

Πανεπιστήμιο Πειραιώς
Τμήμα Ψηφιακών Συστημάτων
Πρόγραμμα Μεταπτυχιακών Σπουδών
ΠΜΣ: ΨΗΦΙΑΚΑ ΣΥΣΤΗΜΑΤΑ ΚΑΙ ΥΠΗΡΕΣΙΕΣ
ΚΑΤΕΥΘΥΝΣΗ: ΠΡΟΗΓΜΕΝΑ ΠΛΗΡΟΦΟΡΙΑΚΑ ΣΥΣΤΗΜΑΤΑ



Μεταπτυχιακή Διπλωματική Εργασία

ΥΛΟΠΟΙΗΣΗ ΚΑΙ ΠΡΑΓΜΑΤΟΠΟΙΗΣΗ ΑΛΓΟΡΙΘΜΩΝ ΠΡΟΛΗΠΤΙΚΗΣ ΣΥΝΤΗΡΗΣΗΣ

Μιχελή Κωνσταντίνα

Ιανουάριος 2020

Επιβλέπων Καθηγητής
Δημοσθένης Κυριαζής, Καθηγητής
Πανεπιστήμιο Πειραιώς

ΠΕΡΙΕΧΟΜΕΝΑ

- Περίληψη.....σελ. 4
- Εισαγωγή.....σελ. 6
- Σκοπός.....σελ. 7
- Αρχιτεκτονική Συστήματος.....σελ. 8
- Δεδομένα.....σελ. 8
- Μεθοδολογία.....σελ. 8
- Κεφάλαιο 1
 - Συντήρηση.....σελ. 10
 - 1.1. Ορισμός Συντήρησης.....σελ. 10
 - 1.2 Διορθωτική συντήρηση (Reactive maintenance).....σελ. 10
 - 1.3 Προληπτική συντήρηση (Preventive Maintenance ή PMS).....σελ. 11
 - 1.4 Προβλεπτική συντήρηση (Predictive Maintenance) .σελ. 11
 - 1.5 Προγνωστική Συντήρηση (Proactive Maintenance).....σελ. 12
- Κεφάλαιο 2
 - Μηχανική Μάθηση.....σελ. 14
 - 2.1 Βασικές Έννοιες της Μηχανικής Μάθησης.....σελ. 14
 - 2.2 Αναπαράσταση Δεδομένων.....σελ. 16
 - 2.3 Κατηγοριοποίηση Μοντέλων Μ.Μ.....σελ. 17
 - 2.4 Αξιολόγηση Απόδοσης και Overfitting.....σελ. 17
 - 2.5 Κλιμάκωση Δεδομένων.....σελ. 19
 - 2.6 Rescaling.....σελ. 20
 - 2.7 Standardization.....σελ. 20
 - 2.8 Επιλογή Αλγορίθμου Machine Learningσελ. 20
 - 2.9 LSTM.....σελ. 21
 - 2.10σελ. 23
 - 2.10.1 Βασικές έννοιες του SVMσελ. 23
 - 2.10.2 Insight in One Class SVM.....σελ. 24
 - 2.11 Gradient Boosting.....σελ. 24
 - 2.12 Cointegration.....σελ. 25
 - 2.13 Matrix profile.....σελ. 26
 - 2.14 Permutation Entropy.....σελ. 27
- Κεφάλαιο 3
 - Anomaly Detection.....σελ. 29
 - 3.1 Τι είναι οι ανωμαλίες.....σελ.30
 - 3.2 Είδη Ανωμαλιών.....σελ. 33
 - 3.2.1. Σημειακές (point anomalies).....σελ. 33
 - 3.2.2. Ανωμαλίες που σχετίζονται με το περιβάλλον (contextual anomalies).....σελ. 33
 - 3.2.3. Συλλογικές ακραίες τιμές (collective anomalies)...σελ. 34
 - 3.3 Κατηγορίες τεχνικών ανίχνευσης ακραίων τιμών.....σελ. 35

- 3.3.1.Επιβλεπόμενες(supervised).....σελ. 35
 - 3.3.2.Μη επιβλεπόμενες (unsupervised).....σελ. 35
 - 3.3.3. Ημι-επιβλεπόμενες (semi-supervised).....σελ. 35
 - 3.4 Τεχνικές ανίχνευσης ακραίων τιμών.....σελ. 36
 - 3.4.1 Τεχνικές βασισμένες στην ταξινόμηση (classification).....σελ. 36
 - 3.4.2 Τεχνικές βασισμένες στην εγγύτητα (proximity) ή στον κοντινότερο γείτονα (nearest neighbor).....σελ. 37
 - 3.4.3 Τεχνικές βασισμένες στην ομαδοποίηση (clustering).....σελ. 38
 - 3.4.4. Τεχνικές ανίχνευσης ακραίων τιμών βασισμένες στη στατιστική.....σελ. 40
 - 3.4.5 Χειρισμός ακραίων τιμών που σχετίζονται με το περιβάλλον(contextual anomalies).....σελ. 42
 - 3.4.6 Χειρισμός συλλογικών ακραίων τιμών (collective anomalies).....σελ. 44
 - 3.5 Σχετική Ερευνα Εύρεσης Ανωμαλιών.....σελ. 44
 - 3.6 Ανίχνευση ακραίων τιμών στις επιχειρήσεις.....σελ 45
 - 3.7 Ανίχνευση Ανωμαλιών στη Ναυτιλία.....σελ 46
- Κεφάλαιο 4^ο
 - Υλοποίηση Συστήματος.....σελ. 51
 - 4.1 Problem Setup.....σελ. 51
 - 4.2 Δομή – Αρχιτεκτονική Συστήματος.....σελ. 52
 - 4.3 Δεδομένα.....σελ. 55
 - 4.3.1 Πηγή Δεδομένων.....σελ. 55
 - 4.3.2 Προ-Επεξεργασία Δεδομένων.....σελ. 57
 - 4.3.3 Feature importance.....σελ. 60
 - 4.4 Επιλογή κατάλληλου Αλγορίθμου – Υλοποίηση.....σελ. 63
 - 4.4.1. Level Anomaly Detector.....σελ. 63
 - 4.4.2. Gradient Boosting Classification Approach.....σελ. 63
 - 4.4.3. LSTM.....σελ. 65
 - 4.4.4. One Class SVM.....σελ. 69
 - 4.4.5. Weighted Permutation Entropy.....σελ. 72
 - 4.4.6 Second-Level Anomaly Detector.....σελ. 75
 - 4.4.7 Single Channel LSTM.....σελ. 76
 - 4.4.8 Cointegration Approach.....σελ. 79
 - 4.4.9 Matrix Profile.....σελ. 82
- Κεφάλαιο 5^ο
 - Συμπεράσματα – Προτάσεις.....σελ. 85
 - 5.1 Αποτελέσματα.....σελ. 85
 - 5.1.1. Γενικά.....σελ.87
 - 5.1.2. Υλοποίηση.....σελ. 87
 - 5.1.3. Future Work.....σελ.88

- 5.2. Συμπεράσματα.....σελ. 89
- 5.3. Πηγές.....σελ. 90

Περίληψη

Δεδομένου ότι τα τελευταία χρόνια τα εμπορικά πλοία αποστέλλουν αυξανόμενα ποσά δεδομένων από τους εγκατεστημένους σε αυτά αισθητήρες στα κέντρα δεδομένων τους, έχει προκύψει η ανάγκη για βελτιωμένα εργαλεία ανάλυσης δεδομένων για να βοηθήσουν τους μηχανικούς, οι οποίοι παρακολουθούν τα δεδομένα αυτά, να μειώσουν τους κίνδυνους (λειτουργικούς, επιχειρησιακούς κτλ). Λαμβάνοντας υπόψιν ότι η Προγνωστική Συντήρηση αποτελεί πολύτιμο κομμάτι της μείωσης του συνολικού κόστους και του λειτουργικού κινδύνου, σε αυτό το δοκίμιο, επιδεικνύουμε την αποτελεσματικότητα ορισμένων προσεγγίσεων Anomaly Detection (Αναγνώρισης Ανωμαλιών) σε δεδομένα χρονοσειρών, που βασίζονται στη Μηχανική Μάθηση καθώς και στη Στατιστική Ανάλυση, όπως τα δίκτυα LSTM, το SVM One Class, το Matrix Profile, Έλεγχος συνοχής κλπ. Σκοπό των ανωτέρω είναι η πρόβλεψη της κατάστασης ορισμένων τμημάτων της κύριας μηχανής του πλοίου. Τα δεδομένα για τα οποία μελετήσαμε τις διαφορετικές προσεγγίσεις προήλθαν από ροές δεδομένων αισθητήρων εγκατεστημένων σε 10 σκάφη μιας Μεγάλης Ελληνικής Ναυτιλιακής Εταιρείας. Τέλος, έχοντας λάβει υπόψιν τα αποτελέσματα των δοκιμών αυτών προτείνουμε ένα συμπληρωματικό μοντέλο που αποτελείται από ένα συνδυασμό των προσεγγίσεων που μελετήθηκαν υποσχόμενοι καλύτερα αποτελέσματα. Το προτεινόμενο συνδυαστικό μοντέλο αποτελείται από δύο επίπεδα, σαν πρώτο βήμα εκτελείται μια πρόβλεψη να αυξήσει έναν συναγερμό για υψηλό δυναμικό μιας ανωμαλίας στα εισερχόμενα δεδομένα, ενώ το δεύτερο δίνει μια πιθανότητα αυτής της ανωμαλίας να υποδεικνύει το ελάττωμα που μελετήσαμε σχετικά με το Crosshead Bearing.

Abstract

As maritime vessels send increasing amounts of sensor data to their data centers, improved data analysis tools are needed to help operations engineers, who monitor this data, to reduce operational risk. Given that, Predictive Maintenance is valuable part of reducing the overall costs and operational risk. In this essay, we demonstrate the effectiveness of some Anomaly (or Novelty) Detection approaches on time-series data, based on Machine Learning and Statistics, such as, Long Short-Term Memory (LSTMs) networks, One Class SVM, Matrix Profile, Cointegration check etc. in predicting the condition of certain parts of vessel main engine. The data on which we studied the different approaches came from data streams of sensor installed in 10 vessels of a Major Greek Maritime Company. Finally we propose a complementary model consisted of a combination of the approaches studied promising better results. The proposed model is comprised of two steps, the first step makes a prediction raising an alarm for high potential of an anomaly in the incoming data, whereas the second one gives a probability of this anomaly to indicate the studied defect about Crosshead Bearing.

Εισαγωγή

Ο κλάδος της ναυτιλίας όπως και πολλοί άλλοι εμπορικοί κλάδοι τα τελευταία χρόνια ήρθαν αντιμέτωποι με ένα οικονομικό φαινόμενο βαθιάς οικονομικής ύφεσης. Το φαινόμενο της οικονομικής κρίσης, όπως ονομάστηκε, δεν άφησε ανεπηρέαστη την ναυτιλία. Οι συνέπειες της οικονομικής κρίσης ξεκίνησαν να γίνονται ορατές στον κλάδο της ναυτιλίας περίπου το 2016. Οι εκφάνσεις αφορούσαν τόσο στις αυξημένες τιμές της αγοράς όσο και στη μείωση των ναυλωμένων πλοίων. Παράλληλα η αυξανόμενη ανησυχία για την καταστολή των εκπομπών ασκεί επιπλέον πίεση στην βιομηχανία της ναυτιλίας, η πίεση αυτή φυσικά μεταφράζεται σε μεγαλύτερα κόστη.

Οι ανωτέρω οικονομικό/περιβαλλοντικοί λόγοι οδήγησαν τις ναυτιλιακές να εφαρμόσουν ορισμένα τεχνικά μέτρα. Ωστόσο, τα περισσότερα εξ' αυτών απαιτούν υψηλό επενδυτικό κόστος, κάτι το οποίο είναι σχεδόν απαγορευτικό. Αντ' αυτού έχουν υιοθετηθεί επιχειρησιακά/λειτουργικά μέτρα όπως ο σχεδιασμός διαδρομών, η βελτιστοποίηση των καλυμμάτων και η λειτουργία του κινητήρα σε συνθήκες αργού ατμού (slow steaming).

Σήμερα, το slow steaming έχει υιοθετηθεί ως τυποποιημένη επιχειρησιακή στρατηγική προκειμένου να παραμείνει κερδοφόρα η κάθε εταιρεία στην ανταγωνιστική αγορά, καθώς είναι ο πιο άμεσος και αποτελεσματικός τρόπος να μειωθεί το λειτουργικό κόστος που συνδέεται με την κατανάλωση καυσίμων καθώς και με την περιστολή των εκπομπών. Σημειώνεται ότι, δεν αναμένεται να αυξηθεί η ταχύτητα λειτουργίας των πλοίων στο εγγύς μέλλον, καθώς το κόστος των καυσίμων αποτελεί σημαντικό παράγοντα για την κερδοφορία της ναυτιλιακής εταιρείας, παρόλο που αγορά δείχνει σημάδια ανάκαμψης.

Πέρα από τη σημαντική μείωση της κατανάλωσης καυσίμου, το slow steaming έχει ως αποτέλεσμα τη λιγότερο αποτελεσματική λειτουργία του κινητήρα και παρουσιάζει ορισμένες προκλήσεις για τα συστήματα κινητήρα. Οι περισσότερες πλοιοκτήτριες εταιρείες παρακολουθούν τους αισθητήρες που είναι εγκατεστημένοι στο πλοίο ή ειδικά στον κινητήρα του σκάφους, συμπεριλαμβανομένης της θερμοκρασίας και της πίεσης σε βασικά σημεία της κύριας μηχανής. Αυτές οι πληροφορίες, σε συνδυασμό με τα γενικότερα δεδομένα όπως η κατανάλωση ενέργειας, οι στροφές του κύριου άξονα, η ροπή του κύριου άξονα, θα μπορούσαν να είναι πολύ χρήσιμες για τον εντοπισμό πιθανής διάβρωσης του Crosshead Bearing σε αρχικά στάδια. Αυτό σημαίνει ότι η ναυτιλιακή εταιρεία θα μπορούσε να διαχειριστεί αποτελεσματικά το άμεσο ελάττωμα. Γίνεται επομένως εύκολα κατανοητό

ότι ένα σύστημα το οποίο θα «προέβλεπε» ένα πιθανό δομικό ζήτημα κινητήρα πριν από την οπτική επιθεώρηση είναι πολύτιμο για μια ναυτιλιακή εταιρεία. Ορισμένα αρκετά συνηθισμένα δομικά ελαττώματα που προκαλούνται από το slow steaming εμφανίζονται στο Crosshead Bearing [2].

Αποτέλεσμα αυτών είναι κλάδος της ναυτιλίας, όπου εξαρτάται σε μεγάλο βαθμό από την καλή λειτουργία των πλοίων. Ένας τρόπος ώστε να μπορέσουν να πετύχουν την καλή λειτουργία είναι η καλή και η σωστή συντήρηση. Ακολουθώντας, λοιπόν, αυτό το δρόμο, έπρεπε να βρουν και να χρησιμοποιήσουν διάφορες μεθόδους συντήρησης και τεχνικές ώστε να μπορούν να κάνουν τη δουλειά τους πιο γρήγορη ώστε να μειώσουν τον χρόνο όπου τα πλοία θα έμεναν εκτός λειτουργίας.

Σκοπός

Σκοπός της εργασίας είναι η δημιουργία ενός εργαλείου, χρήσιμο στις ναυτιλιακές εταιρείες, όπου θα μπορεί να συσχετίζει τα διάφορα μεγέθη που καθορίζουν την κατάσταση των δομικών στοιχείων του Crosshead Bearing της κύριας μηχανής και θα προβλέπει την πιθανότητα εμφάνισης βλάβης σε αυτά. Ενώ το σύστημα αυτό όντας ένα 'use case' του ευρωπαϊκού προγράμματος BigDataStack θα ενσωματωθεί στην υποδομή του προγράμματος.

Ο σκοπός αυτός μπορεί να αναλυθεί σε «υπό – σκοπούς»

- Δοκιμή διαφόρων αλγορίθμων Μηχανικής Μάθησης και Στατιστικής
- Ανάπτυξη συνδυασμού αυτών με σκοπό την πρόβλεψη της κατάστασης της κύριας μηχανής και την πιθανότητα εντοπισμού της βλάβης σε κάποιο συγκεκριμένο κύλινδρο.
- Ενσωμάτωση στην υποδομή του BigDataStack.

Αρχιτεκτονική Συστήματος

Η αρχιτεκτονική του συστήματος έχει καθοριστεί τόσο από τις απαιτήσεις του σκοπού όσο και από της ιδιαιτερότητες των εργαλείων που χρησιμοποιήσαμε κατά την υλοποίηση.

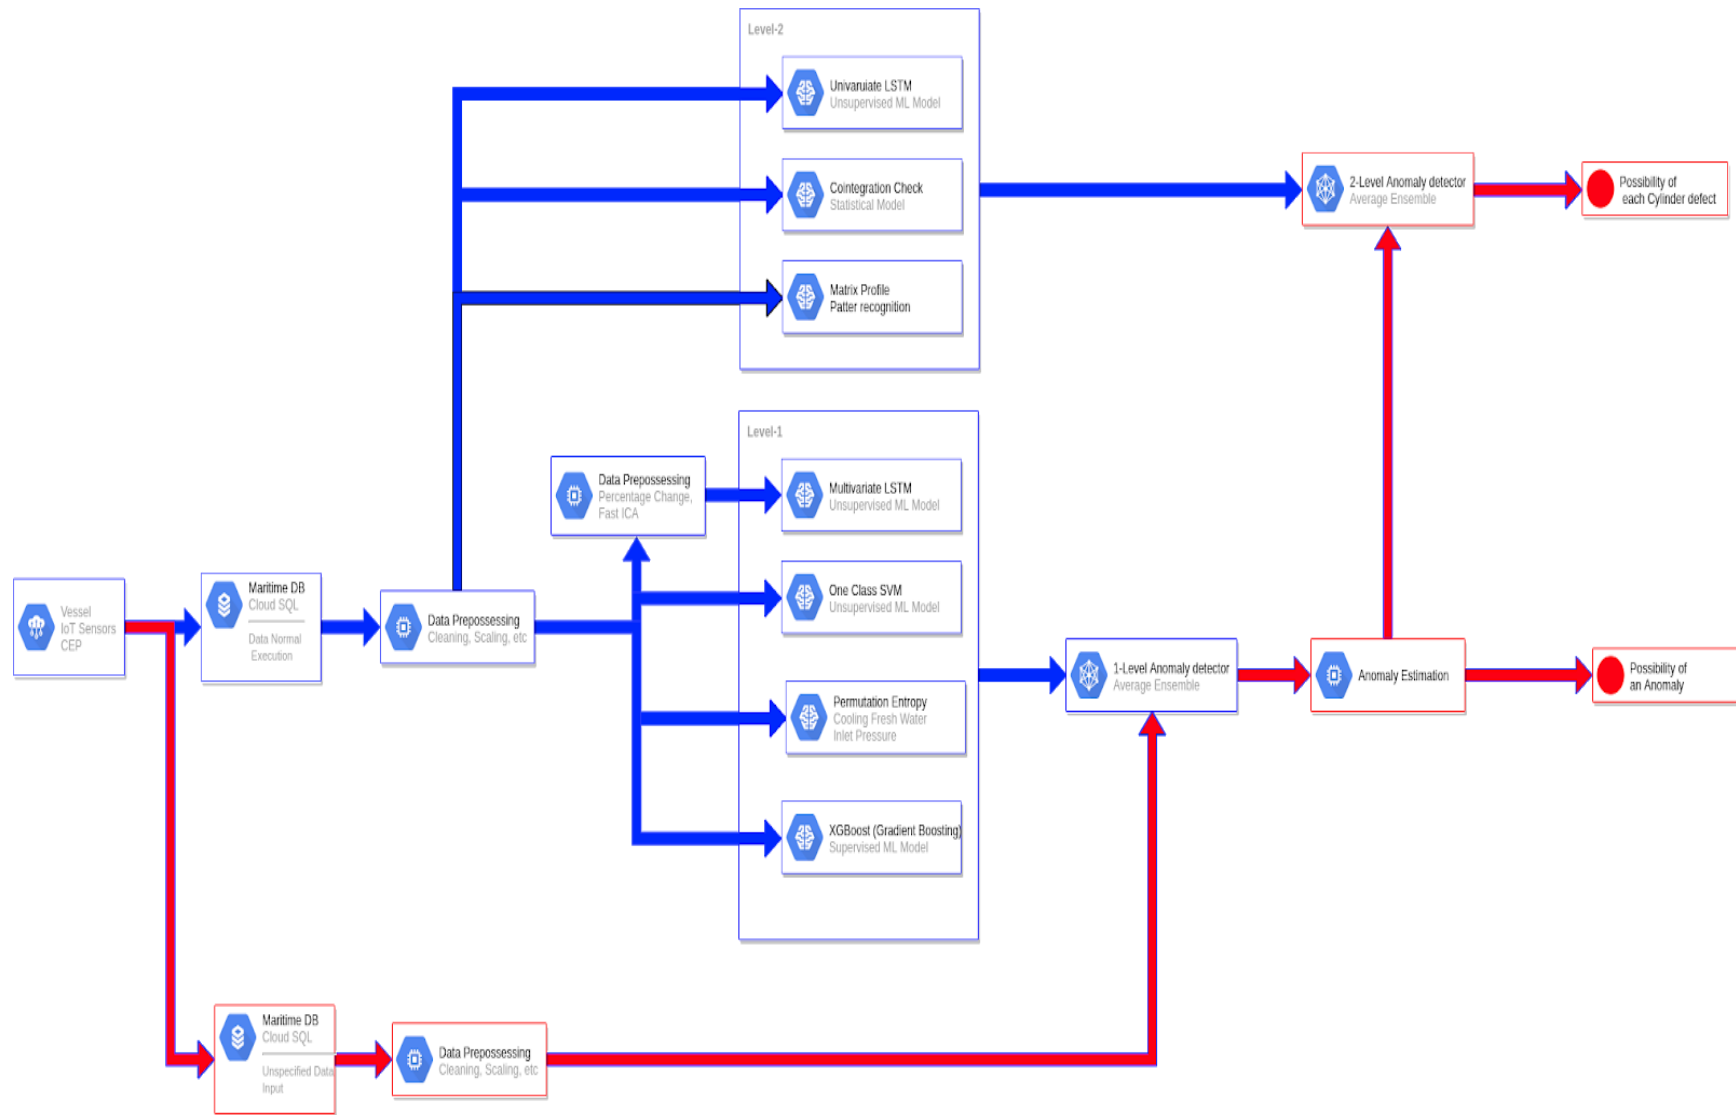
Δεδομένα

Τα δεδομένα μας δόθηκαν από μια μεγάλη ελληνική ναυτιλιακή εταιρεία στα πλαίσια του ευρωπαϊκού χρηματοδοτούμενου έργου BigDataStack. Τα δεδομένα κατά κύριο λόγο αποτελούνται από ροές δεδομένων προερχόμενες από αισθητήρες των πλοίων.

Μεθοδολογία

Η μεθοδολογία που αναπτύσσεται σε αυτό το έγγραφο περιλαμβάνει (α) την περιγραφή μιας κατάλληλης τεχνικής προ επεξεργασίας για το συγκεκριμένο σύνολο δεδομένων και (β) την ανάπτυξη ενός αυτοεκπαιδευόμενου μοντέλου που μπορεί να εκτιμήσει εάν ένα συγκεκριμένο χρονικό σημείο δεδομένων αντιστοιχεί σε φυσιολογική (ονομαστική) κατάσταση ή σε περίπτωση μη φυσιολογικής συμπεριφοράς. Επιπλέον, έχει αναπτυχθεί ένα άλλο μοντέλο (γ) προκειμένου να εκτιμηθεί η πιθανότητα του εξεταζόμενου ελαττώματος να σχετίζεται με το Crosshead Bearing. Ένα διάγραμμα ροής της προτεινόμενης μεθοδολογίας παρουσιάζεται στο σχήμα 1.

Σε σύγκριση με άλλες σχετικές μεθοδολογίες που υπάρχουν στη σχετική βιβλιογραφία, το νέο χαρακτηριστικό αυτού του πλαισίου είναι η σύγκριση διαφορετικών μοντέλων, η εφαρμογή ορισμένων καινοτόμων μοντέλων σε αυτό το συγκεκριμένο πρόβλημα και ο συνδυασμός αυτών των διαφορετικών μοντέλων που υπόσχονται ένα καλύτερο αποτέλεσμα από την σύμφωνα με το «σχήμα» αξιολόγησης που επιλέχθηκε. Επίσης, πρέπει να αναφερθεί ότι η ίδια προσέγγιση μπορεί να χρησιμοποιηθεί και σε άλλες προσεγγίσεις εκτίμησης της κατάστασης χρησιμοποιώντας τύπους δεδομένων χρονοσειράς.



Σχήμα 1: Διάγραμμα Ροής

Κεφάλαιο 1^ο

Συντήρηση

1.1. Ορισμός Συντήρησης

Ως ορισμό της συντήρησης θεωρούμε τη λειτουργία εκείνη ενός οργανισμού την επιφορτισμένη με τη διατήρηση των εγκαταστάσεων και του εξοπλισμού σύμφωνα με τις συγκεκριμένες προδιαγραφές του κατασκευαστή, την προστασία και την ασφάλεια των χειριστών του εξοπλισμού και την προστασία του περιβάλλοντος κρατώντας παράλληλα το κόστος σε χαμηλά επίπεδα.

Τα οφέλη της παρακολούθησης και της προγραμματισμένης συντήρησης είναι:

- Μείωση κόστους
- Αυξημένη αξιοπιστία του εξοπλισμού και προβλεψιμότητα
- Μέγιστη διαθεσιμότητα εξαρτημάτων για τον εξοπλισμό
- Απλοποίηση διαδικασίας ταξινόμησης
- Ασφαλέστερο περιβάλλον για το εργατικό δυναμικό
- Μειωμένες περιβαλλοντικές επιπτώσεις μέσω καλής κατάστασης του εξοπλισμού.

Παρακάτω ακολουθούν οι μέθοδοι συντήρησης που έχουν αναπτυχθεί μέχρι σήμερα.

1.2. Διορθωτική συντήρηση (Reactive maintenance)

Σύμφωνα με αυτή τη μέθοδο το μηχάνημα σε μία παραγωγική αλυσίδα λειτουργεί συνεχώς μέχρι να παρουσιάσει κάποια βλάβη. Η παραγωγή διακόπτεται, η βλάβη επιδιορθώνεται και αποκαθίσταται η συνέχιση της παραγωγής. Η μέθοδος αυτή βρίσκει εφαρμογή σε ορισμένα μηχανήματα, όπου το κόστος αντιμετώπισης της βλάβης είναι μικρό και η διακοπή της λειτουργίας του δεν επηρεάζει σημαντικά τη γραμμή παραγωγής.

1.3. Προληπτική συντήρηση (Preventive Maintenance ή PMS)

Έχει σαν σκοπό την πρόβλεψη βλαβών με εκτέλεση εργασιών συντήρησης βάση οδηγιών του κατασκευαστή. Σαν γνώμονα έχει είτε τις ώρες λειτουργίας του μηχανήματος, είτε μεμονωμένα χρονικά διαστήματα. Προληπτική συντήρηση γίνεται συνήθως τη χρονική στιγμή που αστοχεί 2% του εξοπλισμού που χρησιμοποιείται πειραματικά.

Η προληπτική συντήρηση έχει δύο βαθμίδες:

- Προληπτική συντήρηση 1^{ης} βαθμίδας: όπου αποτελεί τον καθημερινό έλεγχο και η συντήρηση που γίνεται από τους χρήστες. Γίνεται από τους χειριστές του χρησιμοποιώντας τα εγχειρίδια ή απλές οδηγίες χρήσης.
- Προληπτική συντήρηση 2^{ης} βαθμίδας: πραγματοποιείται σε συγκεκριμένα χρονικά διαστήματα όπου έχει υποδείξει ο κατασκευαστής και αντικαθίστανται τα τμήματα εξοπλισμού που επίσης έχει ορίσει ο κατασκευαστής.

Στόχοι της προληπτικής συντήρησης είναι να μπορέσει να ελαχιστοποιήσει τις τυχαίες βλάβες και τον χρόνο εκτός λειτουργίας του εξοπλισμού. Επίσης, στοχεύει στη διατήρηση των χαρακτηριστικών του εξοπλισμού στα πλαίσια των προδιαγραφών του κατασκευαστή όπως και στη προστασία του περιβάλλοντος και του προσωπικού που χειρίζεται τον εξοπλισμό.

1.4. Προβλεπτική συντήρηση (Predictive Maintenance)

Προβλεπτική συντήρηση θεωρούμε τη συντήρηση που συντελείται με συστηματική επιτήρηση μέσω περιοδικών επιθεωρήσεων και μετρήσεων διαφόρων παραγόντων του εξοπλισμού. Επίσης, γίνεται και η αντικατάσταση των εξαρτημάτων λίγο πριν την αστοχία τους. Στόχο έχει τη μείωση του κόστους αντικατάστασης των εξαρτημάτων που προτείνει η προληπτική συντήρηση χωρίς αυτά να παρουσιάζουν εμφανή στοιχεία φθοράς, αστοχίας ή βλάβης. Η μέθοδος αυτή εμφανίζεται με διάφορες ονομασίες όπως Condition Base Maintenance, Predictive Maintenance, Reliability Maintenance. Επίσης, χρησιμοποιεί διάφορες μεθόδους μέτρησης για να κριθεί το πότε πρέπει να επέμβουν οι τεχνικοί για την


επιδιόρθωση ή την αντικατάσταση κάποιου εξαρτήματος. Αυτό, όμως, το οποίο δεν κατάφερε να βελτιώσει είναι η αύξηση του χρόνου ζωής ενός μηχανήματος.

1.5. Προγνωστική Συντήρηση (Proactive Maintenance)

Αυτό που δεν κατάφερε να βελτιώσει η προηγούμενη μέθοδος έρχεται να καλύψει η Προγνωστική Συντήρηση, η οποία μελετά τη συμπεριφορά του μηχανήματος με βάση το χρονικό μιας βλάβης.

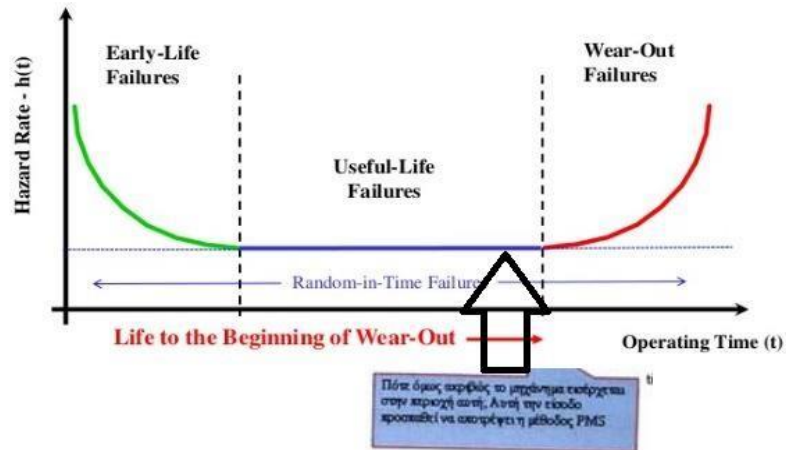
Στόχος της είναι να επιτύχει μέγιστη λειτουργικότητα, αξιοπιστία αλλά και αύξηση της διάρκειας ζωής ενός μηχανήματος.

Σαν βασική ιδέα έχει τον έλεγχο ενός μηχανήματος με τέτοιο τρόπο, ώστε να επιτευχθεί ο εντοπισμός της αιτίας που ευθύνεται για μια βλάβη πριν προκληθεί. Επιπλέον, εκτός από τον εντοπισμό της βλάβης σε πρόωρο στάδιο στοχεύει και στο να υποδείξει τον τρόπο για την εξάλειψη μιας μελλοντικής βλάβης. Η υλοποίηση αυτής της μεθόδου τώρα, γίνεται με την ανάλυση των κραδασμών του μηχανήματος χωρίς να αποκλείονται δευτερεύουσες μέθοδοι.



Σχήμα 2: Βασικό εργαλείο προγνωστικής συντήρησης είναι η θερμογραφία

Bathtub Curve



Σχήμα 3: Bath Tub Curve. Καμπύλη πιθανότητας αστοχίας μηχανήματος συναρτήσει του χρόνου λειτουργίας

Η διαδικασία όπου ακολουθούμε είναι:

- Κατηγοριοποίηση των μηχανημάτων σε κρίσιμα και μη κρίσιμα σημεία με γνώμονα την ασφάλεια του προσωπικού και να μπορεί να κάνει αυτό για το οποίο κατασκευάστηκε
- Δημιουργία βάσης δεδομένων με τα απαραίτητα τεχνικά στοιχεία κάθε μηχανήματος, ιστορικό βλαβών αλλά και εργασίες τελευταίας επισκευής
- Δημιουργία φακέλου ανά μηχανήμα μετά τον έλεγχο και εντοπισμό των θέσεων όπου θα λαμβάνονται οι μετρήσεις
- Περιοδική λήψη μετρήσεων
- Υποβολή αναφοράς κρίσιμων μηχανημάτων που χρήζουν επισκευής
- Εκτέλεση επιπρόσθετων μετρήσεων μετά την εκτέλεση επισκευής.

Η εφαρμογή αυτή έχει τα ακόλουθα οφέλη:

- Συνεχής λειτουργία μηχανημάτων
- Ελαχιστοποίηση απρόβλεπτων διακοπών λειτουργίας
- Μείωση κόστους συντήρησης και επισκευής
- Επέκταση ορίου ζωής μηχανημάτων
- Ακριβής διάγνωση αιτίας της βλάβης
- Τήρηση ελέγχου μηχανημάτων
- Αποθήκευση δεδομένων για μελλοντική αξιολόγηση
- Εξοικονόμηση χρημάτων

Κεφάλαιο 2ο

Μηχανική Μάθηση

Μια από τις κατηγορίες της Τεχνητής Νοημοσύνης που ενέπνευσε μεγάλο ενδιαφέρον στους επιστήμονες του κλάδου - και όχι μόνο - απ' αρχής της θεμελίωσης της τη δεκαετία του 1980 ήταν εκείνη της Μηχανικής Μάθησης (Machine Learning). Αντικείμενο της αποτελεί η κατασκευή προγραμμάτων, ικανών να προσαρμόζουν τη λειτουργία τους με σκοπό τη βελτίωση της απόδοσής τους, μέσω της εμπειρίας που αποκτούν είτε κατά την δημιουργία τους είτε κατά την εκτέλεσή τους. Δεν θα μπορούσε βέβαια να διατυπωθεί ο ισχυρισμός ότι η επιστήμη έχει φτάσει σε σημείο να ερμηνεύσει τη διαδικασία μάθησης του ανθρώπου, πόσο μάλλον να την αποτυπώσει σε πρόγραμμα εκτελέσιμο από υπολογιστή. Αυτό που έχει επιτευχθεί όμως, είναι η δημιουργία αλγορίθμων οι οποίοι μπορούν να αυτοματοποιήσουν την κατασκευή ευφυών συστημάτων χρησιμοποιώντας δεδομένα εκπαίδευσης. Το γεγονός αυτό μαρτυρεί μια πληθώρα επιστημονικών αλλά και εμπορικών εφαρμογών που έχουν αναπτυχθεί τα τελευταία χρόνια, ωφελούμενοι από την χρήση των παραπάνω αλγορίθμων. Σκοπός της ενότητας αυτής είναι μια σύντομη παρουσίαση των θεμελιωδών εννοιών της Μηχανικής Μάθησης, των οικογενειών των οποίων κατατάσσονται οι πιο γνωστές μέθοδοι Μηχανικής Μάθησης, αλλά και των αλγορίθμων που χρησιμοποιήθηκαν για την εκπόνηση της εργασίας αυτής.

2.1. Βασικές Έννοιες της Μηχανικής Μάθησης

Επιχειρώντας τη διατύπωση ενός πιο τυπικού ορισμού από αυτού που αναφέραμε παραπάνω, θα μπορούσαμε να πούμε πως:

Ένα πρόγραμμα μαθαίνει από την εμπειρία E που αποκτά κατά την εκτέλεση ενός συνόλου διεργασιών Δ , εφόσον η απόδοσή του A βελτιώνεται με την αξιοποίηση της εμπειρίας E . [Mitchell 1997].

Από τον παραπάνω ορισμό καθίσταται σαφές πως για να ορίσουμε τυπικά ένα πρόβλημα, θα πρέπει να προσδιορίσουμε: το σύνολο των διεργασιών που θα πρέπει να εκτελεστούν, το

μέτρο της απόδοσης που επιδιώκουμε να αυξήσουμε, καθώς και το είδος της εμπειρίας που απαιτείται για την αύξηση αυτή. Για να μπορέσουμε να κατανοήσουμε καλύτερα τον ορισμό αυτό, παραθέτουμε ως παράδειγμα τη μοντελοποίηση του προβλήματος της πρόβλεψης κίνησης των μετοχών, με το οποίο θα ασχοληθούμε εκτενώς στη συνέχεια:

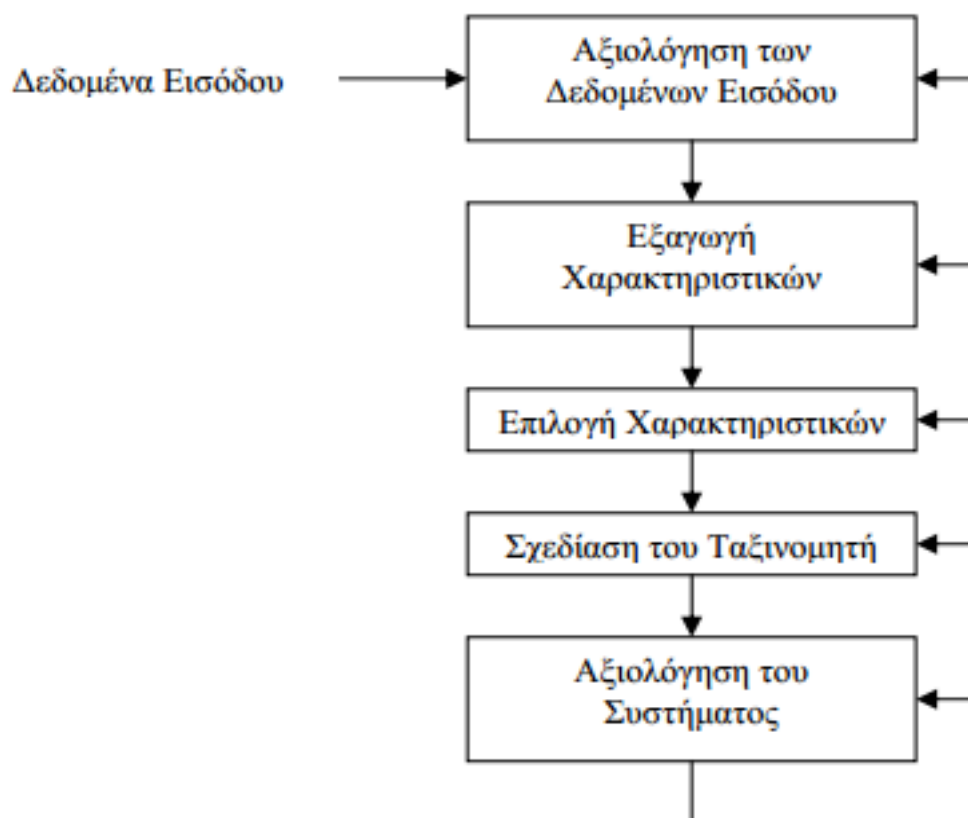
- Επιτελούμενη διεργασία Δ: Πρόβλεψη κίνησης μετοχών (Άνοδος – Πτώση) βασισμένη σε δείκτες Τεχνικής Ανάλυσης.
- Μέτρο Απόδοσης Α: Το ποσοστό των σωστών προβλέψεων.
- Εμπειρία Ε: Ένα σύνολο δεικτών Τεχνικής Ανάλυσης που έχει ήδη ταξινομηθεί.

Στην παρούσα παράγραφο θα επιχειρήσουμε να καταστήσουμε κατανοητές κάποιες βασικές έννοιες της Μηχανικής Μάθησης, ενώ παράλληλα θα παρουσιάσουμε κάποια απαραίτητα βήματα για την υλοποίηση ενός Συστήματος Μ.Μ.

2.2. Αναπαράσταση Δεδομένων

Το πρώτο (και ίσως το σημαντικότερο) βήμα στην σχεδίαση ενός συστήματος μηχανικής μάθησης συναντάται στον προσδιορισμό της «γνώσης» που θα παραχωρηθεί στο σύστημα κατά την εκπαίδευσή του. Θα αναφέρουμε μία πολύ διαδεδομένη έκφραση που χρησιμοποιείται σε παρόμοια συστήματα η οποία είναι «garbage in, garbage out (GIGO)», η οποία ερμηνευμένη πολύ απλά σημαίνει πως εάν εκπαιδεύσετε το σύστημα με «σκουπίδια», θα επιστρέψει «σκουπίδια». Η «γνώση», όπως την αναφέραμε παραπάνω δεν είναι τίποτα άλλο από ένα σύνολο παραδειγμάτων. Μια από τις πλέον συνήθεις μορφές αναπαράστασης των παραδειγμάτων είναι η διανυσματική: κάθε παράδειγμα εκπαίδευσης (sample), ή στιγμιότυπο (instance) όπως έχει επικρατήσει να αποκαλείται, αποτελείται από ένα σύνολο χαρακτηριστικών (attributes ή features), μετρήσιμων δηλαδή ποσοτήτων που έχουν επιλεγεί με τέτοιο τρόπο, ώστε το σύστημα μηχανικής μάθησης να μπορέσει να εκμαιεύσει από αυτά τη γνώση που χρειάζεται. Ανάλογα με το είδος της πληροφορίας των διαφόρων παραδειγμάτων εκπαίδευσης, μπορεί να είναι συνεχείς (continuous) αριθμοί, ή ονομαστικοί (nominal), παρουσιαζόμενοι ως ένα προκαθορισμένο σύνολο διακριτών τιμών, αριθμητικών ή συμβολικών, όπως στην περίπτωση της εφαρμογής που πραγματεύεται η παρούσα εργασία.

Επόμενο στάδιο αποτελεί ο τρόπος με τον οποίο θα διαχειριστεί το «έφυες» σύστημα τη γνώση που αποκοιμίζει κατά την εκπαίδευση, με σκοπό την αποδοτικότερη λειτουργία του. Υιοθετώντας το μοντέλο της διανυσματικής αναπαράστασης, αναζητούμε ουσιαστικά μια συνάρτηση f' η οποία προσεγγίζει όσο το δυνατόν περισσότερο μια ιδανική συνάρτηση με την οποία δύναται να μοντελοποιηθεί το πρόβλημα, τη συνάρτηση στόχου f . Οι δύο συναρτήσεις έχουν ελεύθερη μεταβλητή ένα τυχαίο διάνυσμα x , πεδίο ορισμού το χώρο των στιγμιότυπων και σύνολο τιμών το οποίο καθορίζεται από την εκάστοτε εφαρμογή. Έτσι, η επίλυση ενός προβλήματος μηχανικής μάθησης ανάγεται στην ελαχιστοποίηση της συνάρτησης κόστους, όπου συνάρτηση κόστους συνήθως ορίζεται η απόκλιση της f' από την f . Συνοπτικά, τα βασικά στάδια της σχεδίασης ενός συστήματος μηχανικής μάθησης φαίνονται στο σχήμα 4. Για λόγους πληρότητας, απεικονίζεται και το στάδιο της Επιλογής Χαρακτηριστικών (Attribute Selection), το οποίο θα παρουσιαστεί αναλυτικά πιο κάτω.



Σχήμα 4: Δομή – Αρχιτεκτονική ενός Συστήματος Μηχανικής Μάθησης

2.3. Κατηγοριοποίηση Μοντέλων Μηχανικής Μάθησης

Ανάλογα με το είδος της γνώσης που παρέχεται για εκπαίδευση, οι μέθοδοι μηχανικής μάθησης κατηγοριοποιούνται σε δύο μεγάλες κατηγορίες:

- μάθηση με επίβλεψη (supervised learning),
- μάθηση χωρίς επίβλεψη (unsupervised learning).

Στην πρώτη περίπτωση, το σύστημα κατά τη διάρκεια της μάθησης «καθοδηγείται» από τα παραδείγματα εκπαίδευσης υπό την έννοια ότι υποδεικνύουν στον αλγόριθμο την τιμή της συνάρτησης στόχου. Στην κατηγορία αυτή ανήκουν τα προβλήματα ταξινόμησης (classification), στα οποία το αποτέλεσμα της κατηγοριοποίησης αποτελεί χαρακτηριστικό των στιγμιότυπων εκπαίδευσης και η τιμή του για κάθε στιγμιότυπο συμπεριλαμβάνεται στα δεδομένα εκπαίδευσης. Στην κατηγορία προβλημάτων ταξινόμησης εντάσσεται και το πρόβλημα που πραγματεύεται η παρούσα εργασία.

Αντίθετα, στην περίπτωση της μάθησης χωρίς επίβλεψη, ο αλγόριθμος καλείται να ανακαλύψει σχηματισμούς και σχέσεις μεταξύ των στιγμιότυπων εκπαίδευσης, διαχωρίζοντας τα χωρίς κάποια γνωστά κριτήρια. Παραδείγματα προβλημάτων που εντοπίζονται σε αυτήν την περιοχή είναι το clustering, όπου επιχειρείται ομαδοποίηση των στιγμιότυπων σε κλάσεις των οποίων θα συμπεράνει ο αλγόριθμος, στηριζόμενος στην ομοιότητα των μελών κάθε ομάδας.

2.4. Αξιολόγηση Απόδοσης και Overfitting

Ολοκληρώνοντας τη σύντομη αυτή αναφορά στις θεμελιώδεις έννοιες της μηχανικής μάθησης, κρίνεται σκόπιμη η παρουσίαση ενός συνόλου παραγόντων καθοριστικής σημασίας για τη σχεδίαση ενός αποδοτικού συστήματος μηχανικής μάθησης. Από τους πλέον σημαντικούς θεωρείται η ικανότητα γενίκευσης (generalization ability), η ικανότητά του δηλαδή να χρησιμοποιεί την «γνώση» που απέκτησε μετά την τροφοδότηση του από τα στιγμιότυπα εκπαίδευσης, με αποτελεσματικότητα επί του συνόλου των άγνωστων στιγμιότυπων. Συνήθως, ισχύει ότι, εφόσον η υπόθεση στην οποία κατέληξε το σύστημα μετά την εκπαίδευσή του ισχύει και ερμηνεύει την πλειοψηφία των στιγμιότυπων

εκπαίδευσης, τότε θα είναι σε μεγάλο βαθμό συνεπής και με τα άγνωστα στιγμιότυπα που θα κληθεί να διαχειριστεί κατά την κανονική λειτουργία του. Θα πρέπει να δοθεί ιδιαίτερη προσοχή ωστόσο στο να μην παρερμηνευθεί η παραπάνω πρόταση, καθώς η περίπτωση μιας υπόθεσης η οποία είναι απόλυτα συνεπής με την πλειοψηφία των στιγμιότυπων εκπαίδευσης ενέχει τον κίνδυνο της εκμάθησης των πλέον ασήμαντων λεπτομερειών που είναι δυνατόν να παρατηρηθούν σ' αυτά, με αποτέλεσμα η απόδοση του συστήματος να παρουσιάζει ιδιαίτερα χαμηλή απόδοση στα μη παρατηρούμενα στιγμιότυπα. Το παραπάνω φαινόμενο είναι γνωστό ως φαινόμενο του *overfitting*. Επιχειρώντας έναν πιο τυπικό ορισμό του φαινομένου, θα λέμε πως: Μια υπόθεση h είναι *overfits* στα δεδομένα εκπαίδευσης όταν υπάρχει μια διαφορετική υπόθεση h' τέτοια ώστε, η h να παρουσιάζει μικρότερο σφάλμα από την h' επί των δεδομένων εκπαίδευσης, ενώ ταυτόχρονα η h' να παρουσιάζει μικρότερο σφάλμα από την h επί ολόκληρης της κατανομής των δεδομένων (εκπαίδευσης και ελέγχου). Καθοριστική σημασία στην ποιότητα του σώματος εκπαίδευσης φέρει η ορθή επιλογή των χαρακτηριστικών τα οποία θα στήσουν το χώρο του προβλήματος, καθώς μέσω αυτών καθίσταται δυνατή η αναπαράσταση της γνώσης που απαιτείται για την αποδοτική λειτουργία του συστήματος. Επίσης, απαραίτητη θεωρείται, όπως ήδη αναφέραμε, η ομοιότητα της κατανομής των στιγμιότυπων εκπαίδευσης με την κατανομή των στιγμιότυπων που θα συναντήσει το σύστημα κατά τη διάρκεια της λειτουργίας του. Ο παράγοντας αυτός ωστόσο, σχετίζεται άμεσα με το μέγεθος του σώματος εκπαίδευσης, το οποίο αποτελεί ένα περιορισμένο δείγμα του χώρου του προβλήματος. Ιδιαίτερη προσοχή θα πρέπει, επίσης, να δοθεί στην ορθότητα των δεδομένων που χρησιμοποιούνται για την εκπαίδευση, καθώς δεν είναι σπάνια η περίπτωση παρείσφρησης σφαλμάτων στις τιμές των χαρακτηριστικών κάποιων στιγμιότυπων. Το φαινόμενο αυτό ονομάζεται θόρυβος (*noise*) και συναντάται κατά τη συλλογή δεδομένων από πειραματικές μετρήσεις, αλλά και γενικότερα, όπου επεμβαίνει ο ανθρώπινος παράγοντας στη δημιουργία δεδομένων εκπαίδευσης. Όπως είναι αναμενόμενο, η εκτεταμένη παρουσία θορύβου οδηγεί στον αποπροσανατολισμό του αλγορίθμου μάθησης και στην επιλογή μιας υποβέλτιστης υπόθεσης, ελάχιστα συνεπούς με τα δεδομένα ελέγχου. Αυτό ωστόσο δε συμβαίνει και στην περίπτωση που παρουσιάζεται θόρυβος της ίδιας μορφής και στα δεδομένα αξιολόγησης, οπότε χρειάζεται να μοντελοποιηθεί και αυτός, καθώς ανάγεται πλέον σε «χαρακτηριστικό» του συγκεκριμένου προβλήματος μάθησης. Παρόμοιο φαινόμενο είναι και αυτό της απουσίας τιμών (*missing values*), περιπτώσεων, δηλαδή, όπου οι τιμές ορισμένων

χαρακτηριστικών δεν αναφέρονται για κάποια από τα στιγμιότυπα. Όσον αφορά τέλος, τους παράγοντες εκείνους που υποβοηθούν το μηχανισμό που υιοθετείται για την προσέγγιση της συνάρτησης στόχου, συνοψίζονται στην Αρχή της Ελάχιστης Περιγραφής (Minimum Description Length Principle ή MDL), σύμφωνα με την οποία: Η καλύτερη θεωρία που είναι δυνατόν να εξαχθεί από ένα σώμα δεδομένων είναι η μικρότερη δυνατή, η οποία απαιτεί συνάμα τη μικρότερη ποσότητα πληροφορίας που μοντελοποιεί τις εξαιρέσεις που είναι σχετικές με τη θεωρία αυτή. Η παραπάνω αρχή, γνωστή και ως «Occam's Razor», υποστηρίζει ουσιαστικά πως οι απλούστερες θεωρίες είναι προτιμότερες από τις πιο περίπλοκες. Στην περίπτωση της μηχανικής μάθησης, είναι άμεσα συνυφασμένη με την ικανότητα της γενίκευσης που πρέπει να διακρίνει μια εξαγόμενη υπόθεση, καθώς έχει παρατηρηθεί ότι προσεγγίσεις που είναι επιρρεπείς στον κίνδυνο του Overfitting τείνουν να παράγουν ιδιαίτερα πολύπλοκες υποθέσεις, υποβαθμίζοντας έτσι την απόδοση του συστήματος.

2.5. Κλιμάκωση Δεδομένων

Η κλιμάκωση των χαρακτηριστικών (features) των δεδομένων εκπαίδευσης είναι μια μέθοδος που χρησιμοποιείται για την τυποποίηση της κλίμακας των ανεξάρτητων μεταβλητών ή των χαρακτηριστικών των δεδομένων. Πραγματοποιείται γενικά κατά το στάδιο της προ-επεξεργασίας των δεδομένων, ένα στάδιο που προηγείται χρονικά της εκπαίδευσης του συστήματος. Δεδομένου ότι το εύρος των τιμών των χαρακτηριστικών των δεδομένων ποικίλει σε μεγάλο βαθμό, αντιλαμβανόμαστε πως σε ορισμένους αλγόριθμους Μηχανικής Μάθησης, οι αντικειμενικές συναρτήσεις είναι μοντελοποιημένες κατά τέτοιο τρόπο ώστε να δίνουν μεγαλύτερο βάρος στα χαρακτηριστικά των τιμών των οποίων είναι μεγαλύτερες κατά απόλυτη τιμή. Ως εκ τούτου, το σύνολο όλων των χαρακτηριστικών θα πρέπει να ομαλοποιείται, έτσι ώστε κάθε χαρακτηριστικό να συνεισφέρει ομοιόμορφα στην συνάρτηση κόστους.

2.6. Rescaling

Η απλούστερη μέθοδος είναι η μεταφορά του εύρους τιμών των χαρακτηριστικών σε ένα κοινό σύνολο π.χ. $[0, 1]$ ή $[-1, 1]$. Η επιλογή του εύρους-στόχου εξαρτάται από τη φύση των δεδομένων. Ο γενικός τύπος δίνεται ως εξής:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)}$$

όπου το x είναι μία αρχική τιμή ενός χαρακτηριστικού, και το x' είναι η κοινωνικοποιημένη τιμή.

2.7. Standardization

Στη Μηχανική Μάθηση, μπορούμε να χειριστούμε διαφόρων τύπων δεδομένα, π.χ. ακουστικά σήματα, τις τιμές των εικονοστοιχείων για τα δεδομένα μιας εικόνας, ενώ τα δεδομένα αυτά μπορεί να περιλαμβάνουν πολλές διαστάσεις. Η μέθοδος αυτή έχει ως σκοπό το σύνολο τιμών του κάθε χαρακτηριστικού των δεδομένων να έχει μηδενική μέση τιμή και η διακύμανση του να ισούται με μονάδα. Η γενική μέθοδος υπολογισμού είναι αρχικά να προσδιοριστεί η μέση τιμή και η τυπική απόκλιση της εκάστοτε κατανομής για κάθε χαρακτηριστικό. Στη συνέχεια αφαιρούμε τη μέση τιμή από κάθε χαρακτηριστικό. Τέλος, διαιρούμε τις τιμές που προκύπτουν με την τυπική απόκλιση του αναφερόμενου χαρακτηριστικού.

2.8. Επιλογή Αλγορίθμου Machine Learning

Στην συγκεκριμένη εργασία χρησιμοποιήθηκαν αλγόριθμοι Machine Learning, όπως, LSTM (ένα συγκεκριμένο είδος Deep Neural Network), SVM, XGBoosting (ένα είδος βασισμένο στα δέντρα αποφάσεων) όσο και κάποια Στατιστικά μοντέλα, όπως, το Cointegration μεταξύ δύο χρονοσειρών και το Matrix Profile. Στις επόμενες υποενότητες θα δούμε κάποια πράγματα για τα Μοντέλα που χρησιμοποιήσαμε.


2.9. LSTM

Η μακρά βραχυπρόθεσμη μνήμη (LSTM), είναι μια αρχιτεκτονική τεχνικών επαναλαμβανόμενων νευρωνικών δικτύων, όπου, χρησιμοποιείται στον τομέα του Deep Learning (Deep Neural Networks). Εν αντιθέσει με τα απλά ανεστραμμένα νευρωνικά δίκτυα, το LSTM έχει συνδέσεις ανατροφοδότησης που το κάνουν υπολογιστή γενικής χρήσης. Αυτό σημαίνει ότι μπορεί να υπολογίσει και να χρησιμοποιήσει μια μηχανή Turing.

Τα δίκτυα LSTM είναι κατάλληλα για ταξινόμηση, επεξεργασία και πραγματοποίηση προβλέψεων βάση δεδομένων χρονοσειρών, καθώς μπορεί να υπάρξουν καθυστερήσεις άγνωστης διάρκειας μεταξύ σημαντικών γεγονότων σε μια χρονολογική σειρά. Τα LSTMs αναπτύχθηκαν για να αντιμετωπίσουν προβλήματα διαβάθμισης που μπορεί να αντιμετωπιστούν κατά την εκπαίδευση των RNNs. Η σχετική έλλειψη ευαισθησίας στο μήκος του κενού είναι ένα πλεονέκτημα του LSTM έναντι των RNN, των κρυφών μοντέλων Markov και άλλων μεθόδων μάθησης αλληλουχίας σε πολλές εφαρμογές.

Ιστορικά το LSTM προτάθηκε το 1997 από τους Sepp Hochreiter και Jurger Schmidhuber. Με την εισαγωγή μονάδων σταθερού σφάλματος(CEC), το LSTM ασχολείται με τα προβλήματα έκρηξης και εξαφάνισης. Η αρχική έκδοση του μπλοκ LSTM περιλάμβανε κυψέλες, πύλες εισόδου και εξόδου.

Θεωρητικά, οι κλασικοί RNNs μπορούν να παρακολουθούν αυθαίρετες μακροπρόθεσμες εξαρτήσεις στις ακολουθίες εισόδου. Το πρόβλημά τους είναι πρακτικό. Με τη χρήση οπίσθιου πολλαπλασιασμού, οι κλίσεις που πολλαπλασιάζονται εκ νέου μπορούν να εξαφανιστούν, δηλαδή μπορεί να τείνουν στο μηδέν. Επίσης, μπορεί να εκραγούν, δηλαδή να τείνουν στο άπειρο. Αυτό συμβαίνει λόγω των υπολογισμών που εκτελούνται στη διαδικασία, οι οποίοι χρησιμοποιούν αριθμούς πεπερασμένης ακρίβειας. Τα RNNs που χρησιμοποιούν μονάδες LSTM επιλύουν μερικώς το πρόβλημα μείωσης της κλίσης, επειδή οι μονάδες LSTM επιτρέπουν στις κλίσεις να ρέουν αμετάβλητες. Παρόλα αυτά, τα δίκτυα LSTM εξακολουθούν να έχουν το πρόβλημα της εκρηκτικής κλίσης.



Σχήμα 5: Block Lstm

Υπάρχουν διάφορες αρχιτεκτονικές μονάδων LSTM. Μια κοινή αρχιτεκτονική αποτελείται από μια κυψέλη και τρεις ρυθμιστές, που συνήθως ονομάζονται πύλες της ροής πληροφοριών μέσα στη μονάδα LSTM, μια πύλη εισόδου, μια πύλη εξόδου και μια πύλη forget. Ορισμένες παραλλαγές της μονάδας LSTM δεν έχουν μια ή περισσότερες από αυτές τις πύλες. Παράδειγμα είναι οι επαναλαμβανόμενες μονάδες GRUs, όπου δεν έχουν πόρτα εξόδου.

Η κυψέλη είναι υπεύθυνη για την παρακολούθηση των εξαρτήσεων μεταξύ των στοιχείων στην ακολουθία εισόδου. Η πύλη εισόδου ελέγχει την έκταση στην οποία μια νέα τιμή εισέρχεται μέσα στο κελί, η θυρίδα παρατήρησης ελέγχει την έκταση στην οποία παραμένει μια τιμή στο κελί και η πύλη εξόδου ελέγχει την έκταση στην οποία χρησιμοποιείται η τιμή στο κελί για τον υπολογισμό παραγωγής της μονάδας LSTM. Η λειτουργία ενεργοποίησης είναι συχνά η λειτουργική λειτουργία.

Υπάρχουν συνδέσεις προς και από τις πύλες LSTM, μερικές από τις οποίες είναι επαναλαμβανόμενες. Τα βάρη αυτών των συνδέσεων, τα οποία πρέπει να μάθουν κατά τη διάρκεια της εκπαίδευσης, καθορίζουν το πως λειτουργούν οι πύλες.

2.10. One Class SUPPORT VECTOR MACHINE

Πολλά προβλήματα classifications προσπαθούν να λύσουν την κατάσταση μεταξύ δύο ή πολλαπλών τάξεων. Στόχος της εφαρμογής εκμάθησης μηχανής είναι να διαχωρίσει τα δεδομένα δοκιμών μεταξύ διαφόρων κατηγοριών, χρησιμοποιώντας δεδομένα εκπαίδευσης. Το πρόβλημα είναι όταν έχουμε δεδομένα μόνο μιας τάξης και ο στόχος είναι να δοκιμάσουμε νέα δεδομένα και να διαπιστώσουμε εάν είναι ίδια ή όχι με τα δεδομένα εκπαίδευσης. Μια μέθοδος για την επίλυση τέτοιων προβλημάτων είναι η One Class SVM. Όπως γίνεται αντιληπτό από τον τίτλο του εξεταζόμενου μοντέλου η βασική λειτουργία εναπόκειται στην λειτουργία του SVM μοντέλου.

2.10.1. Βασικές έννοιες του SVM

Αρχικά θα δούμε την παραδοσιακή μηχανή φορέα υποστήριξης δύο κατηγοριών. Ελέγχουμε ένα σύνολο δεδομένων $\Omega = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$; $X_i \in \mathbb{R}^d$ σε ένα χώρο όπου το x_i είναι το i -th σημείο δεδομένων εισόδου και το $y_i \in \{-1, 1\}$ είναι το i -ο σχέδιο εξόδου, υποδεικνύοντας την ιδιότητα μέλους.

Μια καλή ιδιότητα των SVMs είναι ότι μπορεί να δημιουργήσει ένα μη γραμμικό όριο απόφασης προβάλλοντας τα δεδομένα μέσω μιας μη γραμμικής συνάρτησης F σε ένα χώρο με υψηλότερη διάσταση. Αυτό σημαίνει ότι τα σημεία δεδομένων που δεν μπορούν να χωριστούν με μια ευθεία γραμμή στον αρχικό τους χώρο, οδηγούνται σε ένα χώρο f όπου μπορεί να υπάρχει μια ευθεία όπου χωρίζει τα σημεία δεδομένων της μίας τάξης με την άλλη. Όταν αυτό το μέρος θα προβάλλεται στο χώρο εισόδου I , θα έχει τη μορφή μη γραμμικής καμπύλης.

Η μέθοδος SVM διαχωρίζει όλα τα σημεία δεδομένων από την προέλευση και μεγιστοποιεί την απόσταση. Αυτό έχει σαν αποτέλεσμα μια δυαδική συνάρτηση που καταγράφει περιοχές στο χώρο εισόδου όπου είναι η πυκνότητα πιθανότητας των δεδομένων. Έτσι, η συνάρτηση επιστρέφει +1 σε μια μικρή περιοχή (καταγραφή των σημείων εκπαίδευσης) και -1 αλλού.

Η τετραγωνική συνάρτηση ελαχιστοποίησης του προγραμματισμού είναι:

$$\min_{w, \xi_i, \rho} \frac{1}{2} \|w\|^2 + \frac{1}{\nu n} \sum_{i=1}^n \xi_i - \rho$$

subject to:

$$\begin{aligned} (w \cdot \phi(x_i)) &\geq \rho - \xi_i && \text{for all } i = 1, \dots, n \\ \xi_i &\geq 0 && \text{for all } i = 1, \dots, n \end{aligned}$$

2.10.2. Insight in One Class SVM

Η βασική ιδέα του αναφερόμενου μοντέλου έχει να κάνει απλά με την εφαρμογή και την μοντελοποίηση του εκάστοτε προβλήματος. Σαν πρώτο βήμα θα πρέπει να καθορίσουμε αν τα δεδομένα εκπαίδευσης είναι μέλη μιας συγκεκριμένης κλάσης. Με την παροχή των δεδομένων εκπαίδευσης, ένας αλγόριθμος δημιουργεί ένα μοντέλο αυτών των δεδομένων θεωρώντας το ως μια αναπαράσταση μίας κατηγορίας (κλάσης). Εάν τα άγνωστα δεδομένα είναι πολύ διαφορετικά, ανάλογα πάντα με τις μετρικές που θα χρησιμοποιήσουμε, από αυτό το μοντέλο χαρακτηρίζονται ως εκτός τάξης.

2.11. Gradient Boosting

Το Gradient Boosting είναι μια τεχνική μηχανικής μάθησης για προβλήματα παλινδρόμησης και ταξινόμησης, η οποία παράγει ένα μοντέλο πρόβλεψης με τη μορφή ενός συνόλου αδύναμων μοντέλων πρόβλεψης, συνήθως με δέντρο αποφάσεων. Διαμορφώνει το μοντέλο με τρόπο όπως και άλλες μέθοδοι ενίσχυσης, επιτρέποντας τη βελτίωση μιας αυθαίρετης διαφοροποιημένης λειτουργίας απώλειας.

Η ιδέα γι' αυτό προέκυψε από την παρατήρηση του Leo Breiman ότι το Gradient Boosting μπορεί να ερμηνευτεί ως ένας αλγόριθμος βελτιστοποίησης σε μια κατάλληλη συνάρτηση κόστους. Οι εξελικτικοί αλγόριθμοι Gradient Boosting αναπτύχθηκαν στη συνέχεια από τον Jerome H. Friedman, ταυτόχρονα με την γενικότερη λειτουργική κλίση που προάγει την προοπτική των Llew Mason, Jonathan Baxter, Peter Bartlett και Marcus Frean. Τα τελευταία

δύο έγγραφα εισήγαγαν την άποψη των αλγορίθμων Gradient Boosting ως επαναληπτικοί λειτουργικοί αλγόριθμοι κατάταξης κλίσης. Δηλαδή οι αλγόριθμοι όπου βελτιστοποιούν μια συνάρτηση κόστους σε σχέση με το χώρο λειτουργίας επιλέγοντας με επαναληπτικό τρόπο μια συνάρτηση όπου δείχνει την κατεύθυνση αρνητικής κλίσης. Αυτή η λειτουργική άποψη κλίσης του Gradient Boosting οδηγεί στην ανάπτυξη αλγορίθμων Gradient Boosting σε πολλούς τομείς της μηχανικής μάθησης.

Όπως και με άλλες μεθόδους, το Gradient Boosting συνδυάζει τον αδύνατο παράγοντα με τον πιο ισχυρό με επαναληπτικό τρόπο. Για κάθε m , όπου m μεγαλύτερο ή ίσο με 1 και μικρότερο ή ίσο με M , της υποβοηθητικής κλίσης, μπορεί να υποθέσει ότι υπάρχει κάποιο ατελές μοντέλο F_m . Καλό θα ήταν στην αρχή να χρησιμοποιηθεί ένα πολύ αδύναμο μοντέλο που θα προβλέπει απλώς τη μέση τιμή y για το εκπαιδευτικό κομμάτι του αλγορίθμου. Ο αλγόριθμος Gradient Boosting βελτιώνεται στο F_m με την κατασκευή ενός νέου μοντέλου που προσθέτει έναν εκτιμητή h για να παρέχει ένα καλύτερο μοντέλο.

$F_{m+1}(x) = F_m(x) + h(x)$. Για να βρούμε το h , η λύση αύξησης της κλίσης ξεκινάει με την παρατήρηση ότι μια τέλεια h υποδηλώνει $F_{m+1}(x) = F_m(x) + h(x) = y$

2.12. Cointegration

Το Cointegration είναι μια στατιστική ιδιότητα μιας συλλογής (X_1, X_2, \dots, X_k) των μεταβλητών χρονοσειρών. Αρχικά, όλες οι σειρές πρέπει να ενσωματωθούν στη σειρά d . Στη συνέχεια, εάν ένας γραμμικός συνδυασμός αυτής της συλλογής είναι ενσωματωμένος σε σειρά μικρότερη από d , τότε η συλλογή ονομάζεται Cointegration. Τυπικά, εάν (X, Y, Z) είναι κάθε ένα ενσωματωμένο στην τάξη d και υπάρχουν συντελεστές a, b, c έτσι ώστε $aX + bY + cZ$ είναι ενσωματωμένη σε τάξη μικρότερη του d , τότε Y, Z συγχωνεύονται. Η συγχώνευση έχει γίνει μια σημαντική ιδιότητα στη σύγχρονη ανάλυση των χρονικών σειρών. Οι χρονολογικές σειρές έχουν συχνά τάσεις είτε ντετερμινιστικές είτε στοχαστικές. Σε μια εργασία οι Charles Nelson και Charles Plosser (1982) παρείχαν στατιστικές αποδείξεις ότι πολλές μακροοικονομικές χρονολογικές σειρές των ΗΠΑ, έχουν στοχαστικές τάσεις όπου αποκαλούνται και διεργασίες μονάδας ή διεργασίες ενσωματωμένες στην τάξη $1 : I(1)$. Έδειξαν επίσης, ότι οι διεργασίες μονάδας έχουν μη τυποποιημένες στατιστικές ιδιότητες, έτσι ώστε οι συμβατικές μέθοδοι οικονομετρικής θεωρίας να μην ισχύουν για αυτές.


Εάν δύο ή περισσότερες σειρές είναι μεμονωμένα ενσωματωμένες, με την έννοια της χρονικής σειράς, αλλά κάποιοι γραμμικοί συνδυασμοί τους έχουν χαμηλότερη σειρά ολοκλήρωσης, τότε οι σειρές λέγονται ότι είναι συνολοκληρωμένες.

Ο πρώτος που εισήγαγε και ανέλυσε την έννοια της ψευδούς παλινδρόμησης ήταν ο Udney Yule το 1962. Πριν από τη δεκαετία του 80 πολλοί οικονομολόγοι χρησιμοποίησαν γραμμικές παλινδρομήσεις σε μη στατικά δεδομένα χρονολογικών σειρών, τα οποία οι Clive Granger και Paul Newbold έδειξαν ότι είναι μια επικίνδυνη προσέγγιση που θα μπορούσε να παράγει ψευδή συσχέτιση σε δεδομένα όπου εξακολουθούν να είναι μη στάσιμα.


2.13. Matrix profile

Είναι γνωστό ότι όλες οι δεδομένες ροές δεδομένων λέγονται χρονοσειρές. Μια χρονοσειρά T , είναι μια ακολουθία n πραγματικών αριθμών όπου n είναι το μήκος της. Δεν επιμένουμε πολύ για τις παγκόσμιες ιδιότητες μιας χρονικής σειράς, επιμένουμε πιο πολύ στις τοπικές περιοχές που είναι γνωστές ως υποπεριοχές. Μια υποπεριοχή $T(i,m)$ είναι ένα συνεχές υποσύνολο τιμών T μήκος m ξεκινώντας από τη θέση i . Το συγκεκριμένο μέρος όπου προσπαθούμε να ορίσουμε είναι επαναλαμβανόμενα σχήματα ή μοτίβα χρονικών σειρών. Σε γενικές γραμμές, ένας αποτελεσματικός τρόπος για τον εντοπισμό του μοτίβου χρονικών σειρών είναι να υπολογιστεί το Matrix Profile.

Το Matrix Profile μιας χρονοσειράς T είναι μια μετα-χρονοσειρά όπου αποθηκεύει την Z -κανονικοποιημένη Ευκλείδεια απόσταση μεταξύ κάθε υπό ακολουθίας και του πλησιέστερου γειτονικού της, όπου n είναι το μήκος του T και m το μήκος της ζητούμενης υποενότητας. Παρατηρούμε τα ανωτέρω μεγέθη στο παράδειγμα που ακολουθεί.




Σχήμα 6: Παράδειγμα Matrix Profile



Σχήμα 7: Παράδειγμα Matrix Profile

Μπορούμε να δημιουργήσουμε μια σύντομη χρονοσειρά, όπου ονομάζεται Matrix Profile ή MP. Το Matrix Profile στη θέση i -th καταγράφει την απόσταση της υποαλληλουχίας στην T , στη θέση i -th, στον πλησιέστερο γείτονά της μετρώντας την Z - κανονικοποιημένη Ευκλείδεια απόσταση. Παράδειγμα, σε αυτό που ακολουθεί, η υποενότητα που αρχίζει από τι 921 σημαίνει ότι έχει απόσταση 177,0 από τον πλησιέστερο γείτονά της, όπου και αν βρίσκεται (σχήμα 8).



Σχήμα 8: Παράδειγμα Matrix Profile

2.14. Permutation Entropy

Υπάρχει μικρή συναίνεση όσο αναφορά τον ορισμό του περίπλοκου σήματος. Μεταξύ των διαφορετικών προσεγγίσεων, με βάση την εντροπία αυτά είναι εμπνευσμένα είτε από τη μη γραμμική δύναμη είτε από τη συμβολική δύναμη. Η Permutation Entropy (PE) προτείνεται ως μέτρο πολυπλοκότητας βασισμένο στη σύγκριση με τις γειτονικές τιμές κάθε σημείου και τη απεικόνισή τους. Η χρήση συνηθισμένων περιγραφών είναι χρήσιμο στην αίσθηση ότι προσφέρει ασυλία στα μεγάλα αντικείμενα που συμβαίνουν σε χαμηλές συχνότητες. Η Permutation Entropy ισχύει για τακτικές χαστικές, θορυβώδεις ή πραγματικές χρονοσειρές και έχει χρησιμοποιηθεί στο νευρωτικό ηλεκτροεγκεφαλογραφικό πλαίσιο. Η Permutation Entropy χρησιμοποιείται για να οριοθετήσει τα μοτίβα μεταστοιχείωσης μεταξύ των μεμονωμένων τιμών μιας δεδομένης χρονοσειράς. Το χρησιμοποιούμε για την επίτευξη κατανομής πιθανοτήτων των προσιτών προτύπων και για να μπορέσει να ποσοτικοποιήσει

το βαθμό πολυπλοκότητας ενός συστήματος οικονομικής συμπεριφοράς. Τα κανονικά μοτίβα χρησιμοποιούνται για να περιγράψουν τα εγγενή πρότυπα, τα οποία είναι κρυμμένα στη δυναμική του οικονομικού συστήματος. Οι εμπειρικές εφαρμογές που αφορούν τον Dow Jones Industrial Average παρουσιάζονται για να υποδείξουν την αξία ανάκτησης πληροφοριών και την εφαρμογή της μεθόδου Permutation Entropy. Τα αποτελέσματα καταδεικνύουν την ικανότητα της μεθόδου Permutation Entropy να ανιχνεύει την έκταση της πολυπλοκότητας (παρατυπία) και να διακρίνει και να ταξινομεί τις παραδεκτές και απαγορευμένες καταστάσεις. Η μέθοδος Permutation Entropy χαρακτηρίζεται από την εννοιολογική της απλότητα και την υπολογιστική ταχύτητα. Δεν προϋποθέτει καμία παραδοχή βασισμένη στο μοντέλο, συμπεριλαμβανομένου του κατά πόσο το μοντέλο είναι μη γραμμικό και κανονικό ή είναι αμετάβλητο υπό οποιαδήποτε μονοτονική μετατροπή των δεδομένων. Αυτό έρχεται σε μετρικές (Bandt και Pompe 2002) και τοπολογικές (Bandt et al., 2002).

Κεφάλαιο 3^ο

Anomaly Detection

Με τον όρο ‘ανωμαλία’ στα πλαίσια της εργασίας θα αναφέρουμε τη συμπεριφορά κάποιας ή κάποιων μεταβλητών που παρεκκλίνουν από τις αναμενόμενες τιμές ή από αυτές της κανονικής λειτουργίας. Η ανίχνευση (αναγνώριση) ανωμαλιών είναι ένα σημαντικό πρόβλημα που έχει ερευνηθεί σε διάφορους ερευνητικούς τομείς και τομείς εφαρμογών. Πολλές εφαρμογές ανίχνευσης ανωμαλιών έχουν αναπτυχθεί ειδικά για ορισμένους τομείς εφαρμογής, ενώ άλλες είναι πιο γενικές. Η ανίχνευση ανωμαλιών αναφέρεται στο πρόβλημα της εύρεσης προτύπων σε δεδομένα που δεν συμμορφώνονται στην αναμενόμενη συμπεριφορά. Αυτά τα μη συμμορφούμενα στοιχεία συχνά αναφέρονται ως ανωμαλίες, απογοητευτικές παρατηρήσεις, εξαιρέσεις, παρεκκλίσεις, εκπλήξεις, ιδιαιτερότητες ή προσμείξεις σε διαφορετικούς τομείς εφαρμογής. Η ανίχνευση ανωμαλιών βρίσκει εκτεταμένη χρήση σε μία ευρεία ποικιλία εφαρμογών όπως η ανίχνευση απάτης για πιστωτικές κάρτες, ασφάλιση ή ιατρική περίθαλψη, ανίχνευση εισβολών για ασφάλεια κυβερνοχώρου, ανίχνευση βλαβών σε συστήματα κρίσιμης σημασίας για την ασφάλεια και τη στρατιωτική παρακολούθηση για εχθρικές δραστηριότητες. Η σημασία για την ανίχνευση ανωμαλιών οφείλεται στο γεγονός ότι οι ανωμαλίες στα δεδομένα μεταφράζονται σε σημαντικές και συχνά κρίσιμες πληροφορίες που μπορούν να ενεργοποιηθούν σε μια μεγάλη ποικιλία τομέων εφαρμογών.

Ένα παράδειγμα θα μπορούσε να είναι το ανώμαλο μοντέλο κυκλοφορίας σε ένα δίκτυο υπολογιστών. Ένας υπολογιστής με hacking στέλνει ευαίσθητα δεδομένα σε έναν μη εξουσιοδοτημένο προορισμό (Kumar 2005). Μια ανώμαλη εικόνα μαγνητικής τομογραφίας μπορεί να υποδεικνύει την παρουσία κακοηθών όγκων (Spence et al., 2001). Ανωμαλίες στα δεδομένα των συναλλαγών πιστωτικής κάρτας θα μπορούσαν να υποδηλώνουν κλοπή πιστωτικής κάρτας ή κλοπή ταυτότητας (Aleskeron et al. 1997). Ανίχνευση αποκλίσεων ή ανωμαλιών στα δεδομένα έχει μελετηθεί στην κοινότητα στατιστικών στοιχείων ήδη από το 19^ο αιώνα (Edgeworth 1887). Με τον καιρό, για μια ποικιλία ανίχνευσης ανωμαλίας, τεχνικές έχουν αναπτυχθεί σε πολλές ερευνητικές κοινότητες. Πολλές από τις τεχνικές αυτές έχουν αναπτυχθεί ειδικά για ορισμένους τομείς εφαρμογής, ενώ άλλες είναι πιο γενικές.

3.1. Τι είναι οι ανωμαλίες

Είναι στοιχεία στα δεδομένα που δεν συμμορφώνονται με μια καλά ορισμένη έννοια φυσιολογικής συμπεριφοράς. Το σχήμα 9 απεικονίζει ανωμαλίες σε ένα απλό δισδιάστατο σύνολο δεδομένων. Τα δεδομένα έχουν δύο κανονικές περιοχές, N1 και N2, καθώς οι περισσότερες παρατηρήσεις βρίσκονται σε αυτές τις δύο περιοχές. Σημεία αρκετά μακριά από αυτές τις περιοχές, είναι ανωμαλίες.

Ανωμαλίες μπορεί να προκληθούν στα δεδομένα για διάφορους λόγους, όπως κακόβουλη δραστηριότητα, εισβολή στον κυβερνοχώρο, τρομοκρατική δραστηριότητα ή καταστροφή του συστήματος, αλλά όλοι οι λόγοι έχουν το κοινό χαρακτηριστικό ότι είναι ενδιαφέρον για ανάλυση. Η ενδιαφέρουσα ή πραγματική συνάφεια των ανωμαλιών είναι το κύριο χαρακτηριστικό της ανίχνευσης ανωμαλιών.

Η ανίχνευση ανωμαλιών σχετίζεται, αλλά διακρίνεται από την απομάκρυνση του θορύβου (Teng et al. 1990) και (Rousseeuw and Leroy 1987), όπου ασχολούνται με ανεπιθύμητο θόρυβο στα δεδομένα. Ο θόρυβος μπορεί να οριστεί ως φαινόμενο στα δεδομένα που δεν παρουσιάζουν ενδιαφέρον στον αναλυτή, αλλά παρεμποδίζει την ανάλυση δεδομένων. Η αφαίρεση του θορύβου οδηγείται από την ανάγκη να αφαιρεθούν τα ανεπιθύμητα αντικείμενα πριν γίνει οποιαδήποτε ανάλυση δεδομένων.


Ένα άλλο θέμα που σχετίζεται με την ανίχνευση ανωμαλιών είναι η ανίχνευση ανωμαλίας (Markou and Singh 2003a, 2003b; Saunders and Gero 2000), η οποία στοχεύει στην ανίχνευση προηγούμενων παρατηρήσεων (αναδυόμενα ή νέα). Η διάκριση μεταξύ νέων μορφών και ανωμαλιών είναι ότι τα νέα πρότυπα τυπικά ενσωματώνονται στο κανονικό μοντέλο μετά την ανίχνευσή του.

Σε αφηρημένο επίπεδο, μια ανωμαλία ορίζεται ως ένα σχέδιο που δεν συμμορφώνεται με την αναμενόμενη κανονική συμπεριφορά. Επομένως, μια απλή προσέγγιση είναι να ορίσουμε μια περιοχή που αντιπροσωπεύει την κανονική συμπεριφορά και δηλώνει οποιαδήποτε παρατήρηση στα δεδομένα που δεν ανήκουν σε αυτή την κανονική περιοχή ως ανωμαλία. Πολλοί παράγοντες, όμως, κάνουν αυτή την απλή προσέγγιση αρκετά δύσκολη. Ο καθορισμός μιας απλής τιμής που περικλείει κάθε πιθανή κανονική συμπεριφορά συνήθως είναι πολύ δύσκολος. Επίσης, το όριο μεταξύ κανονικής και ανώμαλης συμπεριφοράς συχνά δεν είναι ακριβές. Έτσι, μια ανώμαλη παρατήρηση που βρίσκεται κοντά στα όρια είναι δυσδιάκριτο εάν αποτελεί ανωμαλία ή όχι. Όταν οι ανωμαλίες

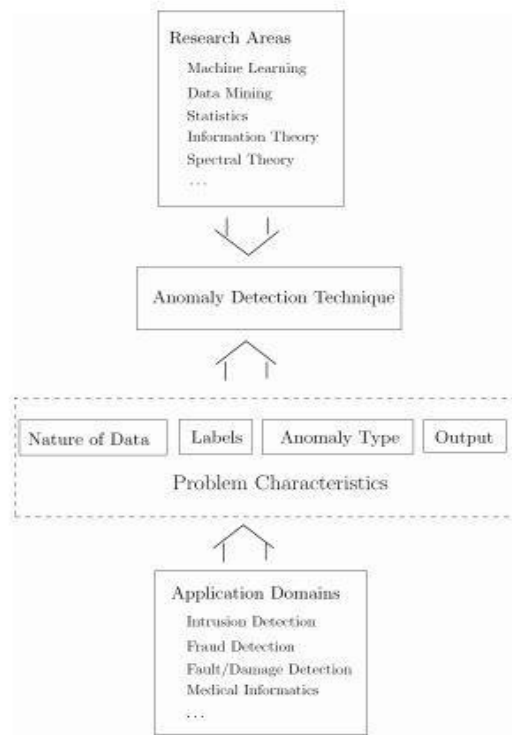
οφείλονται σε κακόβουλες ενέργειες, οι κακόβουλοι αντίπαλοι συχνά προσαρμόζονται για να καταστήσουν τις ανωμαλίες κανονικές, καθιστώντας δύσκολο την οριοθέτηση της κανονικής συμπεριφοράς. Επιπλέον, σε πολλούς τομείς, η φυσιολογική συμπεριφορά συνεχίζει να εξελίσσεται και η σημερινή έννοια φυσιολογικής συμπεριφοράς ενδέχεται να μην είναι επαρκώς αντιπροσωπευτική στο μέλλον.

Η ακριβής έννοια μιας ανωμαλίας είναι διαφορετική για διαφορετικούς τομείς εφαρμογών. Παραδείγματος χάριν, μια μικρή απόκλιση στον ιατρικό τομέα μπορεί να θεωρηθεί ανωμαλία, η ίδια απόκλιση, όμως, στο απόθεμα μιας αποθήκης μπορεί να είναι φυσιολογική. Η διαθεσιμότητα καταγεγραμμένων δεδομένων για την εκπαίδευση των μοντέλων που χρησιμοποιούνται από τεχνικές ανίχνευσης ανωμαλιών είναι ένα σημαντικό θέμα. Αρκετά συχνά τα δεδομένα περιέχουν θόρυβο που τείνει να είναι παρόμοιος με τις πραγματικές ανωμαλίες και ως εκ τούτου, είναι δύσκολο να γίνει διάκριση.

Λόγω αυτών των προκλήσεων, το πρόβλημα ανίχνευσης ανωμαλίας, στη πιο γενική μορφή, δεν είναι εύκολο να λυθεί. Στην πραγματικότητα, οι περισσότερες από τις υπάρχουσες τεχνικές ανίχνευσης ανωμαλιών επιλύουν μια συγκεκριμένη διατύπωση του προβλήματος. Συχνά παράγοντες όπως, η φύση των δεδομένων, η διαθεσιμότητα των δεδομένων, ο τύπος ανωμαλιών, καθορίζονται από τον τομέα εφαρμογής στον οποίο πρέπει να εντοπιστούν ανωμαλίες. Ερευνητές υιοθέτησαν έννοιες από διάφορους κλάδους, όπως, στατιστικούς, Machine Learning, εξόρυξη δεδομένων, θεωρία πληροφοριών, φασματική θεωρία και τις έχουν εφαρμόσει σε συγκεκριμένες διαμορφώσεις προβλημάτων.



Σχήμα 9:Ανωμαλίες σε ένα απλό δισδιάστατο σύνολο δεδομένων




Σχήμα 10: Εφαρμογές Anomaly Detection

3.2 Είδη Ανωμαλιών

3.2.1. Σημειακές (point anomalies)

Σε αυτή την κατηγορία το αντικείμενο στα δεδομένα δείχνει μια διαφορετική συμπεριφορά από τα υπόλοιπα δεδομένα. Είναι το πιο εύκολο ανιχνεύσιμο είδος ακραίας τιμής και είναι το κατάλληλο μέτρο μέτρησης της απόκλισης του ενός σημείου από τα υπόλοιπα.




Σχήμα 11: Σημειακές ακραίες τιμές

3.2.2. Ανωμαλίες που σχετίζονται με το περιβάλλον (contextual anomalies)

Εδώ ένα σημείο των δεδομένων αποκλίνει σημαντικά από τα υπόλοιπα σε ένα συγκεκριμένο περιβάλλον και μόνο σε αυτό. Η έννοια του περιβάλλοντος προκύπτει από τη δομή των δεδομένων και είναι μέρος της διατύπωσης του προβλήματος. Παραδείγματος χάριν, μια τιμή θερμοκρασίας στην Ελλάδα των 30C δεν θεωρείται ακραία, αλλά αν αυτή σημειωθεί το μήνα Δεκέμβριο τότε αποτελεί ανωμαλία.

3.2.3. Συλλογικές ακραίες τιμές (collective anomalies)

Αναφέρεται σε ένα σημείο από τα δεδομένα τα οποία ως ομάδα, δείχνει μια διαφορετική συμπεριφορά στο γενικό σύνολο των δεδομένων, ενώ σαν ανεξάρτητη μονάδα μπορεί να μην αποτελεί ακραία τιμή.



Σχήμα 12: Collective anomaly corresponding to an Atrial Premature Contraction in a human electrocardiogram output

3.3 Κατηγορίες τεχνικών ανίχνευσης ακραίων τιμών.

3.3.1. Επιβλεπόμενες (supervised)

Επιβλεπόμενα προβλήματα είναι εκείνα τα οποία ο υπολογιστής δεν μπορεί να λύσει εξ' ολοκλήρου μόνος του. Ουσιαστικά, καταχωρούμε στον υπολογιστή τα δεδομένα και χρειάζεται ο ανθρώπινος παράγοντας για να μπορέσει να ταξινομήσει αυτά τα δεδομένα. Προϋποθέτει ότι ο άνθρωπος γνωρίζει όλες τις πιθανές ακραίες τιμές ή μπορεί να θεωρήσει φυσιολογικό στα δεδομένα κάτι που δεν είναι τόσο εφικτό. Αυτό μπορεί να γίνει με δύο τρόπους, είτε να πούμε τι είναι κανονικό και οτιδήποτε άλλο θεωρείται ακραία τιμή, είτε να ορίσουμε τι θεωρείται ακραία τιμή και τα υπόλοιπα να θεωρούνται φυσιολογικά. (Omar, και συν., 2013)

3.3.2. Μη επιβλεπόμενες (unsupervised)

Εδώ δεν υπάρχει καμία προ-ταξινόμηση από τον ανθρώπινο παράγοντα και ο υπολογιστής πρέπει να ανιχνεύσει μόνος του που υπάρχουν ακραίες τιμές. Σε αυτή την περίπτωση υποθέτουμε ότι τα δεδομένα που έχουν κανονική συμπεριφορά ακολουθούν συχνά ένα πρότυπο, ενώ οι ακραίες τιμές δεν συμπεριφέρονται με αυτό τον τρόπο. Αυτό δεν λειτουργεί πάντα καθώς υπάρχουν περιπτώσεις όπου ομοιότητα δεν αρκεί.

3.3.3. Ημι-επιβλεπόμενες (semi-supervised)

Εδώ έχουμε κάτι ανάμεσα στις δύο προηγούμενες κατηγορίες. Χρησιμοποιείται όταν από το σύνολο των δεδομένων, είναι λίγα εκείνα τα οποία έχουν προ-χαρακτηριστεί ως κανονικά. Με άξονα αυτά προσπαθούμε να χαρακτηρίσουμε τα υπόλοιπα. Σε αυτή την περίπτωση, το δεδομένο λέγεται ακραία τιμή αν βρίσκεται έξω από το σύνολο και φυσιολογικό όταν είναι εντός. (anodot, 2017 p.5)

3.4. Τεχνικές ανίχνευσης ακραίων τιμών

3.4.1. Τεχνικές βασισμένες στην ταξινόμηση (classification)


Η ταξινόμηση είναι μια μορφή ανάλυσης δεδομένων. Χρησιμοποιείται για να εκπαιδευτεί ένα μοντέλο από ένα σύνολο προ-χαρακτηρισμένων δεδομένων και μετά να ταξινομήσει κάθε σημείο σε μια τάξη με βάση το μοντέλο εκμάθησης. Αυτά τα μοντέλα ονομάζονται ταξινομητές και προβλέπουν κατηγοριοποιημένες ετικέτες κλάσεων. Καθορίζεται ως μια επιβλεπόμενη μέθοδος με δύο βήματα, ένα βήμα εκμάθησης και ένα βήμα ταξινόμησης.

Στο πρώτο στάδιο, ένα σύνολο από χαρακτηριστικά δεδομένων, χρησιμοποιείται για να κατασκευάσουμε ένα μοντέλο ταξινόμησης. Στο δεύτερο στάδιο, ο άνθρωπος καθορίζει αν η ακρίβεια του μοντέλου είναι αποδεκτή. Εφόσον είναι, χρησιμοποιούμε το μοντέλο για να ταξινομήσουμε τα δεδομένα.

Για τον καθορισμό των ακραίων τιμών, τα δεδομένα που χρησιμοποιούνται για την εκμάθηση χαρακτηρίζονται ως κανονικά ή ανώμαλα. Υπάρχουν αρκετοί ταξινομητές, όπου μπορούν να χρησιμοποιηθούν για την ανίχνευση των ακραίων τιμών χρησιμοποιώντας ως μούσουλα τις ετικέτες που είναι διαθέσιμες κατά τη φάση της εκμάθησης. Οι προσεγγίσεις βασισμένες στην ταξινόμηση μπορούν να χρησιμοποιήσουν είτε μοντέλο μιας τάξης (one-class) είτε μοντέλο πολλαπλών τάξεων (multiclass).

Στην περίπτωση του μοντέλου της μίας τάξης, καθορίζεται μία μοναδική χαρακτηρισμένη τάξη. Κατασκευάζεται, δηλαδή, μία τάξη μέσα στην οποία όλα τα δεδομένα που υπάρχουν θεωρούνται κανονικά και τα άλλα είναι ακραίες τιμές. Αυτή η τεχνική, όπως και οι υπόλοιπες τεχνικές αυτού του είδους, χρησιμοποιεί ένα διακριτό σύνολο γύρω από τα κανονικά δεδομένα (σχήμα 13b). Αυτό το μοντέλο μας βοηθά να ανιχνεύσουμε νέες ακραίες τιμές, οι οποίες είναι μακριά από τις ήδη υπάρχουσες σε ένα συγκεκριμένο σύνολο δεδομένων. Μερικά από αυτά τα μοντέλα είναι τα one-class SVM, Gaussian model description και Principal component analysis description.

Στη δεύτερη περίπτωση, το μοντέλο πολλαπλών τάξεων, χρησιμοποιείται όταν τα δεδομένα ανήκουν σε πολλές τάξεις. Εδώ γίνεται διάκριση μεταξύ των κοινωνικών τάξεων και των υπολοίπων (σχήμα 13a). Ένα δεδομένο θεωρείται ακραία τιμή όταν δεν έχει ταξινομηθεί σε καμία τάξη κανονικών δεδομένων.



Σχήμα 13: Using classification for anomaly detection

Στα θετικά των τεχνικών ταξινόμησης, ειδικά των πολλαπλών τάξεων, είναι ότι μπορούν να χρησιμοποιήσουν ισχυρούς αλγόριθμους, οι οποίοι έχουν την ικανότητα να διακρίνουν τις ανωμαλίες μεταξύ των περιπτώσεων που ανήκουν σε διαφορετικές τάξεις. Επίσης, η φάση εκμάθησης των τεχνικών ταξινόμησης είναι αρκετά γρήγορη, καθώς κάθε περίπτωση συγκρίνεται με το ήδη υπολογισμένο μοντέλο.

Στα αρνητικά είναι ότι τα μοντέλα πολλαπλών τάξεων βασίζονται στη διαθεσιμότητα χαρακτηρισμών ακρίβειας για τις ποικίλες κανονικές τάξεις, κάτι το οποίο δεν είναι πάντα εφικτό. Επιπροσθέτως, οι τεχνικές ταξινόμησης, αποδίδουν ένα χαρακτηρισμό σε κάθε δοκιμαστική περίπτωση, κάτι το οποίο μπορεί να γίνει μειονέκτημα όταν είναι επιθυμητή μια βαθμολογία ακραίας τιμής. Για την αντιμετώπιση αυτού του προβλήματος μπορούν να χρησιμοποιηθούν ορισμένες τεχνικές ταξινόμησης που επιτυγχάνουν μια πιθανολογική βαθμολογία πρόβλεψης στο τέλος της ταξινόμησης (Chandola, et al., 2007).

3.4.2. Τεχνικές βασισμένες στην εγγύτητα (proximity) ή στον «κοντινότερο γείτονα» (nearest neighbor)

Αυτές οι τεχνικές βασίζονται στην υπόθεση πως τα κανονικά συμβάντα υπάρχουν στις πυκνές γειτονίες, ενώ οι ακραίες τιμές υπάρχουν μακριά από τους πιο κοντινούς γείτονες. Οι τεχνικές εγγύτητας απαιτούν ένα μέτρο απόστασης ή ομοιότητας που να καθορίζει την απόσταση μεταξύ δύο δεδομένων. Διάφοροι μέθοδοι του τύπου των K-κοντινότερων γειτόνων μπορούν να χρησιμοποιηθούν, οι οποίοι κάνουν χρήση ποικίλων μέτρων, όπως η

απόσταση, η πυκνότητα ή άλλα παρόμοια μέτρα για να καθορίσουν την εγγύτητα μεταξύ των κόμβων. Οι τεχνικές που βασίζονται στη εγγύτητα χωρίζονται σε δύο κατηγορίες.

Στη πρώτη κατηγορία ανήκουν εκείνες που βασίζονται στην απόσταση, οι οποίες είναι κυρίως σημειακές ακραίες τιμές και η ανίχνευση τους γίνεται ως επί τω πλείστων με τη χρήση της ευκλείδειας απόστασης.

Στη δεύτερη κατηγορία ανήκουν εκείνες που βασίζονται στη σχετική πυκνότητα, οι οποίες υπολογίζουν την πυκνότητα της γειτονιάς σε κάθε σημείο. Μια περίπτωση που είναι κοντά σε γειτονιά χαμηλής πυκνότητας χαρακτηρίζεται ως ακραία τιμή ενώ μία που είναι κοντά σε πυκνή γειτονιά θεωρείται φυσιολογική. Γνωστοί αλγόριθμοι αυτής της κατηγορίας είναι οι k-NN Global Anomaly Score, Local Outlier Factor και Connectivity-Based Outlier Factor.

Τα πλεονεκτήματα των τεχνικών εγγύτητας είναι ότι από τη φύση τους είναι μη επιβλεπόμενες και δεν κάνουν υποθέσεις που αφορούν τη γενική κατανομή των δεδομένων, δηλαδή οδηγούνται καθαρά από τα δεδομένα. Επίσης, οι ημι-επιβλεπόμενες τεχνικές λειτουργούν καλύτερα από τις επιβλεπόμενες στην περίπτωση χαμηλών ακραίων τιμών, καθώς η πυκνότητα μιας ακραίας τιμής να σχηματίσει μια στενή γειτονιά σε δεδομένα εκμάθησης είναι πολύ χαμηλή. Τέλος, η προσαρμογή αυτών των τεχνικών σε ένα διαφορετικό τύπο δεδομένων είναι απλή και απαιτεί κυρίως τον καθορισμό ενός κατάλληλου μέτρου απόστασης για τα δεδομένα.

Από την άλλη πλευρά έχουμε και τα μειονεκτήματα. Για τις μη επιβλεπόμενες τεχνικές, αν τα δεδομένα κανονικά δεν έχουν αρκετά στενούς γείτονες, ή αν έχουν ακραίες τιμές που έχουν στενούς γείτονες, τότε οι τεχνικές αποτυγχάνουν να τα χαρακτηρίσουν σωστά, οδηγώντας μας σε λάθος ή χαμένες ακραίες τιμές. Επιπλέον, η υπολογιστική πολυπλοκότητα αποτελεί μια πρόκληση καθώς περιλαμβάνει τον υπολογισμό της απόστασης ενός στοιχείου από όλα τα άλλα προκειμένου να βρούμε τους κοντινότερους γείτονες (Chandola, et al., 2007).

3.4.3. Τεχνικές βασισμένες στην ομαδοποίηση (clustering)

Η ομαδοποίηση ήταν πρωταρχικά μία μη-επιβλεπόμενη τεχνική, ωστόσο αργότερα αναπτύχθηκε και η ημι-επιβλεπόμενη ομαδοποίηση. Παρόλο που η ομαδοποίηση και η ανίχνευση ακραίων τιμών δείχνουν να είναι θεμελιωδώς διαφορετικές, έχουν αναπτυχθεί πολλαπλές μέθοδοι ανίχνευσης ακραίων τιμών βασιζόμενες στην ομαδοποίηση. Με τη

βοήθεια μερικών αλγορίθμων όπως ο K-Means, ο K-Medoids, ο CLARANS, ο BIRCH κ.α. μπορούμε να δημιουργήσουμε τις ομάδες δεδομένων. Οι τεχνικές ανίχνευσης ακραίων τιμών που βασίζονται στην ομαδοποίηση χωρίζονται σε τρεις κατηγορίες.

Η υπόθεση ότι οι κανονικές περιπτώσεις δεδομένων ανήκουν σε μια ομάδα, ενώ οι ακραίες τιμές δεν ανήκουν σε καμία ομάδα αφορά την πρώτη κατηγορία. Σε αυτή την περίπτωση εφαρμόζουμε ένα γνωστό αλγόριθμο ομαδοποίησης στο σύνολο των δεδομένων και η κάθε περίπτωση που δεν ανήκει σε καμία ομάδα δηλώνεται ως ακραία τιμή. Στους αλγόριθμους αυτής της κατηγορίας ανήκουν οι εξής: DBSCAN, ROCK, SNN clustering και ο Z-WINDOWS (Boutsinas, et al., 2006). Ένα πρόβλημα είναι ότι δεν μπορούν να βελτιστοποιηθούν στο να βρίσκουν ακραίες τιμές καθώς σαν σκοπό έχουν να βρίσκουν ομάδες.

Στη δεύτερη κατηγορία έχουμε την υπόθεση πως οι περιπτώσεις κανονικών δεδομένων βρίσκονται κοντά στο κέντρο της κοντινότερης ομάδας τους, ενώ αντίθετα οι ακραίες τιμές έχουν μεγάλη απόσταση από το κέντρο της κοντινότερης ομάδας τους. Αυτές οι τεχνικές αποτελούνται από δύο βήματα. Στο πρώτο τα δεδομένα ομαδοποιούνται χρησιμοποιώντας έναν αλγόριθμο ομαδοποίησης. Στο δεύτερο βήμα, για κάθε περίπτωση δεδομένου, υπολογίζεται η απόσταση από το κοντινότερο κέντρο μάζας ομάδας ως ένας βαθμός ακραίας τιμής. Στη περίπτωση όπου οι ακραίες τιμές σχηματίζουν μόνες τους ομάδες, αυτού του είδους οι τεχνικές δεν είναι δυνατόν να τις ανιχνεύσουν. Για την αντιμετώπιση αυτού του προβλήματος έχουμε την τρίτη κατηγορία.

Η τρίτη κατηγορία βασίζεται στην υπόθεση πως οι κανονικές περιπτώσεις δεδομένων ανήκουν σε μεγάλες και πυκνές ομάδες ενώ οι ακραίες τιμές ανήκουν είτε σε μικρές είτε σε αραιές ομάδες. Σε ομάδες των οποίων το μέγεθος ή/και η πυκνότητα βρίσκονται κάτω από ένα συγκεκριμένο όριο χαρακτηρίζονται ως ακραίες τιμές και είναι περιπτώσεις όπου δηλώνουν αυτές τις τεχνικές. Ο αλγόριθμος FindCBLOF ανιχνεύει τόσο τις ανεξάρτητες περιπτώσεις όσο και τα σημεία που ανήκουν σε μικρές ομάδες ως ακραίες τιμές υπολογίζοντας την ομοιότητα μεταξύ των περιπτώσεων στη μικρή ομάδα και στην πλησιέστερη μεγάλη ομάδα. Υπολογίζει μια βαθμολογία ακραίας τιμής γνωστή ως Cluster-Based Local Outlier Factor(CBLOF), για κάθε δεδομένο, σύμφωνα με την οποία γίνεται ο

διαχωρισμός σε ακραίες τιμές ή όχι. Άλλες τεχνικές για χώρισμα δεδομένων είναι οι k-d trees και CD-trees.

Στα θετικά χαρακτηριστικά των τεχνικών βασισμένων στη ομαδοποίηση είναι ότι μπορούν να λειτουργήσουν με μη επιβλεπόμενο τρόπο. Επίσης, μπορούν να προσαρμοστούν σε άλλους σύνθετους τύπους δεδομένων απλά συνθέτοντας έναν αλγόριθμο ομαδοποίησης που μπορεί να χειριστεί τον συγκεκριμένο τύπο δεδομένων. Τέλος, η φάση εκμάθησης γι' αυτές τις τεχνικές είναι γρήγορη, καθώς ο αριθμός των ομάδων με τις οποίες κάθε παράμετρος πρέπει να συγκριθεί είναι μικρός και σταθερός.

Από την άλλη πλευρά η εκτέλεση των τεχνικών αυτών είναι υψηλά εξαρτώμενη από την αποτελεσματικότητα των αλγορίθμων ομαδοποίησης στο να φτιάξουν τη δομή των ομάδων κανονικών περιπτώσεων. Επίσης, πολλές τεχνικές ανιχνεύουν τις ακραίες τιμές ως επακόλουθο της ομαδοποίησης και δεν βελτιστοποιούνται για την ανίχνευση ακραίων τιμών. Πολλοί αλγόριθμοι ομαδοποίησης θεωρούν πως κάθε δεδομένο πρέπει να ανήκει σε μια ομάδα. Αυτό έχει ως αποτέλεσμα, οι ακραίες τιμές να θεωρούνται μέλη μιας μεγάλης ομάδας και να χαρακτηρίζονται ως κανονικές περιπτώσεις που λειτουργούν με την υπόθεση ότι οι ακραίες τιμές δεν ανήκουν σε καμία ομάδα. Αυτό θεωρείται ένα ακόμη μειονεκτήματα, όπως επίσης, πολλές τεχνικές ομαδοποίησης είναι αποτελεσματικές μόνο όταν οι ακραίες τιμές δεν σχηματίζουν σημαντικές ομάδες μεταξύ τους. Τέλος, η υπολογιστική πολυπλοκότητα για την ομαδοποίηση των δεδομένων αποτελεί συχνά κώλυμα ειδικά όταν χρησιμοποιούνται αλγόριθμοι πολυπλοκότητας $O(N^2d)$, όπου N ο αριθμός των περιπτώσεων και d ο αριθμός των ομάδων. (Chandola, et al., 2007)

3.4.4. Τεχνικές ανίχνευσης ακραίων τιμών βασισμένες στη στατιστική

Οι τεχνικές αυτές για την ανίχνευση ακραίων τιμών κάνουν υποθέσεις σχετικά με την κανονικότητα των δεδομένων. Υποθέτουν ότι τα κανονικά δεδομένα ενός συνόλου δεδομένων δημιουργούνται από τη στοχαστική διαδικασία. Κατ' επέκταση, οι κανονικές περιπτώσεις δεδομένων συμβαίνουν στις περιοχές υψηλής πυκνότητας ενός στοχαστικού μοντέλου ενώ οι ακραίες τιμές συναντώνται σε περιοχές χαμηλής πυκνότητας. Να σημειωθεί ότι έχουν χρησιμοποιηθεί και παραμετρικές αλλά και μη παραμετρικές μέθοδοι.

Τέτοιου είδους τεχνικές παίρνουν ένα στατιστικό μοντέλο των δοσμένων δεδομένων (συνήθως για την κανονική συμπεριφορά), και εφαρμόζουν μια στατιστική δοκιμή συμπερασμάτων για να καθορίσουν αν μια περίπτωση ανήκει σε αυτό το μοντέλο ή όχι. Δηλώνονται ακραίες τιμές, όταν τα σημεία που έχουν μικρή πιθανότητα να δημιουργήθηκαν από το γνωστό μοντέλο, στηριγμένοι στο εφαρμοσμένο τεστ.

Μια παραμετρική μέθοδος υποθέτει ότι τα κανονικά δεδομένα δημιουργούνται από μια παραμετρική κατανομή με παράμετρο θ , η συντήρηση πυκνότητας πιθανότητας της παραμετρικής κατανομής $f(x, \theta)$ δίνει την πιθανότητα ένα αντικείμενο x να δημιουργείται από την κατανομή. Όσο πιο μικρή αυτή η τιμή τόσο πιο πιθανό το x να είναι μια ακραία τιμή. Η ανίχνευση ακραίων τιμών βασιζόμενη στην κατανομή gauss είναι αυτή που έχει μελετηθεί περισσότερο.

Μια μη παραμετρική μέθοδος, δεν υποθέτει εκ των προτέρων ένα στατιστικό μοντέλο. Αντ' αυτού προσπαθεί να καθορίσει το μοντέλο από τα εισαγόμενα δεδομένα. Οι περισσότερες μη παραμετρικές μέθοδοι δεν υποθέτουν πως το μοντέλο είναι εντελώς χωρίς παράμετρο. Αυτό που κάνουν, είναι να θεωρούν πως ο αριθμός και η φύση των παραμέτρων είναι ευέλικτη και δεν ορίζονται εκ των προτέρων. Η χρήση ιστογραμμάτων για τη διατήρηση ενός προφίλ των δεδομένων είναι ίσως η πιο δημοφιλής μη παραμετρική μέθοδος. Η τεχνικές των ιστογραμμάτων στηρίζονται από τη φύση τους στη συχνότητα των δεδομένων. (Zhang, 2013) Γνωστοί αλγόριθμοι που βασίζονται στη στατιστική είναι οι Histogram-based Outlier Score (HBOS) και Robust Principal Component Analysis Anatomy Score (rPCA).

Όταν οι υποθέσεις που σχετίζονται με τη βασική κατανομή των δεδομένων ισχύουν, οι στατιστικές τεχνικές παρέχουν μια στατιστικά δικαιολογημένη λύση για την ανίχνευση ακραίων τιμών. Επίσης, η βαθμολογική κλίμακα ακραίας τιμής που παρέχεται από μια στατιστική τεχνική σχετίζονται με το διάστημα εμπιστοσύνης, το οποίο μπορεί να χρησιμοποιηθεί ως επιπρόσθετη πληροφορία για να πάρουμε μια απόφαση που αφορά οποιαδήποτε παρατήρηση. Τέλος, αν το βήμα εκτίμησης της κατανομής είναι ανθεκτικό στις ακραίες τιμές, τότε οι στατιστικές τεχνικές μπορούν να λειτουργήσουν σε μη επιβλεπόμενο περιβάλλον χωρίς την ανάγκη χαρακτηρισμένων δεδομένων εκμάθησης. Όλα αυτά, λοιπόν, θεωρούνται τα πλεονεκτήματα των στατιστικών τεχνικών.

Από την άλλη μεριά, όμως, έχουμε και τα μειονεκτήματα. Το κύριο μειονέκτημα των στατιστικών τεχνικών είναι ότι βασίζονται στην υπόθεση πως τα δεδομένα δημιουργήθηκαν από μια συγκεκριμένη κατανομή. Αυτή η υπόθεση συχνά δεν ισχύει, ειδικά για δεδομένα

υψηλής διάστασης. Ακόμη και αν η στατιστική υπόθεση μπορεί να δημιουργηθεί λογικά, υπάρχουν αρκετά υποθετικά τεστ στατιστικής που μπορούν να εφαρμοστούν για την ανίχνευση ακραίων τιμών, όπου η επιλογή του καλύτερου και καταλληλότερου δεν είναι συχνά μια εύκολη διαδικασία. Τέλος, όσο αναφορά τα μειονεκτήματα αυτών των τεχνικών έχουμε ότι οι τεχνικές που βασίζονται σε ιστογράμματα είναι σχετικά εύκολες στην εφαρμογή, αλλά μια βασική έλλειψη είναι ότι δεν μπορούν να συλλάβουν τις αλληλεπιδράσεις μεταξύ διαφορετικών κατανομών. Μια ακραία τιμή μπορεί να έχει τιμές χαρακτηριστικών που μεμονωμένα να είναι συχνές, αλλά ο συνδυασμός τους να είναι σπάνιος. Ωστόσο μια τεχνική βασισμένη σε ιστογράμματα δεν θα ήταν ικανή να ανιχνεύσει τέτοιες ακραίες τιμές (Chandola, et al., 2007)

3.4.5. Χειρισμός ακραίων τιμών που σχετίζονται με το περιβάλλον(contextual anomalies)

Οι ακραίες τιμές που σχετίζονται με το περιβάλλον, απαιτούν τα δεδομένα να έχουν ένα σύνολο περιβαλλοντικών χαρακτηριστικών, για να μπορέσει να γίνει ο καθορισμός του περιβάλλοντος και ένα σύνολο χαρακτηριστικών συμπεριφοράς, για την ανίχνευση ακραίων τιμών μέσα στο περιβάλλον. Μερικοί τρόποι που τα περιβαλλοντικά χαρακτηριστικά μπορούν να οριστούν ακολουθούν παρακάτω.

Ο πρώτος τρόπος ονομάζεται χωρικά. Τα δεδομένα έχουν χωρικά χαρακτηριστικά, τα οποία καθορίζουν την τοποθεσία ενός δεδομένου και ως εκ τούτου τη χωρική γειτονία. Υπάρχουν πολλές τεχνικές για χωρικά δεδομένα που έχουν προταθεί στη διεθνή βιβλιογραφία.

Ένας δεύτερος τρόπος είναι τα γραφήματα. Οι άκρες που συνδέουν τα δεδομένα καθορίζουν τη γειτονία για κάθε δεδομένο. Επίσης, υπάρχουν αρκετές τεχνικές που έχουν προταθεί γι' αυτό τον τύπο προβλημάτων.

Επόμενος τρόπος είναι η διαδοχή. Τα δεδομένα είναι διαδοχικά. Τα περιβαλλοντικά χαρακτηριστικά δηλαδή, ενός δεδομένου είναι η θέση του στη σειρά. Οι χρονοσειρές έχουν εντελώς εξερευνηθεί στην κατηγορία ανίχνευσης των περιβαλλοντικών ακραίων τιμών.

Τέλος, έχουμε το προφίλ. Πολλές φορές τα δεδομένα μπορεί να μην έχουν μια σαφή χωρική ή διαδοχική δομή, αλλά μπορεί να χωρίζονται ή ομαδοποιούνται σε επιμέρους συστατικά χρησιμοποιώντας ένα σύνολο περιβαλλοντικών χαρακτηριστικών. Ουσιαστικά αυτά τα χαρακτηριστικά χρησιμοποιούνται για να δώσουν ένα προφίλ και να ομαδοποιήσουν τους χρήστες σε συστήματα παρακολούθησης δραστηριότητας. Σε τέτοιες περιπτώσεις οι χρήστες αναλύονται σύμφωνα με την ομάδα ακραίων τιμών στην οποία ανήκουν.

Υπάρχουν δύο τρόποι εκτέλεσης του προβλήματος ανίχνευσης περιβαλλοντικών ακραίων τιμών.

Ο πρώτος είναι να μειώσουμε το πρόβλημα, σε πρόβλημα ανίχνευσης σημειακών ακραίων τιμών. Αφού, οι ακραίες τιμές που σχετίζονται με το περιβάλλον είναι ανεξάρτητες περιπτώσεις δεδομένων, αλλά είναι ακραίες τιμές μόνο σε σχέση με ένα συγκεκριμένο περιβάλλον, αρκεί να εφαρμόσουμε μια γνωστή τεχνική ανίχνευσης σημειακών ακραίων τιμών μέσα σε ένα περιβάλλον. Δύο είναι τα βήματα τα οποία περιλαμβάνει μια βασική τεχνική μείωσης. Πρώτον, καθορίζουμε το περιβάλλον για κάθε περίπτωση χρησιμοποιώντας τα περιβαλλοντικά χαρακτηριστικά και δεύτερον, υπολογίζουμε το βαθμό ακραίας τιμής για τη συγκεκριμένη περίπτωση μέσα στο περιβάλλον, χρησιμοποιώντας μια γνωστή τεχνική ανίχνευσης σημειακών ακραίων τιμών.

Ο δεύτερος τρόπος εκτέλεσης του προβλήματος ανίχνευσης περιβαλλοντικών ακραίων τιμών βρίσκει εφαρμογή όταν το να διαχωρίσουμε το σύνολο των δεδομένων σε ξεχωριστά περιβάλλοντα δεν είναι εύκολο, όπως στις χρονοσειρές και τις ακολουθίες συμβάντων. Ο τρόπος αυτός μοντελοποιεί την κανονική συμπεριφορά των δεδομένων, με σεβασμό στα διάφορα περιβάλλοντα.

Στη συνέχεια, θα δούμε τα πλεονεκτήματα και τα μειονεκτήματα των τεχνικών ανίχνευσης ακραίων τιμών που σχετίζονται με το περιβάλλον.

Το κύριο πλεονέκτημα αυτών των τεχνικών είναι ότι επιτρέπουν ένα φυσικό ορισμό ακραίων τιμών σε πολλές εφαρμογές της πραγματικής ζωής, όπου τα δεδομένα έχουν την τάση να είναι όμοια μέσα σε ένα περιβάλλον. Επίσης, μπορούν αυτές οι τεχνικές να ανιχνεύσουν τιμές που δεν είναι ικανές να ανιχνεύουν ακραίες τιμές ενώ μπορεί να μην είναι ανιχνεύσιμες από τις σημειακές τεχνικές οι οποίες έχουν μια πιο συνολική εικόνα των δεδομένων.

Το αρνητικό των τεχνικών ανίχνευσης περιβαλλοντικών ακραίων τιμών είναι το γεγονός πως εφαρμόζονται μόνο όταν το περιβάλλον μπορεί να καθοριστεί. (Chandola, et.al., 2007)

3.4.6. Χειρισμός συλλογικών ακραίων τιμών (collective anomalies)

Συλλογικές ακραίες τιμές είναι το υποσύνολο των δεδομένων που συμβαίνουν μαζί ως μια ομάδα και των οποίων η εμφάνιση δεν είναι κανονική σε σχέση με την φυσιολογική συμπεριφορά. Οι ανεξάρτητες περιπτώσεις που ανήκουν σε αυτή την ομάδα, δεν αποτελούν από μόνες τους ακραίες τιμές, αλλά η συνύπαρξή τους είναι αυτή η ειδική μορφή που τις κάνει ακραίες τιμές. Το πρόβλημα ανίχνευσης συλλογικών ακραίων τιμών είναι πιο δύσκολο από αυτών των σημειακών ή περιβαλλοντικών ακραίων τιμών, καθώς θα πρέπει να ελέγξουμε τη δομή των δεδομένων για ανώμαλες περιοχές. Η σχέση μεταξύ των δεδομένων κάνει επιτακτική την ανάγκη ύπαρξης τεχνικών ανίχνευσης συλλογικών ακραίων τιμών. Οι τύποι σχέσεων που έχουν μελετηθεί πιο συχνά είναι τρεις:

Αρχικά έχουμε τη διαδοχική. Οι τεχνικές αυτές δουλεύουν με διαδοχικά δεδομένα και θεωρούν ως ακραίες τιμές τις ακολουθίες. Τυπικά σύνολα δεδομένων περιλαμβάνουν ακολουθίες συμβάντων, όπως, τηλεφωνικά δεδομένα ή αριθμητικές χρονοσειρές. Σε τέτοιου είδους δεδομένα, ελέγχουμε τις δομές που δημιουργούνται από το χρόνο, οι οποίες συμβαίνουν σε τμήματα χρονοσειρών ή ακολουθίες.

Εν συνεχεία έχουμε την χωρική. Αυτές οι τεχνικές δουλεύουν με χωρικά δεδομένα και θεωρούν τις συνδεδεμένες περιοχές μέσα στα δεδομένα ως ακραίες τιμές.

Τέλος, έχουμε τα γραφήματα. Αυτές οι τεχνικές δουλεύουν με δεδομένα γραφημάτων και θεωρούν τα συνδεδεμένα υπό γραφήματα μέσα στα δεδομένα ως ακραίες τιμές.

3.5. Ερεύνα Εύρεσης Ανωμαλιών

Η ανίχνευση ανωμαλιών υπήρξε θέμα πολλών ερευνών και άρθρων ανασκόπησης. Οι Hodge και Austin (2004) παρέχουν μια εκτεταμένη έρευνα των τεχνικών ανίχνευσης ανωμαλιών που αναπτύσσονται στο Machine Learning και στους στατιστικούς τομείς. Μια εκτεταμένη ανασκόπηση των τεχνικών ανίχνευσης καινοτομίας χρησιμοποιώντας νευρωτικά δίκτυα και

στατιστικές προσεγγίσεις, παρουσιάστηκε στο Markou and Singh(2003a) και Markou and Singh (2003b) αντίστοιχα.

Οι Patcha και Park 2007 και Snyder(2001), παρουσιάζουν μια έρευνα των τεχνικών ανίχνευσης ανωμαλιών που χρησιμοποιούνται ειδικά για την ανίχνευση διείσδυσης στον κυβερνοχώρο. Μια σημαντική έρευνα για την ανίχνευση των εξωστρεφών έχει γίνει στα στατιστικά στοιχεία και έχει αναθεωρηθεί σε πολλά βιβλία. (Rousseeuw and Leroy 1987; Barnett and Lewis 1994; Hawkins 1980, Beckman and Cook 1983; Baker et al, 2006).

Table I. Comparison of our Survey to Other Related Survey Articles. 1—Our Survey, 2—Hodge and Austin [2004], 3—Agyemang et al. [2006], 4—Markou and Singh [2003a], 5—Markou and Singh [2003b], 6—Patcha and Park [2007], 7—Beckman and Cook [1983], 8—Bakar et al. [2006]

		1	2	3	4	5	6	7	8
Techniques	Classification Based	✓	✓	✓	✓		✓		
	Clustering Based	✓	✓	✓			✓		
	Nearest Neighbor Based	✓	✓	✓			✓		✓
	Statistical	✓	✓	✓		✓	✓	✓	✓
	Information Theoretic	✓							
	Spectral	✓							
Applications	Cyber-Intrusion Detection	✓					✓		
	Fraud Detection	✓							
	Medical Anomaly Detection	✓							
	Industrial Damage Detection	✓							
	Image Processing	✓							
	Textual Anomaly Detection	✓							
	Sensor Networks	✓							

Σχήμα 14: Σύνολο των τεχνικών και τομέων εφαρμογής

3.6. Ανίχνευση ακραίων τιμών στις επιχειρήσεις

Η ανάγκη της ανάλυσης προτύπων δεδομένων και της εύρεσης ακραίων τιμών που μπορεί να αποκαλύψουν κάτι μη προσδοκώμενο, κρίνεται επιτακτική καθώς οι επιχειρήσεις είναι υψηλής ταχύτητας και το περιβάλλον είναι ανταγωνιστικό και συχνά μεταβαλλόμενο. Η διαδικασία ανίχνευσης ακραίων τιμών είναι αρκετά σημαντική για μία επιχείρηση, καθώς μπορεί να οδηγήσει σε εξοικονόμηση χρημάτων και κατά συνέπεια αύξηση κερδών και στη δημιουργία νέων επιχειρησιακών ευκαιριών. Η επιχείρηση, γνωρίζοντας το στόχο αυτό, να μάθει δηλαδή το άγνωστο, μπορεί να κάνει μελλοντικά σχέδια.

Για να μπορέσει να υπάρξει ισορροπία των διαδικασιών αυτών με τις ανάγκες των πελατών, χρειάζεται να γίνει μια σωστή διαχείριση. Σκοπό έχει τη συνεχή βελτίωση και η επιχείρηση να προσπαθεί να δρα πιο αποτελεσματικά και αποδοτικά. Η βελτιστοποίηση και η ανάλυση των επιχειρησιακών διαδικασιών αποτελεί μια εργασία με προκλήσεις ακόμη και για τους ειδικούς. (Rogge-Solti, et al., 2014)

Οι επιχειρησιακές λειτουργίες σχετίζονται με πολλούς παράγοντες και μοντελοποιούνται ως σύνθετες επιχειρησιακές διεργασίες. Εκτελώντας τις επιχειρηματικές εργασίες δημιουργείται ένα μεγάλο πλήθος σύνθετων δεδομένων. Τα δεδομένα αποτελούν σημεία στη ροή των διαδικασιών που κατά τη διάρκεια της διαδικασίας ακολουθούν διαφορετικές διαδρομές. Στόχος της ανίχνευσης ακραίων τιμών είναι να μπορέσουμε να χρησιμοποιήσουμε τα σύνθετα δεδομένα προκειμένου να αναλύσουμε τις λειτουργίες με σκοπό τη βελτιστοποίηση της ροής της κάθε διαδικασίας. (Hao, et al., 2006)

Η αυτόματη ανίχνευση ακραίων τιμών είναι μια τεχνική του Machine Learning και είναι μια αρκετά περίπλοκη διαδικασία. Χρειάζεται να υπάρχουν εκατοντάδες, χιλιάδες ή και εκατομμύρια μετρικών που βοηθούν μια επιχείρηση να καθορίσει τι σημαίνει συγκρινόμενο με το τι έχει συμβεί στο παρελθόν ή το τι ενδέχεται να συμβεί στο μέλλον. Τα πρότυπα των δεδομένων εξελίσσονται κάνοντας δύσκολη την επιλογή των μοντέλων ή των αλγορίθμων που θα εφαρμοστούν. Οι εταιρείες που χρησιμοποιούν τα κατάλληλα μοντέλα είναι ικανές να ανιχνεύσουν ακόμη και τις πιο λεπτές ακραίες τιμές. Εκείνες όμως, που χρησιμοποιούν λάθος μοντέλα αποτυγχάνουν στο να μπορέσουν να ανακαλύψουν όλες τις ακραίες τιμές ή βρίσκουν κάποιες εκεί που δεν υπάρχουν. Αυτό το λάθος μπορεί να τους οδηγήσει σε απώλεια εισοδήματος, δυσαρεστημένους πελάτες ή απώλεια σημαντικών επενδυτικών ευκαιριών.

3.7. Ανίχνευση Ανωμαλιών στη Ναυτιλία

Οι θαλάσσιες μεταφορές αντιπροσωπεύουν περίπου το 90% του παγκόσμιου εμπορίου κατ' όγκο, καθιστώντας τις προκλήσεις ασφαλείας και προστασίας ως υψηλή προτεραιότητα για τα έθνη σε ολόκληρο τον κόσμο. Τα δεδομένα της θαλάσσιας παρακολούθησης συλλέγονται σε διαφορετικές κλίμακες και χρησιμοποιούνται όλο και περισσότερο για την επίτευξη υψηλότερων επιπέδων συνειδητοποίησης της κατάστασης.

Η τεχνολογία αυτόματου συστήματος αναγνώρισης (AIS) παρέχει τεράστιο όγκο πληροφοριών σχεδόν σε πραγματικό χρόνο, ζητώντας έναν συνεχώς αυξανόμενο βαθμό αυτοματοποίησης για τη μετατροπή των δεδομένων σε σημαντικές πληροφορίες που υποστηρίζουν τους υπεύθυνους λήψης αποφάσεων. Παράδειγμα αποτελεί το Κέντρο Ναυτιλιακής Έρευνας και πειραματισμού (CMRE), όπου λαμβάνει σήμερα κατά μέσο όρο 600 εκατομμύρια μηνύματα AIS ανά μήνα από πολλαπλές πηγές και το ποσοστό αυξάνεται. Το σύστημα AIS είναι ένα αυτοσχέδιο σύστημα ανταλλαγής μηνυμάτων που σχεδιάστηκε αρχικά για την αποφυγή συγκρούσεων (το AIS είναι υποχρεωτικό για τα πλοία χωρητικότητας 300 ολικής χωρητικότητας και άνω σε διεθνή δρομολόγια 500 και άνω για φορτία που δεν βρίσκονται σε διεθνή ύδατα και επιβατηγά πλοία. Πλοία άνω των 15 μέτρων που πλέουν σε ύδατα που υπάγονται στη δικαιοδοσία της Ευρωπαϊκής Ένωσης, απαιτείται να είναι εφοδιασμένα με AIS). Τα κράτη μέλη μεταδίδουν πληροφορίες σχετικά με την τοποθεσία τους (θέση, ταυτότητα κ.α.) με μεταβλητό ρυθμό ανανέωσης. Τα σκάφη που βρίσκονται στην άγκυρα μεταδίδουν τη θέση τους κάθε δύο λεπτά και αυξάνουν το ρυθμό μετάδοσης έως και δύο δευτερόλεπτα όταν κάνουν ελιγμούς ή ιστιοπλοΐα με μεγάλη ταχύτητα. Κάθε πέντε λεπτά τα σκάφη μεταδίδουν άλλα δεδομένα (στατικά και σχετικά με το ταξίδι) που περιέχουν αναγνωριστικά στοιχεία, όπως ο αριθμός του Διεθνούς Ναυτιλιακού Οργανισμού (IMO), το διακριτικό κλήσεως, το όνομα του πλοίου και η ταυτότητα κίνησης υπηρεσίας θαλάσσιων μεταφορών (MMSI), που χρησιμοποιούνται ως πρωτεύον κλειδί κ στο μήνυμα προς τις πληροφορίες θέσης. Στατικές πληροφορίες περιλαμβάνουν επίσης, το μέγεθος, ο τύπος του σκάφους και το φορτίο, ενώ τα δεδομένα σχετικά με το ταξίδι, όπως ο εκτιμώμενος χρόνος άφιξης(ETA) και ο προορισμός, καθορίζονται με το χέρι και δεν είναι πλήρως αξιόπιστοι . Τα τελευταία χρόνια, έχουν παραληφθεί από τα πλοία και παράκτιοι σταθμοί έχουν διαβιβαστεί σε περιφερειακά ή εθνικά κέντρα δεδομένων. Όταν συνδέονται πολλαπλοί δέκτες σε δίκτυα, προκύπτουν ορισμένες προκλήσεις με διαλείμματα δεδομένων που λαμβάνονται από πολλαπλούς δέκτες, διόρθωση σφαλμάτων σε χρονικά σήματα που εκχωρούνται με διαφορετικούς δέκτες και αναγνώριση κομματιών σκαφών που μοιράζονται εσφαλμένα το αναγνωριστικό μηνύματος. Αυτό το επίπεδο προκαταρκτικής επεξεργασίας είναι απαραίτητο για την εξαγωγή μοτίβων θαλάσσιας κίνησης, ειδικά σε παγκόσμια κλίμακα. Η λήψη μηνυμάτων AIS από το θαλάσσιο σύστημα, γίνεται όλο και πιο συνηθισμένη. Σε αντίθεση με τα επίγεια δίκτυα δεκτών AIS, των οποίων η απόδοση χαρακτηρίζεται από υψηλή επιμονή, αλλά περιορισμένη κάλυψη, ενώ τα δορυφορικά συστήματα μπορούν να

παραλάβουν μηνύματα στην ανοιχτή θάλασσα, μακριά από την ακτογραμμή. Οι δορυφορικοί δέκτες τείνουν να τοποθετούνται σε δορυφόρους χαμηλής γήινης τροχιάς (LEO), οπότε η κάλυψη AIS είναι παγκόσμια, λόγω του χρόνου επανεξέτασης της πλατφόρμας. Είναι σαφές ότι κατά την ενσωμάτωση τέτοιων συστημάτων με δεδομένα που λαμβάνονται από επίγειους δέκτες υπάρχουν πρόσθετα ζητήματα για την επίλυση με αναπροσαρμογή μεταβλητής συχνότητας και κάλυψη.

Η ναυτική γνώση μπορεί να χρησιμοποιηθεί για την πραγματοποίηση ανίχνευσης ανωμαλιών βασιζόμενη σε κανόνες και χαμηλές πιθανότητες. Οι προσεγγίσεις ανίχνευσης ανωμαλιών που βασίζονται σε κανόνες αφορούν τη δημιουργία ειδοποιήσεων βάσει ενός συνόλου κανόνων, όπως η μέγιστη επιτρεπόμενη ταχύτητα σε ένα λιμάνι, η παρουσία σε περιοχές όπου περιορίζονται στη ναυσιπλοΐα ή οι ασυμφωνίες μεταξύ των ισχυρισμών του πλοίου και της πραγματικής δραστηριότητας. Αντίθετα, η ανίχνευση ανωμαλίας χαμηλής πιθανότητας στοχεύει στον εντοπισμό αποκλίσεων από την κανονικότητα των μοντέλων κυκλοφορίας των πλοίων που προκύπτουν στη φάση εκμάθησης. Οι συμπεριφορές που διαφέρουν από την κανονικότητα δεν σημαίνει ότι είναι ανωμαλίες σε λειτουργικό πλαίσιο, αλλά επισημαίνονται ως ασυνήθιστες για περαιτέρω ανάλυση.

Η κυκλοφορία των πλοίων και οι πληροφορίες κίνησης, όταν εξάγονται, μπορούν εναλλακτικά να αξιοποιηθούν για την πρόβλεψη της διαδρομής του πλοίου σε δεδομένη χρονική στιγμή. Αυτό είναι αρκετά χρήσιμο, παραδείγματος χάρη, στις εφαρμογές καταπολέμησης της πειρατείας για τον εντοπισμό περιοχών κινδύνου που σχετίζονται με την προβλεπόμενη παρουσία πυκνότητας λευκής ναυτιλίας και των ομάδων δράσης πειρατών. Η παρακολούθηση προς τα πίσω και προς τα εμπρός των σκαφών μπορεί να βελτιωθεί σημαντικά χρησιμοποιώντας τα μαθησιακά μοντέλα θαλάσσιας κυκλοφορίας, τα οποία είναι ιδιαίτερα χρήσιμα όταν προσπαθούμε να συγχωνεύσουμε πληροφορίες AIS και οπτικά συστήματα ή ραντάρ με σύνθετο άνοιγμα (SAR) με βάση το διάστημα.

Η κατανομή και ο χαρακτηρισμός της κυκλοφορίας μπορούν επίσης, να χρησιμοποιηθούν για την αύξηση της απόκρισης και την απόδοσης ταξινόμησης, επιτρέποντας την παρακολούθηση και την ταξινόμηση βάσει της γνώσης. Η γνώση των σχεδίων των σκαφών μπορεί να χρησιμοποιηθεί πρώτον για τη σύνδεση των ιχνών που προέρχονται από τον ίδιο στόχο και που διασπάται από κενά στην κάλυψη ή στη μειωμένη παρατηρητικότητα και δεύτερον, την παροχή εκ των προτέρων γνώσης σχετικά με τον τύπο του σκάφους για λόγους ταξινόμησης.

Σε τομείς όπως η άμυνα, η αεροπορία, η αυτοκινητοβιομηχανία και η παραγωγή πυρηνικής ενέργειας, η εστίαση της συντήρησης έχει μετατοπιστεί από αντιδραστική και προληπτική προς την πρόβλεψη. Ωστόσο, στον τομέα της ναυτιλίας, οι προηγμένες μέθοδοι παρακολούθησης δεν έχουν ακόμη εφαρμοστεί ευρέως. Παρ' όλα αυτά, τα τελευταία χρόνια έχουν καταβληθεί προσπάθειες για προληπτική συντήρηση στη ναυτιλιακή βιομηχανία. Παραδείγματος χάριν, έχει προταθεί μια μεθοδολογία, όπου τα δεδομένα δόνησης συνδυάζονται με δεδομένα επιδόσεων (πιέσεις κυλίνδρων) για την παρακολούθηση κατάστασης της κύριας μηχανής. Συνεπώς, το θερμοδυναμικό μοντέλο κύριων και βοηθητικών κινητήρων έχει αναπτυχθεί και χρησιμοποιηθεί για την εκτέλεση παρακολούθησης της κατάστασης. Επιπλέον, η Hountalas ανέπτυξε ένα μοντέλο απόδοσης πετρελαιοκινητήρων, το οποίο μπορεί να καλύψει τόσο τις κανονικές όσο και τις ελαττωματικές συνθήκες. Εξάλλου, έχει αναπτυχθεί ένας αλγόριθμος αυτο-μάθησης για τη διάγνωση σφαλμάτων στο σύστημα καύσης ενός θαλάσσιου πετρελαιοκινητήρα. Οι Dikis and Lazakis παρουσιάζουν το πλαίσιο των έργων Επιθεώρησης Δυνατοτήτων για την Ενισχυμένη Ασφάλεια Πλοίων (INCASS), το οποίο ανέπτυξε εργαλεία για την ενίσχυση της παρακολούθησης των μηχανημάτων, συνδυάζοντας πληροφορίες σε πραγματικό χρόνο με εργαλεία ανάλυσης κινδύνου μηχανών. Σε αυτό το πεδίο εφαρμογής, αναπτύχθηκε ένα εργαλείο ανάλυσης κινδύνου μηχανών που εκτελεί υποστήριξη για την παρακολούθηση της κατάστασης και τη συντήρηση των αποφάσεων. Ο Dikis επεξεργάστηκε περαιτέρω αυτό το εργαλείο, εξετάζοντας και αξιολογώντας τον κίνδυνο αποτυχίας και υποβάθμισης της αξιοπιστίας των εξαρτημάτων χρησιμοποιώντας τα δεδομένα πρώτης εισόδου. Περαιτέρω, οι Gkerekos δημιούργησαν ένα μοντέλο αυτοεκπαίδευσης για την παρακολούθηση της κατάστασης των μηχανών του πλοίου με βάση τις μετρήσεις των κραδασμών και τα ακατέργαστα φυσικά δεδομένα. Οι Coraddu and Cipollini προτείνουν μια μέθοδο παλινδρόμησης για την εκτίμηση της υποβάθμισης συνιστωσών σε έναν τύπο μονάδας πρόωσης θαλάσσιου συνδυασμένου ντίζελ, ηλεκτρικής και αερίου (CODLAG) στην ύπαρξη πληροφοριών υποβάθμισης στο σύνολο δεδομένων κατάρτισης μοντέλων. Σε αυτές τις μελέτες χρησιμοποιήθηκαν προσομοιωμένα δεδομένα, επομένως υπήρχαν ρητά διαθέσιμες πληροφορίες κατάστασης φθοράς. Ο Cipollini, στη συνέχεια, χρησιμοποίησε το ίδιο σύνολο δεδομένων για να συγκρίνει αλγόριθμους επίβλεψης και επιτήρησης για ανίχνευση βλαβών. Οι Raptodimos και Lazakis διερεύνησαν την εφαρμογή αυτο-οργανωτικών χαρτών, ενός μη επιτηρούμενου νευρικού δικτύου, για την παρακολούθηση της κατάστασης ενός δίχρονου

θαλάσσιου κινητήρα ντίζελ, προσδιορίζοντας ομάδες που περιέχουν δεδομένα που αντιπροσωπεύουν μη φυσιολογικές συνθήκες λειτουργίας του κινητήρα. Η παρακολούθηση της απόδοσης των μηχανημάτων είναι ένας τομέας που απαιτεί την ανάπτυξη ενός κατάλληλου μοντέλου. Αυτό το μοντέλο μπορεί είτε να χρησιμοποιήσει μια ανάλυση πρώτων αρχών (δηλαδή το μοντέλο white-box), είτε να χρησιμοποιήσει μια προσέγγιση πιο «βίαιης δύναμης» αναπτύσσοντας ένα μοντέλο που χρησιμοποιεί αλγορίθμους αυτοδιδασκαλίας σε συνδυασμό με ένα αποκτημένο σύνολο δεδομένων (δηλ. Μοντέλο μαύρου κουτιού). Συχνά, εφαρμόζεται ένας συνδυασμός και των δύο τεχνικών, οδηγώντας σε μοντέλα γκριζού κουτιού. Ο Yang ανέπτυξε ένα πλαίσιο για την ανάλυση των δεδομένων που αποκτήθηκαν μέσω των μετρήσεων διαύλου του εποπτικού ελέγχου και της λήψης δεδομένων (SCADA) των αιολικών στροβίλων για την παρακολούθηση της κατάστασης με βάση τις συσχετίσεις μεταξύ των μετρήσεων. Ο Kowalski πρότεινε μια μεθοδολογία με γνώμονα τα δεδομένα που μαθαίνει από ένα σύνολο δεδομένων που περιέχει 14 ελαττωματικές συνθήκες, επιπλέον της κανονικής συμπεριφοράς και είναι στη συνέχεια σε θέση να διακρίνει μεταξύ τους σε νέα σημεία δεδομένων. Οι Widido και Yang παρουσίασαν μια επισκόπηση των τεχνικών του μηχανισμού υποστήριξης του φορέα (SVM) για τη διάγνωση και την παρακολούθηση σφαλμάτων σε εφαρμογές μηχανικής. Οι Yin και Hou βασίστηκαν σε αυτήν την ανασκόπηση, παρέχοντας μια ενημερωμένη επισκόπηση των εφαρμογών SVM για τη διάγνωση σφαλμάτων και την παρακολούθηση της διαδικασίας.

Κεφάλαιο 4^ο

Υλοποίηση Συστήματος

4.1. Problem Setup

Όπως αναφέρθηκε, η δυσλειτουργία που εξετάζεται αφορά τη διάβρωση του Crosshead Bearing στον κύριο κινητήρα ενός σκάφους εξαιτίας του slow steaming. Οι μηχανικοί πιστεύουν ότι η εμφάνιση της διάβρωσης μπορεί να διαρκέσει περισσότερο από ένα μήνα για να καταστήσει τη δυσλειτουργία του Crosshead Bearing αξιοσημείωτη. Θεωρώντας ότι διαθέτουμε ένα σύνολο δεδομένων, συμπεριλαμβανομένων των κύριων ροών δεδομένων αισθητήρων 10 δεξαμενών του ίδιου ή αδελφικού τύπου πλοίων για περίπου 5 έτη έκαστο, αλλά μόνο 30 διαφορετικές ημέρες ελαττωμάτων, αποφασίσαμε να αντιμετωπίσουμε αυτήν την πρόκληση ως Anomaly Detection, λόγω του μικρού αριθμού καταγεγραμμένων ελαττωμάτων του εξεταζόμενου τύπου.

Σε γενικές γραμμές, εφαρμόσαμε τεχνικές Ανίχνευσης Ανωμαλιών σε πραγματικές μεταβλητές δεδομένων χρονοσειρών πολλών μεταβλητών, οι οποίες, επίσης ισχύουν για δεδομένα αισθητήρων, όπως αυτά των εξεταζόμενων караβιών. Η έλλειψη χαρακτηρισμένων χρονικών σημείων ως ανωμαλίες μας οδήγησε σε εφαρμογή μη εποπτευόμενων ή ημι-εποπτευόμενων προσεγγίσεων. Συνεπώς, στο πλαίσιο μας, η πρόκληση του εντοπισμού πιθανών ανωμαλιών στην απόδοση του κύριου κινητήρα ενός πλοίου μπορεί να μοντελοποιηθεί ως πρόβλημα δημιουργίας ενός μοντέλου που περιγράφει την κανονική συμπεριφορά της κύριας μηχανής και τη σύγκρισή του με μια οποιαδήποτε παρατηρούμενη κατάσταση. Τα δεδομένα στα οποία εργαζόμαστε, όπως ήδη αναφέρθηκε, είναι δεδομένα χρονοσειρών. Η ανίχνευση της ανώμαλης συμπεριφοράς στα δεδομένα της χρονοσειράς αποτελείται από τρία στάδια, κάθε ένα από τα οποία βασίζεται στον προκάτοχό του:

Στο πρώτο στάδιο είναι ένας αλγόριθμος για την πρόβλεψη των τιμών μιας χρονικής σειράς κάποιων βημάτων μπροστά.

Στο δευτερο στάδιο είναι το μέτρο απόκλισης μεταξύ των προβλεπόμενων τιμών και των παρατηρούμενων τιμών.

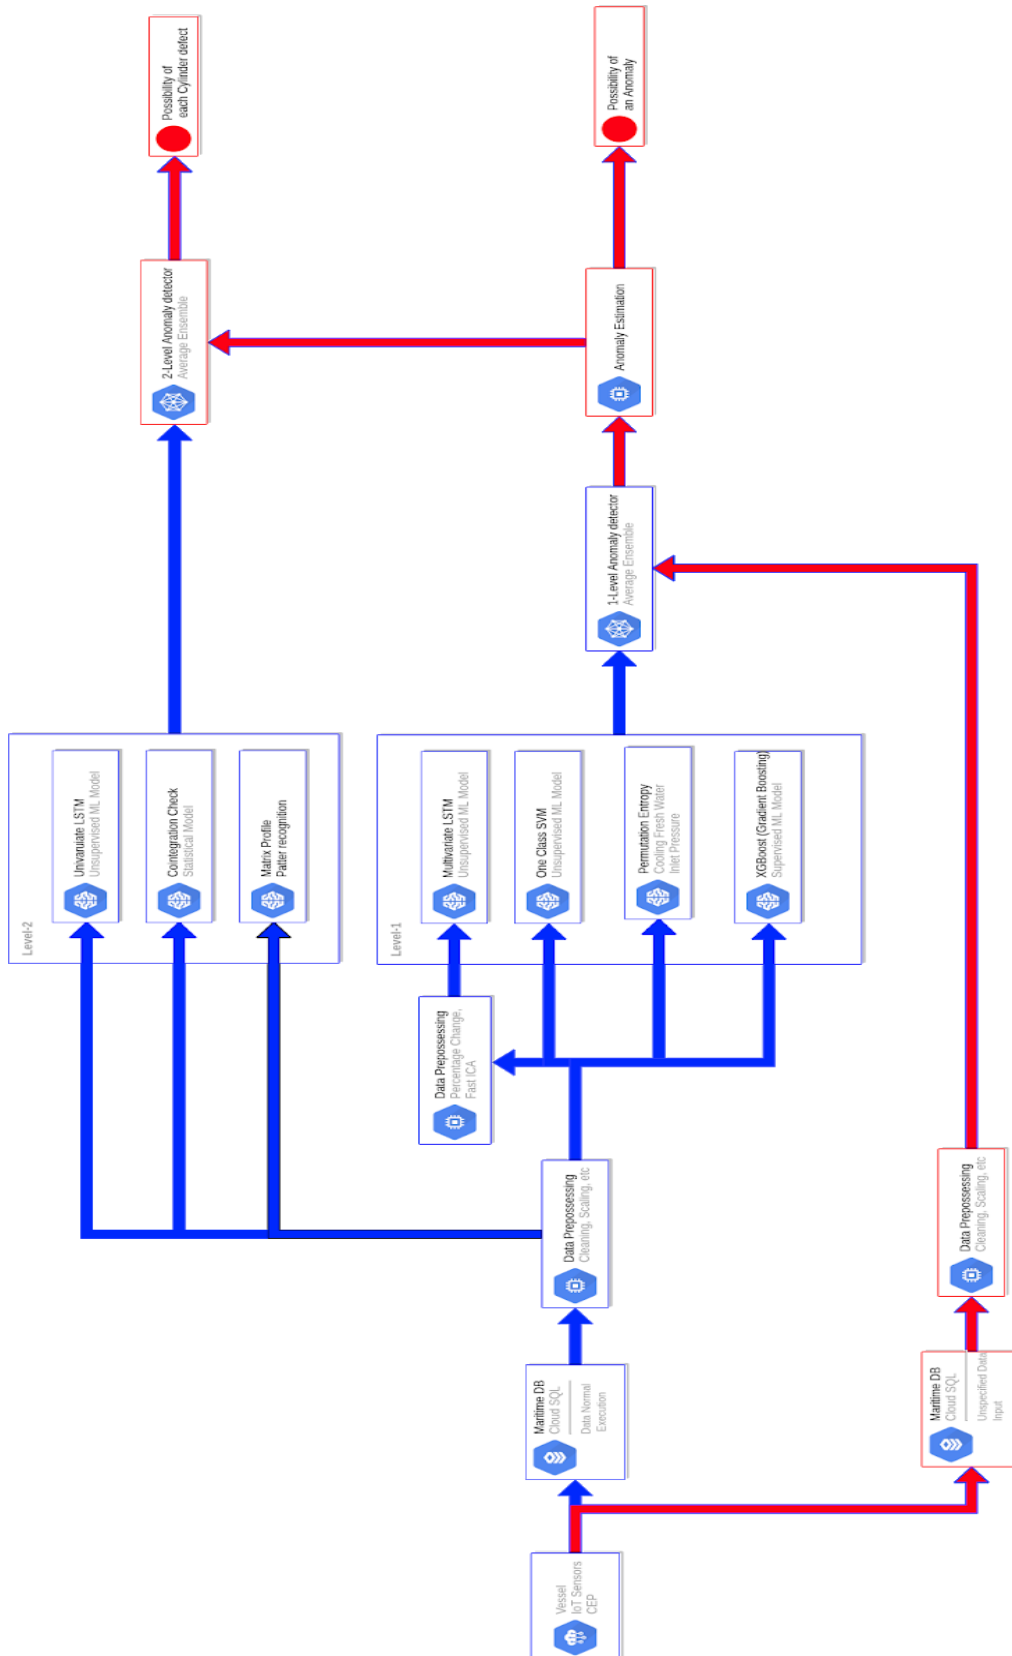
Τέλος, στο τρίτο στάδιο είναι ο μηχανισμός για να αποφασιστεί εάν και πότε μια παρατηρούμενη τιμή ή ακολουθία παρατηρημένων τιμών είναι «υπερβολικά αποκλίνουσα» από την προβλεπόμενη τιμή.

Τα δεδομένα προερχόμενα από πραγματικές πηγές είναι συχνά θορυβώδη, πολλών διαστάσεων, τα περισσότερα από τα οποία μπορεί να περιέχουν παραποιήσεις στις τιμές ή ακόμα και καθόλου τιμές, οπότε έπρεπε να φροντίσουμε στην κατάλληλη προεπεξεργασία των δεδομένων. Λαμβάνοντας υπόψη το σενάριο μας, η διαπίστωση της ύπαρξης ενός πιθανού προβλήματος στη κύρια μηχανή του πλοίου μπορεί να είναι πιο δύσκολη καθώς μελετάμε μόνο έναν τύπον ελαττώματος, οπότε πρέπει να διακρίνουμε τη αιτία της προβλεπόμενης ανωμαλίας.

Όσον αφορά τη στρατηγική αξιολόγησης που ακολουθήσαμε, πρέπει να αναφέρουμε ότι είναι αρκετά δύσκολο να αξιολογήσουμε τα αποτελέσματα των μοντέλων μας, καθώς είναι άγνωστο με ποιο τρόπο το εξεταζόμενο ελάττωμα εξελίσσεται με το χρόνο. Γι' αυτό προτείνουμε ένα κατάλληλο στατικό παράθυρο στο οποίο υποθέτουμε ότι το ελάττωμα εξελίσσεται. Επιπλέον, πρόκειται να αξιολογήσουμε ως True Positive εάν η πρόβλεψή μας πέφτει σε αυτό το στατικό παράθυρο πριν από την κάθε πραγματική ημερομηνία ελαττώματος. Ειδικά η αξιολόγηση κάθε μοντέλου θα λαμβάνει υπόψιν τις τιμές precision και recall που βασίζονται στο προαναφερθέν σύστημα σήμανσης στατικών παραθύρων.

4.2. Δομή – Αρχιτεκτονική Συστήματος

Η μεθοδολογία που αναπτύσσεται σε αυτό το έγγραφο περιλαμβάνει την περιγραφή μιας κατάλληλης τεχνικής προεπεξεργασίας για το δεδομένο σύνολο δεδομένων και την ανάπτυξη ενός αυτοεκπαιδευόμενου μοντέλου που μπορεί να εκτιμήσει εάν ένα συγκεκριμένο χρονικό σημείο δεδομένων αντιστοιχεί σε φυσιολογική (ονομαστική) συμπεριφορά ή σε περίπτωση μη φυσιολογικής συμπεριφοράς. Επιπλέον, έχει αναπτυχθεί ένα άλλο μοντέλο προκειμένου να εκτιμηθεί η πιθανότητα του εξεταζόμενου ελαττώματος να σχετίζεται με το Crosshead Bearing. Ένα διάγραμμα ροής της προτεινόμενης μεθοδολογίας παρουσιάζεται στο σχήμα 15.



Σχήμα 15: Ροή διαδικασιών

Πιο συγκεκριμένα στο σχέδιο του σχήματος 15, φαίνεται η ροή των διαδικασιών τόσο για την υλοποίηση της εκπαίδευσης των μελετώμενων μοντέλων (μπλε γραμμές) όσο και για την εκτέλεση της διαδικασίας αναγνώρισης ανωμαλιών (κόκκινη γραμμή). Τα δύο μοντέλα '1-Level Anomaly Detector' και '2-Level Anomaly Detector' είναι ουσιαστικά η γνώση που αποκτά το σύστημα μας μετά την «εκπαίδευση», το αποτέλεσμα με το οποίο μπορούμε να παράγουμε προβλέψεις σε συνδυασμό με τα «άγνωστα» δεδομένα. Προφανώς, τα ενδιάμεσα στάδια περιλαμβάνουν διεργασίες προ-επεξεργασίας δεδομένων, όπως, feature Selection, Feature scaling, Training καθώς και την αποθήκευση κάποιων δεδομένων με σκοπό τη χρήση τους σε μεταγενέστερες διεργασίες κ.α.

Τα βήματα που ακολουθήσαμε για την υλοποίηση των προβλέψεών μας περιλαμβάνουν όλη τη διαδικασία από την εξαγωγή των τιμών των αισθητήρων με χρονική περίοδο μίας ώρας, την επεξεργασία αυτών, αποσκοπώντας στην εκπαίδευση με αυτές των διάφορων μοντέλων. Αναφερόμενοι στον '1-Level Anomaly Detector,' στόχος μας είναι να αξιοποιήσουμε το Machine Learning και τις Στατιστικές προσεγγίσεις για να ταξινομήσουμε τις ανωμαλίες στα περιοδικά, αλλά θορυβώδη δεδομένα μας. Δεδομένου ότι δεν διαθέτουμε ένα μεγάλο αριθμό χαρακτηρισμένων παραδειγμάτων για την άμεση εφαρμογή εποπτευόμενης μάθησης για ταξινόμηση ανωμαλιών, προσεγγίσαμε το πρόβλημα σε δύο μέρη.

Αρχικά, εκπαιδεύσαμε τα διάφορα μοντέλα μας, όπως, το LSTM, το OneClassSVM XGB και τον Έλεγχο της Εντροπίας Permutation με σκοπό να προβλέψουμε την αναμενόμενη τιμή στις επόμενες χρονικές στιγμές. Η εκπαίδευση έλαβε υπόψιν τη ροή δεδομένων που χαρακτηρίστηκαν ως κανονική λειτουργία. Δεύτερον, εφαρμόσαμε διάφορους κανόνες ανίχνευσης ανωμαλιών που συγκρίνουν τις πραγματικές τιμές με τις προβλεπόμενες τιμές.

Στη συνέχεια, όσον αφορά το δεύτερο επίπεδο του ανιχνευτή θα λαμβάνει ως είσοδο την ένδειξη που δίνεται από το πρώτο επίπεδο και θα πρέπει να υποδηλώνει την πιθανότητα ότι το ελάττωμα βρίσκεται σε έναν συγκεκριμένο κύλινδρο της κύριας μηχανής. Σε αυτή την έρευνα, δοκιμάσαμε μοντέλα, όπως, LSTM με ένα κανάλι, One Class SVM και Cointegration Check για ανίχνευση ανωμαλιών και Matrix Profile για αναγνώριση προτύπων. Και για τις δύο προσεγγίσεις τα δεδομένα που χρησιμοποιήθηκαν προέρχονταν αποκλειστικά από τους αισθητήρες που είναι τοποθετημένοι σε κάθε κύλινδρο.

4.3. Δεδομένα

Όπως αναφέραμε στο Κεφάλαιο 2.2 το σημαντικότερο στοιχείο καθοριστικής σημασίας για την απόδοση του κάθε αλγορίθμου του Machine Learning, είναι η αξιοπιστία και η κατάλληλη επεξεργασία των δεδομένων εκπαίδευσης.

4.3.1. Πηγή Δεδομένων

Αρχικά τα δεδομένα που θα χρησιμοποιηθούν σαν παραδείγματα και θα αποτελέσουν το σώμα των Δεδομένων μας το οποίο αργότερα θα καταταμηθεί σε σώμα «εκπαίδευσης» και «ελέγχου απόδοσης» στον Αλγόριθμο μας, αποτελούνται από πολλαπλές ροές δεδομένων με χρονικό πλαίσιο 1 λεπτό ή 10 λεπτά ανάλογα. Τα περισσότερα δεδομένα προέρχονταν από τους κύριους αισθητήρες της μηχανής των πλοίων και από ορισμένα γενικά δεδομένα δοχείων. Τα πιο πολύτιμα από τα ρεύματα δίνονται στην επόμενη μήτρα.

VESSEL_DATA table structure	MAIN_ENGINE_DATA table structure
Consumed power (kW),	Air Cooler Cooling Water Inlet Pressure (Pa)
Wind-speed (kn),	Cylinder #1-10 Scavenge Air Fire Detection Temperature (°C),
GPS speed (kn),	Cooling Fresh Water Inlet Pressure (Pa),
Speed through water – longitudinal (kn),	Control Air Pressure (Pa),
Speed through water – transverse (kn),	Exhaust Valve Spring Air Inlet Pressure (Pa)
rotations per minute of the main shaft,	Fuel Oil Flow Rate (lt),
Wind angle (0-359.99 degrees),	Fuel Oil Inlet Pressure (Pa),
Total Twenty-foot Equivalent Unit (TEU) (# of containers),	Fuel Oil Inlet Temperature (°C),
Total Forty-foot Equivalent Unit (FEU) (# of containers),	Jacket Cooling Fresh Water Inlet Temperature Low (°C)
Low-sulfur fuel oil consumption (metric tones),	Cylinder #1-10 Exhaust Gas Out Temperature (°C),
High-sulfur fuel oil consumption (metric tones),	Cylinder #1-10 Jacket Cooling Fresh Water Outlet Temperature (°C),
Vessel draft at port-side (left-side looking to the fore) (m),	Cylinder #1-10 Piston Cooling Outlet Temperature (°C),
Vessel draft at starboard-side (right-side looking to the fore) (m),	Turbo-Charger #1-3 Exhaust Gas Inlet Temperature (°C)
Vessel draft at stern (m),	Turbo-Charger #1-3 Exhaust Gas Outlet Temperature (°C),
Vessel draft at fore (m),	Turbo-Charger #1-3 Lube Oil Inlet Pressure (Pa),
Speed through water – calculated by stw_trans and stw_lon (kn),	Turbo-Charger #1-3 Lube Oil Outlet Pressure (Pa),
Total number of containers,	Turbo-Charger #1-3 RPMs,
Vessel draft at mid-line (m),	Scavenge Air Inlet Pressure (Pa),
The trim of the vessel, calculated by draft_aft and draft_fore,	Scavenge Air Receiver Temperature (°C),
The latitude of the vessel's position,	Starting Air Pressure (Pa),
The longitude of the vessel's position,	Thrust Pad Temperature (°C),
	Main Lube Oil Inlet Pressure (Pa),
	Main Lube Oil Inlet Temperature (°C)
	Fuel Oil Temperature (°C)
	Torque of the main shaft (N/m),

Εκτός από αυτές τις ροές δεδομένων, παραλάβαμε τις ημερομηνίες που έλαβαν χώρα ορισμένες συντηρήσεις υποδηλώνοντας την περίοδο ενός καταγεγραμμένου ελαττώματος. Το ελάττωμα ενδιαφέροντος αφορά τη διαρθρωτική αλλοίωση του Crosshead Bearing, ένα πραγματικά σπάνιο ελάττωμα. Η μορφή που αποκτήσαμε τα δεδομένα είναι “.csv”. Σε τελική μορφή τα δεδομένα εξάγονται από την βάση δεδομένων της Ναυτιλιακής Εταιρείας. Ο αριθμός των δεδομένων καλύπτει ημερήσιες ιστορικές τιμές από το 2014.

4.3.2. Προ-Επεξεργασία Δεδομένων

Τα δεδομένα που απαιτούνται για την εκπαίδευση των μοντέλων έχουν ανακτηθεί μέσω της Maritime Company DB. Τα χαρακτηριστικά συλλογής δεδομένων δεν επηρεάζουν την προτεινόμενη μεθοδολογία και οποιαδήποτε από τις διαδικασίες μπορεί να περιλαμβάνει ασυνεπή και / ή ελαττωματικά δεδομένα παραδείγματος χάριν λόγω ασυνεπειών καταγραφής, ανθρώπινου σφάλματος ή σφαλμάτων αισθητήρων.

Θα πρέπει να αναφέρουμε ότι στα περισσότερα από τα παρακάτω πειράματα έχουμε δειγματίσει τα δεδομένα σε ωριαία χρονικά διαστήματα με την επιλογή της μέσης, της μέγιστης και της ελάχιστης τιμής κάθε χρονικού πλαισίου. Αυτός είναι και ο πρώτος τρόπος για να μειώσουμε την επίδραση του θορύβου στα δεδομένα μας. Με την προτεινόμενη αναδειγματοληψία πιστεύεται επίσης, ότι όχι μόνο οι χρήσιμες πληροφορίες δεν απορρίπτονται αλλά και όλα τα προτεινόμενα μοντέλα είναι πιο αποδοτικά όσον αφορά το χρόνο και τους πόρους.

Η μεθοδολογία προεπεξεργασίας αποτελείται από τα ακόλουθα βήματα:

1) Imputation of missing values. Για διάφορους λόγους, πολλά πραγματικά σύνολα δεδομένων περιέχουν τιμές που λείπουν, συχνά κωδικοποιούνται ως κενά, NaN ή άλλα σύμβολα κράτησης θέσης. Τέτοια σύνολα δεδομένων, ωστόσο είναι ασυμβίβαστα με Αλγορίθμους Machine Learning. Μια βασική στρατηγική που χρησιμοποιούν για ελλιπή σύνολα δεδομένων είναι να απορρίψει ολόκληρες γραμμές ή / και στήλες που περιέχουν τις τιμές που λείπουν. Ωστόσο, αυτό έρχεται με το τίμημα της απώλειας δεδομένων, τα οποία μπορεί να είναι πολύτιμα (αν και ημιτελή). Μια καλύτερη στρατηγική είναι να γίνει εκτίμηση

των ελλειπουσών τιμών, δηλαδή, να τους συναγάγει από το γνωστό μέρος των δεδομένων. Μία στρατηγική κάλυψης τέτοιων σημείων είναι είτε χρησιμοποιώντας τη μέση τιμή, το μέσο όρο ή την πιο συχνή τιμή της γραμμής ή της στήλης στην οποία βρίσκονται οι τιμές που λείπουν. Εμείς λάβαμε υπόψιν ότι τα δεδομένα μας είναι χρονοσειρές και συμπληρώσαμε τα κενά με την τελευταία γνωστή τιμή της μεταβλητής ('fill forward').

2) Οι μετρημένες παράμετροι απόδοσης διορθώνονται στις συνθήκες περιβάλλοντος ISO (MAN B & W Diesel A / S 2004).

3) Επίσης, στα περισσότερα ρεύματα βρήκαμε μερικές ακραίες τιμές που μπορεί να αντιστοιχούν στο ελάττωμα κάθε αισθητήρα κάποιου άλλου μετασχηματισμού κατά τη διάρκεια της διαδικασίας αποθήκευσης. Αν και τα διανύσματα χαρακτηριστικών σαρώνονται για στοιχεία με τιμές πέραν των 3 ή 4 stds, τότε αυτά τα διανύσματα αποσυνδέονται. Υποθέτοντας μια κανονική κατανομή, το 99,7% των κανονικών δεδομένων θα πρέπει να βρίσκεται μέσα σε $m + 3s$. Επομένως, αυτή η διατύπωση φιλτράρει τα πιο ανώμαλα σημεία δεδομένων από το σύνολο δεδομένων, χωρίς να επηρεάζει τη συντριπτική πλειονότητα των κανονικών σημείων. (σχήμα 16)

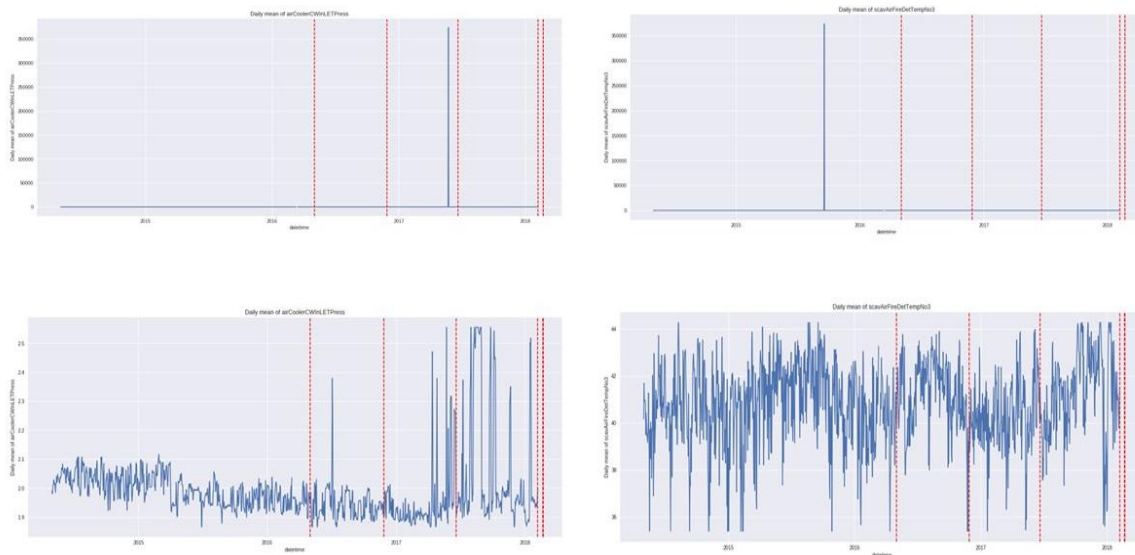
4) Για να εξομαλύνουμε λίγο περισσότερο τις χρονολογικές σειρές, χρησιμοποιήσαμε ένα κυλιόμενο μέσο.

5) Σε ορισμένα μοντέλα αντί για χρήση κάθε διανύσματος, χρησιμοποιήσαμε την ποσοστιαία αλλαγή με το βήμα του 1 timedelta .

6) Εφαρμόσαμε επίσης, λειτουργίες κλιμάκωσης και κανονικοποίησης και σε ορισμένες περιπτώσεις χρησιμοποιήσαμε PCA ή ICA για να δημιουργήσουμε νέα χαρακτηριστικά.

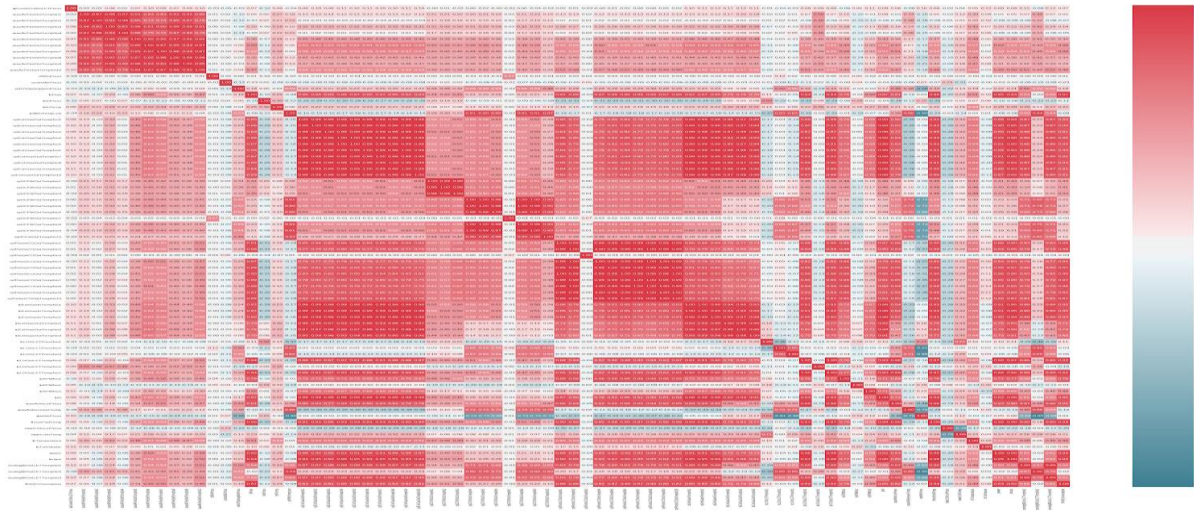
7) Ο τρόπος με τον οποίο χωρίζουμε το σύνολο δεδομένων μας σε σύνολα εκπαίδευσης, επικύρωσης και δοκιμών εξαρτάται από τις απαιτήσεις κάθε μεθόδου που χρησιμοποιείται.

8) Σε πολλά μοντέλα, όπως, τα LSTM και το SVM, το επόμενο βήμα για την υλοποίηση του αλγόριθμου είναι, όπως προαναφέραμε σε ανωτέρω παράγραφο, η κλιμάκωση των δεδομένων. Σε αυτή τη περίπτωση θα πραγματοποιήσουμε κλιμάκωση Standarization. Επαναλαμβάνουμε ότι το προκύπτον σώμα δεδομένων δημιουργείται αφαιρώντας την mean value και εν συνεχεία διαιρώντας με τη διακύμανση.



Σχήμα 16

Ένα άλλο ενδιαφέρον στοιχείο των δεδομένων μας είναι ότι τα περισσότερα από τα δεδομένα μας είναι πολύ συσχετισμένα μεταξύ τους. Το σχήμα 17 είναι το Matrix of Pearson Correlation για όλα τα δεδομένα. Είναι ευνόητο ότι οι ίδιες παράμετροι σε διαφορετικούς κυλίνδρους του κύριου κινητήρα ή στους διάφορους υπερσυμπιεστές είναι τα χαρακτηριστικά που είναι πολύ συσχετισμένα. Έτσι, σε ορισμένα μοντέλα ανίχνευσης ανωμαλιών πρώτου επιπέδου είτε δεν χρησιμοποιήσαμε αυτά τα χαρακτηριστικά είτε χρησιμοποιήσαμε τη μέση τιμή τους.



Σχήμα 17: Matrix of Pearson Correlation

Τέλος, πρέπει να αναφερθεί ότι έχουμε ελέγξει την ακινησία των δεδομένων χρησιμοποιώντας τη δοκιμασία Augmented Dickey-Fuller και όλα αποδείχτηκαν στάσιμα. Αυτό το τμήμα ήταν κρίσιμο για την εφαρμογή οποιασδήποτε μεθόδου πρόβλεψης βάσει ιστορικών δεδομένων.


4.3.3. Feature importance

Έχοντας τελειώσει με την προ-επεξεργασία των δεδομένων μας, έχει προκύψει ένα νέο data set το οποίο εκπροσωπεί τα ίδια χαρακτηριστικά με το αρχικό μόνο που οι τιμές τους είναι κατάλληλα τροποποιημένες. Επόμενο στάδιο είναι η επιλογή χαρακτηριστικών, επίσης γνωστή ως επιλογή χαρακτηριστικού υποσυνόλου (FSS), ή επιλογή χαρακτηριστικού (Χαρακτηριστικό Επιλογής). Αποτελεί μια διαδικασία-μέθοδο για την επιλογή ενός υποσυνόλου από το σύνολο των χαρακτηριστικών της εισόδου, για να κάνει το μοντέλο πιο αποτελεσματικό. Ο όρος «αποτελεσματικό» ερμηνεύεται ως εξής: κατά την πρακτική εφαρμογή Αλγορίθμων Machine Learning, η ποσότητα των χαρακτηριστικών είναι συνήθως πολύ μεγάλη, στα οποία μπορεί να υπάρχουν χαρακτηριστικά που δεν παρέχουν πληροφορία ή τα χαρακτηριστικά μπορεί να έχουν εξάρτηση μεταξύ τους. Η διαδικασία αυτή μπορεί να μειώσει τον αριθμός των χαρακτηριστικών βελτιώνοντας τόσο την ακρίβεια όσο και την ταχύτητα του μοντέλου. Μία δημοφιλής μέθοδος επιλογής είναι η συσχέτιση του

εκάστοτε χαρακτηριστικού με την έξοδο του μοντέλου. Εμείς επιλέξαμε να εξετάσουμε την επίδραση που έχει το κάθε ένα ως προς το ζητούμενο αποτέλεσμα, το πόσο σημαντικό είναι. Για να το εξετάσουμε αυτό, δημιουργήσαμε μια προσαρμοσμένη ετικέτα στα δεδομένα μας με βάση τις ημερομηνίες των ελαττωμάτων. Έτσι, αποφασίσαμε ένα στατικό χρονικό παράθυρο 30 ημερών πριν από τη δεδομένη ημερομηνία βλάβης, ορίζοντας την ετικέτα '1' ή 'True' σε αυτές και το '0' διαφορετικά. Ο συλλογισμός αυτής της προσέγγισης είναι ότι υπάρχει μεγάλη πιθανότητα ένα σκάφος να συνεχίσει το ταξίδι του με ένα ελαφρώς διαβρωμένο Crosshead Bearing για περισσότερο από 30 ημέρες.

Χρησιμοποιήσαμε ένα μοντέλο Boost Gradient (Xgboost) για να εξαγάγουμε τη γραφική παράσταση που παρουσιάζεται στη Εικόνα 1. Εκπαιδεύσαμε το μοντέλο xgboost στα δεδομένα ενός συγκεκριμένου σκάφους. Τα δεδομένα δεν ήταν ισορροπημένα, έτσι χρησιμοποιήσαμε την παράμετρο «scale_pos_weight» του δοκιμαζόμενου μοντέλου για να το αντιμετωπίσουμε.

Από το δεδομένο διάγραμμα είναι ξεκάθαρο ότι τα χαρακτηριστικά με τη μεγαλύτερη επίδραση στην κύρια κατάσταση του κινητήρα είναι η πίεση αέρα ελέγχου, η πίεση εισόδου αέρα ελατηρίου καυσαερίων (Pa), η παροχή ροής καυσίμου (lt), η πίεση εισόδου καυσίμου λαδιού (Pa) , Θερμοκρασία εισόδου καυσίμου (° C) και πίεση εκκίνησης αέρα (Pa). Το πιο σημαντικό είναι ότι χαρακτηριστικά όπως ο συνολικός αριθμός των εμπορευματοκιβωτίων, η διαμόρφωση του σκάφους, υπολογιζόμενη με σχέδιο και ύψος ρυμούλκησης, σχέδιο βυθίσματος στο μπροστινό μέρος (m), βύθισμα σκαφών στην πρύμνη (m), συνολική ισοδύναμη μονάδα είκοσι ποδιών (TEU) (# εμπορευματοκιβωτίων), η συνολική ισοδύναμη μονάδα των τεσσάρων ποδιών (FEU) (αριθμός εμπορευματοκιβωτίων) κ.λπ. δεν έχει σημαντική προγνωστική δυνατότητα, οπότε δεν θα τα χρησιμοποιούσαμε στα πρότυπα πρόβλεψης.



Εικόνα 1: Αποτελέσματα μετά τη χρήση μοντέλου Boost Gradient (Xgboost)

4.4. Επιλογή κατάλληλου Αλγορίθμου – Υλοποίηση

4.4.1. Level Anomaly Detector

Χρησιμοποιήσαμε τόσο εποπτευόμενα (XGBoost) όσο και μη επιτηρούμενα μοντέλα (LSTM, One Class SVM), συνοδευόμενα από έλεγχο κυλιόμενης τιμής Permutation Entropy. Δεδομένου ότι δεν ήταν γνωστό εάν το πρόβλημα απαιτεί εύρεση παρατεταμένων ανωμαλιών ή απλώς σύντομων καθυστερήσεων ή στιγμιαίας αδράνειας στα δεδομένα, οι μέθοδοι ανίχνευσής μας επικεντρώθηκαν τόσο σε συνεχή τμήματα δραστηριότητας όσο και σε μεμονωμένα σημεία. Δοκιμάσαμε πολλούς συνδυασμούς των μοντέλων και των κανόνων μας και διαπιστώσαμε ότι η χρήση της διασταύρωσης των μεθόδων ανίχνευσης ανωμαλίας μας αποδείχθηκε μια αποτελεσματική μέθοδος ανίχνευσης ανωμαλιών των Crosshead Bearing.


4.4.2. Gradient Boosting Classification Approach

Τα δέντρα ταξινόμησης και παλινδρόμησης είναι μία από τις πιο εύρωστες και αποτελεσματικές τεχνικές εκμάθησης μηχανών. Μπορεί επίσης να εφαρμοστεί σε προβλήματα ανίχνευσης ανωμαλιών με διάφορους τρόπους. Κατ' αρχάς, κάποιος μπορεί να χρησιμοποιήσει εποπτευόμενη μάθηση για να εκπαιδεύσει δέντρα για να ταξινομήσει σημεία ανωμαλίας και μη ανωμαλίας. Προκειμένου να γίνει αυτό, είναι απαραίτητο να υπάρχουν σήματα σημείων δεδομένων ανωμαλίας. Η σημασία αυτής της προσέγγισης είναι ότι δεν συνδέεται με την έννοια της δομής του σήματος εισόδου και μπορούν να εισαχθούν πολλές παράμετροι χαρακτηριστικών για την εκτέλεση της μαθησιακής διαδικασίας και την παραγωγή περίπλοκων μοντέλων.

Στη συνέχεια, αποκτάμε τις προβλέψεις σε άλλα σκάφη, τα οποία ήταν άγνωστα για το μοντέλο μας. Το σχήμα 18 δείχνει την προβλεπόμενη πιθανότητα κάθε σφραγίδα του σκάφους να έχει αυτό το είδος δυσλειτουργίας, χρησιμοποιώντας το ίδιο μοντέλο xgboost που είχαμε εκπαιδεύσει νωρίτερα.

Οι μπλε κορυφές είναι οι χρονικές περιόδους που υποθέτουμε ότι το σκάφος είχε πρόβλημα σύμφωνα με την παραπάνω συλλογιστική της περιόδου των 30 ημερών πριν από την παρατήρηση του ελαττώματος. Η κόκκινη γραμμή είναι η προβλεπόμενη πιθανότητα κάθε σφραγίδας.

Είναι περισσότερο από προφανές ότι το μοντέλο δεν προβλέπει μόνο πολλά "ψεύτικα θετικά", αλλά έχει και πολλά "ψεύτικα αρνητικά". Δεδομένου ότι είχαμε ένα μικρό αριθμό επισημάνσεων ανωμαλιών, αναμένεται να μην αντιδράσει σωστά σε δεδομένα που δεν έχουν δει. Το γεγονός ότι αυτό το μοντέλο μπορεί να δώσει μια εικόνα μπορεί να είναι χρήσιμο σε ένα σύνολο με διαφορετικές μεθόδους.



Σχήμα 18: Προβλεπόμενη πιθανότητα κάθε σφραγίδα του σκάφους να έχει το είδος δυσλειτουργίας που εξετάζουμε

Παρακάτω αναφέρονται οι πίνακες αποτελεσμάτων. Σημειώνεται ότι θεωρητικά με την εμφάνιση μιας ανωμαλίας εντός του προγεγραμμένου χρόνου μπορεί να θεωρηθεί ως επιτυχείς πρόβλεψη, αποφασίσαμε να χρησιμοποιήσουμε μια πιο απλή τακτική θεωρώντας την ως πιο αντικειμενική για την ανάδειξη των αδυναμιών κάθε μοντέλου.

Confusion Matrix		
	Predicted Negative	Predicted Positive
Actually Negative	31712	382
Actually Positive	2996	248

Πίνακας 1

	precision	recall	f1-score	support
0	0.91	0.99	0.95	32094
1	0.39	0.08	0.13	3244

Πίνακας 2

Παρατηρούμε το μεγάλο αριθμό των μη σωστών κατηγοριοποιημένων ανωμαλιών. Αυτό αρχικά είναι αναμενόμενο λόγω της δυσκολίας και του θορύβου που περιέχουν τα δεδομένα μας. Ενδιαφέρον βέβαια παρουσιάζει διαισθητικά το διάγραμμα, καθώς είναι εμφανές ότι το μοντέλο προβλέπει αρκετά 'προβληματικά' σημεία στις σωστές περιοχές πριν από κάθε βλάβη. Εκτιμάται ότι με την χρήση μεγαλύτερου αριθμού δεδομένων η απόδοση του μοντέλου θα βελτιωθεί σημαντικά καθώς θα αποκτήσει γνώση για περισσότερες προβληματικές καταστάσεις.

4.4.3. LSTM

Μια από τις πιο ελπιδοφόρες προσεγγίσεις ανίχνευσης ανωμαλιών που αφορούν δεδομένα χρονοσειράς, είναι τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNNs), ειδικά η Long-Short Temporal Memory (LSTM) είναι ο ιδανικός υποψήφιος για την ανίχνευση ανωμαλιών που περιλαμβάνουν μη γραμμικές αριθμητικές ροές χρονοσειράς των δεδομένων. Ο επικρατέστερος τρόπος με τον οποίο χρησιμοποιούνται σε εργασίες ανίχνευσης ανωμαλιών είναι αρκετά απλός. Ένα μοντέλο LSTM εκπαιδεύεται σε δεδομένα που θεωρούνται κανονική λειτουργία, δηλαδή χωρίς βλάβες, έτσι ώστε τα LSTMs να καταγράφουν και να


μοντελοποιούν την κανονική συμπεριφορά ενός συστήματος, παρέχοντας ένα μοντέλο συμπεριφοράς του συστήματος υπό κανονικές συνθήκες. Τότε είναι προφανές ότι το εκπαιδευμένο μοντέλο προβλέπει την επόμενη τιμή και το σφάλμα μεταξύ της προβλεπόμενης τιμής σχετικά με την πραγματική τιμή και έτσι, υποδεικνύει μια πιθανή ανωμαλία.

Είναι προφανές ότι αναφερόμαστε σε μια μη επιτηρούμενη μέθοδο καταγραφής ανωμαλιών, καθώς δεν υπάρχει ανάγκη για ύπαρξη επισημασμένων ανωμαλιών. Επίσης, πρέπει να αναφερθεί ότι αυτή η προσέγγιση είναι κατάλληλη για την αναγνώριση των collective anomalies. Επίσης, το LSTM μπορεί να χειριστεί δεδομένα πολλαπλών χρονικών σειρών, δεδομένου ότι μπορούν να μοντελοποιήσουν πολύπλοκες μη γραμμικές αλληλεπιδράσεις χαρακτηριστικών που υπάρχουν συχνά σε τέτοιες ροές δεδομένων πολλαπλών χρονοσειρών.

Σε αυτό το επίπεδο κατασκευάσαμε ένα μοντέλο βασισμένο σε LSTM που έχει ως είσοδο τη ροή δεδομένων από πολλαπλές ροές δεδομένων και ως έξοδο την τιμή του επόμενου χρονομέτρου (πρόβλεψη ενός βήματος). Δοκιμάσαμε διάφορα χρονικά παράθυρα και σε διαφορετικά χρονικά πλαίσια. Χρησιμοποιήσαμε τα δεδομένα των πλοίων τα οποία δεν εμφάνισαν κανένα ελάττωμα της διασταυρούμενης κεφαλής, ως κανονικά δεδομένα. Εκπαιδεύσαμε το μοντέλο μας σε αυτά τα δεδομένα και στη συνέχεια χρησιμοποιώντας τα δεδομένα πλοίων που η Crosshead Bearing είχε εμφανίσει βλάβη, σαν δοκιμαστικό σετ δεδομένων, συγκρίνουμε την προβλεπόμενη έξοδο σε σχέση με την πραγματική δεδομένη έξοδο κάθε αισθητήρα.


Μόλις δημιουργηθεί μια προβλεπόμενη τιμή $\hat{y}(t)$ για κάθε βήμα t , το σφάλμα πρόβλεψης υπολογίζεται ως το μέσο απόλυτο σφάλμα μεταξύ αυτών και των πραγματικών τιμών. Στη συνέχεια, το σύνολο των σφαλμάτων εξομαλύνεται για να μειώνει τις αιχμές σε σφάλματα που συμβαίνουν συχνά με τις προβλέψεις βασισμένες σε LSTM, καθώς οι απότομες αλλαγές στις τιμές συχνά δεν προβλέπουν σωστά και οδηγούν σε τιμές σφάλματος ακόμα και όταν αυτή η συμπεριφορά είναι φυσιολογική. Για να αξιολογήσουμε εάν οι τιμές είναι φυσιολογικές, ορίζουμε ένα κατώφλι για τα εξομαλυμένα σφάλματα πρόβλεψης - οι τιμές που αντιστοιχούν σε εξομαλυμένα σφάλματα πάνω από το όριο ταξινομούνται ως ανωμαλίες.

Η αρχιτεκτονική του LSTM που χρησιμοποιήσαμε αποτελείται από 5 hidden layers [200.500.700.500.200], το παράθυρο μνήμης ήταν 100 ώρες με τη συνάρτηση ενεργοποίησης \tanh και ένα σχετικά μεγάλο Dropout (0.50) μετά από κάθε layer. Χρησιμοποιήθηκε επίσης, Early Stopping για να περιοριστεί η εκπαίδευση σε μοντέλα και κανάλια που παρουσιάζουν μειώσεις στο validation error. Επίσης, λόγω της παρουσίας θορύβου στα δεδομένα, παρατηρήσαμε ότι η εκκίνηση των τυχαίων βαρών στην περίπτωση μας είχε πολύ μεγάλη επίδραση στην απόδοση, έτσι, εκπαιδεύσαμε 20 μοντέλα με διαφορετική τυχαία αρχικοποίηση και χρησιμοποιήσαμε τον μέσο όρο αυτών ως μοντέλο.



Σχήμα 19: Σφάλμα πρόβλεψης του LSTM

Στο σχήμα 19 παρουσιάζεται το σφάλμα πρόβλεψης του LSTM ενώ με τις κάθετες κόκκινες γραμμές απεικονίζονται οι μέρες επισκευής των βλαβών. Ο προτεινόμενος Detector που βασίζεται στην προσέγγιση αυτή μπορεί να είναι ένα απλό δυναμικό όριο που βασίζεται στην τυπική απόκλιση αυτού του σφάλματος. Χρησιμοποιήσαμε ένα φίλτρο 3,5 φορές το std ως το κατώφλι μας. Αυτό σημαίνει ότι πρέπει κάθε ώρα να προβλέπουμε τις επόμενες τιμές κάθε αισθητήρα και στη συνέχεια να υπολογίσουμε το σφάλμα μεταξύ της πρόβλεψης και της πραγματικής τιμής. Στη συνέχεια, αν αυτές οι τιμές ξεπεράσουν αυτό το όριο, το σύστημα θα ενεργοποιήσει συναγερμό.



Σχήμα 20: Αποτέλεσμα του Detector

Στο σχήμα 20 εμφανίζεται το αποτέλεσμα του Detector. Οι μπλε γραμμές είναι οι ενδείξεις ανωμαλίας του μοντέλου LSTM και οι πορτοκαλί γραμμές αντιπροσωπεύουν τις πραγματικές περιόδους ελαττωμάτων. Υποθέτοντας, όπως αναφέρθηκε προηγουμένως, το στατικό παράθυρο των 30 ημερών πριν από τη δεδομένη ημερομηνία ελαττώματος, ως ανόητη περίοδο.

Τα αποτέλεσμα είναι τα εξής:

Confusion Matrix		
	Predicted Negative	Predicted Positive
Actually Negative	22151	271
Actually Positive	3163	81

Πίνακας 3

	precision	Recall	f1-score	support
0	0.88	0.99	0.95	22422
1	0.22	0.03	0.05	3244

Πίνακας 4

4.4.4. One Class SVM


Τα SVM είναι μοντέλα μάθησης με επίβλεψη, τα οποία αναλύουν δεδομένα, αναγνωρίζουν πρότυπα και μπορούν να χρησιμοποιηθούν για εργασίες ταξινόμησης και παλινδρόμησης όπως αναφέρθηκε και παραπάνω. Τυπικά, ο αλγόριθμος SVM λαμβάνει ένα σύνολο εκπαιδευτικών παραδειγμάτων που φέρουν την ένδειξη ότι ανήκουν σε μία από τις δύο κατηγορίες. Ένα μοντέλο SVM βασίζεται στη διαίρεση των σημείων δειγματοληψίας σε ξεχωριστές κατηγορίες με όσο το δυνατό μεγαλύτερο κενό, ενώ επιβάλλονται κυρώσεις σε δείγματα κατάρτισης που βρίσκονται στη λάθος πλευρά του χάσματος. Στη συνέχεια, το μοντέλο SVM προβαίνει σε προβλέψεις αναθέτοντας σημεία σε μία πλευρά του χάσματος ή του άλλου.

Μερικές φορές η μέθοδος της υπερδειγματοληψίας χρησιμοποιείται για την αναπαραγωγή των υπαρχόντων δειγμάτων έτσι ώστε να δημιουργήσουμε ένα μοντέλο δύο τάξεων, αλλά είναι αδύνατο να προβλέψουμε όλα τα νέα πρότυπα από περιορισμένα παραδείγματα. Επιπλέον, η συλλογή ακόμη και περιορισμένων παραδειγμάτων μπορεί να είναι δαπανηρή. Επομένως, στο One Class SVM, το μοντέλο εκπαιδεύεται σε δεδομένα που έχουν μόνο μία κατηγορία, η οποία είναι η "κανονική" κατηγορία. Συγκεντρώνει τις ιδιότητες των φυσιολογικών περιπτώσεων και από αυτές τις ιδιότητες μπορεί να προβλέψει ποια παραδείγματα είναι αντίθετα με τα κανονικά παραδείγματα. Αυτό είναι χρήσιμο για την ανίχνευση ανωμαλιών, επειδή η έλλειψη των εκπαιδευτικών παραδειγμάτων είναι αυτό που ορίζει τις ανωμαλίες, δηλαδή υπάρχουν συνήθως πολύ λίγα παραδείγματα της εισβολής του δικτύου, της απάτης ή άλλης ανώμαλης συμπεριφοράς. Στο βήμα ενός μοντέλου svm, ένα υπερκείμενο που περιλαμβάνει τα αρχικά φυσιολογικά σημεία προκύπτει για να επισημάνει αναλόγως τα νέα σημεία ως φυσιολογικά ή μη φυσιολογικά. Ταυτόχρονα, η απόσταση μεταξύ του υπερπληρωμένου και κάθε νέου σημείου μπορεί να χρησιμοποιηθεί ως μέτρο κανονικότητας. Όσο πιο απομακρυσμένο σημείο είναι από το υπερπλάνο προς την κανονική πλευρά, η κανονικότητα του εξεταζόμενου συστήματος αυξάνεται και αντίστροφα. Επιπλέον, καθώς κάθε σημείο δεδομένων αξιολογείται ανεξάρτητα, εφαρμόζεται ένα φίλτρο σταθμισμένου κινητού μέσου (EWMA) για την εξομάλυνση των περιττών συστροφών και για την καλύτερη αξιολόγηση της συνολικής συμπεριφοράς.


Έτσι, εκπαιδεύσαμε δύο μοντέλα SVM σε δεδομένα από πλοία που δεν είχαν καμιά δυσλειτουργία. Το πρώτο εκπαιδεύτηκε σε τυποποιημένες ροές δεδομένων και το δεύτερο εκπαιδεύτηκε στην ωριαία ποσοστιαία μεταβολή των ροών δεδομένων. Τέλος, χρησιμοποιήσαμε το δεύτερο μοντέλο, καθώς φαίνεται πιο ισχυρό. Τα σχήματα 21 και 22 δείχνουν την υπολογισμένη απόσταση μεταξύ κάθε σημείου δεδομένων και του δεδομένου εκπαιδευμένου μοντέλου SVM. Το πρώτο διάγραμμα δείχνει την περίπτωση που χρησιμοποιήθηκαν τα χρονοδιαγράμματα που υπήρχαν, και στη δεύτερη χρησιμοποιήσαμε την ωριαία ποσοστιαία μεταβολή.

Θα πρέπει επίσης να αναφερθεί ότι χρησιμοποιούμε τις μέσες τιμές των δεδομένων που αναφέρονται σε συγκεκριμένο κύλινδρο. Αυτή η υπόθεση όχι μόνο έκανε το μοντέλο μας πιο ισχυρό, αλλά και λιγότερο υπολογιστικά δαπανηρό.

Ο ανιχνευτής που χρησιμοποιείται για αυτό το μοντέλο είναι ένα απλό κατώφλι, το οποίο ορίστηκε κάτω από 1100 στην βαθμολογία ανωμαλιών που προέρχεται από το μοντέλο svm.




Σχήμα 21(α): περίπτωση που χρησιμοποιήθηκαν τα χρονοδιαγράμματα που υπήρχαν



Σχήμα 21(β): χρησιμοποιήσαμε την ωριαία ποσοστιαία μεταβολή.

Σχήμα 22: Υπολογισμένη απόσταση μεταξύ κάθε σημείου δεδομένων και του δεδομένου εκπαιδευμένου μοντέλου SVM



Σχήμα 23: Αποτέλεσμα του Detector

Στο σχήμα 22 εμφανίζεται το αποτέλεσμα του Detector. Οι μπλε γραμμές είναι οι ενδείξεις ανωμαλίας του μοντέλου One Class SVM και η πορτοκαλί γραμμή αντιπροσωπεύει τις πραγματικές περιόδους ελαττωμάτων. Υποθέτοντας, όπως αναφέρθηκε προηγουμένως, το στατικό παράθυρο των 30 ημερών πριν από τη δεδομένη ημερομηνία ελαττώματος, ως ανόητη περίοδο.

Τα αποτέλεσμα είναι τα εξής:

Confusion Matrix		
	Predicted Negative	Predicted Positive
Actually Negative	20726	1696
Actually Positive	2775	469

Πίνακας 5

	precision	recall	f1-score	support
0	0.88	0.92	0.9	22422
1	0.22	0.14	0.17	3244

Πίνακας 6

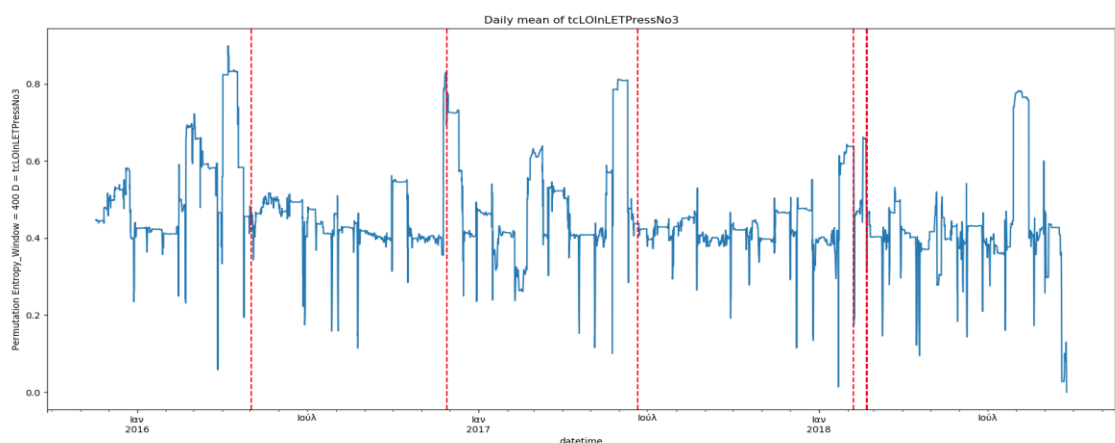
4.4.5. Weighted Permutation Entropy

Με απλά λόγια η Permutation Entropy είναι ένα μέτρο πολυπλοκότητας σε διαδοχικά δεδομένα, όπου αναφέρει το ποσό των νέων πληροφοριών που εμφανίζονται κατά μέσο όρο, σε κάθε σημείο μιας ακολουθίας. Στο πλαίσιο των χρονοσειρών, αυτό μεταφράζεται σε ένα μέτρο του τρόπου με τον οποίο η πληροφορία διαδίδεται προς τα εμπρός. Η πρόθεσή μας και η υποκείμενη εικασία πίσω από την προσέγγισή μας είναι ότι οι απότομες αλλαγές στην εντροπία μπορεί να υποδηλώνουν ότι συνέβη κάτι καινούργιο που σημαίνει είτε δυσλειτουργία του κινητήρα είτε το σύστημα των δεδομένων. Με άλλα λόγια, χρησιμοποιούμε απλώς σταθμισμένη εντροπία μετάδοσης ως μέτρο της πολυπλοκότητας μιας χρονικής σειράς και αντιμετωπίζουμε απότομες μεταβολές σε αυτή την πολυπλοκότητα ως σήμα πιθανών ανωμαλιών που απαντώνται φυσικά ή σχετίζονται με δεδομένα.


Χρησιμοποιήσαμε ως παράμετρο $D = 3$ και παράθυρο κύλισης = 600 timestamps. Και πάλι όλα υπολογίστηκαν με βάση την ώρα.

Τα πειράματά μας έδειξαν ότι υπάρχουν μερικές ροές δεδομένων που μπορούν να συλλάβουν τα ελαττώματα, οπότε αποφασίσαμε να το χρησιμοποιήσουμε στο μοντέλο του 1 επιπέδου. Οι προαναφερθείσες παράμετροι είναι η Πίεση Εισόδου Ψύξης Νωπού Νερού και Η Πίεση Εισόδου Λαδιού Λιπαντικού Στρόβιλο-Φορτιστή # 3. Τα διαγράμματα αυτών των χαρακτηριστικών ακολουθούν στις παρακάτω εικόνες.

Ο προτεινόμενος Detector με βάση την σταθμισμένη εντροπία είναι ένα απλό στατικό όριο στο 0,6. Αυτό σημαίνει ότι θα πρέπει να υπολογίζουμε συνεχώς την εντροπία μεταστοιχείωσης και όταν αυτές οι τιμές ξεπεράσουν αυτό το όριο, το σύστημα θα υποδείξει ανωμαλία.



Σχήμα 24: Αποτέλεσμα πειραμάτων



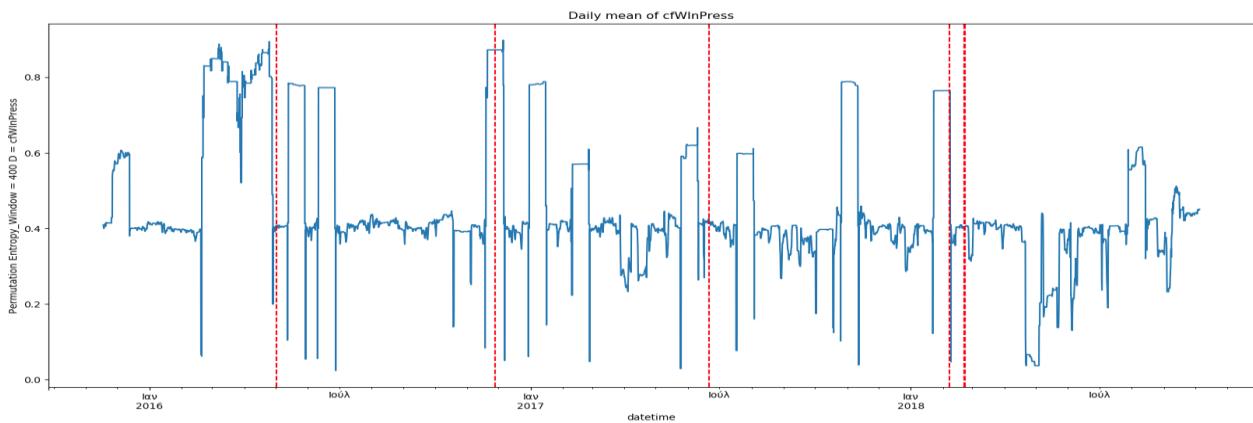
Σχήμα 254: Αποτέλεσμα πειραμάτων

Confusion Matrix		
	Predicted Negative	Predicted Positive
Actually Negative	18333	4089
Actually Positive	1265	1979

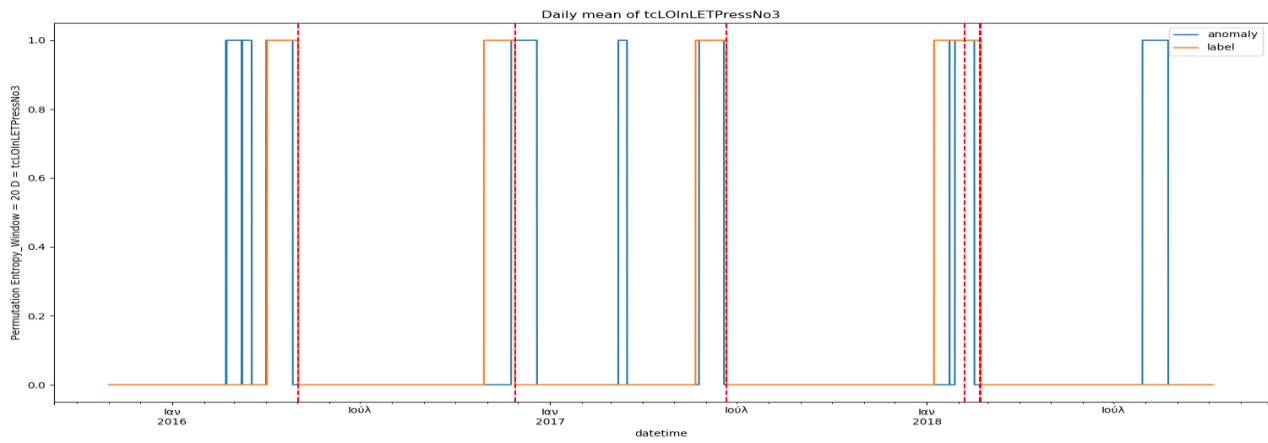
Πίνακας 7

	precision	recall	f1-score	support
0	0.94	0.82	0.87	22422
1	0.33	0.61	0.43	3244

Πίνακας 8



Σχήμα 26: Αποτέλεσμα πειραμάτων



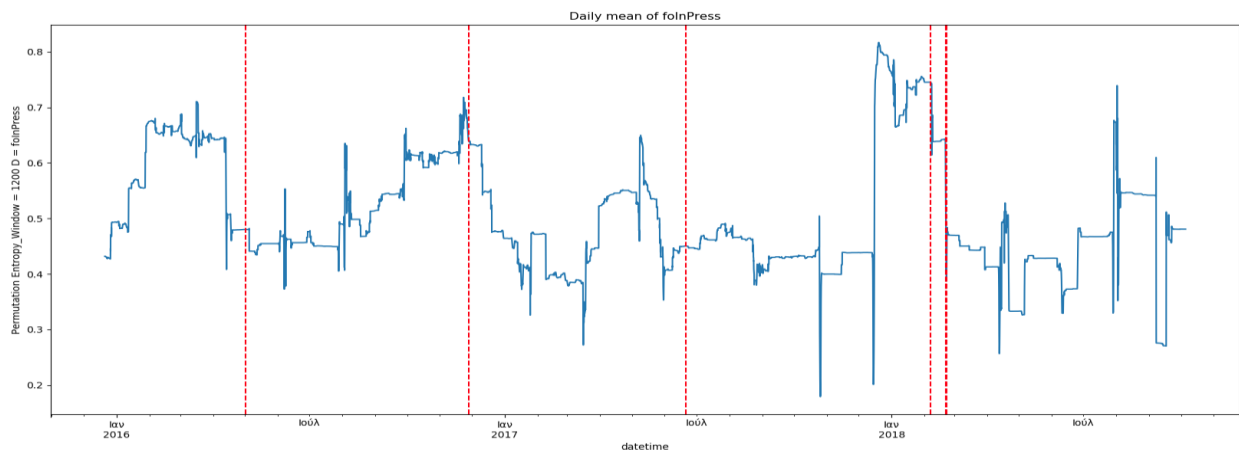
Σχήμα 27: Αποτέλεσμα πειραμάτων

Confusion Matrix		
	Predicted Negative	Predicted Positive
Actually Negative	18333	4089
Actually Positive	1265	1979

Πίνακας 9

	precision	recall	f1-score	support
0	0.93	0.91	0.92	22422
1	0.47	0.53	0.5	3244

Πίνακας 10



Σχήμα 28: Αποτέλεσμα πειραμάτων

Confusion Matrix		
	Predicted Negative	Predicted Positive
Actually Negative	19276	3146
Actually Positive	1230	2014

Πίνακας 11

	precision	recall	f1-score	support
0	0.94	0.86	0.9	22422
1	0.39	0.62	0.48	3244

Πίνακας 12

4.4.6. Second-Level Anomaly Detector

Το δεύτερο επίπεδο του ανιχνευτή θα λαμβάνει ως είσοδο την ένδειξη που δίνεται από το πρώτο επίπεδο και θα πρέπει να υποδηλώνει την πιθανότητα ότι το ελάττωμα βρίσκεται σε έναν συγκεκριμένο κύλινδρο της κύριας μηχανής. Σε αυτή την έρευνα, δοκιμάσαμε μοντέλα όπως LSTM με ένα κανάλι, One Class SVM και Cointegration Check για ανίχνευση ανωμαλιών και Matrix Profile για αναγνώριση προτύπων. Και για τις δύο προσεγγίσεις τα δεδομένα που χρησιμοποιήθηκαν προέρχονται αποκλειστικά από τους αισθητήρες που τοποθετήθηκαν σε κάθε κύλινδρο.


4.4.7. Single Channel LSTM

Για κάθε ροή δεδομένων δημιουργείται ένα ενιαίο μοντέλο και κάθε μοντέλο χρησιμοποιείται για την πρόβλεψη τιμών για το συγκεκριμένο κανάλι. Η μοντελοποίηση κάθε καναλιού επιτρέπει ανεξάρτητα την ανιχνευσιμότητα στο επίπεδο του καναλιού, παρέχοντας μια ένδειξη για το ποιο κύλινδρο μπορεί να είναι κατεστραμμένο.

Για κάθε σημείο $x(t)$, ένα μήκος ακολουθίας s , προσδιορίζει τον αριθμό των σημείων που εισάγονται στο μοντέλο για πρόβλεψη. Το μήκος πρόβλεψης που χρησιμοποιείται είναι 1, δηλαδή ο αριθμός των βημάτων που πρέπει να προβλεφθούν είναι 1. Κατά συνέπεια, δημιουργείται μια ενιαία κλίμακα πρόβλεψης $\hat{y}(t)$ για την πραγματική τιμή του αισθητήρα σε κάθε βήμα t .

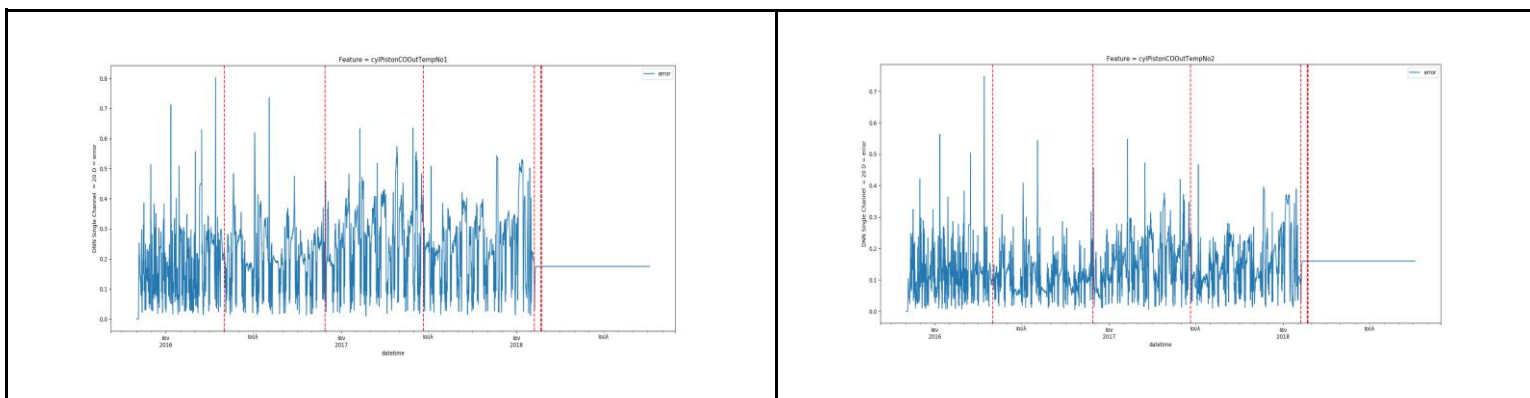
Στα παρακάτω σχήματα, μπορούμε να δούμε με μπλε γραμμή τις πραγματικές τιμές κάθε καναλιού, με πράσινη τις προβλεπόμενες τιμές και με το κόκκινο το τετράγωνο σφάλμα μεταξύ των πραγματικών και των προβλεπόμενων τιμών. Επιπλέον, με μπλε κατακόρυφες γραμμές στην υποπαράγραφο σφάλματος σημειώνονται οι ημερομηνίες ελαττωμάτων. Η υπόθεσή μας δηλώνει ότι το σφάλμα πριν από τις ημερομηνίες των ελαττωμάτων πρέπει να είναι υψηλότερο από τα υπόλοιπα υποστυλώματα σε έναν συγκεκριμένο κύλινδρο που σπάστηκε εκείνη τη στιγμή.

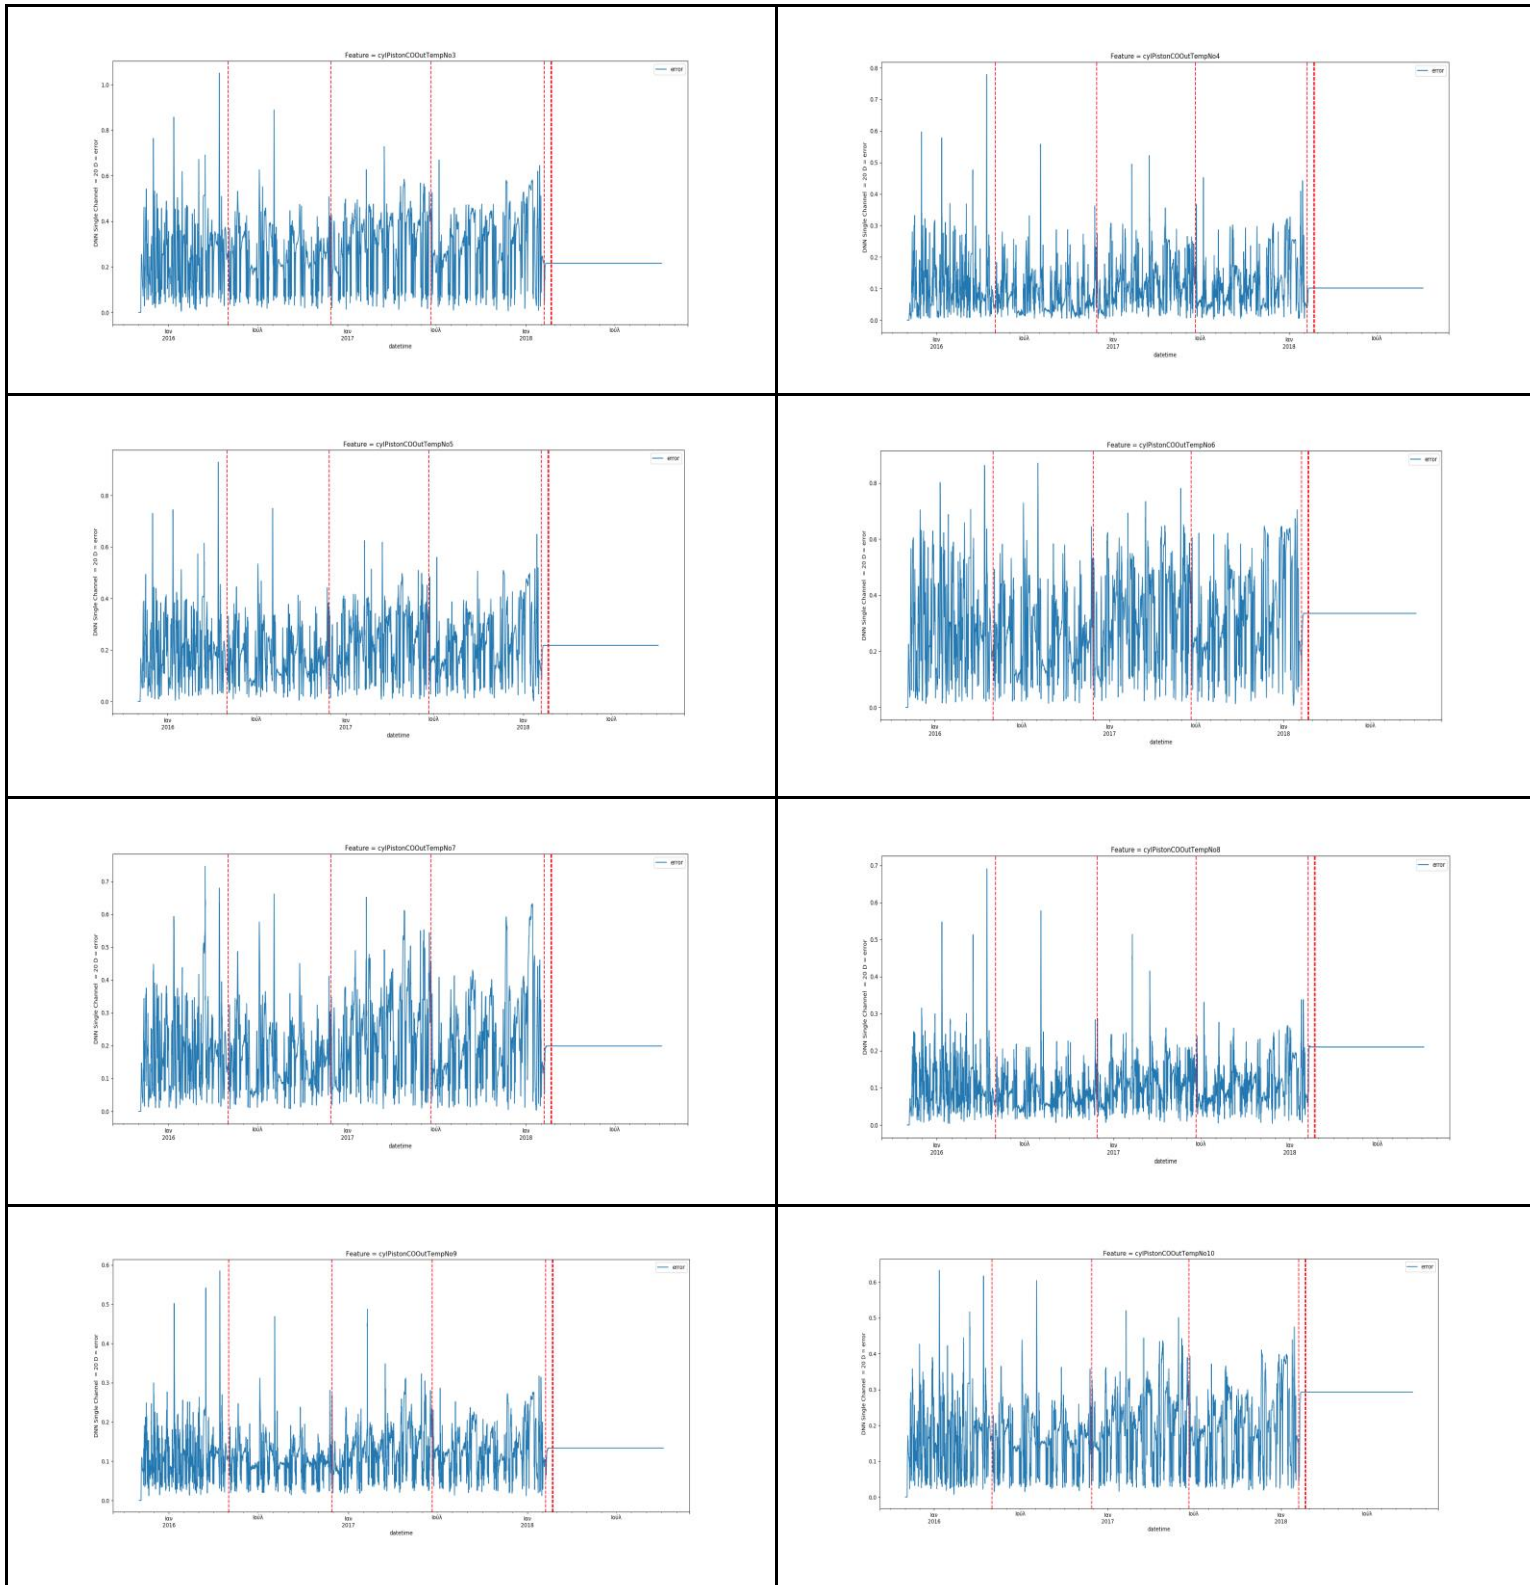




Σχήμα 29: Αποτέλεσμα πειραμάτων

Η αρχιτεκτονική του LSTM που χρησιμοποιήσαμε αποτελείται από 5 κρυμμένα στρώματα [64,100,250,100,64], το παράθυρο μνήμης ήταν 100 ώρες με τη λειτουργία ενεργοποίησης ταπη και μια αρκετά μεγάλη απόκλιση (0.50) μετά από κάθε στρώση. Η πρόωρη διακοπή χρησιμοποιήθηκε για να περιοριστεί η εκπαίδευση σε μοντέλα και κανάλια που παρουσιάζουν μειώσεις στο σφάλμα επικύρωσης. Επίσης, λόγω των θορυβωδών δεδομένων, παρατηρήσαμε ότι η αρχικοποίηση των τυχαίων βαρών στην περίπτωση μας είχε πολύ μεγάλη επίδραση στην απόδοση, έτσι εκπαιδεύσαμε 10 μοντέλα με διαφορετικούς τυχαίους σπόρους και χρησιμοποιήσαμε τον μέσο όρο ως μοντέλο.





Σχήμα 30: σφάλμα πρόβλεψης για κάθε θερμοκρασία κυλίνδρου / εμβόλου ψύξης (° C).

Μετά από πολλές δοκιμές καταλήξαμε στο συμπέρασμα ότι οι μετρήσεις που παρακολουθούνται σε κάθε κύλινδρο έχουν σχεδόν ταυτόσημη συμπεριφορά ακόμη και πριν από μια συγκεκριμένη δυσλειτουργία σε έναν μοναδικό κύλινδρο. Στο σχήμα 29 όπου παρουσιάζεται το σφάλμα πρόβλεψης για κάθε θερμοκρασία κυλίνδρου / εμβόλου ψύξης

(° C). Οι κόκκινες κατακόρυφες γραμμές υποδηλώνουν ελάττωμα της διασταυρούμενης έδρας του κυλίνδρου αριθ. 9-2-4-8-4 αντίστοιχα. Είναι προφανές ότι οι κορυφές του σφάλματος πρόβλεψης εμφανίζονται ταυτόχρονα στις ίδιες χρονικές στιγμές σε όλους σχεδόν τους κυλίνδρους, πράγμα που σημαίνει ότι δεν γνωρίζουν το ελάττωμα που μελετά.

4.4.8. Cointegration Approach

Όταν δύο μεταβλητές κινούνται προς την ίδια κατεύθυνση, λέγεται ότι συσχετίζονται θετικά. Αν κινούνται σε αντίθετες κατευθύνσεις, η συσχέτιση λέγεται ότι είναι αρνητική. Παρατηρείται κατά τη διαδικασία ανάλυσης και παρουσιάζεται στην παράγραφο 4.3.2 ότι πολλά από τα ρεύματα δεδομένων συσχετίζονται σε μεγάλο βαθμό. Ειδικά οι αισθητήρες που μετρούν την ίδια τιμή σε διαφορετικό κύλινδρο ή έμβολο.

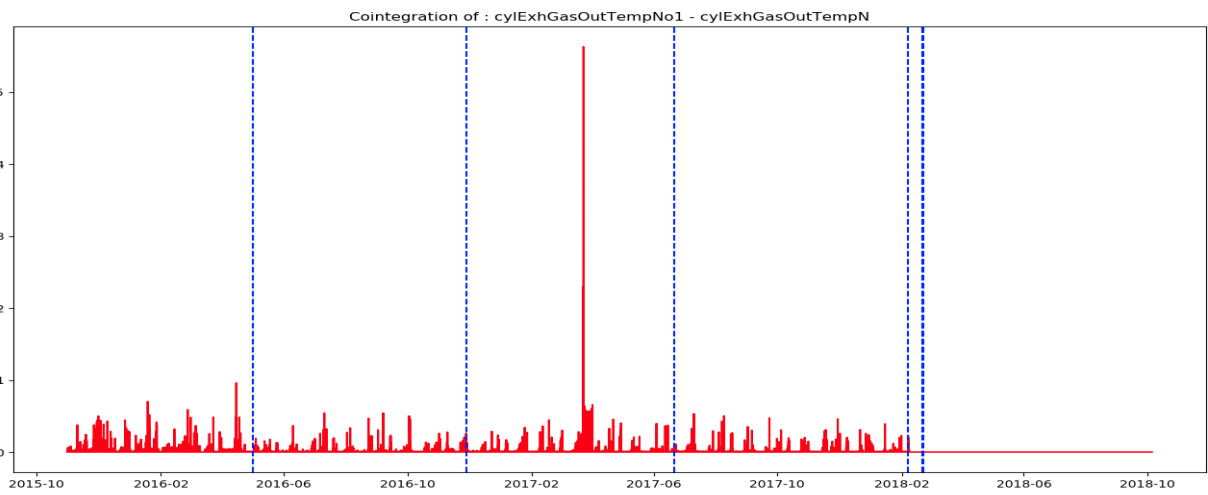
Η cointegration συμβάλλει στον προσδιορισμό του βαθμού στον οποίο δύο μεταβλητές είναι ευαίσθητες στην ίδια μέση τιμή για μια συγκεκριμένη χρονική περίοδο. Έτσι, η συνένωση δεν αντικατοπτρίζει αν οι δύο χρονοσειρές θα κινηθούν στην ίδια ή την αντίθετη κατεύθυνση, αλλά μπορούν να πουν εάν η απόσταση μεταξύ τους παραμένει η ίδια με την πάροδο του χρόνου.

Η παραδοχή μας είναι ότι κάποια ζεύγη χρονοσειρών συνενώνονται. Αφού έπρεπε να ελέγξουμε ότι οι χρονοσειρές μας είναι stationary, υπολογίσαμε τη διαφορά μεταξύ τους. Έχοντας ελέγξει ως προς το stationarity και απεικονίσει το δεδομένης spread, υποθέτουμε με σιγουριά ότι τα περισσότερα από τα χαρακτηριστικά γνωρίσματα είναι cointegrated. Με βάση αυτή τη θεωρία υποθέσαμε ότι εάν παρατηρήσουμε μια προσωρινή απότομη αυξομείωση στην απόσταση δύο συνενωμένων χρονοσειρών, μπορεί να υποδηλώνει μια ανωμαλία ή μια δυσλειτουργία. Έτσι αποφασίσαμε να μελετήσουμε συγκεκριμένα την συνένωση μεταξύ των δεδομένων αισθητήρων ενός συγκεκριμένου κυλίνδρου / εμβόλου μεταξύ τους και μεταξύ ορισμένων κύριων μεταβλητών θερμοκρασίας και πίεσεως. Τα ζεύγη ροών που χρησιμοποιούνται δίνονται στον επόμενο πίνακα. Πρέπει να αναφερθεί ότι δοκιμάζονται πολλές μέθοδοι επαναδειγματοληψίας και χρησιμοποιήσαμε επίσης, προσπάθειες για την εξάλειψη της εποχικότητας των δεδομένων χωρίς σημαντική επίπτωση στο αποτέλεσμα.


First Feature	
scavAirFireDetTempNo1-scavAirFireDetTempNo10	Cylinder #1 - 10 Scavenge Air Fire Detection Temperature (°C),
cylExhGasOutTempNo1-cylExhGasOutTempNo10	Cylinder #1 - 10 Exhaust Gas Out Temperature (°C),
cylJCFWOutTempNo1-cylJCFWOutTempNo10	Cylinder #1 - 10 Jacket Cooling Fresh Water Outlet Temperature (°C),
cylPistonCOOutTempNo1-cylPistonCOOutTempNo10	Cylinder #1 - 10 Piston Cooling Outlet Temperature (°C),
Second Feature	
Mean/Max of scavAirFireDetTempNo1- 10	Mean and Max of Cylinders Scavenge Air Fire Detection Temperature
Mean/Max cylExhGasOutTempNo1-10	Mean and Max of Cylinders Exhaust Gas Out Temperature (°C),
Mean/Max cylJCFWOutTempNo1-10	Mean and Max of Cylinders Jacket Cooling Fresh Water Outlet Temperature,
Mean/Max cylPistonCOOutTempNo1-10	Mean and Max of Cylinders Piston Cooling Outlet Temperature (°C),
foInTemp	Fuel Oil Inlet Temperature (°C),
jcfWInTempLow	Jacket Cooling Fresh Water Inlet Temperature Low (°C)
startAirPress	Starting Air Pressure (Pa),
thrustPadTemp	Thrust Pad Temperature (°C),
mainLOInTemp	Main Lube Oil Inlet Temperature (°C)
foTemperature	Fuel Oil Temperature (°C)
speed_overground	GPS speed (kn),
stw	Speed through water – calculated by stw_trans and stw_lon (kn),
scavAirInLetPress	Scavenge Air Inlet Pressure (Pa),
scavAirReceiverTemp	Scavenge Air Receiver Temperature (°C),

Πίνακας 13


Τα παρακάτω σχήματα υποδεικνύουν μερικά ενδιαφέροντα διαγράμματα cointegration. Εύκολα αντιλαμβανόμαστε ότι καμία από τις αυξήσεις στα διαγράμματα συνεννόησης δεν οφείλονται σε ελαττωματικό κύλινδρο. Επιπλέον, παρατηρώντας διαγράμματα ίδιων μεταβλητών διαφορετικών κυλίνδρων παρατηρείται ότι είναι πανομοιότυπα ακόμα και όταν μελετώνται διαφορετικοί κύλινδροι. Αυτό σημαίνει είτε ότι αυτή η προσέγγιση δεν είναι κατάλληλη για να διακρίνει τη δυσλειτουργία μεταξύ διαφορετικών κυλίνδρων ή ότι τα δεδομένα που προέρχονται από τους αισθητήρες που είναι ειδικό για τους κυλίνδρους είναι κακοί όσον αφορά την ποιότητα.



Σχήμα 31: Διάγραμμα cointegration



Σχήμα 31: Διάγραμμα cointegration

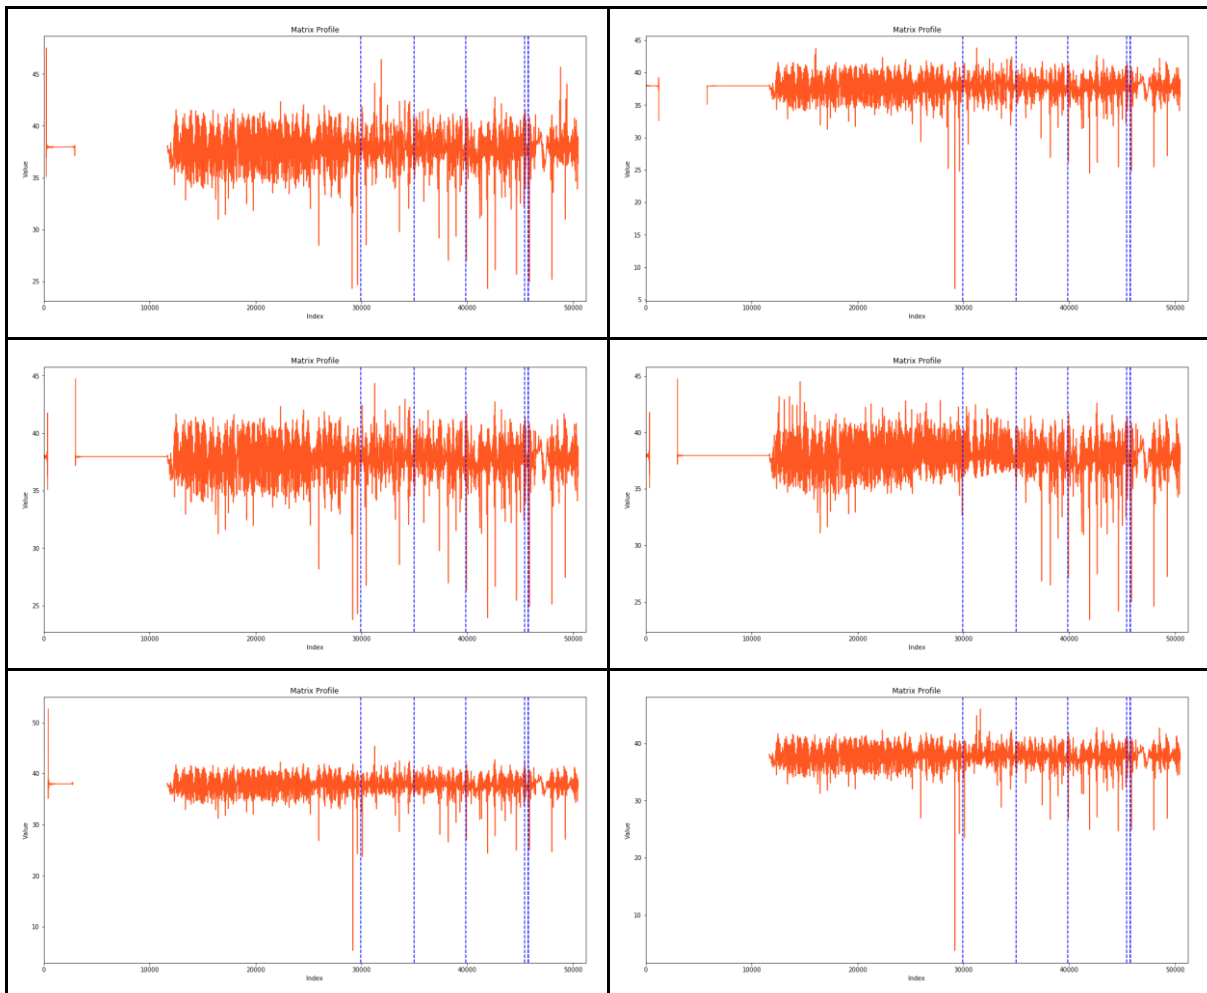


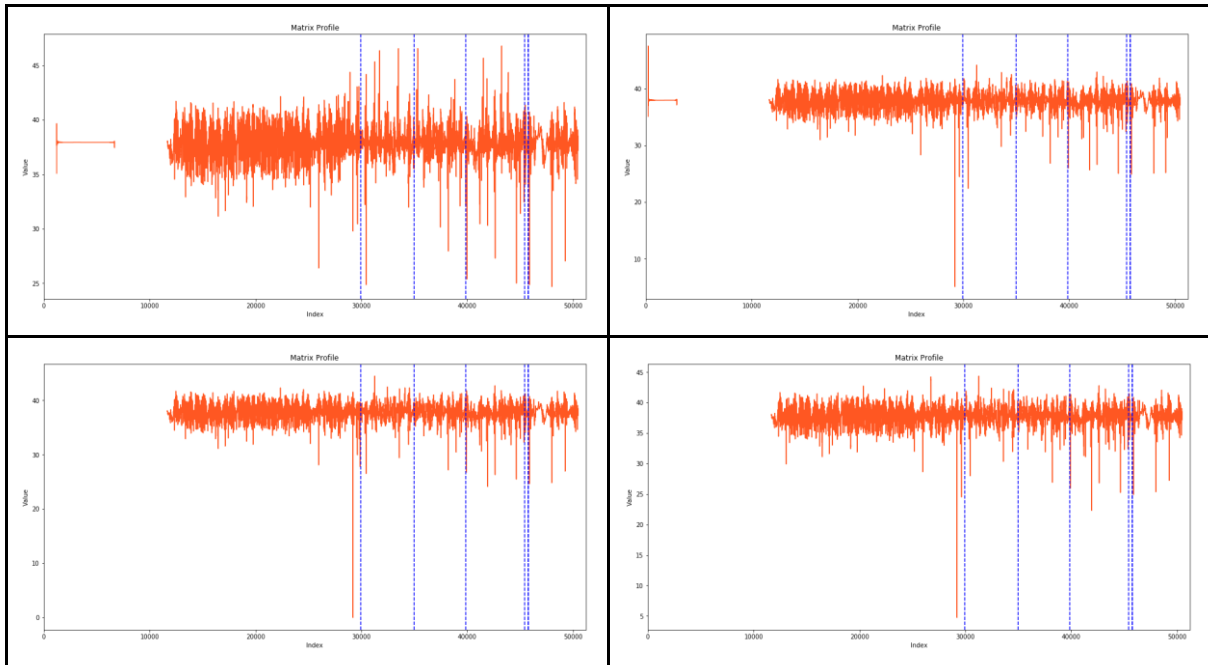
Σχήμα 32: Διάγραμμα cointegration

4.4.9. Matrix Profile

Όπως αναφέρθηκε στην παράγραφο 2.13 ένας τρόπος να εντοπίσουμε επαναλαμβανόμενα μοτίβα σε μια χρονοσειρά είναι να υπολογίσουμε το Matrix Profile. Λαμβάνοντας αυτό υπόψιν, η υπόθεσή μας υποδεικνύει ότι πριν από κάθε ελάττωμα θα πρέπει να βρούμε το ίδιο μοτίβο στις χρονολογικές σειρές ειδικών κυλίνδρων. Συνεπώς, διατηρήσαμε ως ζητούμενο μοτίβο μια χρονική περίοδο 30 ημερών από τον πρώτο αποτυχημένο κύλινδρο (αναφερόμενοι στη χρονοσειρά των μεταβλητών αυτού του συγκεκριμένου κυλίνδρου) και υπολογίσαμε το Matrix Profile του άλλου κυλίνδρου χρησιμοποιώντας αυτή την ειδική υποπεριοχή, περιμένοντας να δούμε ότι η χαμηλότερη τιμή του Matrix Profile θα τοποθετηθεί πριν από ένα ελάττωμα του κάθε κυλίνδρου.

Τα επόμενα διαγράμματα παρουσιάζουν το Matrix Profile μιας συγκεκριμένης περιόδου πριν από την πρώτη ημερομηνία ελαττώματος. Για άλλη μια φορά θα πρέπει να σημειωθεί ότι δοκιμάστηκαν πολλές μέθοδοι αναδειγματοληψίας και προσπαθήσαμε επίσης, να αποτρέψουμε και να απομακρύνουμε την εποχικότητα των δεδομένων χωρίς σημαντική επίπτωση στο αποτέλεσμα.






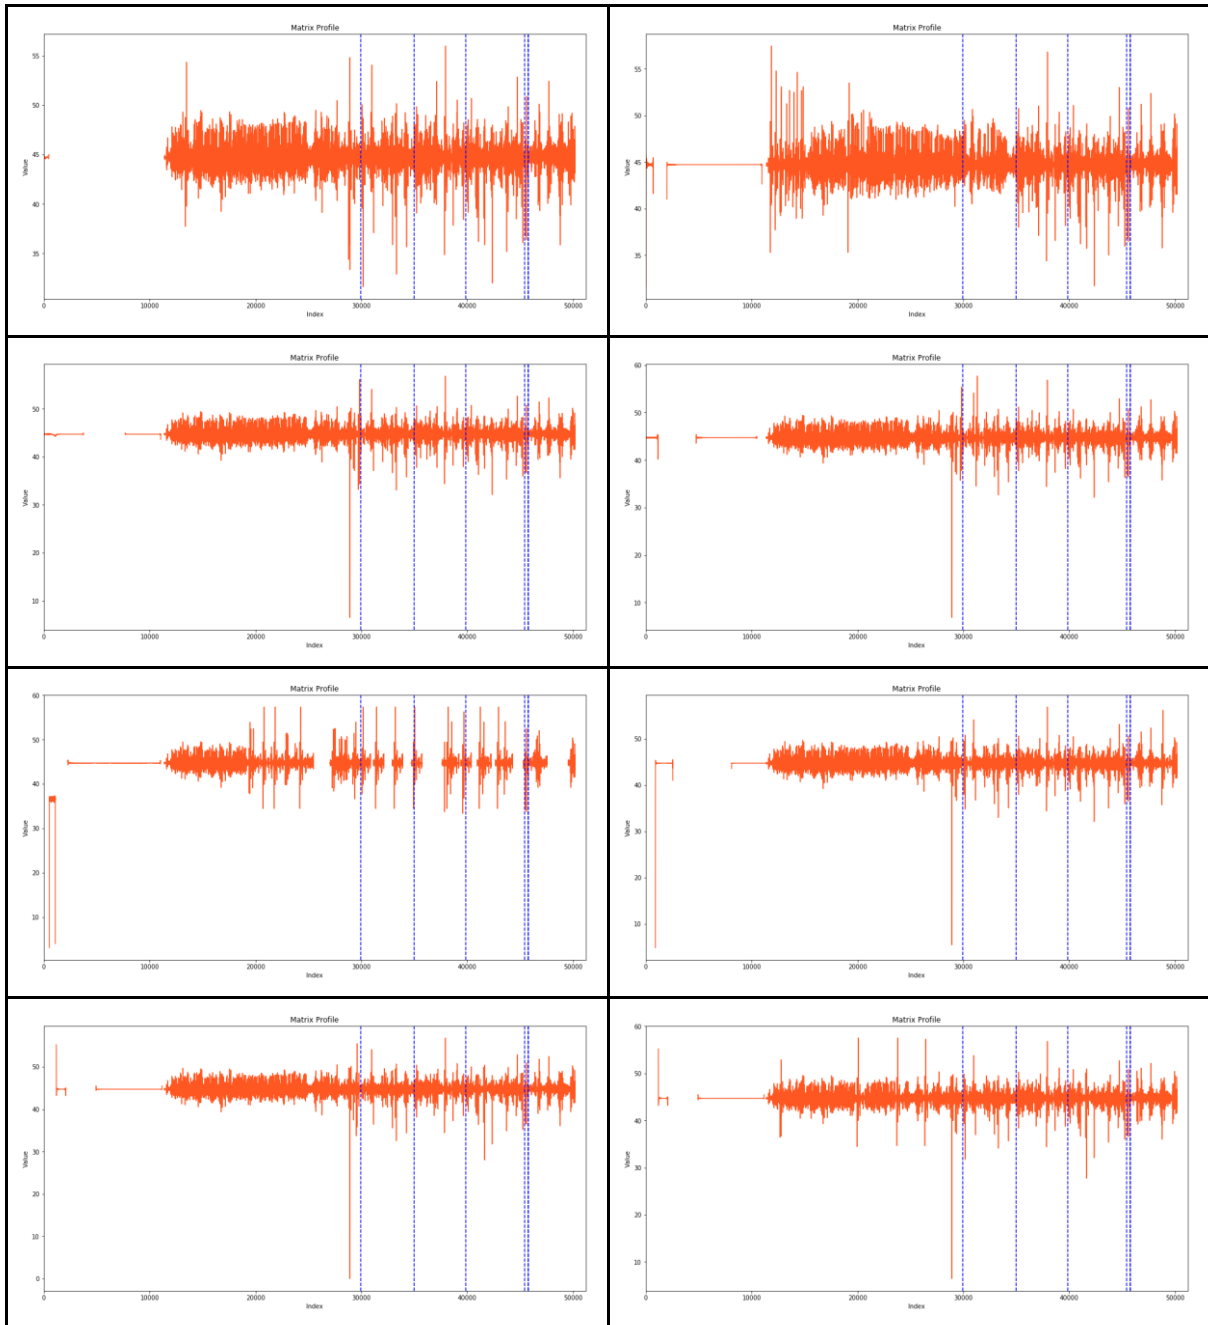
Σχήμα 32: Matrix Profile μιας συγκεκριμένης περιόδου πριν από την πρώτη ημερομηνία ελαττώματος

Το σχήμα 34 δείχνει το Matrix Profile της θερμοκρασίας νερού ψύξης σε κάθε κύλινδρο 1-10, χρησιμοποιώντας ως ερώτημα 30 ημέρες υπο-αλληλουχία της θερμοκρασίας νερού ψύξης του κυλίνδρου Νο 9 πριν από το πρώτο ελάττωμα. Οι μπλε κατακόρυφες γραμμές υποδηλώνουν ελάττωμα του Crosshead Bearing του κυλίνδρου αριθ. 9-2-4-8-4 αντίστοιχα. Δεν μπορούμε να καταλάβουμε ποιος κύλινδρος είναι πιο πιθανόν να δυσλειτουργεί. Είναι περισσότερο από προφανές ότι κανένα από τα παραπάνω σχήματα δεν παρέχει καμία πληροφορία σχετικά με το ποιος κύλινδρος μπορεί να είναι πιο πιθανό να είναι ο σπασμένος. Όταν η εποχικότητα δεν έχει αφαιρεθεί, οι χαμηλότερες τιμές του Matrix Profile προήλθαν από την περιοδική λειτουργία και όχι από δυσλειτουργίες.

Στη συνέχεια αφαιρώντας την εποχικότητα και επαναυπολογίσαμε το MP των ιδίων μεταβλητών και παρουσιάζεται στα επόμενα σχήματα 33.

*οι πορτοκαλι γραμμες είναι το MP, και οι μπλέ οι ημερομηνίες βλαβών





Σχήμα 33: Matrix Profile

Και πάλι όταν έχει αφαιρεθεί η παράμετρος εποχικότητας, δεν υπάρχει σημαντική ομοιότητα (χαμηλή τιμή του Matrix Profile) με οποιαδήποτε άλλη χρονική στιγμή.


Κεφάλαιο 5ο

Συμπεράσματα – Προτάσεις

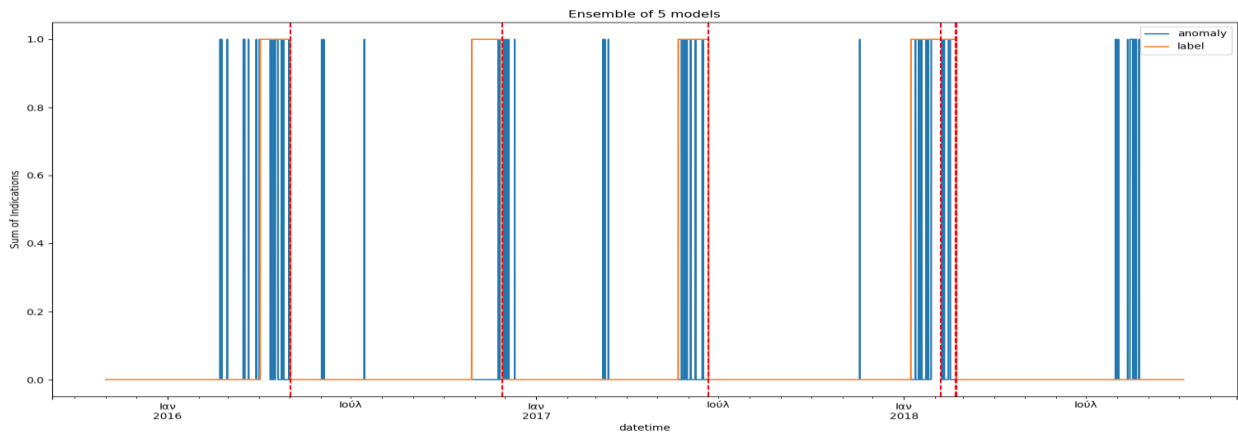
5.1 Αποτελέσματα

5.1.1. Γενικά

Όπως περιεγράφηκε και στην παράγραφο 4, δοκιμάστηκαν μέθοδοι σε δύο επίπεδα με διαφορετικές παραμέτρους, διαφορετικά δεδομένα και ελαφρώς διαφορετικό σκοπό. Στο πρώτο επίπεδο τα αποτελέσματα παρατέθηκαν στην παράγραφο 4 κατά μονάς για κάθε προσέγγιση. Στη συνέχεια δημιουργήσαμε ένα απλό σύνολο των μοντέλων που αναφέρονται στο πρώτο επίπεδο ανίχνευσης ανωμαλιών. Χρησιμοποιήσαμε το άθροισμα αυτών, δηλαδή όταν υπάρχει βαθμολογία 6, όλα τα μοντέλα συμφωνούν ότι υπάρχει μια ανωμαλία που μας κάνει πιο σίγουρους για το αποτέλεσμα μας. Χρησιμοποιήσαμε ένα όριο πάνω από 3, για την ενεργοποίηση συναγερμού στο σύστημα. Όπως μπορούμε να δούμε από τα σχήματα 35 και 36, το σύνολο είναι πιο σταθερό από κάθε μοντέλο ξεχωριστά.



Σχήμα 34: Αποτελέσματα



Σχήμα 35: Αποτελέσματα

Confusion Matrix		
	Predicted Negative	Predicted Positive
Actually Negative	22250	172
Actually Positive	2559	685

Πίνακας 14

	precision	recall	f1-score	support
0	0.9	0.99	0.94	22422
1	0.8	0.21	0.33	3244

Πίνακας 15

model	precision	recall	f1-score
LSTM	0.22	0.03	0.05
XGB	0.39	0.08	0.13
PE_1	0.33	0.61	0.43
PE_2	0.47	0.53	0.5
PE_3	0.39	0.62	0.48
One Class SVM	0.22	0.14	0.17
Ensemble	0.8	0.21	0.33
Ensemble (no LSTM)	0.5	0.7	0.58

Πίνακας 16

Όπως φαίνεται στον Πίνακα 16, τα καλύτερα αποτελέσματα όσον αφορά την βαθμολογία F1 επιτυγχάνονται χρησιμοποιώντας το άθροισμα όλων των προαναφερθέντων μοντέλων εκτός από προβλέψεις βάσει LSTM.

Οι παράμετροι δεν ήταν σαφώς ρυθμισμένοι ώστε να μην έχουν μεγαλύτερη precision, ούτε recall. Επίσης, η προσέγγιση του μέσου όρου είναι πολύ απλή και μπορούν να χρησιμοποιηθούν πιο πολύπλοκες μέθοδοι συνδυασμού των μοντέλων. Μπορούν επίσης, να χρησιμοποιηθούν και πιο εξελιγμένοι ανιχνευτές αντί να χρησιμοποιούν μόνο κατώτατα όρια όπως, υβριδικοί ανιχνευτές που βασίζονται σε συσσωρευτές ανώμαλων σημείων και ρυθμιστές κατωφλιών τροχαίου.

Είναι πολύ σημαντικό να εξετάσουμε ρητά τα πραγματικά δεδομένα, πράγμα που σημαίνει ότι έπρεπε να αντιμετωπίσουμε πολλές δυσάρεστες παραμέτρους. Διαπιστώσαμε επίσης, ότι είναι αρκετά δύσκολο να αντλήσουμε πληροφορίες από τις δεδομένες ροές δεδομένων σχετικά με ποιο κύλινδρο είναι πιο πιθανό να απολυθεί.

Όσον αφορά τις προσεγγίσεις μας στο δεύτερο επίπεδο, όπου επικεντρωθήκαμε στην προσπάθεια να προβλέψουμε την πιθανότητα η εξεταζόμενη βλάβη να εντοπίζεται σε ένα συγκεκριμένο κύλινδρο, πρέπει να παραδεχτούμε ότι δεν στέφθηκε με επιτυχία. Όπως αναφέρεται και στην ενότητα 4, οι μεταβολές στις ροές δεδομένων από διαφορετικούς κυλίνδρους είναι σχεδόν πανομοιότυπες και οι ελάχιστες παρεκκλίσεις που παρουσιάζουν δεν μπορούν να ερμηνεύσουν την εξεταζόμενη βλάβη.

5.1.2. Υλοποίηση

Οι μέθοδοι που παρουσιάζονται σε αυτό το έγγραφο έχουν ενσωματωθεί σε ένα σύστημα το οποίο βρίσκεται επί του παρόντος στο πλαίσιο του έργου BigDataStack, ένα έργο που συγχρηματοδοτείται από την Ευρωπαϊκή Επιτροπή. Πάνω από 60 πλοία μεταφοράς εμπορευματοκιβωτίων βρισκόταν κάτω από έναν κορυφαίο διεθνή ναυτιλιακό φορέα, πάνω από 100 κανάλια παρακολουθούνται σε ωριαία βάση, καθώς τα δεδομένα αποστέλλονται από τα σκάφη, τα μοντέλα εκπαιδεύονται εκτός σύνδεσης κάθε εβδομάδα με πρόωρη διακοπή. Ωστόσο, ένα σημαντικό εμπόδιο για να γίνει ένα κεντρικό στοιχείο της πρόβλεψης για την κατάσταση του Crosshead Bearing είναι ο τρέχων βαθμός των ψευδών θετικών και η δυσκολία πρόβλεψης του ακριβούς κυλίνδρου. Η υιοθέτηση νέων τεχνολογιών και συστημάτων σημαίνει αυξημένο κίνδυνο σπατάλης πολύτιμου χρόνου και προσοχής. Η διερεύνηση ακόμη και λίγων ψευδών θετικών μπορεί να οδηγήσει τους χρήστες να χάσουν

την εμπιστοσύνη τους, ως εκ τούτου η επίτευξη υψηλής ακρίβειας επεξεργασίας είναι απαραίτητη για την υιοθεσία.

Η εφαρμογή μπορεί να τροποποιηθεί ως προς το πότε πρέπει να εκτελεσθεί η επανεκπαίδευση. Επίσης, αποφασίσαμε να ανακτήσουμε τη ροή από μια βάση δεδομένων Datastore όπου αποθηκεύονται. Και στη συνέχεια αποθηκεύουμε την ένδειξη σφάλματος συνοδευόμενη από μια εκτιμώμενη πιθανότητα. Όλες αυτές οι εργασίες εκτελούνται με βάση έναν χρονοπρογραμματιστή.

5.1.3. Future Work

Η πιλοτική εφαρμογή και τα πειραματικά αποτελέσματα είναι βασικά ορόσημα για τον καθορισμό ότι είναι εφικτό ένα μεγάλης κλίμακας σύστημα αυτόματης παρακολούθησης της κατάστασης. Η μελλοντική δουλειά θα επικεντρωθεί στη βελτίωση των προβλέψεων κυρίως μέσω βελτιωμένης μηχανικής. Παρακολούθηση κύριων κραδασμών κινητήρα του σκάφους θα ήταν πραγματικά ενημερωτικό ειδικά για ελαττώματα όπως διαφθορά φέρει Crosshead. Επίσης, θα μπορούσε να είναι χρήσιμο ένα συμπληρωματικό μοντέλο που βασίζεται στην εναπομένουσα διάρκεια ζωής κάθε μηχανικού μέρους.

Οι δύο προαναφερθείσες βελτιώσεις αποτελούν βασικούς τομείς μελλοντικών εργασιών που θα είναι γενικά ευεργετικοί για την παρακολούθηση δυναμικών και πολύπλοκων πλοίων. Σχεδιάζουμε επίσης να συνεχίσουμε να βελτιώνουμε τις προσεγγίσεις μας δίνοντας έμφαση στη χρήση πιο σύνθετων ανιχνευτών ανωμαλίας.

Τέλος, μια άλλη βασική πτυχή του προβλήματος που δεν έχει αντιμετωπιστεί είναι οι αλληλεπιδράσεις και οι εξαρτήσεις που είναι εγγενείς στα δεδομένα των αισθητήρων. Αυτό έχει αντιμετωπιστεί εν μέρει μέσω μιας οπτικής διεπαφής, αλλά μια πιο μαθηματική και αυτοματοποιημένη άποψη στις συσχετίσεις μεταξύ των ανωμαλιών καναλιού θα παρείχε σημαντική εικόνα για σύνθετες συμπεριφορές συστήματος και ανωμαλίες.

5.2. Συμπεράσματα

Το παρόν έγγραφο παρουσιάζει και ορίζει μια σημαντική και αυξανόμενη πρόκληση στο πλαίσιο των ναυτιλιακών επιχειρήσεων που μπορεί να αποκτήσει μεγάλο όφελος από τις σύγχρονες προσεγγίσεις ανίχνευσης ανωμαλιών. Παρουσιάζουμε ορισμένες σύγχρονες προσεγγίσεις στον τομέα ανίχνευσης ανωμαλιών ενώ αντιμετωπίζουμε βασικές προκλήσεις που περιλαμβάνουν την ερμηνεία, την κλίμακα, την ακρίβεια και την πολυπλοκότητα που είναι εγγενείς σε πολλά σενάρια ανίχνευσης ανωμαλιών. Τα αποτελέσματα της ανά χείρας εργασίας κρίνονται ικανοποιητικά και σίγουρα παρέχουν και βοηθούν του μηχανικούς στον εντοπισμό σφαλμάτων της κύριας μηχανής. Σίγουρα το προδιαγεγραμμένο σύστημα δεν μπορεί να λειτουργήσει αυτόνομα, αλλά σε ένα πλαίσιο υπο την επίβλεψη και την παρακολούθηση των μηχανικών.

Σημαντικοί τομείς βελτίωσης και περαιτέρω αξιολόγησης έχουν επίσης εντοπιστεί καθώς αναζητούμε την επέκταση των δυνατοτήτων και την εφαρμογή συστημάτων για μια ποικιλία πλοίων.

5.3. Πηγές

- Σχήμα 2 σελ. 13 <https://www.infraspec.gr/organosi-programmaton-syntirisis/>
- Σχήμα 3 σελ. 14
<https://sumantachatterjeece.wordpress.com/2017/01/11/bathtub-curve-2/>
- One Class SVM σελ. 24 <http://rvlasveld.github.io/blog/2013/07/12/introduction-to-one-class-support-vector-machines/>
- Permutation Entropy σελ 28 <https://www.mdpi.com/2225-1146/7/1/10/htm>
- Anomaly detection: A survey σελ. 29 <https://dl.acm.org/citation.cfm?id=1541882>
- Σχήμα 9 σελ. 32 ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ «Data mining: Αλγόριθμοι ανίχνευσης ακραίων τιμών και εφαρμογή αυτών σε επιχειρηματικά δεδομένα» Μαρία Κατσούδα
- Σχήμα 12 σελ. 34 <https://stats.stackexchange.com/questions/323553/difference-between-contextual-anomaly-and-collective-anomaly>
- Τεχνικές ανίχνευσης ακραίων τιμών σελ. 36
 - <https://www.semanticscholar.org/paper/Visual-Interactive-Preprocessing-of-Time-Series-Bernard-Ruppert/5ec0c65a71f8e790ae9093f3f5997222d28efdf4>
 - http://www.ctanujit.com/uploads/2/5/3/9/25393293/time_series_analysis_sd1final.pdf
 - Pyle, D.: Data Preparation for Data Mining. Morgan Kaufmann, San Francisco (1999) Google Scholar
 - Σχήμα σελ. 37 https://www.researchgate.net/figure/Using-classification-for-anomaly-detection-Chandola-et-al-2009_fig14_281650757

- Ανίχνευση Ανωμαλιών στη Ναυτιλία σελ. 46
 - <https://www.mdpi.com/1099-4300/15/6/2218/htm>
 - Cimino, G.; Ancieri, G.; Horn, S.; Bryan, K. Sensor Data Management to Achieve Information Superiority in Maritime Situational Awareness; CMRE Formal Report, NATO Unclassified; NATO: Brussels, Belgium, 2013; in press. [Google Scholar]
 - International Convention for the Safety of Life at Sea (SOLAS), Chapter V: Safety of Navigation, Regulation 19. 13 December 2002.
 - Commission of the European Communities. Common position adopted by the Council with a view to the adoption of a Directive of the European Parliament and of the Council amending Directive 2002/59/EC establishing a Community vessel traffic monitoring and information system; Document COM 2008 310 final–2005/0239 COD; Brussels, Belgium, 11 June 2008; Available online: <http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=COM:2008:0310:FIN:EN:pdf> (accessed on 30 May 2013).
 - Baldauf, M.; Benedict, K.; Motz, F. Aspects of technical reliability of navigation systems and human element in case of collision avoidance. In Proceedings of the Navigation Conference and Exhibition, London, UK, 28–30 October 2008; pp. 1–11.
 - Hoye, G.K.; Eriksen, T.; Meland, B.J.; Narheim, B.T. Space-based AIS for global maritime traffic monitoring. *Acta Astronaut.* 2008, 62, 240–245. [Google Scholar] [CrossRef]
 - Hall, D.L.; Llinas, J. An introduction to multisensor data fusion. *Proc. IEEE* 1997, 85, 6–23. [Google Scholar] [CrossRef]
 - Roy, J. Anomaly Detection in the Maritime Domain. In Proceedings of SPIE: Optics and Photonics in Global Homeland Security IV, Orlando, FL, USA, 16 March 2008; Halvorson, C.S., Lehrfeld, D., Saito, T., Eds.; Volume 6945.

- Laxhammar, R. Anomaly Detection in Trajectory Data for Surveillance Applications. Ph.D. Thesis, Orebro University, Orebro, Sweden, 2011. [Google Scholar]
- Hansen, J.; Jacobs, G.; Hsu, L.; Dykes, J.; Dastugue, J.; Allard, R.; Barron, C.; Lalejini, D.; Abramson, M.; Russell, S.; et al. Information domination: Dynamically coupling METOC and INTEL for improved guidance for piracy interdiction. 2011 NRL Review 2011, 110–119. [Google Scholar]
- Vespe, M.; Sciotti, M.; Burro, F.; Battistello, G.; Sorge, S. Maritime multi-sensor data association based on geographic and navigational knowledge. In Proceedings of IEEE Radar Conference RADAR 08, Rome, Italy, 26–30 May 2008; pp. 1–6.
- https://link.springer.com/chapter/10.1007%2F978-3-319-10247-4_1#Sec15
- Μείωση Κόστους Ανταλλακτικών Συντήρησης σε Ναυτιλιακή Εταιρία-Μελέτη περίπτωσης Cardiff Marine Inc. Σουρβίνος Νικόλαος