεων, αξιολογείται κατά πόσο η πραγματική συμπεριφορά του συστήματος αποκλίνει από τη συμπεριφορά που θεωρείται φυσιολογική σύμφωνα με τα εκπαιδευμένα μοντέλα. Με τον τρόπο αυτό είναι δυνατή η αναγνώριση πιθανών ανωμαλιών ακόμη και όταν οι μετρήσεις παραμένουν εντός των συμβατικών ορίων λειτουργίας.

Στην παρούσα εργασία τα residuals χρησιμοποιούνται ως βασικός δείκτης αξιολόγησης της συμπεριφοράς των συμπιεστών και της απόδοσης των μοντέλων πρόβλεψης. Οι τιμές αυτές αποθηκεύονται μαζί με τις πραγματικές και τις προβλεπόμενες μετρήσεις στην InfluxDB, ώστε να είναι διαθέσιμες για περαιτέρω ανάλυση και οπτικοποίηση μέσω Grafana.

Η συγκεκριμένη αρχιτεκτονική επιτρέπει τον διαχωρισμό του επιπέδου πρόβλεψης από τα υπόλοιπα τμήματα της πλατφόρμας. Έτσι διευκολύνεται η συντήρηση και η μελλοντική αναβάθμιση των μοντέλων μηχανικής μάθησης χωρίς να απαιτούνται τροποποιήσεις στην υποδομή συλλογής, επεξεργασίας και αποθήκευσης δεδομένων. Επιπλέον, η χρήση REST API επιτρέπει την εύκολη αντικατάσταση ή προσθήκη νέων μοντέλων στο μέλλον, διατηρώντας αμετάβλητη τη συνολική αρχιτεκτονική του συστήματος.

## 4.8 Αποθήκευση και Οπτικοποίηση Δεδομένων

Η τελική φάση της πλατφόρμας αφορά την αποθήκευση και οπτικοποίηση των δεδομένων που παράγονται κατά τη λειτουργία του συστήματος. Για τον σκοπό αυτό χρησιμοποιούνται η βάση δεδομένων χρονοσειρών InfluxDB και η πλατφόρμα οπτικοποίησης Grafana, οι οποίες αποτελούν ιδιαίτερα διαδεδομένες λύσεις σε εφαρμογές Industrial IoT και παρακολούθησης βιομηχανικών διεργασιών.

Μετά την επεξεργασία των τηλεμετρικών δεδομένων και την εκτέλεση των προβλέψεων από το Predictive Service, το Node-RED αποθηκεύει στην InfluxDB όλες τις απαραίτητες πληροφορίες για την παρακολούθηση της λειτουργίας των συμπιεστών. Συγκεκριμένα, για κάθε χρονική στιγμή αποθηκεύονται:

- οι πραγματικές μετρήσεις (Actual Values),
- οι προβλεπόμενες τιμές των μοντέλων (Predicted Values),

- οι τιμές residual που προκύπτουν από τη σύγκριση πραγματικών και προβλεπόμενων τιμών.

Η αποθήκευση των δεδομένων σε μορφή χρονοσειρών επιτρέπει την εύκολη αναζήτηση, επεξεργασία και ανάλυση της ιστορικής συμπεριφοράς του εξοπλισμού. Παράλληλα, παρέχει τη δυνατότητα συσχέτισης διαφορετικών μεταβλητών και παρακολούθησης της εξέλιξής τους σε βάθος χρόνου.

Η InfluxDB λειτουργεί ως κεντρικό αποθετήριο δεδομένων της πλατφόρμας. Κάθε νέα μέτρηση που παραλαμβάνεται από το σύστημα συνοδεύεται από χρονική σήμανση (timestamp) και αποθηκεύεται μαζί με τις αντίστοιχες προβλέψεις και τα residuals. Με τον τρόπο αυτό δημιουργείται ένα πλήρες ιστορικό λειτουργίας για κάθε συμπίεστη, το οποίο μπορεί να αξιοποιηθεί τόσο για online παρακολούθηση όσο και για μεταγενέστερη ανάλυση.

Για την παρουσίαση των δεδομένων χρησιμοποιείται το Grafana, το οποίο συνδέεται απευθείας με την InfluxDB και ανακτά τις απαραίτητες χρονοσειρές. Μέσω του Grafana δημιουργούνται διαδραστικά dashboards που επιτρέπουν την παρακολούθηση της λειτουργίας των συμπίεστων σε σχεδόν πραγματικό χρόνο.

Τα dashboards που αναπτύσσονται στο πλαίσιο της εργασίας παρουσιάζουν:

- τις πραγματικές μετρήσεις των μεταβλητών λειτουργίας,
- τις αντίστοιχες προβλέψεις των μοντέλων,
- τη χρονική εξέλιξη των residuals,
- τη σύγκριση μεταξύ πραγματικής και αναμενόμενης συμπεριφοράς.

Η παράλληλη απεικόνιση πραγματικών και προβλεπόμενων τιμών επιτρέπει την άμεση αξιολόγηση της απόδοσης των μοντέλων και διευκολύνει τον εντοπισμό πιθανών αποκλίσεων. Επιπλέον, η παρακολούθηση των residuals παρέχει μια σαφέστερη εικόνα της συμπεριφοράς του εξοπλισμού, καθώς αναδεικνύει μεταβολές που ενδέχεται να μην είναι άμεσα εμφανείς από την εξέταση των πρωτογενών μετρήσεων.

Ο συνδυασμός InfluxDB και Grafana ολοκληρώνει την αρχιτεκτονική της πλατφόρμας προγνωστικής συντήρησης, παρέχοντας ένα ενιαίο περιβάλλον αποθήκευσης, ανάλυσης και παρακολούθησης των δεδομένων λειτουργίας. Με τον τρόπο αυτό καθίσταται δυνατή η συνεχής αξιολόγηση της κατάστασης των συμπίεστων και η υποστήριξη διαδικασιών έγκαιρης ανίχνευσης ανωμαλιών.

## 5. Αποτελέσματα και Αξιολόγηση Μοντέλων Πρόβλεψης

### 5.1 Μεθοδολογία Αξιολόγησης

Η αξιολόγηση των μοντέλων πρόβλεψης πραγματοποιείται χρησιμοποιώντας ιστορικά δεδομένα λειτουργίας βιομηχανικών συμπιεστών φυσικού αερίου. Για κάθε μεταβλητή αναπτύχθηκε ανεξάρτητο μοντέλο Ridge Regression, το οποίο εκπαιδεύτηκε χρησιμοποιώντας το 80% των διαθέσιμων δεδομένων, ενώ το υπόλοιπο 20% χρησιμοποιήθηκε ως σύνολο ελέγχου για την αξιολόγηση της απόδοσής του.

Η εκπαίδευση πραγματοποιήθηκε με δεδομένα του έτους 2021, ενώ τα δεδομένα του έτους 2022 χρησιμοποιούνται στη συνέχεια για την προσομοίωση της online λειτουργίας της πλατφόρμας προγνωστικής συντήρησης. Με τον τρόπο αυτό διαχωρίζεται η διαδικασία ανάπτυξης των μοντέλων από τη διαδικασία λειτουργίας του συστήματος.

Για κάθε συμπιεστή αναπτύσσονται πέντε ανεξάρτητα μοντέλα πρόβλεψης που αντιστοιχούν στις ακόλουθες μεταβλητές:

- Outlet Temperature
- Discharge Pressure
- HPC Aft X Vibration
- HPC Aft Y Vibration
- HPC Forward X Vibration

Η αξιολόγηση των μοντέλων βασίζεται στις ακόλουθες μετρικές:

#### **Mean Absolute Error (MAE)**

Το MAE εκφράζει το μέσο απόλυτο σφάλμα μεταξύ πραγματικών και προβλεπόμενων τιμών και παρέχει άμεση εκτίμηση της ακρίβειας του μοντέλου.

#### **Root Mean Square Error (RMSE)**

Το RMSE δίνει μεγαλύτερη βαρύτητα σε μεγάλες αποκλίσεις μεταξύ πραγματικών και προβλεπόμενων τιμών και χρησιμοποιείται ευρέως στην αξιολόγηση μοντέλων πρόβλεψης χρονοσειρών.

#### **Coefficient of Determination ( $R^2$ )**

Ο συντελεστής προσδιορισμού  $R^2$  εκφράζει το ποσοστό της διακύμανσης των δεδομένων που παράχθηκαν από το μοντέλο. Τιμές κοντά στη μονάδα υποδηλώνουν ιδιαίτερα υψηλή ακρίβεια πρόβλεψης.

## 5.2 Αποτελέσματα Compressor #1

Τα αποτελέσματα του Compressor #1 παρουσιάζουν πολύ καλή απόδοση σε όλες τις μεταβλητές που εξετάζονται. Οι τιμές του συντελεστή προσδιορισμού  $R^2$  κυμαίνονται μεταξύ 0.9802 και 0.9926, γεγονός που δείχνει ότι τα μοντέλα μπορούν να αναπαράγουν με μεγάλη ακρίβεια τη συμπεριφορά του εξοπλισμού.

| Μεταβλητή               | MAE    | RMSE   | $R^2$  |
|-------------------------|--------|--------|--------|
| Outlet Temperature      | 0.6687 | 1.4838 | 0.9918 |
| Discharge Pressure      | 1.6093 | 3.1230 | 0.9890 |
| HPC Aft X Vibration     | 0.2886 | 0.4904 | 0.9925 |
| HPC Aft Y Vibration     | 0.2529 | 0.4561 | 0.9926 |
| HPC Forward X Vibration | 0.5085 | 0.9197 | 0.9802 |
|                         |        |        |        |

**Πίνακας 1** - Αποτελέσματα Compressor #1

### 5.2.1 Outlet Temperature

Το μοντέλο πρόβλεψης της θερμοκρασίας εξόδου παρουσιάζει ιδιαίτερα υψηλή ακρίβεια με συντελεστή προσδιορισμού  $R^2$  ίσο με 0.9918. Η χαμηλή τιμή του MAE δείχνει ότι οι προβλέψεις ακολουθούν με μεγάλη ακρίβεια τις πραγματικές μετρήσεις.

### 5.2.2 Discharge Pressure

Το μοντέλο της πίεσης κατάθλιψης επιτυγχάνει  $R^2$  ίσο με 0.9890. Παρότι εμφανίζει το μεγαλύτερο RMSE μεταξύ των μεταβλητών του Compressor #1, η συνολική του απόδοση παραμένει ιδιαίτερα ικανοποιητική.

### 5.2.3 HPC Aft X Vibration


Το μοντέλο των κραδασμών HPC Aft X παρουσιάζει πολύ υψηλή ακρίβεια με  $R^2$  ίσο με 0.9925, αποτυπώνοντας αποτελεσματικά τη χρονική συμπεριφορά της μεταβλητής.

### 5.2.4 HPC Aft Y Vibration

Η καλύτερη επίδοση του Compressor #1 παρατηρείται στη μεταβλητή HPC Aft Y Vibration, όπου το μοντέλο επιτυγχάνει  $R^2$  ίσο με 0.9926 και τις χαμηλότερες τιμές σφάλματος.

### 5.2.5 HPC Forward X Vibration

Η μεταβλητή HPC Forward X Vibration παρουσιάζει τη χαμηλότερη απόδοση μεταξύ των πέντε μοντέλων, με  $R^2$  ίσο με 0.9802. Παρ' όλα αυτά, η επίδοση παραμένει ιδιαίτερα υψηλή και απολύτως αποδεκτή για εφαρμογές προγνωστικής συντήρησης.



**Εικόνα 18** - Dashboard παρακολούθησης πραγματικών και προβλεπόμενων μεταβλητών του Compressor #1.

## 5.3 Αποτελέσματα Compressor #2

Τα αποτελέσματα του Compressor #2 παρουσιάζουν ακόμη υψηλότερη ακρίβεια σε σχέση με τον Compressor #1. Όλες οι μεταβλητές εμφανίζουν συντελεστή προσδιορισμού μεγαλύτερο από 0.999, γεγονός που υποδεικνύει εξαιρετική ικανότητα πρόβλεψης.

| Μεταβλητή               | MAE    | RMSE   | R <sup>2</sup> |
|-------------------------|--------|--------|----------------|
| Outlet Temperature      | 0.0409 | 0.1349 | 0.9998         |
| Discharge Pressure      | 0.1014 | 0.3345 | 0.9998         |
| HPC Aft X Vibration     | 0.0402 | 0.0792 | 0.9997         |
| HPC Aft Y Vibration     | 0.0361 | 0.0744 | 0.9996         |
| HPC Forward X Vibration | 0.0260 | 0.0545 | 0.9999         |

**Πίνακας 2** – Αποτελέσματα Compressor #2

### 5.3.1 Outlet Temperature

Το μοντέλο πρόβλεψης της θερμοκρασίας εξόδου επιτυγχάνει R<sup>2</sup> ίσο με 0.9998, παρουσιάζοντας εξαιρετική συμφωνία μεταξύ πραγματικών και προβλεπόμενων τιμών.

### 5.3.2 Discharge Pressure

Η πρόβλεψη της πίεσης κατάθλιψης παρουσιάζει επίσης πολύ υψηλή ακρίβεια, με R<sup>2</sup> ίσο με 0.9998 και ιδιαίτερα χαμηλά σφάλματα.

### 5.3.3 HPC Aft X Vibration


Το μοντέλο των κραδασμών HPC Aft X επιτυγχάνει R<sup>2</sup> ίσο με 0.9997, επιβεβαιώνοντας την αποτελεσματικότητα της μεθοδολογίας που ακολουθήθηκε.

### 5.3.4 HPC Aft Y Vibration

Η μεταβλητή HPC Aft Y παρουσιάζει R<sup>2</sup> ίσο με 0.9996 και πολύ μικρές τιμές σφάλματος, γεγονός που δείχνει εξαιρετική δυνατότητα πρόβλεψης.

### 5.3.5 HPC Forward X Vibration

Η καλύτερη συνολικά επίδοση της εργασίας παρατηρείται στη μεταβλητή HPC Forward X Vibration του Compressor #2, όπου επιτυγχάνεται R<sup>2</sup> ίσο με 0.9999 και οι χαμηλότερες τιμές MAE και RMSE μεταξύ όλων των μοντέλων.



**Εικόνα 19** - Dashboard παρακολούθησης πραγματικών και προβλεπόμενων μεταβλητών του Compressor #2.

## 5.4 Συνολική Συζήτηση Αποτελεσμάτων

Τα αποτελέσματα δείχνουν ότι η προτεινόμενη μεθοδολογία μπορεί να προβλέψει με μεγάλη ακρίβεια κρίσιμες λειτουργικές παραμέτρους βιομηχανικών συμπιεστών φυσικού αερίου. Και στους δύο συμπιεστές οι τιμές του συντελεστή προσδιορισμού παραμένουν ιδιαίτερα υψηλές, γεγονός που επιβεβαιώνει την καταλληλότητα της Ridge Regression για την περιγραφή της συμπεριφοράς των εξεταζόμενων χρονοσειρών.

Ο Compressor #2 παρουσιάζει συνολικά καλύτερη απόδοση σε όλες τις μεταβλητές συγκριτικά με τον Compressor #1. Η διαφορά αυτή πιθανόν σχετίζεται με τη μεγαλύτερη σταθερότητα της λειτουργίας του ή με μικρότερη μεταβλητότητα των δεδομένων που χρησιμοποιήθηκαν κατά την εκπαίδευση και αξιολόγηση των μοντέλων.

Η καλύτερη συνολικά επίδοση παρατηρείται στη μεταβλητή HPC Forward X Vibration του Compressor #2, με  $R^2$  ίσο με 0.9999, ενώ η χαμηλότερη επίδοση εμφανίζεται στη μεταβλητή HPC Forward X Vibration του Compressor #1, με  $R^2$  ίσο με 0.9802. Παρ' όλα αυτά, ακόμη και η χαμηλότερη επίδοση παραμένει ιδιαίτερα υψηλή και επιβεβαιώνει την ικανότητα των μοντέλων να αναπαράγουν τη λειτουργική συμπεριφορά των συμπιεστών.

Συνολικά, τα αποτελέσματα καταδεικνύουν ότι η συνδυαστική αξιοποίηση τεχνικών feature engineering και Ridge Regression μπορεί να αποτελέσει μια αποτελεσματική και υπολογιστικά αποδοτική προσέγγιση για εφαρμογές

προγνωστικής συντήρησης σε βιομηχανικό εξοπλισμό. Η υψηλή ακρίβεια των μοντέλων δημιουργεί τις προϋποθέσεις για αξιόπιστο υπολογισμό residuals και έγκαιρη ανίχνευση αποκλίσεων κατά τη λειτουργία της πλατφόρμας.


## 6. Υλοποίηση και Λειτουργία της Πλατφόρμας Προγνωστικής Συντήρησης

### 6.1 Υποδομή LoRaWAN και Συλλογή Δεδομένων

Η συλλογή των δεδομένων πραγματοποιείται μέσω υποδομής LoRaWAN, η οποία αναπτύχθηκε για τις ανάγκες της πλατφόρμας προγνωστικής συντήρησης. Η υποδομή αποτελείται από δύο αισθητηριακούς κόμβους βασισμένους σε Raspberry Pi Pico RP2040 και SX1262 tranceiver, καθώς και από gateway Raspberry Pi 4 εξοπλισμένο με Waveshare SX1302 LoRaWAN Gateway HAT.


Κάθε αισθητηριακός κόμβος αντιστοιχεί σε έναν συμπιεστή και μεταδίδει περιοδικά τις αντίστοιχες λειτουργικές μεταβλητές προς το δίκτυο LoRaWAN. Το gateway παραλαμβάνει τα πακέτα δεδομένων και τα προωθεί προς την πλατφόρμα ChirpStack, η οποία αναλαμβάνει τη διαχείριση των LoRaWAN συσκευών και τη δρομολόγηση των δεδομένων προς τα επόμενα επίπεδα της αρχιτεκτονικής.

Για τις ανάγκες της εργασίας χρησιμοποιούνται ιστορικά δεδομένα λειτουργίας, τα οποία μετατρέπονται σε συνεχή ροή ασύρματων δεδομένων. Οι αισθητηριακοί κόμβοι μεταδίδουν ένα uplink μήνυμα κάθε 20 δευτερόλεπτα, προσομοιώνοντας τη λειτουργία ενός πραγματικού συστήματος παρακολούθησης σε σχεδόν πραγματικό χρόνο.



**Εικόνα 20** - Καταχωρημένες LoRaWAN συσκευές στην πλατφόρμα ChirpStack.

Η κατάσταση λειτουργίας κάθε συσκευής παρακολουθείται μέσω του ChirpStack, το οποίο παρέχει πληροφορίες σχετικά με την τελευταία επικοινωνία, την ποιότητα σήματος και τα στατιστικά μετάδοσης.




**Εικόνα 21** - Data packages που μεταδίδονται μέσω LoRaWAN συσκευής στο ChirpStack.

## 6.2 Ροή Δεδομένων στην Πλατφόρμα

Η πλατφόρμα προγνωστικής συντήρησης βασίζεται σε μια πολυεπίπεδη αρχιτεκτονική η οποία συνδυάζει τεχνολογίες Industrial IoT, συστήματα επεξεργασίας δεδομένων και αλγορίθμους μηχανικής μάθησης.

Τα δεδομένα μεταδίδονται από τους αισθητηριακούς κόμβους προς το LoRaWAN Gateway και στη συνέχεια προωθούνται στο ChirpStack. Μέσω MQTT τα δεδομένα μεταφέρονται στο Node-RED, όπου πραγματοποιείται η αποκωδικοποίηση και η επεξεργασία τους. Στη συνέχεια αποστέλλονται στο Predictive Service για την παραγωγή προβλέψεων, ενώ τα αποτελέσματα αποθηκεύονται στην InfluxDB και οπτικοποιούνται μέσω του Grafana.




**Εικόνα 22 - Συνολική αρχιτεκτονική της πλατφόρμας προγνωστικής συντήρησης.**

## 6.3 Επεξεργασία Δεδομένων και Πρόβλεψη

Το Node-RED αποτελεί το κεντρικό στοιχείο επεξεργασίας της πλατφόρμας. Μέσω MQTT subscriptions λαμβάνει τα μηνύματα που δημοσιεύονται από το ChirpStack και αναλαμβάνει την αποκωδικοποίηση των payloads που αποστέλλονται από τους αισθητηριακούς κόμβους.


Οι τιμές που μεταδίδονται μέσω LoRaWAN βρίσκονται σε μορφή ακεραίων αριθμών με κατάλληλο scaling, ώστε να περιορίζεται το μέγεθος των πακέτων δεδομένων. Το Node-RED ανακατασκευάζει τις αρχικές μετρήσεις και τις μετατρέπει στις αντίστοιχες φυσικές μονάδες μέτρησης.

Στη συνέχεια δημιουργούνται HTTP requests προς το Predictive Service, το οποίο φιλοξενεί τα εκπαιδευμένα μοντέλα φιλοσοφίας Ridge Regression. Για κάθε νέα μέτρηση επιστρέφονται οι αντίστοιχες προβλεπόμενες τιμές, ενώ παράλληλα υπολογίζονται και τα residuals μέσω της σύγκρισης πραγματικών και προβλεπόμενων τιμών.



**Εικόνα 23** - Συνολική ροή επεξεργασίας δεδομένων στο Node-RED.

Μετά τη λήψη των προβλέψεων πραγματοποιείται ο υπολογισμός των residuals, τα οποία αποτελούν τον βασικό δείκτη απόκλισης της πραγματικής λειτουργίας από την αναμενόμενη συμπεριφορά του συστήματος.



**Εικόνα 24** - Τμήμα της ροής Node-RED που υλοποιεί την επικοινωνία με το Predictive Service και τον υπολογισμό residuals.


## 6.4 Αποθήκευση Δεδομένων στην InfluxDB

Οι πραγματικές μετρήσεις, οι προβλεπόμενες τιμές και οι αντίστοιχες τιμές residual αποθηκεύονται σε βάση δεδομένων χρονοσειρών InfluxDB.

Η χρήση της InfluxDB επιτρέπει την αποτελεσματική διαχείριση μεγάλου όγκου χρονικών δεδομένων, καθώς κάθε καταγραφή συνοδεύεται από χρονική σήμανση και μπορεί να ανακτηθεί εύκολα για σκοπούς ανάλυσης και οπτικοποίησης.

Η δομή των δεδομένων περιλαμβάνει measurements, tags, fields και timestamps, επιτρέποντας τη δημιουργία ενός ολοκληρωμένου ιστορικού λειτουργίας για κάθε συμπιεστή.

Z




**Εικόνα 25** - Χρονοσειρές δεδομένων που αποθηκεύονται στην InfluxDB.

## 6.5 Οπτικοποίηση και Παρακολούθηση μέσω Grafana

Η οπτικοποίηση των δεδομένων πραγματοποιείται μέσω του Grafana, το οποίο συνδέεται απευθείας με την InfluxDB και ανακτά τις απαραίτητες χρονοσειρές για τη δημιουργία dashboards παρακολούθησης.

Μέσω του Grafana παρουσιάζονται τόσο οι πραγματικές όσο και οι προβλεπόμενες τιμές των μεταβλητών λειτουργίας, καθώς και οι αντίστοιχες τιμές residual. Η δυνατότητα αυτή επιτρέπει την άμεση αξιολόγηση της συμπεριφοράς των μοντέλων πρόβλεψης και την αναγνώριση πιθανών αποκλίσεων κατά τη λειτουργία του συστήματος.




Εικόνα 26 - Κεντρικό dashboard παρακολούθησης της πλατφόρμας.

## 6.6 Παρακολούθηση Compressor #1

Για τον πρώτο συμπίεστή αναπτύχθηκαν dashboards που επιτρέπουν τη συνεχή παρακολούθηση των βασικών λειτουργικών μεταβλητών και των αντίστοιχων προβλέψεων των μοντέλων μηχανικής μάθησης.

Η παράλληλη απεικόνιση πραγματικών και προβλεπόμενων τιμών επιτρέπει την άμεση αξιολόγηση της ακρίβειας των μοντέλων και την αναγνώριση αποκλίσεων κατά τη λειτουργία της πλατφόρμας.




**Εικόνα 27** - Σύγκριση πραγματικών και προβλεπόμενων τιμών θερμοκρασίας εξόδου για τον Compressor #1.



**Εικόνα 28** - Σύγκριση πραγματικών και προβλεπόμενων τιμών πίεσης κατάθλιψης για τον Compressor #1.

Οι τιμές residual παρέχουν μια επιπλέον ένδειξη σχετικά με την απόκλιση μεταξύ πραγματικής και αναμενόμενης συμπεριφοράς. Η παρακολούθησή τους επιτρέπει την αναγνώριση περιόδων κατά τις οποίες η λειτουργία του εξοπλισμού αποκλίνει από το πρότυπο λειτουργίας που έχει μάθει το μοντέλο.




**Εικόνα 29** - Παρακολούθηση residuals για τον Compressor #1.

## 6.7 Παρακολούθηση Compressor #2

Η ίδια αρχιτεκτονική εφαρμόζεται και στον δεύτερο συμπιεστή, επιτρέποντας την ανεξάρτητη παρακολούθηση των λειτουργικών μεταβλητών του μέσω της πλατφόρμας Grafana.

Τα δεδομένα συλλέγονται μέσω του δικτύου LoRaWAN, επεξεργάζονται από το Node-RED και το Predictive Service και αποθηκεύονται στην InfluxDB, ακολουθώντας την ίδια διαδικασία που περιγράφηκε για τον Compressor #1.

Το dashboard του Compressor #2 παρέχει συγκεντρωτική εικόνα της λειτουργίας του συστήματος και επιτρέπει την παρακολούθηση των πραγματικών και προβλεπόμενων τιμών των μεταβλητών λειτουργίας.



**Εικόνα 30** - Dashboard παρακολούθησης του Compressor #2.

## 6.8 Συνολική Λειτουργία της Πλατφόρμας

Η αναπτυγμένη πλατφόρμα συνδυάζει τεχνολογίες Industrial IoT, LoRaWAN, βάσεις δεδομένων χρονοσειρών και τεχνικές μηχανικής μάθησης σε ένα ενιαίο περιβάλλον προγνωστικής συντήρησης.

Η συλλογή των δεδομένων πραγματοποιείται μέσω του δικτύου LoRaWAN, η επεξεργασία μέσω του Node-RED και του Predictive Service, ενώ η αποθήκευση

και η οπτικοποίηση υλοποιούνται μέσω των InfluxDB και Grafana αντίστοιχα. Η αρχιτεκτονική αυτή επιτρέπει τη συνεχή παρακολούθηση κρίσιμων λειτουργικών παραμέτρων, την παραγωγή προβλέψεων σε σχεδόν πραγματικό χρόνο και τον υπολογισμό residuals που μπορούν να χρησιμοποιηθούν για την έγκαιρη ανίχνευση ανωμαλιών.

Τα αποτελέσματα δείχνουν ότι η αξιοποίηση ανοιχτού λογισμικού και τεχνολογιών χαμηλού κόστους μπορεί να οδηγήσει στην ανάπτυξη μιας ολοκληρωμένης πλατφόρμας προγνωστικής συντήρησης με δυνατότητα εφαρμογής σε πραγματικές βιομηχανικές εγκαταστάσεις.

## 7. Συζήτηση Αποτελεσμάτων και Τεχνικές Προκλήσεις

### 7.1 Περιορισμοί των Διαθέσιμων Δεδομένων

Η ανάπτυξη των μοντέλων πρόβλεψης βασίζεται σε ιστορικά δεδομένα λειτουργίας πραγματικών βιομηχανικών συμπιεστών φυσικού αερίου. Τα δεδομένα προέρχονται από αναφορές λειτουργίας του συστήματος παρακολούθησης της εγκατάστασης και περιλαμβάνουν κρίσιμες λειτουργικές μεταβλητές όπως θερμοκρασίες, πιέσεις και μετρήσεις κραδασμών.

Παρότι τα δεδομένα προέρχονται από πραγματικό βιομηχανικό εξοπλισμό, η εργασία παρουσιάζει ορισμένους περιορισμούς που σχετίζονται με τη διαθεσιμότητα και τη μορφή των πληροφοριών. Η αρχική χρονική ανάλυση των μετρήσεων είναι ωριαία, γεγονός που περιορίζει τη δυνατότητα παρακολούθησης ταχέων μεταβολών της λειτουργίας του εξοπλισμού. Σε πραγματικές εφαρμογές προγνωστικής συντήρησης χρησιμοποιούνται συχνά δεδομένα με σημαντικά υψηλότερη συχνότητα δειγματοληψίας, ιδιαίτερα για μεταβλητές όπως οι κραδασμοί, όπου η έγκαιρη ανίχνευση ανωμαλιών εξαρτάται σε μεγάλο βαθμό από τη λεπτομερή καταγραφή της δυναμικής συμπεριφοράς του εξοπλισμού.

Επιπλέον, η διαθέσιμη πληροφορία περιορίζεται στις μεταβλητές που περιλαμβάνονται στα ιστορικά αρχεία. Δεν υπάρχει πρόσβαση σε πρόσθετα δεδομένα λειτουργίας, δεδομένα συντήρησης ή ιστορικό βλαβών, τα οποία θα μπορούσαν να αξιοποιηθούν για την ανάπτυξη πιο σύνθετων μοντέλων πρόβλεψης και τη βελτίωση της διαδικασίας ανίχνευσης ανωμαλιών.

Παρά τους περιορισμούς αυτούς, το διαθέσιμο σύνολο δεδομένων αποδείχθηκε επαρκές για την ανάπτυξη και αξιολόγηση της προτεινόμενης αρχιτεκτονικής

προγνωστικής συντήρησης και επέτρεψε την εξαγωγή χρήσιμων συμπερασμάτων σχετικά με τη λειτουργία των μοντέλων πρόβλεψης.

## 7.2 Περιορισμοί της Προσομοίωσης Πραγματικού Χρόνου

Η πλατφόρμα που αναπτύχθηκε στο πλαίσιο της παρούσας εργασίας προσομοιώνει τη λειτουργία ενός πραγματικού συστήματος προγνωστικής συντήρησης σε περιβάλλον σχεδόν πραγματικού χρόνου. Ωστόσο, τα δεδομένα που διακινούνται στο σύστημα δεν προέρχονται από εγκατεστημένους αισθητήρες πεδίου αλλά από ιστορικές καταγραφές λειτουργίας οι οποίες αναπαράγονται μέσω των αισθητηριακών κόμβων LoRaWAN.

Οι Raspberry Pi Pico λειτουργούν ως γεννήτριες ασύρματων δεδομένων, αναπαράγοντας τις ιστορικές μετρήσεις και μεταδίδοντάς τες μέσω του δικτύου LoRaWAN. Με τον τρόπο αυτό επιτυγχάνεται η πλήρης δοκιμή της αρχιτεκτονικής επικοινωνίας και επεξεργασίας δεδομένων, χωρίς όμως να υπάρχει άμεση σύνδεση με πραγματικό βιομηχανικό εξοπλισμό κατά τη διάρκεια της λειτουργίας της πλατφόρμας.

Η προσέγγιση αυτή επιλέχθηκε ώστε να είναι δυνατή η αξιολόγηση όλων των επιμέρους τμημάτων της αρχιτεκτονικής χωρίς να απαιτείται πρόσβαση σε πραγματικό σύστημα παραγωγής δεδομένων. Παράλληλα, παρέχει τη δυνατότητα επαναληψιμότητας των δοκιμών και ελέγχου της συμπεριφοράς της πλατφόρμας κάτω από διαφορετικά σενάρια λειτουργίας.

Επομένως, η παρούσα υλοποίηση αποτελεί ένα proof-of-concept σύστημα, το οποίο αποδεικνύει τη λειτουργικότητα της προτεινόμενης αρχιτεκτονικής και μπορεί να αποτελέσει τη βάση για μελλοντική διασύνδεση με πραγματικούς αισθητήρες και βιομηχανικές εγκαταστάσεις.

## 7.3 Τεχνικές Προκλήσεις Υλοποίησης

Η ανάπτυξη μιας ολοκληρωμένης πλατφόρμας προγνωστικής συντήρησης απαιτεί τη συνεργασία πολλών διαφορετικών τεχνολογιών και λογισμικών συστημάτων. Κατά τη διάρκεια της υλοποίησης προέκυψαν τεχνικές προκλήσεις που σχετίζονται τόσο με την επικοινωνία όσο και με την επεξεργασία και διαχείριση των δεδομένων.

Μία από τις σημαντικότερες προκλήσεις αφορά τη διασύνδεση των επιμέρους επιπέδων της αρχιτεκτονικής. Η αξιόπιστη μεταφορά δεδομένων από τους αισθητηριακούς κόμβους προς το ChirpStack, η δημοσίευση μέσω MQTT και η

επεξεργασία μέσω Node-RED απαιτούν σωστή παραμετροποίηση όλων των εμπλεκόμενων συστημάτων.

Ιδιαίτερη προσοχή απαιτήθηκε επίσης στη διαδικασία κωδικοποίησης και αποκωδικοποίησης των δεδομένων. Οι μετρήσεις μεταδίδονται σε μορφή ακεραίων τιμών με χρήση scaling, ώστε να περιορίζεται το μέγεθος των πακέτων LoRaWAN. Κατά συνέπεια, η σωστή ανακατασκευή των πραγματικών φυσικών μεγεθών αποτελεί κρίσιμο βήμα για την ορθή λειτουργία της πλατφόρμας.

Επιπλέον, η υλοποίηση του Predictive Service απαιτεί τον συγχρονισμό μεταξύ των πραγματικών μετρήσεων, των προβλέψεων των μοντέλων και των residuals που υπολογίζονται σε κάθε χρονική στιγμή. Η διαδικασία αυτή είναι απαραίτητη ώστε οι πληροφορίες που αποθηκεύονται στην InfluxDB και προβάλλονται στο Grafana να είναι συνεπείς και χρονικά ευθυγραμμισμένες.

Παρά την πολυπλοκότητα της αρχιτεκτονικής, η αξιοποίηση τεχνολογιών ανοικτού λογισμικού επέτρεψε την επιτυχή ολοκλήρωση της πλατφόρμας και τη διασύνδεση όλων των απαιτούμενων υποσυστημάτων.

## 7.4 Αξιολόγηση της Προτεινόμενης Αρχιτεκτονικής

Η αρχιτεκτονική που αναπτύχθηκε παρουσιάζει σημαντικά πλεονεκτήματα ως προς την επεκτασιμότητα, την ευελιξία και το κόστος υλοποίησης. Η χρήση ανεξάρτητων επιπέδων λειτουργίας επιτρέπει την εύκολη τροποποίηση ή αντικατάσταση επιμέρους στοιχείων χωρίς να επηρεάζεται η συνολική λειτουργία της πλατφόρμας.

Η αξιοποίηση του LoRaWAN προσφέρει μια οικονομική λύση για τη μεταφορά δεδομένων σε εφαρμογές βιομηχανικής παρακολούθησης, ενώ το MQTT επιτρέπει την αποδοτική και αξιόπιστη ανταλλαγή δεδομένων μεταξύ των διαφορετικών συστημάτων. Παράλληλα, το Node-RED παρέχει ένα ιδιαίτερα εύελικτο περιβάλλον για την ανάπτυξη ροών επεξεργασίας δεδομένων χωρίς την ανάγκη σύνθετου προγραμματισμού.

Ένα από τα σημαντικότερα χαρακτηριστικά της αρχιτεκτονικής είναι η εκτεταμένη χρήση τεχνολογιών ανοικτού λογισμικού. Το ChirpStack, το Node-RED, η InfluxDB, το Grafana και τα εργαλεία μηχανικής μάθησης που χρησιμοποιούνται στην εργασία διατίθενται ελεύθερα, γεγονός που μειώνει σημαντικά το κόστος υλοποίησης και συντήρησης.

Επιπλέον, η αρχιτεκτονική δεν εξαρτάται από συγκεκριμένο κατασκευαστή εξοπλισμού ή λογισμικού. Η δυνατότητα ενσωμάτωσης διαφορετικών

αισθητήρων, συστημάτων επικοινωνίας και μοντέλων πρόβλεψης καθιστά την πλατφόρμα κατάλληλη για ένα ευρύ φάσμα βιομηχανικών εφαρμογών.

## 7.5 Δυνατότητα Βιομηχανικής Εφαρμογής

Η προτεινόμενη πλατφόρμα παρουσιάζει σημαντικές δυνατότητες εφαρμογής σε πραγματικά βιομηχανικά περιβάλλοντα. Η αρχιτεκτονική μπορεί να προσαρμοστεί εύκολα σε διαφορετικούς τύπους εξοπλισμού, όπως συμπίεστές, αντλίες, ηλεκτροκινητήρες, ανεμιστήρες και γενικότερα σε περιστρεφόμενα μηχανήματα που απαιτούν συνεχή παρακολούθηση της λειτουργικής τους κατάστασης.

Σε εγκαταστάσεις του ενεργειακού τομέα, όπως σταθμοί συμπίεσης φυσικού αερίου, μονάδες παραγωγής ενέργειας και βιομηχανικές εγκαταστάσεις διεργασιών, η δυνατότητα έγκαιρης ανίχνευσης αποκλίσεων μπορεί να συμβάλει στη μείωση των απρογραμμάτιστων διακοπών λειτουργίας και στη βελτιστοποίηση των διαδικασιών συντήρησης.

Η χρήση τεχνολογιών χαμηλού κόστους και ανοικτού λογισμικού καθιστά την προσέγγιση ιδιαίτερα ελκυστική για πιλοτικές εγκαταστάσεις ή για οργανισμούς που επιθυμούν να υλοποιήσουν λύσεις προγνωστικής συντήρησης χωρίς την ανάγκη μεγάλων επενδύσεων σε εμπορικές πλατφόρμες.

Παράλληλα, η αρχιτεκτονική μπορεί να διασυνδεθεί με υφιστάμενα συστήματα SCADA, DCS ή ιστορικές βάσεις δεδομένων, επιτρέποντας την ενσωμάτωση των δυνατοτήτων προγνωστικής συντήρησης σε ήδη εγκατεστημένες βιομηχανικές υποδομές.

Συνολικά, τα αποτελέσματα της εργασίας δείχνουν ότι η συνδυαστική αξιοποίηση τεχνολογιών Industrial IoT, LoRaWAN, μηχανικής μάθησης και ανοικτού λογισμικού μπορεί να αποτελέσει μια αξιόπιστη και τεχνικά εφικτή προσέγγιση για την ανάπτυξη σύγχρονων συστημάτων προγνωστικής συντήρησης στον βιομηχανικό και ενεργειακό τομέα.

## 8. Συμπεράσματα και Μελλοντικές Επεκτάσεις

### 8.1 Συμπεράσματα

Η παρούσα διπλωματική εργασία είχε ως στόχο την ανάπτυξη μιας ολοκληρωμένης πλατφόρμας προγνωστικής συντήρησης για βιομηχανικούς

συμπιεστές φυσικού αερίου, αξιοποιώντας τεχνολογίες Industrial Internet of Things (IIoT), ασύρματη επικοινωνία LoRaWAN και τεχνικές μηχανικής μάθησης.

Στο πλαίσιο της εργασίας σχεδιάστηκε και υλοποιήθηκε μια πλήρης αρχιτεκτονική συλλογής, επεξεργασίας, αποθήκευσης και οπτικοποίησης δεδομένων. Η αρχιτεκτονική περιλαμβάνει αισθητηριακούς κόμβους βασισμένους σε Raspberry Pi Pico RP2040 και SX1262, υποδομή LoRaWAN με χρήση ChirpStack, μηχανισμό ανταλλαγής δεδομένων μέσω MQTT, επεξεργασία δεδομένων με Node-RED, αποθήκευση χρονοσειρών σε InfluxDB και οπτικοποίηση μέσω Grafana.

Παράλληλα, αναπτύχθηκαν μοντέλα μηχανικής μάθησης βασισμένα στη μέθοδο Ridge Regression με στόχο την πρόβλεψη κρίσιμων λειτουργικών παραμέτρων των συμπιεστών. Η διαδικασία εκπαίδευσης βασίστηκε σε ιστορικά δεδομένα λειτουργίας του έτους 2021, ενώ τα δεδομένα του έτους 2022 χρησιμοποιήθηκαν για την προσομοίωση της online λειτουργίας της πλατφόρμας.

Τα αποτελέσματα έδειξαν ότι τα μοντέλα μπορούν να αναπαράγουν με ιδιαίτερα υψηλή ακρίβεια τη συμπεριφορά των εξεταζόμενων μεταβλητών. Οι τιμές του συντελεστή προσδιορισμού  $R^2$  κυμάνθηκαν από 0.9802 έως 0.9999, επιβεβαιώνοντας την αποτελεσματικότητα της προτεινόμενης μεθοδολογίας. Παράλληλα, η χρήση residuals επέτρεψε την ποσοτικοποίηση της απόκλισης μεταξύ πραγματικής και αναμενόμενης συμπεριφοράς, δημιουργώντας τις προϋποθέσεις για εφαρμογές έγκαιρης ανίχνευσης ανωμαλιών.

Επιπλέον, η εργασία απέδειξε ότι είναι εφικτή η ανάπτυξη μιας ολοκληρωμένης πλατφόρμας προγνωστικής συντήρησης χρησιμοποιώντας αποκλειστικά τεχνολογίες ανοικτού λογισμικού και εξοπλισμό χαμηλού κόστους. Η προσέγγιση αυτή μειώνει σημαντικά το κόστος υλοποίησης και επιτρέπει την εύκολη προσαρμογή της πλατφόρμας σε διαφορετικά βιομηχανικά περιβάλλοντα.

Συνολικά, τα αποτελέσματα επιβεβαιώνουν ότι ο συνδυασμός τεχνολογιών IIoT, LoRaWAN και μηχανικής μάθησης μπορεί να αποτελέσει μια αποτελεσματική λύση για την ανάπτυξη συστημάτων προγνωστικής συντήρησης στον ενεργειακό και βιομηχανικό τομέα.

## 8.2 Συνεισφορά της Εργασίας

Η κύρια συνεισφορά της εργασίας δεν περιορίζεται στην ανάπτυξη ενός μοντέλου πρόβλεψης, αλλά αφορά τη δημιουργία μιας ολοκληρωμένης αρχιτεκτονικής Industrial IoT για εφαρμογές προγνωστικής συντήρησης.

Συγκεκριμένα, η εργασία συνδυάζει σε ένα ενιαίο περιβάλλον:

- τεχνολογίες Industrial IoT,
- δίκτυα LoRaWAN,
- πρωτόκολλα ανταλλαγής δεδομένων MQTT,
- εργαλεία επεξεργασίας δεδομένων Node-RED,
- βάσεις δεδομένων χρονοσειρών InfluxDB,
- πλατφόρμες οπτικοποίησης Grafana,
- και αλγορίθμους μηχανικής μάθησης για πρόβλεψη λειτουργικών μεταβλητών.

Η συγκεκριμένη προσέγγιση παρουσιάζει ιδιαίτερο ενδιαφέρον, καθώς αναπαριστά με ρεαλιστικό τρόπο την αρχιτεκτονική που θα μπορούσε να εφαρμοστεί σε πραγματικές βιομηχανικές εγκαταστάσεις. Παράλληλα, η αξιοποίηση τεχνολογιών ανοικτού λογισμικού αποδεικνύει ότι είναι δυνατή η ανάπτυξη προηγμένων λύσεων προγνωστικής συντήρησης χωρίς την ανάγκη χρήσης εξειδικευμένων εμπορικών πλατφορμών.

Ένα ακόμη σημαντικό στοιχείο της εργασίας είναι η σύνδεση ιστορικών βιομηχανικών δεδομένων με μια πλήρως λειτουργική online πλατφόρμα παρακολούθησης, προσεγγίζοντας τον τρόπο λειτουργίας ενός πραγματικού συστήματος predictive maintenance.

### 8.3 Μελλοντικές Επεκτάσεις

Παρότι η πλατφόρμα που αναπτύχθηκε παρουσιάζει πλήρη λειτουργικότητα, υπάρχουν αρκετές δυνατότητες περαιτέρω εξέλιξης και βελτίωσης.

Μία από τις σημαντικότερες επεκτάσεις αφορά τη διασύνδεση του συστήματος με πραγματικούς αισθητήρες εγκατεστημένους σε βιομηχανικό εξοπλισμό. Με τον τρόπο αυτό η πλατφόρμα θα μπορεί να λειτουργεί σε πραγματικό χρόνο χωρίς την ανάγκη αναπαραγωγής ιστορικών δεδομένων.

Επιπλέον, θα μπορούσαν να ενσωματωθούν πρόσθετες μεταβλητές λειτουργίας, όπως:

- θερμοκρασίες εδράνων,
- ηλεκτρικά μεγέθη κινητήρων,
- θέσεις βαλβίδων,
- δεδομένα συστημάτων λίπανσης,

- και πρόσθετες μετρήσεις κραδασμών.

Η επέκταση του διαθέσιμου συνόλου δεδομένων θα μπορούσε να βελτιώσει περαιτέρω την ακρίβεια των μοντέλων και να αυξήσει τις δυνατότητες ανίχνευσης ανωμαλιών.

Από πλευράς μηχανικής μάθησης, ενδιαφέρον παρουσιάζει η αξιολόγηση πιο σύνθετων αλγορίθμων, όπως:

- Random Forest,
- Gradient Boosting,
- XGBoost,
- Long Short-Term Memory (LSTM) νευρωνικά δίκτυα,
- και μοντέλα ανίχνευσης ανωμαλιών χωρίς επίβλεψη (unsupervised anomaly detection).

Μια ακόμη πιθανή επέκταση αφορά την υλοποίηση μηχανισμών online learning, όπου τα μοντέλα θα μπορούν να ενημερώνονται δυναμικά καθώς συλλέγονται νέα δεδομένα λειτουργίας.

Παράλληλα, η πλατφόρμα θα μπορούσε να επεκταθεί ώστε να υποστηρίζει μηχανισμούς ειδοποιήσεων και συναγερμών, αποστέλλοντας αυτόματα ενημερώσεις όταν οι τιμές residual υπερβαίνουν προκαθορισμένα όρια.

Τέλος, η ανάπτυξη cloud-based ή edge-computing εκδόσεων της αρχιτεκτονικής θα μπορούσε να επιτρέψει την εφαρμογή της σε μεγαλύτερες και γεωγραφικά κατακεντρωμένες βιομηχανικές εγκαταστάσεις, ενισχύοντας περαιτέρω τις δυνατότητες παρακολούθησης και ανάλυσης δεδομένων.

## 8.4 Τελική Αποτίμηση

Η μετάβαση της βιομηχανίας προς το Industry 4.0 και τον ψηφιακό μετασχηματισμό δημιουργεί αυξανόμενη ανάγκη για λύσεις που επιτρέπουν τη συνεχή παρακολούθηση και αξιολόγηση της κατάστασης κρίσιμου εξοπλισμού. Η προγνωστική συντήρηση αποτελεί έναν από τους βασικούς πυλώνες αυτής της μετάβασης, καθώς συμβάλλει στη βελτίωση της αξιοπιστίας, στη μείωση του κόστους συντήρησης και στην αποτελεσματικότερη διαχείριση των διαθέσιμων πόρων.

Η εργασία αυτή παρουσιάζει μια ολοκληρωμένη προσέγγιση που συνδυάζει τεχνολογίες Industrial IoT, ασύρματη επικοινωνία, επεξεργασία δεδομένων και

μηχανική μάθηση σε μια ενιαία πλατφόρμα. Τα αποτελέσματα που προέκυψαν δείχνουν ότι τέτοιες λύσεις μπορούν να υλοποιηθούν με σχετικά μικρό κόστος και να αποτελέσουν τη βάση για την ανάπτυξη σύγχρονων συστημάτων προγνωστικής συντήρησης στον ενεργειακό και βιομηχανικό τομέα.

Η εμπειρία που αποκτήθηκε κατά την ανάπτυξη της πλατφόρμας επιβεβαιώνει ότι η αξιοποίηση ανοικτών τεχνολογιών και εργαλείων μπορεί να προσφέρει σημαντικές δυνατότητες τόσο για ερευνητικές εφαρμογές όσο και για πραγματικές βιομηχανικές εγκαταστάσεις, συμβάλλοντας στην περαιτέρω διάδοση των τεχνολογιών Industry 4.0.

## Κατάλογος Βιβλιογραφίας

- Banks, A & Gupta, R 2014, MQTT Version 3.1.1, OASIS Standard.
- Boyes, H, Hallaq, B, Cunningham, J & Watson, T 2018, 'The Industrial Internet of Things (IIoT): An Analysis Framework', Computers in Industry, vol. 101, pp. 1–12.
- Brownlee, J 2019, Machine Learning Mastery with Time Series Forecasting, Machine Learning Mastery, Melbourne.
- Carvalho, TP, Soares, FAAMN, Vita, R, Francisco, RP, Basto, JP & Alcalá, SG 2019, 'A Systematic Literature Review of Machine Learning Methods Applied to Predictive Maintenance', Computers & Industrial Engineering, vol. 137, p. 106024.
- Çınar, ZM, Nuhu, AA, Zeeshan, Q, Korhan, O, Asmael, M & Safaei, B 2020, 'Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0', Sustainability, vol. 12, no. 19, p. 8211.
- Ertürk, MA, Aydın, MA, Büyükakkaşlar, MT & Evirgen, H 2019, 'A Survey on LoRaWAN Architecture, Protocol and Technologies', Future Internet, vol. 11, no. 10, p. 216.
- Géron, A 2022, Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow, 3rd edn, O'Reilly Media, Sebastopol.
- Grafana Labs n.d., Grafana Documentation, viewed 15 July 2026, <<https://grafana.com/docs>>.
- Hastie, T, Tibshirani, R & Friedman, J 2009, The Elements of Statistical Learning, 2nd edn, Springer, New York.
- Hoerl, AE & Kennard, RW 1970, 'Ridge Regression: Biased Estimation for Nonorthogonal Problems', Technometrics, vol. 12, no. 1, pp. 55–67.
- Hoerl, AE, Kennard, RW & Baldwin, KF 1975, 'Ridge Regression: Some Simulations', Communications in Statistics, vol. 4, no. 2, pp. 105–123.
- InfluxData n.d., InfluxDB Documentation, viewed 15 July 2026, <<https://docs.influxdata.com>>.
- James, G, Witten, D, Hastie, T & Tibshirani, R 2021, An Introduction to Statistical Learning, 2nd edn, Springer, New York.
- Krupitzer, C, Wagenhals, T, Züfle, M et al. 2020, 'A Survey on Predictive Maintenance for Industry 4.0', arXiv preprint arXiv:2002.08224.

- Kuhn, M & Johnson, K 2019, *Feature Engineering and Selection: A Practical Approach for Predictive Models*, CRC Press, Boca Raton.
- LoRa Alliance 2020, *LoRaWAN Specification v1.0.4*, LoRa Alliance, Fremont.
- OpenJS Foundation n.d., *Node-RED Documentation*, viewed 15 July 2026, <<https://nodered.org/docs>>.
- Paul, B 2020, 'An Overview of LoRaWAN', *WSEAS Transactions on Communications*, vol. 19, pp. 119–124.
- Raza, U, Kulkarni, P & Sooriyabandara, M 2017, 'Low Power Wide Area Networks: An Overview', *IEEE Communications Surveys & Tutorials*, vol. 19, no. 2, pp. 855–873.
- Serradilla, O, Zugasti, E & Zurutuza, U 2020, 'Deep Learning Models for Predictive Maintenance: A Survey, Comparison, Challenges and Prospect', *Applied Sciences*, vol. 10, no. 21, p. 7506.
- Sisinni, E, Saifullah, A, Han, S, Jennehag, U & Gidlund, M 2018, 'Industrial Internet of Things: Challenges, Opportunities, and Directions', *IEEE Transactions on Industrial Informatics*, vol. 14, no. 11, pp. 4724–4734.
- Sundaram, JPS, Du, W & Zhao, Z 2020, 'A Survey on LoRa Networking: Research Problems, Current Solutions and Open Issues', *IEEE Communications Surveys & Tutorials*, vol. 22, no. 1, pp. 371–388.
- Xu, LD, He, W & Li, S 2014, 'Internet of Things in Industries: A Survey', *IEEE Transactions on Industrial Informatics*, vol. 10, no. 4, pp. 2233–2243.
- Zheng, A & Casari, A 2018, *Feature Engineering for Machine Learning: Principles and Techniques for Data Scientists*, O'Reilly Media, Sebastopol.
- Zhu, T, Ran, Y, Zhou, X & Wen, Y 2019, 'A Survey of Predictive Maintenance: Systems, Purposes and Approaches', *arXiv preprint arXiv:1912.07383*.