



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ

ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ &

ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

ΕΡΓΑΣΤΗΡΙΟ ΔΙΟΙΚΗΣΗΣ ΠΛΗΡΟΦΟΡΙΑΚΩΝ ΣΥΣΤΗΜΑΤΩΝ

ΑΝΙΧΝΕΥΣΗ ΑΝΩΜΑΛΙΩΝ ΣΕ ΔΕΔΟΜΕΝΑ

ΠΡΑΓΜΑΤΙΚΟΥ ΧΡΟΝΟΥ ΓΙΑ ΤΗ

ΒΙΟΜΗΧΑΝΙΑ 4.0

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Αφροδίτη Α. Φούκα

Επιβλέπων: Γ. Μέντζας

Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούλιος 2021



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ

ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ &

ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

ΕΡΓΑΣΤΗΡΙΟ ΔΙΟΙΚΗΣΗΣ ΠΛΗΡΟΦΟΡΙΑΚΩΝ ΣΥΣΤΗΜΑΤΩΝ

**ΑΝΙΧΝΕΥΣΗ ΑΝΩΜΑΛΙΩΝ ΣΕ ΔΕΔΟΜΕΝΑ
ΠΡΑΓΜΑΤΙΚΟΥ ΧΡΟΝΟΥ ΓΙΑ ΤΗ
ΒΙΟΜΗΧΑΝΙΑ 4.0**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Αφροδίτη Α. Φούκα

Επιβλέπων: Γ. Μέντζας

Καθηγητής ΕΜΠ

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 19η Ιουλίου 2021.

.....

Γρηγόρης Μέντζας

Καθηγητής Ε.Μ.Π.

.....

Δημήτριος Ασκούνης

Καθηγητής Ε.Μ.Π.

.....

Χάρης Δούκας

Αν. Καθηγητής Ε.Μ.Π.

.....
Αφροδίτη Α. Φούκα

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π

Copyright ©Αφροδίτη Α. Φούκα, 2021

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα. Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου (Ν.5343/1932, άρθρο 202).

Περίληψη

Λόγω της αναγκαιότητας της τεχνολογίας των αισθητήρων, ένας μεγάλος αριθμός αισθητήρων χρησιμοποιείται για να παρακολουθεί την κατάσταση υγείας του εξοπλισμού στις βιομηχανικές εγκαταστάσεις με αποτέλεσμα την αύξηση των δυνατοτήτων της στην πρόβλεψη ανωμαλιών σε (σχεδόν) πραγματικό χρόνο. Παρ' όλα αυτά οι υπάρχοντες αλγόριθμοι στην προβλεπτική συντήρηση έχουν αρκετούς περιορισμούς σχετικά με την επεκτασιμότητα, την αποτελεσματικότητα και την αξιοπιστία τους αποτρέποντας την ευρεία εφαρμογή τους σε πολλούς βιομηχανικούς τομείς. Αυτή η διπλωματική εργασία προτείνει μία προσέγγιση για πρόβλεψη της κατάστασης υγείας του εξοπλισμού σε πραγματικό χρόνο χρησιμοποιώντας τη διαδικασία εξαγωγής χαρακτηριστικών στον τομέα του χρόνου (time-domain features extraction), ένα νευρωνικό δίκτυο Long-Short Term Memory (LSTM) και τον αλγόριθμο ανίχνευσης ανωμαλιών με Bayesian λογική (Bayesian Online Changepoint Detection). Η προτεινόμενη προσέγγιση έχει εφαρμοστεί σε δεδομένα από μία πραγματική βιομηχανία επεξεργασίας μετάλλου και πραγματοποιήθηκαν εκτενή πειράματα πάνω σε αυτά.

Σε αυτή τη διπλωματική εργασία επίσης διεξήχθησαν πειράματα για εκτίμηση της κατάστασης υγείας του εξοπλισμού σε πραγματικό χρόνο χρησιμοποιώντας τη διαδικασία εξαγωγής χαρακτηριστικών στον τομέα του χρόνου (time-domain features extraction) και τον αλγόριθμο ανίχνευσης ανωμαλιών με Bayesian λογική (Bayesian Online Changepoint Detection) για την ίδια εφαρμογή. Τέλος, παρουσιάζονται τα αποτελέσματα και τα συμπεράσματα από την προτεινόμενη προσέγγιση και ολόκληρη την πειραματική διαδικασία.

Λέξεις Κλειδιά

Προβλεπτική ανάλυση, βαθιά μηχανική μάθηση, ανίχνευση σημείου αλλαγής, πρόγνωση, μηχανική μάθηση, προβλεπτική συντήρηση, βιομηχανία 4.0

Abstract

Due to the emergence of sensing technology, a large number of sensors is used to monitor the health state of manufacturing equipment, thus enhancing the capabilities of predicting abnormal behaviors in (near) real-time. However, existing algorithms in predictive maintenance suffer from several limitations related to their scalability, efficiency, and reliability preventing their wide application to various industries. This diploma thesis proposes an approach for real-time prediction of the equipment health state using time-domain features extraction, Long Short-Term Memory (LSTM) Neural Networks, and Bayesian Online Changepoint Detection (BOCD). The proposed approach is applied to a real-life case in the steel industry and extensive experiments are performed.

In this diploma thesis also are performed experiments for real-time estimation of the equipment health state using time-domain features extraction and Bayesian Online Changepoint Detection (BOCD) for the same use case. Finally, is discussed the results and the conclusions drawn from the proposed approach and the whole experimentation procedure.

Keywords

Predictive analytics, deep learning, changepoint detection, prognosis, machine learning, predictive maintenance, Industry 4.0

Ευχαριστίες

Θα ήθελα, καταρχάς, να ευχαριστήσω τον καθηγητή κ. Μέντζα για την επίβλεψη αυτής της διπλωματικής εργασίας και για την ευκαιρία που μου έδωσε να την εκπονήσω στο εργαστήριό του. Επίσης, θα ήθελα να ευχαριστήσω τον Αλέξανδρο Μπουσδέκη και την Κατερίνα Λεπενιώτη για την ιδιαίτερα στενή και αποδοτική συνεργασία που είχαμε κατά την εκπόνηση της συγκεκριμένης εργασίας και για τη συνολική υποστήριξή τους. Τέλος, θα ήθελα να ευχαριστήσω την οικογένεια μου, τους φίλους μου και τους συμφοιτητές μου για την υποστήριξή τους όλα αυτά τα χρόνια.

Περιεχόμενα

Περίληψη	6
Abstract	7
Ευχαριστίες	8
1. Εισαγωγή.....	11
1.1 Αντικείμενο και Στόχοι διπλωματικής εργασίας.....	11
1.2 Διάρθρωση της διπλωματικής εργασίας	12
2. Βιβλιογραφική Επισκόπηση.....	13
2.1 Βιομηχανία 4.0	13
2.2 Προβλεπτική Συντήρηση	18
2.3 Ανίχνευση Ανωμαλιών και Διάγνωση Σφαλμάτων σε Πραγματικό Χρόνο	22
2.3.1 Μέθοδοι ανίχνευσης ανωμαλιών με Στατιστική Ανάλυση	23
2.3.2 Μέθοδοι ανίχνευσης ανωμαλιών με Μηχανική Μάθηση	25
3. Προτεινόμενη προσέγγιση	32
3.1 Long Short Term Memory Neural Network.....	34
3.1.1 LSTM, δομή και λειτουργία	36
3.1.2 Αλγόριθμος LSTM.....	40
3.2 Εξαγωγή χαρακτηριστικών (feature extraction).....	42
3.3 Bayesian Online Changepoint detection	46
3.3.1 Περιγραφή Bayesian αλγορίθμου	47
4. Εφαρμογή και Αξιολόγηση	52
4.1 Υλοποίηση.....	52
4.2 Περιγραφή συνόλου δεδομένων	53
4.3 Αξιολόγηση της Προτεινόμενης Προσέγγισης.....	63
4.3.1 Διάγνωση αλλαγής κατάστασης της υγείας του εξοπλισμού	63
4.3.1.1 Πείραμα 1: Online Bayesian Changepoint Detection	63

4.3.1.2 Πείραμα 2: Feature Extraction – Online Bayesian Changepoint Detection	75
4.3.2 Πρόγνωση αλλαγής κατάστασης της υγείας του εξοπλισμού	83
4.3.2.1 Πείραμα 3: Online Bayesian Changepoint Detection	84
4.3.2.2 Πείραμα 4: Feature Extraction - Online Bayesian Changepoint	91
5. Συμπεράσματα και Μελλοντική Εργασία.....	98
Βιβλιογραφία.....	100

1. Εισαγωγή

1.1 Αντικείμενο και Στόχοι διπλωματικής εργασίας

Με την εισαγωγή της Βιομηχανίας 4.0, η προβλεπτική συντήρηση είναι μια διαδικασία ιδιαίτερου και ανερχόμενου ενδιαφέροντος τόσο σε βιβλιογραφικό όσο και σε πρακτικό επίπεδο. Αυτό συμβαίνει λόγω του κέρδους που μπορεί να έχει μία βιομηχανική μονάδα σε οικονομικό επίπεδο αλλά και σε επίπεδο αξιοπιστίας και ανταγωνιστικότητας. Μέσω αυτής της σκοπιάς, η ανάγκη για παρακολούθηση της κατάστασης λειτουργίας ενός εξοπλισμού είναι πολύ σημαντική με αποτέλεσμα την αυξημένη χρήση αισθητήρων. Ο επόμενος στόχος είναι η ανίχνευση ανωμαλιών στη λειτουργία του εξοπλισμού σε πραγματικό χρόνο στο πλαίσιο της προβλεπτικής συντήρησης.

Εκτός από τα παραπάνω, η τεχνολογική πρόοδος που έχει επιτευχθεί είναι η βάση για την πρόβλεψη της κατάστασης λειτουργίας του εξοπλισμού ώστε να ενισχυθεί η εφαρμογή της προβλεπτικής συντήρησης. Η προσέγγιση αυτή απαιτεί τη χρήση αλγορίθμων μηχανικής μάθησης έτσι ώστε να είναι εφικτή η διαχείριση περίπλοκων και μη γραμμικών εισόδων, όπως είναι τα δεδομένα που καταγράφονται μέσω των αισθητήρων σε μία βιομηχανική μονάδα καθώς εμπεριέχουν αρκετό θόρυβο. Αυτός είναι ένας περιορισμός των παραπάνω αλγορίθμων και γι' αυτό το λόγο στην προτεινόμενη προσέγγιση χρησιμοποιείται η μέθοδος της βαθιάς μηχανικής μάθησης καθώς και μία διαδικασία εξαγωγής χαρακτηριστικών.

1.2 Διάρθρωση της διπλωματικής εργασίας

Η παρούσα διπλωματική εργασία οργανώνεται σε πέντε κεφάλαια.

Στο **Κεφάλαιο 1** παρουσιάζεται το αντικείμενο της διπλωματικής εργασίας καθώς και η διάρθρωση του κειμένου της.

Στο **Κεφάλαιο 2** αναλύεται το θεωρητικό υπόβαθρο που απαιτείται για την κατανόηση της μετέπειτα υλοποίησης και ανάλυσης, βασισμένο στην υπάρχουσα βιβλιογραφία.

Στο **Κεφάλαιο 3** παρουσιάζεται σε βάθος ο τρόπος λειτουργίας των βασικών αλγορίθμων που χρησιμοποιήθηκαν στην προτεινόμενη προσέγγιση και η παραμετροποίηση που έγινε για τις ανάγκες της παρούσας εργασίας.

Στο **Κεφάλαιο 4** περιγράφεται αρχικά η διαδικασία συλλογής δεδομένων και έπειτα η πειραματική διαδικασία και τα αποτελέσματά της.

Στο **Κεφάλαιο 5** καταλήγουμε σε συμπεράσματα και προτείνουμε μελλοντικές επεκτάσεις πάνω στο αντικείμενο της εργασίας μας.

2. Βιβλιογραφική Επισκόπηση

2.1 Βιομηχανία 4.0

Ο κόσμος της βιομηχανίας διαρκώς υποστηρίζεται ως προς την ανάπτυξή του από κάθε τεχνολογική και επιστημονική πρόοδο που λαμβάνει χώρα σε όλον τον κόσμο. Από την οπτική της τεχνολογικής εξέλιξης υπάρχουν τέσσερις βιομηχανικές επαναστάσεις που μπορούν να διακριθούν ως προς το αντικείμενό τους και τον χρόνο που εκτυλίχθηκαν. Η πρώτη είχε ως αποτέλεσμα την εισαγωγή του νερού και της πίεσης του ατμού στις βιομηχανικές εγκαταστάσεις ενώ η δεύτερη εισήγαγε τον ηλεκτρισμό στην παραγωγική διαδικασία βοηθώντας επιπλέον στον διαμοιρασμό των εργασιών σε μία βιομηχανική εγκατάσταση (Bousdekis, 2018). Χρονικά αναφέρονται στην περίοδο από το τέλος του 18^{ου} αιώνα έως τις αρχές της δεκαετίας του 1970, όπου και τοποθετείται η αρχή της τρίτης βιομηχανικής επανάστασης (Veza, Mladineo, & Peko, 2015).

Κατά την τρίτη βιομηχανική επανάσταση, η τεχνολογία της πληροφορίας και η χρήση των ηλεκτρονικών υπήρξε σε κάθε είδους βιομηχανική ανάπτυξη και επιχείρηση με σκοπό να ενισχύσει την αυτοματοποίηση πολλών λειτουργιών. Ο υπολογιστής λοιπόν ήταν το κέντρο ενδιαφέροντος εκείνης της περιόδου και όλα όσα μπορούσε εκείνος να προσφέρει. Στην πρώτη δεκαετία του 20^{ου} αιώνα παρουσιάζεται η τέταρτη βιομηχανική επανάσταση ή αλλιώς στην Βιομηχανία 4.0, όπως ονομάστηκε, όπου το κέντρο του ενδιαφέροντος δεν είναι ο υπολογιστής πια, αλλά το διαδίκτυο, το οποίο διευρύνει τους ορίζοντες στον τομέα της βιομηχανίας αποκτώντας ένα νέο υψηλότερο επίπεδο ποιότητας στη λειτουργία του και στο αποτέλεσμα που παράγει (Bousdekis, 2018). Στα σχήματα 1 και 2 παρουσιάζονται με μία πυραμίδα η δομή της τρίτης βιομηχανικής επανάστασης (βιομηχανίας 3.0) και με ένα πιο σύνθετο σχεδιάγραμμα τα

συστατικά μέρη της βιομηχανίας 4.0 (Plattform Industrie 4.0, 2021) και η μεταξύ τους σύνδεση αντίστοιχα.



Σχήμα 1: Βιομηχανία 3.0.



Σχήμα 2: Βιομηχανία 4.0.

Η τέταρτη βιομηχανική επανάσταση χαρακτηρίζεται από την εισαγωγή του διαδικτύου των πραγμάτων (Internet of Things - IoT) στη βιομηχανία προωθώντας την αμφίδρομη επικοινωνία μεταξύ διαφορετικών αντικειμένων σε πραγματικό χρόνο με έναν ασφαλή και αξιόπιστο τρόπο. Βασικός σκοπός της είναι η δημιουργία ενός περιβάλλοντος, το οποίο να είναι κατάλληλο για επεξεργασία δεδομένων σε πραγματικό χρόνο, να είναι έξυπνο, αυτόνομο και ικανό να ανταλλάσσει και να χρησιμοποιεί εξωγενείς πληροφορίες. Προκειμένου να πραγματοποιηθούν όλα τα παραπάνω, ο σχεδιασμός της Βιομηχανίας 4.0 βασίζεται σε μία από τις πιο πρόσφατες καινοτομίες, αυτή της δημιουργίας δικτύων μεταξύ διαδικτυακών και φυσικών

αντικειμένων (cyber-physical systems - CPS). Τα φυσικά αντικείμενα αποτελούνται από αισθητήρες, πλατφόρμες για την εποπτεία οποιασδήποτε λειτουργίας και υπολογιστές, τα οποία συνεργάζονται και επικοινωνούν μεταξύ τους προκρίμενου να συλλέγουν και να παρέχουν δεδομένα στα αντικείμενα του διαδικτύου. Τα δεύτερα με τη σειρά τους χρησιμοποιούνται για τη διαχείριση και την επεξεργασία αυτών των δεδομένων καθώς και για τη λήψη αποφάσεων (Angelopoulos, Michailidis, Nomikos, Trakadas, Hatziefremidis, Voliotis, & Zahariadis, 2020).

Τα δίκτυα μεταξύ διαδικτυακών και φυσικών αντικειμένων επιτρέπουν στα μηχανήματα που είναι μέρη αυτών να προσαρμόζουν τη συμπεριφορά τους στις εντολές που τους δίνονται σε πραγματικό χρόνο και στις καταστάσεις λειτουργίας τους κάνοντας παράλληλα βελτιστοποίηση στην λειτουργία τους και επαναπροσδιορισμό των παραμέτρων τους. Επιπλέον το γεγονός ότι λαμβάνονται πληροφορίες από έναν μεγάλο όγκο ετερογενών δεδομένων είναι το κλειδί στην τεχνολογική εξέλιξη της Βιομηχανίας 4.0, παρέχοντας ευελιξία στα δίκτυα που δημιουργούνται (Bousdekis, Lepenioti, Ntalaperas, Vergeti, Apostolou, & Boursinos, 2019).

Ένα από τα πιο σημαντικά και ενδιαφέροντα χαρακτηριστικά της Βιομηχανίας 4.0, όπως αναφέρθηκε, είναι η εισαγωγή του διαδικτύου των πραγμάτων όπως και των δικτύων που αναπτύσσονται μεταξύ διαδικτυακών και φυσικών αντικειμένων στον τομέα αυτό καθώς γίνεται εφικτή η ψηφιοποίηση όλων των διαδικασιών και η σύνδεση όλων των επιμέρους τμημάτων της μονάδας μεταξύ τους. Σαν αποτέλεσμα η κάθε βιομηχανική μονάδα αποκτά ευελιξία και περισσότερες δυνατότητες ώστε να είναι περισσότερο ανταγωνιστική όπως επίσης να εξελίσσεται στο χρόνο και να ακολουθεί τις τρέχουσες τεχνολογίες (Bousdekis, Apostolou, & Mentzas, 2019).

Η ευελιξία που παρέχεται κάνει πιο αποτελεσματική την παραγωγική διαδικασία. Πολλές φορές εκείνη αποτελείται από επιμέρους βήματα τα οποία μπορούν να συντονιστούν με τον βέλτιστο τρόπο, όταν αυτά ελέγχονται και είναι συνδεδεμένα με ψηφιακό τρόπο. Επίσης ο σχεδιασμός του φορτίου αλλά και της λειτουργίας του κάθε μηχανήματος βελτιστοποιείται μέσω της παραπάνω διαδικασίας. Ένα ακόμα χαρακτηριστικό παράδειγμα της ευελιξίας της είναι ο κατακερματισμός της παραγωγικής διαδικασίας σε επιμέρους κομμάτια με τέτοιο τρόπο ώστε να είναι αυτοτελή και να μπορούν να συνδυαστούν κατάλληλα ώστε να παραχθεί διαφορετικό αποτέλεσμα κάθε φορά ανάλογα με τις εκάστοτε ανάγκες. Αυτό θα έχει ως αποτέλεσμα

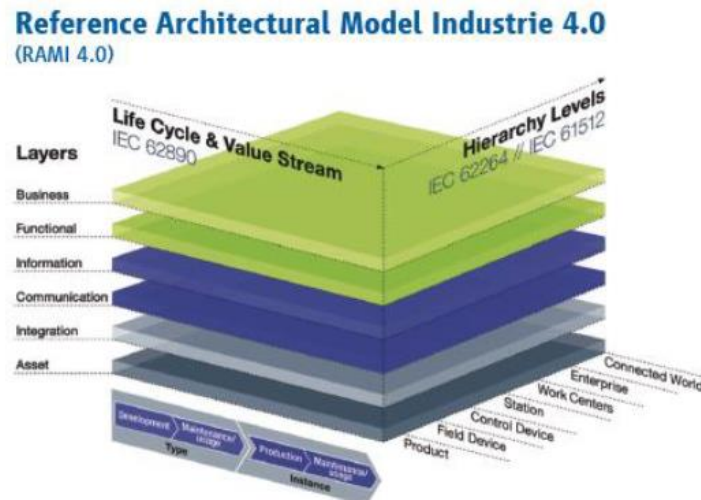
την αύξηση της παραγωγικότητας και της αποτελεσματικότητας της μονάδας καθώς θα μπορέσουν να δημιουργηθούν εξατομικευμένα προϊόντα με χαμηλό κόστος.

Με άλλα λόγια, η βιομηχανία που είχε μέχρι στιγμής συγκεντρωτικά συστήματα ελέγχου αλλάζει μορφή και ο έλεγχος της παραγωγικής διαδικασίας βασίζεται πλέον στη λογική της αποκεντρωτικής ευφυΐας (decentralized intelligence) (Bousdekis, 2018). Παράλληλα, λόγω των δικτύων μεταξύ διαδικτυακών και φυσικών αντικειμένων, που κυριαρχεί στη συγκεκριμένη περίοδο, το κάθε μέλος μιας βιομηχανικής μονάδας μπορεί να προσαρμόσει τη λειτουργία του ανάλογα με τις εντολές που του δίνονται σε πραγματικό χρόνο και με στόχο τη βελτιστοποίηση της απόδοσής του. Η βιομηχανία 4.0 εστιάζει κατά κύριο λόγο στην ικανότητα των συστημάτων να προσλαμβάνουν μεγάλο όγκο δεδομένων, να τις επεξεργάζονται, να εξάγουν χρήσιμα συμπεράσματα για εκείνα και να προσαρμόζουν τη λειτουργία τους ανάλογα. Συγχρόνως είναι σημαντικό να αποθηκεύουν αυτή τη πληροφορία που έχει κερδηθεί μέσω της εμπειρίας για μελλοντική χρήση και βελτιστοποίηση του συστήματος.

Η μεγαλύτερη πρόκληση που αντιμετωπίζει η βιομηχανία 4.0 είναι η διαχείριση ενός τεράστιου όγκου ετερογενών δεδομένων που προκύπτουν από ολόκληρη την αλυσίδα της παραγωγικής διαδικασίας (Μεγάλα Δεδομένα – Big Data). Η επεξεργασία τους και η περαιτέρω ανάλυσή τους με αποτέλεσμα την εξαγωγή χρήσιμης πληροφορίας είναι ένα από τα πιο χρήσιμα εργαλεία για την βελτιστοποίηση της λειτουργίας μιας βιομηχανίας. Ένα έξυπνο και ευέλικτο παραγωγικό σύστημα μαζί με τα κατάλληλα εργαλεία είναι θεμέλιος λίθος για την επιτυχή εφαρμογή διασυνδεδεμένης και κατανεμημένης παραγωγής στα «έξυπνα» εργοστάσια.

Προκειμένου να αναπαρασταθούν όλα τα παραπάνω χαρακτηριστικά καθώς και ο τρόπος της μεταξύ τους σύνδεσης δημιουργήθηκε ένα τρισδιάστατο μοντέλο, το RAMI 4.0, αναπαριστώντας τη συγκεκριμένη αρχιτεκτονική. Το μοντέλο αυτό εστιάζει ιδιαίτερα στη διάρκεια ζωής του προϊόντος και στην συνολική αξία που εκείνο αποκτά καθώς είναι τα πιο σημαντικά κριτήρια για την παραγωγή του με βάση τη σύγχρονη μηχανική. Τα δύο αυτά μεγέθη παρουσιάζονται από τον ένα οριζόντιο άξονα του μοντέλου. Ο δεύτερος οριζόντιος άξονας περιέχει τα συστατικά μέρη που συνθέτουν τη Βιομηχανία 4.0 και η διάταξή τους βασίζεται στο βαθμό λειτουργίας τους μέσα σε αυτό το πλαίσιο. Τέλος, στην κατακόρυφη διεύθυνση αναπαρίστανται τα διαφορετικά επίπεδα που απαρτίζουν το μοντέλο, όπως είναι αυτό της επικοινωνίας και της

λειτουργικότητας (Bousdekis, 2018). Με πιο γραφικό τρόπο φαίνεται η αρχιτεκτονική RAMI 4.0 στο σχήμα 3.



Σχήμα 3: Η αρχιτεκτονική RAMI 4.0.

Η ανάλυση και η αξιοποίηση των δεδομένων που συλλέγονται σε πραγματικό χρόνο είναι μία από τις σημαντικότερες καινοτομίες που προσφέρει η Βιομηχανία 4.0. Έχει ιδιαίτερο ενδιαφέρον καθώς εισάγει την έννοια της προβλεπτικής συντήρησης, η οποία θα αναλυθεί με περισσότερη λεπτομέρεια παρακάτω, μέσω της γίνεται η ανίχνευση σφαλμάτων, πρόβλεψη αυτών και ορίζονται οι απαραίτητες ενέργειες ώστε να μην οδηγηθεί το αντικείμενο μελέτης σε σφάλμα. Αξιοσημείωτη επίσης είναι η δυνατότητα που προσφέρει ώστε να προσδιοριστεί ο χρόνος μετά τον οποίο το αντικείμενο θα οδηγηθεί σε σφάλμα ή σε περάτωση της λειτουργίας του. Με αυτόν τον τρόπο η παραγωγική διαδικασία γίνεται πιο αποτελεσματική και επιπλέον μπορεί να καθοριστεί από την φάση του σχεδιασμού της παραγωγής ποια υλικά μπορούν να επαναχρησιμοποιηθούν ή να ανακυκλωθούν (Bousdekis, Lepenioti, Ntalaperas, Vergeti, Apostolou, & Boursinos, 2019).

2.2 Προβλεπτική Συντήρηση

Με το πέρασμα των τελευταίων δεκαετιών, οι λειτουργίες συντήρησης έχουν αλλάξει δραστικά με την εξέλιξη της τεχνολογίας. Η συντήρηση ορίζεται ως ένα σύνολο από ενέργειες ή δραστηριότητες που λαμβάνουν χώρα με σκοπό να επαναφέρουν ένα αντικείμενο στην αρχική του κατάσταση έτσι ώστε να επιτελεί τις λειτουργίες για τις οποίες είναι σχεδιασμένο. Στη σύγχρονη βιομηχανία συνεχώς απαιτείται υψηλός βαθμός αξιοπιστίας στην παραγωγική διαδικασία, χαμηλό περιβαλλοντολογικό ρίσκο και υψηλή ασφάλεια ως προς τον άνθρωπο. Παράλληλα η ποιότητα του παραγόμενου προϊόντος όπως και της διαδικασίας με την οποία παράγεται θα πρέπει να είναι σταθερή και υψηλή. Η συντήρηση στη βιομηχανία έχει αποκτήσει ιδιαίτερο ενδιαφέρον στην ακαδημαϊκή αλλά και στην βιομηχανική κοινότητα αποτελώντας αναπόσπαστο κομμάτι από την οργάνωση και διαχείριση των λειτουργιών μιας παραγωγικής αλυσίδας (Bousdekis, 2018).

Η τεχνολογική ανάπτυξη έχει αυξήσει την πολυπλοκότητα στον βιομηχανικό εξοπλισμό που χρησιμοποιείται αλλά και στα παραγωγικά συστήματα. Οι οικονομικές συνέπειες που μπορούν να προκληθούν από έναν αναπάντεχο τερματισμό λειτουργίας του εξοπλισμού έστω και για μία ημέρα ανέρχονται στις 100.000 με 200.000 ευρώ. Η αξιοπιστία λειτουργίας του βιομηχανικού εξοπλισμού και των παραγωγικών συστημάτων γενικότερα είναι υψίστης σημασίας καθώς επηρεάζει σημαντικά την κερδοφορία και την ανταγωνιστικότητα της βιομηχανικής μονάδας. Γι' αυτό το λόγο δίνεται ιδιαίτερη έμφαση στην αποτελεσματικότητα της συντήρησης των μηχανημάτων, των συστημάτων παραγωγής και των διαδικασιών που γίνονται στη παραγωγική μονάδα. Η συντήρηση στον τομέα της βιομηχανίας χωρίζεται σε τρεις κατηγορίες. Η πρώτη ονομάζεται συντήρηση βλάβης και αναφέρεται στην διαδικασία όπου μία σειρά ενεργειών (αντικατάσταση ή επιδιόρθωση) πραγματοποιείται στον εξοπλισμό ώστε να γυρίσει στην αρχική κατάσταση λειτουργίας του αφού συμβεί η βλάβη. Η επόμενη κατηγορία βασίζεται σε χρονοδιαγράμματα, τα οποία ορίζουν συγκεκριμένα χρονικά διαστήματα που πρέπει να γίνει η συντήρηση του εξοπλισμού έτσι ώστε να ελαχιστοποιούνται το κόστος που προκαλείται από τις βλάβες και το πλήθος αυτών καθώς και να αυξάνεται η ποιότητα του προϊόντος. Η τελευταία κατηγορία είναι εκείνη της συντήρησης που βασίζεται στην κατάσταση του συστήματος τη δεδομένη χρονική στιγμή. Πρόκειται για μία τακτική όπου προσπαθεί

να αποφύγει περιττές ενέργειες συντήρησης, να μειώσει την αβεβαιότητα αυτών των διαδικασιών και παράλληλα να τις εκτελεί μόνο όταν υπάρχουν ενδείξεις μη φυσιολογικής λειτουργίας του εξοπλισμού. Η παρακολούθηση της κατάστασης λειτουργίας του εξοπλισμού έγινε εφικτή μέσω της ανάπτυξης κατάλληλων τεχνολογιών και εξοπλισμού με αισθητήρες, όπου μπορούν να μετρούν ένα επαρκές πλήθος παραμέτρων σε υψηλή συχνότητα για την μετέπειτα ανάλυση. Με αυτό τον τρόπο είναι δυνατό να παρακολουθείται σε πραγματικό χρόνο η κατάσταση λειτουργίας του εξοπλισμού και με βάση αυτή να αποφασίζονται οι δράσεις συντήρησης με τον βέλτιστο τρόπο.

Η προβλεπτική συντήρηση είναι η εξέλιξη ουσιαστικά της παραπάνω κατηγορίας συντήρησης. Εμπεριέχει τα βασικά χαρακτηριστικά της αλλά παράλληλα χαρακτηρίζεται από την χρήση αλγορίθμων με στόχο την ανίχνευση και την πρόβλεψη της παρούσας και της μελλοντικής κατάστασης του εξοπλισμού. Παρ' όλο που αρχικά ήταν δύο διαφορετικές τεχνικές, καθώς η δεύτερη βασιζόταν στην εμπειρία των ειδικών και στις προδιαγραφές των κατασκευαστών αποκλειστικά, αργότερα η προβλεπτική συντήρηση χρησιμοποιεί για ανάλυση τα δεδομένα που παράγονται από τους σένσορες σε πραγματικό χρόνο (Bousdekis, 2018).

Με την εισαγωγή της Βιομηχανίας 4.0 δημιουργήθηκε η ανάγκη για συνεχή παρακολούθηση της κατάστασης λειτουργίας του εξοπλισμού ώστε να είναι εφικτή η ανίχνευση ανωμαλιών ή παρεκκλίνουσας συμπεριφοράς από την αναμενόμενη σε πραγματικό χρόνο. Επομένως η προτεραιότητα των βιομηχανιών είναι πλέον η προβλεπτική συντήρηση καθώς είναι ένας τρόπος για την ομαλότερη και αποτελεσματικότερη λειτουργία του εξοπλισμού. Στον τομέα αυτό μία βλάβη ενός σημαντικού μηχανήματος μπορεί να προκαλέσει σημαντική δυσλειτουργία στην παραγωγική διαδικασία, χρόνο και κόστος για την επισκευή και επαναλειτουργία του. Γι' αυτό το λόγο είναι πολύ σημαντική η συμβολή της προβλεπτικής συντήρησης αφού είναι πιο προσοδοφόρα η διόρθωση ενός επερχόμενου σφάλματος παρά η επισκευή του εξοπλισμού αφού έχει συμβεί η βλάβη.

Η προβλεπτική συντήρηση είναι μία απαραίτητη πτυχή της Βιομηχανίας 4.0 καθώς προηγείται της βλάβης ενός εξοπλισμού και εμπεριέχει διορθωτικές κινήσεις πριν από αυτή. Δεν αναφέρεται, δηλαδή, σε επιδιόρθωση του εξοπλισμού έπειτα της βλάβης αλλά ούτε σε μία προγραμματισμένη διαδικασία συντήρησης με βάση το χρονικό διάστημα που ορίζει ο κατασκευαστής του. Αντίθετα, η διαδικασία αυτή χρησιμοποιεί

ένα μεγάλο όγκο δεδομένων (Μεγάλα Δεδομένα) που προκύπτουν είτε από καταγραφή των αισθητήρων σε πραγματικό χρόνο είτε από ιστορικά δεδομένα, με σκοπό την ανάλυσή τους και εν τέλει την ανίχνευση ανωμαλιών στη λειτουργία του εξοπλισμού. Βασικό μέλημα του εγχειρήματος αυτού είναι η πρόβλεψη της μελλοντικής κατάστασης του εξοπλισμού καθώς και πιθανές επερχόμενες βλάβες σε αυτόν προκειμένου να ελαχιστοποιήσει ή τουλάχιστον να μετριάσει το αντίκτυπο της μελλοντικής βλάβης.

Η τεχνική αυτή προσφέρει πολλά πλεονεκτήματα καθώς η βιομηχανική μονάδα γίνεται αρχικά πιο ανταγωνιστική και αποτελεσματική. Έπειτα μεγιστοποιείται η διάρκεια ζωής του εξοπλισμού, μειώνοντας παράλληλα τις φορές όπου ο εξοπλισμός αποσυνδέεται από την παραγωγική αλυσίδα και επομένως το κόστος συντήρησης. Συνεχίζοντας βελτιώνεται η ασφάλεια λειτουργίας όλων των μηχανημάτων που συμμετέχουν στο δίκτυο λειτουργίας της μονάδας και γενικότερα η αξιοπιστία της παραγωγικής διαδικασίας. Παράλληλα γίνεται καλύτερη χρήση των πρώτων υλών που χρησιμοποιούνται και καλύτερος προγραμματισμός των εργασιών που πρέπει να γίνουν. Συνοψίζοντας, ένα σημαντικό πλεονέκτημα της προβλεπτικής συντήρησης είναι η γνώση σε πραγματικό χρόνο της κατάστασης όλης της παραγωγικής διαδικασίας και η συνεχόμενη απόκτηση εμπειρίας για το πώς εκείνη λειτουργεί και μπορεί να βελτιωθεί (Bousdekis, Apostolou, & Mentzas, 2019).

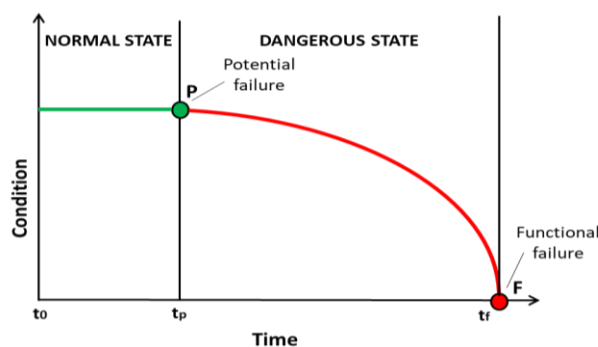
Η σύγχρονη μορφή της διαχείρισης της συντήρησης διαμορφώνει την προβλεπτική συντήρηση ικανή να παρέχει πολλές δυνατότητες στην κατανόηση της φυσικής λειτουργίας του εξοπλισμού και επομένως στον προσδιορισμό της χρήσιμης διάρκειας ζωής ενός συστήματος. Αυτό επιτυγχάνεται αναγνωρίζοντας μοτίβα που παρουσιάζουν τα διαθέσιμα δεδομένα από διάφορες πηγές με δυναμικό τρόπο. Ο απώτερος στόχος είναι οι προτάσεις συντήρησης που θέτονται να εκμεταλλεύονται στο έπακρο το πλαίσιο της προβλεπτικής συντήρησης και τις προόδους που εκείνη κάνει (Bousdekis, 2018).

Η διαδικασία και το νόημα της προβλεπτικής συντήρησης μπορεί να γίνει πιο κατανοητή μέσω του διαγράμματος που απεικονίζει την καμπύλη P-F και φαίνεται στο σχήμα 4 . Η καμπύλη αυτή είναι σε συνάρτηση με το χρόνο και χωρίζεται σε δύο στάδια. Στο πρώτο απεικονίζεται η ομαλή λειτουργία του εξοπλισμού ενώ στο δεύτερο η κατάσταση όπου ξεκινά να εμφανίζεται μία δυσλειτουργία σε αυτόν και εν τέλει να οδηγείται σε κάποιο σφάλμα. Με βάση την παραπάνω καμπύλη συμπεραίνεται ότι η

βλάβη και επομένως η διακοπή της λειτουργίας του εξοπλισμού είναι μία διαδικασία που διαρκεί στο χρόνο και όχι ένα ακαριαίο γεγονός. Το σημείο P στο διάγραμμα συμβολίζει τη χρονική στιγμή όπου διαπιστώθηκε ότι ο εξοπλισμός παρουσιάζει δυσλειτουργία ενώ το σημείο F συμβολίζει την βλάβη που όντως συνέβη. Στην πραγματικότητα το δεύτερο σημείο προκύπτει από ιστορικά δεδομένα τα οποία δημιουργούν μία κατανομή από πιθανές χρονικές στιγμές εκδήλωσης βλάβης για τη συγκεκριμένη μορφή που μελετάται.

Σκοπός της παραγωγικής διαδικασίας σε μία βιομηχανία είναι η αποφυγή αυτού του σημείου F και βασιζόμενη σε αυτό, προγραμματίζεται η συντήρηση των επιμέρους εξοπλισμών. Η προβλεπτική συντήρηση αντίθετα στοχεύει στην μετακίνηση του διαστήματος P-F πιο κοντά στο σημείο όπου ξεκινά η δυσλειτουργία του εξοπλισμού, δηλαδή στην αρχή του δεύτερου σταδίου του διαγράμματος. Αυτό μπορεί να επιτευχθεί χρησιμοποιώντας αισθητήρες και συστήματα επεξεργασίας μεγάλου όγκου δεδομένων που προκύπτουν από τους αισθητήρες σε πραγματικό χρόνο.

Ο προσδιορισμός του σημείου όπου γίνεται η αλλαγή από την ομαλή λειτουργία στη μη ομαλή επιτρέπει την πρόβλεψη της μελλοντικής συμπεριφοράς του εξοπλισμού καθώς και τη λήψη αποφάσεων για τις εναλλακτικές δράσεις που μπορούν να γίνουν προκειμένου να αποφευχθεί το σφάλμα. Με αυτό τον τρόπο περιορίζονται οι επιπτώσεις στην παραγωγική διαδικασία και βελτιστοποιούνται οι διαδικασίες συντήρησης (Bousdekis, Apostolou, & Mentzas, 2019). Παρ' όλα αυτά η εφαρμογή της προβλεπτικής συντήρησης μέσω των αλγορίθμων που χρησιμοποιεί, αντιμετωπίζει αρκετές δυσκολίες λόγω της πολυπλοκότητας και της δυναμικότητας που χαρακτηρίζουν τον χώρο της βιομηχανίας. Η βασικότερη πρόκληση αυτής της μεθόδου είναι ο τεράστιος όγκος δεδομένων, του οποίου η φύση αλλάζει στην πάροδο του χρόνου και η περίπλοκη συσχέτιση που δημιουργείται μεταξύ τους (Bousdekis, Lepenioti, Ntalaperas, Vergeti, Apostolou, & Boursinos, 2019).



Σχήμα 4: Κατάσταση λειτουργίας του εξοπλισμού μέσω καμπύλης P-F.

2.3 Ανίχνευση Ανωμαλιών και Διάγνωση Σφαλμάτων σε Πραγματικό Χρόνο

Όπως έχει αναλυθεί και παραπάνω, ο τομέας της βιομηχανίας είναι ένας από τους πολλούς στους οποίους έχει εισαχθεί η έννοια του διαδικτύου των πραγμάτων σε όλες τις επιμέρους λειτουργίες του. Έτσι πλέον κάθε μέρος του συστήματος που συμμετέχει σε κάθε λειτουργία συνοδεύεται από έναν τεράστιο όγκο παραγόμενων δεδομένων, ο οποίος περιγράφει την φυσιολογική λειτουργία του αλλά εμπεριέχει και ανωμαλίες σε αυτή. Η δυνατότητα της ανίχνευσης μιας ανωμαλίας στη λειτουργία ενός εξοπλισμού ή κάποιου συστήματος γενικότερα μπορεί να έχει τεράστιο αντίκτυπο στη συνολική λειτουργία του.

Η διαδικασία της ανίχνευσης ανωμαλιών είναι μια σύνθετη επεξεργασία καθώς εξαρτάται από πολλούς παράγοντες. Αρχικά, το κλειδί για αυτή τη διαδικασία είναι ο καθορισμός του ακριβούς ορίου μεταξύ της ομαλής και της μη ομαλής λειτουργίας, το οποίο και παρουσιάζει τη μεγαλύτερη δυσκολία στην ανάλυση αυτή. Προκειμένου να επιλεγεί η κατάλληλη τεχνική ανίχνευσης ανωμαλιών θα πρέπει να σταθμιστούν αρκετοί παράγοντες. Ένας σημαντικός παράγοντας για την επιλογή αυτή είναι η φύση των παραγόμενων δεδομένων, αν δηλαδή είναι δυαδικής μορφής, αν είναι συνεχή στο χρόνο ή διακριτές τιμές καθώς και η σχέση με την οποία συνδέονται μεταξύ τους. Συνεχίζοντας θα πρέπει να είναι γνωστή η διαθεσιμότητα των δεδομένων που χρησιμοποιούνται για την εκπαίδευση των μοντέλων που θα χρησιμοποιηθούν για την ανίχνευση ανωμαλιών. Τέλος είναι ιδιαίτερης σημασίας ο προσδιορισμός του τύπου της παρεκκλίνουσας συμπεριφοράς. Πιο συγκεκριμένα θα πρέπει να προσδιοριστεί αν αναφέρεται σε ανωμαλία σημείου, μοτίβου ή αν η συγκεκριμένη συμπεριφορά είναι υπό συνθήκες.

Η ανωμαλία σημείου αναφέρεται στον εντοπισμό ενός σημείου του οποίου η τιμή διαφέρει από τις υπόλοιπες του συνόλου δεδομένων. Το είδος του συνόλου δεδομένων στο οποίο αναφέρεται η συγκεκριμένη ανωμαλία είναι αυτό όπου οι τιμές του έχουν ένα συγκεκριμένο εύρος και στη φυσιολογική λειτουργία δεν ξεπερνούν τη μέγιστη και την ελάχιστη τιμή που αυτό καθορίζει. Επομένως μία απότομη αύξηση ή μείωση κάποιας τιμής που παράλληλα ξεπερνά αυτά τα όρια μπορεί να περιγράψει μία μη φυσιολογική συμπεριφορά του εξοπλισμού ή της λειτουργίας που μελετάμε. Τέτοιου

είδους ανωμαλίες είναι προτιμότερο να εντοπίζονται πριν την επεξεργασία του συνόλου των δεδομένων και την ανάλυσή του.

Μία άλλη κατηγορία μορφής των δεδομένων είναι εκείνη που παρουσιάζει συγκεκριμένο και επαναλαμβανόμενο μοτίβο στην πάροδο του χρόνου εμπεριέχοντας και αυξομειώσεις στις τιμές τους. Οποιαδήποτε απόκλιση από αυτό το μοτίβο μπορεί να θεωρηθεί ως μία ανωμαλία στη λειτουργία της. Τέλος υπάρχουν και συμπεριφορές των δεδομένων οι οποίες θεωρούνται ανωμαλίες υπό συνθήκες. Ένα χαρακτηριστικό παράδειγμα είναι ότι η κυκλοφορική συμφόρηση στους δρόμους της Αθήνας είναι φυσιολογική συμπεριφορά στις ώρες αιχμής, όπως το πρωί ή το μεσημέρι, αλλά αργά το βράδυ δεν είναι φυσιολογική και αποτελεί μία ανωμαλία για την ροή της κυκλοφορίας. Ακολούθως στο συγκεκριμένο είδος δεν έχουν σημασία μόνο οι τιμές των δεδομένων αλλά και οι συνθήκες που τις ακολουθούν (Fahim, & Sillitti, 2019).

Χάρη στην γρήγορη ανάπτυξη της τεχνολογίας που αφορά τους αισθητήρες, χρησιμοποιούνται σε ένα ευρύ φάσμα εφαρμογών προκειμένου να συμβάλλουν στην παρακολούθηση της κατάστασης λειτουργίας ενός εξοπλισμού στη βιομηχανία. Τα συστήματα που συνήθως συμμετέχουν στην παραγωγική διαδικασία μιας μονάδας παρουσιάζουν σταδιακή απόκλιση από τη φυσιολογική λειτουργία και όχι ακαριαία βλάβη. Το γεγονός αυτό καθιστά εφικτή την πρόβλεψη της αποκλίνουσας συμπεριφοράς, καθώς υπάρχει ένα χρονικό διάστημα που μεσολαβεί από τη βλάβη. Στον τομέα της βιομηχανίας, ο σχεδιασμός και η ανάπτυξη μεθόδων με στόχο την ανίχνευση ανωμαλιών είναι ιδιαίτερης σημασίας καθώς μειώνουν τις πιθανότητες να συμβεί μία απροσδόκητη βλάβη του συστήματος (Fahim, & Sillitti, 2019). Όλα τα παραπάνω οδήγησαν στον προσανατολισμό πολλών ερευνητικών εργασιών σε μεθόδους που βασίζονται στην ανάλυση δεδομένων (data-driven methods) προκειμένου να ανιχνεύσουν και να προβλέψουν κάποια ανωμαλία στη λειτουργία του εξοπλισμού. Με βάση τη βιβλιογραφία η ανίχνευση ανωμαλιών σε μία λειτουργία μπορεί να γίνει με στατιστικές μεθόδους αλλά επίσης ιδιαίτερο ενδιαφέρον έχει η χρήση αλγορίθμων μηχανικής μάθησης (Fahim, & Sillitti, 2019).

2.3.1 Μέθοδοι ανίχνευσης ανωμαλιών με Στατιστική Ανάλυση

Τα δεδομένα που καταγράφονται από τους αισθητήρες σε έναν εξοπλισμό, πέρα από τα διάφορα μεγέθη που περιγράφουν, περιέχουν παράλληλα την πληροφορία του

χρόνου και της συχνότητας που τα συνοδεύουν. Σε σήματα που ανήκουν στον τομέα του χρόνου, όπως είναι η μέση τιμή, η τυπική απόκλιση ή η διακύμανση, η πληροφορία αυτή μπορεί να απεικονίσει την συμπεριφορά του συστήματος. Σε πιο σύνθετα συστήματα όμως απαιτείται ανάλυση και σε άλλα μεγέθη αλλά και σε μεγαλύτερο βάθος, προκειμένου να αποκτηθεί η επιθυμητή εικόνα του συστήματος. Ένα χαρακτηριστικό παράδειγμα που χρησιμοποιείται για εκτενέστερη ανάλυση είναι οι ιδιότητες που προκύπτουν από σήματα στον τομέα της συχνότητας, όπως ο μετασχηματισμός Fourier και μπορούν να αποδώσουν είτε από μόνες του είτε σε συνδυασμό με ιδιότητες που προκύπτουν στον χρόνο, πολύ χρήσιμη πληροφορία προκειμένου να κατανοηθεί η λειτουργία ενός συστήματος. Επομένως, μία στατιστική μέθοδος ανίχνευσης ανωμαλιών σημείου είναι εκείνη που βασίζεται στη χρονική συσχέτιση των δεδομένων (Temporal Logic). Ένας τομέας της βιομηχανίας στον οποίο έχει εφαρμοστεί είναι εκείνος των βενζινοκίνητων οχημάτων.

Τα βιομηχανικά συστήματα είναι περίπλοκα και περιέχουν ένα ευρύ φάσμα και μεγάλο πλήθος αισθητήρων, προκειμένου να καταγράφουν την λειτουργία του εξοπλισμού στον οποίο έχουν τοποθετηθεί και να παρέχουν με τον βέλτιστο τρόπο πρόβλεψη για τη μη φυσιολογική λειτουργία του. Για τέτοιου είδους προσεγγίσεις, έχει αποδειχτεί ότι οι μέθοδοι που βασίζονται στη συσχέτιση μεγεθών (Correlation Analysis) είναι οι πιο κατάλληλοι και αποτελεσματικοί για την εύρεση ανωμαλιών που υφίστανται υπό συνθήκες. Οι συγκεκριμένοι μέθοδοι μπορούν να απεικονίσουν την πραγματική κατάσταση λειτουργίας του εξοπλισμού καθώς οι συσχετισμοί που αναπτύσσονται και παρουσιάζονται, αντιπροσωπεύουν τους φυσικούς μηχανισμούς και τις συνθήκες της λειτουργίας του εξοπλισμού. Συνοψίζοντας, έχουν αρκετά πλεονεκτήματα σε σχέση με την απλή εφαρμογή μιας ανάλυσης σε πραγματικό χρόνο και έχει βρει εφαρμογή στους ηλεκτρικούς κινητήρες στα εργοστάσια. Με παρόμοιο τρόπο λειτουργεί και το μοντέλο density-based model, όπου χρησιμοποιείται προκειμένου να ανιχνεύσει ανωμαλίες σημείου στη λειτουργία που μελετά. Έχει εφαρμοστεί σε σύστημα παραγωγής ισχύος. Τελειώνοντας, μία ακόμα στατιστική μέθοδος ανάλυσης είναι η Markov chain, όπου ανιχνεύει ανωμαλίες σημείου και έχει εφαρμοστεί σε δεδομένα που προέρχονται από αισθητήρες πίεσης (Fahim, & Sillitti, 2019).

2.3.2 Μέθοδοι ανίχνευσης ανωμαλιών με Μηχανική Μάθηση

Λόγω των απαιτήσεων που δημιουργούνται στη σημερινή μορφή των τεχνολογιών η συνεχής συλλογή δεδομένων σε πραγματικό χρόνο και σε γρήγορο ρυθμό είναι αναγκαία για την περαιτέρω ανάλυση και ανίχνευση ανωμαλιών. Μία αλλαγή στην κατάσταση λειτουργίας μπορεί να συμβεί σε επίπεδο δευτερολέπτου ή ακόμα και σε χιλιοστό του δευτερολέπτου και αυτό έχει ως αποτέλεσμα την αναγκαιότητα για τη μικρή συχνότητα στην καταγραφή των δεδομένων. Παράλληλα η μεγάλη ταχύτητα του διαδικτύου αυξάνει εκθετικά τη διάθεση των δεδομένων σε πραγματικό χρόνο. Όλα τα παραπάνω δυσκολεύουν τη διαχείριση και την επεξεργασία των δεδομένων, καθώς ο όγκος τους είναι πολύ μεγάλος. Επιπλέον τα δεδομένα μπορεί να είναι δομημένα αλλά και μερικώς ή και καθόλου δομημένα, γεγονός που δυσχεραίνει ακόμα περισσότερο την περαιτέρω ανάλυσή τους. Παρ' όλα αυτά υπάρχουν αρκετά εργαλεία που μπορούν να πραγματοποιήσουν ανάλυση δεδομένων τέτοιων χαρακτηριστικών (Μεγάλα Δεδομένα - Big Data) σε πραγματικό χρόνο. Ο όρος Μεγάλα Δεδομένα είναι συνυφασμένος με την περιγραφή πληροφορίας από μία ροή δεδομένων και πλέον υπάρχει σε όλους τους τομείς, από τις επιχειρήσεις μέχρι τους διάφορους τομείς της επιστήμης και ο όγκος των διαθέσιμων δεδομένων αναμένεται να αυξάνεται κατά 40% κάθε χρόνο παγκοσμίως.

Στη σύγχρονη εποχή, εξαιτίας του μεγάλου όγκου δεδομένων και της ποικιλομορφίας τους λόγω των πολλών και διαφορετικών πηγών, ένα μεγάλο μέρος της βιομηχανίας έχει προσανατολιστεί στις διαδικασίες που προσφέρουν ανταπόκριση σε πραγματικό χρόνο. Επιπροσθέτως, λόγω του ότι τα περισσότερα δεδομένα προέρχονται από συνδεδεμένες συσκευές και αισθητήρες στο διαδίκτυο, είναι ιδιαίτερα κρίσιμη η λήψη αποφάσεων σε πραγματικό χρόνο. Όλα αυτά τα δεδομένα που συλλέγονται θα πρέπει να αποθηκευτούν και να επεξεργαστούν σε πραγματικό χρόνο προκειμένου να γίνει ανίχνευση ανωμαλιών σε αυτό το χρόνο και να λαμβάνεται η πραγματική κατάσταση λειτουργίας του συστήματος.

Οι βιομηχανικές εφαρμογές χαρακτηρίζονται από την ποικιλομορφία τους και το μεγαλύτερο μέρος αυτών καλούνται να διαχειριστούν Μεγάλα Δεδομένα. Γι' αυτό το λόγο οι αλγόριθμοι μηχανικής μάθησης βρίσκονται στο προσκήνιο της έρευνας καθώς μπορούν να διαχειριστούν δεδομένα με αυτά τα χαρακτηριστικά. Επομένως και η

ανίχνευση ανωμαλιών σε πραγματικό χρόνο με Μεγάλα Δεδομένα είναι μια εφαρμογή όπου απαιτείται η χρήση μηχανικής μάθησης καθώς θα επιφέρει καλύτερα αποτελέσματα ως προς την εκτέλεση της συγκεκριμένης λειτουργίας και την ακρίβεια του αποτελέσματός της. Ο τομέας της βιομηχανίας αντιμετωπίζει πολλές προκλήσεις λόγω των γρήγορων εξελίξεων της τεχνολογίας αλλά οι ανεπτυγμένες και υψηλού επιπέδου μέθοδοι ανίχνευσης ανωμαλιών μπορούν να ανταπεξέλθουν σε αυτές τις συνθήκες. Όλη η παραπάνω διαδικασία που περιεγράφηκε βρίσκει εφαρμογή σε πολλούς τομείς πέρα από την ανίχνευση ανωμαλιών στο βιομηχανικό τομέα, όπως τα κοινωνικά δίκτυα, η ανάλυση σε επίπεδο διαδικτύου, οι έξυπνες εφαρμογές οικιακής χρήσης και πολλά άλλα (Habeeb, Nasaruddin, Gani, Hashem, Ahmed, & Imran, 2019).

Η ανίχνευση ανωμαλιών σε δεδομένα που συλλέγονται και υφίστανται ανάλυση σε πραγματικό χρόνο εφαρμόζεται σε πολλές λειτουργίες μιας βιομηχανίας. Η πληροφορία που μπορεί να παρέχει η συγκεκριμένη διαδικασία είναι ιδιαίτερης σημασίας αλλά η αξιοπιστία της είναι ακόμα αμφιλεγόμενη. Στην ανάλυση σε πραγματικό χρόνο πολύ συχνά χρησιμοποιούνται οι στατιστικοί μέθοδοι λόγω της υπολογιστικής ευελιξίας που προσφέρουν. Παρ' όλα αυτά οι μέθοδοι αυτοί πολλές φορές έχουν περιορισμούς και γι' αυτό επιλέγονται άλλες τεχνικές για την ανίχνευση ανωμαλιών, όπου δεν απαιτούν προσδιορισμό επιπλέον παραμέτρων όπως απαιτούν οι στατιστικοί μέθοδοι.

Ο βασικός στόχος της μηχανικής μάθησης είναι το σύστημα στο οποίο εφαρμόζεται να μπορεί να μαθαίνει από το παρελθόν και το παρόν και να χρησιμοποιεί αυτή τη γνώση ώστε να προβλέπει τη μελλοντική κατάσταση λειτουργίας και να παράλληλα να παίρνει αποφάσεις σχετικά με τις μελλοντικές ενέργειες που πρέπει να γίνουν. Η μηχανική μάθηση έχει τη δυνατότητα να εφαρμοστεί σε πολλούς τομείς της βιομηχανίας όπως είναι αυτός των αυτόνομων οχημάτων, της παραγωγικής διαδικασίας, του διαδικτύου, γενικότερα της επιστήμης και σε πολλούς ακόμα.

Πολλοί αλγόριθμοι έχουν χρησιμοποιηθεί για να επιτύχουν τον συγκεκριμένο σκοπό, δηλαδή να εξάγουν χρήσιμη πληροφορία από ένα σύνολο δεδομένων με στόχο όλα τα παραπάνω. Οι αλγόριθμοι αυτοί μπορούν να κατηγοριοποιηθούν σε δύο μεγάλες ομάδες, στους αλγορίθμους μηχανικής μάθησης με επίβλεψη (supervised machine learning algorithms) και χωρίς αυτή (unsupervised machine learning algorithms) (Habeeb, Nasaruddin, Gani, Hashem, Ahmed, & Imran, 2019).

Ένα χαρακτηριστικό παράδειγμα είναι ο αλγόριθμος Support Vector Machine (SVM) σε συνδυασμό με ένα ant colony δίκτυο, όπου προσφέρει υψηλής απόδοσης σύστημα ανίχνευσης ανωμαλιών, περιέχοντας παράλληλες φάσεις για να επιτύχει στο σκοπό του σε πραγματικό χρόνο. Ο συνδυασμός αυτός παρέχει υψηλή ακρίβεια και ταχύτητα στους υπολογισμούς συγκριτικά με πιο κλασσικούς τρόπους ανίχνευσης. Μία παραλλαγή του αλγορίθμου SVM είναι εκείνος της μίας κλάσης (one class Support Vector Machine – OC-SVM), ο οποίος ομαδοποιεί τα δεδομένα ώστε να διαμορφώσει το μοντέλο που προσομοιώνει τη συμπεριφορά των δεδομένων στο σύνολό τους. Με τον τρόπο αυτό μπορεί να ανιχνεύσει κάποια ανωμαλία στη λειτουργία που περιγράφεται. Υπάρχει όμως ο περιορισμός στην εξαγωγή χαρακτηριστικών, ο οποίος παραμένει σε χαμηλό επίπεδο. Ένας άλλος αλγόριθμος OC-SVM μπορεί να χρησιμοποιηθεί απευθείας για ανίχνευση ανωμαλιών και όχι μέσω κατηγοριοποίησης καθώς εκπαιδεύεται στο σύνολο των δεδομένων αφού έχουν αυτά συλλεχθεί. Μάλιστα μπορεί να εφαρμοστεί σε πραγματικό χρόνο. Ουσιαστικά ο αλγόριθμος OC-SVM έχει την ίδια λειτουργία με τον αρχικό αλγόριθμο SVM με το επιπλέον χαρακτηριστικό να επεξεργάζεται και δεδομένα χωρίς κάποια ετικέτα και να συνδέει τα δεδομένα που δέχεται ως είσοδο με ένα ευρύ φάσμα χαρακτηριστικών.

Επιπροσθέτως για την ανίχνευση ανωμαλιών μπορεί να χρησιμοποιηθεί ο αλγόριθμος enhanced support vector, ο οποίος είναι ιδιαίτερα γνωστός για την χρήση του σε εφαρμογές που υλοποιούνται σε πραγματικό χρόνο. Προσφέρει πολύ καλής ακρίβειας κατηγοριοποίηση των εισερχόμενων δεδομένων είτε ως ανωμαλία είτε ως φυσιολογική λειτουργία. Η ακρίβειά του βέβαια μπορεί να αυξηθεί αν χρησιμοποιηθούν βάρη για κάθε διαφορετική περίπτωση των δεδομένων σε πραγματικό χρόνο. Παρ' όλα αυτά η πολυπλοκότητα που παρουσιάζει στην επιλογή αυτών των παραμέτρων είναι ένα μειονέκτημα της εφαρμογής του. Ένας ακόμα ιδιαίτερος συνδυασμός αλγορίθμων με στόχο την ανίχνευση ανωμαλιών είναι αυτός του Hybrid of one-class support vector machine και του deep belief nets, όπου συγκροτούν ένα μοντέλο ικανό να διαχειριστεί πολλαπλών διαστάσεων και μεγάλου μεγέθους σύνολο δεδομένων. Η συγκεκριμένη αρχιτεκτονική έχει υψηλή αποδοτικότητα ως προς την ανίχνευση ανωμαλιών και υψηλή υπολογιστική ικανότητα ως προς το να εκπαιδεύσει το μοντέλο αλλά και να εξετάσει τη λειτουργία του.

Εκτός από τις παραπάνω μεθόδους, ο αλγόριθμος random cut forest μπορεί να εφαρμοστεί σε επεξεργασίες ανίχνευσης ανωμαλιών. Το πλεονέκτημά του είναι ότι

μπορεί να εφαρμοστεί σε δεδομένα που παρουσιάζουν δυναμικότητα ως προς την ανίχνευση ανωμαλιών. Παράλληλα είναι ένας αλγόριθμος πολλά υποσχόμενος στη διαδικασία των λανθασμένων ειδοποιήσεων, με αποτέλεσμα την αυξημένη αξιοπιστία του στην ανίχνευση ανωμαλιών και σφαλμάτων. Όμως υπάρχει ένας περιορισμός στη λειτουργία του καθώς το μέγεθος του συνόλου των δεδομένων που πρόκειται να επεξεργαστεί δεν μπορεί να είναι πολύ μεγάλο.

Επιπροσθέτως, ο αλγόριθμος Cluster centre and nearest neighbour (CANN) είναι ένα μοντέλο ικανό να αναγνωρίζει όμοιες και ανόμοιες κλάσεις μέσα σε ένα σύνολο δεδομένων. Παρουσιάζεται επίσης ως ένας επαρκής και ικανοποιητικός τρόπος ανίχνευσης ανωμαλιών. Από την άλλη πλευρά, ο αλγόριθμος αυτός δεν μπορεί να χρησιμοποιήσει και να προσαρμόσει στη λειτουργία του αρκετά χαρακτηριστικά, γεγονός που θα μπορούσε να αυξήσει την ακρίβεια του εξαγόμενου αποτελέσματος. Ένας ακόμα χρήσιμος αλγόριθμος ονομάζεται Expectation maximization algorithm και φτιάχνει ένα μοντέλο προκειμένου να ανιχνεύσει ανωμαλίες σε δεδομένα που έχουν συσχετιστεί με το χρόνο (timeseries) και βρίσκει εφαρμογή στη βιομηχανία. Το μοντέλο αυτό είναι αρκετά αποτελεσματικό στην ανίχνευση ανωμαλιών και παράλληλα συντελεί ώστε να εμφανίζει χαμηλό επίπεδο λανθασμένων ειδοποιήσεων, αυξάνοντας την απόδοσή του με αυτό τον τρόπο. Παρ' όλα αυτά η πολυπλοκότητα που εμφανίζει στην ανανέωση παραμέτρων είναι ένας παράγοντας που πρέπει να ληφθεί υπόψιν.

Ένας ακόμα τρόπος ανίχνευσης ανωμαλιών είναι η χρήση του μοντέλου hidden semi-markov model, το οποίο έχει υψηλή αποδοτικότητα ως προς την συγκεκριμένη λειτουργία καθώς έχει υψηλή ευαισθησία στις αλλαγές κατάστασης (Habeeb, Nasaruddin, Gani, Hashem, Ahmed, & Imran, 2019). Σύμφωνα με τη βιβλιογραφία θεωρείται ένας από τους καταλληλότερους αλγορίθμους στον τομέα της βιομηχανίας καθώς μπορεί να αποτυπώσει αλλαγές που γίνονται σταδιακά και όχι απαραίτητα ακαριαία (Yang, Zheng, & Qi, 2020). Όμως αν το σύνολο δεδομένων είναι άγνωστου μεγέθους και μεγάλου χρονικού διαστήματος αυξάνει την πολυπλοκότητα του αλγορίθμου (Habeeb, Nasaruddin, Gani, Hashem, Ahmed, & Imran, 2019).

Μία μέθοδος ανίχνευσης ανωμαλιών που μπορεί να διαχειριστεί Μεγάλα Δεδομένα με μηχανική μάθηση είναι εκείνη των δικτύων με Bayesian λογική (Bayesian Networks – BN). Το σύστημα των δικτύων αυτών χωρίζεται σε δύο μέρη, το ποιοτικό και το ποσοτικό. Η λειτουργία του πρώτου μέρους του μοντέλου είναι να αναπαριστά με

κόμβους τους διάφορους παράγοντες που απαρτίζουν το πρόβλημα και με αιχμές τις μεταξύ τους σχέσεις. Στη συνέχεια, στο δεύτερο μέρος του μοντέλου υπολογίζεται για τον κάθε κόμβο μία κατανομή πιθανοτήτων ώστε να επιτευχθεί η ανίχνευση ανωμαλιών.

Μία επόμενη μέθοδος με την ίδια λογική είναι ο αλγόριθμος Nearest Neighbours (NN) η οποία βασίζεται στον υπολογισμό αποστάσεων μεταξύ των στοιχείων που αποτελούν το σύνολο των δεδομένων, με σκοπό την κατηγοριοποίηση τους σε πρώτη φάση και πρόβλεψη της μελλοντικής συμπεριφοράς του συστήματος σε δεύτερη. Χρησιμοποιεί επίσης ιστορικά δεδομένα, δηλαδή δεδομένα που έχουν ήδη καταγραφεί σε προηγούμενες χρονικές στιγμές, για να επιτύχει το σκοπό του. Μία έλλειψη που παρουσιάζει ο αλγόριθμος είναι εκείνη της ανικανότητας υπολογισμού της ομοιότητας που παρουσιάζουν τα δεδομένα μεταξύ τους καθώς ο αλγόριθμος δεν μπορεί να υπολογίσει με μεγάλη ακρίβεια την απόσταση αυτή, ιδιαίτερα όταν πρόκειται για ένα μικρό σύνολο δεδομένων από χαρακτηριστικά. Επιπλέον έχει υψηλές απαιτήσεις σε μνήμη και υπολογιστική πολυπλοκότητα όταν εφαρμόζεται για ανίχνευση ανωμαλιών (Habeeb, Nasaruddin, Gani, Hashem, Ahmed, & Imran, 2019).

Στον τομέα της βιομηχανίας, πέρα από τον αλγόριθμο του μοντέλου hidden semi-markov, βρίσκουν επίσης ιδιαίτερη εφαρμογή οι αλγόριθμοι που βασίζονται στον SVM αλγόριθμο όπως και εκείνοι που βασίζονται σε μεθοδολογίες κατηγοριοποίησης (Clustering methods). Οι μέθοδοι αυτοί δημιουργούν ομάδες δεδομένων με παρόμοια χαρακτηριστικά και όταν καλούνται να επεξεργαστούν νέα δεδομένα, αν εκείνα δεν ανήκουν σε κάποια από αυτές τις ομάδες δίνουν σήμα πως πρόκειται για μία ανωμαλία στη λειτουργία που μελετάται (Fahim, & Sillitti, 2019).

Σε εφαρμογές που απαιτούν επεξεργασίες σε πραγματικό χρόνο, οι αλγόριθμοι μηχανικής μάθησης πρέπει να αναλύουν μία συνεχή σειρά από δεδομένα που συλλέγονται σε πραγματικό χρόνο. Επομένως κάθε χρονική στιγμή δεν είναι διαθέσιμα όλα τα δεδομένα αλλά μόνο εκείνα που έχουν ήδη καταγραφεί. Οι αλγόριθμοι λοιπόν αυτοί καλούνται να επεξεργάζονται τα δεδομένα τη στιγμή της καταγραφής τους αλλά παράλληλα να λαμβάνουν και τις κατάλληλες αποφάσεις σε πραγματικό χρόνο. Οι υπάρχοντες αλγόριθμοι μηχανικής μάθησης με κατάλληλη διαχείριση μπορούν να ανταπεξέλθουν στις παραπάνω απαιτήσεις. Παρ' όλα αυτά δεν προσφέρονται για κατηγοριοποίηση ενός τεράστιου όγκου δεδομένων και δεν είναι ικανοί να διαχειριστούν αδόμητα δεδομένα. Το γεγονός αυτό τους καθιστά αναποτελεσματικούς

όταν πρόκειται για πολλαπλά επίπεδα μάθησης, επηρεάζοντας και την υπολογιστική τους ικανότητα. Μάλιστα η υπολογιστική πολυπλοκότητα αυξάνεται εκθετικά όταν τα δεδομένα προς επεξεργασία είναι πολλαπλών διαστάσεων (Habeeb, Nasaruddin, Gani, Hashem, Ahmed, & Imran, 2019).

Προκειμένου να βελτιωθεί η ανίχνευση ανωμαλιών ή σφαλμάτων στη λειτουργία που μελετάται και να μειωθούν οι περιορισμοί των παραδοσιακών μεθόδων μηχανικής μάθησης, που αναφέρονται παραπάνω, αναπτύχθηκαν οι μέθοδοι βαθιάς μηχανικής μάθησης. Οι μέθοδοι αυτοί βασίζονται στα δεδομένα που συλλέγονται από τους αισθητήρες και στα πολλαπλά επίπεδα, όπου το καθένα είναι σχεδιασμένο να είναι απλό και μη γραμμικό ώστε να είναι ικανό να δημιουργεί αυτόματα νέες μορφές των δεδομένων και να παρέχει πρόβλεψη ή κατηγοριοποίηση των δεδομένων με μεγαλύτερη ακρίβεια.

Σε βιομηχανικές εφαρμογές, τα δεδομένα που χρησιμοποιούνται για ανίχνευση ανωμαλιών περιέχουν θόρυβο λόγω της προέλευσής τους. Μία λύση που χρησιμοποιεί την τεχνική της βαθιάς μηχανικής μάθησης είναι ο αλγόριθμος LiftingNet που είναι πολύ αποτελεσματικός στη διαχείριση τέτοιου είδους δεδομένων και είναι ικανός να εκπαιδεύσει το αντίστοιχο μοντέλο χωρίς κάποια προηγούμενη επεξεργασία εξαγωγής χαρακτηριστικών παρέχοντας ακριβή αποτελέσματα. Φαίνεται ότι ο συγκεκριμένος αλγόριθμος μπορεί να προσαρμοστεί σε διάφορες εφαρμογές παρέχοντας κατηγοριοποίηση ανωμαλιών ξεπερνώντας σε απόδοση τον αλγόριθμο SVM στο αντίστοιχο έργο. Παρ' όλα αυτά έχει κάποιους περιορισμούς στη λειτουργία του, όπως το γεγονός ότι δεν μπορεί να χρησιμοποιηθεί σε εφαρμογές που απαιτούν γρήγορη εκπαίδευση του δικτύου καθώς εκείνη θα περιόριζε την αποτελεσματικότητά του (Angelopoulos, Michailidis, Nomikos, Trakadas, Hatziefremidis, Voliotis, & Zahariadis, 2020).

Επιπλέον, ένα αναδρομικό δίκτυο, βασισμένο στην τεχνική βαθιάς μηχανικής μάθησης, παρουσιάζει ιδιαίτερη ικανότητα στην κατανόηση των σύνθετων και μη γραμμικών σχέσεων που αναπτύσσονται ανάμεσα στα δεδομένα εισόδου και εξόδου. Επιπλέον μπορεί να διαχειριστεί τις μικρού χρονικού διαστήματος σχέσεις (short term dependencies) που αναπτύσσονται ανάμεσα στα δεδομένα και τον χρόνο. Επίσης ένας λόγος που θεωρείται προτιμότερο σαν σύστημα πρόβλεψης της μελλοντικής κατάστασης του συστήματος είναι το γεγονός ότι δεν έχει τους περιορισμούς των προηγούμενων μεθόδων. Παρ' όλα αυτά ένα νευρωνικό δίκτυο δεν λειτουργεί με

μεγάλη αποδοτικότητα όταν επεξεργάζεται δεδομένα με μεγάλου χρονικού διαστήματος σχέσεις ή με άλλα λόγια όταν επεξεργάζεται δεδομένα που έχουν ληφθεί σε χρονικές στιγμές μακρινές από την τρέχουσα χρονική στιγμή. Αυτό συμβαίνει λόγω του προβλήματος της υπερδιαμόρφωσης ή της υποδιαμόρφωσης.

Η λύση στο πρόβλημα αυτό είναι το νευρωνικό δίκτυο Long-Short Term Memory (LSTM) όπου είναι μία εξέλιξη ενός αναδρομικού δικτύου και είναι σχεδιασμένο να προλαμβάνει το πρόβλημα της υπερδιαμόρφωσης ή της υποδιαμόρφωσης. Επομένως μπορεί να διαχειριστεί δεδομένα είτε κοντά είτε μακριά από την τρέχουσα χρονική στιγμή (Shi & Chehade, 2021). Η λειτουργία του νευρωνικού δικτύου LSTM καθώς και των αναδρομικών δικτύων αναλύονται παρακάτω καθώς είναι μέρος της προτεινόμενης προσέγγισης.

3. Προτεινόμενη προσέγγιση

Η προτεινόμενη προσέγγιση της εργασίας αυτής έχει ως στόχο την ανίχνευση σημείων αλλαγής συμπεριφοράς του εξοπλισμού σε πραγματικό χρόνο έτσι ώστε να πραγματοποιηθούν ενέργειες συντήρησης σε εκείνον πριν επέλθει η κατάρρευσή του λόγω κάποιας βλάβης. Με αυτόν τον τρόπο αυξάνεται η διάρκεια ζωής του εξοπλισμού και βελτιστοποιείται η χρήση που του γίνεται καθώς οι ενέργειες συντήρησης και παραγωγής είναι προσαρμοσμένες σε κάθε ένα από τα κομμάτια της παραγωγής ανάλογα με τις ανάγκες του και ιδιαιτερότητές του. Για το συγκεκριμένο σκοπό σχεδιάστηκε η προτεινόμενη προσέγγιση, η οποία αποτελείται από επιμέρους αλγόριθμους όπου κάθε ένας επιτελεί αυτόνομο και ανεξάρτητο έργο προκειμένου να επιτευχθεί το βέλτιστο δυνατό αποτέλεσμα.

Η πρωταρχική του ιδέα βασίζεται στη λογική της καμπύλης P-F, όπως αναλύεται παραπάνω, η οποία δίνει μια αντιπροσωπευτική εικόνα για τη συμπεριφορά ενός εξοπλισμού στη φυσιολογική λειτουργία αλλά και σε εκείνη που παρουσιάζει ανωμαλίες. Σκοπός επομένως είναι η πρόβλεψη του σημείου που αρχίζει να αλλάζει η συμπεριφορά του εξοπλισμού (σημείο P) πολύ νωρίτερα απ' ό τι θα γινόταν αντιληπτό από τον υπεύθυνο για τη λειτουργία του εξοπλισμού από ενδείξεις που θα εμφανίζονταν. Στην επίτευξη του παραπάνω στόχου συμβάλλουν οι τεχνολογικές καινοτομίες που σχετίζονται με αισθητήρες για την παρακολούθηση της παραγωγικής διαδικασίας και ακολούθως για την καταγραφή των δεδομένων που είναι απαραίτητα για την μετέπειτα ανάλυση. Συγχρόνως θα χρησιμοποιηθούν αλγόριθμοι μηχανικής μάθησης στο πλαίσιο της προβλεπτικής συντήρησης για να προβλεφθούν τα δεδομένα που χρειάζονται για την συγκεκριμένη μελέτη.

Πιο συγκεκριμένα η προτεινόμενη προσέγγιση περιέχει τρεις βασικούς αλγορίθμους από τους οποίους ο πρώτος υλοποιεί ένα νευρωνικό δίκτυο Long Short Term Memory (LSTM), ο επόμενος τη διαδικασία της εξαγωγής χαρακτηριστικών (Time-domain feature extraction) και ο τελευταίος πραγματοποιεί την ανίχνευση σημείου αλλαγής με Bayesian λογική (Bayesian Online Changepoint Detection - BOCD). Οι αλγόριθμοι ενεργούν σειριακά και η διάταξή τους παρουσιάζεται στο σχήμα 5.



Σχήμα 5: Η επεξεργασία δεδομένων σύμφωνα με την προτεινόμενη προσέγγιση.


Αρχικά οι μετρήσεις που καταγράφονται σε πραγματικό χρόνο από τους αισθητήρες λαμβάνονται ως είσοδος από το νευρωνικό δίκτυο LSTM και παράγονται οι προβλεπόμενες τιμές για τα ίδια μεγέθη σε ένα χρονικό διάστημα που προκαθορίζεται από την σύνθεση του δικτύου. Έπειτα οι τιμές αυτές τροφοδοτούν τον αλγόριθμο που θα εξάγει τα χαρακτηριστικά που απαιτούνται για την επερχόμενη ανάλυση των δεδομένων. Επίσης είναι σημαντικό να αναφερθεί ότι τα δεδομένα που λαμβάνονται ως είσοδος στην συγκεκριμένη επεξεργασία δεν είναι το σύνολο των δεδομένων του κάθε μεγέθους αλλά επιλέγονται από ένα κυλιόμενο στο χρόνο παράθυρο σταθερού μεγέθους. Η διαδικασία αυτή ακολουθείται επειδή ο αλγόριθμος της ανίχνευσης σημείου αλλαγής είναι ευαίσθητος στον θόρυβο και θα πρέπει να αφαιρεθεί από το σήμα που πρόκειται να εισαχθεί σε εκείνον έτσι ώστε να επιτευχθεί εξαγωγή πληροφορίας σε υψηλότερο επίπεδο από αυτό των αρχικών δεδομένων και να μειωθεί η αβεβαιότητα που αρχικά εμπεριέχει. Τέλος, το σήμα που προκύπτει από την εξαγωγή χαρακτηριστικών τροφοδοτεί τον αλγόριθμο ανίχνευσης σημείου αλλαγής, ο οποίος υποδεικνύει μέσω ενός γραφήματος την πιθανότητα ένα σημείο να είναι σημείο αλλαγής. Παράλληλα μέσω των πιθανοτήτων που υπολογίζει, προβλέπει την μελλοντική κατάσταση του εξοπλισμού στο προαναφερθέν χρονικό διάστημα που καθορίστηκε από το νευρωνικό δίκτυο.

Στο κεφάλαιο 3.1 θα αναλυθεί η δομή και η λειτουργία του νευρωνικού δικτύου LSTM, στο 3.2 θα παρουσιαστεί η επεξεργασία της εξαγωγής χαρακτηριστικών και

τέλος στο 3.3 θα εξηγηθεί η λειτουργία του αλγορίθμου BOCD. Παράλληλα θα παρουσιαστούν οι παράμετροι που έχουν επιλεγεί για τη λειτουργία του κάθε αλγορίθμου με βάση την προτεινόμενη προσέγγιση.


3.1 Long Short Term Memory Neural Network

Το Long Short Term Memory (LSTM) είναι ένα αναδρομικό νευρωνικό δίκτυο (recurrent neural network, RNN) που χρησιμοποιείται στο πεδίο της βαθιάς μηχανικής μάθησης. Η συγκεκριμένη κατηγορία νευρωνικών δικτύων είναι ιδανική για εφαρμογές που επεξεργάζονται σειριακά δεδομένα, όπως είναι και οι χρονοσειρές. Το χρήσιμο σε εκείνα είναι ότι διαθέτουν ένα βρόγχο επανάληψης στη δομή τους, ο οποίος επιτρέπει τη διατήρηση της πληροφορίας από την προηγούμενη κατάσταση και την αξιοποίησή της για την πρόβλεψη της επόμενης. Η βασική μονάδα ενός τέτοιου δικτύου φαίνεται παρακάτω στο σχήμα 6 και αποτελείται από την είσοδο (x_t), το κύτταρο (cell) και την έξοδο (h_t).



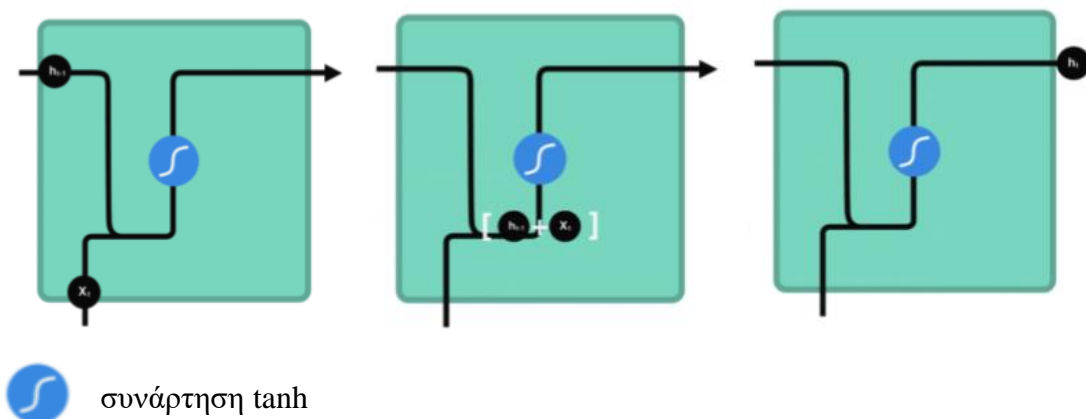
Σχήμα 6: Η δομή ενός RNN κυττάρου.

Ένα αναδρομικό νευρωνικό δίκτυο αποτελείται από πολλές τέτοιες διατάξεις στη σειρά, με αποτέλεσμα η πληροφορία να περνάει από το προηγούμενο στο επόμενο κομμάτι αυτής της αλυσίδας. Παρακάτω φαίνεται και διαγραμματικά (σχήμα 7) η δομή ενός τέτοιου δικτύου, η οποία μάλιστα δικαιολογεί την ιδιαίτερη χρήση της στη διαχείριση σειριακών δεδομένων.



Σχήμα 7: Η δομή ενός αναδρομικού νευρωνικού δικτύου (RNN).

Ιδιαίτερο ενδιαφέρον παρουσιάζει η διαδικασία που γίνεται μέσα στο κάθε κύτταρο (A) της βασικής μονάδας του νευρωνικού δικτύου, το οποίο αποτελείται από ένα νευρωνικό επίπεδο και η λειτουργία του αναπαρίσταται παρακάτω σε τρία βήματα. Αρχικά, τα δεδομένα προς επεξεργασία, μετατρέπονται σε ένα διάνυσμα, κατανοητό από το δίκτυο. Το διάνυσμα αυτό αποτελεί την τρέχουσα είσοδο του κυττάρου x_t και με την πληροφορία που προέρχεται από την έξοδο του προηγούμενου κυττάρου h_{t-1} συνδυάζονται σε ένα νέο διάνυσμα $[x_t + h_{t-1}]$. Στο επόμενο βήμα, το νέο διάνυσμα αυτό υφίσταται επεξεργασία από τη συνάρτηση \tanh . Πιο συγκεκριμένα, η συνάρτηση αυτή κανονικοποιεί τα δεδομένα στο πεδίο τιμών $[-1,1]$, ώστε η πληροφορία εξόδου να είναι πιο κατανοητή και να μην επιτρέπεται η εκτόξευση τιμών λόγω πολλαπλής επεξεργασίας τους. Το αποτέλεσμα αυτής της επεξεργασίας είναι η έξοδος του κυττάρου, η οποία αποτελεί τη νέα κατάσταση μνήμης του δικτύου.



Σχήμα 8: Η απεικόνιση της λειτουργίας του κυττάρου ενός αναδρομικού νευρωνικού δικτύου.


Όταν λοιπόν ένα αναδρομικό νευρωνικό δίκτυο προσπαθεί να προβλέψει την επόμενη τιμή, συνδυάζει την προηγούμενη πληροφορία που κατέχει με τη παρούσα είσοδο, ώστε να πραγματοποιήσει τη λειτουργία του. Όμως δεν μπορούν να εκμεταλλευτούν πληροφορία που δεν είναι στο πρόσφατο χρονικό περιβάλλον τους και επομένως να τη συνδυάσουν με την τρέχουσα επεξεργασία. Το γεγονός αυτό είναι και το βασικότερο μειονέκτημά τους και βασίζεται στην ύπαρξη του προβλήματος με όνομα «vanishing gradient problem».

Ο υπολογισμός ενός νέου βάρους σε ένα νευρωνικό δίκτυο γίνεται μέσω του τύπου $w_{new} = w_{old} - lr * grad$ όπου w_{new} είναι το νέο βάρος ενώ w_{old} το ήδη υπολογισμένο βάρος, lr είναι ο ρυθμός με τον οποίο «μαθαίνει» το νευρωνικό δίκτυο και $grad$ είναι μία παράμετρος που υπολογίζεται καθώς γίνεται προσπέλαση από το τελευταίο στο πρώτο επίπεδο του δικτύου και η τιμή του μειώνεται εκθετικά. Αν λοιπόν το τελευταίο μέγεθος μειωθεί πάρα πολύ, αυτό έχει ως αποτέλεσμα τα δύο βάρη να μην έχουν διαφορά μεταξύ τους και επομένως το νευρωνικό δίκτυο να μην εκπαιδεύεται όπως είναι ο αρχικός του στόχος.

3.1.1 LSTM, δομή και λειτουργία

Λύση σε αυτό το πρόβλημα έρχονται να δώσουν τα νευρωνικά δίκτυα LSTM και GRU (Gated Recurrent Units), καθώς μπορούν να συγκρατούν πληροφορίες από ένα σημαντικό πλήθος παρελθοντικών χρονικών βημάτων. Με βάση πολλές δοκιμές που έχουν γίνει, η πρώτη κατηγορία προσφέρει ικανοποιητικά αποτελέσματα σε προβλήματα με σειριακά δεδομένα και ειδικότερα με χρονοσειρές και γι' αυτό το λόγο επιλέχθηκε στην συγκεκριμένη εργασία.

Το LSTM νευρωνικό δίκτυο, όπως και ένα RNN, είναι μία αλυσίδα από όμοιες διατάξεις, που όμως κάθε μία αποτελείται από τέσσερα επίπεδα που αλληλεπιδρούν μεταξύ τους. Η δομή κάθε διάταξης, που ονομάζεται κύτταρο, φαίνεται στο σχεδιάγραμμα (σχήμα 9) και περιγράφεται παρακάτω.



Σχήμα 9: Η δομή ενός LSTM κυττάρου

Η διάταξη αυτή αποτελείται αρχικά από μία οριζόντια γραμμή (cell state), η οποία διαπερνά όλη την δομή και ο ρόλος της είναι να κρατάει την μνήμη του δικτύου. Επίσης διαθέτει τριών ειδών πύλες (forget, input, output gate), οι οποίες προστατεύουν την μνήμη καθώς ελέγχουν την πρόσθεση ή την αφαίρεση πληροφοριών σε εκείνη. Κάθε πύλη αποτελείται από μία σιγμοειδή συνάρτηση (sigmoid function), η οποία προσαρμόζει τα δεδομένα στο διάστημα $[0,1]$ και τη λειτουργία του πολλαπλασιασμού.

Αναλυτικότερα, η οριζόντια γραμμή της κάθε μίας διάταξης που αποτελούν την αλυσίδα του LSTM, μεταφέρει πληροφορία κατά μήκος όλης της αλυσίδας και με αυτόν τον τρόπο πληροφορίες από προηγούμενα χρονικά βήματα μπορούν να συνδυαστούν με πληροφορίες επόμενων και να αντιμετωπιστεί το πρόβλημα των RNN δικτύων. Στη διαδρομή αυτή μπορεί να προστίθεται ή να αφαιρείται πληροφορία όπως αναφέρθηκε, μέσω των πυλών, οι οποίες ουσιαστικά αποφασίζουν τι είναι χρήσιμο ώστε να προστεθεί στη μνήμη κατά τη διάρκεια της εκπαίδευσης του νευρωνικού και τι όχι ώστε να απορριφθεί. Αυτό αριθμητικά παρουσιάζεται μέσα από το αποτέλεσμα της σιγμοειδούς συνάρτησης, όπου το 1 συμβολίζει το απόλυτα χρήσιμο και το 0 το

απόλυτα άχρηστο. Οι ενδιάμεσες τιμές εμφανίζουν σε τι ποσοστό είναι ωφέλιμη η πληροφορία που επεξεργάζεται.

Οι τρεις πύλες της διάταξης έχουν ως είσοδο ένα συνδυασμό της εξόδου του προηγούμενου κυττάρου της αλυσίδας (h_{t-1}) και των δεδομένων που προέρχονται από τους αισθητήρες της βιομηχανικής μονάδας προς επεξεργασία εκείνης της χρονικής στιγμής (x_t). Η έξοδος τους διαφέρει ανάλογα με τη λειτουργία της κάθε μίας. Η πρώτη πύλη (forget gate) έχει ως έξοδο ένα ποσοστό της πληροφορίας εισόδου (f_t) ανάλογα με το πόσο σημαντική ή όχι θεωρείται εκείνη και σε τι μέρος, για να αποθηκευτεί στη μνήμη, να περάσει δηλαδή στη γραμμή του «cell state». Αποφασίζει λοιπόν τι είναι σημαντικό ή όχι για την εκπαίδευση του νευρωνικού δικτύου. Η δεύτερη πύλη (input gate) αποφασίζει ποιες τιμές πρέπει να ενημερωθούν και να λάβουν νέα τιμή (i_t) και η τελευταία πύλη (output gate) αποφασίζει το μέρος της τρέχουσας κατάστασης της μνήμης που θα οδηγηθεί στην έξοδο της διάταξης (o_t) (Ranjah, 2020).

Αφού αναλύθηκε η σύνθεση και η λειτουργία των βασικών δομών ενός LSTM κυττάρου, μπορεί να αποδοθεί σε βήματα η συνολική λειτουργία του.

- 1 Συνδυάζονται σε ένα διάνυσμα η έξοδος του προηγούμενου κυττάρου και η τρέχουσα είσοδος στο κύτταρο, όπου αφορά το σύνολο των δεδομένων προς επεξεργασία.

$$[h_{t-1} + x_t]$$

- 2 Το διάνυσμα $[x_t + h_{t-1}]$ περνά από την «forget gate» και παράγεται η f_t .

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f)$$

- 3 Η f_t πολλαπλασιάζεται με την προηγούμενη κατάσταση μνήμης C_{t-1} .

$$[C_{t-1} * f_t]$$

- 4 Το διάνυσμα $[x_t + h_{t-1}]$ περνά από την «input gate» και παράγεται η i_t .

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i)$$

- 5 Το διάνυσμα $[x_t + h_{t-1}]$ περνά από την tanh συνάρτηση και παράγεται η \tilde{C}_t .

$$\tilde{C}_t = \tanh(W_C * [h_{t-1}, x_t] + b_C)$$

- 6 Τα αποτελέσματα των δύο προηγούμενων βημάτων πολλαπλασιάζονται μεταξύ τους.

$$[i_t * \tilde{C}_t]$$

- 7 Προσθέτω τα αποτελέσματα που έχουν παραχθεί από τους πολλαπλασιασμούς στα βήματα 3 και 6 και προκύπτει η νέα κατάσταση μνήμης C_t .

$$C_t = C_{t-1} * f_t + i_t * \tilde{C}_t$$

- 8 Το διάνυσμα $[x_t + h_{t-1}]$ περνά από την «output gate» και παράγεται η o_t .

$$o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o)$$

- 9 Η νέα κατάσταση μνήμης υφίσταται τη λειτουργία μίας tanh συνάρτησης και το αποτέλεσμα πολλαπλασιάζεται με την o_t παράγοντας τη νέα έξοδο του κυττάρου h_t .

$$h_t = o_t * \tanh(C_t)$$

Η λειτουργία της tanh συνάρτησης έχει εξηγηθεί παραπάνω καθώς είναι μέρος και του κυττάρου ενός RNN δικτύου. Η έξοδος του κυττάρου είναι η h_t και η νέα κατάσταση μνήμης του κυττάρου είναι η C_t . Και τα δύο αυτά μεγέθη περνούν στο επόμενο κύτταρο της αλυσίδας του LSTM καθώς χρησιμοποιούνται και τα δύο για την πρόβλεψη της επόμενης τιμής της αλληλουχίας, που είναι και ο τελικός στόχος του νευρωνικού δικτύου (Olah, 2015). Με αυτό τον τρόπο προβλέπονται οι τιμές των μεγεθών που πρόκειται να μελετηθούν στο πλαίσιο της ανίχνευσης ανωμαλιών και της προτεινόμενης προσέγγισης αυτής της εργασίας.

Ένα ιδιαίτερο χαρακτηριστικό που θα πρέπει να ληφθεί υπόψιν στην διαμόρφωση του νευρωνικού δικτύου είναι το πρόβλημα της υπερδιαμόρφωσης των δεδομένων. Πιο συγκεκριμένα αναφέρεται στην κατάσταση όπου το μοντέλο έχει εκπαιδευτεί τόσο καλά που οι προβλέψεις του παρουσιάζουν πολύ μικρή απόκλιση από τις πραγματικές τιμές. Έτσι λοιπόν θα επιδεικνύει πολύ μεγάλη ακρίβεια στο συγκεκριμένο σύνολο δεδομένων αλλά σε νέα και άγνωστα για εκείνο δεδομένα, η ακρίβειά του θα είναι αρκετά μικρότερη. Το γεγονός αυτό καθιστά το μοντέλο μη λειτουργικό και αναποτελεσματικό. Αντίστοιχα το πρόβλημα της υποδιαμόρφωσης δημιουργείται όταν το μοντέλο δεν έχει επαρκή δεδομένα ώστε να εκπαιδευτεί ικανοποιητικά και έτσι δεν αντιλαμβάνεται όλα τα μοτίβα που παρουσιάζουν τα δεδομένα. Σαν αποτέλεσμα οι προβλεπόμενες τιμές εμφανίζουν γραμμική σχέση με το χρόνο και παρουσιάζονται σαν μία ευθεία γραμμή (Bronshstein, 2017).

3.1.2 Αλγόριθμος LSTM

Ο αλγόριθμος που χρησιμοποιήθηκε για να υλοποιήσει την παραπάνω λειτουργία και ανάπτυξη του νευρωνικού δικτύου απαρτίζεται από τα παρακάτω μέρη. Αρχικά δέχεται ως είσοδο τα δεδομένα που καταγράφονται από τους αισθητήρες που έχουν τοποθετηθεί στον εξοπλισμό της βιομηχανικής μονάδας και τα αμέσως επόμενα βήματα αφορούν την μετατροπή τους σε κατάλληλη μορφή, ικανή να χρησιμοποιηθούν από τις επιμέρους διαδικασίες του νευρωνικού δικτύου. Έτσι τα δεδομένα πρωτίστως μετατρέπονται με τέτοιο τρόπο ώστε τα στατιστικά τους χαρακτηριστικά, όπως η μέση τιμή, η διακύμανση κλπ, να είναι συνεχή στο χρόνο (stationary timeseries).

Στην επόμενη μετατροπή, δημιουργείται μία ετικέτα για κάθε μία τιμή των μεγεθών που μελετώνται, η οποία ουσιαστικά είναι μία επόμενη τιμή του ίδιου μεγέθους, που έχει οριστεί ως είσοδος του νευρωνικού δικτύου, από εκείνη που εξετάζεται τη δεδομένη χρονική στιγμή. Το αν η τιμή της ετικέτας θα είναι στο άμεσα χρονικά περιβάλλον της εξεταζόμενης τιμής ή στο μακρινό, εξαρτάται από την παράμετρο που θα ορισθεί στη συνάρτηση `shift()`, που δρα μέσα στη συνάρτηση αυτής της δεύτερης μετατροπής. Η παράμετρος αυτής της συνάρτησης καθορίζει πόσα δείγματα μετά θα είναι η τιμή που θα ορισθεί ως ετικέτα της τιμής που μελετάται τη δεδομένη χρονική στιγμή. Στη συγκεκριμένη μελέτη χρησιμοποιούνται οι παράμετροι 180 και 360 όπου αντιστοιχούν σε μισή και μία ώρα αντίστοιχα.

Η τελευταία μετατροπή που υφίστανται τα μεγέθη που μελετώνται είναι η κανονικοποίηση τους μέσα στο πεδίο τιμών $[-1,1]$ ώστε να είναι διαχειρίσιμες και κατανοητές τιμές. Ένας επιπλέον λόγος που πραγματοποιείται η μετατροπή αυτή, είναι για να αποφευχθούν πολύ μεγάλες τιμές λόγω πολλαπλών επεξεργασιών, οι οποίες δε θα αποτελούν σαφές αποτέλεσμα. Τέλος να σημειωθεί ότι η μετατροπή αυτή προσομοιώνει τη λειτουργία της συνάρτησης `tanh`, η οποία έχει περιγραφεί παραπάνω, στη γενικότερη περιγραφή του LSTM δικτύου.

Αφού λοιπόν γίνουν οι παραπάνω μετατροπές στα δεδομένα, εκείνα χωρίζονται σε δύο μέρη. Το πρώτο αφορά την φάση της εκπαίδευσης του νευρωνικού δικτύου (training) και το δεύτερο μέρος την φάση κατά την οποία θα εξεταστεί και θα εκτιμηθεί αν εκείνο δίνει ικανοποιητικά αποτελέσματα ως προς τις προβλέψεις που δημιουργεί για το μέγεθος που μελετά (testing). Το πλήθος δεδομένων του πρώτου μέρους είναι πολύ μεγαλύτερο σε σχέση με το δεύτερο, ώστε να πραγματοποιηθεί ικανοποιητική

εκπαίδευση του δικτύου και να μην οδηγηθεί το μοντέλο σε υποδιαμόρφωση αλλά και σε μία αναλογία που δεν θα οδηγηθεί σε υπερδιαμόρφωση. Το νευρωνικό δίκτυο που χρησιμοποιήθηκε στα παρακάτω πειράματα χρησιμοποιεί το 80% του συνόλου των δεδομένων για την πρώτη φάση ενώ το υπόλοιπο 20% για τη δεύτερη.

Συνεχίζοντας, σημαντικό βήμα είναι η διαμόρφωση των παραμέτρων του νευρωνικού δικτύου αρχίζοντας από το πλήθος των δειγμάτων που επεξεργάζεται σε κάθε βήμα το δίκτυο πριν ανανεώσει τις εσωτερικές του παραμέτρους (batch_size). Έπειτα πρέπει να προσδιοριστεί το πλήθος των επαναλήψεων που θα πραγματοποιήσει ο αλγόριθμος στο σύνολο των δεδομένων (epochs) καθώς και ο αριθμός των νευρώνων που απαρτίζουν το δίκτυο (neurons). Σε κάθε επανάληψη υπολογίζεται μία τιμή του μεγέθους που μελετά προσδιορίζοντας την απόκλιση της προβλεπόμενης τιμής από την πραγματική (loss) και σκοπός του νευρωνικού δικτύου είναι να μειώσει όσο είναι δυνατόν αυτή την τιμή, ώστε να αποδώσει μεγαλύτερη ακρίβεια στις προβλέψεις του. Θεωρητικά όσο μεγαλύτερος είναι ο αριθμός των επαναλήψεων (epochs), τόσο πιο μικρή θα είναι αυτή η απόκλιση. Όμως στην πραγματικότητα υπάρχουν περιορισμοί από τις δυνατότητες του υπολογιστικού συστήματος, στο οποίο γίνεται η διαδικασία, καθώς απαιτείται περισσότερη μνήμη για περισσότερες επαναλήψεις. Η επιλογή του αριθμού των νευρώνων όπως και των μεγεθών batch size και epochs βασίζεται σε πειραματικές δοκιμές που έγιναν, ώστε να επιτευχθεί το καλύτερο δυνατό αποτέλεσμα, δηλαδή η καλύτερη προσέγγιση της προβλεπόμενης τιμής του μεγέθους που μελετάται. Τέλος προσδιορίζεται το μέσο υπολογισμού της απόκλισης των πραγματικών τιμών και των αντίστοιχων προβλέψεων στη δεύτερη φάση του testing (measure of loss) καθώς και ο αλγόριθμος ο οποίος αλλάζει κάποια μεγέθη του νευρωνικού δικτύου, όπως είναι τα βάρη των νευρώνων, προκειμένου να μειώσει τις αποκλίσεις που αναφέρθηκαν προηγουμένως (optimizer). Η ακριβής επιλογή αυτών των παραμέτρων φαίνονται στον πίνακα 1.

Παράμετρος	Τιμή
Batch size	1
epochs	50
Neurons	1
Measure of loss	rmse
optimizer	adam

Πίνακας 1: Προσδιορισμός παραμέτρων νευρωνικού δικτύου LSTM.

Εφόσον έχει διαμορφωθεί το μοντέλο και τα δεδομένα προς εκπαίδευση σε κατάλληλη μορφή, ξεκινά η εκπαίδευση του μοντέλου και έπειτα αποθηκεύονται οι παράμετροι του μοντέλου, όπως είναι η αρχιτεκτονική του, τα βάρη των νευρώνων και η διαμόρφωση του μοντέλου σε αρχεία. Αυτό συμβαίνει ώστε να χρησιμοποιηθούν αργότερα και να ανανεωθούν οι τιμές των παραμέτρων αυτών στην φάση του testing. Η αποθήκευση αυτή γίνεται μέσω ενός αρχείου μορφής json, όπου εκεί αποθηκεύεται η αρχιτεκτονική του μοντέλου και ενός αρχείου μορφής h5, όπου εκεί αποθηκεύονται τα βάρη των νευρώνων και χρησιμοποιούνται μετέπειτα.

Το επόμενο βήμα αφορά τη φάση testing και τον υπολογισμό της αποδοτικότητας του μοντέλου. Ο αλγόριθμος επίσης ανακαλεί τις παραμέτρους του μοντέλου που είχαν αποθηκευτεί κατά τη διαδικασία της εκπαίδευσης μέσω του αρχείου h5 ώστε να συμπεριληφθούν στη διαδικασία κατά την οποία γίνονται οι προβλέψεις για τις τιμές ενδιαφέροντος. Οι προβλεπόμενες τιμές αναπαριστώνται γραφικά σε συνάρτηση με το χρόνο και συγκρίνονται με τις αντίστοιχες πραγματικές. Μέσω του διαγράμματος αυτού προκύπτει μία πρώτη αποτίμηση της ακρίβειας του μοντέλου. Ο αλγόριθμος έχει ακόμα ένα μετρητικό όργανο της ακρίβειας, το οποίο έχει οριστεί στη φάση διαμόρφωσης του μοντέλου (rmse). Η τιμή αυτή επίσης καταγράφεται καθώς δείχνει την ικανότητα του μοντέλου στην πρόβλεψη τιμών και με τι ακρίβεια. Τέλος οι παράμετροι του μοντέλου ανανεώνουν τις τιμές του και αποθηκεύονται στα ήδη υπάρχοντα αρχεία.

3.2 Εξαγωγή χαρακτηριστικών (feature extraction)

Τα δεδομένα που συλλέγονται από αισθητήρες συνήθως χρειάζονται μια προεπεξεργασία ώστε να αφαιρείται ο θόρυβος που εμπεριέχεται στο σήμα λόγω της χρήσης τους και να ελαχιστοποιείται η αβεβαιότητα που προκαλείται από εκείνους. Επιπλέον με τον τρόπο αυτό παράγεται πληροφορία με επαρκή ακρίβεια έτσι ώστε η ανάλυση των δεδομένων, που έπεται να παράγει αξιόπιστα αποτελέσματα. Ιδιαίτερα σε σήματα δονήσεων, όπως είναι εκείνα που παράγονται κατά κύριο λόγο στη βιομηχανία, η εξαγωγή χαρακτηριστικών μεγεθών είναι απαραίτητη όταν η ανάλυση των δεδομένων αφορά ανίχνευση σφαλμάτων και πρόβλεψη διάφορων μεγεθών.

Οι μέθοδοι που χρησιμοποιούνται για την εξαγωγή χαρακτηριστικών μεγεθών μπορούν να διαχωριστούν σε τέσσερις ευρείες κατηγορίες. Ξεκινώντας με την πρώτη προσέγγιση, η διαδικασία αυτή γίνεται στο πεδίο του χρόνου (time-domain features extraction) ενώ στη δεύτερη πραγματοποιείται στο πεδίο της συχνότητας (frequency-domain features extraction). Η επόμενη περιλαμβάνει το συνδυασμό των δύο προηγούμενων μεθόδων (time-frequency domain features extraction) και η τελευταία εμπεριέχει μεθόδους όπως η μέτρηση της ανομοιομορφίας της φάσης (phase-space dissimilarity measurement) και η μέτρηση της πολυπλοκότητας (complexity measurement).

Η καταλληλότερη προσέγγιση για εξαγωγή χαρακτηριστικών μεγεθών από σήματα δονήσεων είναι εκείνη που γίνεται στον τομέα του χρόνου. Στην συγκεκριμένη κατηγορία ανήκουν αρχικά μεγέθη όπως η μέση τιμή (mean), η ενεργός διαβάθμιση της μέσης τιμής (root mean square - rms), η τυπική απόκλιση (standard deviation - std) και η διακύμανση (variance), τα οποία χρησιμοποιούνται για να εντοπίσουν τις διαφορές ανάμεσα σε σήματα δονήσεων (Caesarendra & Tjahjowidodo, 2017). Με περισσότερη λεπτομέρεια, η μέση τιμή υπολογίζει το ηλίκο που προκύπτει από το άθροισμα των τιμών του σήματος και το πλήθος τους ενώ η τιμή της ενεργούς διαβάθμισης της μέσης τιμής υπολογίζει την τετραγωνική ρίζα της μέσης τιμής του σήματος υψωμένο στο τετράγωνο. Το μέγεθος αυτό αυξάνεται σταδιακά όσο αναπτύσσεται ένα σφάλμα μέσα στο σήμα προς μελέτη, αλλά δεν μπορεί να παρέχει πληροφορία στο αρχικό στάδιο ανάπτυξης του σφάλματος. Συνεχίζοντας, η διακύμανση είναι ένα μέγεθος που αναπαριστά την διασπορά του σήματος λαμβάνοντας ως αναφορά τη μέση τιμή του ενώ η τυπική απόκλιση υπολογίζει την τετραγωνική ρίζα της διακύμανσης του σήματος.

Πιο ιδιαίτερα μεγέθη, ικανά να αποδώσουν περισσότερη πληροφορία, είναι η κύρτωση (kurtosis) και η ασυμμετρία (skewness), τα οποία επεξεργάζονται την συνάρτηση πυκνότητας πιθανότητας του σήματος. Πιο συγκεκριμένα η κύρτωση υπολογίζει την μέγιστη τιμή της συνάρτησης και υποδηλώνει αν το σήμα είναι μπορεί να ανταποκριθεί άμεσα σε κάποια αλλαγή. Σε φυσιολογικές συνθήκες, η κύρτωση που εξάγεται από ένα σήμα δονήσεων ισούται προσεγγιστικά με την τιμή τρία, ενώ αν υπάρχουν σφάλματα σε αυτό τότε η συνάρτηση πυκνότητας πιθανότητας αλλάζει και επομένως η τιμή της κύρτωσης είναι μεγαλύτερη από εκείνη της φυσιολογικής λειτουργίας. Αντίστοιχα, η ασυμμετρία είναι ένα μέγεθος που λαμβάνεται από την

μέση τιμή της συνάρτησης πυκνότητας πιθανότητας και χρησιμοποιείται για να υποδείξει αν το σήμα δονήσεων είναι αρνητικά ή θετικά ασύμμετρο (skewed). Σε ένα σήμα με κανονική κατανομή η ασυμμετρία έχει μηδενική τιμή αλλά αν εκείνο διαταραχθεί λόγω σφαλμάτων τότε θα λάβει είτε αρνητική είτε θετική τιμή ανάλογα με την ασυμμετρία που θα παρουσιάσει (Caesarendra & Tjahjowidodo, 2017). Επιπλέον αξίζει να σημειωθεί ότι τα δύο παραπάνω μεγέθη μπορούν να εφαρμοστούν σε σήματα που δεν είναι αμιγώς συνεχή ως προς τον χρόνο (stationary) σε αντίθεση με χαρακτηριστικά όπως η μέση τιμή και η τυπική απόκλιση.

Ένα ακόμα μέγεθος που μπορεί να εξαχθεί από την συνάρτηση πυκνότητας πιθανότητας για σήματα δονήσεων είναι η εντροπία (entropy), η οποία υπολογίζει το ιστόγραμμα της παραπάνω συνάρτησης και υποδεικνύει το μέγεθος της τυχαιότητας και της αβεβαιότητας του σήματος. Τέλος, στην ίδια κατηγορία ανήκουν το ανώτερο και το κατώτατο όριο του ιστογράμματος (lower and upper bound histogram), τα οποία υπολογίζουν τη μέγιστη και την ελάχιστη τιμή της συνάρτησης πυκνότητας πιθανότητας αντίστοιχα (Caesarendra & Tjahjowidodo, 2017). Η συνοπτική περιγραφή των παραπάνω μεγεθών καθώς και οι μαθηματικού τύποι με τους οποίους υπολογίζονται φαίνονται στον Πίνακα 2.

Χαρακτηριστικό μέγεθος	Μαθηματικός τύπος	Συνοπτική περιγραφή
Μέση τιμή	$m = \frac{\sum_{i=1}^N x_i}{N}$	Υπολογίζει το πηλίκο που προκύπτει από το άθροισμα των τιμών του σήματος και το πλήθος τους.
Ενεργός διαβάθμιση της μέσης τιμής	$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	Υπολογίζει την τετραγωνική ρίζα της μέσης τιμής του σήματος υψωμένο στο τετράγωνο.
Διακύμανση	$var = \frac{\sum_{i=1}^N (x_i - m)^2}{(N - 1)\sigma^2}$	Υπολογίζει την διασπορά του σήματος λαμβάνοντας ως αναφορά τη μέση τιμή του.
Τυπική απόκλιση	$SD = \sqrt{\frac{\sum_{i=1}^N (x_i - m)^2}{(N - 1)\sigma^2}}$	Υπολογίζει την τετραγωνική ρίζα της διακύμανσης του σήματος.
Κύρτωση	$Ku = \frac{\sum_{i=1}^N (x_i - m)^4}{(N - 1)\sigma^4}$	Υπολογίζει την μέγιστη τιμή της συνάρτησης πυκνότητας πιθανότητας.
Ασυμμετρία	$Sk = \frac{\sum_{i=1}^N (x_i - m)^3}{(N - 1)\sigma^3}$	Υποδεικνύει κατά πόσο το σήμα είναι αρνητικά ή θετικά ασύμμετρο.
Εντροπία	$e(p) = - \sum_{i=1}^n p(z_i) \log_2 p(z_i)$	Υπολογίζει το ιστόγραμμα της συνάρτησης πυκνότητας πιθανότητας.
Ανώτερο όριο ιστογράμματος	$h_U = \max(x_i) + \Delta/2$	Υπολογίζει την μέγιστη τιμή της συνάρτησης πυκνότητας πιθανότητας.
Κατώτατο όριο ιστογράμματος	$h_L = \max(x_i) - \Delta/2$	Υπολογίζει την ελάχιστη τιμή της συνάρτησης πυκνότητας πιθανότητας.

Πίνακας 2: Συνοπτική περιγραφή των χαρακτηριστικών μεγεθών που εξάγονται στο πεδίο του χρόνου.

Σύμφωνα με τη βιβλιογραφία, τα χαρακτηριστικά μέση τιμή (mean), ενεργός διαβάθμιση της μέσης τιμής (rms), τυπική απόκλιση (standard deviation), κύρτωση (kurtosis) και ασυμμετρία (skewness) είναι τα κατάλληλα για επεξεργασία σημάτων δονήσεων που προέρχονται από το βιομηχανικό τομέα. Αυτός είναι και ο λόγος που επιλέγονται στην συγκεκριμένη προσέγγιση (Caesarendra & Tjahjowidodo, 2017).

Τα χαρακτηριστικά που περιεγράφηκαν παραπάνω έχουν ως αποτέλεσμα μία τιμή που υπολογίζεται από το σύνολο των δεδομένων που μελετώνται. Όμως στη συγκεκριμένη προσέγγιση η διαδικασία εξαγωγής χαρακτηριστικών είναι κυλιόμενη και το αποτέλεσμα που εξάγεται είναι μία καμπύλη με τις τιμές που υπολογίζονται σε κάθε βήμα. Με άλλα λόγια η διαδικασία αυτή χρησιμοποιεί ένα «παράθυρο» με συγκεκριμένο μέγεθος έτσι ώστε ο υπολογισμός των χαρακτηριστικών να μη γίνεται από όλο το σύνολο δεδομένων αλλά από ένα υποσύνολο σταθερού μεγέθους το οποίο όμως κινείται στο χρόνο. Επομένως ο υπολογισμός των χαρακτηριστικών που εξάγονται συμπεριλαμβάνει τιμές από προηγούμενες χρονικές στιγμές και την τρέχουσα. Η ποσότητα των ιστορικών δεδομένων αυτών καθορίζεται από το «παράθυρο» που έχει οριστεί για τον υπολογισμό του κάθε χαρακτηριστικού. Η χρήση του «παραθύρου» και επομένως των ιστορικών δεδομένων έχουν ως αποτέλεσμα την εξαγωγή πληροφοριών σε ανώτερο επίπεδο και μεγαλύτερη υπολογιστική αποτελεσματικότητα. Το ακριβές μέγεθος «παραθύρου» για το κάθε χαρακτηριστικό προσδιορίστηκε μετά από δοκιμές ώστε να επιτευχθεί το βέλτιστο αποτέλεσμα όσον αφορά την πληροφορία που θα εξαχθεί από την απεικόνιση των χαρακτηριστικών και φαίνεται στον πίνακα 3.

feature	Window
Kurtosis	25
skewness	30
Mean	10
Standard deviation	15
rms	15

Πίνακας 3: Το μέγεθος του window για κάθε rolling feature.

Προκειμένου να γίνει πιο κατανοητή η λειτουργία των rolling features αρκεί να δοθεί ένα παράδειγμα. Έτσι αν γίνεται εξαγωγή του χαρακτηριστικού kurtosis με

window = 25, τότε η πρώτη τιμή του συγκεκριμένου χαρακτηριστικού θα εξαχθεί από τα δεδομένα προς μελέτη που βρίσκονται στις θέσεις 1 έως 25, ενώ η δεύτερη τιμή από τα δεδομένα στις θέσεις 2 έως 26 και ούτω καθεξής. Με τον όρο θέση εννοείται η σειρά με την οποία έχουν καταγραφεί τα δεδομένα από τον αισθητήρα στην συγκεκριμένη περίπτωση.

3.3 Bayesian Online Changepoint detection

Μία χρονοσειρά είναι μία συλλογή από παρατηρήσεις σε χρονολογική σειρά. Τα δεδομένα αυτά έχουν μεγάλο μέγεθος, οπότε και καταλαμβάνουν περισσότερη μνήμη, είναι πολλαπλών διαστάσεων και ανανεώνονται συνεχώς (Fu, 2011). Ένα ακόμη χαρακτηριστικό τους είναι ότι διακρίνονται απότομες αλλαγές στην δομή τους, όπως ένα άλμα σε αρκετά μεγαλύτερη τιμή από την προηγούμενη ή μία διαφορετική συμπεριφορά στην κατανομή των δεδομένων. Εκείνα τα σημεία που αλλάζουν συμπεριφορά ονομάζονται σημεία αλλαγής και χωρίζουν ουσιαστικά τα δεδομένα σε ομογενή τμήματα.

Ο σκοπός πολλών εφαρμογών είναι η γρήγορη και με μεγάλη ακρίβεια ανίχνευση αυτών των σημείων και η έρευνα για το πως αυτό μπορεί να επιτευχθεί έχει ξεκινήσει από το 1954. Οι δύο μεγάλες κατηγορίες μεθόδων που χρησιμοποιούνται για αυτό είναι η «Bayesian» προσέγγιση και η προσέγγιση με βάση τη συχνότητα (frequentist). Στη μελέτη αυτή χρησιμοποιείται η πρώτη προσέγγιση καθώς είναι πιο κατάλληλη για την ανίχνευση σημείων αλλαγής σε χρονοσειρές, λόγω της ευκολίας της στην ποσοτικοποίηση της πιθανότητας μία θέση να είναι σημείο αλλαγής, σε σχέση με άλλες μεθόδους (Eckley, Fearnhead, & Killick, 2011). Επίσης, η επιλογή αυτή βασίστηκε στη βιβλιογραφία σύμφωνα με την οποία ο «Bayesian» αλγόριθμος φέρει καλύτερα αποτελέσματα σε δεδομένα βιομηχανικού χαρακτήρα και απαιτήσεων, καθώς εμφανίζει μικρότερη χρονική καθυστέρηση και μεγαλύτερη ακρίβεια στον εντοπισμό ενός σημείου αλλαγής (Namono, Emmanouilidis, Ruiz-Carcel, & Starr, 2020).

Η ανίχνευση ανωμαλιών σε μία κατάσταση λειτουργίας είναι, όπως αναφέρθηκε και παραπάνω, μία διαδικασία κατά την οποία γίνεται η ταυτοποίηση απότομων αλλαγών σε σειριακά δεδομένα και μπορεί να πραγματοποιηθεί σε πραγματικό χρόνο αλλά και εκ των υστέρων. Με άλλα λόγια, η ανίχνευση ανωμαλιών μπορεί να γίνει

κατά τη διάρκεια της συλλογής δεδομένων αλλά είναι δυνατό να πραγματοποιηθεί και η μελέτη ενός συνόλου δεδομένων αφού έχει ολοκληρωθεί η συλλογή τους.

Οι περισσότεροι αλγόριθμοι με «Bayesian» λογική εστιάζουν στον κατακερματισμό του συνόλου των δεδομένων και σε τεχνικές οι οποίες παράγουν αποτέλεσμα από μεταγενέστερη ανάλυση αυτών, αλλά ο αλγόριθμος που θα χρησιμοποιηθεί και στην συγκεκριμένη μελέτη εστιάζει στον εντοπισμό της αιτίας της πρόκλησης του προβλήματος και κατά την εκτέλεσή του δημιουργεί μία κατανομή της επόμενης τιμής στην ακολουθία δεδομένων, λαμβάνοντας υπόψιν μόνο τις τιμές που μέχρι στιγμής έχουν καταγραφεί.

3.3.1 Περιγραφή Bayesian αλγορίθμου

Τα μεγέθη προς μελέτη αυτού του αλγορίθμου είναι μία σειρά από παρατηρήσεις x_1, x_2, \dots, x_T , οι οποίες χωρίζονται σε διάφορες ανόμοιες και μη επικαλυπτόμενες περιοχές με μήκος g_1, g_2, \dots, g_T και τα όρια μεταξύ τους είναι τα σημεία αλλαγής (change points) (Namono, Emmanouilidis, Ruiz-Carcel, & Starr, 2020). Επίσης θεωρείται ότι οι παρατηρήσεις αυτές είναι ανεξάρτητες και ομοιόμορφα κατανεμημένες τυχαίες μεταβλητές με κατανομή πιθανότητας $P(x_t | n_\rho)$ όπου n_ρ ανεξάρτητες και παρόμοια κατανεμημένες τυχαίες μεταβλητές και $\rho \in [1, +\infty]$. Επιπλέον, μία ομαδοποίηση παρατηρήσεων μεταξύ της χρονικής στιγμής a και b συμβολίζεται με $x_{a:b}$ και η εκ των προτέρων κατανομή πιθανότητας στο διάστημα μεταξύ δύο σημείων αλλαγής με $P_{gap}(g)$.

Σκοπός αυτής της προσέγγισης είναι να εκτιμηθεί η μεταγενέστερη κατανομή πιθανότητας στο τρέχον μήκος δεδομένων r_t τη χρονική στιγμή t . Το μήκος δεδομένων r_t είναι μία συνάρτηση που εξαρτάται από το χρόνο, η οποία μηδενίζεται όταν συμβαίνει μία αλλαγή κατάστασης, συναντά δηλαδή ένα σημείο αλλαγής και αναφέρεται στο σύνολο δεδομένων από το πιο πρόσφατο σημείο αλλαγής μέχρι εκείνη τη χρονική στιγμή. Επιπλέον οι παρατηρήσεις που αφορούν ένα μήκος δεδομένων r_t συμβολίζονται με $x_t^{(r)}$ ενώ αν το μήκος δεδομένων είναι μηδενικό ($r = 0$) τότε συμβολίζονται με $x^{(r)}$.

Προκειμένου να γίνει η πρόβλεψη της κατανομής πιθανότητας στο τρέχον μήκος δεδομένων πρέπει αρχικά να υπολογιστεί με αναδρομικό τρόπο η εκ των υστέρων

κατανομή πιθανότητας (τύπος 2) και να ενσωματωθεί σε αυτή, η οριακή προβλεπτική κατανομή (τύπος 1) μέσω του παρακάτω τυπολογίου.

$$P(x_{t+1}|\mathbf{x}_{1:t}) = \sum_{r_t} P(x_{t+1}|x_t^{(r)}, r_t)P(r_t|\mathbf{x}_{1:t}) \quad (1)$$

$$P(r_t|\mathbf{x}_{1:t}) = \frac{P(r_t, \mathbf{x}_{1:t})}{P(\mathbf{x}_{1:t})} \quad (2)$$

$$P(r_t, \mathbf{x}_{1:t}) = \sum_{r_{t-1}} P(r_t, r_{t-1}, \mathbf{x}_{1:t}) \quad (3)$$

Ο τρίτος τύπος υπολογίζει την συνάρτηση πυκνότητας πιθανότητας στο τρέχον μήκος δεδομένων με αναδρομικό τρόπο, ώστε να υπολογιστεί η εκ των υστέρων κατανομή πιθανότητας. Τέλος, αξίζει να σημειωθεί ότι η προβλεπτική κατανομή $P(x_t|r_{t-1}, \mathbf{x}_{1:t})$ εξαρτάται μόνο από τα πρόσφατα δεδομένα $x_t^{(r)}$. Επομένως η συνάρτηση πυκνότητας πιθανότητας μπορεί να υπολογιστεί αναδρομικά βασιζόμενη στο τρέχον μήκος δεδομένων r_t , δεδομένου του r_{t-1} , και στην προβλεπτική κατανομή που προέκυψε από την νέα τιμή που παρατηρήθηκε, δεδομένων των τιμών που έχουν παρατηρηθεί μέχρι στιγμής.

Για τον υπολογισμό των παραπάνω μεγεθών, εκτός από την διατύπωση των αναδρομικών τύπων, χρειάζεται και ο ορισμός των οριακών συνθηκών, ο οποίος γίνεται βάσει δύο θεωρήσεων. Στην πρώτη περίπτωση, μία αλλαγή σημείου έχει συμβεί πριν την πρώτη τιμή των δεδομένων προς μελέτη και επομένως η συνάρτηση πιθανότητας μηδενίζεται για το αρχικό μήκος δεδομένων (τύπος 4). Αντίθετα στη δεύτερη περίπτωση γίνεται η μελέτη σε ένα πρόσφατο υποσύνολο δεδομένων και η οριακή συνθήκη διαμορφώνεται από την κανονικοποιημένη «συνάρτηση επιβίωσης» (survival function) (τύπος 5), η οποία υποδεικνύει το χρονικό διάστημα στο τέλος του οποίου ένα ή περισσότερα γεγονότα να συμβούν. Οι συνθήκες με μαθηματική μορφή φαίνονται παρακάτω.

$$P(r_0 = 0) = 1 \quad (4)$$

$$P(r_0 = \tau) = \frac{1}{Z} \tilde{S}(\tau) \quad (5),$$

Οι τελεστές που απαρτίζουν τον τύπο 5, είναι η κανονικοποιημένη σταθερά Z και $\tilde{S}(\tau) = \sum_{t=r+1}^{\infty} P_{gap}(g = t)$ (6).

Η υπολογιστική αποδοτικότητα του αλγορίθμου οφείλεται στη μορφή της συνάρτησης πιθανότητας να υπάρξει ένα σημείο αλλαγής, βασιζόμενη στα

προηγούμενα δεδομένα $P(r_t|r_{t-1})$. Η συνάρτηση αυτή είναι παντού μηδενική εκτός από όταν αυξάνεται το μήκος δεδομένων καθώς προστίθεται μία νέα τιμή σε αυτό ($r_t = r_{t-1} + 1$) και όταν παρατηρείται ένα νέο σημείο αλλαγής ($r_t = 0$). Πιο παραστατικά η συνάρτηση της πιθανότητας αυτής είναι

$$P(r_t|r_{t-1}) = \begin{cases} H(r_{t-1} + 1), & r_t = 0 \\ 1 - H(r_{t-1} + 1), & r_t = r_{t-1} + 1 \\ 0, & \text{διαφορετικά} \end{cases} \quad (7)$$

όπου $H(\tau)$ είναι η «συνάρτηση κινδύνου» (hazard function) και παρουσιάζει ποια τμήματα δεδομένων έχουν υψηλότερη ή χαμηλότερη πιθανότητα να συμβεί ένα γεγονός και ισούται με

$$H(\tau) = \frac{P_{gap}(g = \tau)}{\sum_{t=\tau}^{\infty} P_{gap}(g = t)} \quad (8).$$

Στην ειδική περίπτωση που η συνάρτηση $P_{gap}(g = \tau)$ ακολουθεί εκθετική κατανομή με παράμετρο λ , τότε η συνάρτηση κινδύνου είναι σταθερή και ισούται με $H(\tau) = 1/\lambda$ (9).

Ένα ιδιαίτερα χρήσιμο εργαλείο για την ανίχνευση ανωμαλιών και ουσιαστικά για τον αλγόριθμο που περιγράφεται σε αυτή την εργασία, είναι τα εκθετικά μοντέλα. Το γεγονός που τα καθιστά εύχρηστα είναι ότι μπορούν να προσφέρουν ένα σύνολο παραμετρικών κατανομών πιθανότητας και στατιστικών μεγεθών, τα οποία μπορούν να υπολογίζονται κατά τη διάρκεια συλλογής των δεδομένων. Η μορφή των πιθανοτήτων με βάση αυτά τα μοντέλα αναφέρονται για λόγους πληρότητας και φαίνονται στις εξισώσεις (10) και (11). Επίσης, αξίζει να σημειωθεί ότι η προβλεπτική κατανομή σε ένα τρέχον μήκος δεδομένων παραμετροποιείται από τα μεγέθη $v_t^{(r)}$ και $X_t^{(r)}$, όπου οι εξισώσεις τους παρουσιάζονται στην περιγραφή του αλγορίθμου σε βήματα.

$$P(x|n) = h(x)\exp(n^T U(x) - A(n)) \quad (10)$$

$$A(n) = \log \int dn h(x) \exp(n^T U(x)) \quad (11)$$

Συνοψίζοντας ο αλγόριθμος του οποίου η λειτουργία και οι παράμετροι αναλύθηκαν παραπάνω μπορεί να αποτυπωθεί στα παρακάτω βήματα.

- 1 αρχικοποίηση μέσω οριακών συνθηκών

$$P(r_0) = \tilde{S}(r) \text{ or } P(r_0 = 0) = 1$$

$$v_1^{(0)} = v_{prior}$$

$$\mathbf{X}_1^{(0)} = \mathbf{X}_{prior}$$

- 2 παρατήρηση της επόμενης τιμής των δεδομένων: x_t

- 3 εκτίμηση προβλεπτικής πιθανότητας

$$\pi_t^{(r)} = P(x_t | v_t^{(r)}, \mathbf{X}_t^{(r)})$$

- 4 υπολογισμός πιθανότητας καθώς αυξάνεται το τρέχον μήκος δεδομένων

$$P(r_t = r_{t-1} + 1, \mathbf{x}_{1:t}) = P(r_{t-1}, \mathbf{x}_{1:t-1}) \pi_t^{(r)} (1 - H(r_{t-1}))$$

- 5 υπολογισμός πιθανότητας για την ύπαρξη σημείου αλλαγής

$$P(r_t = 0, \mathbf{x}_{1:t}) = \sum_{r_{t-1}} P(r_{t-1}, \mathbf{x}_{1:t-1}) \pi_t^{(r)} H(r_{t-1})$$

- 6 υπολογισμός πιθανότητας στην ομάδα παρατηρήσεων, από την πρώτη μέχρι τη χρονική στιγμή t

$$P(\mathbf{x}_{1:t}) = \sum_{r_t} P(r_t, \mathbf{x}_{1:t})$$

- 7 ορισμός της κατανομής του μήκους δεδομένων

$$P(r_t | \mathbf{x}_{1:t}) = \frac{P(r_t, \mathbf{x}_{1:t})}{P(\mathbf{x}_{1:t})}$$

- 8 ανανέωση της τιμής των παραμέτρων

$$v_{t+1}^{(0)} = v_{prior}$$

$$\mathbf{X}_{t+1}^{(0)} = \mathbf{X}_{prior}$$

$$v_{t+1}^{(r+1)} = v_t^{(r)} + 1$$

$$\mathbf{X}_{t+1}^{(r+1)} = \mathbf{X}_t^{(r)} + \mathbf{u}(x_t)$$

- 9 υπολογισμός της οριακής προβλεπτικής κατανομής

$$P(x_{t+1} | \mathbf{x}_{1:t}) = \sum_{r_t} P(x_{t+1} | x_t^{(r)}, r_t) P(r_t | \mathbf{x}_{1:t})$$

10 επιστροφή στο βήμα 2, για παρατήρηση της επόμενης τιμής

Η χρονική και χωρική πολυπλοκότητα του αλγορίθμου είναι γραμμικής μορφής σε σχέση με το πλήθος των δεδομένων προς επεξεργασία και υπολογίζεται σε κάθε χρονική στιγμή βασιζόμενη στα δεδομένα που έχουν παρατηρηθεί μέχρι εκείνη τη στιγμή (Adams & MacKay, 2007).

Η παραπάνω περιγραφή δίνει μία σαφή εικόνα για τη λειτουργία και το στόχο ενός αλγορίθμου με «Bayesian» λογική. Στη συγκεκριμένη εργασία χρησιμοποιήθηκε ένας τέτοιος αλγόριθμος, ο οποίος υπολογίζει τα μεγέθη που απαιτούνται για τον υπολογισμό της πιθανότητας κάθε σημείου να είναι σημείο αλλαγής (log-likelihood). Με άλλα λόγια, ο αλγόριθμος δέχεται ως είσοδο τα δεδομένα στα οποία είναι επιθυμητή η ανίχνευση ανωμαλιών και ως αποτέλεσμα εξάγεται αρχικά για κάθε χρονική στιγμή που αντιστοιχεί στο σύνολο δεδομένων, η τιμή της πιθανότητας να είναι σημείο αλλαγής. Οι τιμές αυτές χρησιμοποιούνται ώστε να δημιουργηθεί το διάγραμμα που παρουσιάζει γραφικά την παραπάνω πληροφορία. Πιο συγκεκριμένα, οι τιμές των πιθανοτήτων που υπολογίζονται αφορούν το μέγεθος log-likelihood, το οποίο έχει λογαριθμικό χαρακτήρα και αρνητικό πρόσημο. Στο διάγραμμα που διαμορφώνεται ο κατακόρυφος άξονας είναι σε λογαριθμική κλίμακα και ο οριζόντιος αναπαριστά τον χρόνο.

Ένα ακόμα μέγεθος που προκύπτει από την εφαρμογή του αλγορίθμου είναι η θέση του σημείου με τη μεγαλύτερη πιθανότητα να είναι σημείο αλλαγής. Παρ' όλο που μπορεί η καμπύλη που παράγεται να έχει αρκετά σημεία με ικανή τιμή πιθανότητας ώστε να παρουσιάσει αλλαγή κατάστασης, ο αλγόριθμος επιστρέφει εκείνη με τη μεγαλύτερη τιμή πιθανότητας, δηλαδή το σημείο όπου η καμπύλη είναι στην πιο ψηλή θέση στο διάγραμμα. Στη συγκεκριμένη προσέγγιση επιστρέφει τη χρονική στιγμή όπου είναι πιο πιθανή η αλλαγή συμπεριφοράς. Τέλος επιστρέφει το μέσο όρο των τιμών που βρίσκονται σε όλες τις προηγούμενες χρονικές στιγμές από εκείνη που θεωρείται ως η πιο πιθανή για αλλαγή κατάστασης από τον αλγόριθμο. Όμοια υπολογίζεται ο μέσος όρος των τιμών του μεγέθους που μελετάται και βρίσκονται ύστερα από τη χρονική στιγμή που αναφέρθηκε προηγουμένως.

4. Εφαρμογή και Αξιολόγηση

4.1 Υλοποίηση

Η παρούσα εργασία υλοποιήθηκε με Python, έκδοση 3.7.3 και χρησιμοποιήθηκε το προγραμματιστικό περιβάλλον ανοικτού κώδικα της Spyder, έκδοση 4.1.5, προκειμένου να γραφεί και να επεξεργαστεί ο κώδικας που απαιτούνταν. Η Spyder είναι μία πλατφόρμα, η οποία διαθέτει αρκετά χρήσιμα επιστημονικά προγραμματιστικά πακέτα ή αλλιώς βιβλιοθήκες όπως η Pandas, NumPy, Matplotlib και πολλά άλλα.

Η Pandas είναι μία δημοφιλής, γρήγορη, ευέλικτη και εύκολη στη χρήση βιβλιοθήκη ανοικτού κώδικα, η οποία προσφέρεται για ανάλυση και διαχείριση δεδομένων μέσω της προγραμματιστικής γλώσσας Python. Μία επόμενη και χρήσιμη βιβλιοθήκη είναι η NumPy, μέσω της οποίας είναι πολύ πιο εύκολη η διαχείριση μεγάλων και πολυδιάστατων πινάκων και διαθέτει ένα μεγάλο σύνολο περίπλοκων μαθηματικών συναρτήσεων που μπορούν να εφαρμοστούν σε πίνακες. Επίσης χρησιμοποιήθηκε η βιβλιοθήκη Matplotlib για την οπτικοποίηση των δεδομένων και των αποτελεσμάτων μέσω γραφημάτων καθώς προσφέρει πολλά εργαλεία για τη δημιουργία στατικού, κινούμενου και διαδραστικού γραφικού περιβάλλοντος διεπαφής με τον χρήστη.

Προκειμένου να γίνει εκπαίδευση ενός νευρωνικού δικτύου καθώς και η πρόβλεψη και ανάλυση δεδομένων χρησιμοποιήθηκε η βιβλιοθήκη scikit-learn, η οποία παρέχει απλά και αποτελεσματικά εργαλεία για τον παραπάνω σκοπό. Είναι μία βιβλιοθήκη που έχει διαμορφωθεί με γνώμονα τις βιβλιοθήκες NumPy, SciPy και matplotlib.

Επιπλέον χρησιμοποιήθηκαν βιβλιοθήκες από την πλατφόρμα ανοικτού κώδικα TensorFlow, η οποία χρησιμοποιείται στο πεδίο της μηχανικής μάθησης και προσφέρει πολλές δυνατότητες στην ανάπτυξη και την διαχείριση οποιασδήποτε σχετικής εφαρμογής. Ένα πολύ χρήσιμο εργαλείο που προσφέρει είναι το Keras, το οποίο είναι μία απλή, ευέλικτη και ισχυρή βιβλιοθήκη και προσφέρει όλα τα μέσα ώστε να δημιουργηθεί και να διαμορφωθεί ένα νευρωνικό μοντέλο.


Τέλος χρησιμοποιήθηκαν κάποια πακέτα της Python για να διευκολύνουν κάποιες διεργασίες. Αρχικά χρησιμοποιήθηκε το πακέτο datetime, το οποίο παρέχει κλάσεις για τη διαχείριση ημερομηνιών και ωρών και έπειτα το πακέτο μαθηματικών συναρτήσεων math προκειμένου να γίνουν αριθμητικές πράξεις όπως ο υπολογισμός του λογάριθμου ενός αριθμού. Ένα ακόμη πακέτο που χρησιμοποιήθηκε ήταν το glob με σκοπό τη διαχείριση των διευθύνσεων – μονοπατιών των αρχείων που καλούνταν να επεξεργαστεί ο κώδικας.

4.2 Περιγραφή συνόλου δεδομένων

Για την παρούσα μελέτη χρησιμοποιήθηκαν δεδομένα που προήλθαν από τη βιομηχανική εγκατάσταση MAILLIS, η οποία διεξάγει ψυχρή έλαση σε μέταλλα. Η διαδικασία αυτή ουσιαστικά μειώνει το πάχος του μετάλλου ή το αναδιαμορφώνει μέσω δύο ραούλων, τα οποία στρέφονται με την αντίθετη φορά από αυτή της κίνησης του μετάλλου. Για να γίνει αυτή η διαδικασία θα πρέπει η θερμοκρασία του μετάλλου να είναι χαμηλότερη από εκείνη όπου το μέταλλο επανακρυσταλλοποιείται. Η διαδικασία της ψυχρής έλασης που πραγματοποιείται στη συγκεκριμένη μονάδα αλλάζει το πάχος του μετάλλου στο βέλτιστο μικρότερο πάχος με τέλεια λεία επιφάνεια. Για παράδειγμα, αν εισαχθεί στον εξοπλισμό μέταλλο βάρους 4 τόνων και πάχους 2 χιλιοστών, το πάχος του μετάλλου που θα εξαχθεί απ' τον εξοπλισμό μπορεί να ανήκει σε ένα ευρύ φάσμα με μικρότερο μέγεθος εκείνο των 0.4 χιλιοστών (Bousdekis, Lepenioti, Ntalaperas, Vergeti, Apostolou, & Boursinos, 2019). Κατά τη διάρκεια της διαδικασίας ολόκληρη η μονάδα είναι κλεισμένη σε πλέγμα για λόγους ασφαλείας και τα ράουλα ψεκάζονταν διαρκώς με έλαιο προκειμένου να μειωθεί η θερμότητα και η τριβή μεταξύ των ραούλων και του μετάλλου.

Τα πιο σημαντικά μέρη του εξοπλισμού είναι αρχικά το ζευγάρι των ραούλων που την πραγματοποιεί την ψυχρή έλαση (working rolls) και το μέταλλο περνάει ανάμεσά

τους προκειμένου να μειωθεί το πάχος του όπως περιεγράφηκε παραπάνω. Υπάρχει ακόμα ένα ζευγάρι ραούλων (back-up rolls) με μεγαλύτερη διάμετρο από εκείνη των πρώτων και είναι τοποθετημένο εξωτερικά τους, όπως φαίνεται στο σχήμα 10(α). Τα δεύτερα ράουλα κινούνται με αντίθετη φορά από εκείνη των πρώτων και ο ρόλος του είναι να βοηθούν την κίνηση των πρώτων ώστε να αποφεύγεται η κάμψη τους. Τέλος αναπόσπαστο κομμάτι του εξοπλισμού είναι ο κινητήρας που περιστρέφει τα ράουλα (Bousdekis, Lepenioti, Ntalaperas, Vergeti, Apostolou, & Boursinos, 2019). Η σύνθεση των παραπάνω συστημάτων πραγματοποιεί ψυχρή έλαση σε μέταλλα όπως αναλύθηκε και φαίνεται στο σχήμα 10(β). Στα σχήματα 10(γ) και 10(δ) φαίνεται το μπροστινό αλλά και το πίσω μέρος των ραούλων αντίστοιχα μαζί με την ακριβή θέση των αισθητήρων σε εκείνα.



(α)



(β)



(γ)



(δ)

Σχήμα 10: (α) η διάταξη των ραούλων του εξοπλισμού, (β) η μονάδα ψυχρής έλασης, (γ) το μπροστινό και (δ) το πίσω μέρος των ραούλων και οι αντίστοιχοι αισθητήρες.

Ολόκληρη η μονάδα της ψυχρής έλασης απαιτεί συντήρηση λόγω φυσιολογικής φθοράς αλλά και απροσδόκητης βλάβης στον εξοπλισμό. Γι' αυτό το λόγο κρίνεται αναγκαία η εφαρμογή της προβλεπτικής συντήρησης και επομένως η συλλογή και ανάλυση δεδομένων που αφορούν τη λειτουργία του εξοπλισμού. Πιο συγκεκριμένα έχουν τοποθετηθεί 10 αισθητήρες στον εξοπλισμό της ψυχρής έλασης, σε θέσεις που φαίνονται στα σχήματα 10(γ) και 10(δ), προκειμένου να συλλέξουν δεδομένα σχετικά με τις δονήσεις. Επίσης στη μονάδα ψυχρής έλασης υπάρχει ένας αισθητήρας που μετράει την ταχύτητα του κινητήρα και ακόμα ένας που μετράει το ρεύμα του. Στη συγκεκριμένη μελέτη μας ενδιαφέρουν μόνο τα δεδομένα που συλλέγονται από τους πρώτους. Αναλυτικότερα οι αισθητήρες αυτοί καταγράφουν τιμές για τέσσερις διαφορετικές μεταβλητές ανά δέκα δευτερόλεπτα που αφορούν μετρήσεις δονήσεων (vibration data). Αυτές είναι η επιτάχυνση (acceleration), η κατάσταση των ραούλων ως προς την αντίσταση και τις δονήσεις (overall bearing), η απότομη αλλαγή κατάστασης (shock) και η ταχύτητα (velocity) και οι μονάδες μέτρησής του φαίνονται στον πίνακα 4. Οι μετρήσεις αυτές αφορούσαν το χρονικό διάστημα από 26/8/2019 έως 11/12/2019 και το πλήθος των αρχείων που δημιουργήθηκαν από διαφορετικούς αισθητήρες ήταν δέκα σε πλήθος με μέγεθος που κυμαινόταν από 500.000 μέχρι 740.000 δεδομένα για κάθε ένα μέγεθος που προαναφέρθηκε.

Μέγεθος	Μονάδα μέτρησης
Acceleration	mm/s ²
Overall bearing	απόλυτος αριθμός
Shock	απόλυτος αριθμός
velocity	mm/s

Πίνακας 4: Μεγέθη που καταγράφονται από τους αισθητήρες και οι μονάδες μέτρησής τους.

Προτού τοποθετηθούν οι αισθητήρες και εισαχθεί η δυνατότητα της προβλεπτικής συντήρησης, η συντήρηση του εξοπλισμού γινόταν βασιζόμενη σε χρονοδιάγραμμα ανά 8 ώρες χωρίς να λαμβάνεται υπόψιν η κατάσταση λειτουργίας του εξοπλισμού και η κατάσταση στην οποία βρίσκονταν τα ράουλα. Όταν αποσυνδέονταν λοιπόν τα

ράουλα από τον εξοπλισμό προκρίμενου να πραγματοποιηθεί η προγραμματισμένη συντήρηση, ανάλογα με την κατάσταση στην οποία βρίσκονταν είτε επιδιορθώνονταν είτε αντικαθίσταντο. Με αυτόν τον τρόπο όμως υπήρχε πιθανότητα αντικατάστασης του εξοπλισμού νωρίτερα απ' ότι θα μπορούσε να γίνει και ως αποτέλεσμα χανόταν από εκείνον λειτουργικός χρόνος και ακολούθως δεν επιτυγχανόταν το βέλτιστο κέρδος από εκείνον. Απ' την άλλη πλευρά ενδιάμεσα από τις διαδικασίες συντήρησης μπορούσε να συμβεί μία απρόβλεπτη βλάβη σε κάποιο ράουλο, η οποία έθετε εκτός λειτουργίας ολόκληρη τη μονάδα στην οποία ανήκε, γεγονός που ζημίωνε την παραγωγική διαδικασία όλης της βιομηχανικής μονάδας.

Παράλληλα οι εργαζόμενοι που ήταν υπεύθυνοι για την επίβλεψη της λειτουργίας των ραούλων κατέγραφαν σε ένα αρχείο τα αναγνωριστικά στοιχεία του κάθε ενός καθώς και την ημερομηνία και ώρα έναρξης λειτουργίας του μηχανήματος με το συγκεκριμένο ράουλο και αντίστοιχα την ημερομηνία και ώρα λήξης λειτουργίας του, η οποία μας δείχνει τη στιγμή που συνέβη κάποια βλάβη. Οι βλάβες αυτές μπορεί να προέρχονταν από φυσιολογική φθορά του ραούλου ή από κάποια βλάβη κατά τη λειτουργία του. Ενδιαφέρον προς μελέτη παρουσιάζει η δεύτερη κατηγορία και αναφέρεται σε βλάβες όπως το σκάσιμο, το σπάσιμο, το φρακάρισμα, τα σημάδια ή ένα συνδυασμό των παραπάνω. Σε αυτό το σημείο αξίζει να αναφερθεί ότι η καταγραφή της ώρας λήξης ενδέχεται να έχει μία απόκλιση από την πραγματική τιμή, της τάξης του λεπτού λόγω του ανθρώπινου παράγοντα. Αυτή η μικρή μετατόπιση στο χρόνο της ώρας λήξης έχει προσθέσει στα δεδομένα μας κάποιες τιμές μετά από εκείνη της βλάβης, γεγονός όμως που δεν θα προκαλέσει σημαντική αλλοίωση στα αποτελέσματα που θα παραχθούν.

Έτσι λοιπόν συνδυάζοντας αυτές τις δύο πηγές πληροφοριών δημιουργήθηκαν δεκαπέντε νέα αρχεία σε μορφή csv που αναφέρονταν μόνο σε συγκεκριμένο χρονικό διάστημα ενδιαφέροντος και για μία βλάβη το καθένα. Επιλέχθηκαν μόνο οι βλάβες που είχαν μια ικανοποιητική χρονική διάρκεια ώστε να υπάρχουν αρκετά δεδομένα προς επεξεργασία και να είναι πιο ασφαλή τα όποια συμπεράσματα θα προέρχονταν από την επεξεργασία αυτή. Ένα δεύτερο κριτήριο επιλογής ήταν η ύπαρξη ποικιλίας στις βλάβες ώστε να μελετηθούν όλες επαρκώς, αγνοώντας φυσικά τη φυσιολογική φθορά. Το αποτέλεσμα αυτής της επιλογής ήταν να δημιουργηθούν τα δεκαπέντε αυτά αρχεία με τα χαρακτηριστικά που φαίνονται στον Πίνακα 5.

	Βλάβη	ημερομηνία	Ωρα έναρξης	Ωρα λήξης	Διάρκεια καταγραφής δεδομένων	Μέγεθος αρχείου (δεδομένα)
1	σκάσιμο	12/9/2019	15:00	23:40	8 ώρες 40 λεπτά	2931
2	σκάσιμο	20/9/2019	15:00	18:25	3 ώρες 25 λεπτά	1143
3	σκάσιμο	5/11/2019	15:00	2:05	11 ώρες 5 λεπτά	3885
4	σκάσιμο	28/11/2019	15:00	18:55	3 ώρες 55 λεπτά	1328
5	σπάσιμο	3/10/2019	15:00	20:10	5 ώρες 10 λεπτά	1801
6	σπάσιμο	6/12/2019	7:00	16:15	9 ώρες 15 λεπτά	3116
7	σπάσιμο	10/12/2019	2:20	7:30	5 ώρες 10 λεπτά	1719
8	φρακάρισμα	26/9/2019	23:00	4:00	5 ώρες	1657
9	φρακάρισμα	10/12/2019	9:30	15:20	5 ώρες 50 λεπτά	1956
10	σημάδια	4/9/2019	7:00	13:00	6 ώρες	2068
11	σημάδια	6/11/2019	15:00	20:40	5 ώρες 40 λεπτά	1981
12	σημάδια	22/11/2019	7:00	8:45	1 ώρα 45 λεπτά	606
συνδυασμός βλαβών						
13	Σκάσιμο και σημάδια	24/10/2019	15:00	18:40	3 ώρες 40 λεπτά	1243
14	Σκάσιμο και σημάδια	11/12/2019	4:20	7:10	2 ώρες 50 λεπτά	959
15	Φρακάρισμα και σημάδια	3/12/2019	22:30	1:05	2 ώρες 35 λεπτά	881

Πίνακας 5: περιγραφή αρχείων που προέκυψαν και αποτελούν τα δεδομένα προς περαιτέρω επεξεργασία.

Το κάθε αρχείο από αυτά που δημιουργήθηκαν εκ νέου, περιέχουν έξι στήλες εκ των οποίων η πρώτη αναφέρεται στο όνομα του ραούλου, ανάλογα με τη θέση του αισθητήρα σε αυτό. Η δεύτερη στήλη έχει την ημερομηνία και την ώρα σε μορφή timestamp UTC ώστε να είναι εκφρασμένη σε παγκόσμια βάση και όχι σε τοπική ώρα και οι υπόλοιπες τέσσερις στήλες αναφέρονται στις τιμές των μεγεθών που παράγουν οι αισθητήρες και τα δεδομένα αυτά αποτελούν χρονοσειρές.

Για την καλύτερη ανάλυση και κατανόηση της συμπεριφοράς κάθε μεγέθους, που βρίσκεται στις τέσσερις αυτές στήλες του αρχείου, στην ομαλή λειτουργία αλλά και τη στιγμή της βλάβης βρέθηκε η μέγιστη και η ελάχιστη τιμή κάθε ενός με τη βοήθεια της Python και τα αποτελέσματα φαίνονται στους Πίνακα 6 και Πίνακα 7.

Μέγιστη τιμή				
	Acceleration	Overall bearing	shock	velocity
1	6.85305	3.554553	1	353.089
2	1.714163	4.713173	0	2.01879
3	4.672617	7.842309	0	13.21228
4	0.474517	7.782812	0	2.23817
5	2.431763	5.949059	0	25.35853
6	2.331308	6.921682	0	47.79137
7	1.830614	5.475924	0	15.38477
8	0.505013	3.840388	0	1.135958
9	0.829451	3.728596	3.079945	13.16094
10	0.915634	6.885503	0	1.400537
11	3.862491	6.424241	0	145.579
12	0.889853	8.142121	0	3.800718
13	1.899441	8.127891	0	2.599594
14	0.426116	2.960805	7.485986	2.452092
15	0.197208	7.420845	0	2.114257

Πίνακας 6: Η μέγιστη τιμή κάθε μεγέθους που περιγράφεται στα αρχεία δεδομένων.

Ελάχιστη τιμή				
	Acceleration	Overall bearing	shock	velocity
1	0.0013902	0.002396	0	0.023945792
2	0.001504	0.002424	0	0.033166073
3	0.0192347	2.878508	0	0.054428205
4	0.021451	0	0	0.034355883
5	0.0013823	0.001932	0	0.046641894
6	0.0017343	0	0	0.060338125
7	0.0015654	0.002133	0	0.039025065
8	0.0014066	0.00232	0	0.027720286
9	0.0011185	0	0	0
10	0.0012836	0.001977	0	0.034850989
11	0.0018293	0.002719	0	0.052079022
12	0.0130262	0.025779	0	0.098794945
13	0.0018091	0.002009	0	0.071153969
14	0.0011283	0.001149	0	0
15	0.0239427	0	0	0.029037541

Πίνακας 7: Η ελάχιστη τιμή κάθε μεγέθους που περιγράφεται στα αρχεία δεδομένων.

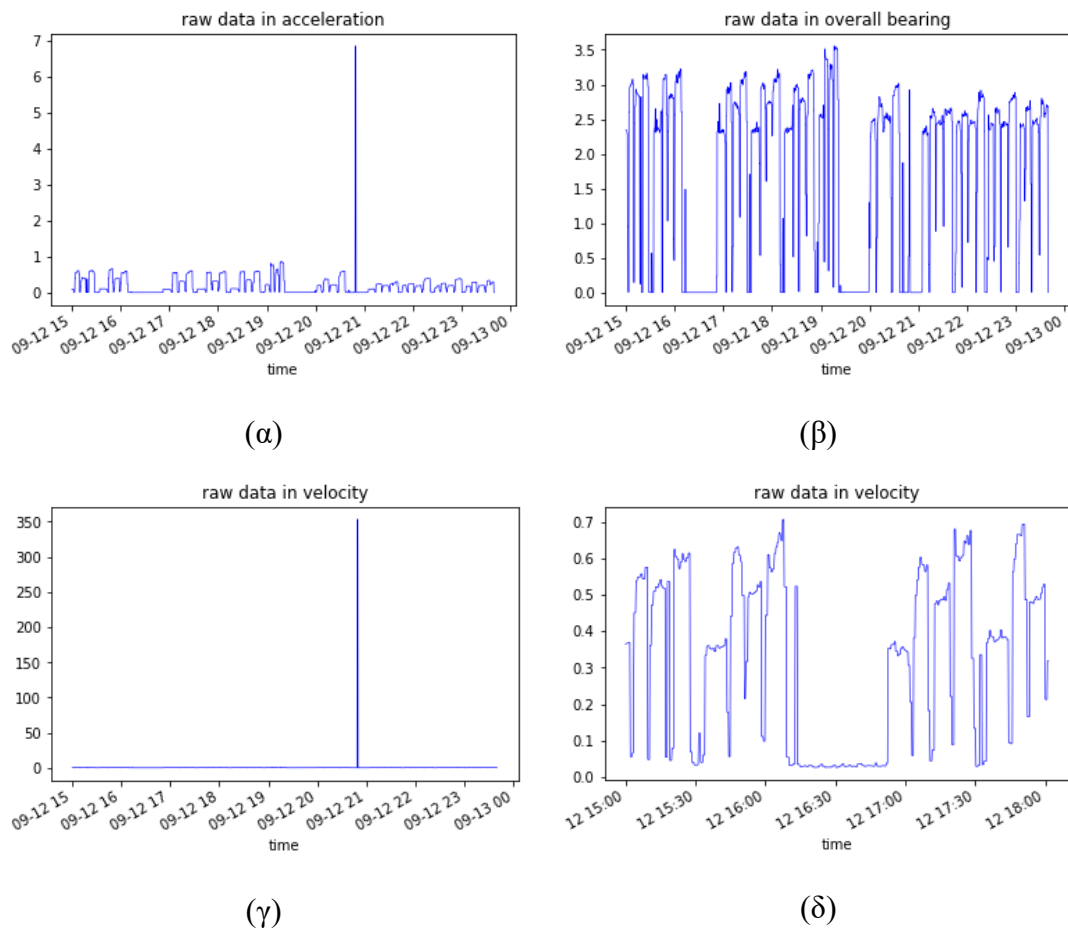
Από την παραπάνω περιγραφή των δεδομένων προκύπτει αρχικά ότι το μέγεθος «shock» περιγράφει την ύπαρξη ή όχι κάποιας σημαντικής διαταραχής στη λειτουργία της διάταξης. Η μη ύπαρξή της περιγράφεται με μία μηδενική τιμή ενώ η αντίθετη κατάσταση με μία θετική τιμή. Η επιτάχυνση (acceleration) παίρνει μόνο θετικές τιμές με ελάχιστη τιμή πολύ κοντά στο μηδέν ενώ η μέγιστη δεν ξεπερνά το 7. Παρόμοια συμπεριφορά εμφανίζει και το δεύτερο μέγεθος (overall bearing) με τη μέγιστη τιμή του να μην ξεπερνά το 8. Τέλος, η ταχύτητα (velocity) παρουσιάζει και εκείνη ελάχιστη τιμή πολύ κοντά στο 0 αλλά η μέγιστη τιμή της είναι αρκετά μεγαλύτερη συγκριτικά με εκείνη των δύο προηγούμενων μεγεθών.

Στον πίνακα 8 αντιπαραβάλλεται η μέγιστη τιμή του μεγέθους velocity με την μέση τιμή των δεδομένων του κάθε συνόλου δεδομένων με σκοπό να φανεί η διαφοροποίηση

μερικών τιμών από τον μέσο όρο. Αναλυτικότερα, η ταχύτητα (velocity) σε κάποιες περιπτώσεις παρουσιάζει σε κάποια χρονική στιγμή μία πολύ μεγαλύτερη τιμή σχετικά με τις υπόλοιπες. Το γεγονός αυτό γίνεται εμφανές μέσω της σύγκρισης της μεγαλύτερης τιμής της ταχύτητας με τον αντίστοιχο μέσο όρο (Πίνακας 8) και από το διάγραμμα που αποτυπώνονται όλα τα μεγέθη ενός συνόλου δεδομένων (raw data) (Σχήμα 11). Το παράδειγμα αυτό αφορά το σύνολο δεδομένων με ημερομηνία 12/9/2019 και βλάβη «σκάσιμο».

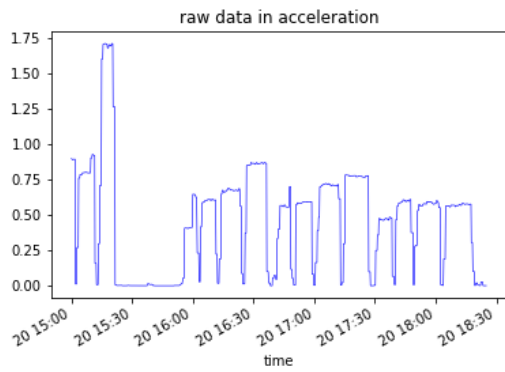
	Μέγιστη τιμή velocity	Μέση τιμή velocity
1	353.089	0.9446835
2	2.01879	0.6408098
3	13.21228	0.9503354
4	2.23817	0.4293525
5	25.35853	0.385453
6	47.79137	0.3873443
7	15.38477	0.2253589
8	1.135958	0.2814984
9	13.16094	0.1697181
10	1.400537	0.5015921
11	145.579	0.7935178
12	3.800718	0.4695365
13	2.599594	0.5245759
14	2.452092	0.1438348
15	2.114257	0.2332838

Πίνακας 8: Η μέγιστη τιμή και η μέση τιμή της επιτάχυνσης.

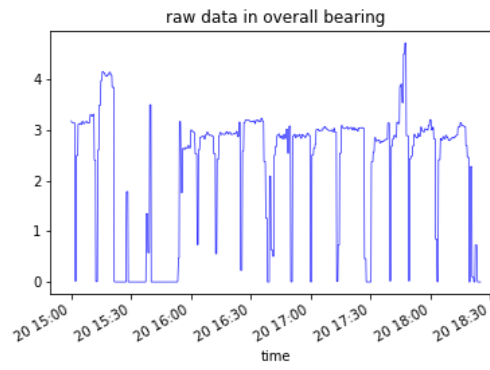


Σχήμα 11: Αναπαράσταση όλων των μεγεθών του συνόλου δεδομένων: (α) acceleration, (β) overall bearing, (γ) velocity, (δ) velocity σε μεγέθυνση.


Τα παραπάνω διαγράμματα απεικονίζουν τα δεδομένα για κάθε ένα από τα μεγέθη που καταγράφει ο αισθητήρας. Από το σχήμα 11(α) που αφορά την επιτάχυνση παρατηρούμε ότι υπάρχει μία τιμή που διαφοροποιείται από τις υπόλοιπες αλλά επιτρέπει να φανεί έως ένα βαθμό και η διακύμανση των υπόλοιπων τιμών, καθώς δεν υπάρχει τεράστια απόκλιση ανάμεσα στη μέγιστη και τις υπόλοιπες. Αντίθετα στην περίπτωση της ταχύτητας (σχήμα 11(γ)) είναι εμφανές ότι η διακύμανση των τιμών δεν υπάρχει και όλες παρουσιάζονται ως μία ευθεία γραμμή πολύ κοντά στο μηδέν, την οποία διακόπτει μία κάθετη που αναπαριστά την μέγιστη τιμή. Αν αποτυπώσουμε κάποιες τιμές πριν από αυτή τη μέγιστη τιμή, όπως φαίνεται σχήμα 11(δ), θα παρατηρήσουμε ότι υπάρχει διαφορά μεταξύ των δεδομένων της ταχύτητας και δεν είναι μηδενικές. Τέλος ένα αντιπαράδειγμα, όπου δεν υπάρχουν μεγάλες διαφορές στις τιμές και είναι ευδιάκριτη η διακύμανσή τους, παρουσιάζεται στο σχήμα 12 και αφορά το αρχείο με ημερομηνία 20/9/2019 και βλάβη επίσης «σκάσιμο».



(α)



(β)



(γ)

Σχήμα 12: Αναπαράσταση όλων των μεγεθών του συνόλου δεδομένων: (α) acceleration, (β)overall bearing, (γ)velocity.

Παρατηρώντας όλα τα διαγράμματα που προκύπτουν από τα μεγέθη που καταγράφονται από τους αισθητήρες για κάθε σύνολο δεδομένων και την ιδιαιτερότητα που παρουσιάζεται στο σχήμα 11(γ) προκύπτει ότι η μεγάλη τιμή της ταχύτητας πιθανόν να προέρχεται από αναταραχή στο περιβάλλον του αισθητήρα και δεν ερμηνεύεται με φυσικό τρόπο ώστε να σχετίζεται με το μέγεθος της ταχύτητας και την συμπεριφορά του εξοπλισμού.

4.3 Αξιολόγηση της Προτεινόμενης Προσέγγισης

Προκειμένου να μελετήσουμε και να αξιολογήσουμε την ανίχνευση ανωμαλιών σε βιομηχανικά δεδομένα πραγματοποιήθηκαν τέσσερα πειράματα, τα οποία χωρίζονται σε δύο κατηγορίες. Η πρώτη κατηγορία έχει ως στόχο τη μελέτη και ανάλυση των δεδομένων αφού έχει πραγματοποιηθεί η βλάβη στον εξοπλισμό, ενώ η δεύτερη στοχεύει στην πρόβλεψή της. Έτσι λοιπόν τα δύο πρώτα πειράματα επεξεργάζονται τα δεδομένα που προκύπτουν από τους σένσορες (raw data) και αναλύθηκαν παραπάνω, ενώ τα δύο επόμενα επεξεργάζονται αυτά που δίνει ως έξοδο το νευρωνικό δίκτυο (predicted values). Τα μεγέθη που προκύπτουν από την καταγραφή των αισθητήρων και έχουν ενδιαφέρον ανάλυσης είναι τα acceleration, overall bearing και velocity ενώ απορρίπτεται το μέγεθος shock καθώς δεν διαθέτει χρήσιμη πληροφορία για την ανάλυση των δεδομένων πέρα από την ύπαρξη μιας διαταραχής. Επίσης χρήσιμη παρατήρηση είναι ότι τα σύνολα δεδομένων είναι χρονοσειρές και επομένως ο χρόνος είναι ένας σημαντικός παράγοντας στη συγκεκριμένη μελέτη. Τα δομικά στοιχεία αυτών των πειραμάτων είναι οι τρεις αλγόριθμοι, των οποίων η λειτουργία και η δομή έχει αναλυθεί παραπάνω, σε διάφορους συνδυασμούς όπως περιγράφεται και παρακάτω.


4.3.1 Διάγνωση αλλαγής κατάστασης της υγείας του εξοπλισμού

Σε αυτή την κατηγορία πειραμάτων η ανάλυση αφορά το σύνολο των δεδομένων αφού έχει γίνει η καταγραφή τους σε προηγούμενο χρονικό διάστημα και αφού έχει διαγνωσθεί το σφάλμα και το είδος του.


4.3.1.1 Πείραμα 1: Online Bayesian Changepoint Detection

Στο πρώτο πείραμα εφαρμόζεται ο αλγόριθμος Bayesian online changepoint detection (BOCD) στα raw data για κάθε σύνολο δεδομένων και προκύπτει μία καμπύλη που αναπαριστά την πιθανότητα κάθε σημείο να αναφέρεται σε βλάβη ή σε κάποια λειτουργία διαφορετική της φυσιολογικής. Η δομή του πειράματος φαίνεται

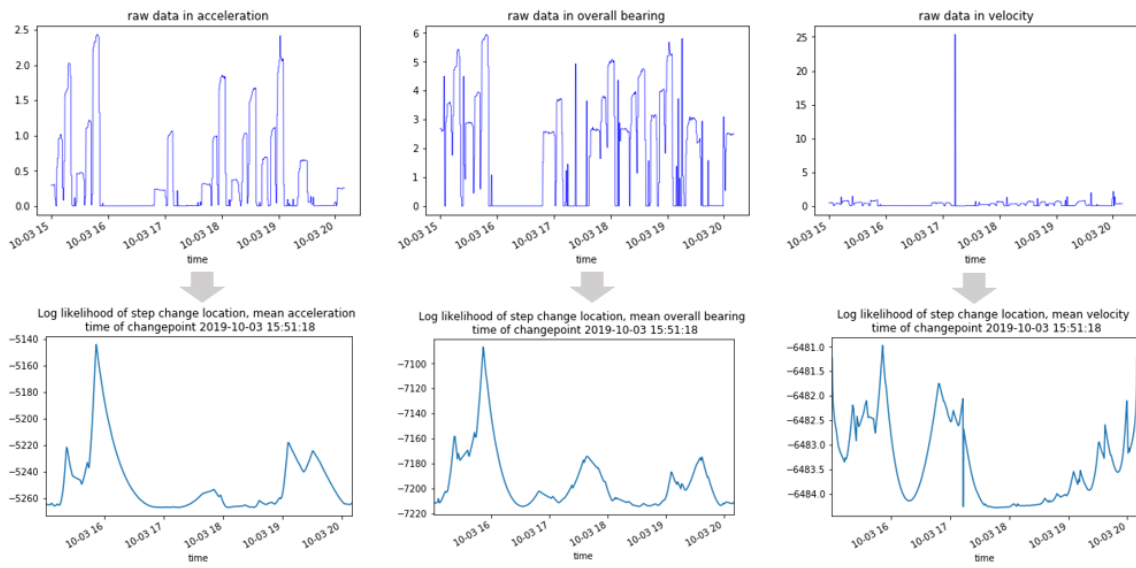
στο Σχήμα 13 και στο Σχήμα 14 φαίνεται το αποτέλεσμα της εφαρμογής του αλγορίθμου για το μέγεθος acceleration και για τη βλάβη «σπάσιμο» μαζί με τα raw data στα οποία εφαρμόστηκε ο αλγόριθμος. Στα επόμενα σχεδιαγράμματα (σχήματα 15 έως 19) απεικονίζονται τα αποτελέσματα του πειράματος σε κάποια σύνολα δεδομένων ενδεικτικά και πιο συγκεκριμένα ένα από κάθε βλάβη ώστε να παρουσιάζεται η γενικότερη εικόνα των αποτελεσμάτων του πειράματος. Πιο συγκεκριμένα, στα σχήματα αυτά, η πρώτη σειρά αναπαριστά τα raw data του κάθε μεγέθους από τα acceleration, overall bearing και velocity ενός συνόλου δεδομένων και η δεύτερη δείχνει το αποτέλεσμα της εφαρμογής του αλγορίθμου BOCD σε κάθε ένα από αυτά ξεχωριστά.



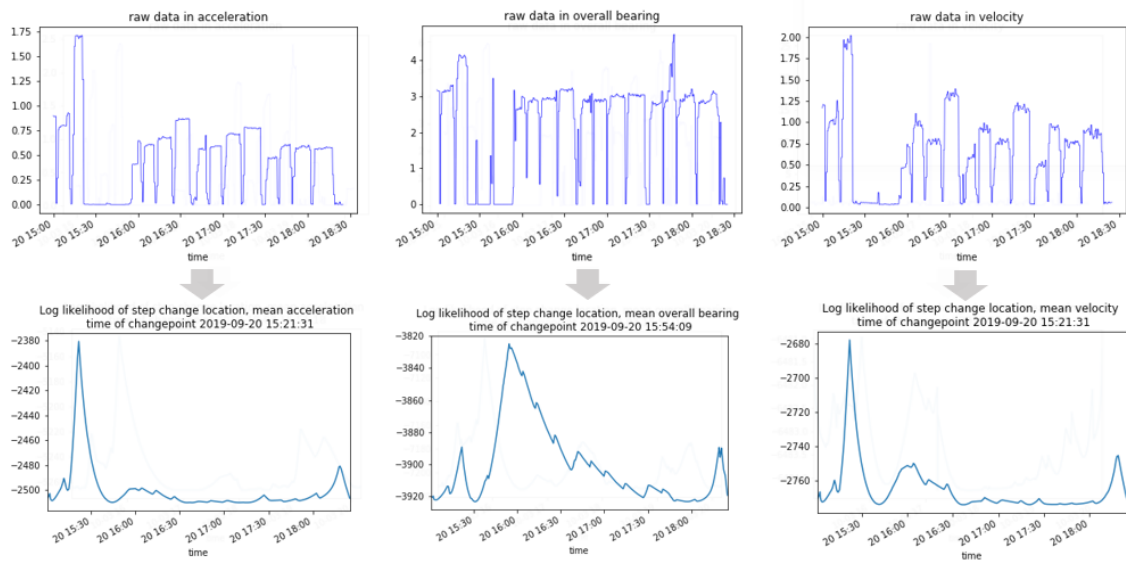
Σχήμα 13: Η δομή του πειράματος 1.



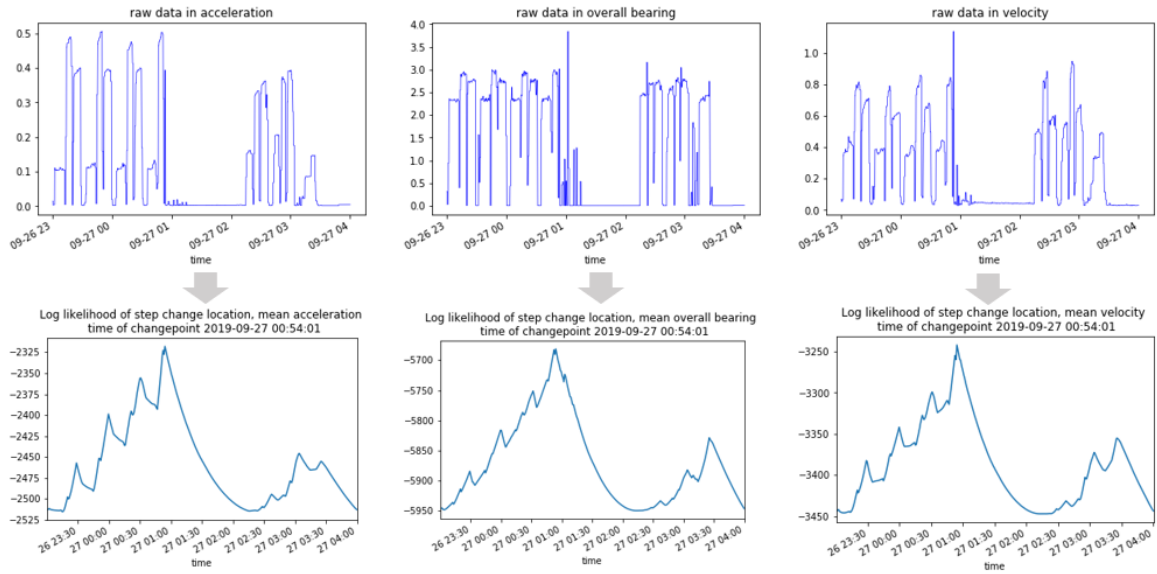
Σχήμα 14: Εφαρμογή του αλγορίθμου BOCD στα raw data για το μέγεθος acceleration για τη βλάβη «σπάσιμο».



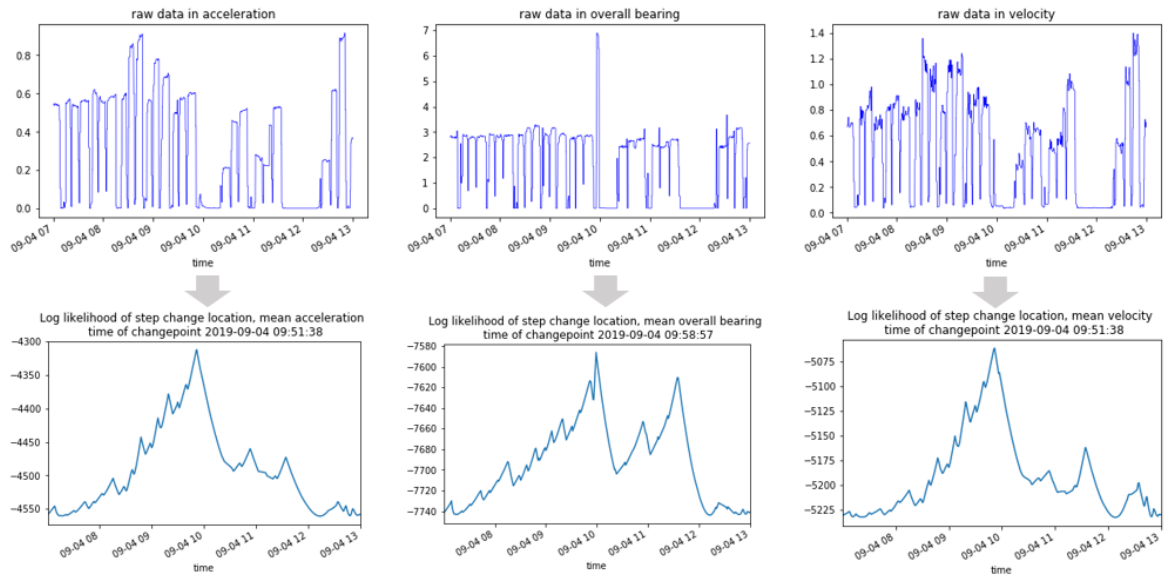
Σχήμα 15 : Εφαρμογή του αλγορίθμου BOCD στα raw data για τα μεγέθη acceleration, overall bearing και velocity και τη βλάβη «σπάσιμο».



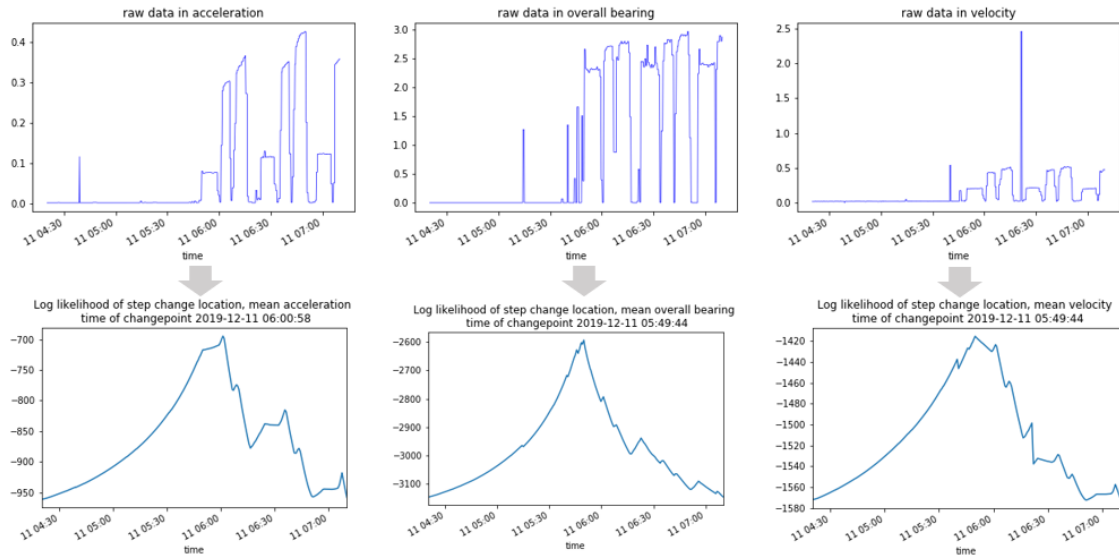
Σχήμα 16: Εφαρμογή του αλγορίθμου BOCD στα raw data για τα μεγέθη acceleration, overall bearing και velocity και τη βλάβη «σκάσιμο».



Σχήμα 17: Εφαρμογή του αλγορίθμου BOCD στα raw data για τα μεγέθη acceleration, overall bearing και velocity και τη βλάβη «φρακάρισμα».



Σχήμα 18: Εφαρμογή του αλγορίθμου BOCD στα raw data για τα μεγέθη acceleration, overall bearing και velocity και τη βλάβη «σημάδια».



Σχήμα 19: Εφαρμογή του αλγορίθμου BOCD στα raw data για τα μεγέθη acceleration, overall bearing και velocity του συνδυασμού βλαβών «σκάσιμο» και «σημάδια».

Το αποτέλεσμα από την εφαρμογή του αλγορίθμου Bayesian online changepoint detection όπως φαίνεται και από τα παραπάνω διαγράμματα είναι μία καμπύλη που παρουσιάζει αιχμές και η μέγιστη αιχμή καταδεικνύει τη χρονική στιγμή με τη μεγαλύτερη πιθανότητα να συμβεί κάποια αλλαγή στην κατάσταση λειτουργίας ή βλάβη. Στον κατακόρυφο άξονα βρίσκεται το μέγεθος της πιθανότητας σε λογαριθμική κλίμακα (log likelihood) ενώ στον οριζόντιο φαίνεται ο χρόνος που υποδηλώνεται από το μήνα, τη μέρα και την ώρα για το χρονικό διάστημα της λειτουργίας του εξοπλισμού που μελετάμε. Ιδανικά θα θέλαμε κάθε καμπύλη να έχει μόνο μία έντονη αιχμή ώστε να προσδιορίζεται με ακρίβεια η χρονική στιγμή της βλάβης καθώς γνωρίζουμε ότι συνέβη και μάλιστα, χρονικά, στο τελευταίο μέρος του συνόλου των δεδομένων. Όμως ο αλγόριθμος BOCD είναι αρκετά ευαίσθητος στον θόρυβο και τα σήματα που επεξεργάζεται προέρχονται από δονήσεις στον βιομηχανικό τομέα και επομένως περιέχουν θόρυβο που δεν έχει απομονωθεί προηγουμένως. Είναι ευδιάκριτο άλλωστε από τη μορφή που έχουν τα raw data ότι εμπεριέχουν παρασιτικά σήματα. Αυτός είναι και ο λόγος για τον οποίο τα πειραματικά μας αποτελέσματα δεν έχουν την ιδανική μορφή και η πληροφορία που μας δίνει δεν χαρακτηρίζεται από ακρίβεια και αξιοπιστία.

Παράλληλα με την καμπύλη που εξάγει ο αλγόριθμος καταγράφηκε και η ακριβής χρονική στιγμή που θεωρείται από εκείνον ως ανωμαλία στη λειτουργία του εξοπλισμού ή βλάβη για κάθε ένα από τα σύνολα δεδομένων. Χάριν σύγκρισης με τα διαγράμματα που αποτυπώνονται παραπάνω, καταγράφηκαν στον πίνακα 9 τα αντίστοιχα αποτελέσματα και για τα τρία μεγέθη των αισθητήρων που μας ενδιαφέρουν.

βλάβη	acceleration	overall bearing	velocity
4/9/2019 σημάδια	2019-09-04 09:51:38	2019-09-04 09:58:57	2019-09-04 09:51:38
20/9/2019 σκάσιμο	2019-09-20 15:21:31	2019-09-20 15:54:09	2019-09-20 15:21:31
26/9/2019 φρακάρισμα	2019-09-27 00:54:01	2019-09-27 00:54:01	2019-09-27 00:54:01
3/10/2019 σπάσιμο	2019-10-03 15:51:18	2019-10-03 15:51:18	2019-10-03 15:51:18
11/12/2019 συνδυασμός βλαβών σκάσιμο και σημάδια	2019-12-11 06:00:58	2019-12-11 05:49:44	2019-12-11 05:49:44

Πίνακας 9: Χρονική στιγμή που θεωρείται βλάβη ή ανωμαλία από τον αλγόριθμο BOCD ανά βλάβη.

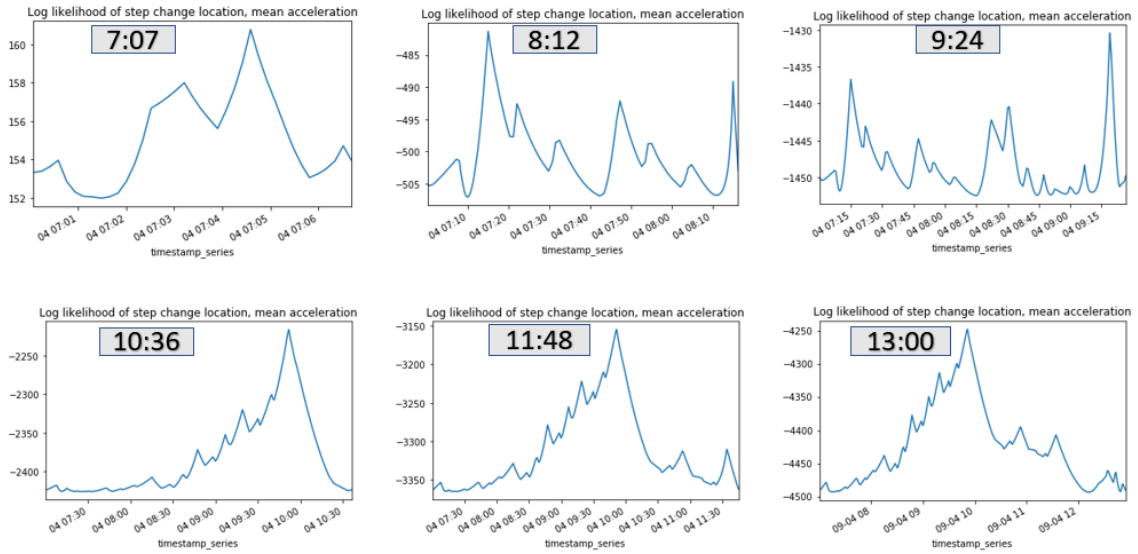
Συνδυάζοντας την πληροφορία που μας δίνει το κάθε διάγραμμα με την ώρα όπου προσδιορίζεται η βλάβη για κάθε περίπτωση επιβεβαιώνεται ότι ο αλγόριθμος θεωρεί πως η βλάβη πραγματοποιήθηκε τη χρονική στιγμή που παρουσιάζει και την μεγαλύτερη αιχμή. Επίσης παρουσιάζεται ότι σε μερικά είδη βλάβης τα τρία μεγέθη που μελετώνται εξάγουν παρόμοιο αποτέλεσμα και στη μορφή της καμπύλης που εξάγεται από τον αλγόριθμο αλλά και στη χρονική στιγμή που προσδιορίζεται η βλάβη. Όμως στα περισσότερα σύνολα δεδομένων παρουσιάζουν ομοιότητα δύο μεγέθη μεταξύ τους και το τρίτο εξάγει διαφορετικό αποτέλεσμα. Το γεγονός αυτό οφείλεται στο θόρυβο που εμπεριέχει το αρχικό σήμα και επιπλέον στο ότι η είσοδος του αλγορίθμου είναι απευθείας τα raw data χωρίς κάποια επεξεργασία προηγούμενης. Γι' αυτό το λόγο τα αποτελέσματα του πρώτου πειράματος δεν διακρίνονται από υψηλή ακρίβεια και αξιοπιστία.

Πέρα από την ανάλυση που πραγματοποιήθηκε και περιεγράφηκε παραπάνω, έγινε και μία ανάλυση των δεδομένων αυτών σε προσομοίωση λειτουργίας σε πραγματικό

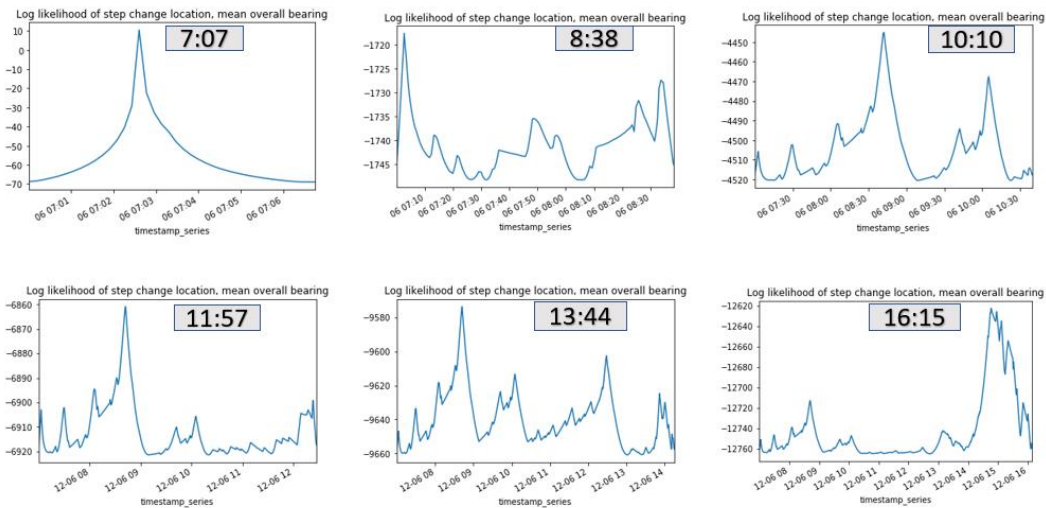
χρόνο. Πιο συγκεκριμένα ο αλγόριθμος τροφοδοτούνταν με επαναληπτικό τρόπο με ένα υποσύνολο των αρχικών δεδομένων. Η πρώτη επανάληψη εκτελέστηκε με τις πρώτες 40 τιμές του αρχικού συνόλου δεδομένων και σε κάθε επανάληψη προστίθεντο ακόμα ένα υποσύνολο του ίδιου μεγέθους, διατηρώντας όλα τα προηγούμενα προς επεξεργασία. Οι τιμές λαμβάνονταν με τη σειρά που είχαν καταγραφεί από τους αισθητήρες διατηρώντας τη χρονική σειρά και όχι τυχαία. Το μέγεθος των 40 τιμών επιλέχθηκε μετά από πειραματισμό και κρίθηκε κατάλληλο καθώς διατηρούσε την ισορροπία ανάμεσα στην πληροφορία που λαμβανόταν από το αποτέλεσμα και στο υπολογιστικό κόστος. Πιο αναλυτικά τα στιγμιότυπα που λαμβάνονταν από κάθε επανάληψη περιείχαν επαρκή πληροφορία για τις διαφοροποιήσεις που υπήρχαν ανάμεσά τους και το υπολογιστικό κόστος ήταν σε τέτοιο βαθμό που μπορούσε να πραγματοποιηθεί από ένα συμβατικό υπολογιστή. Άλλωστε όταν εξαγόταν μία καμπύλη ενώ είχαν προστεθεί πολύ λίγες τιμές στο σύνολο των δεδομένων, η διαφοροποίηση μεταξύ της προηγούμενης και της επόμενης καμπύλης ήταν σχεδόν ανύπαρκτη και επομένως δε βοηθούσε τη μελέτη. Τα αποτελέσματα από την παραπάνω επεξεργασία φαίνονται στα σχήματα 20 και 21 όπου αναγράφεται και η χρονική στιγμή λήψης του στιγμιότυπου.

Πιο αναλυτικά στο σχήμα 20 μελετάται το σύνολο δεδομένων των 2068 τιμών που καταγράφηκε στις 4/9/2019 με διάρκεια από τις 7:00 μέχρι τις 13:00 και αφορούσε τη βλάβη «σημάδια». Πραγματοποιήθηκαν συνολικά 51 επαναλήψεις και επομένως κάθε διάγραμμα είχε χρονική απόσταση από το επόμενο, 7 λεπτά και δειγματοληπτικά παρουσιάζονται τα παρακάτω διαγράμματα.

Αντίστοιχα στο σχήμα 21 μελετάται το σύνολο δεδομένων των 3116 τιμών που καταγράφηκε στις 6/12/2019 με χρονική διάρκεια από τις 7:00 μέχρι τις 16:15 και αφορούσε τη βλάβη «σπάσιμο». Πραγματοποιήθηκαν συνολικά 78 επαναλήψεις και επομένως κάθε διάγραμμα είχε χρονική απόσταση από το επόμενο, 7 λεπτά και δειγματοληπτικά παρουσιάζονται τα παρακάτω διαγράμματα.



Σχήμα 20 : Εφαρμογή του αλγορίθμου BOCD στα raw data σε πραγματικό χρόνο για το μέγεθος acceleration και τη βλάβη «σημάδια».

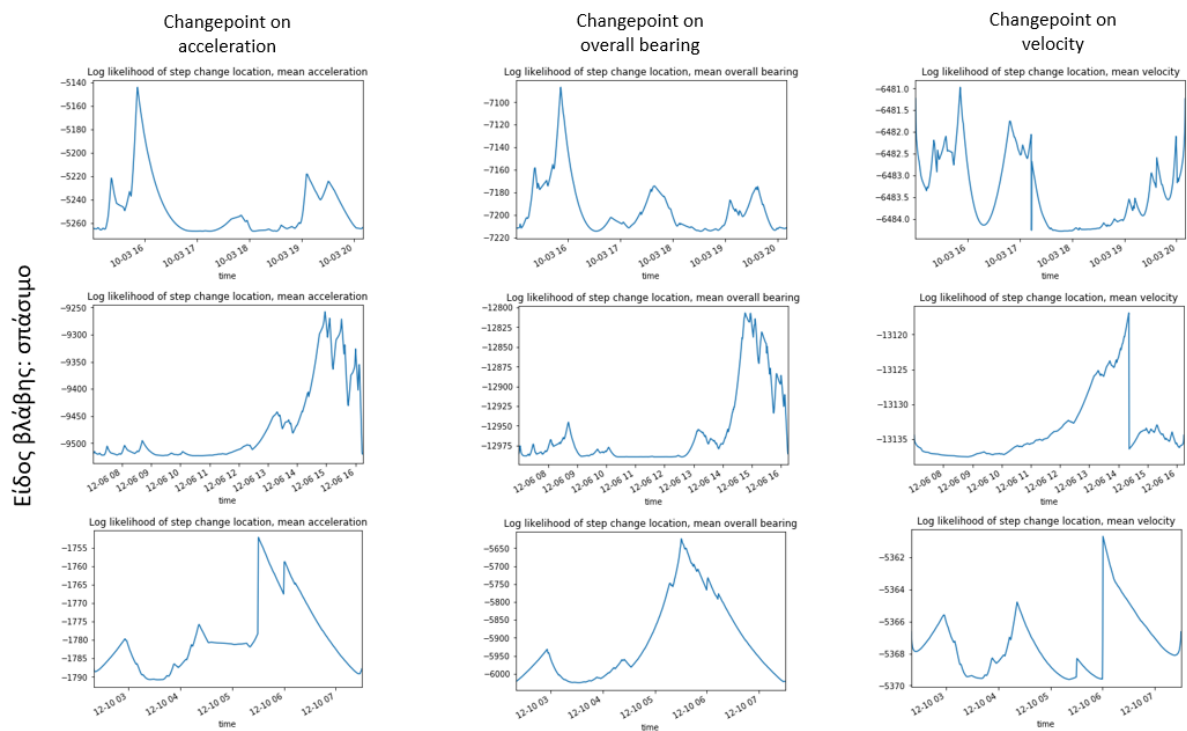


Σχήμα 21: Εφαρμογή του αλγορίθμου BOCD στα raw data σε πραγματικό χρόνο για το μέγεθος overall bearing και τη βλάβη «σπάσιμο».

Από τα παραπάνω αποτελέσματα βλέπουμε ότι καθώς περνάει ο χρόνος και προστίθενται δεδομένα, η μορφή της καμπύλης αλλάζει και παρουσιάζει αιχμές σε διαφορετικά σημεία. Αυτό συμβαίνει διότι ο αλγόριθμος λαμβάνει υπόψιν του όλο το σύνολο των δεδομένων που του δίνεται στην κάθε επανάληψη αλλά δεν συμπεριλαμβάνει στην ανάλυσή του τα αποτελέσματα των προηγούμενων επαναλήψεων. Επομένως μία εύλογη παρατήρηση είναι ότι καθώς προστίθενται δεδομένα στην ανάλυση του αλγορίθμου, το αποτέλεσμα μπορεί να αλλάξει ακόμα και

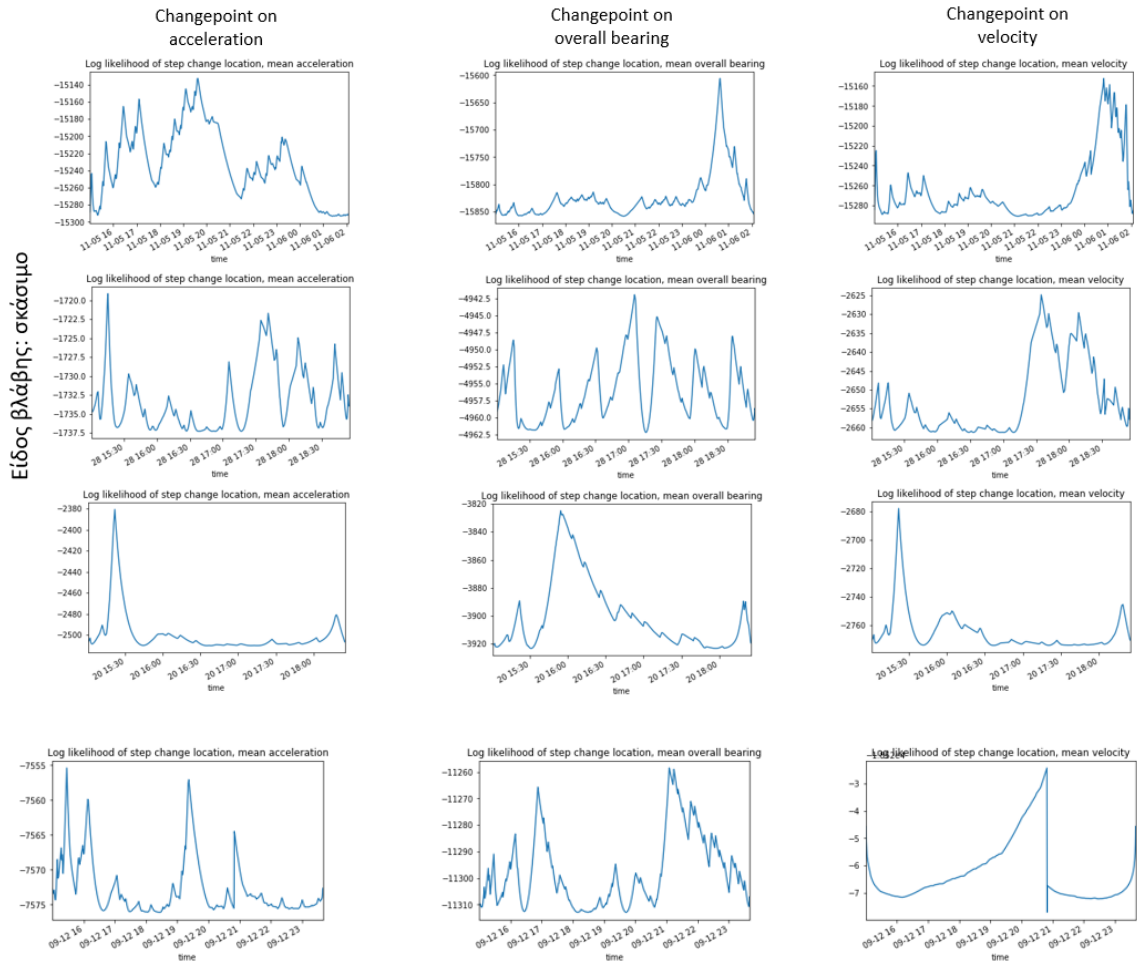
δραματικά σε ένα σύντομο χρονικό διάστημα. Εδώ φαίνεται ακόμα πιο έντονα η αναγκαιότητα παρακολούθησης της λειτουργίας του εξοπλισμού σε πραγματικό χρόνο ώστε να είναι πιο αποτελεσματική η προβλεπτική συντήρηση της βιομηχανικής μονάδας.

Αν συγκεντρώσουμε όλα τα παραπάνω αποτελέσματα ανά είδος βλάβης και για τα τρία μεγέθη ενδιαφέροντος προκύπτουν τα παρακάτω διαγράμματα. Σε κάθε σχήμα η κάθε στήλη αφορά το αποτέλεσμα του αλγορίθμου BOCD για κάθε ένα από τα μεγέθη acceleration, overall bearing και velocity με τη σειρά.

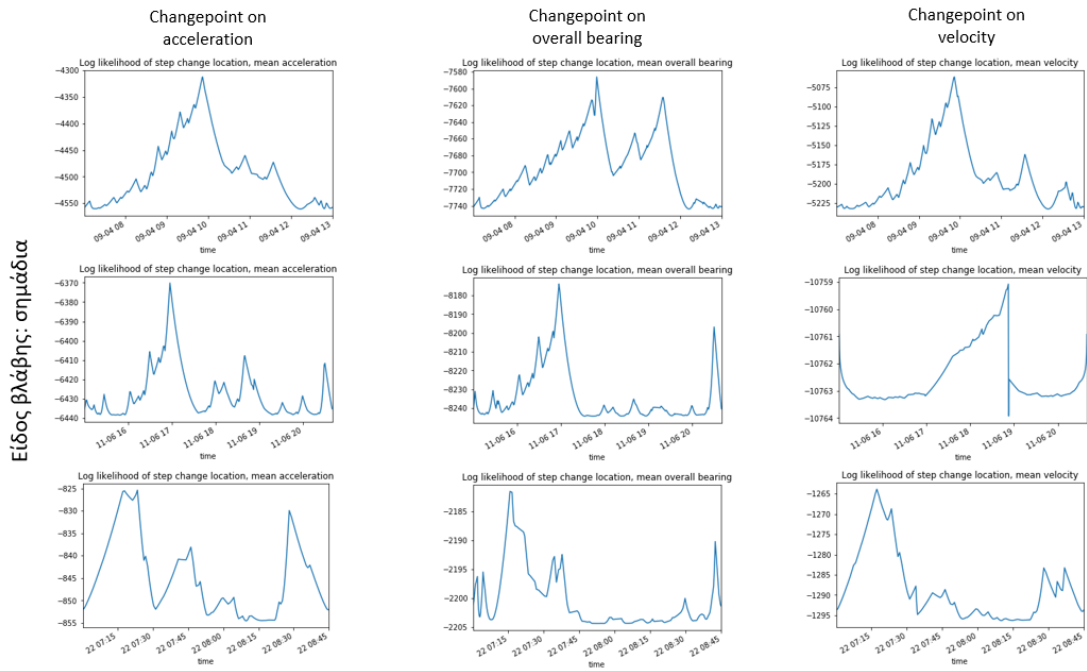


Σχήμα 22: Καμπύλες εφαρμογής του αλγορίθμου BOCD για acceleration, overall bearing και velocity για τα σύνολα δεδομένων που αφορούν τη βλάβη «σπάσιμο».

Είδος βλάβης: σκάσιμο

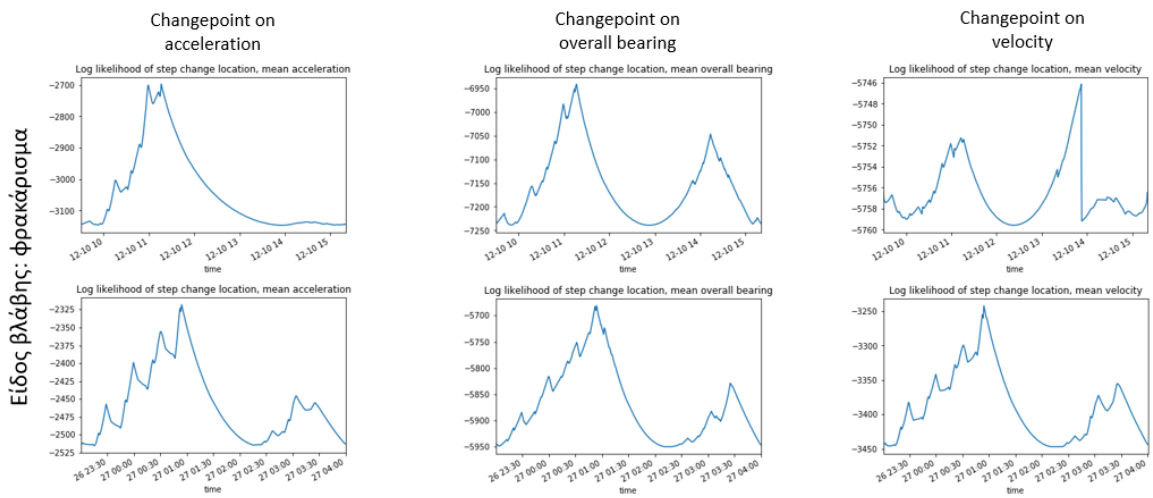


Σχήμα 23: Καμπύλες εφαρμογής του αλγορίθμου BOCD για acceleration, overall bearing και velocity για τα σύνολα δεδομένων που αφορούν τη βλάβη «σκάσιμο».



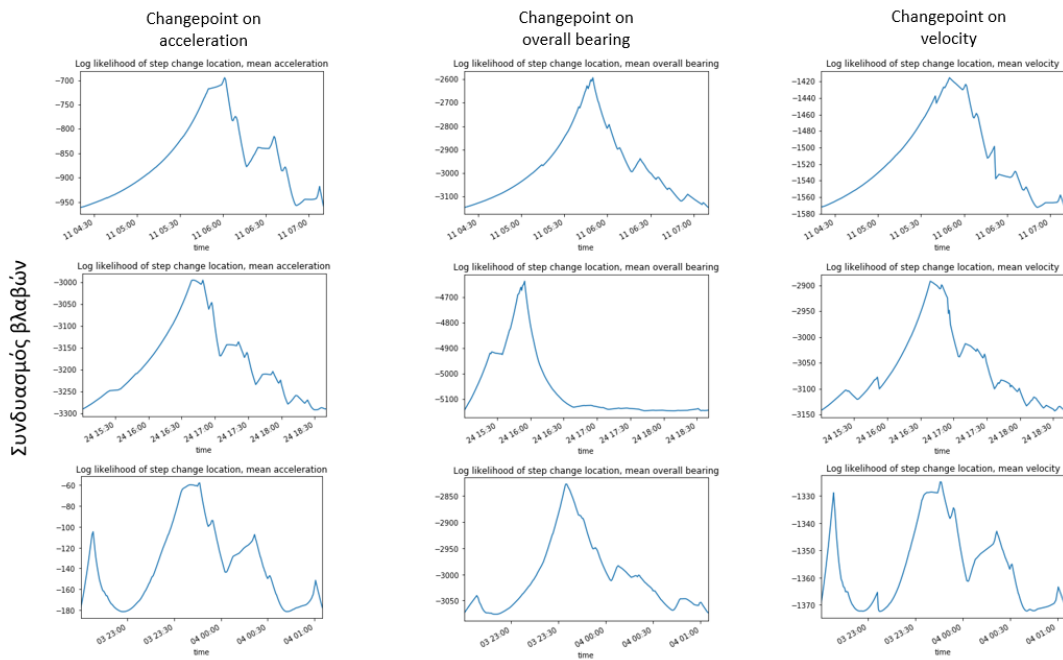
Είδος βλάβης: σημάδια

Σχήμα 24: Καμπύλες εφαρμογής του αλγορίθμου BOCD για acceleration, overall bearing και velocity για τα σύνολα δεδομένων που αφορούν τη βλάβη «σημάδια».



Είδος βλάβης: φρακάρισμα

Σχήμα 25: Καμπύλες εφαρμογής του αλγορίθμου BOCD για acceleration, overall bearing και velocity για τα σύνολα δεδομένων που αφορούν τη βλάβη «φρακάρισμα».




Σχήμα 26: Καμπύλες εφαρμογής του αλγορίθμου BOCD για acceleration, overall bearing και velocity για τα σύνολα δεδομένων που αφορούν τους συνδυασμούς βλαβών.

Η σύγκριση με βάση το είδος της βλάβης έγινε προκειμένου να μελετηθεί η συμπεριφορά του αλγορίθμου που εφαρμόστηκε γνωρίζοντας ότι ο εξοπλισμός κατέληξε στο ίδιο είδος βλάβης. Συγκρίνοντας λοιπόν τα αποτελέσματα από τη βλάβη «σπάσιμο» παρατηρείται ότι οι καμπύλες από την εφαρμογή του BOCD αλγορίθμου στα μεγέθη acceleration και overall bearing εντοπίζουν νωρίτερα την αλλαγή συμπεριφοράς του εξοπλισμού σε σχέση με το μέγεθος velocity και εμφανίζουν μια πιο ευκρινή εικόνα της καμπύλης που περιγράφει την πιθανότητα κάθε χρονική στιγμή να είναι σημείο αλλαγής. Όμοια παρατήρηση μπορεί να γίνει και για τη βλάβη «φρακάρισμα». Αντίθετα, στις βλάβες «σκάσιμο» και «σημάδια» οι περισσότερες καμπύλες δεν δίνουν σαφή εικόνα της κατάστασης λειτουργίας του εξοπλισμού και η πληροφορία που λαμβάνεται εμπεριέχει μεγάλη αβεβαιότητα. Οι βλάβες που προκύπτουν ως συνδυασμός των άλλων κατηγοριών βλαβών διαφοροποιούνται από όλες τις προηγούμενες καθώς οι καμπύλες εμφανίζονται αρκετά ευκρινείς και επίσης τα διαγράμματα από την εφαρμογή του BOCD αλγορίθμου στο μέγεθος overall bearing δίνουν πιο σαφή εικόνα της αλλαγής κατάστασης του εξοπλισμού.

4.3.1.2 Πείραμα 2: Feature Extraction – Online Bayesian Changepoint Detection

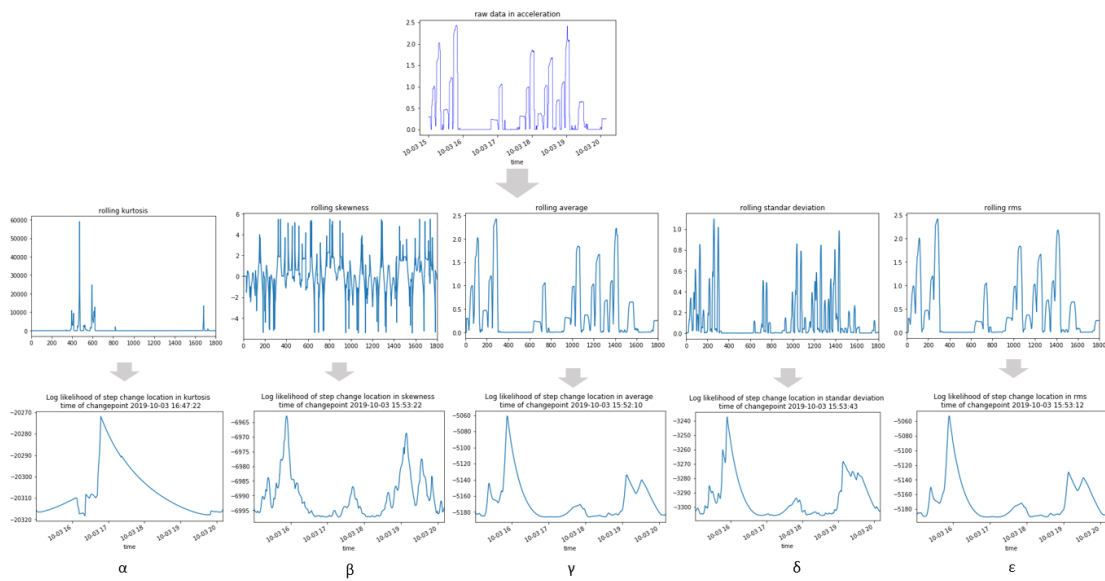
Στο δεύτερο πείραμα αυτής της κατηγορίας αρχικά εφαρμόζεται στα τρία μεγέθη των raw data ο αλγόριθμος της εξαγωγής χαρακτηριστικών (feature extraction) παράγοντας 5 rolling features με τη διαδικασία που έχει αναφερθεί και στην προτεινόμενη προσέγγιση. Στη συνέχεια, σε κάθε ένα από τα χαρακτηριστικά που παράγονται για κάθε μέγεθος που μελετάται εφαρμόζεται ο αλγόριθμος BOCD ώστε να πραγματοποιηθεί ανίχνευση αλλαγής συμπεριφοράς στη λειτουργία του εξοπλισμού μέσω της ανάλυσης των χαρακτηριστικών.

Το επιπλέον αυτό βήμα στη διεξαγωγή του πειράματος έγινε έτσι ώστε να ληφθεί πληροφορία από ανώτερο επίπεδο επεξεργασίας και όχι από τα δεδομένα που καταγράφονται από τους αισθητήρες, καθώς εκείνα περιέχουν θόρυβο που δυσχεραίνει την ανάλυση, όπως φαίνεται από τα αποτελέσματα του πρώτου πειράματος. Η δομή του πειράματος, του οποίου η λειτουργία αναλύθηκε παραπάνω φαίνεται στο σχήμα 27.

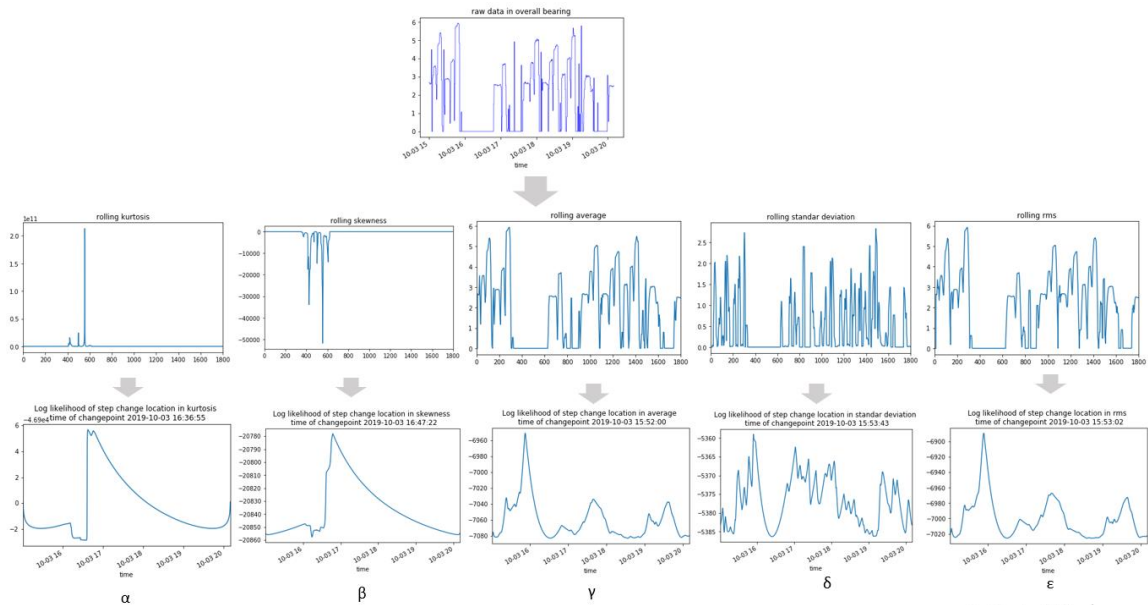


Σχήμα 27: Η δομή του πειράματος 2.

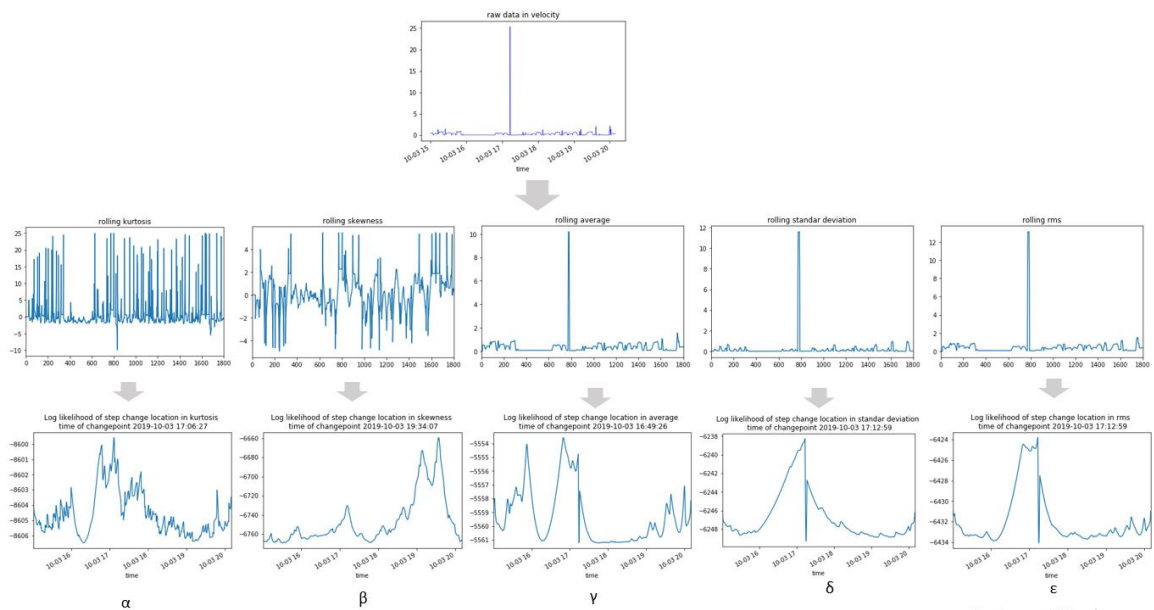
Τα αποτελέσματα του παραπάνω πειράματος φαίνονται στα διαγράμματα που ακολουθούν. Στην πρώτη σειρά φαίνονται τα αρχικά δεδομένα (raw data) όπου εφαρμόζεται ο αλγόριθμος της εξαγωγής χαρακτηριστικών για ένα μέγεθος από τα acceleration, overall bearing και velocity. Στην επόμενη σειρά παρουσιάζονται τα 5 χαρακτηριστικά που εξάγονται και στην αμέσως επόμενη το αποτέλεσμα του BOCD αλγορίθμου σε κάθε ένα από τα χαρακτηριστικά. Η αναλυτική παρουσίαση των αποτελεσμάτων στα σχήματα 28 έως 30 γίνεται για να αναπαρασταθούν και τα ενδιάμεσα στάδια του πειράματος. Παράλληλος στόχος είναι η ανάλυση της μορφής των χαρακτηριστικών που παράγονται πέρα από το τελικό αποτέλεσμα που παράγεται από την επεξεργασία τους.



Σχήμα 28: Εφαρμογή των αλγορίθμων feature extraction και BOCD στα raw data για το μέγεθος acceleration και τη βλάβη «σπάσιμο»: α)kurtosis, β)skewness, γ)mean, δ)std, ε)rms.



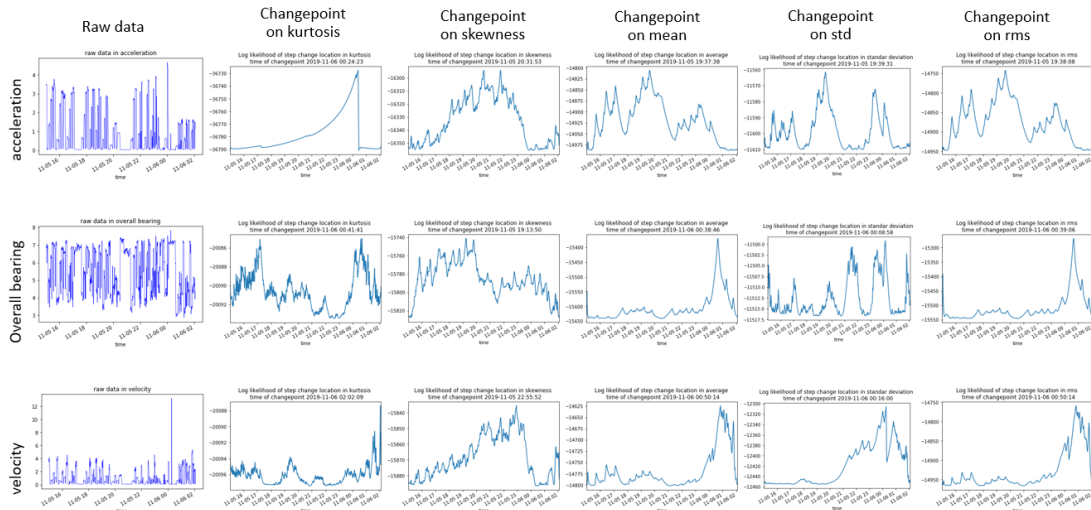
Σχήμα 29: Εφαρμογή των αλγορίθμων feature extraction και BOCD στα raw data για το μέγεθος overall bearing και τη βλάβη «σπάσιμο»: α)kurtosis, β)skewness, γ)mean, δ)std, ε)rms.



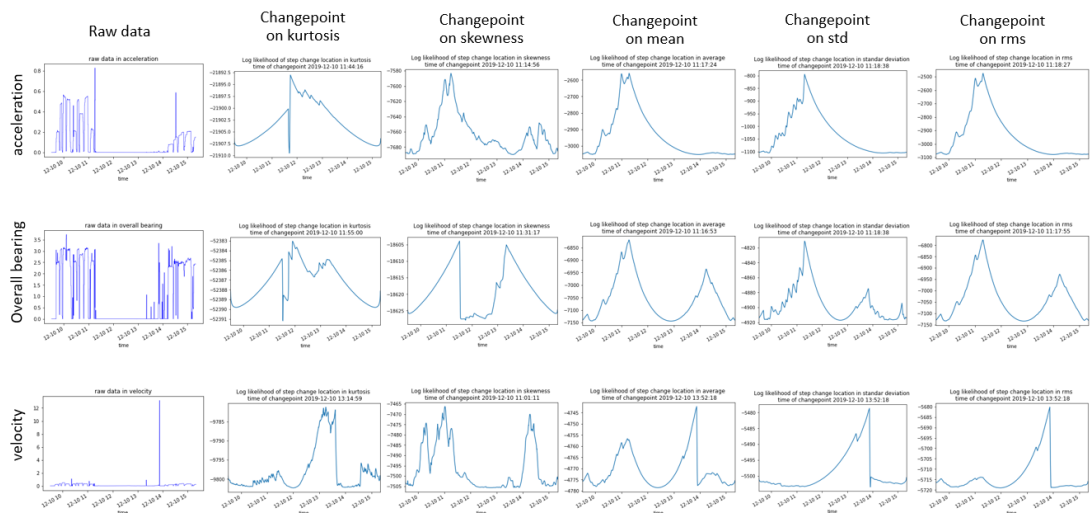
Σχήμα 30: Εφαρμογή των αλγορίθμων feature extraction και BOCD στα raw data για το μέγεθος velocity και τη βλάβη «σπάσιμο»: α)kurtosis, β)skewness, γ)mean, δ)std, ε)rms.

Από τη μορφή των χαρακτηριστικών που εξάγονται από κάθε σύνολο δεδομένων συμπεραίνουμε ότι αναμενόμενα τα χαρακτηριστικά συμπεριφέρονται διαφορετικά και κάποια εξάγουν τελείως διαφορετική εικόνα παρ' όλο που η είσοδος είναι η ίδια, δηλαδή το αρχικό σύνολο δεδομένων από την καταγραφή των αισθητήρων. Μπορούμε όμως να παρατηρήσουμε ότι τα χαρακτηριστικά mean, standard deviation και rms παρουσιάζουν παρόμοια εικόνα όταν επεξεργάζονται την ίδια είσοδο.

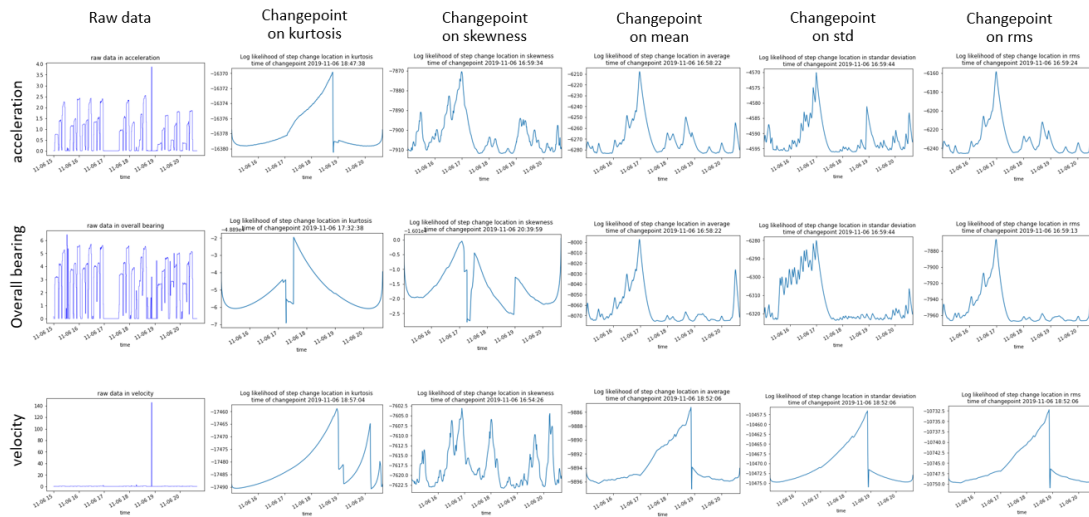
Παρακάτω φαίνονται τα αποτελέσματα για κάποια σύνολα δεδομένων ενδεικτικά, ένα για κάθε βλάβη ώστε να είναι πιο πλήρης η αποτύπωση των πειραματικών αποτελεσμάτων. Σε κάθε σχήμα, στην πρώτη στήλη παρουσιάζονται τα αρχικά δεδομένα του κάθε μεγέθους από τα acceleration, overall bearing και velocity για μία βλάβη και στις επόμενες στήλες φαίνεται το αποτέλεσμα της εφαρμογής του αλγορίθμου BOCD σε κάθε ένα χαρακτηριστικό από τα kurtosis, skewness, mean, standard deviation και rms. Οι καμπύλες αυτές αποτελούν και το αποτέλεσμα προς αξιολόγηση του δεύτερου πειράματος.



Σχήμα 31: Εφαρμογή των αλγορίθμων feature extraction και BOCD στα raw data για τα μεγέθη acceleration, overall bearing και velocity και τη βλάβη «σκάσιμο».



Σχήμα 32: Εφαρμογή των αλγορίθμων feature extraction και BOCD στα raw data για τα μεγέθη acceleration, overall bearing και velocity και τη βλάβη «φρακάρισμα».



Σχήμα 33: Εφαρμογή των αλγορίθμων feature extraction και BOCD στα raw data για τα μεγέθη acceleration, overall bearing και velocity και τη βλάβη «σημάδια».

Παραπάνω διατυπώθηκε ότι στις περισσότερες περιπτώσεις τα τρία τελευταία χαρακτηριστικά που εξάγονται από ένα σύνολο δεδομένων εμφανίζουν παρόμοια μορφή. Την ίδια συμπεριφορά ακολουθούν και οι καμπύλες που προκύπτουν από την εφαρμογή του BOCD αλγορίθμου σε αυτά τα χαρακτηριστικά όπως φαίνεται από τα παραπάνω αποτελέσματα. Επίσης στις περισσότερες περιπτώσεις παρουσιάζουν πιο ευκρινή εικόνα για την αλλαγή κατάστασης λειτουργίας του εξοπλισμού και επομένως εμφάνιση βλάβης από τα δύο πρώτα χαρακτηριστικά. Συγκρίνοντας το χαρακτηριστικό kurtosis με το skewness προκύπτει ότι το πρώτο προσδιορίζει με μεγαλύτερη ευκρίνεια το σημείο αλλαγής ενώ το δεύτερο δεν αποδίδει χρήσιμη πληροφορία για την ανάλυση. Επίσης πρέπει να σημειωθεί ότι τα διαφορετικά είδη βλαβών παρουσιάζουν διαφορετική εικόνα ως προς το ποιο χαρακτηριστικό είναι καταλληλότερο για την υπόδειξη του σημείου αλλαγής συμπεριφοράς.

Παράλληλα με τα διαγράμματα καταγράφεται από την έξοδο του αλγορίθμου BOCD τη χρονική στιγμή όπου θεωρείται ότι συνέβη κάποια ανωμαλία στη λειτουργία του εξοπλισμού ή κάποια βλάβη σε αυτόν για κάθε ένα από τα σύνολα δεδομένων. Στον πίνακα 10 φαίνονται αυτές οι χρονικές στιγμές για τα σύνολα δεδομένων για τα οποία αποτυπώθηκαν τα διαγράμματα παραπάνω.

βλάβη	feature	acceleration	overall bearing	velocity
3/10/2019 σπάσιμο	Kurtosis	2019-10-03 16:47:22	2019-10-03 16:36:55	2019-10-03 17:06:27
	Skewness	2019-10-03 15:53:22	2019-10-03 16:47:22	2019-10-03 19:34:07
	mean	2019-10-03 15:52:10	2019-10-03 15:52:00	2019-10-03 16:49:26
	Std	2019-10-03 15:53:43	2019-10-03 15:53:43	2019-10-03 17:12:59
	rms	2019-10-03 15:53:12	2019-10-03 15:53:02	2019-10-03 17:12:59
5/11/2019 σκάσιμο	Kurtosis	2019-11-06 00:24:23	2019-11-06 00:41:41	2019-11-06 02:02:09
	Skewness	2019-11-05 20:31:53	2019-11-05 19:13:50	2019-11-05 22:55:52
	mean	2019-11-05 19:37:38	2019-11-06 00:38:46	2019-11-06 00:50:14
	Std	2019-11-05 19:39:31	2019-11-06 00:08:58	2019-11-06 00:16:00
	rms	2019-11-05 19:38:08	2019-11-06 00:39:06	2019-11-06 00:50:14
10/12/2019 φρακάρισμα	Kurtosis	2019-12-10 11:44:16	2019-12-10 11:55:00	2019-12-10 13:14:59
	Skewness	2019-12-10 11:14:56	2019-12-10 11:31:17	2019-12-10 11:01:11
	mean	2019-12-10 11:17:24	2019-12-10 11:16:53	2019-12-10 13:52:18
	Std	2019-12-10 11:18:38	2019-12-10 11:18:38	2019-12-10 13:52:18
	rms	2019-12-10 11:18:27	2019-12-10 11:17:55	2019-12-10 13:52:18
6/11/2019 σημάδια	Kurtosis	2019-11-06 18:47:38	2019-11-06 17:32:38	2019-11-06 18:57:04
	Skewness	2019-11-06 16:59:34	2019-11-06 20:39:59	2019-11-06 16:54:26
	mean	2019-11-06 16:58:22	2019-11-06 16:58:22	2019-11-06 18:52:06
	Std	2019-11-06 16:59:44	2019-11-06 16:59:44	2019-11-06 18:52:06
	rms	2019-11-06 16:59:24	2019-11-06 16:59:13	2019-11-06 18:52:06

Πίνακας 10: Χρονική στιγμή που εντοπίστηκε ανωμαλία από τον αλγόριθμο BOCD σε κάθε feature ανά βλάβη.

Η προηγούμενη διαπίστωση επιβεβαιώνεται και από τον παραπάνω πίνακα καθώς τα χαρακτηριστικά mean, std και rms προσδιορίζουν την ίδια χρονική στιγμή, με μία πολύ μικρή απόκλιση, ως σημείο αλλαγής ενώ τα άλλα δύο χαρακτηριστικά διαφοροποιούνται. Επίσης οι χρονικές στιγμές που προσδιορίζονται από την επεξεργασία των τριών τελευταίων χαρακτηριστικών είναι σε προηγούμενο χρονικό διάστημα σε σχέση με τα άλλα δυο.

Τα αποτελέσματα αυτού του πειράματος έδειξαν ότι η επιλογή χαρακτηριστικών ως πιο κατάλληλων για ανάλυση εξαρτάται από την εφαρμογή στην οποία θα χρησιμοποιηθούν, τα μεγέθη που καταγράφονται και από τα οποία εξάγονται καθώς και τη βλάβη στην οποία έχει επέλθει ο εξοπλισμός. Επομένως ανάλογα με την επιλογή των αισθητήρων για καταγραφή των δεδομένων και την συμπεριφορά που παρουσιάζουν εκείνα ως προς την απόκλιση από τη φυσιολογική λειτουργία, επιλέγεται και το αντίστοιχο χαρακτηριστικό που θα εξαχθεί, το οποίο θα δώσει την πληρέστερη εικόνα λειτουργίας αλλά και αλλαγή κατάστασης του εξοπλισμού.

Παρατηρώντας τα αποτελέσματα του πρώτου και του δεύτερου πειράματος διαπιστώνεται η αρχική υπόθεση και στόχος του δεύτερου πειράματος, να ληφθεί

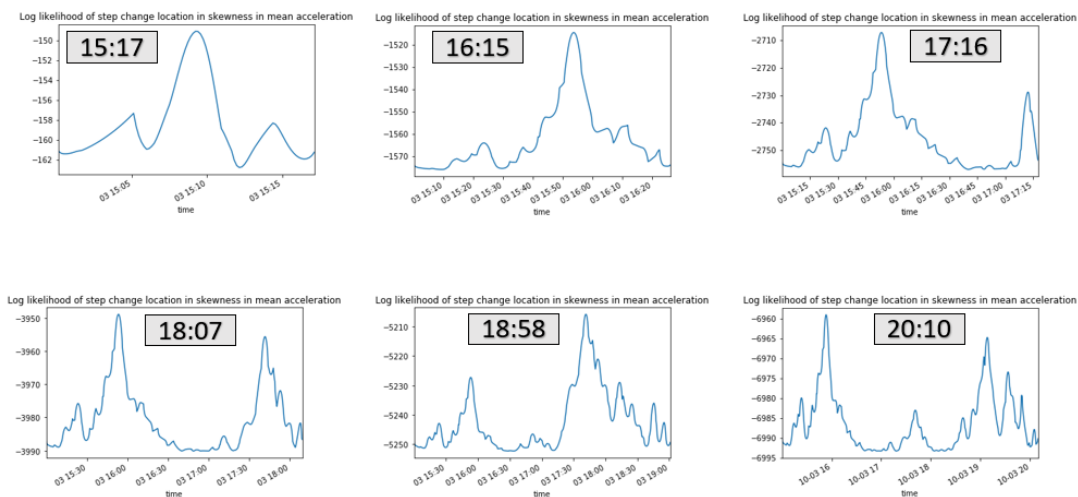
πληροφορία από ανώτερο επίπεδο επεξεργασίας. Όντως από τις καμπύλες που προκύπτουν από το δεύτερο πείραμα, λαμβάνεται καλύτερη εικόνα της συμπεριφοράς του εξοπλισμού σε σχέση με το πρώτο πείραμα. Αυτό συμβαίνει λόγω του θορύβου που εμπεριέχεται στα raw data μειώνοντας την ακρίβεια του αλγορίθμου BOCD και επομένως της αποτελεσματικότητας στην ανίχνευση ανωμαλιών. Η εξαγωγή χαρακτηριστικών εξομάλυνε αυτή τη δυσχέρεια και αύξησε την ευκρίνεια των παραγόμενων καμπυλών και την ακρίβεια της προσέγγισης.

Όπως και στο πρώτο πείραμα, έγινε μελέτη των αποτελεσμάτων του δεύτερου πειράματος σε πραγματικό χρόνο με παρόμοιο τρόπο. Αναλυτικότερα, η διαδικασία ξεκίνησε με ένα υποσύνολο δεδομένων και σε κάθε επανάληψη προστίθεντο ένα ακόμα υποσύνολο σταθερού μεγέθους, όπου ο αλγόριθμος το επεξεργάζεται στο σύνολό του. Για κάθε σύνολο δεδομένων επιλέχθηκε διαφορετικό μέγεθος ανάλογα με το αρχικό του μέγεθος και με τέτοιο τρόπο ώστε να περιέχεται επαρκής πληροφορία στα αποτελέσματα αλλά παράλληλα να μην είναι μεγάλο το υπολογιστικό κόστος όσον αφορά τις επαναλήψεις. Ένα ακόμα κριτήριο επιλογής αυτού του μεγέθους είναι ότι θα πρέπει να είναι μεγαλύτερο από το «παράθυρο» του χαρακτηριστικού που υπολογίζεται. Στο πείραμα αυτό είναι πιο έντονη η ανάγκη για σωστή επιλογή μεγέθους υποσυνόλου δεδομένων γιατί εξάγονται 5 διαφορετικά χαρακτηριστικά και σε κάθε ένα από αυτά γίνεται η ανίχνευση ανωμαλιών για κάθε μία από τις επαναλήψεις που ορίζονται. Επομένως οι καμπύλες που παράγονται είναι πάρα πολλές σε αριθμό και δυσκολεύουν την εκτέλεση του αλγορίθμου αλλά και την μετέπειτα ανάλυσή τους. Τα ακριβή μεγέθη φαίνονται στον πίνακα 11 και προέκυψαν μετά από πειραματισμό ώστε να πληρούνται τα παραπάνω κριτήρια.

Αρχικό μέγεθος συνόλου δεδομένων	Μέγεθος υποσυνόλου δεδομένων
~1000	50
~2000	100
~3000	150
~4000	200

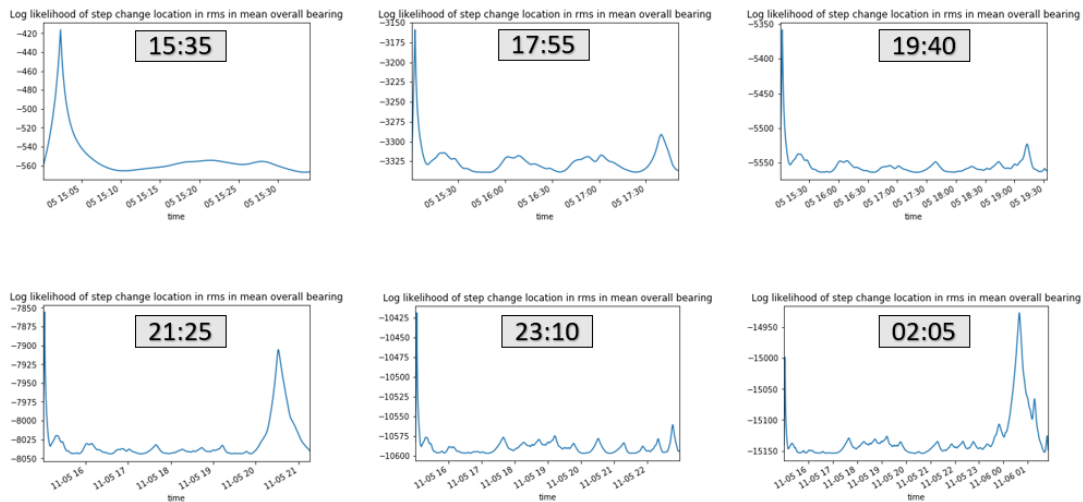
Πίνακας 11: Μέγεθος του υποσυνόλου των δεδομένων για επεξεργασία σε πραγματικό χρόνο του πειράματος 2.

Πιο αναλυτικά στο σχήμα 34 μελετάται το σύνολο δεδομένων των 1801 τιμών που καταγράφηκε στις 3/10/2019 με διάρκεια από τις 15:00 μέχρις τη 20:10 και αφορούσε τη βλάβη «σπάσιμο». Πραγματοποιήθηκαν συνολικά 18 επαναλήψεις και επομένως κάθε διάγραμμα είχε χρονική απόσταση από το επόμενο, 17 λεπτά. Δειγματοληπτικά παρουσιάζονται τα παρακάτω διαγράμματα.



Σχήμα 34: Εφαρμογή των αλγορίθμων feature extraction και BOCD στα raw data για το μέγεθος acceleration, το χαρακτηριστικό skewness και τη βλάβη «σπάσιμο».

Αντίστοιχα στο σχήμα 35 μελετάται το σύνολο δεδομένων των 3885 τιμών που καταγράφηκε στις 5/11/2019 με χρονική διάρκεια από τις 15:00 μέχρι τις 02:05 και αφορούσε τη βλάβη «σκάσιμο». Πραγματοποιήθηκαν συνολικά 19 επαναλήψεις και επομένως κάθε διάγραμμα είχε χρονική απόσταση από το επόμενο, 35 λεπτά. Δειγματοληπτικά παρουσιάζονται τα παρακάτω διαγράμματα.



Σχήμα 35: Εφαρμογή των αλγορίθμων feature extraction και BOCD στα raw data για το μέγεθος overall bearing, το χαρακτηριστικό rms και τη βλάβη «σκάσιμο».


Όπως και στο πρώτο πείραμα, είναι εμφανές ότι όσο προστίθενται δεδομένα στο σύνολο εκείνων που επεξεργάζονται οι αλγόριθμοι, το αποτέλεσμα διαφοροποιείται και μάλιστα μερικές φορές παρουσιάζεται τελείως διαφορετική εικόνα καθώς περνάει ο χρόνος.

4.3.2 Πρόγνωση αλλαγής κατάστασης της υγείας του εξοπλισμού

Σε αυτή τη δεύτερη κατηγορία πειραμάτων ο στόχος είναι η πρόβλεψη της βλάβης ή της αλλαγής κατάστασης του εξοπλισμού πριν αυτή συμβεί. Για αυτό το σκοπό έχει δημιουργηθεί ένα νευρωνικό δίκτυο LSTM, όπως περιγράφεται και στην προτεινόμενη προσέγγιση, προκειμένου να προβλεφθούν οι τιμές των μεγεθών που έχουν καταγραφεί από τους αισθητήρες που είναι εγκατεστημένοι στον εξοπλισμό. Με άλλα λόγια γίνεται πρόβλεψη για τα μεγέθη acceleration, overall bearing και velocity για κάθε περίπτωση συνόλου δεδομένων. Σε αυτή την κατηγορία πειραμάτων δεν λαμβάνεται υπόψιν το είδος της βλάβης του κάθε συνόλου δεδομένων, παρ' όλο που είναι γνωστό λόγω του τρόπου δημιουργίας τους, καθώς ο σκοπός είναι η πρόβλεψή της.

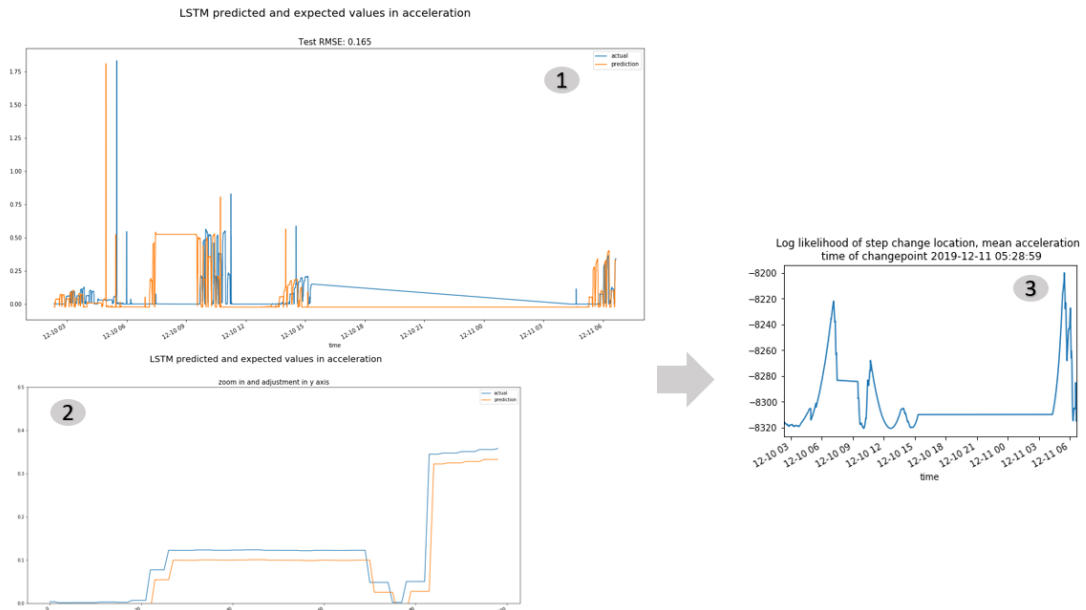
4.3.2.1 Πείραμα 3: Online Bayesian Changepoint Detection

Τα raw data σε αυτό το πείραμα χρησιμοποιούνται ως είσοδος στο νευρωνικό δίκτυο προκειμένου να γίνει η πρόβλεψη των τιμών των μεγεθών acceleration, overall bearing και velocity. Στις τιμές αυτές εφαρμόζεται ο αλγόριθμος Bayesian online changepoint detection (BOCD) και το αποτέλεσμα που προκύπτει είναι μία καμπύλη με τα χαρακτηριστικά που έχουν αναλυθεί και στα προηγούμενα πειράματα. Στο σχήμα 36 φαίνεται η δομή του τρίτου πειράματος.

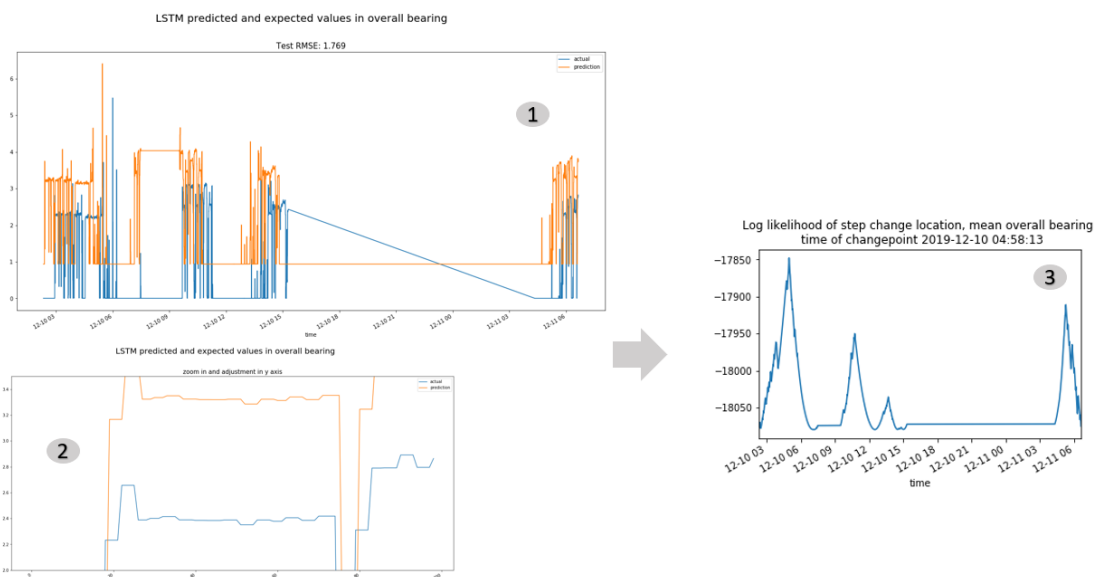


Σχήμα 36: Η δομή του πειράματος 3.

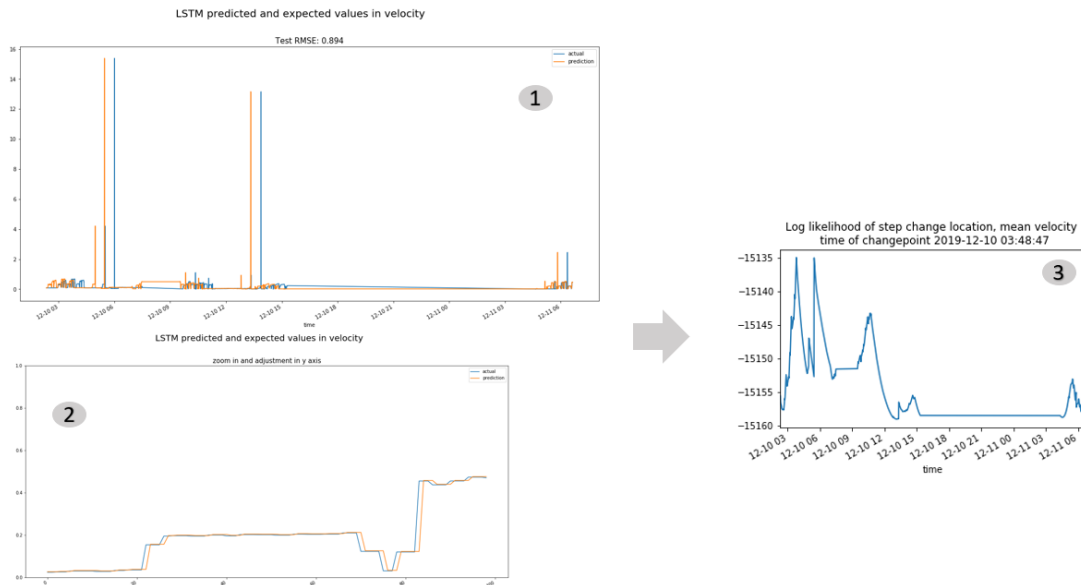
Η πρώτη εφαρμογή του νευρωνικού δικτύου γίνεται με σκοπό την πρόβλεψη των τιμών αυτών στο χρονικό διάστημα της μισής ώρας, ώστε να υπάρχει χρόνος αντίδρασης από τον χειριστή του εξοπλισμού και να αποφευχθεί η βλάβη μέσω κατάλληλων ενεργειών. Με άλλα λόγια, το δίκτυο προβλέπει ποια θα είναι η τιμή του κάθε μεγέθους σε μισή ώρα από την τρέχουσα χρονική στιγμή, εφόσον γνωρίζει όλες τις προηγούμενες τιμές του μεγέθους που μελετάται, αλλά όχι τις επόμενες. Στα επόμενα σχήματα απεικονίζονται για κάθε μέγεθος ξεχωριστά οι προβλεπόμενες τιμές του νευρωνικού δικτύου και το αποτέλεσμα της εφαρμογής του BOCD αλγορίθμου. Πιο αναλυτικά, σε κάθε σχήμα, το διάγραμμα 1 απεικονίζει τις προβλεπόμενες τιμές (πορτοκαλί γραμμή) ενός μεγέθους σε αντιπαραβολή με τις πραγματικές τιμές (μπλε γραμμή) ενώ το διάγραμμα 2 δείχνει σε μεγέθυνση ένα κομμάτι του πρώτου διαγράμματος έτσι ώστε να είναι πιο εμφανής η απόκλιση της πραγματικής από την προβλεπόμενη τιμή. Τέλος το διάγραμμα 3 δείχνει το αποτέλεσμα της εφαρμογής του αλγορίθμου BOCD στις προβλεπόμενες τιμές του κάθε μεγέθους.



Σχήμα 37: Προβλεπόμενες και πραγματικές τιμές του μεγέθους acceleration και εφαρμογή του αλγορίθμου BOCD στις πρώτες.



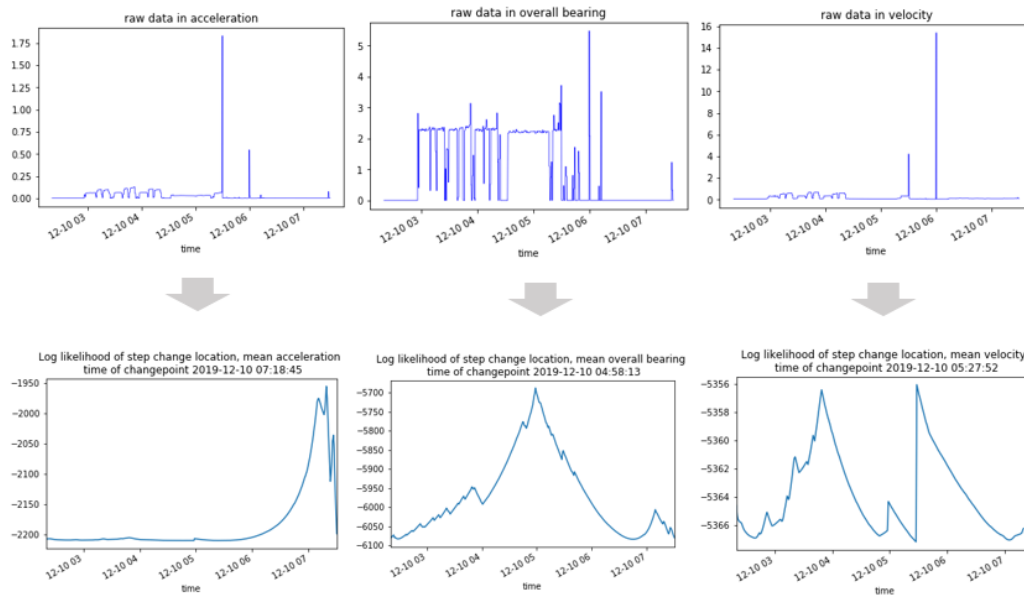
Σχήμα 38: Προβλεπόμενες και πραγματικές τιμές του μεγέθους overall bearing και εφαρμογή του αλγορίθμου BOCD στις πρώτες.



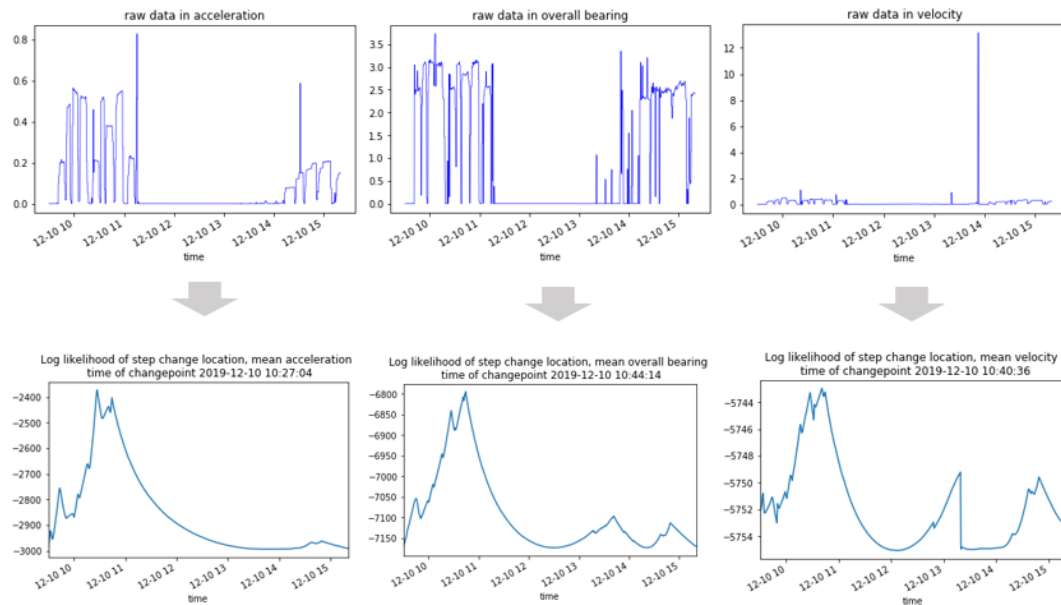
Σχήμα 39: Προβλεπόμενες και πραγματικές τιμές του μεγέθους velocity και εφαρμογή του αλγορίθμου BOCD στις πρώτες.

Αυτό που παρατηρείται έντονα από την απεικόνιση των προβλεπόμενων τιμών είναι ότι ακολουθούν το μοτίβο των πραγματικών τιμών. Αυτό οφείλεται σε δύο βασικούς παράγοντες. Αρχικά η συχνότητα συλλογής των δεδομένων είναι πάρα πολύ μεγάλη με αποτέλεσμα τα κοντινά χρονικά δεδομένα να έχουν παραπλήσια ή και ίδια τιμή. Έπειτα οι περισσότερες τιμές των μεγεθών που καταγράφονται από τους αισθητήρες και μελετώνται βρίσκονται σε ένα περιορισμένο εύρος τιμών. Η συνθήκη αυτή οδηγεί το νευρωνικό δίκτυο να εκπαιδευτεί σε πολύ καλό επίπεδο και να μπορεί να προβλέψει τα μεγέθη με μεγάλη ακρίβεια.

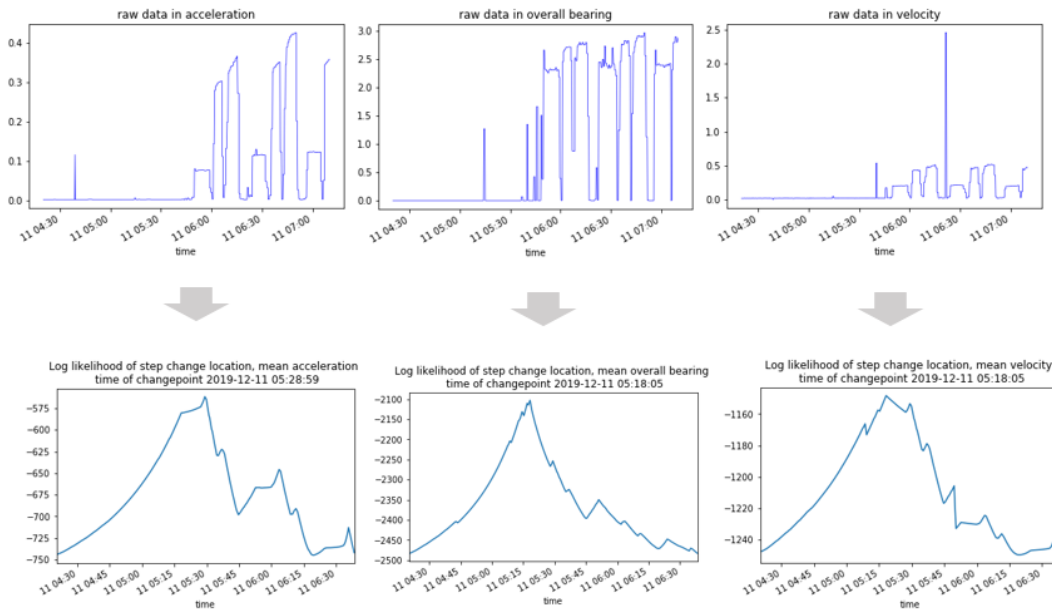
Στα παρακάτω σχήματα φαίνεται το πρώτο και το τελευταίο βήμα των εφαρμογών που έγιναν για το συγκεκριμένο πείραμα για κάποια σύνολα δεδομένων ενδεικτικά. Έτσι στην πρώτη σειρά των διαγραμμάτων απεικονίζουν τα καταγεγραμμένα δεδομένα από τους αισθητήρες για τα μεγέθη acceleration, overall bearing και velocity και στην δεύτερη παρουσιάζεται η καμπύλη που προκύπτει από την εφαρμογή του BOCD αλγορίθμου σε κάθε ένα από αυτά.



Σχήμα 40: Εφαρμογή του αλγορίθμου BOCD στις προβλεπόμενες τιμές των μεγεθών acceleration, overall bearing και velocity του πρώτου συνόλου δεδομένων που καταγράφηκε στις 10/12/2019.



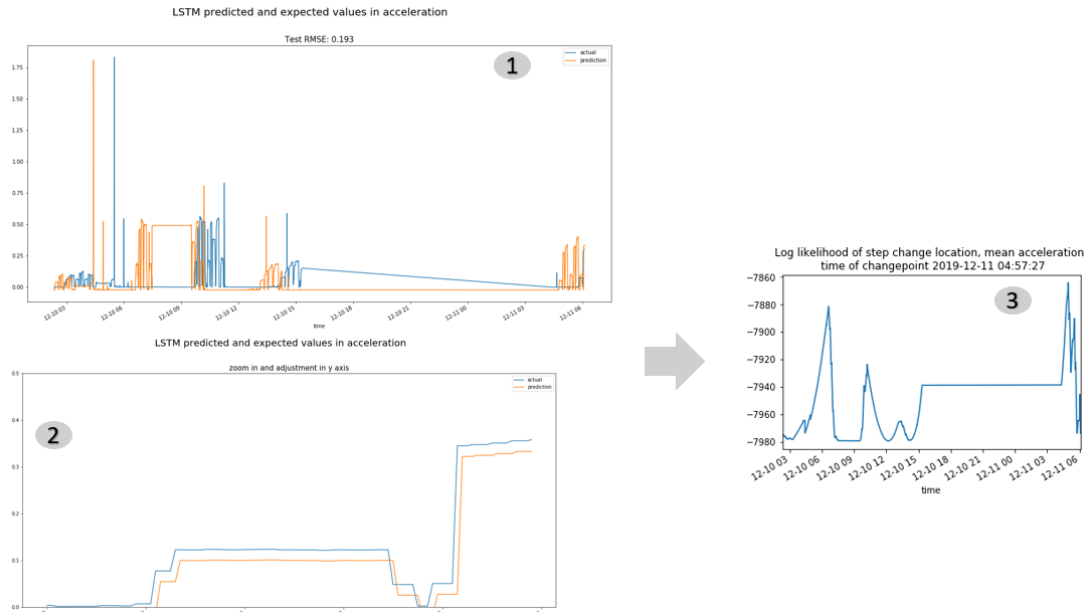
Σχήμα 41: Εφαρμογή του αλγορίθμου BOCD στις προβλεπόμενες τιμές των μεγεθών acceleration, overall bearing και velocity του δεύτερου συνόλου δεδομένων που καταγράφηκε στις 10/12/2019.



Σχήμα 42: Εφαρμογή του αλγορίθμου BOCD στις προβλεπόμενες τιμές των μεγεθών acceleration, overall bearing και velocity του συνόλου δεδομένων που καταγράφηκε στις 11/12/2019.

Από τις παραπάνω καμπύλες παρατηρείται ότι το αποτέλεσμα της εφαρμογής του αλγορίθμου BOCD στις προβλεπόμενες τιμές των μεγεθών δεν οδηγεί σε σαφή εικόνα της κατάστασης λειτουργίας του εξοπλισμού. Στα παραπάνω σχήματα υπάρχουν παραπάνω από μία αιχμές με ικανή τιμή πιθανότητας να είναι σημείο αλλαγής. Το αποτέλεσμα αυτό ήταν αναμενόμενο καθώς ο αλγόριθμος BOCD επεξεργάζεται τις προβλεπόμενες τιμές των μεγεθών που είχαν καταγραφεί από τους αισθητήρες αλλά δεν έχει αφαιρεθεί από αυτά τα σήματα ο θόρυβος που υπάρχει λόγω της φύσης των σημάτων σε βιομηχανικές εγκαταστάσεις.

Σε επόμενο βήμα έγιναν οι ίδιες δοκιμές και προβλέφθηκαν οι τιμές των μεγεθών acceleration, overall bearing και velocity σε διάστημα μιας ώρας ώστε να διαπιστωθεί αν παίζει ρόλο στην διεξαγωγή του πειράματος. Στο σχήμα 43 φαίνονται οι προβλεπόμενες με τις αντίστοιχες πραγματικές τιμές του συνόλου δεδομένων (διάγραμμα 1), η μεγέθυνση ενός μέρους αυτών (διάγραμμα 2) και το αποτέλεσμα της εφαρμογής του αλγορίθμου BOCD στις προβλεπόμενες τιμές (διάγραμμα 3).




Σχήμα 43: Προβλεπόμενες και πραγματικές τιμές του μεγέθους acceleration και εφαρμογή του αλγορίθμου BOCD στις πρώτες.

Συγκρίνοντας τα σχήματα 37 και 43 διαπιστώνεται ότι το χρονικό διάστημα στο οποίο προβλέπονται τα μεγέθη προς μελέτη δεν παίζει ρόλο στην μορφή των καμπυλών που παράγονται από το πείραμα, απλώς τις μετατοπίζει στο χρόνο προς τα αριστερά. Το συμπέρασμα αυτό επιβεβαιώνεται από το παρακάτω πίνακα όπου καταγράφονται οι χρονικές στιγμές αλλαγής συμπεριφοράς του εξοπλισμού για κάθε ένα σύνολο δεδομένων. Παρατηρείται δηλαδή ότι όταν η πρόβλεψη των μεγεθών ενδιαφέροντος γίνεται σε μεγαλύτερο χρονικό διάστημα, τότε το σημείο αλλαγής παρουσιάζεται νωρίτερα.

	acceleration	overall bearing	velocity
Πρόβλεψη τιμών στη μισή ώρα			
10/12/2019 πρώτο	2019-12-10 07:18:45	2019-12-10 04:58:13	2019-12-10 05:27:52
10/12/2019 δεύτερο	2019-12-10 10:27:04	2019-12-10 10:44:14	2019-12-10 10:40:36
11/12/2019	2019-12-11 05:28:59	2019-12-11 05:18:05	2019-12-11 05:18:05
Πρόβλεψη τιμών στη μία ώρα			
10/12/2019 πρώτο	2019-12-10 06:38:00	2019-12-10 04:25:05	2019-12-10 03:16:35
10/12/2019 δεύτερο	2019-12-10 09:54:58	2019-12-10 10:12:15	2019-12-10 10:08:28
11/12/2019	2019-12-11 04:57:27	2019-12-11 04:46:33	2019-12-11 04:46:33

Πίνακας 12: Χρονική στιγμή που εντοπίστηκε ανωμαλία από τον αλγόριθμο BOCD σε κάθε feature ανά σύνολο δεδομένων.

Όπως και στα προηγούμενα πειράματα, έγινε ανάλυση σε πραγματικό χρόνο προκειμένου να αποτυπωθεί η συμπεριφορά του αλγορίθμου στο χρόνο, χρησιμοποιώντας αυτή τη φορά τις τιμές που προβλέπει το νευρωνικό δίκτυο για τα τρία μεγέθη που καταγράφουν οι αισθητήρες. Πιο αναλυτικά στο σχήμα 44 μελετάται το σύνολο δεδομένων των 1956 τιμών που καταγράφηκε στις 10/12/2019 με διάρκεια από τις 9:30 μέχρις τη 15:20. Όπως και στο Πείραμα 1, οι επαναλήψεις έγιναν με σταθερό μέγεθος υποσυνόλου αλλά εδώ των 200 τιμών. Πραγματοποιήθηκαν συνολικά 22 επαναλήψεις και επομένως κάθε διάγραμμα είχε χρονική απόσταση από το επόμενο, 38 λεπτά. Δειγματοληπτικά λήφθηκαν τα παρακάτω διαγράμματα του σχήματος 44.




Σχήμα 44: Εφαρμογή του αλγορίθμου BOCD στις προβλεπόμενες τιμές του μεγέθους overall bearing.

Με την πάροδο του χρόνου και επομένως προσθήκη δεδομένων στην είσοδο του αλγορίθμου, το τελικό αποτέλεσμα διαφοροποιείται. Μάλιστα, παρατηρείται ότι όσο αυξάνονται τα δεδομένα προστίθενται αιχμές στην καμπύλη του BOCD αλγορίθμου, εντοπίζοντας κι άλλες χρονικές στιγμές με έντονη πιθανότητα να εμφανιστεί δυσλειτουργία.

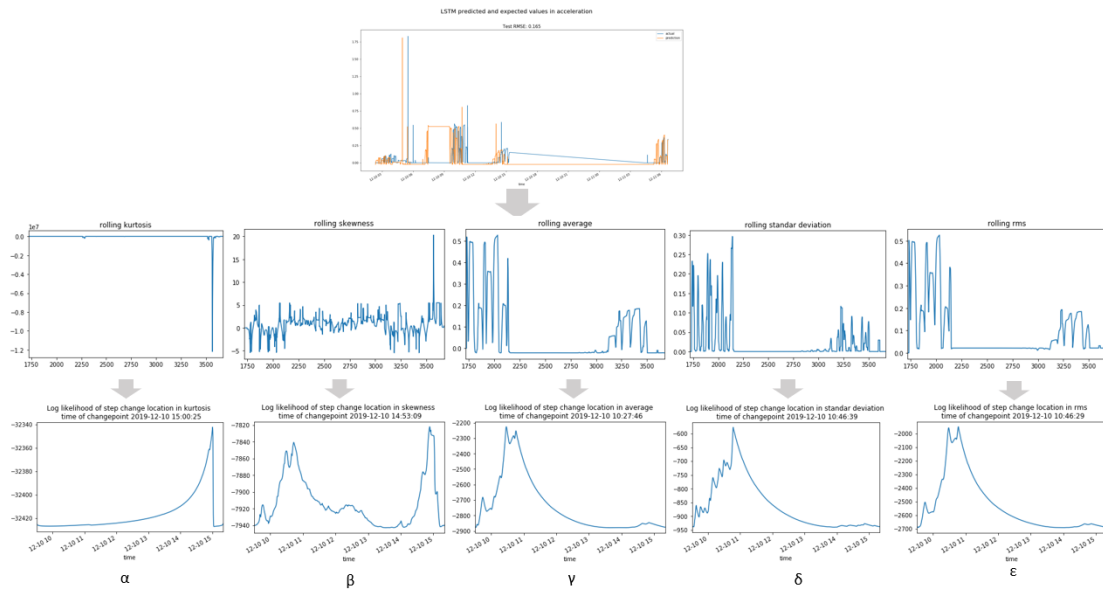
4.3.2.2 Πείραμα 4: Feature Extraction - Online Bayesian Changepoint Detection

Στο δεύτερο πείραμα αυτής της κατηγορίας γίνεται επίσης πρόβλεψη των τιμών των μεγεθών acceleration, overall bearing και velocity μέσω του νευρωνικού δικτύου LSTM. Η διαφοροποίηση με το προηγούμενο πείραμα γίνεται στο ενδιάμεσο στάδιο της εξαγωγής των 5 χαρακτηριστικών από τις προβλεπόμενες τιμές των μεγεθών προς μελέτη. Η διαδικασία εξαγωγής χαρακτηριστικών είναι η ίδια όπως παρουσιάστηκε στο Πείραμα 2. Συνεχίζοντας, στα εξαγόμενα χαρακτηριστικά εφαρμόζεται ο αλγόριθμος Bayesian online changepoint detection (BOCD) ώστε να αποτυπωθεί η κατάσταση λειτουργίας του εξοπλισμού. Διαγραμματικά φαίνεται η δομή του πειράματος 4 στο σχήμα 45.

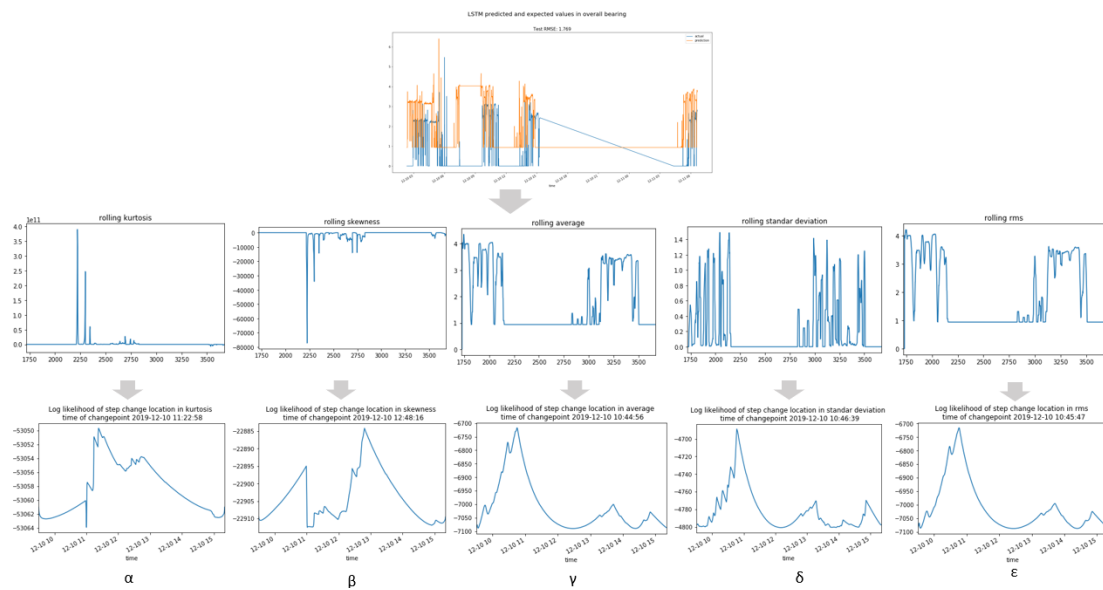


Σχήμα 45: Η δομή του πειράματος 4.

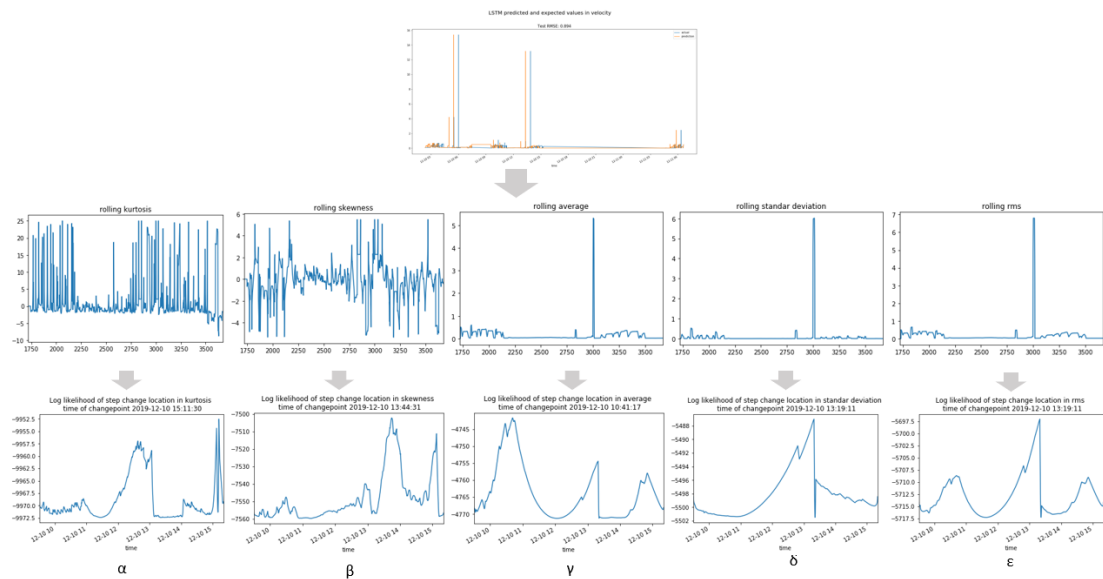
Τα αποτελέσματα του παραπάνω πειράματος φαίνονται στα διαγράμματα που ακολουθούν. Στην πρώτη σειρά των σχημάτων φαίνονται οι προβλεπόμενες τιμές των μεγεθών ενδιαφέροντος σε αντιπαραβολή με τις πραγματικές τιμές των δεδομένων αυτών. Στις προβλεπόμενες τιμές των μεγεθών acceleration, overall bearing και velocity ξεχωριστά εφαρμόζεται ο αλγόριθμος της εξαγωγής χαρακτηριστικών και εκείνα αποτυπώνονται στην επόμενη σειρά των σχημάτων. Τέλος στην τρίτη σειρά απεικονίζεται το αποτέλεσμα του BOCD αλγορίθμου σε κάθε ένα από αυτά τα χαρακτηριστικά. Τα παρακάτω σχήματα αφορούν σύνολο δεδομένων που καταγράφηκε στις 10/12/2019.



Σχήμα 46: Εφαρμογή των αλγορίθμων feature extraction και BOCD στις προβλεπόμενες τιμές του μεγέθους acceleration: α)kurtosis, β)skewness, γ)mean, δ)std, ε)rms.



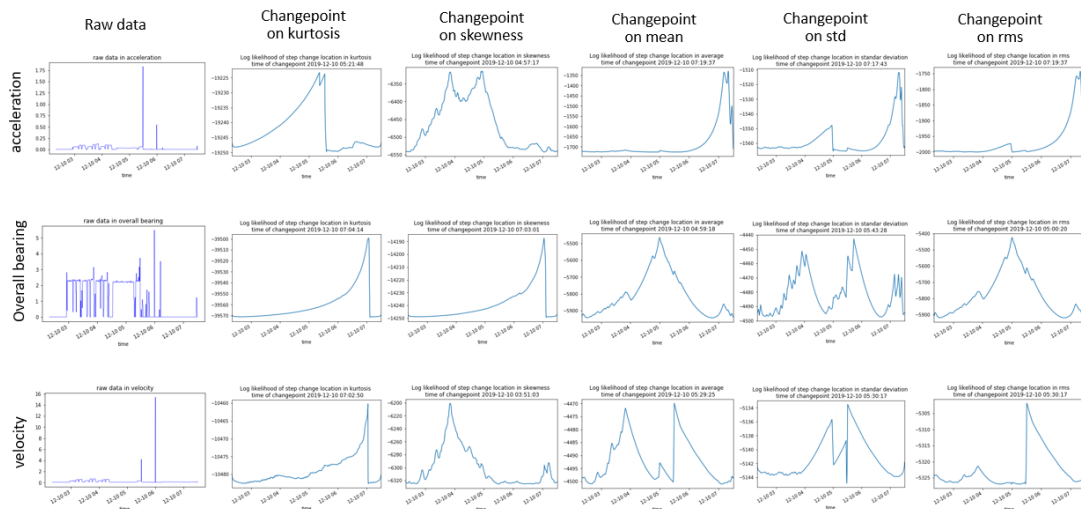
Σχήμα 47: Εφαρμογή των αλγορίθμων feature extraction και BOCD στις προβλεπόμενες τιμές του μεγέθους overall bearing: α)kurtosis, β)skewness, γ)mean, δ)std, ε)rms.



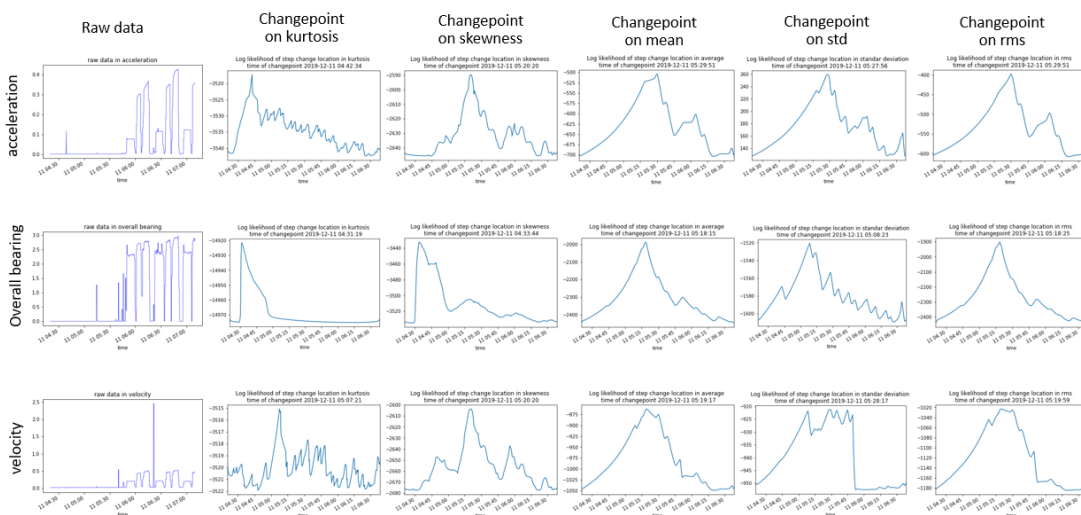
Σχήμα 48: Εφαρμογή των αλγορίθμων feature extraction και BOCD στις προβλεπόμενες τιμές του μεγέθους velocity: α)kurtosis, β)skewness, γ)mean, δ)std, ε)rms.

Όπως και στο Πείραμα 2, η απεικόνιση του κάθε χαρακτηριστικού είναι διαφορετική έχοντας ίδια είσοδο. Βέβαια εμφανίζονται αρκετές ομοιότητες στη συμπεριφορά των χαρακτηριστικών mean, standard deviation και rms. Αυτός είναι και ο λόγος που το αποτέλεσμα του αλγορίθμου BOCD εμφανίζει αρκετά κοινά σημεία για τα συγκεκριμένα χαρακτηριστικά. Επιπλέον απ' το σύνολο των διαγραμμάτων που παρουσιάζουν το τελικό αποτέλεσμα του Πειράματος 4, φαίνεται μία καλύτερη εικόνα για την διαδικασία της ανίχνευσης ανωμαλιών καθώς οι αιχμές των καμπυλών είναι πιο ξεκάθαρες και είναι λιγότερες σε αριθμό συγκρίνοντας τα με τα προηγούμενα πειράματα. Επομένως η εξαγωγή χαρακτηριστικών πρόσφερε καλύτερη ανάλυση και επεξεργασία των δεδομένων, καθώς δεν επηρεάζει ο θόρυβος των δεδομένων το αποτέλεσμα σε τέτοιο βαθμό με το προηγούμενο πείραμα.

Παρακάτω φαίνονται τα αποτελέσματα για κάποια σύνολα δεδομένων ενδεικτικά, όπου εφαρμόστηκε η διαδικασία του πειράματος αυτού. Σε κάθε σχήμα, στην πρώτη στήλη παρουσιάζονται τα αρχικά δεδομένα του κάθε μεγέθους από τα acceleration, overall bearing και velocity για ένα σύνολο δεδομένων και στις επόμενες στήλες φαίνεται το αποτέλεσμα της εφαρμογής του αλγορίθμου BOCD σε κάθε ένα χαρακτηριστικό από τα kurtosis, skewness, mean, standard deviation και rms. Οι καμπύλες αυτές αποτελούν και το αποτέλεσμα προς αξιολόγηση του τέταρτου πειράματος.



Σχήμα 49: Εφαρμογή των αλγορίθμων feature extraction και BOCD στις προβλεπόμενες τιμές των μεγεθών acceleration, overall bearing και velocity του συνόλου δεδομένων που καταγράφηκε στις 10/12/2019.



Σχήμα 50: Εφαρμογή των αλγορίθμων feature extraction και BOCD στις προβλεπόμενες τιμές των μεγεθών acceleration, overall bearing και velocity του συνόλου δεδομένων που καταγράφηκε στις 11/12/2019.

Όπως και στα παραπάνω πειράματα γίνεται η παράλληλη καταγραφή της χρονικής στιγμής όπου θεωρείται το σημείο της αλλαγής συμπεριφοράς της λειτουργίας του εξοπλισμού σύμφωνα με τον αλγόριθμο BOCD. Η πρόβλεψη τιμών είχε γίνει στο χρονικό διάστημα της μισής ώρας. Τα δεδομένα παρακάτω παρουσιάζονται με τέτοια σειρά ώστε να αντιστοιχούν στη σειρά που παρουσιάζονται οι παραπάνω ομάδες διαγραμμάτων.

features		acceleration	overall bearing	velocity
10/12/2019 πρώτο	Kurtosis	2019-12-10 15:00:25	2019-12-10 11:22:58	2019-12-10 15:11:30
	Skewness	2019-12-10 14:53:09	2019-12-10 12:48:16	2019-12-10 13:44:31
	mean	2019-12-10 10:27:46	2019-12-10 10:44:56	2019-12-10 10:41:17
	Std	2019-12-10 10:46:39	2019-12-10 10:46:39	2019-12-10 13:19:11
	rms	2019-12-10 10:46:29	2019-12-10 10:45:47	2019-12-10 13:19:11
10/12/2019 δεύτερο	Kurtosis	2019-12-10 05:21:48	2019-12-10 07:04:14	2019-12-10 07:02:50
	Skewness	2019-12-10 04:57:17	2019-12-10 07:03:01	2019-12-10 03:51:03
	mean	2019-12-10 07:19:37	2019-12-10 04:59:18	2019-12-10 05:29:25
	Std	2019-12-10 07:17:43	2019-12-10 05:43:28	2019-12-10 05:30:17
	rms	2019-12-10 07:19:37	2019-12-10 05:00:20	2019-12-10 05:30:17
11/12/2019	Kurtosis	2019-12-11 04:42:34	2019-12-11 04:31:19	2019-12-11 05:07:21
	Skewness	2019-12-11 05:20:20	2019-12-11 04:33:44	2019-12-11 05:20:20
	mean	2019-12-11 05:29:51	2019-12-11 05:18:15	2019-12-11 05:19:17
	Std	2019-12-11 05:27:56	2019-12-11 05:08:23	2019-12-11 05:28:17
	rms	2019-12-11 05:29:51	2019-12-11 05:18:25	2019-12-11 05:19:59

Πίνακας 13: Χρονική στιγμή που εντοπίστηκε ανωμαλία από τον αλγόριθμο BOCD σε κάθε feature των μεγεθών acceleration, overall bearing και velocity ανά σύνολο δεδομένων.

Συνδυάζοντας τα σχήματα με τα αποτελέσματα του Πειράματος 4 και τον Πίνακα 13 προκύπτει ότι η εφαρμογή του αλγορίθμου στα χαρακτηριστικά mean, standard deviation και rms δίνει καλύτερα αποτελέσματα σε σχέση με τα άλλα δύο, kurtosis και skewness. Όπως αναφέρθηκε και παραπάνω παρουσιάζουν παρόμοια συμπεριφορά, διαφορετική για κάθε σύνολο δεδομένων και αυτό μπορεί να γίνει αντιληπτό από τη χρονική στιγμή που προσδιορίζουν ως την πιο πιθανή για εμφάνιση ανωμαλιών. Επιπλέον το χαρακτηριστικό mean αντιλαμβάνεται νωρίτερα την δυσλειτουργία του εξοπλισμού καθώς παρουσιάζει ανωμαλία σε προηγούμενη χρονική στιγμή από τα υπόλοιπα χαρακτηριστικά για όλα τα μεγέθη που μελετώνται.


Στο πείραμα αυτό σας είσοδος χρησιμοποιούνται οι προβλεπόμενες τιμές των μεγεθών acceleration, overall bearing και velocity και όχι εκείνες που καταγράφονται από τους αισθητήρες, μέσω του νευρωνικού δικτύου. Έτσι λοιπόν, η προσέγγιση αυτή κερδίζει σε χρόνο. Με άλλα λόγια είναι πιο κερδοφόρο να γίνεται ανίχνευση ανωμαλιών σε τιμές που προβλέπονται στο μέλλον παρά σε τιμές που καταγράφονται σε πραγματικό χρόνο, αφού προσφέρεται περισσότερος χρόνος για την εφαρμογή δράσεων, οι οποίες θα οδηγήσουν τον εξοπλισμό να αποφύγει τη βλάβη. Με αυτό τον τρόπο βελτιώνεται η διαδικασία της προβλεπτικής συντήρησης και μειώνεται το κόστος λειτουργίας της βιομηχανικής μονάδας.

Για χάριν πληρότητας εμφανίζονται στο Πίνακα 14 οι χρονικές στιγμές εντοπισμού ανωμαλιών σε κάθε χαρακτηριστικό για το μέγεθος acceleration ενώ επεξεργάζονται οι προβλεπόμενες τιμές των μεγεθών στο χρονικό διάστημα της μίας ώρας. Το συμπέρασμα είναι ίδιο με το Πείραμα 3.

	features	acceleration
10/12/2019 πρώτο	Kurtosis	2019-12-10 14:27:55
	Skewness	2019-12-10 10:10:53
	Average	2019-12-10 09:55:39
	Std	2019-12-10 10:14:42
	rms	2019-12-10 09:56:31
10/12/2019 δεύτερο	Kurtosis	2019-12-10 04:49:19
	Skewness	2019-12-10 03:18:39
	Average	2019-12-10 06:38:31
	Std	2019-12-10 06:44:57
	rms	2019-12-10 06:47:02
11/12/2019	Kurtosis	2019-12-11 04:35:48
	Skewness	2019-12-11 04:48:48
	Average	2019-12-11 04:58:18
	Std	2019-12-11 04:56:35
	rms	2019-12-11 04:58:18

Πίνακας 14: Χρονική στιγμή που εντοπίστηκε ανωμαλία από τον αλγόριθμο BOCD σε κάθε feature του μεγέθους acceleration ανά σύνολο δεδομένων.

Τελειώνοντας, όπως και στα προηγούμενα πειράματα, έγινε ανάλυση σε πραγματικό χρόνο προκειμένου να αποτυπωθεί η συμπεριφορά των αλγορίθμων στο χρόνο, χρησιμοποιώντας αυτή τη φορά τις τιμές που προβλέπει το νευρωνικό δίκτυο για τα τρία μεγέθη που καταγράφουν οι αισθητήρες. Αναλυτικότερα, στο σχήμα 51 μελετάται το σύνολο δεδομένων των 1243 τιμών που καταγράφηκε στις 24/10/2019 με διάρκεια από τις 15:00 μέχρις τη 18:40. Όπως και στο Πείραμα 2, οι επαναλήψεις έγιναν με σταθερό μέγεθος υποσυνόλου, το οποίο ήταν ανάλογο του μεγέθους του αρχικού συνόλου. Αναλυτικά τα μεγέθη φαίνονται στον Πίνακα 11. Πραγματοποιήθηκαν συνολικά 24 επαναλήψεις και επομένως κάθε διάγραμμα είχε χρονική απόσταση από το επόμενο, 9 λεπτά. Δειγματοληπτικά λήφθηκαν τα παρακάτω διαγράμματα του σχήματος 51.



Σχήμα 51: Εφαρμογή των αλγορίθμων feature extraction και BOCD στα raw data για το μέγεθος overall bearing, το χαρακτηριστικό rms και τη βλάβη «σκάσιμο».

Όπως και στα προηγούμενα πειράματα, με την πάροδο του χρόνου και ακολούθως προσθήκη δεδομένων στην διαδικασία επεξεργασίας των αλγορίθμων, το τελικό αποτέλεσμα διαφοροποιείται. Το γεγονός ότι παρουσιάζει καλύτερη εικόνα από το Πείραμα 3, οφείλεται στην εξαγωγή χαρακτηριστικών που προηγείται της ανίχνευσης ανωμαλιών, όπου επιτυγχάνει εξαγωγή πληροφορίας από ανώτερο επίπεδο.

5. Συμπεράσματα και Μελλοντική Εργασία

Με την πρόοδο της τεχνολογίας στον βιομηχανικό τομέα, πολλοί αισθητήρες χρησιμοποιούνται για να παρακολουθούν την κατάσταση λειτουργίας των εξοπλισμών που απαρτίζουν την βιομηχανική μονάδα. Με αυτό τον τρόπο δίνεται η δυνατότητα ανίχνευσης ανωμαλιών στην λειτουργία τους σε πραγματικό χρόνο και επομένως η εφαρμογή της προβλεπτικής συντήρησης. Οι αλγόριθμοι μηχανικής μάθησης που μέχρι στιγμής έχουν χρησιμοποιηθεί στο εγχείρημα αυτό σύμφωνα με τη βιβλιογραφία, έχουν αρκετούς περιορισμούς. Γι' αυτό το λόγο στην προτεινόμενη προσέγγιση χρησιμοποιήθηκε αλγόριθμος βαθιάς μηχανικής μάθησης προκειμένου να προβλεφθεί ανωμαλία στην λειτουργία του εξοπλισμού. Αναλυτικότερα χρησιμοποιήθηκε ο αλγόριθμος Bayesian Online Changepoint Detection για την ανίχνευση ανωμαλιών, η διαδικασία Time-Domain Features Extraction για εξαγωγή χαρακτηριστικών και το νευρωνικό δίκτυο Long-Short Term Memory για να προβλεφθούν οι τιμές των μεγεθών που μελετά η συγκεκριμένη εργασία. Επίσης πρέπει να σημειωθεί ότι τα δεδομένα που καταγράφονται από τους αισθητήρες εμπεριέχουν αρκετό θόρυβο με αποτέλεσμα, όταν η ανίχνευση ανωμαλιών χρησιμοποιεί αυτά τα δεδομένα, χωρίς κάποια προηγούμενη επεξεργασία, να παράγει αποτελέσματα με μεγάλη αβεβαιότητα. Στην περίπτωση που η ανίχνευση ανωμαλιών γίνεται μετά την εξαγωγή χαρακτηριστικών, τα αποτελέσματα διακρίνονται από μεγαλύτερη ακρίβεια. Τα δεδομένα στην οποία βασίστηκε ολόκληρη η πειραματική διαδικασία προέρχονται από πραγματική βιομηχανική εγκατάσταση, η οποία διαθέτει εξοπλισμό για ψυχή έλαση μετάλλων.

Η μελλοντική εργασία κατευθύνεται σε πολλούς τομείς. Αρχικά η προτεινόμενη προσέγγιση θα εφαρμοστεί και σε άλλους τομείς της βιομηχανίας προκειμένου να αυξηθεί η χρήση της και να βελτιωθεί η λειτουργία της μέσω εφαρμογής της και σε άλλα σύνολα δεδομένων. Επιπλέον θα αναπτυχθεί ένα πιο σύνθετο βαθιά νευρωνικό

δίκτυο και θα συγκριθεί με το ήδη υπάρχον προκειμένου να προστεθούν κι άλλοι παράμετροι ως είσοδος και να βελτιωθεί η ακρίβεια και η αποτελεσματικότητά του. Παράλληλα θα αναπτυχθούν μοντέλα προβλεπτικής ανάλυσης σχετικά με τη εναπομείνασα χρήσιμη ζωή (Remaining Useful Life - RUL) του εξοπλισμού. Η ανάλυση αυτή θα πυροδοτείται από την ανίχνευση ανωμαλιών στη λειτουργία του.

Βιβλιογραφία

Bousdekis, A., Lepenioti, K., Ntalaperas, D., Vergeti, D., Apostolou, D., & Boursinos, V. (2019, June). A RAMI 4.0 view of predictive maintenance: software architecture, platform and case study in steel industry. In *International Conference on Advanced Information Systems Engineering* (pp. 95-106). Springer, Cham.

Bousdekis, A., Apostolou, D., & Mentzas, G. (2019). Predictive maintenance in the 4th industrial revolution: benefits, business opportunities, and managerial implications. *IEEE Engineering Management Review*, 48(1), 57-62.

(Bousdekis, Apostolou, & Mentzas, 2019)

Fahim, M., & Sillitti, A. (2019). Anomaly detection, analysis and prediction techniques in iot environment: A systematic literature review. *IEEE Access*, 7, 81664-81681.

Habeeb, R. A. A., Nasaruddin, F., Gani, A., Hashem, I. A. T., Ahmed, E., & Imran, M. (2019). Real-time big data processing for anomaly detection: A survey. *International Journal of Information Management*, 45, 289-307.

Xu, Y., Sun, Y., Wan, J., Liu, X., & Song, Z. (2017). Industrial big data for fault diagnosis: Taxonomy, review, and applications. *IEEE Access*, 5, 17368-17380.

Liu, R., Yang, B., Zio, E., & Chen, X. (2018). Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, 108, 33-47.

Wang, T., Han, Q., Chu, F., & Feng, Z. (2019). Vibration based condition monitoring and fault diagnosis of wind turbine planetary gearbox: A review. *Mechanical Systems and Signal Processing*, 126, 662-685.

Tobon-Mejia, D. A., Medjaher, K., & Zerhouni, N. (2012). CNC machine tool's wear diagnostic and prognostic by using dynamic Bayesian networks. *Mechanical Systems and Signal Processing*, 28, 167-182.

Caesarendra, W., & Tjahjowidodo, T. (2017). A review of feature extraction methods in vibration-based condition monitoring and its application for degradation trend estimation of low-speed slew bearing. *Machines*, 5(4), 21.

Lu, C., Saifullah, A., Li, B., Sha, M., Gonzalez, H., Gunatilaka, D., ... & Chen, Y. (2015). Real-time wireless sensor-actuator networks for industrial cyber-physical systems. *Proceedings of the IEEE*, 104(5), 1013-1024.

- Adams, R. P., & MacKay, D. J. (2007). Bayesian online changepoint detection. *arXiv preprint arXiv:0710.3742*.
- Eckley, I. A., Fearnhead, P., & Killick, R. (2011). Analysis of changepoint models. *Bayesian Time Series Models*, 205-224.
- Bayarri, M. J., & Berger, J. O. (2004). The interplay of Bayesian and frequentist analysis. *Statistical Science*, 58-80.
- Fu, T. C. (2011). A review on time series data mining. *Engineering Applications of Artificial Intelligence*, 24(1), 164-181.
- Angelopoulos, A., Michailidis, E. T., Nomikos, N., Trakadas, P., Hatziefremidis, A., Voliotis, S., & Zahariadis, T. (2020). Tackling faults in the industry 4.0 era—a survey of machine-learning solutions and key aspects. *Sensors*, 20(1), 109.
- Namoano, B., Emmanouilidis, C., Ruiz-Carcel, C., & Starr, A. G. (2020). Change detection in streaming data analytics: A comparison of Bayesian online and martingale approaches. *IFAC-PapersOnLine*, 53(3), 336-341.
- Shi, Z., & Chehade, A. (2021). A dual-LSTM framework combining change point detection and remaining useful life prediction. *Reliability Engineering & System Safety*, 205, 107257.
- Zhang, J., Wang, P., Yan, R., & Gao, R. X. (2018). Long short-term memory for machine remaining life prediction. *Journal of manufacturing systems*, 48, 78-86.
- Bousdekis, A., & Mentzas, G. (2021). Enterprise Integration and Interoperability for Big Data-driven Processes in the frame of Industry 4.0. *Frontiers in Big Data*, 4, 22.
- Bousdekis, A. (2018). Proactive computing in industrial maintenance decision making.
- Shi, Z., & Chehade, A. (2021). A dual-LSTM framework combining change point detection and remaining useful life prediction. *Reliability Engineering & System Safety*, 205, 107257.
- Yang, T., Zheng, Z., & Qi, L. (2020). A method for degradation prediction based on Hidden Semi-Markov models with mixture of Kernels. *Computers in Industry*, 122, 103295.

Kumar, A., Chinnam, R. B., & Tseng, F. (2019). An HMM and polynomial regression based approach for remaining useful life and health state estimation of cutting tools. *Computers & Industrial Engineering*, 128, 1008-1014.

Zheng, S., Ristovski, K., Farahat, A., & Gupta, C. (2017, June). Long short-term memory network for remaining useful life estimation. In *2017 IEEE international conference on prognostics and health management (ICPHM)* (pp. 88-95). IEEE.

Namoano, B., Emmanouilidis, C., Ruiz-Carcel, C., & Starr, A. G. (2020). Change detection in streaming data analytics: A comparison of Bayesian online and martingale approaches. *IFAC-PapersOnLine*, 53(3), 336-341.

Olah, C. (2015, August 27). Understanding LSTM Networks. [Blog post]. Retrieved from <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

Phi, M. (2018, September 24). Illustrated Guide to LSTM's and GRU's: A step by step explanation. [Blog post]. Retrieved from <https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21>

Ranjah, R. (2020, March 19). Guide to LSTMs for beginners. [Blog post]. Retrieved from <https://medium.com/analytics-vidhya/guide-to-lstms-for-beginners-ac9d1fc86176>

Srivastava, P. (2017, December 10). Essentials of Deep Learning : Introduction to Long Short Term Memory. [Blog post]. Retrieved from <https://www.analyticsvidhya.com/blog/2017/12/fundamentals-of-deep-learning-introduction-to-lstm/>

Bronstein, A. (2017, May 17). Train/Test Split and Cross Validation in Python. [Blog post]. Retrieved from <https://towardsdatascience.com/train-test-split-and-cross-validation-in-python-80b61beca4b6>

Plattform Industrie 4.0, 2021. Retrieved from <https://www.plattform-i40.de/PI40/Navigation/EN/Industrie40/WhatIsIndustrie40/what-is-industrie40.html>

Veza, I., Mladineo, M., & Peko, I. (2015). Analysis of the current state of Croatian manufacturing industry with regard to industry 4.0. *Vodice, Croatia: Croatian Association of Production Engineering*.