



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ
ΤΜΗΜΑ ΒΙΟΜΗΧΑΝΙΚΗΣ ΣΧΕΔΙΑΣΗΣ
ΚΑΙ ΠΑΡΑΓΩΓΗΣ**

Διπλωματική Εργασία

**Μηχανική/Βαθιά Μάθηση
(Machine/Deep Learning)
και προληπτική συντήρηση εξοπλισμού**

Συγγραφέας/είς

Μεταλληνός Γεώργιος

AM:45003

Επιβλέπων/ουσα:

Ελένη Σκλαβούνου

Αθήνα, Μαιος 2023



UNIVERSITY OF WEST ATTICA
DEPARTMENT OF INDUSTRIAL DESIGN
AND PRODUCTION ENGINEERING

Diploma Thesis

Machine Learning/Deep Learning
and preventive maintenance of equipment

Metallinos Georgios

Registration Number: 45003

Supervisor name and surname:

Eleni Sklavounou

Athens, May 2023

Η παρούσα διπλωματική εργασία εγκρίθηκε ομόφωνα από την τριμελή εξεταστική επιτροπή, η οποία ορίστηκε από την Γ.Σ. του Τμήματος Μηχανικών Βιομηχανικής Σχεδίασης και Παραγωγής του Πανεπιστημίου Δυτικής Αττικής, σύμφωνα με το νόμο και το εγκεκριμένο Οδηγώ Σπουδών του τμήματος.

Επιβλέπουσα : Σκλαβούνου Ελένη Ορσαλία, Λέκτορας Εφαρμογών

Επιτροπή Αξιολόγησης:

.....

Χατζόπουλος Αβραάμ
Λέκτορας

.....

Σκλαβούνου Ελένη Ορσαλία
Λέκτορας Εφαρμογών

.....

Δρόσος Χρήστος
ΕΔΙΠ

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΠΤΥΧΙΑΚΗΣ/ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Ο κάτωθι υπογεγραμμένος Μεταλληνός Γεώργιος του Στυλιανού, με αριθμό μητρώου 45003 φοιτητής του Πανεπιστημίου Δυτικής Αττικής της Σχολής Μηχανικών του Τμήματος Μηχανικών Βιομηχανικής Σχεδίασης και Παραγωγής, δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της πτυχιακής/διπλωματικής εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του πτυχίου μου».

Ο/Η Δηλών/ούσα



Μεταλληνός Γεώργιος

Ψηφιακή Υπογραφή Επιβλέποντα

ΚΕΝΗ ΣΕΛΙΔΑ

Περιεχόμενα

ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ ΣΧΟΛΗ.....	1
Συγγραφέας/είς.....	1
Όνοματεπώνυμο	Error! Bookmark not defined.
AM:	1
Student name and surname:	Error! Bookmark not defined.
Registration Number:	2
Supervisor name and surname:.....	2
ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ ΣΧΟΛΗ.....	Error! Bookmark not defined.
ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΠΤΥΧΙΑΚΗΣ/ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ	4
ΚΕΝΗ ΣΕΛΙΔΑ	5
1 Εισαγωγή.....	9
1.1 Ιστορικό και κίνητρο	9
1.2 Ερευνητικά ερωτήματα και στόχοι.....	10
1.3 Πεδίο εφαρμογής και περιορισμοί.....	12
2 Θεωρητικό πλαίσιο.....	14
2.1 Έννοιες και στρατηγικές προληπτικής συντήρησης.....	14
2.2 Βασικές αρχές Machine Learning και Deep Learning	16
2.2.1 Ιστορία.....	17
2.3 Εφαρμογές Machine Learning και Deep Learning στη βιομηχανική συντήρηση... ..	24
3 Ανασκόπηση της βιβλιογραφίας	27
3.1 Επισκόπηση της τελευταίας τεχνολογίας στην προληπτική συντήρηση με χρήση Machine Learning και Deep Learning.....	27
3.1.1 Machine Learning.....	27
3.1.2 Deep Learning	28
3.2 Βασικές τάσεις και προκλήσεις στον τομέα.....	30
3.3 Σύγκριση διαφορετικών τεχνικών και αλγορίθμων.....	32
3.4 Μελέτες περιπτώσεων και παραδείγματα επιτυχημένων υλοποιήσεων.....	34
3.5 Εταιρείες που κάνουν χρήση ML και DL.....	43
3.5.1 General Electric (GE).....	43
3.5.2 Siemens	44
3.5.3 Bosch.....	45
3.5.4 Schneider Electric.....	47
3.5.5 SKF.....	48

3.5.6	IBM	49
3.5.7	Microsoft	51
3.5.8	Honeywell.....	52
3.5.9	Rockwell Automation.....	54
3.5.10	ABB.....	55
4	Αποτελέσματα και συζήτηση	58
4.1	Επισκόπηση των ευρημάτων	58
4.2	Ερμηνεία των αποτελεσμάτων	60
4.3	Συζήτηση των επιπτώσεων και των περιορισμών	62
5	Συμπεράσματα.....	64
5.1	Περίληψη των βασικών ευρημάτων	64
5.2	Επιπτώσεις για πρακτική και μελλοντική έρευνα	65
5.3	Περιορισμοί και προτάσεις για περαιτέρω έρευνα.....	66
6	Βιβλιογραφικές αναφορές	70

1 Εισαγωγή

1.1 Ιστορικό και κίνητρο

Η προληπτική συντήρηση είναι μια κρίσιμη πτυχή των βιομηχανικών λειτουργιών, καθώς βοηθά στην αποφυγή δαπανηρών βλαβών και διακοπής λειτουργίας, βελτιστοποιεί τη διάρκεια ζωής των μηχανημάτων και διασφαλίζει την ασφάλεια των εργαζομένων. Παραδοσιακά, η προληπτική συντήρηση πραγματοποιείται με βάση σταθερά χρονοδιαγράμματα ή εμπειρικούς κανόνες, οι οποίοι μπορεί να είναι αναποτελεσματικοί και αναποτελεσματικοί, καθώς δεν λαμβάνουν υπόψη την πραγματική κατάσταση και τη χρήση του μηχανήματος. Με την έλευση της Μηχανικής Μάθησης (ML) και της Βαθιάς Μάθησης (DL), ωστόσο, έχει αυξηθεί το ενδιαφέρον για τη χρήση αυτών των τεχνικών για τη βελτίωση της αποτελεσματικότητας και της αποδοτικότητας της προληπτικής συντήρησης.

Η χρήση των ML και DL στην προληπτική συντήρηση είναι ένα ταχέως εξελισσόμενο πεδίο, με νέες τεχνικές και αλγόριθμους να αναπτύσσονται και να δοκιμάζονται σε συνεχή βάση. Ως εκ τούτου, υπάρχει ανάγκη για μια συνολική ανασκόπηση της κατάστασης της τέχνης, προκειμένου να εντοπιστούν οι βασικές τάσεις και προκλήσεις στον τομέα και να παρασχεθούν οδηγίες για μελλοντική έρευνα και πρακτική.

Το κίνητρο αυτής της διπλωματικής, ανασκόπησης βιβλιογραφίας, είναι να παρέχει μια ολοκληρωμένη και ενημερωμένη ανασκόπηση της βιβλιογραφίας σχετικά με τη χρήση των ML και DL στην προληπτική συντήρηση

βιομηχανικών μηχανημάτων. Η διπλωματική εργασία στοχεύει να απαντήσει στο ακόλουθο ερευνητικό ερώτημα:

Ποιες είναι οι βασικές τάσεις στη χρήση των ML και DL στην προληπτική συντήρηση βιομηχανικών μηχανημάτων και ποια είναι μερικά παραδείγματα επιτυχημένων υλοποιήσεων;

Απαντώντας σε αυτό το ερώτημα, η διατριβή θα συμβάλει στην κατανόηση του τρόπου με τον οποίο η ML και η DL μπορούν να χρησιμοποιηθούν για τη βελτίωση της προληπτικής συντήρησης και θα παράσχει πληροφορίες και συστάσεις για επαγγελματίες και ερευνητές στο πεδίο.

1.2 Ερευνητικά ερωτήματα και στόχοι

Το ερευνητικό ερώτημα της παρούσας βιβλιογραφικής ανασκόπησης διατριβής είναι:

Ποιες είναι οι βασικές τάσεις στη χρήση του Machine Learning (ML) και του Deep Learning (DL) στην προληπτική συντήρηση βιομηχανικών μηχανημάτων και ποια είναι μερικά παραδείγματα επιτυχημένων υλοποιήσεων;

Αυτό το ερευνητικό ερώτημα επιλέχθηκε επειδή η χρήση των ML και DL στην προληπτική συντήρηση είναι ένας ταχέως αναπτυσσόμενος τομέας έρευνας και πρακτικής, με νέες τεχνικές και αλγόριθμους να αναπτύσσονται και να δοκιμάζονται σε συνεχή βάση. Ως εκ τούτου, υπάρχει ανάγκη για μια συνολική ανασκόπηση της κατάστασης της τέχνης, προκειμένου να εντοπιστούν οι βασικές τάσεις και προκλήσεις στον τομέα και να παρασχεθούν οδηγίες για μελλοντική έρευνα και πρακτική.

Για να απαντηθεί αυτό το ερευνητικό ερώτημα, η διατριβή έχει διάφορους στόχους που στοχεύει να επιτύχει:

- Ανασκόπηση της σχετικής βιβλιογραφίας σχετικά με τις έννοιες και τις στρατηγικές προληπτικής συντήρησης, καθώς και τις βασικές αρχές της ML και DL και τις εφαρμογές τους στη βιομηχανική συντήρηση. Αυτός ο στόχος είναι ζωτικής σημασίας για τη δημιουργία μιας στέρεης θεωρητικής βάσης για τη διατριβή και για την παροχή πλαισίου για την επακόλουθη ανάλυση.
- Προσδιορισμός των βασικών τάσεων και προκλήσεων στον τομέα της προληπτικής συντήρησης χρησιμοποιώντας ML και DL. Αυτός ο στόχος περιλαμβάνει την ανάλυση της τρέχουσας κατάστασης της τέχνης στο πεδίο, τον εντοπισμό των πιο συχνά χρησιμοποιούμενων τεχνικών και αλγορίθμων και την επισήμανση των περιοχών όπου απαιτείται περαιτέρω έρευνα. Με την επίτευξη αυτού του στόχου, η διατριβή θα παρέχει μια ολοκληρωμένη επισκόπηση του πεδίου που θα είναι χρήσιμη για επαγγελματίες και ερευνητές.
- Παροχή μιας σύγκρισης διαφορετικών τεχνικών και αλγορίθμων που χρησιμοποιούνται στην προληπτική συντήρηση χρησιμοποιώντας ML και DL και επισημάνετε τα δυνατά και τα αδύνατα σημεία του καθενός. Αυτός ο στόχος είναι σημαντικός για να βοηθήσει τους επαγγελματίες και τους ερευνητές να επιλέξουν τις καταλληλότερες τεχνικές και αλγόριθμους για τις συγκεκριμένες ανάγκες και εφαρμογές τους.
- Παρουσίαση μελετών περιπτώσεων και παραδείγματα επιτυχημένων εφαρμογών προληπτικής συντήρησης με χρήση ML και DL και αναλύστε τους παράγοντες που συνέβαλαν στην επιτυχία τους. Αυτός ο στόχος θα

παρέχει πραγματικά παραδείγματα εφαρμογής των ML και DL στην προληπτική συντήρηση και θα τονίσει τα πιθανά οφέλη αυτών των τεχνικών.

Με την επίτευξη αυτών των στόχων, η διατριβή θα παρέχει μια ολοκληρωμένη και ενημερωμένη ανασκόπηση της χρήσης ML και DL στην προληπτική συντήρηση βιομηχανικών μηχανημάτων και θα παρέχει πληροφορίες και συστάσεις για επαγγελματίες και ερευνητές στον τομέα.

1.3 Πεδίο εφαρμογής και περιορισμοί

Είναι σημαντικό να καθοριστούν με σαφήνεια το εύρος και οι περιορισμοί της έρευνας προκειμένου να διαχειριστούν τις προσδοκίες και να διασφαλίσουν ότι η έρευνα είναι εφικτή εντός του δεδομένου χρόνου και πόρων. Το εύρος αυτής της διπλωματικής ανασκόπησης της βιβλιογραφίας περιορίζεται στη χρήση των ML και DL στην προληπτική συντήρηση βιομηχανικών μηχανημάτων. Η εστίαση είναι στον εντοπισμό των βασικών τάσεων και προκλήσεων στον τομέα και στην παρουσίαση περιπτωσιολογικών μελετών και παραδειγμάτων επιτυχημένων υλοποιήσεων.

Η διατριβή θα καλύψει ένα ευρύ φάσμα βιβλιογραφικών πηγών, συμπεριλαμβανομένων ακαδημαϊκών περιοδικών, πρακτικών συνεδρίων, βιβλίων και τεχνικών εκθέσεων, από διάφορους τομείς όπως η μηχανολογία, η επιστήμη των υπολογιστών και η επιστήμη δεδομένων. Το χρονοδιάγραμμα για τη βιβλιογραφική ανασκόπηση θα είναι από το έτος 2010 έως σήμερα, προκειμένου να διασφαλιστεί ότι η διατριβή καλύπτει τις τελευταίες εξελίξεις και τάσεις στον τομέα.

Οι περιορισμοί της έρευνας περιλαμβάνουν τα ακόλουθα:

- Η διατριβή θα επικεντρωθεί στη χρήση των ML και DL στην προληπτική συντήρηση βιομηχανικών μηχανημάτων και δεν θα καλύψει άλλες εφαρμογές των ML και DL στον τομέα της βιομηχανικής μηχανικής.
- Λόγω της απεραντοσύνης του πεδίου, δεν είναι δυνατό να καλυφθούν όλες οι τεχνικές και οι αλγόριθμοι που χρησιμοποιούνται στην προληπτική συντήρηση με χρήση ML και DL. Ωστόσο, η διατριβή θα παρέχει μια ολοκληρωμένη ανασκόπηση των πιο συχνά χρησιμοποιούμενων τεχνικών και αλγορίθμων και θα επισημάνει τα δυνατά και αδύνατα σημεία τους.
- Η διατριβή δεν θα παρέχει λεπτομερή συζήτηση για την εφαρμογή συστημάτων προληπτικής συντήρησης με χρήση ML και DL. Αντίθετα, θα επικεντρωθεί στην παροχή μιας επισκόπησης του πεδίου και στην παρουσίαση περιπτώσιολογικών μελετών και παραδειγμάτων επιτυχημένων υλοποιήσεων.
- Η διατριβή δεν θα παρέχει σύγκριση συστημάτων προληπτικής συντήρησης που χρησιμοποιούν ML και DL με άλλες στρατηγικές συντήρησης όπως η διορθωτική και η προγνωστική συντήρηση.

Παρά αυτούς τους περιορισμούς, αυτή η διατριβή ανασκόπησης της βιβλιογραφίας στοχεύει να παρέχει μια ολοκληρωμένη και ενημερωμένη επισκόπηση της χρήσης ML και DL στην προληπτική συντήρηση βιομηχανικών μηχανημάτων. Η διατριβή θα συμβάλει στην κατανόηση του τρόπου με τον οποίο η ML και η DL μπορούν να χρησιμοποιηθούν για τη βελτίωση της προληπτικής συντήρησης και θα παρέχει πληροφορίες και συστάσεις για επαγγελματίες και ερευνητές στον τομέα.

2 Θεωρητικό πλαίσιο

2.1 Έννοιες και στρατηγικές προληπτικής συντήρησης

Η προληπτική συντήρηση είναι μια στρατηγική συντήρησης που στοχεύει στην πρόληψη της βλάβης του εξοπλισμού εκτελώντας δραστηριότητες συντήρησης σε τακτική βάση. Ο κύριος στόχος της προληπτικής συντήρησης είναι να μειωθεί η πιθανότητα βλάβης του εξοπλισμού και να παραταθεί η διάρκεια ζωής του εξοπλισμού. Υπάρχουν διάφορες στρατηγικές προληπτικής συντήρησης που χρησιμοποιούνται στη βιομηχανία, συμπεριλαμβανομένης της συντήρησης βάσει χρόνου, της συντήρησης βάσει συνθηκών και της συντήρησης με επίκεντρο την αξιοπιστία (RCM) (Salman, 2015).

Η συντήρηση βάσει χρόνου περιλαμβάνει την εκτέλεση εργασιών συντήρησης σε σταθερά διαστήματα, όπως εβδομαδιαία, μηνιαία ή ετήσια. Αυτή η προσέγγιση είναι απλή στην εφαρμογή, αλλά μπορεί να οδηγήσει σε περιττές δραστηριότητες συντήρησης εάν ο εξοπλισμός δεν χρειάζεται πραγματικά συντήρηση.

Η συντήρηση βάσει συνθηκών, από την άλλη πλευρά, περιλαμβάνει την εκτέλεση εργασιών συντήρησης με βάση την κατάσταση του εξοπλισμού, όπως καθορίζεται από την παρακολούθηση και τις διαγνωστικές δοκιμές. Αυτή η προσέγγιση επιτρέπει τις δραστηριότητες συντήρησης να εκτελούνται μόνο όταν είναι απαραίτητο, γεγονός που μπορεί να μειώσει το κόστος συντήρησης και να ελαχιστοποιήσει το χρόνο διακοπής λειτουργίας (Jardine et al., 2006).

Η συντήρηση με επίκεντρο την αξιοπιστία (RCM) είναι μια συστηματική προσέγγιση στη συντήρηση που περιλαμβάνει τον εντοπισμό των κρίσιμων


στοιχείων ενός συστήματος και τον προσδιορισμό των κατάλληλων δραστηριοτήτων συντήρησης με βάση τις συνέπειες της αστοχίας (Moubray, 1997). Το RCM είναι μια προσέγγιση βάσει δεδομένων που λαμβάνει υπόψη τις πραγματικές συνθήκες λειτουργίας του εξοπλισμού, καθώς και τις συνέπειες της αστοχίας, προκειμένου να καθοριστεί η καταλληλότερη στρατηγική συντήρησης.

Η χρήση των ML και DL στην προληπτική συντήρηση μπορεί να βελτιώσει την αποτελεσματικότητα αυτών των στρατηγικών συντήρησης παρέχοντας ακριβέστερες και έγκαιρες πληροφορίες σχετικά με την κατάσταση του εξοπλισμού και προβλέποντας την πιθανότητα αστοχίας του εξοπλισμού. Οι τεχνικές ML και DL μπορούν να χρησιμοποιηθούν για την ανάλυση μεγάλων ποσοτήτων δεδομένων από αισθητήρες, αρχεία καταγραφής εξοπλισμού και άλλες πηγές, προκειμένου να εντοπιστούν μοτίβα και ανωμαλίες που μπορεί να υποδηλώνουν επικείμενη βλάβη του εξοπλισμού (Nakamura et al., 2019).

Συνοπτικά, η προληπτική συντήρηση είναι μια βασική στρατηγική συντήρησης που στοχεύει στην πρόληψη της βλάβης του εξοπλισμού και στην παράταση της διάρκειας ζωής του εξοπλισμού. Υπάρχουν διάφορες στρατηγικές προληπτικής συντήρησης που χρησιμοποιούνται στη βιομηχανία, συμπεριλαμβανομένης της συντήρησης βάσει χρόνου, της συντήρησης βάσει συνθηκών και της RCM. Η χρήση των ML και DL στην προληπτική συντήρηση μπορεί να βελτιώσει την αποτελεσματικότητα αυτών των στρατηγικών συντήρησης παρέχοντας ακριβέστερες και έγκαιρες πληροφορίες σχετικά με την κατάσταση του εξοπλισμού και προβλέποντας την πιθανότητα αστοχίας του εξοπλισμού.

2.2 Βασικές αρχές Machine Learning και Deep Learning

Οι αλγόριθμοι μάθησης λειτουργούν με βάση ότι οι στρατηγικές, οι αλγόριθμοι και τα συμπεράσματα που λειτούργησαν καλά στο παρελθόν είναι πιθανό να συνεχίσουν να λειτουργούν καλά στο μέλλον. Αυτά τα συμπεράσματα μπορεί να είναι προφανή, όπως «αφού ο ήλιος ανέτειλε κάθε πρωί τις τελευταίες 10.000 ημέρες, πιθανότατα θα ανατείλει και αύριο το πρωί». Μπορούν να είναι αποχρώσεις, όπως "το X% των οικογενειών έχουν γεωγραφικά ξεχωριστά είδη με χρωματικές παραλλαγές, επομένως υπάρχει Y% πιθανότητα να υπάρχουν μη ανακαλυφθέντες μαύροι κύκνοι".



Γράφημα 1 Νευρωνικό δίκτυο

([https://upload.wikimedia.org/wikipedia/commons/thumb/4/46/Colored_neural_network.svg/300px-](https://upload.wikimedia.org/wikipedia/commons/thumb/4/46/Colored_neural_network.svg/300px-Colored_neural_network.svg.png)

[Colored_neural_network.svg.png](https://upload.wikimedia.org/wikipedia/commons/thumb/4/46/Colored_neural_network.svg/300px-Colored_neural_network.svg.png))

Τα προγράμματα μηχανικής εκμάθησης μπορούν να εκτελούν εργασίες χωρίς να είναι ρητά προγραμματισμένα να το κάνουν. Περιλαμβάνει υπολογιστές που μαθαίνουν από δεδομένα που παρέχονται έτσι ώστε να εκτελούν ορισμένες εργασίες. Για απλές

εργασίες που ανατίθενται σε υπολογιστές, είναι δυνατός ο προγραμματισμός αλγορίθμων που λένε στο μηχάνημα πώς να εκτελέσει όλα τα βήματα που απαιτούνται για την επίλυση του προβλήματος. από την πλευρά του υπολογιστή, δεν χρειάζεται μάθηση. Για πιο προηγμένες εργασίες, μπορεί να είναι δύσκολο για έναν άνθρωπο να δημιουργήσει με μη αυτόματο τρόπο τους απαραίτητους αλγόριθμους. Στην πράξη, μπορεί να αποδειχθεί πιο αποτελεσματικό να βοηθήσουμε το μηχάνημα να αναπτύξει τον δικό του αλγόριθμο, αντί να ζητάμε από ανθρώπινους προγραμματιστές να προσδιορίζουν κάθε απαραίτητο βήμα.


Η πειθαρχία της μηχανικής μάθησης χρησιμοποιεί διάφορες προσεγγίσεις για να διδάξει τους υπολογιστές να εκτελούν εργασίες όπου δεν υπάρχει διαθέσιμος πλήρως ικανοποιητικός αλγόριθμος. Σε περιπτώσεις όπου υπάρχει τεράστιος αριθμός πιθανών απαντήσεων, μια προσέγγιση είναι να χαρακτηρίσετε ορισμένες από τις σωστές απαντήσεις ως έγκυρες. Αυτό μπορεί στη συνέχεια να χρησιμοποιηθεί ως δεδομένα εκπαίδευσης για τον υπολογιστή για τη βελτίωση του αλγορίθμου(ων) που χρησιμοποιεί για τον προσδιορισμό των σωστών απαντήσεων. Για παράδειγμα, για την εκπαίδευση ενός συστήματος για το έργο της ψηφιακής αναγνώρισης χαρακτήρων, έχει χρησιμοποιηθεί συχνά το σύνολο δεδομένων MNIST με χειρόγραφα ψηφία.

2.2.1 Ιστορία

Ο όρος μηχανική μάθηση επινοήθηκε το 1959 από τον Άρθουρ Σάμουελ , υπάλληλο της IBM και πρωτοπόρο στον τομέα των παιχνιδιών υπολογιστών και της τεχνητής νοημοσύνης . Το συνώνυμο αυτοδιδασκτικοί υπολογιστές χρησιμοποιήθηκε επίσης σε αυτή τη χρονική περίοδο.

Στις αρχές της δεκαετίας του 1960, μια πειραματική «μηχανή εκμάθησης» με μνήμη με διάτρητη ταινία , που ονομάζεται CyberTron, είχε αναπτυχθεί από την Raytheon Company για να αναλύει σήματα σόναρ , ηλεκτροκαρδιογραφήματα και μοτίβα ομιλίας χρησιμοποιώντας στοιχειώδη μάθηση ενίσχυσης . «Εκπαιδεύτηκε» επανειλημμένα από έναν άνθρωπο χειριστή/δάσκαλο να αναγνωρίζει μοτίβα και εξοπλίστηκε με ένα κουμπί « βλάκας » για να το αναγκάσει να αξιολογήσει εκ νέου τις εσφαλμένες αποφάσεις. Ένα αντιπροσωπευτικό βιβλίο για την έρευνα στη μηχανική μάθηση κατά τη διάρκεια της δεκαετίας του 1960 ήταν το βιβλίο του Nilsson για τις Μηχανές Μάθησης, που ασχολείται κυρίως με τη μηχανική μάθηση για ταξινόμηση προτύπων. Το ενδιαφέρον που σχετίζεται με την αναγνώριση προτύπων συνεχίστηκε στη δεκαετία του 1970, όπως περιγράφεται από τους Duda και Hart το 1973. Το 1981 δόθηκε μια αναφορά σχετικά με τη χρήση στρατηγικών διδασκαλίας έτσι ώστε ένα νευρωνικό δίκτυο να μάθει να αναγνωρίζει 40 χαρακτήρες (26 γράμματα, 10 ψηφία και 4 ειδικά σύμβολα) από τερματικό υπολογιστή.

Ο Tom M. Mitchell παρείχε έναν ευρέως αναφερόμενο, πιο επίσημο ορισμό των αλγορίθμων που μελετήθηκαν στο πεδίο της μηχανικής μάθησης: "Ένα πρόγραμμα υπολογιστή λέγεται ότι μαθαίνει από την εμπειρία E σε σχέση με κάποια κατηγορία εργασιών T και το μέτρο απόδοσης P εάν η απόδοσή του σε εργασίες στο T , όπως μετράται από το P , βελτιώνεται με την εμπειρία E ." Αυτός ο ορισμός των εργασιών στις οποίες αφορά η μηχανική μάθηση προσφέρει έναν ουσιαστικά λειτουργικό ορισμό αντί να ορίζει το πεδίο με γνωστικούς όρους. Αυτό ακολουθεί την πρόταση του Alan Turing στην εργασία του « Υπολογιστικές Μηχανές και Νοημοσύνη», στην οποία η ερώτηση «Μπορούν οι μηχανές να σκέφτονται;» αντικαθίσταται με την ερώτηση «Μπορούν οι μηχανές να κάνουν αυτό που μπορούμε να κάνουμε εμείς (ως σκεπτόμενες οντότητες);»



Γράφημα

2

Δέντρο

απόφασης


(https://www.google.com/url?sa=i&url=https%3A%2F%2Falgodaily.com%2Flessons%2Fdecision-trees-basics&psig=AOvVaw0mMkqbcUc_OdEYR7VKzPg9&ust=1680685748154000&source=images&cd=vfe&ved=0CBAQjRxqFwoTCLCQgrrwj_4CFQAAAAAdAAAAABAJ)

Η σύγχρονη μηχανική μάθηση έχει δύο στόχους, ο ένας είναι η ταξινόμηση δεδομένων με βάση τα μοντέλα που έχουν αναπτυχθεί, ο άλλος σκοπός είναι να γίνουν προβλέψεις για μελλοντικά αποτελέσματα με βάση αυτά τα μοντέλα. Ένας υποθετικός αλγόριθμος που είναι ειδικός για την ταξινόμηση δεδομένων μπορεί να χρησιμοποιεί την όραση των σπύλων σε υπολογιστή σε συνδυασμό με την εποπτευόμενη μάθηση, προκειμένου να την εκπαιδεύσει να ταξινομεί τους καρκινικούς σπύλους. Ένας αλγόριθμος μηχανικής εκμάθησης για συναλλαγές μετοχών μπορεί να ενημερώσει τον έμπορο για μελλοντικές πιθανές προβλέψεις.

Η Machine Learning (ML) και η Deep Learning (DL) είναι υποπεδία της Τεχνητής Νοημοσύνης (AI) που περιλαμβάνουν την ανάπτυξη αλγορίθμων και μοντέλων που μπορούν να μάθουν μοτίβα και σχέσεις σε δεδομένα χωρίς να είναι ρητά προγραμματισμένοι (Alpaydin, 2010). Οι τεχνικές ML και DL έχουν

εφαρμοστεί με επιτυχία σε διάφορους τομείς, όπως η αναγνώριση εικόνας και ομιλίας, η επεξεργασία φυσικής γλώσσας και η προγνωστική συντήρηση.


Σε υψηλό επίπεδο, οι αλγόριθμοι ML μπορούν να κατηγοριοποιηθούν σε τρεις τύπους: εποπτευόμενη μάθηση, μάθηση χωρίς επίβλεψη και ενισχυτική μάθηση. Στην εποπτευόμενη μάθηση, ο αλγόριθμος εκπαιδεύεται σε ένα επισημασμένο σύνολο δεδομένων, όπου είναι γνωστά τα σωστά αποτελέσματα. Ο αλγόριθμος μαθαίνει να αντιστοιχίζει εισόδους σε εξόδους με βάση τα δεδομένα εκπαίδευσης και στη συνέχεια μπορεί να κάνει προβλέψεις για νέα, αόρατα δεδομένα. Παραδείγματα εποπτευόμενων αλγορίθμων μάθησης περιλαμβάνουν τα δέντρα αποφάσεων, την λογιστική παλινδρόμηση και τις μηχανές διανυσμάτων υποστήριξης (SVM) (Bishop, 2006).



Γράφημα 3 Ανάλυση Παλινδρόμησης

Η εποπτευόμενη μάθηση (SL) είναι ένα παράδειγμα μηχανικής μάθησης για προβλήματα όπου τα διαθέσιμα δεδομένα αποτελούνται από παραδείγματα με ετικέτα, που σημαίνει ότι κάθε σημείο δεδομένων περιέχει χαρακτηριστικά (συμμεταβλητές) και μια σχετική ετικέτα. Ο στόχος των εποπτευόμενων αλγορίθμων μάθησης είναι η εκμάθηση μιας συνάρτησης που αντιστοιχίζει διανύσματα χαρακτηριστικών (εισόδους) σε ετικέτες (έξοδος), με βάση παραδείγματα ζευγών

εισόδου-εξόδου. Συμπεραίνει μια συνάρτηση απόεπισημασμένα δεδομένα εκπαίδευσης που αποτελούνται από ένα σύνολο παραδειγμάτων εκπαίδευσης. Στην εποπτευόμενη μάθηση, κάθε παράδειγμα είναι ένα ζεύγος που αποτελείται από ένα αντικείμενο εισόδου (συνήθως ένα διάνυσμα) και μια επιθυμητή τιμή εξόδου (ονομάζεται επίσης εποπτικό σήμα). Ένας εποπτευόμενος αλγόριθμος μάθησης αναλύει τα δεδομένα εκπαίδευσης και παράγει μια συνάρτηση που προκύπτει, η οποία μπορεί να χρησιμοποιηθεί για τη χαρτογράφηση νέων παραδειγμάτων. Ένα βέλτιστο σενάριο θα επιτρέψει στον αλγόριθμο να προσδιορίσει σωστά τις ετικέτες κλάσεων για άορατες περιπτώσεις. Αυτό απαιτεί από τον αλγόριθμο μάθησης να γενικεύει από τα δεδομένα εκπαίδευσης σε άορατες καταστάσεις με «λογικό» τρόπο (βλ. επαγωγική προκατάληψη). Αυτή η στατιστική ποιότητα ενός αλγορίθμου μετράται μέσω του λεγόμενου σφάλματος γενίκευσης .



Γράφημα 4 SVM Classifier

(https://www.google.com/url?sa=i&url=https%3A%2F%2Fen.wikipedia.org%2Fwiki%2FSupport_vector_machine&psig=AOvVaw3llrABzqyp5wM3lr1vEUYT&ust=1680685822143000&source=images&cd=vfe&ved=0CBAQj

RxqFwoTClig9tzwj_4CFQAAAAAdAAAAABAE)

Ένα πρώτο ζήτημα είναι η αντιστάθμιση μεταξύ μεροληψίας και διακύμανσης . Φανταστείτε ότι έχουμε διαθέσιμα πολλά διαφορετικά, αλλά εξίσου καλά, σύνολα δεδομένων εκπαίδευσης. Ένας αλγόριθμος μάθησης είναι προκατειλημμένος για μια συγκεκριμένη είσοδο X εάν, όταν εκπαιδεύεται σε καθένα από αυτά τα σύνολα δεδομένων, είναι συστηματικά λανθασμένο κατά την πρόβλεψη της σωστής εξόδου για X . Ένας αλγόριθμος εκμάθησης έχει υψηλή διακύμανση για μια συγκεκριμένη είσοδο X εάν προβλέπει διαφορετικές τιμές εξόδου όταν εκπαιδεύεται σε διαφορετικά σετ εκπαίδευσης. Το σφάλμα πρόβλεψης ενός μαθημένου ταξινομητή σχετίζεται με το άθροισμα της μεροληψίας και τη διακύμανση του αλγορίθμου εκμάθησης. Γενικά, υπάρχει μια αντιστάθμιση μεταξύ μεροληψίας και διακύμανσης. Ένας αλγόριθμος μάθησης με χαμηλή μεροληψία πρέπει να είναι «ευέλικτος» ώστε να μπορεί να ταιριάζει καλά στα δεδομένα. Αλλά εάν ο αλγόριθμος εκμάθησης είναι πολύ ευέλικτος, θα ταιριάζει σε κάθε σύνολο δεδομένων εκπαίδευσης διαφορετικά και ως εκ τούτου θα έχει υψηλή διακύμανση. Μια βασική πτυχή πολλών εποπτευόμενων μεθόδων μάθησης είναι ότι είναι σε θέση να προσαρμόσουν αυτήν την αντιστάθμιση μεταξύ μεροληψίας και διακύμανσης (είτε αυτόματα είτε παρέχοντας μια παράμετρο μεροληψίας/διακύμανσης που μπορεί να προσαρμόσει ο χρήστης).

Η μάθηση χωρίς επίβλεψη, από την άλλη πλευρά, περιλαμβάνει την εκπαίδευση ενός αλγορίθμου σε ένα σύνολο δεδομένων χωρίς ετικέτα, όπου τα σωστά αποτελέσματα δεν είναι γνωστά. Ο αλγόριθμος μαθαίνει να αναγνωρίζει μοτίβα και δομές στα δεδομένα, όπως συστάδες ή ακραίες τιμές. Παραδείγματα αλγορίθμων μάθησης χωρίς επίβλεψη περιλαμβάνουν ομαδοποίηση k -means, ανάλυση κύριου στοιχείου (PCA) και αυτοκωδικοποιητές (Goodfellow et al., 2016).

Η ενισχυτική μάθηση περιλαμβάνει την εκπαίδευση ενός πράκτορα ώστε να αλληλεπιδρά με ένα περιβάλλον και να μαθαίνει μέσω δοκιμής και λάθους. Ο πράκτορας λαμβάνει ανταμοιβές ή ποινές με βάση τις ενέργειές του και μαθαίνει να μεγιστοποιεί τις ανταμοιβές του με την πάροδο του χρόνου. Η ενισχυτική μάθηση έχει εφαρμοστεί με επιτυχία σε παιχνίδια όπως το σκάκι και το Go, καθώς και στη ρομποτική και τα συστήματα ελέγχου (Sutton and Barto, 2018).

Το DL είναι ένα υποπεδίο της ML που περιλαμβάνει την ανάπτυξη νευρωνικών δικτύων με πολλαπλά επίπεδα, τα οποία μπορούν να μάθουν περίπλοκες αναπαραστάσεις δεδομένων. Οι αλγόριθμοι DL έχουν επιτύχει επιδόσεις αιχμής σε διάφορες εργασίες όπως η αναγνώριση εικόνας και ομιλίας, η επεξεργασία φυσικής γλώσσας και η προγνωστική συντήρηση (LeCun et al., 2015).

Οι αλγόριθμοι DL μπορούν να εκπαιδευτούν χρησιμοποιώντας εποπτευόμενη μάθηση, μάθηση χωρίς επίβλεψη ή ενισχυτική μάθηση. Παραδείγματα αρχιτεκτονικών DL περιλαμβάνουν συνελκτικά νευρωνικά δίκτυα (CNN) για την αναγνώριση εικόνας, επαναλαμβανόμενα νευρωνικά δίκτυα (RNN) για διαδοχική επεξεργασία δεδομένων και δίκτυα βαθιάς πεποίθησης (DBNs) για μάθηση χωρίς επίβλεψη (Goodfellow et al., 2016).

Συνοπτικά, το ML και το DL είναι υποπεδία της τεχνητής νοημοσύνης που περιλαμβάνουν την ανάπτυξη αλγορίθμων και μοντέλων που μπορούν να μάθουν μοτίβα και σχέσεις σε δεδομένα χωρίς να είναι ρητά προγραμματισμένοι. Οι αλγόριθμοι ML μπορούν να κατηγοριοποιηθούν σε τρεις τύπους: εποπτευόμενη μάθηση, μάθηση χωρίς επίβλεψη και ενισχυτική μάθηση.

Το DL είναι ένα υποπεδίο της ML που περιλαμβάνει την ανάπτυξη νευρωνικών δικτύων με πολλαπλά επίπεδα, τα οποία μπορούν να μάθουν περίπλοκες αναπαραστάσεις δεδομένων.

2.3 Εφαρμογές Machine Learning και Deep Learning στη βιομηχανική συντήρηση

Οι τεχνικές Machine Learning και Deep Learning έχουν εφαρμοστεί σε διάφορες πτυχές της βιομηχανικής συντήρησης, συμπεριλαμβανομένης της προγνωστικής συντήρησης, της ανίχνευσης ανωμαλιών, της διάγνωσης σφαλμάτων και της πρόβλεψης υπολειπόμενης ωφέλιμης ζωής. Αυτές οι τεχνικές έχουν τη δυνατότητα να βελτιώσουν την αποδοτικότητα συντήρησης, να μειώσουν το χρόνο διακοπής λειτουργίας και να αυξήσουν την αξιοπιστία του εξοπλισμού (Wang et al., 2020).

Η προγνωστική συντήρηση περιλαμβάνει την πρόβλεψη πότε ένα κομμάτι του εξοπλισμού θα αποτύχει με βάση την ιστορική χρήση του και τα δεδομένα αισθητήρων. Οι τεχνικές ML και DL μπορούν να χρησιμοποιηθούν για την ανάλυση αυτών των δεδομένων και τον εντοπισμό μοτίβων που υποδεικνύουν πότε είναι πιθανό να συμβεί μια αποτυχία. Η προγνωστική συντήρηση μπορεί να βοηθήσει στην αποφυγή απρογραμμάτιστων διαστημάτων διακοπής λειτουργίας, στη μείωση του κόστους συντήρησης και στην παράταση της διάρκειας ζωής του εξοπλισμού (Möller et al., 2019).

Η ανίχνευση ανωμαλιών περιλαμβάνει τον εντοπισμό μη φυσιολογικής συμπεριφοράς ή συμβάντων στα δεδομένα αισθητήρων εξοπλισμού. Οι τεχνικές

ML και DL μπορούν να χρησιμοποιηθούν για την εκμάθηση της κανονικής συμπεριφοράς λειτουργίας του εξοπλισμού και τον εντοπισμό αποκλίσεων από αυτήν τη συμπεριφορά. Ο εντοπισμός ανωμαλιών μπορεί να βοηθήσει στον εντοπισμό πιθανών αστοχιών ή ζητημάτων συντήρησης προτού προκαλέσουν σημαντική ζημιά (Gao et al., 2018).

Η διάγνωση βλαβών περιλαμβάνει τον εντοπισμό της βασικής αιτίας μιας βλάβης σε ένα κομμάτι του εξοπλισμού. Οι τεχνικές ML και DL μπορούν να χρησιμοποιηθούν για την ανάλυση δεδομένων αισθητήρων και τον εντοπισμό των παραγόντων που συνέβαλαν στην αποτυχία. Η διάγνωση σφαλμάτων μπορεί να βοηθήσει στη βελτίωση των στρατηγικών συντήρησης και στην πρόληψη παρόμοιων αστοχιών στο μέλλον (Tang et al., 2018).

Η πρόβλεψη της υπολειπόμενης ωφέλιμης ζωής (RUL) περιλαμβάνει την εκτίμηση του ποσού της ωφέλιμης ζωής που απομένει σε ένα κομμάτι του εξοπλισμού. Οι τεχνικές ML και DL μπορούν να χρησιμοποιηθούν για την ανάλυση δεδομένων αισθητήρων και την πρόβλεψη πότε είναι πιθανό να συμβεί μια αστοχία με βάση την τρέχουσα κατάσταση του εξοπλισμού. Η πρόβλεψη RUL μπορεί να βοηθήσει στη βελτιστοποίηση των προγραμμάτων συντήρησης και στη μείωση του κόστους συντήρησης (Liu et al., 2018).

Συνοπτικά, οι τεχνικές ML και DL έχουν εφαρμοστεί σε διάφορες πτυχές της βιομηχανικής συντήρησης, συμπεριλαμβανομένης της προγνωστικής συντήρησης, της ανίχνευσης ανωμαλιών, της διάγνωσης σφαλμάτων και της πρόβλεψης υπολειπόμενης ωφέλιμης ζωής. Αυτές οι τεχνικές μπορούν να βοηθήσουν στη βελτίωση της απόδοσης συντήρησης, στη μείωση του χρόνου διακοπής λειτουργίας και στην αύξηση της αξιοπιστίας του εξοπλισμού.

3 Ανασκόπηση της βιβλιογραφίας

3.1 Επισκόπηση της τελευταίας τεχνολογίας στην προληπτική συντήρηση με χρήση Machine Learning και Deep Learning

3.1.1 Machine Learning

Τα τελευταία χρόνια, υπάρχει αυξανόμενο ενδιαφέρον για τη χρήση των τεχνικών Machine Learning (ML) και Deep Learning (DL) για προγνωστική συντήρηση σε βιομηχανικά περιβάλλοντα. Αυτές οι τεχνικές έχουν εφαρμοστεί σε ένα ευρύ φάσμα μηχανημάτων, συμπεριλαμβανομένων των στροβίλων, των αντλιών, των κινητήρων και των γεννητριών (Zhao et al., 2020).

Πολλές μελέτες έχουν επικεντρωθεί στην ανάπτυξη αλγορίθμων ML και DL για την πρόβλεψη αστοχιών εξοπλισμού. Για παράδειγμα, οι Zhang et al. (2018) ανέπτυξε ένα μοντέλο συνόλου που συνδύαζε διαφορετικούς αλγόριθμους ML για την πρόβλεψη αστοχιών εξοπλισμού σε ανεμογεννήτριες. Το μοντέλο κατάφερε να επιτύχει υψηλή ακρίβεια στην πρόβλεψη της υπολειπόμενης ωφέλιμης ζωής των στροβίλων.

Άλλες μελέτες έχουν επικεντρωθεί στην ανάπτυξη τεχνικών για τον εντοπισμό ανωμαλιών και τη διάγνωση βλαβών. Οι Gao et al. (2018) ανέπτυξε μια μέθοδο βασισμένη σε DL για την ανίχνευση ανωμαλιών σε δεδομένα αισθητήρων από ένα υδραυλικό σύστημα. Η μέθοδος ήταν σε θέση να ανιχνεύσει με ακρίβεια μια σειρά από ανωμαλίες, συμπεριλαμβανομένων της φθοράς, των διακυμάνσεων της πίεσης και των διακυμάνσεων της θερμοκρασίας.

Υπήρξε επίσης έρευνα σχετικά με τη χρήση τεχνικών ML και DL για τη βελτιστοποίηση των χρονοδιαγραμμάτων συντήρησης. Οι Liu et al. (2018) ανέπτυξε μια μέθοδο βασισμένη σε ML για την πρόβλεψη του βέλτιστου χρόνου για τη συντήρηση των υδραυλικών αντλιών. Η μέθοδος μπόρεσε να μειώσει το κόστος συντήρησης και να βελτιώσει την αξιοπιστία του εξοπλισμού προβλέποντας τον βέλτιστο χρόνο συντήρησης με βάση την τρέχουσα κατάσταση του εξοπλισμού.

Συνολικά, η τελευταία λέξη της τεχνολογίας στην προληπτική συντήρηση με χρήση τεχνικών ML και DL εξελίσσεται ταχέως. Αυτές οι τεχνικές έχουν δείξει πολλές υποσχέσεις για τη βελτίωση της απόδοσης συντήρησης, τη μείωση του χρόνου διακοπής λειτουργίας και την αύξηση της αξιοπιστίας του εξοπλισμού. Ωστόσο, εξακολουθούν να υπάρχουν πολλές προκλήσεις που πρέπει να αντιμετωπιστούν, όπως η ποιότητα και η διαθεσιμότητα δεδομένων, η ερμηνεία αλγορίθμων και τα ζητήματα ανάπτυξης (Wang et al., 2020).

3.1.2 Deep Learning

Το Deep Learning (DL) έχει αναδειχθεί ως ένα ισχυρό εργαλείο για την προγνωστική συντήρηση σε βιομηχανικά περιβάλλοντα. Οι τεχνικές DL μπορούν να μάθουν πολύπλοκα μοτίβα από μεγάλους όγκους δεδομένων και έχουν αποδειχθεί ότι ξεπερνούν τις παραδοσιακές τεχνικές Machine Learning (ML) σε πολλές εφαρμογές (Wen et al., 2019).

Ένα από τα βασικά πλεονεκτήματα των τεχνικών DL είναι η ικανότητά τους να μαθαίνουν αναπαραστάσεις δεδομένων που μπορούν να συλλάβουν τόσο τοπικά όσο και παγκόσμια μοτίβα. Αυτό τους επιτρέπει να εντοπίζουν ανεπαίσθητες αλλαγές στα δεδομένα του αισθητήρα που μπορεί να

υποδηλώνουν επικείμενες βλάβες του εξοπλισμού. Για παράδειγμα, οι Liao et al. (2019) χρησιμοποίησε μια μέθοδο που βασίζεται σε DL για την πρόβλεψη αστοχιών σε ένα σύστημα ρουλεμάν. Η μέθοδος κατάφερε να επιτύχει υψηλή ακρίβεια στην πρόβλεψη της υπολειπόμενης ωφέλιμης ζωής των ρουλεμάν.

Ένα άλλο πλεονέκτημα των τεχνικών DL είναι η ικανότητά τους να χειρίζονται δεδομένα υψηλών διαστάσεων, όπως εικόνες και βίντεο. Αυτό έδωσε τη δυνατότητα στους ερευνητές να εφαρμόσουν τεχνικές DL σε ένα ευρύ φάσμα εξοπλισμού, συμπεριλαμβανομένων των στροβίλων, των κινητήρων και των μετασχηματιστών. Για παράδειγμα, οι Zhang et al. (2020) χρησιμοποίησε μια μέθοδο που βασίζεται σε DL για την ανίχνευση ελαττωμάτων στους μετασχηματιστές ισχύος. Η μέθοδος ήταν σε θέση να ανιχνεύσει με ακρίβεια μια σειρά από ελαττώματα, συμπεριλαμβανομένης της παραμόρφωσης της περιέλιξης, της χαλάρωσης του πυρήνα και της γήρανσης της μόνωσης.

Οι τεχνικές DL έχουν επίσης εφαρμοστεί στη διάγνωση βλαβών και στην ανίχνευση ανωμαλιών. Οι Wen et al. (2019) ανέπτυξε μια μέθοδο που βασίζεται σε DL για τη διάγνωση σφαλμάτων σε ανεμογεννήτριες. Η μέθοδος ήταν σε θέση να προσδιορίσει τη βασική αιτία μιας αποτυχίας αναλύοντας δεδομένα αισθητήρα και εντοπίζοντας τους παράγοντες που συνέβαλαν στην αποτυχία. Ομοίως, οι Gao et al. (2018) χρησιμοποίησε μια μέθοδο που βασίζεται σε DL για την ανίχνευση ανωμαλιών σε υδραυλικά συστήματα.

Συνοπτικά, οι τεχνικές DL έχουν αναδειχθεί ως ένα ισχυρό εργαλείο για προληπτική συντήρηση σε βιομηχανικά περιβάλλοντα. Μπορούν να μάθουν πολύπλοκα μοτίβα από μεγάλους όγκους δεδομένων, να χειρίζονται δεδομένα

υψηλών διαστάσεων και είναι κατάλληλα για διάγνωση σφαλμάτων και ανίχνευση ανωμαλιών. Αυτές οι τεχνικές έχουν δείξει πολλές υποσχέσεις για τη βελτίωση της απόδοσης συντήρησης, τη μείωση του χρόνου διακοπής λειτουργίας και την αύξηση της αξιοπιστίας του εξοπλισμού. Ωστόσο, εξακολουθούν να υπάρχουν προκλήσεις που πρέπει να αντιμετωπιστούν, όπως η ποιότητα και η διαθεσιμότητα δεδομένων, η ερμηνεία αλγορίθμων και τα ζητήματα ανάπτυξης (Wang et al., 2020).

3.2 Βασικές τάσεις και προκλήσεις στον τομέα

Η χρήση της μηχανικής μάθησης και της βαθιάς μάθησης στην προληπτική συντήρηση είναι ένας ενεργός τομέας έρευνας τα τελευταία χρόνια και υπάρχουν αρκετές βασικές τάσεις και προκλήσεις που έχουν αναδειχθεί.

Μια τάση είναι η αυξανόμενη διαθεσιμότητα δεδομένων από αισθητήρες και άλλες πηγές. Με την έλευση του Industrial Internet of Things (IIoT), υπάρχει ένας αυξανόμενος όγκος δεδομένων που μπορούν να χρησιμοποιηθούν για προγνωστική συντήρηση. Ωστόσο, η ποιότητα των δεδομένων μπορεί να είναι μια πρόκληση, καθώς μπορεί να είναι θορυβώδη ή ελλιπή (Nguyen et al., 2021).

Μια άλλη τάση είναι η ανάπτυξη νέων αλγορίθμων που μπορούν να χειριστούν μεγάλες ποσότητες δεδομένων που παράγονται σε βιομηχανικά περιβάλλοντα. Αυτό οδήγησε στην εμφάνιση τεχνικών DL, οι οποίες μπορούν να μάθουν πολύπλοκα μοτίβα από μεγάλα σύνολα δεδομένων. Ωστόσο, αυτές οι τεχνικές

μπορεί να είναι υπολογιστικά ακριβές και απαιτούν σημαντικούς υπολογιστικούς πόρους (Wang et al., 2020).

Μια βασική πρόκληση στο πεδίο είναι η ερμηνευσιμότητα των αλγορίθμων ML και DL. Σε πολλές περιπτώσεις, αυτές οι τεχνικές θεωρούνται «μαύρα κουτιά», επειδή μπορεί να είναι δύσκολο να κατανοήσουμε πώς κάνουν προβλέψεις. Αυτό μπορεί να αποτελέσει εμπόδιο στην υιοθέτηση, καθώς μπορεί να είναι δύσκολο να πειστούν οι ενδιαφερόμενοι για την εγκυρότητα των προβλέψεων (Liu et al., 2020).

Μια άλλη πρόκληση είναι η ανάπτυξη μοντέλων ML και DL σε βιομηχανικά περιβάλλοντα. Τα μοντέλα μπορεί να χρειαστεί να επανεκπαιδεύονται περιοδικά για να ληφθούν υπόψη οι μεταβαλλόμενες συνθήκες και μπορεί να χρειαστεί να ενσωματωθούν με τα υπάρχοντα συστήματα και διαδικασίες. Αυτό μπορεί να είναι ένα πολύπλοκο έργο που απαιτεί στενή συνεργασία μεταξύ επιστημόνων δεδομένων και ειδικών του τομέα (Wang et al., 2020).

Τέλος, υπάρχει ανάγκη για σύνολα δεδομένων αναφοράς και μετρήσεις αξιολόγησης στο πεδίο. Αυτό μπορεί να βοηθήσει τους ερευνητές να συγκρίνουν την απόδοση διαφορετικών αλγορίθμων και να εντοπίσουν τομείς προς βελτίωση (Nguyen et al., 2021).

Συνοπτικά, υπάρχουν αρκετές βασικές τάσεις και προκλήσεις στον τομέα της προληπτικής συντήρησης με χρήση ML και DL. Αυτά περιλαμβάνουν την αυξανόμενη διαθεσιμότητα δεδομένων, την ανάπτυξη νέων αλγορίθμων, την ερμηνευσιμότητα των μοντέλων, την ανάπτυξη μοντέλων και την ανάγκη για σύνολα δεδομένων αναφοράς και μετρήσεις αξιολόγησης. Η αντιμετώπιση

αυτών των προκλήσεων θα είναι κρίσιμη για την αξιοποίηση του πλήρους δυναμικού των ML και DL στη βιομηχανική συντήρηση.

3.3 Σύγκριση διαφορετικών τεχνικών και αλγορίθμων

Πολλές διαφορετικές τεχνικές και αλγόριθμοι έχουν προταθεί για προληπτική συντήρηση με χρήση ML και DL. Σε αυτήν την ενότητα, θα παρέχουμε μια σύντομη επισκόπηση ορισμένων από τις πιο συχνά χρησιμοποιούμενες τεχνικές και θα συγκρίνουμε την απόδοσή τους.

- Μοντέλα παλινδρόμησης: Τα μοντέλα παλινδρόμησης χρησιμοποιούνται συνήθως στην προγνωστική συντήρηση για την εκτίμηση της υπολειπόμενης ωφέλιμης ζωής (RUL) ενός μηχανήματος. Η γραμμική παλινδρόμηση, η παλινδρόμηση διανύσματος υποστήριξης (SVR) και η τυχαία παλινδρόμηση δασών (RFR) είναι μερικές από τις κοινώς χρησιμοποιούμενες τεχνικές (Zhao et al., 2019). Ωστόσο, αυτά τα μοντέλα μπορεί να μην είναι κατάλληλα για πολύπλοκα μη γραμμικά συστήματα.
- Νευρωνικά δίκτυα: Τα νευρωνικά δίκτυα είναι μια δημοφιλής επιλογή για προγνωστική συντήρηση, επειδή μπορούν να μάθουν πολύπλοκα μοτίβα από δεδομένα. Το πολυστρωματικό perceptron (MLP), το συνεκτικό νευρωνικό δίκτυο (CNN) και η μακροπρόθεσμη βραχυπρόθεσμη μνήμη (LSTM) είναι μερικές από τις κοινώς χρησιμοποιούμενες αρχιτεκτονικές νευρωνικών δικτύων (Bai et al., 2020). Ωστόσο, τα νευρωνικά δίκτυα μπορεί να είναι υπολογιστικά ακριβά και μπορεί να απαιτούν σημαντικούς υπολογιστικούς πόρους.

- Δέντρα απόφασης: Τα δέντρα αποφάσεων είναι μια άλλη τεχνική που χρησιμοποιείται συνήθως για την προγνωστική συντήρηση. Μπορούν να χρησιμοποιηθούν για τον εντοπισμό των πιο σημαντικών χαρακτηριστικών σε ένα σύνολο δεδομένων και για να κάνουν προβλέψεις με βάση αυτά τα χαρακτηριστικά. Το τυχαίο δάσος (RF) και το δέντρο απόφασης που ενισχύει την κλίση (GBDT) είναι μερικοί από τους κοινώς χρησιμοποιούμενους αλγόριθμους δέντρων αποφάσεων (Li et al., 2020). Ωστόσο, τα δέντρα αποφάσεων μπορεί να είναι επιρρεπή σε υπερβολική προσαρμογή και μπορεί να μην γενικεύονται καλά σε νέα δεδομένα.
- Υβριδικά μοντέλα: Τα υβριδικά μοντέλα συνδυάζουν πολλαπλές τεχνικές για τη βελτίωση της ακρίβειας των προβλέψεων. Για παράδειγμα, ορισμένοι ερευνητές έχουν προτείνει το συνδυασμό νευρωνικών δικτύων με δέντρα αποφάσεων για τη δημιουργία ενός υβριδικού μοντέλου που μπορεί να χειριστεί τόσο μη γραμμικές όσο και γραμμικές σχέσεις (Wang et al., 2021). Άλλοι ερευνητές έχουν προτείνει το συνδυασμό μοντέλων παλινδρόμησης με τεχνικές βαθιάς μάθησης για τη βελτίωση της ακρίβειας εκτίμησης RUL (Xu et al., 2020).

Γενικά, η επιλογή της τεχνικής ή του αλγορίθμου θα εξαρτηθεί από το συγκεκριμένο πρόβλημα και το συγκεκριμένο σύνολο δεδομένων. Δεν υπάρχει λύση που να ταιριάζει σε όλους και οι ερευνητές μπορεί να χρειαστεί να πειραματιστούν με διαφορετικές τεχνικές και αρχιτεκτονικές για να βρουν την καλύτερη προσέγγιση. Παρόλα αυτά, οι μελέτες που εξετάζονται σε αυτήν την ενότητα υποδηλώνουν ότι οι τεχνικές βαθιάς μάθησης, ιδιαίτερα το LSTM και το CNN, τείνουν να ξεπερνούν άλλες τεχνικές όσον αφορά την ακρίβεια (Bai et al., 2020; Wang et al., 2021). Ωστόσο, αυτές οι τεχνικές μπορεί να είναι

υπολογιστικά ακριβές και μπορεί να μην είναι κατάλληλες για όλες τις εφαρμογές.

3.4 Μελέτες περιπτώσεων και παραδείγματα επιτυχημένων υλοποιήσεων

Η μελέτη που διεξήχθη από τους Zhao et al. (2019) είχε ως στόχο να προβλέψει την αστοχία ρουλεμάν σε ανεμογεννήτριες χρησιμοποιώντας τεχνικές μηχανικής εκμάθησης. Τα ρουλεμάν αποτελούν βασικό συστατικό των ανεμογεννητριών και η αστοχία τους μπορεί να οδηγήσει σε δαπανηρούς χρόνους διακοπής λειτουργίας και επισκευές. Οι συγγραφείς χρησιμοποίησαν ένα σύνολο δεδομένων από σήματα δόνησης που συλλέχθηκαν από αισθητήρες στο κιβώτιο ταχυτήτων της ανεμογεννήτριας για να εκπαιδεύσουν και να δοκιμάσουν το μοντέλο τους.

Για την προεπεξεργασία των δεδομένων, οι συγγραφείς εφάρμοσαν μια τεχνική που ονομάζεται αποσύνθεση πακέτων κυματιδίων, η οποία επιτρέπει την εξαγωγή χαρακτηριστικών από τα σήματα δόνησης. Τα εξαγόμενα χαρακτηριστικά στη συνέχεια χρησιμοποιήθηκαν για την εκπαίδευση και τη δοκιμή διαφόρων μοντέλων μηχανικής μάθησης, συμπεριλαμβανομένων μοντέλων δέντρων αποφάσεων, τυχαίου δάσους και μηχανών υποστήριξης διανυσμάτων (SVM).

Οι συγγραφείς πέτυχαν ακρίβεια 98,8% στην πρόβλεψη αστοχίας ρουλεμάν χρησιμοποιώντας το μοντέλο SVM. Το μοντέλο SVM ήταν επίσης σε θέση να προσδιορίσει τα χαρακτηριστικά που ήταν πιο σημαντικά για την πρόβλεψη αστοχίας ρουλεμάν, τα οποία θα μπορούσαν να βοηθήσουν τις ομάδες συντήρησης να δώσουν προτεραιότητα στις προσπάθειές τους.

Συνολικά, αυτή η μελέτη καταδεικνύει τις δυνατότητες των τεχνικών μηχανικής εκμάθησης για την πρόβλεψη αστοχίας ρουλεμάν σε ανεμογεννήτριες χρησιμοποιώντας σήματα δόνησης. Προβλέποντας την αστοχία πριν αυτή συμβεί, οι ομάδες συντήρησης μπορούν να λάβουν προληπτικά μέτρα για την πρόληψη του χρόνου διακοπής λειτουργίας και τη μείωση του κόστους συντήρησης.

Η μελέτη που διεξήχθη από τους Wang et al. (2021) είχε ως στόχο να προβλέψει τις αστοχίες εξοπλισμού σε μια χημική μονάδα χρησιμοποιώντας τεχνικές βαθιάς μάθησης. Οι συγγραφείς χρησιμοποίησαν ένα σύνολο δεδομένων αναγνώσεων αισθητήρων που συλλέχθηκαν από διάφορους εξοπλισμούς στο εργοστάσιο, συμπεριλαμβανομένων αντλιών, βαλβίδων και εναλλάκτη θερμότητας, για να εκπαιδεύσουν και να δοκιμάσουν το μοντέλο τους.

Για την προεπεξεργασία των δεδομένων, οι συγγραφείς εφάρμοσαν μια τεχνική που ονομάζεται ανάλυση κύριου συστατικού (PCA), η οποία μειώνει τη διάσταση των δεδομένων διατηρώντας παράλληλα τα πιο σημαντικά χαρακτηριστικά. Το μειωμένο σύνολο δεδομένων χρησιμοποιήθηκε στη συνέχεια για την εκπαίδευση και τη δοκιμή ενός μοντέλου βαθιάς νευρωνικού δικτύου (DNN).

Οι συγγραφείς πέτυχαν ακρίβεια 92% στην πρόβλεψη αστοχιών εξοπλισμού χρησιμοποιώντας το μοντέλο DNN. Συνέκριναν επίσης την απόδοση του μοντέλου DNN με άλλα μοντέλα μηχανικής μάθησης, συμπεριλαμβανομένων των μοντέλων δέντρου αποφάσεων, τυχαίου δάσους και SVM, και διαπίστωσαν ότι το μοντέλο DNN τα ξεπέρασε ως προς την ακρίβεια.

Οι συγγραφείς διεξήγαγαν επίσης μια ανάλυση ευαισθησίας για να εντοπίσουν τους πιο σημαντικούς αισθητήρες για την πρόβλεψη αστοχιών εξοπλισμού. Βρήκαν ότι οι αισθητήρες θερμοκρασίας και πίεσης ήταν οι πιο σημαντικοί για την πρόβλεψη αστοχιών της αντλίας, ενώ οι αισθητήρες ταχύτητας ροής ήταν οι πιο σημαντικοί για την πρόβλεψη αστοχιών της βαλβίδας.

Συνολικά, αυτή η μελέτη καταδεικνύει τις δυνατότητες των τεχνικών βαθιάς εκμάθησης για την πρόβλεψη αστοχιών εξοπλισμού σε μια χημική μονάδα χρησιμοποιώντας δεδομένα αισθητήρων. Με την πρόβλεψη των αστοχιών πριν συμβούν, οι ομάδες συντήρησης μπορούν να λάβουν προληπτικά μέτρα για να αποτρέψουν τη διακοπή λειτουργίας και να μειώσουν το κόστος συντήρησης.

Τα δέντρα αποφάσεων είναι μια δημοφιλής μέθοδος για προγνωστική συντήρηση λόγω της ικανότητάς τους να αναγνωρίζουν τα πιο σημαντικά χαρακτηριστικά σε ένα σύνολο δεδομένων και να κάνουν προβλέψεις με βάση αυτά τα χαρακτηριστικά. Λειτουργούν με την αναδρομική κατάτμηση των δεδομένων σε μικρότερα υποσύνολα με βάση τις τιμές ορισμένων χαρακτηριστικών μέχρι να μπορέσει να γίνει μια πρόβλεψη. Η προκύπτουσα δομή δέντρου μπορεί να χρησιμοποιηθεί για την πρόβλεψη του αποτελέσματος των νέων δεδομένων.

Το τυχαίο δάσος (RF) και το δέντρο απόφασης που ενισχύει την κλίση (GBDT) είναι δύο από τους κοινώς χρησιμοποιούμενους αλγόριθμους δέντρων αποφάσεων στην προγνωστική συντήρηση. Η RF δημιουργεί πολλαπλά δέντρα αποφάσεων και συνδυάζει τις προβλέψεις τους για να βελτιώσει την ακρίβεια και να μειώσει την υπερπροσαρμογή. Το GBDT, από την άλλη πλευρά, δημιουργεί επαναληπτικά δέντρα αποφάσεων και χρησιμοποιεί τα σφάλματα

των προηγούμενων δέντρων για να καθοδηγήσει την κατασκευή των επόμενων δέντρων.

Παρά τα πλεονεκτήματά τους, τα δέντρα αποφάσεων μπορεί να είναι επιρρεπή σε υπερβολική προσαρμογή και μπορεί να μην γενικεύονται καλά σε νέα δεδομένα. Η υπερπροσαρμογή συμβαίνει όταν το δέντρο είναι πολύ περίπλοκο και καταγράφει θόρυβο στα δεδομένα αντί για τα υποκείμενα μοτίβα. Για να αποφευχθεί η υπερβολική προσαρμογή, μπορούν να χρησιμοποιηθούν τεχνικές όπως το κλάδεμα ή ο καθορισμός ορίων στο βάθος του δέντρου ή στο ελάχιστο μέγεθος δείγματος.

Συνολικά, τα δέντρα απόφασης είναι μια χρήσιμη τεχνική στην προγνωστική συντήρηση, αλλά η αποτελεσματικότητά τους εξαρτάται από το συγκεκριμένο σύνολο δεδομένων και το συγκεκριμένο πρόβλημα. Είναι σημαντικό να ρυθμίσετε προσεκτικά τις παραμέτρους του αλγορίθμου του δέντρου αποφάσεων και να αξιολογήσετε την απόδοσή του στα δεδομένα επικύρωσης για να διασφαλίσετε καλή γενίκευση σε νέα δεδομένα.

Η προγνωστική συντήρηση γίνεται όλο και πιο σημαντική στην αεροδιαστημική βιομηχανία λόγω του υψηλού κόστους και των κινδύνων που συνδέονται με τις αστοχίες του εξοπλισμού. Τα τελευταία χρόνια, οι τεχνικές βαθιάς μάθησης έχουν δείξει πολλά υποσχόμενα αποτελέσματα στην πρόβλεψη αστοχιών εξοπλισμού σε εφαρμογές αεροδιαστημικής.

Η μελέτη των Xu et al. (2020) στόχευε στην πρόβλεψη αστοχιών εξοπλισμού στην αεροδιαστημική βιομηχανία χρησιμοποιώντας τεχνικές βαθιάς μάθησης. Οι συγγραφείς χρησιμοποίησαν ένα σύνολο δεδομένων πτήσης, συμπεριλαμβανομένων παραμέτρων όπως η θερμοκρασία του κινητήρα, η πίεση

και η κατανάλωση καυσίμου, για να εκπαιδεύσουν ένα μοντέλο βαθιάς νευρωνικού δικτύου. Το μοντέλο μπόρεσε να μάθει τις πολύπλοκες σχέσεις μεταξύ των δεδομένων εισόδου και των αστοχιών εξοπλισμού και πέτυχε ακρίβεια 98% στην πρόβλεψη αστοχιών εξοπλισμού.

Η χρήση της βαθιάς μάθησης σε αυτή τη μελέτη επέτρεψε τον εντοπισμό λεπτών προτύπων και σχέσεων στα δεδομένα που θα ήταν δύσκολο να εντοπιστούν χρησιμοποιώντας παραδοσιακές τεχνικές μηχανικής μάθησης. Οι συγγραφείς σημείωσαν ότι η ακρίβεια του μοντέλου τους θα μπορούσε να βελτιωθεί περαιτέρω με την ενσωμάτωση πρόσθετων πηγών δεδομένων και τη βελτιστοποίηση της αρχιτεκτονικής και των παραμέτρων του μοντέλου.

Συνολικά, η μελέτη των Xu et al. (2020) καταδεικνύει τις δυνατότητες των τεχνικών βαθιάς εκμάθησης στην προγνωστική συντήρηση στην αεροδιαστημική βιομηχανία. Με την ακριβή πρόβλεψη των αστοχιών του εξοπλισμού, η συντήρηση μπορεί να προγραμματιστεί εκ των προτέρων, μειώνοντας τον χρόνο διακοπής λειτουργίας και το κόστος που σχετίζεται με την απρογραμμάτιστη συντήρηση.

Οι σταθμοί ηλεκτροπαραγωγής είναι πολύπλοκα συστήματα που απαιτούν αξιόπιστο και αποτελεσματικό εξοπλισμό για να διασφαλιστεί η συνεχής λειτουργία. Η προγνωστική συντήρηση με τη χρήση τεχνικών μηχανικής εκμάθησης έχει δείξει πολλά υποσχόμενα αποτελέσματα στην πρόβλεψη αστοχιών εξοπλισμού σε σταθμούς ηλεκτροπαραγωγής.

Η μελέτη των Xue et al. (2018) είχε ως στόχο να προβλέψει την αστοχία του εξοπλισμού σε μια μονάδα ηλεκτροπαραγωγής χρησιμοποιώντας τεχνικές μηχανικής μάθησης. Οι συγγραφείς χρησιμοποίησαν ένα σύνολο δεδομένων

αναγνώσεων αισθητήρων, συμπεριλαμβανομένων δεδομένων θερμοκρασίας, πίεσης και δόνησης, για να εκπαιδεύσουν ένα μοντέλο μηχανικής μάθησης. Το μοντέλο μπόρεσε να μάθει τα πρότυπα και τις σχέσεις μεταξύ των δεδομένων εισόδου και των αστοχιών εξοπλισμού και πέτυχε ακρίβεια 93,5% στην πρόβλεψη αστοχίας εξοπλισμού.

Οι συγγραφείς χρησιμοποίησαν έναν συνδυασμό τεχνικών επιλογής χαρακτηριστικών, προεπεξεργασίας δεδομένων και επιλογής μοντέλου για να βελτιστοποιήσουν την απόδοση του μοντέλου τους. Ο επιλεγμένος αλγόριθμος μηχανικής μάθησης ήταν μια μηχανή διανυσμάτων υποστήριξης (SVM), ένας δημοφιλής και ευρέως χρησιμοποιούμενος αλγόριθμος για εφαρμογές πρόβλεψης συντήρησης.

Η μελέτη των Xue et al. (2018) καταδεικνύει τις δυνατότητες των τεχνικών μηχανικής εκμάθησης σε εφαρμογές πρόβλεψης συντήρησης στη βιομηχανία σταθμών παραγωγής ενέργειας. Με την ακριβή πρόβλεψη των αστοχιών του εξοπλισμού, η συντήρηση μπορεί να προγραμματιστεί εκ των προτέρων, μειώνοντας τον χρόνο διακοπής λειτουργίας και το κόστος που σχετίζεται με την απρογραμμάτιστη συντήρηση. Οι συγγραφείς σημείωσαν ότι η απόδοση του μοντέλου τους θα μπορούσε να βελτιωθεί περαιτέρω με την ενσωμάτωση πρόσθετων πηγών δεδομένων και τη βελτιστοποίηση των παραμέτρων του μοντέλου.

Η βιομηχανία πετρελαίου και φυσικού αερίου περιλαμβάνει τη χρήση ενός ευρέος φάσματος εξοπλισμού που είναι κρίσιμος για την αποτελεσματική λειτουργία. Η αστοχία του εξοπλισμού μπορεί να οδηγήσει σε σημαντικές διακοπές λειτουργίας, απώλειες παραγωγής και κινδύνους ασφάλειας. Επομένως,

η προγνωστική συντήρηση είναι μια κρίσιμη πτυχή αυτού του κλάδου. Σε μια μελέτη που διεξήχθη από τους Zhang et al. (2019), χρησιμοποιήθηκαν τεχνικές βαθιάς μάθησης για την πρόβλεψη αστοχίας εξοπλισμού στη βιομηχανία πετρελαίου και φυσικού αερίου.

Οι συγγραφείς χρησιμοποίησαν ένα σύνολο δεδομένων με αναγνώσεις αισθητήρων από εξοπλισμό σε μια τοποθεσία παραγωγής πετρελαίου και φυσικού αερίου. Τα δεδομένα περιελάμβαναν πληροφορίες σχετικά με τη θερμοκρασία, την πίεση, τους κραδασμούς και άλλες παραμέτρους. Ένα μοντέλο βαθιάς μάθησης εκπαιδεύτηκε χρησιμοποιώντας αυτό το σύνολο δεδομένων για την πρόβλεψη αστοχίας εξοπλισμού. Το μοντέλο χρησιμοποίησε έναν συνδυασμό συνελκτικών νευρωνικών δικτύων (CNN) και δικτύων βραχυπρόθεσμης μνήμης (LSTM).

Τα αποτελέσματα της μελέτης έδειξαν ότι το μοντέλο βαθιάς μάθησης πέτυχε ακρίβεια 96,7% στην πρόβλεψη αστοχίας εξοπλισμού. Το μοντέλο ήταν επίσης σε θέση να προσδιορίσει τον πιο κρίσιμο εξοπλισμό που απαιτούσε συντήρηση. Οι συγγραφείς κατέληξαν στο συμπέρασμα ότι οι τεχνικές βαθιάς μάθησης μπορούν να είναι ένα αποτελεσματικό εργαλείο για την προγνωστική συντήρηση στη βιομηχανία πετρελαίου και φυσικού αερίου και μπορούν να βοηθήσουν στη βελτίωση της αξιοπιστίας του εξοπλισμού και στη μείωση του κόστους συντήρησης.

Η μελέτη που διεξήχθη από τους Guo et al. (2019) είχε ως στόχο να αναπτύξει ένα μοντέλο προγνωστικής συντήρησης για ένα μύλο θερμής έλασης σε ένα εργοστάσιο χάλυβα χρησιμοποιώντας τεχνικές μηχανικής μάθησης. Οι συγγραφείς χρησιμοποίησαν ένα σύνολο δεδομένων με αναγνώσεις αισθητήρων

από το μύλο και ανέπτυξαν ένα μοντέλο πρόβλεψης συντήρησης που βασίζεται στον αλγόριθμο του μηχανήματος διανύσματος υποστήριξης (SVM). Το σύνολο δεδομένων περιλάμβανε πληροφορίες σχετικά με την ταχύτητα έλασης, τη θερμοκρασία και την πίεση του μύλου, μεταξύ άλλων παραμέτρων. Οι συγγραφείς συνέλεξαν επίσης δεδομένα σχετικά με τα αρχεία συντήρησης για να αναλύσουν τη σχέση μεταξύ αστοχίας εξοπλισμού και δεδομένων αισθητήρα.

Τα αποτελέσματα έδειξαν ότι το μοντέλο που βασίζεται σε SVM πέτυχε ακρίβεια 93,3% στην πρόβλεψη αστοχίας εξοπλισμού. Οι συγγραφείς σημείωσαν ότι το μοντέλο πρόβλεψης βοήθησε στον εντοπισμό των πιο κρίσιμων αστοχιών εξοπλισμού και παρείχε μια αποτελεσματική προσέγγιση για τη βελτίωση του προγραμματισμού συντήρησης και τη μείωση του χρόνου διακοπής λειτουργίας. Επιπλέον, οι συγγραφείς τόνισαν τη σημασία της εξέτασης τόσο των δεδομένων αισθητήρων όσο και των αρχείων συντήρησης σε μοντέλα πρόβλεψης συντήρησης για τη βελτίωση της ακρίβειας και της αποτελεσματικότητάς τους.

Στη μελέτη που διεξήχθη από τους Liu et al. (2021), χρησιμοποιήθηκαν τεχνικές βαθιάς μάθησης για την πρόβλεψη της αστοχίας των μηχανών CNC. Οι συγγραφείς συνέλεξαν ένα σύνολο δεδομένων με αναγνώσεις αισθητήρων από τις μηχανές CNC, το οποίο περιελάμβανε πληροφορίες για το ρεύμα του κινητήρα του άξονα, το ρεύμα του σερβοκινητήρα και τη θερμοκρασία του ψυκτικού. Στη συνέχεια, οι συγγραφείς εκπαιδύσαν ένα μοντέλο βαθιάς μάθησης χρησιμοποιώντας αυτό το σύνολο δεδομένων και πέτυχαν ακρίβεια 98,5% στην πρόβλεψη αστοχίας μηχανής.

Το μοντέλο βαθιάς μάθησης που χρησιμοποιήθηκε στη μελέτη ήταν ένα συνελκτικό νευρωνικό δίκτυο (CNN), το οποίο χρησιμοποιείται συνήθως σε εργασίες αναγνώρισης εικόνων, αλλά έχει επίσης εφαρμοστεί σε δεδομένα χρονοσειρών. Το CNN σχεδιάστηκε για να εξάγει χαρακτηριστικά από τις μετρήσεις του αισθητήρα και να ταξινομεί την κατάσταση του μηχανήματος ως κανονική ή ελαττωματική. Οι συγγραφείς χρησιμοποίησαν επίσης μια τεχνική που ονομάζεται μάθηση μεταφοράς για να τελειοποιήσουν ένα προεκπαιδευμένο μοντέλο CNN για τη συγκεκριμένη εργασία τους.

Τα αποτελέσματα αυτής της μελέτης υποδηλώνουν ότι οι τεχνικές βαθιάς μάθησης μπορούν να είναι αποτελεσματικές στην πρόβλεψη της αστοχίας των μηχανών CNC. Αυτό έχει σημαντικές επιπτώσεις για τη μεταποιητική βιομηχανία, καθώς μπορεί να βοηθήσει στη μείωση του χρόνου διακοπής λειτουργίας και του κόστους συντήρησης.

Οι μεταφορικοί ιμάντες χρησιμοποιούνται συνήθως στις μεταποιητικές βιομηχανίες για τη μεταφορά αγαθών και προϊόντων. Η αποτυχία τους μπορεί να οδηγήσει σε δαπανηρές διακοπές και απώλειες παραγωγής. Σε αυτή τη μελέτη, οι συγγραφείς χρησιμοποίησαν τεχνικές μηχανικής εκμάθησης για να προβλέψουν την αστοχία των μεταφορικών ταινιών σε μια γραμμή παραγωγής. Συνέλεξαν ένα σύνολο δεδομένων αναγνώσεων αισθητήρων, συμπεριλαμβανομένων της θερμοκρασίας, των κραδασμών και της επιτάχυνσης, και χρησιμοποίησαν τα δεδομένα για να εκπαιδεύσουν ένα μοντέλο μηχανικής μάθησης.

Οι συγγραφείς χρησιμοποίησαν μια εποπτευόμενη προσέγγιση μάθησης και συνέκριναν διαφορετικούς αλγόριθμους, συμπεριλαμβανομένων των δέντρων

αποφάσεων, των τυχαίων δασών και των μηχανών διανυσμάτων υποστήριξης (SVM). Διαπίστωσαν ότι το SVM ξεπέρασε άλλους αλγόριθμους όσον αφορά την ακρίβεια και την αποτελεσματικότητα. Το εκπαιδευμένο μοντέλο χρησιμοποιήθηκε στη συνέχεια για να προβλέψει την αστοχία των μεταφορικών ταινιών σε πραγματικό χρόνο.

Η μελέτη πέτυχε ακρίβεια 91,2% στην πρόβλεψη της αστοχίας των μεταφορικών ταινιών, η οποία μπορεί να βοηθήσει τις ομάδες συντήρησης να λάβουν προληπτικά μέτρα πριν συμβεί η αστοχία. Τα αποτελέσματα αυτής της μελέτης μπορούν να είναι χρήσιμα σε διάφορες βιομηχανίες, συμπεριλαμβανομένης της μεταποίησης και της εφοδιαστικής, όπου οι μεταφορικοί μάντες χρησιμοποιούνται εκτενώς.

3.5 Εταιρείες που κάνουν χρήση ML και DL

3.5.1 General Electric (GE)

Το τμήμα Power της GE χρησιμοποίησε μηχανική εκμάθηση για να προβλέψει τις αστοχίες εξοπλισμού σε αεριοστρόβιλους. Αναλύοντας τα δεδομένα του αισθητήρα, το σύστημα ήταν σε θέση να ανιχνεύσει πιθανές βλάβες του εξοπλισμού πριν αυτές εμφανιστούν, επιτρέποντας τη συντήρηση να εκτελείται προληπτικά και όχι αντιδραστικά. Αυτό είχε ως αποτέλεσμα τη μείωση του χρόνου διακοπής λειτουργίας και την αύξηση της αξιοπιστίας του εξοπλισμού (GE, n.d.).

Επιπλέον, η GE Aviation εφάρμοσε προγνωστική συντήρηση χρησιμοποιώντας μηχανική εκμάθηση για κινητήρες αεροσκαφών. Αναλύοντας δεδομένα αισθητήρων από κινητήρες αεροσκαφών κατά την πτήση, το σύστημα μπορεί

να προβλέψει πότε τα εξαρτήματα είναι πιθανό να αποτύχουν, επιτρέποντας τον προληπτικό προγραμματισμό της συντήρησης. Αυτό είχε ως αποτέλεσμα σημαντική εξοικονόμηση κόστους για τις αεροπορικές εταιρείες, καθώς και αυξημένη ασφάλεια για τους επιβάτες (GE Aviation, n.d.).

3.5.2 Siemens

Η Siemens είναι μια παγκόσμια εταιρεία τεχνολογίας που χρησιμοποιεί τεχνικές μηχανικής μάθησης (ML) και βαθιάς μάθησης (DL) για τη βελτίωση της προγνωστικής συντήρησης στα προϊόντα και τις υπηρεσίες της. Ένα παράδειγμα αυτού είναι η χρήση του ML για την παρακολούθηση και την πρόβλεψη αστοχιών σε ανεμογεννήτριες. Αναλύοντας μεγάλες ποσότητες δεδομένων αισθητήρων που συλλέγονται από τους στρόβιλους, η Siemens είναι σε θέση να εντοπίσει μοτίβα και ανωμαλίες που μπορεί να υποδηλώνουν επικείμενη αστοχία. Αυτό τους επιτρέπει να προγραμματίζουν τη συντήρηση και τις επισκευές προληπτικά, αντί να αντιδρούν, ελαχιστοποιώντας το χρόνο διακοπής λειτουργίας και μεγιστοποιώντας την απόδοση.

Η Siemens χρησιμοποιεί επίσης DL για προγνωστική συντήρηση στους αεριοστρόβιλους της. Αναλύοντας δεδομένα από ένα ευρύ φάσμα αισθητήρων που είναι εγκατεστημένοι στους στρόβιλους, οι αλγόριθμοι DL είναι σε θέση να προσδιορίζουν μοτίβα που μπορεί να υποδεικνύουν πιθανά προβλήματα, όπως ασυνήθιστους κραδασμούς ή θερμοκρασίες. Αυτές οι πληροφορίες επιτρέπουν στη Siemens να προβλέψει πότε απαιτείται συντήρηση, μειώνοντας την πιθανότητα απροσδόκητου χρόνου διακοπής λειτουργίας και διασφαλίζοντας ότι οι τουρμπίνες λειτουργούν με μέγιστη απόδοση.

Εκτός από τις ανεμογεννήτριες και τους αεριοστρόβιλους, η Siemens χρησιμοποιεί ML και DL σε πολλά άλλα προϊόντα και υπηρεσίες, συμπεριλαμβανομένων των σιδηροδρομικών συστημάτων, του βιομηχανικού αυτοματισμού και των τεχνολογιών κτιρίων. Για παράδειγμα, χρησιμοποιούν ML για τη βελτιστοποίηση της απόδοσης των συστημάτων θέρμανσης, εξαερισμού και κλιματισμού (HVAC) στα κτίρια. Αναλύοντας δεδομένα σχετικά με την πληρότητα, τον καιρό και άλλους παράγοντες, οι αλγόριθμοι ML μπορούν να προσαρμόσουν τις ρυθμίσεις θερμοκρασίας και αερισμού για να εξασφαλίσουν βέλτιστη άνεση, ελαχιστοποιώντας την κατανάλωση ενέργειας.

Η Siemens έχει αναφέρει σημαντικά οφέλη από τη χρήση των ML και DL για προγνωστική συντήρηση. Σε μια μελέτη περίπτωσης, ανέφεραν μείωση 10% στο κόστος συντήρησης και 20% μείωση στον απρογραμματίστο χρόνο διακοπής λειτουργίας για τις ανεμογεννήτριες. Για τους αεριοστρόβιλους, ανέφεραν 1% βελτίωση στην απόδοση και 5% μείωση στο κόστος συντήρησης. Αυτά τα αποτελέσματα καταδεικνύουν την αποτελεσματικότητα των ML και DL στη βελτίωση της προγνωστικής συντήρησης και στη μείωση του κόστους σε βιομηχανικές εφαρμογές.

3.5.3 Bosch

Η Bosch είναι μια άλλη εταιρεία που εφαρμόζει τεχνικές μηχανικής μάθησης και βαθιάς εκμάθησης για προγνωστική συντήρηση. Έχουν αναπτύξει ένα σύστημα που ονομάζεται σύστημα Predictive Maintenance and Remote Diagnosis (PMRD), το οποίο χρησιμοποιείται για την πρόβλεψη αστοχιών εξοπλισμού στις μονάδες παραγωγής τους (Zhang et al., 2020).

Το σύστημα PMRD χρησιμοποιεί αλγόριθμους μηχανικής μάθησης για την ανάλυση δεδομένων αισθητήρων από μηχανές σε πραγματικό χρόνο και την ανίχνευση ανωμαλιών που μπορεί να υποδηλώνουν επικείμενες βλάβες. Το σύστημα χρησιμοποιεί επίσης τεχνικές βαθιάς εκμάθησης για εξαγωγή και επιλογή χαρακτηριστικών για τον εντοπισμό των πιο σημαντικών χαρακτηριστικών για την πρόβλεψη αστοχιών εξοπλισμού.

Η Bosch έχει αναφέρει σημαντικές βελτιώσεις στον χρόνο λειτουργίας του εξοπλισμού και μείωση του κόστους συντήρησης από την εφαρμογή του συστήματος PMRD. Για παράδειγμα, έχουν αναφέρει μείωση 70% στο χρόνο διακοπής λειτουργίας του μηχανήματος, αύξηση 10% στη συνολική αποτελεσματικότητα του εξοπλισμού και μείωση 30% στο κόστος συντήρησης (Bosch, n.d.).

Επιπλέον, η Bosch μοιράστηκε ορισμένες περιπτώσιολογικές μελέτες σχετικά με την επιτυχή εφαρμογή του συστήματος PMRD. Μια τέτοια μελέτη περίπτωσης αφορούσε μια γραμμή παραγωγής για μπεκ ψεκασμού καυσίμου, όπου το σύστημα PMRD ήταν σε θέση να ανιχνεύσει και να διαγνώσει μια αστοχία σε ένα μηχάνημα προτού προκληθεί διακοπή λειτουργίας, εξοικονομώντας στην εταιρεία περίπου 200.000 ευρώ σε απώλειες παραγωγής (Bosch, n.d.).

Συνολικά, η χρήση τεχνικών μηχανικής μάθησης και βαθιάς εκμάθησης στο σύστημα PMRD της Bosch έχει επιδείξει σημαντικές βελτιώσεις στον χρόνο λειτουργίας του εξοπλισμού και τη μείωση του κόστους συντήρησης, καθιστώντας το μια πολλά υποσχόμενη λύση για προγνωστική συντήρηση στον κατασκευαστικό κλάδο.

3.5.4 Schneider Electric

Η Schneider Electric είναι παγκόσμιος ηγέτης στον ψηφιακό μετασχηματισμό και τη διαχείριση ενέργειας, προσφέροντας ένα ευρύ φάσμα προϊόντων και υπηρεσιών για διάφορους κλάδους. Χρησιμοποιούν τεχνικές μηχανικής μάθησης και βαθιάς μάθησης για προγνωστική συντήρηση στον δικό τους εξοπλισμό, καθώς και για την παροχή λύσεων στους πελάτες τους.

Ένα παράδειγμα χρήσης των ML και DL για προγνωστική συντήρηση είναι το EcoStruxure Machine Advisor, μια πλατφόρμα που βασίζεται σε σύννεφο που επιτρέπει την απομακρυσμένη παρακολούθηση και την προγνωστική συντήρηση του βιομηχανικού εξοπλισμού. Η πλατφόρμα χρησιμοποιεί αλγόριθμους μηχανικής μάθησης για να αναλύει δεδομένα από αισθητήρες και να παρέχει έγκαιρες προειδοποιήσεις για πιθανές βλάβες του εξοπλισμού, επιτρέποντας την προληπτική συντήρηση πριν χαλάσει ο εξοπλισμός.

Σύμφωνα με μια μελέτη περίπτωσης της Schneider Electric, ένας κατασκευαστής εξοπλισμού συσκευασίας εφάρμοσε τη λύση EcoStruxure Machine Advisor και πέτυχε 40% μείωση του χρόνου διακοπής λειτουργίας και 15% αύξηση στην παραγωγικότητα (Schneider Electric, n.d.).

Ένα άλλο παράδειγμα είναι η χρήση της βαθιάς εκμάθησης για προγνωστική συντήρηση στον ηλεκτρικό εξοπλισμό διανομής της Schneider Electric. Η εταιρεία ανέπτυξε έναν αλγόριθμο βαθιάς μάθησης για την ανάλυση δεδομένων από αισθητήρες που είναι εγκατεστημένοι στον εξοπλισμό και την πρόβλεψη της πιθανότητας βλάβης του εξοπλισμού. Σύμφωνα με μια μελέτη περίπτωσης της Schneider Electric, αυτή η λύση πέτυχε ποσοστό ακρίβειας 99% στην πρόβλεψη αστοχιών εξοπλισμού (Schneider Electric, n.d.).

Αυτά τα παραδείγματα καταδεικνύουν τα πιθανά οφέλη από τη χρήση μηχανικής μάθησης και βαθιάς μάθησης για προγνωστική συντήρηση σε διάφορους κλάδους, συμπεριλαμβανομένης της βελτιωμένης αξιοπιστίας του εξοπλισμού, του μειωμένου χρόνου διακοπής λειτουργίας και της αυξημένης παραγωγικότητας.

3.5.5 SKF

Η SKF είναι κορυφαίος προμηθευτής ρουλεμάν, στεγανοποιήσεων και συστημάτων λίπανσης. Έχουν επίσης εφαρμόσει τεχνικές ML και DL για την προγνωστική συντήρηση του εξοπλισμού τους.

Ένα παράδειγμα χρήσης του ML είναι η υπηρεσία Rotating Equipment Performance (REP), η οποία χρησιμοποιεί δεδομένα δόνησης για να προβλέψει την υπολειπόμενη ωφέλιμη ζωή των περιστρεφόμενων μηχανημάτων. Το σύστημα χρησιμοποιεί έναν αλγόριθμο ML για την ανάλυση των δεδομένων δόνησης και την παροχή έγκαιρων προειδοποιήσεων για πιθανές αστοχίες. Η SKF ισχυρίζεται ότι η υπηρεσία REP ήταν επιτυχής στην πρόβλεψη του 85-90% των βλαβών πριν αυτές συμβούν (SKF, n.d.).

Επιπλέον, η SKF έχει επίσης εφαρμόσει τεχνικές DL για προγνωστική συντήρηση στις διαδικασίες κατασκευής της. Χρησιμοποιούν έναν συνδυασμό αισθητήρων και αλγορίθμων DL για να παρακολουθούν τη διαδικασία παραγωγής και να ανιχνεύουν ανωμαλίες που θα μπορούσαν να υποδεικνύουν πιθανές βλάβες του εξοπλισμού. Εντοπίζοντας έγκαιρα αυτά τα ζητήματα, η SKF μπορεί να αποφύγει δαπανηρές διακοπές λειτουργίας και να μειώσει το κόστος συντήρησης (SKF, n.d.).

Συνολικά, η χρήση ML και DL από την SKF για προγνωστική συντήρηση είχε ως αποτέλεσμα βελτιωμένη αξιοπιστία του εξοπλισμού και μειωμένο κόστος συντήρησης. Ωστόσο, πιο λεπτομερή δεδομένα σχετικά με την αποτελεσματικότητα των συγκεκριμένων τεχνικών τους δεν είναι δημόσια διαθέσιμα.

3.5.6 IBM

Η IBM βρίσκεται στην πρώτη γραμμή της έρευνας και της ανάπτυξης στον τομέα της προγνωστικής συντήρησης με χρήση μηχανικής μάθησης και βαθιάς μάθησης. Έχουν αναπτύξει μια σειρά λύσεων για προγνωστική συντήρηση, όπως το IBM Maximo Asset Monitor και το IBM Predictive Maintenance and Quality.

Το IBM Maximo Asset Monitor χρησιμοποιεί AI και ML για να αναλύει δεδομένα σε πραγματικό χρόνο από αισθητήρες και άλλες πηγές για να προβλέψει τις αστοχίες του εξοπλισμού και τις ανάγκες συντήρησης. Μπορεί να βοηθήσει τις επιχειρήσεις να μειώσουν το χρόνο διακοπής λειτουργίας, να βελτιώσουν την αξιοπιστία του εξοπλισμού και να βελτιστοποιήσουν τα χρονοδιαγράμματα συντήρησης. Η IBM ισχυρίζεται ότι το Maximo Asset Monitor μπορεί να μειώσει το κόστος συντήρησης έως και 10% και να αυξήσει το χρόνο λειτουργίας του εξοπλισμού έως και 20%.

Η IBM Predictive Maintenance and Quality είναι μια λύση που αξιοποιεί την ML και τη βαθιά μάθηση για την πρόβλεψη και την πρόληψη αστοχιών εξοπλισμού σε εργοστάσια παραγωγής. Χρησιμοποιεί δεδομένα αισθητήρων και άλλες πηγές πληροφοριών για να εντοπίσει πιθανά προβλήματα πριν προκύψουν και να ειδοποιήσει τις ομάδες συντήρησης για να λάβουν

προληπτικά μέτρα. Η IBM ισχυρίζεται ότι η Προγνωστική Συντήρηση και Ποιότητα μπορούν να μειώσουν το κόστος συντήρησης έως και 30%, να αυξήσουν το χρόνο λειτουργίας του εξοπλισμού έως και 25% και να βελτιώσουν την ποιότητα των προϊόντων έως και 35%.

Η IBM έχει επίσης πραγματοποιήσει αρκετές μελέτες και δημοσιεύει ερευνητικές εργασίες σχετικά με τη χρήση των ML και DL στην προγνωστική συντήρηση. Για παράδειγμα, σε μια μελέτη που δημοσιεύτηκε στο Journal of Quality in Maintenance Engineering, οι ερευνητές της IBM χρησιμοποίησαν τεχνικές DL για να προβλέψουν τις αστοχίες εξοπλισμού σε μια μονάδα παραγωγής ημιαγωγών. Η μελέτη πέτυχε ποσοστό ακρίβειας 94,7% στην πρόβλεψη αστοχιών εξοπλισμού.

Σε μια άλλη μελέτη που δημοσιεύτηκε στο Journal of Manufacturing Systems, οι ερευνητές της IBM χρησιμοποίησαν έναν συνδυασμό μοντέλων ML και φυσικής για να προβλέψουν την υπολειπόμενη ωφέλιμη ζωή των εργαλείων κοπής που χρησιμοποιούνται στην κατασκευή. Η μελέτη πέτυχε ακρίβεια πρόβλεψης άνω του 90% για την υπολειπόμενη ωφέλιμη ζωή των κοπτικών εργαλείων.

Συνολικά, η IBM έχει αναπτύξει μια σειρά λύσεων και έχει διεξαγάγει εκτενή έρευνα στον τομέα της προγνωστικής συντήρησης χρησιμοποιώντας ML και DL, με πολλά υποσχόμενα αποτελέσματα.

3.5.7 Microsoft

Η Microsoft εργάζεται επίσης ενεργά για τη χρήση μηχανικής μάθησης και βαθιάς μάθησης για προγνωστική συντήρηση. Ένα παράδειγμα είναι η συνεργασία τους με την Thyssenkrupp Elevator για την ανάπτυξη μιας προγνωστικής λύσης συντήρησης για ανελκυστήρες που χρησιμοποιούν το Azure Machine Learning. Η λύση χρησιμοποιεί αισθητήρες IoT και αλγόριθμους μηχανικής μάθησης για την ανάλυση δεδομένων από ανελκυστήρες σε πραγματικό χρόνο και την πρόβλεψη πιθανών προβλημάτων προτού προκύψουν, μειώνοντας το χρόνο διακοπής λειτουργίας και το κόστος συντήρησης (Microsoft, 2017).

Επιπλέον, η Microsoft έχει αναπτύξει το Azure IoT Suite, μια συλλογή υπηρεσιών για συσκευές IoT που περιλαμβάνει δυνατότητες πρόβλεψης συντήρησης χρησιμοποιώντας αλγόριθμους μηχανικής εκμάθησης. Η λύση δίνει τη δυνατότητα στις επιχειρήσεις να παρακολουθούν και να αναλύουν δεδομένα από τον εξοπλισμό τους σε πραγματικό χρόνο, να εντοπίζουν μοτίβα και ανωμαλίες και να προβλέπουν πιθανά ζητήματα πριν προκύψουν (Microsoft, 2021).

Μια μελέτη περίπτωσης που διεξήχθη από τη Microsoft και την Hitachi Solutions Europe κατέδειξε επίσης την αποτελεσματικότητα της χρήσης μηχανικής μάθησης για προγνωστική συντήρηση στην κατασκευή. Η μελέτη ανέλυσε δεδομένα από μια γραμμή παραγωγής μιας κατασκευαστικής εταιρείας και χρησιμοποίησε αλγόριθμους μηχανικής μάθησης για να προβλέψει τις αστοχίες του εξοπλισμού. Η λύση πέτυχε ποσοστό ακρίβειας 97% στην πρόβλεψη αστοχιών εξοπλισμού, με αποτέλεσμα τη μείωση του χρόνου

διακοπής λειτουργίας και του κόστους συντήρησης για την εταιρεία (Microsoft, 2020).

Συνολικά, η χρήση της μηχανικής εκμάθησης και της βαθιάς εκμάθησης από τη Microsoft για προγνωστική συντήρηση έχει δείξει πολλά υποσχόμενα αποτελέσματα, με τις λύσεις τους να βοηθούν τις επιχειρήσεις να μειώσουν το χρόνο διακοπής λειτουργίας και το κόστος συντήρησης και να βελτιώσουν τη συνολική αξιοπιστία του εξοπλισμού.

3.5.8 Honeywell

Η Honeywell είναι μια πολυεθνική εταιρεία που παρέχει λογισμικό, υπηρεσίες και τεχνολογίες για διάφορους κλάδους, όπως η αεροδιαστημική, η άμυνα, η μεταποίηση και το πετρέλαιο και το φυσικό αέριο. Η εταιρεία χρησιμοποιεί τη μηχανική μάθηση και τη βαθιά μάθηση για προγνωστική συντήρηση στο πρόγραμμα Honeywell Connected Plant (HCP), το οποίο στοχεύει στη βελτίωση της αποτελεσματικότητας και της αξιοπιστίας των βιομηχανικών λειτουργιών.

Η προσέγγιση της Honeywell στην προγνωστική συντήρηση περιλαμβάνει τη συλλογή και ανάλυση μεγάλων όγκων δεδομένων αισθητήρων από βιομηχανικό εξοπλισμό, όπως αντλίες, συμπιεστές και τουρμπίνες. Η εταιρεία χρησιμοποιεί αλγόριθμους μηχανικής εκμάθησης για να αναλύσει αυτά τα δεδομένα και να εντοπίσει μοτίβα που μπορούν να υποδεικνύουν αστοχίες εξοπλισμού ή ανάγκες συντήρησης.

Ένα παράδειγμα χρήσης της μηχανικής μάθησης από τη Honeywell για προγνωστική συντήρηση είναι στη βιομηχανία πετρελαίου και φυσικού αερίου. Σε μια μελέτη περίπτωσης, η Honeywell συνεργάστηκε με μια μεγάλη εταιρεία

πετρελαίου και φυσικού αερίου για την εφαρμογή λύσεων πρόβλεψης συντήρησης χρησιμοποιώντας αλγόριθμους μηχανικής μάθησης. Το σύστημα ανέλυσε δεδομένα από διάφορους αισθητήρες, συμπεριλαμβανομένων της θερμοκρασίας, των κραδασμών και της πίεσης, για να ανιχνεύσει ανωμαλίες και να προβλέψει πιθανές βλάβες του εξοπλισμού. Ως αποτέλεσμα, η εταιρεία πετρελαίου και φυσικού αερίου κατάφερε να μειώσει τον προγραμματιστό χρόνο διακοπής λειτουργίας κατά 25% και να βελτιώσει την αξιοπιστία του εξοπλισμού κατά 50%.

Η Honeywell έχει επίσης χρησιμοποιήσει τη βαθιά μάθηση για προγνωστική συντήρηση στην αεροδιαστημική βιομηχανία. Σε μια μελέτη περίπτωσης, η Honeywell συνεργάστηκε με μια αεροπορική εταιρεία για να προβλέψει τις βλάβες του κινητήρα χρησιμοποιώντας αλγόριθμους βαθιάς εκμάθησης. Το σύστημα ανέλυσε δεδομένα από διάφορες πηγές, συμπεριλαμβανομένων δεδομένων πτήσης, αρχείων συντήρησης και δεδομένων αισθητήρων, για να εντοπίσει μοτίβα που θα μπορούσαν να υποδεικνύουν επικείμενες βλάβες του κινητήρα. Ως αποτέλεσμα, η αεροπορική εταιρεία κατάφερε να μειώσει τις καθυστερήσεις που σχετίζονται με τον κινητήρα κατά 30% και να βελτιώσει την αξιοπιστία των αεροσκαφών κατά 15%.

Συνολικά, η Honeywell έχει αποδείξει την αποτελεσματικότητα της μηχανικής μάθησης και της βαθιάς μάθησης για προγνωστική συντήρηση σε διάφορους κλάδους. Αναλύοντας μεγάλους όγκους δεδομένων αισθητήρων, η Honeywell μπόρεσε να εντοπίσει βλάβες του εξοπλισμού πριν αυτές συμβούν και να βελτιώσει την αξιοπιστία και την αποτελεσματικότητα των βιομηχανικών λειτουργιών.

3.5.9 Rockwell Automation

Η Rockwell Automation είναι κορυφαίος πάροχος λύσεων βιομηχανικού αυτοματισμού, συμπεριλαμβανομένων τεχνολογιών πρόβλεψης συντήρησης. Χρησιμοποιούν αλγόριθμους μηχανικής μάθησης και βαθιάς μάθησης για να προβλέψουν τις αστοχίες του εξοπλισμού σε πραγματικό χρόνο και να παρέχουν έγκαιρες προειδοποιήσεις στις ομάδες συντήρησης.

Μία από τις βασικές λύσεις που προσφέρει η Rockwell Automation για προγνωστική συντήρηση είναι η πλατφόρμα FactoryTalk Analytics. Αυτή η πλατφόρμα χρησιμοποιεί αλγόριθμους μηχανικής μάθησης για την ανάλυση δεδομένων από διάφορες πηγές, συμπεριλαμβανομένων αισθητήρων, προγραμματιζόμενων λογικών ελεγκτών (PLC) και διεπαφών ανθρώπου-μηχανής (HMIs), για τον εντοπισμό μοτίβων που υποδεικνύουν πιθανές αστοχίες εξοπλισμού. Η πλατφόρμα περιλαμβάνει επίσης έναν πίνακα εργαλείων που παρέχει ειδοποιήσεις σε πραγματικό χρόνο στις ομάδες συντήρησης, ώστε να μπορούν να λάβουν διορθωτικά μέτρα πριν συμβεί μια αστοχία.

Σύμφωνα με μια μελέτη περίπτωσης της Rockwell Automation, ένας κατασκευαστής καταναλωτικών συσκευασμένων αγαθών (CPG) κατάφερε να μειώσει τον απρογραμματίστο χρόνο διακοπής λειτουργίας κατά 10% και το κόστος συντήρησης κατά 20% χρησιμοποιώντας την πλατφόρμα FactoryTalk Analytics για προγνωστική συντήρηση. Ο κατασκευαστής ήταν σε θέση να εντοπίσει πιθανές βλάβες του εξοπλισμού πριν εμφανιστούν και να λάβει διορθωτικά μέτρα, τα οποία μείωσαν την ανάγκη για δαπανηρές επισκευές και διακοπές λειτουργίας.

Μια άλλη μελέτη περίπτωσης από την Rockwell Automation αφορούσε έναν κατασκευαστή τροφίμων και ποτών που αντιμετώπιζε συχνές βλάβες στις δεξαμενές ανάμειξης. Χρησιμοποιώντας την πλατφόρμα FactoryTalk Analytics, ο κατασκευαστής μπόρεσε να εντοπίσει ένα μοτίβο στα δεδομένα που υποδείκνυε ότι ένα συγκεκριμένο στοιχείο στις δεξαμενές ανάμειξης προκαλούσε τις αστοχίες. Ο κατασκευαστής μπόρεσε να αντικαταστήσει το ελαττωματικό εξάρτημα και να μειώσει τον αριθμό των αστοχιών, γεγονός που εξοικονομούσε χιλιάδες δολάρια σε κόστος συντήρησης και επισκευής.

Συνολικά, η χρήση αλγορίθμων μηχανικής μάθησης και βαθιάς μάθησης από την Rockwell Automation για προγνωστική συντήρηση έχει δείξει σημαντικά οφέλη για τους πελάτες της, συμπεριλαμβανομένου του μειωμένου χρόνου διακοπής λειτουργίας και του κόστους συντήρησης.

3.5.10 ABB

Η ABB, μια ελβετο-σουηδική πολυεθνική εταιρεία, χρησιμοποιεί ML και DL στις εφαρμογές προληπτικής συντήρησης. Το ABB Ability™ Asset Vista Condition Monitoring είναι ένα βιομηχανικό σύστημα διαχείρισης περιουσιακών στοιχείων που χρησιμοποιεί τεχνικές μηχανικής εκμάθησης και βαθιάς εκμάθησης για την παρακολούθηση της υγείας και της απόδοσης κρίσιμου εξοπλισμού σε πραγματικό χρόνο. Το σύστημα χρησιμοποιεί αισθητήρες για τη συλλογή δεδομένων από τον εξοπλισμό, τα οποία στη συνέχεια αναλύονται χρησιμοποιώντας αλγόριθμους μηχανικής μάθησης για τον εντοπισμό μοτίβων και τάσεων που θα μπορούσαν να υποδεικνύουν πιθανή βλάβη του εξοπλισμού.

Μια μελέτη περίπτωσης που καταδεικνύει την αποτελεσματικότητα της λύσης προληπτικής συντήρησης που βασίζεται σε ML και DL της ABB διεξήχθη

στην καναδική επιχείρηση πετρελαίου άμμου της Syncrude. Το σύστημα Asset Vista της ABB αναπτύχθηκε για την παρακολούθηση της υγείας 900 κρίσιμων στοιχείων, συμπεριλαμβανομένων των κινητήρων, των αντλιών και των συμπιεστών, σε πραγματικό χρόνο. Το σύστημα χρησιμοποίησε αλγόριθμους ML για να αναλύσει τα δεδομένα του αισθητήρα και να ανιχνεύσει τυχόν ανωμαλίες που θα μπορούσαν να υποδεικνύουν πιθανή βλάβη του εξοπλισμού. Το σύστημα ήταν σε θέση να εντοπίσει πολλές βλάβες του εξοπλισμού εκ των προτέρων, επιτρέποντας στην ομάδα συντήρησης να προγραμματίσει προληπτικά τις επισκευές και να αποφύγει δαπανηρές διακοπές λειτουργίας. Ως αποτέλεσμα, η Syncrude κατάφερε να εξοικονομήσει 2,5 εκατομμύρια δολάρια σε απρογραμματίστο κόστος διακοπής λειτουργίας.

Ένα άλλο παράδειγμα χρήσης των ML και DL από την ABB για προληπτική συντήρηση είναι η συνεργασία της με τη σουηδική εταιρεία εξόρυξης Boliden. Η λύση Ability™ Performance Optimization for hoists της ABB αναπτύχθηκε για την παρακολούθηση της υγείας του κρίσιμου εξοπλισμού, συμπεριλαμβανομένων των ανυψωτικών μηχανημάτων και των μεταφορέων, σε πραγματικό χρόνο. Το σύστημα χρησιμοποίησε αλγόριθμους ML για να αναλύσει τα δεδομένα του αισθητήρα και να εντοπίσει τυχόν ανωμαλίες που θα μπορούσαν να υποδεικνύουν πιθανή βλάβη του εξοπλισμού. Το σύστημα μπόρεσε να εντοπίσει μια πιθανή αστοχία ρουλεμάν σε ένα από τα ανυψωτικά, επιτρέποντας στην ομάδα συντήρησης να προγραμματίσει επισκευές πριν αποτύχει ο εξοπλισμός, με αποτέλεσμα σημαντική εξοικονόμηση κόστους.

Συνολικά, η χρήση των ML και DL από την ABB στις λύσεις προληπτικής συντήρησης της έχει αποδείξει σημαντική εξοικονόμηση κόστους για τους

πελάτες της, επιτρέποντας τον προληπτικό προγραμματισμό συντήρησης και την αποφυγή δαπανηρών βλαβών εξοπλισμού.

4 Αποτελέσματα και συζήτηση

4.1 Επισκόπηση των ευρημάτων

Το κεφάλαιο των αποτελεσμάτων και της συζήτησης παρέχει μια επισκόπηση των ευρημάτων της έρευνας και υπογραμμίζει τις βασικές ιδέες και τις επιπτώσεις της μελέτης. Με βάση την ανασκόπηση της βιβλιογραφίας και των περιπτώσιολογικών μελετών, μπορεί να συναχθεί το συμπέρασμα ότι η προγνωστική συντήρηση με τη χρήση τεχνικών μηχανικής μάθησης και βαθιάς μάθησης έχει γίνει μια δημοφιλής και αποτελεσματική προσέγγιση για τη βελτίωση της αξιοπιστίας και της αποτελεσματικότητας των βιομηχανικών συστημάτων.

Ένα από τα κύρια ευρήματα της έρευνας είναι ότι οι αλγόριθμοι μηχανικής μάθησης και βαθιάς μάθησης μπορούν να προβλέψουν αποτελεσματικά τις βλάβες του εξοπλισμού αναλύοντας δεδομένα αισθητήρων και εντοπίζοντας μοτίβα και ανωμαλίες. Για παράδειγμα, στη μελέτη των Zhao et al. (2019), οι τεχνικές μηχανικής εκμάθησης πέτυχαν ακρίβεια 98,8% στην πρόβλεψη αστοχίας ρουλεμάν σε ανεμογεννήτριες. Ομοίως, οι Wang et al. (2021) ανέφερε ακρίβεια 92% στην πρόβλεψη αστοχιών εξοπλισμού σε ένα χημικό εργοστάσιο χρησιμοποιώντας τεχνικές βαθιάς μάθησης.

Ένα άλλο σημαντικό εύρημα είναι ότι διαφορετικές τεχνικές και αλγόριθμοι μπορεί να έχουν διαφορετικά επίπεδα ακρίβειας και απόδοσης ανάλογα με τη συγκεκριμένη εφαρμογή και το σύνολο δεδομένων. Για παράδειγμα, οι Li et al. (2020) διαπίστωσε ότι τα δέντρα απόφασης μπορεί να είναι αποτελεσματικά για προγνωστική συντήρηση, αλλά μπορεί επίσης να είναι επιρρεπή σε

υπερβολική προσαρμογή. Από την άλλη πλευρά, οι Xu et al. (2020) ανέφερε υψηλή ακρίβεια 98% στην πρόβλεψη αστοχιών εξοπλισμού στην αεροδιαστημική βιομηχανία χρησιμοποιώντας τεχνικές βαθιάς μάθησης.

Η έρευνα υπογραμμίζει επίσης τη σημασία της ποιότητας και της ποσότητας των δεδομένων στην προγνωστική συντήρηση. Η ακρίβεια και η αξιοπιστία των μοντέλων προγνωστικής συντήρησης εξαρτώνται σε μεγάλο βαθμό από την ποιότητα και την ποσότητα των δεδομένων που χρησιμοποιούνται για την εκπαίδευση των μοντέλων. Ανεπαρκή ή ανεπαρκή δεδομένα μπορεί να οδηγήσουν σε ανακριβείς προβλέψεις και αναξιόπιστα μοντέλα. Ως εκ τούτου, είναι σημαντικό να συλλέγονται και να προεπεξεργάζονται τα δεδομένα προσεκτικά για να διασφαλιστεί ότι είναι αντιπροσωπευτικά και κατάλληλα για εκπαίδευση μοντέλων πρόβλεψης.

Επιπλέον, η έρευνα εντοπίζει αρκετές προκλήσεις και περιορισμούς στον τομέα της προγνωστικής συντήρησης χρησιμοποιώντας τεχνικές μηχανικής μάθησης και βαθιάς μάθησης. Για παράδειγμα, η έλλειψη ερμηνείας ορισμένων μοντέλων μπορεί να δυσκολέψει την κατανόηση και τη διάγνωση των αιτιών πίσω από τις αστοχίες του εξοπλισμού. Επιπλέον, οι υψηλές απαιτήσεις υπολογισμού και πόρων ορισμένων αλγορίθμων μπορούν να περιορίσουν την πρακτική εφαρμογή τους σε ορισμένους κλάδους.

Συμπερασματικά, τα ευρήματα αυτής της έρευνας υποδηλώνουν ότι η προγνωστική συντήρηση χρησιμοποιώντας τεχνικές μηχανικής μάθησης και βαθιάς μάθησης μπορεί να είναι ένα ισχυρό εργαλείο για τη βελτίωση της αξιοπιστίας και της αποτελεσματικότητας των βιομηχανικών συστημάτων. Ωστόσο, είναι σημαντικό να εξεταστεί προσεκτικά η συγκεκριμένη εφαρμογή

και το σύνολο δεδομένων και να αντιμετωπιστούν προκλήσεις όπως η ποιότητα των δεδομένων και η επιλογή αλγορίθμων για να διασφαλιστούν ακριβείς και αξιόπιστες προβλέψεις.

4.2 Ερμηνεία των αποτελεσμάτων

Η ερμηνεία των αποτελεσμάτων είναι μια κρίσιμη πτυχή κάθε μελέτης. Στην περίπτωση της προγνωστικής συντήρησης με χρήση τεχνικών μηχανικής μάθησης και βαθιάς μάθησης, τα αποτελέσματα που προκύπτουν από τα μοντέλα πρέπει να αναλυθούν και να ερμηνευτούν διεξοδικά.

Αρκετές μελέτες έχουν αναφέρει υψηλά ποσοστά ακρίβειας στην πρόβλεψη αστοχιών εξοπλισμού χρησιμοποιώντας τεχνικές μηχανικής εκμάθησης και βαθιάς εκμάθησης. Για παράδειγμα, στη μελέτη των Zhao et al. (2019), επιτεύχθηκε ποσοστό ακρίβειας 98,8% στην πρόβλεψη αστοχίας ρουλεμάν σε ανεμογεννήτριες. Ομοίως, στη μελέτη των Wang et al. (2021), επιτεύχθηκε ποσοστό ακρίβειας 92% στην πρόβλεψη αστοχιών εξοπλισμού σε μια χημική μονάδα χρησιμοποιώντας τεχνικές βαθιάς εκμάθησης.

Τα δέντρα αποφάσεων έχουν επίσης χρησιμοποιηθεί ευρέως στην προγνωστική συντήρηση, καθώς μπορούν να προσδιορίσουν τα πιο σημαντικά χαρακτηριστικά σε ένα σύνολο δεδομένων και να κάνουν προβλέψεις με βάση αυτά τα χαρακτηριστικά. Ωστόσο, τα δέντρα αποφάσεων μπορεί να είναι επιρρεπή στην υπερπροσαρμογή και μπορεί να μην γενικεύονται καλά σε νέα δεδομένα, όπως σημειώνεται από τους Li et al. (2020).

Τα αποτελέσματα που προέκυψαν από τις περιπτώσιολογικές μελέτες και τα παραδείγματα επιτυχημένων εφαρμογών δείχνουν ότι η προγνωστική συντήρηση

χρησιμοποιώντας τεχνικές μηχανικής μάθησης και βαθιάς μάθησης μπορεί να βελτιώσει σημαντικά την αξιοπιστία του εξοπλισμού και να μειώσει το χρόνο διακοπής λειτουργίας. Ωστόσο, είναι σημαντικό να σημειωθεί ότι η επιτυχία αυτών των τεχνικών εξαρτάται από πολλούς παράγοντες όπως η ποιότητα των δεδομένων, η επιλογή των αλγορίθμων και η τεχνογνωσία των εμπλεκόμενων επιστημόνων δεδομένων.

Επιπλέον, ορισμένες προκλήσεις, όπως η ποιότητα των δεδομένων, η έλλειψη δεδομένων με ετικέτα και η ερμηνευτικότητα των μοντέλων, πρέπει να αντιμετωπιστούν στον τομέα της προγνωστικής συντήρησης με τη χρήση τεχνικών μηχανικής μάθησης και βαθιάς μάθησης. Η αντιμετώπιση αυτών των προκλήσεων θα απαιτήσει τη συνεργασία μεταξύ ειδικών τομέα και επιστημόνων δεδομένων για να διασφαλιστεί ότι τα μοντέλα είναι σχετικά με τον συγκεκριμένο τομέα και ότι τα αποτελέσματα που λαμβάνονται είναι χρήσιμα και εφαρμόσιμα.

Συνοπτικά, η ερμηνεία των αποτελεσμάτων από την προγνωστική συντήρηση χρησιμοποιώντας τεχνικές μηχανικής μάθησης και βαθιάς μάθησης είναι κρίσιμη για την κατανόηση της αποτελεσματικότητας αυτών των τεχνικών στη βελτίωση της αξιοπιστίας του εξοπλισμού και στη μείωση του χρόνου διακοπής λειτουργίας. Τα αποτελέσματα που προέκυψαν από τις περιπτώσιολογικές μελέτες και τα παραδείγματα επιτυχημένων υλοποιήσεων δείχνουν τις δυνατότητες αυτών των τεχνικών, αλλά χρειάζεται περισσότερη δουλειά για την αντιμετώπιση των προκλήσεων και τη διασφάλιση της συνάφειας και της χρησιμότητας των μοντέλων σε συγκεκριμένους τομείς.

4.3 Συζήτηση των επιπτώσεων και των περιορισμών

Η συζήτηση των επιπτώσεων και των περιορισμών της μελέτης αποτελεί σημαντικό μέρος του κεφαλαίου Αποτελέσματα και Συζήτηση. Οι επιπτώσεις της μελέτης αναφέρονται στον πιθανό αντίκτυπο και τη σημασία των ευρημάτων, ενώ οι περιορισμοί αναφέρονται στις αδυναμίες ή τους περιορισμούς της μελέτης που μπορεί να επηρεάσουν τη γενίκευση και την ερμηνεία των αποτελεσμάτων.

Όσον αφορά τις επιπτώσεις της μελέτης, είναι σημαντικό να συζητήσουμε πώς τα ευρήματα μπορούν να συμβάλουν στον τομέα της προγνωστικής συντήρησης και στον συγκεκριμένο κλάδο όπου διεξήχθη η μελέτη. Για παράδειγμα, εάν η μελέτη πέτυχε υψηλό ποσοστό ακρίβειας στην πρόβλεψη αστοχιών εξοπλισμού, θα μπορούσε να έχει σημαντικό αντίκτυπο στη μείωση του χρόνου διακοπής λειτουργίας, στην αύξηση της ασφάλειας και στη βελτιστοποίηση των προγραμμάτων συντήρησης, οδηγώντας σε εξοικονόμηση κόστους για τον κλάδο (Wang et al., 2021; Zhang et al., 2019). Τα ευρήματα της μελέτης θα μπορούσαν επίσης να συμβάλουν στην ανάπτυξη πιο εξελιγμένων και αποτελεσματικών μοντέλων προγνωστικής συντήρησης που μπορούν να εφαρμοστούν σε άλλους κλάδους.

Ωστόσο, είναι εξίσου σημαντικό να συζητηθούν οι περιορισμοί της μελέτης, καθώς μπορούν να επηρεάσουν τη γενίκευση και την ερμηνεία των αποτελεσμάτων. Οι περιορισμοί μπορεί να περιλαμβάνουν το μέγεθος και την αντιπροσωπευτικότητα του συνόλου δεδομένων, την επιλογή και την απόδοση του αλγορίθμου, τη διαθεσιμότητα και την ποιότητα των δεδομένων του αισθητήρα και άλλους παράγοντες που μπορεί να επηρεάσουν την ακρίβεια και

την αξιοπιστία του μοντέλου (Guo et al., 2019; Liu et al., 2021). Επιπλέον, είναι σημαντικό να ληφθούν υπόψη οι πρακτικοί περιορισμοί της εφαρμογής μοντέλων πρόβλεψης συντήρησης, όπως το κόστος και η πολυπλοκότητα του συστήματος, η εκπαίδευση και οι δεξιότητες που απαιτούνται για το προσωπικό συντήρησης και οι προκλήσεις της ενοποίησης του μοντέλου με το υπάρχον σύστημα συντήρησης (Xue et al., 2018).

Συνολικά, η συζήτηση των επιπτώσεων και των περιορισμών της μελέτης μπορεί να προσφέρει μια πιο ολοκληρωμένη κατανόηση της σημασίας και της συνάφειας της μελέτης στο πεδίο της προγνωστικής συντήρησης. Μπορεί επίσης να παρέχει πληροφορίες και συστάσεις για μελλοντική έρευνα και πρακτικές εφαρμογές.

5 Συμπεράσματα

5.1 Περίληψη των βασικών ευρημάτων

Το κεφάλαιο των συμπερασμάτων συνήθως συνοψίζει τα βασικά ευρήματα του ερευνητικού έργου και παρέχει μια συνολική αξιολόγηση της επιτυχίας και των περιορισμών της μελέτης. Στο πλαίσιο της προγνωστικής συντήρησης με χρήση μηχανικής μάθησης και βαθιάς μάθησης, τα βασικά ευρήματα μπορεί να περιλαμβάνουν την αποτελεσματικότητα διαφορετικών αλγορίθμων και τεχνικών για την πρόβλεψη αστοχιών εξοπλισμού, την ακρίβεια των προβλέψεων και τα πιθανά οφέλη από την εφαρμογή ενός συστήματος πρόβλεψης συντήρησης.

Για παράδειγμα, τα βασικά ευρήματα μπορεί να υποδεικνύουν ότι οι τεχνικές βαθιάς μάθησης έχουν δείξει υψηλότερη ακρίβεια στην πρόβλεψη αστοχιών εξοπλισμού σε σύγκριση με τις τεχνικές μηχανικής μάθησης, όπως φαίνεται στις μελέτες περίπτωσης των Xu et al. (2020) και οι Zhang et al. (2019). Επιπλέον, η χρήση τεχνικών συνόλου, όπως ο συνδυασμός πολλαπλών μοντέλων, μπορεί να βελτιώσει περαιτέρω την ακρίβεια των προβλέψεων, όπως καταδεικνύεται στη μελέτη των Wang et al. (2021).

Το κεφάλαιο των συμπερασμάτων μπορεί επίσης να συζητήσει τα πιθανά οφέλη από την εφαρμογή ενός συστήματος πρόβλεψης συντήρησης, όπως η μείωση του χρόνου διακοπής λειτουργίας και του κόστους συντήρησης, η βελτίωση της αξιοπιστίας και της ασφάλειας του εξοπλισμού και η βελτίωση της συνολικής λειτουργικής απόδοσης. Ωστόσο, είναι σημαντικό να αναγνωριστούν οι περιορισμοί της μελέτης, όπως η διαθεσιμότητα και η ποιότητα των δεδομένων, η πολυπλοκότητα και η μεταβλητότητα των τρόπων

αστοχίας του εξοπλισμού και η ανάγκη για συνεχή συντήρηση και ενημέρωση των μοντέλων πρόβλεψης.

Συνολικά, το κεφάλαιο των συμπερασμάτων χρησιμεύει ως περίληψη του ερευνητικού έργου και παρέχει μια ευρύτερη προοπτική σχετικά με τις επιπτώσεις και τις εφαρμογές των ευρημάτων στον τομέα της προγνωστικής συντήρησης.

5.2 Επιπτώσεις για πρακτική και μελλοντική έρευνα

Οι συνέπειες για την πρακτική και τη μελλοντική έρευνα μπορούν να αντληθούν από τα βασικά ευρήματα της μελέτης. Όσον αφορά την πρακτική, η χρήση τεχνικών μηχανικής μάθησης και βαθιάς μάθησης για προγνωστική συντήρηση έχει βρεθεί ότι είναι αποτελεσματική σε διάφορα βιομηχανικά περιβάλλοντα. Έχει τη δυνατότητα να μειώσει το χρόνο διακοπής λειτουργίας, να ελαχιστοποιήσει το κόστος συντήρησης και να αυξήσει τη συνολική απόδοση του εξοπλισμού. Ως εκ τούτου, συνιστάται στις βιομηχανίες να εξετάσουν το ενδεχόμενο εφαρμογής αυτών των τεχνικών στις στρατηγικές συντήρησης τους.

Ωστόσο, είναι σημαντικό να σημειωθούν οι περιορισμοί της τρέχουσας έρευνας, η οποία περιλαμβάνει την ανάγκη για μεγάλα και διαφορετικά σύνολα δεδομένων, καθώς και την απαίτηση για εξειδίκευση στον τομέα προκειμένου να αναπτυχθούν ακριβή μοντέλα. Επιπλέον, η εφαρμογή αυτών των τεχνικών μπορεί να απαιτεί σημαντικές επενδύσεις από άποψη χρόνου, πόρων και τεχνογνωσίας.

Η μελλοντική έρευνα θα μπορούσε να επικεντρωθεί στη βελτίωση της ακρίβειας των μοντέλων προγνωστικής συντήρησης εξερευνώντας νέους αλγόριθμους, καθώς και ενσωματώνοντας δεδομένα από άλλες πηγές, όπως ο καιρός ή τα πρότυπα χρήσης. Επιπλέον, θα μπορούσε να διεξαχθεί έρευνα για την ανάπτυξη οικονομικά αποδοτικών και φιλικών προς τον χρήστη εργαλείων για την εφαρμογή της προγνωστικής συντήρησης σε βιομηχανικά περιβάλλοντα.

Συνολικά, η χρήση τεχνικών μηχανικής μάθησης και βαθιάς μάθησης για προγνωστική συντήρηση έχει σημαντικές δυνατότητες για τη βελτίωση της απόδοσης συντήρησης και τη μείωση του κόστους σε διάφορους κλάδους. Ωστόσο, απαιτείται περαιτέρω έρευνα για την πλήρη αξιοποίηση των δυνατοτήτων αυτών των τεχνικών και για την αντιμετώπιση των σημερινών περιορισμών.

5.3 Περιορισμοί και προτάσεις για περαιτέρω έρευνα

Στο κεφάλαιο των συμπερασμάτων, είναι σημαντικό να αναγνωρίσουμε τους περιορισμούς της μελέτης και να προτείνουμε τομείς για περαιτέρω έρευνα. Ένας περιορισμός της χρήσης τεχνικών μηχανικής εκμάθησης για προγνωστική συντήρηση είναι η διαθεσιμότητα και η ποιότητα των δεδομένων. Ορισμένες μελέτες έχουν βρει ότι τα ανεπαρκή ή ανακριβή δεδομένα μπορούν να επηρεάσουν αρνητικά την ακρίβεια των μοντέλων προγνωστικής συντήρησης (Wang et al., 2021; Liu et al., 2021). Επιπλέον, μπορεί να είναι δύσκολο να επιλέξετε τον καταλληλότερο αλγόριθμο μηχανικής μάθησης για μια δεδομένη εφαρμογή, καθώς διαφορετικοί αλγόριθμοι μπορεί να αποδίδουν διαφορετικά ανάλογα με το σύνολο δεδομένων και το συγκεκριμένο πρόβλημα που αντιμετωπίζεται (Li et al., 2020).

Για την αντιμετώπιση αυτών των περιορισμών, η μελλοντική έρευνα θα μπορούσε να επικεντρωθεί στην ανάπτυξη μεθόδων για τη βελτίωση της συλλογής δεδομένων και της ποιότητας σε βιομηχανικά περιβάλλοντα. Αυτό θα μπορούσε να περιλαμβάνει τη χρήση πιο προηγμένων αισθητήρων ή τεχνικών για τον καθαρισμό και την προεπεξεργασία δεδομένων. Επιπλέον, θα μπορούσε να γίνει περαιτέρω έρευνα σχετικά με την απόδοση διαφορετικών αλγορίθμων μηχανικής μάθησης για συγκεκριμένες εφαρμογές, με έμφαση στην ανάπτυξη πιο ακριβών και ισχυρών μοντέλων. Θα μπορούσε επίσης να είναι πολύτιμο να διερευνηθεί η δυνατότητα συνδυασμού πολλαπλών τεχνικών μηχανικής μάθησης, όπως η χρήση ενός συνδυασμού βαθιάς μάθησης και δέντρων αποφάσεων, για τη βελτίωση της προγνωστικής ακρίβειας (Xu et al., 2020).

Επιπλέον, η μελλοντική έρευνα θα μπορούσε να επικεντρωθεί στη διερεύνηση του δυναμικού της προγνωστικής συντήρησης για συγκεκριμένες βιομηχανίες ή τύπους εξοπλισμού που έχουν λάβει λιγότερη προσοχή στη βιβλιογραφία. Για παράδειγμα, μπορεί να υπάρχουν ευκαιρίες για την εφαρμογή τεχνικών πρόβλεψης συντήρησης σε γεωργικό εξοπλισμό ή εξοπλισμό εξόρυξης, κάτι που θα μπορούσε να έχει σημαντικά οφέλη για αυτούς τους κλάδους. Επιπλέον, ενδέχεται να υπάρχουν ευκαιρίες για ενσωμάτωση της προγνωστικής συντήρησης με άλλες τεχνολογίες, όπως η ρομποτική ή ο αυτοματισμός, για περαιτέρω βελτίωση των διαδικασιών συντήρησης και της απόδοσης του εξοπλισμού.

Συνολικά, ενώ η χρήση τεχνικών μηχανικής μάθησης για προγνωστική συντήρηση έχει δείξει πολλά υποσχόμενη, υπάρχουν ακόμη πολλοί τομείς για περαιτέρω έρευνα και ανάπτυξη. Αντιμετωπίζοντας τους περιορισμούς και τις

προκλήσεις που εντοπίστηκαν σε αυτή τη μελέτη, η μελλοντική έρευνα θα μπορούσε να οδηγήσει σε πιο ακριβή και αποτελεσματικά μοντέλα πρόβλεψης συντήρησης και σημαντικές βελτιώσεις στην αξιοπιστία του εξοπλισμού και στην απόδοση συντήρησης. Στο κεφάλαιο των συμπερασμάτων, είναι σημαντικό να αναγνωρίσουμε τους περιορισμούς της μελέτης και να προτείνουμε τομείς για περαιτέρω έρευνα. Ένας περιορισμός της χρήσης τεχνικών μηχανικής εκμάθησης για προγνωστική συντήρηση είναι η διαθεσιμότητα και η ποιότητα των δεδομένων. Ορισμένες μελέτες έχουν βρει ότι τα ανεπαρκή ή ανακριβή δεδομένα μπορούν να επηρεάσουν αρνητικά την ακρίβεια των μοντέλων προγνωστικής συντήρησης (Wang et al., 2021; Liu et al., 2021). Επιπλέον, μπορεί να είναι δύσκολο να επιλέξετε τον καταλληλότερο αλγόριθμο μηχανικής μάθησης για μια δεδομένη εφαρμογή, καθώς διαφορετικοί αλγόριθμοι μπορεί να αποδίδουν διαφορετικά ανάλογα με το σύνολο δεδομένων και το συγκεκριμένο πρόβλημα που αντιμετωπίζεται (Li et al., 2020).

Για την αντιμετώπιση αυτών των περιορισμών, η μελλοντική έρευνα θα μπορούσε να επικεντρωθεί στην ανάπτυξη μεθόδων για τη βελτίωση της συλλογής δεδομένων και της ποιότητας σε βιομηχανικά περιβάλλοντα. Αυτό θα μπορούσε να περιλαμβάνει τη χρήση πιο προηγμένων αισθητήρων ή τεχνικών για τον καθαρισμό και την προεπεξεργασία δεδομένων. Επιπλέον, θα μπορούσε να γίνει περαιτέρω έρευνα σχετικά με την απόδοση διαφορετικών αλγορίθμων μηχανικής μάθησης για συγκεκριμένες εφαρμογές, με έμφαση στην ανάπτυξη πιο ακριβών και ισχυρών μοντέλων. Θα μπορούσε επίσης να είναι πολύτιμο να διερευνηθεί η δυνατότητα συνδυασμού πολλαπλών τεχνικών μηχανικής μάθησης, όπως η χρήση ενός συνδυασμού βαθιάς μάθησης και δέντρων αποφάσεων, για τη βελτίωση της προγνωστικής ακρίβειας (Xu et al., 2020).

Επιπλέον, η μελλοντική έρευνα θα μπορούσε να επικεντρωθεί στη διερεύνηση του δυναμικού της προγνωστικής συντήρησης για συγκεκριμένες βιομηχανίες ή τύπους εξοπλισμού που έχουν λάβει λιγότερη προσοχή στη βιβλιογραφία. Για παράδειγμα, μπορεί να υπάρχουν ευκαιρίες για την εφαρμογή τεχνικών πρόβλεψης συντήρησης σε γεωργικό εξοπλισμό ή εξοπλισμό εξόρυξης, κάτι που θα μπορούσε να έχει σημαντικά οφέλη για αυτούς τους κλάδους. Επιπλέον, ενδέχεται να υπάρχουν ευκαιρίες για ενσωμάτωση της προγνωστικής συντήρησης με άλλες τεχνολογίες, όπως η ρομποτική ή ο αυτοματισμός, για περαιτέρω βελτίωση των διαδικασιών συντήρησης και της απόδοσης του εξοπλισμού.

Συνολικά, ενώ η χρήση τεχνικών μηχανικής μάθησης για προγνωστική συντήρηση έχει δείξει πολλά υποσχόμενη, υπάρχουν ακόμη πολλοί τομείς για περαιτέρω έρευνα και ανάπτυξη. Αντιμετωπίζοντας τους περιορισμούς και τις προκλήσεις που εντοπίστηκαν σε αυτή τη μελέτη, η μελλοντική έρευνα θα μπορούσε να οδηγήσει σε πιο ακριβή και αποτελεσματικά μοντέλα πρόβλεψης συντήρησης και σημαντικές βελτιώσεις στην αξιοπιστία του εξοπλισμού και στην απόδοση συντήρησης.

6 Βιβλιογραφικές αναφορές

- Αθανασίου, Γ. (2021). Προβλεπτική συντήρηση: Εφαρμογές στον τομέα της βιομηχανίας. Αθήνα: Εκδόσεις ΕΚΔΟΣΕΙΣ Α. Τζιβεριδης.
- Βρυώνης, Δ., & Κουτσούμπας, Κ. (2019). Προβλεπτική συντήρηση σε βιομηχανικά συστήματα με χρήση μεθόδων μηχανικής μάθησης. Περιοδικό Επιθεώρηση Τεχνολογίας και Τεχνικής Εκπαίδευσης, 16(1), 63-74.
- Βύρωνας, Σ., Τριανταφύλλου, Π., & Πατσουράκος, Ν. (2018). Προβλεπτική συντήρηση εξοπλισμού με χρήση μεθόδων μηχανικής μάθησης: Παράδειγμα εφαρμογής σε μονάδα αποστείρωσης. Περιοδικό Μηχανική Και Ενέργεια, 17(2), 27-33.
- Παπαδόπουλος, Σ. (2020). Προβλεπτική συντήρηση εξοπλισμού στη βιομηχανία με τη χρήση αλγορίθμων μηχανικής μάθησης. Περιοδικό Ενέργεια, Περιβάλλον, Οικονομία, 5(1), 27-33.
- Saxena and K. Goebel, "Turbofan engine degradation simulation data set," NASA Ames Prognostics Data Repository, 2008.
- K. Medjaher, Y. Zerhouni, and A. Rezg, "An adaptive prognostic approach based on a degradation model and a bayesian framework," Mechanical Systems and Signal Processing, vol. 25, no. 5, pp. 1803-1823, 2011.
- R. Yan, L. Peng, and J. Zheng, "A deep learning approach to fault diagnosis for rotating machinery based on the convolutional neural network and support vector machine," Shock and Vibration, vol. 2017, Article ID 5067651, 13 pages, 2017.

- J. H. Lee, H. Lee, and K. R. Lee, "A review of online diagnostic and prognostic approaches for electric machines and drives," *IEEE Transactions on Industrial Electronics*, vol. 63, no. 8, pp. 4680-4691, 2016.
- W. Hu, G. Gao, Y. Dong, and S. Huang, "Intelligent fault diagnosis of rotating machinery using deep belief network based on deep learning algorithm," *Mathematical Problems in Engineering*, vol. 2018, Article ID 8574696, 13 pages, 2018.
- D. Dolz, R. Granell, D. Robles, and D. Gandia, "A review of machine learning techniques for predictive maintenance," *Computers & Industrial Engineering*, vol. 176, p. 107088, 2019.
- Zanella, N. Bui, A. Castellani, L. Vangelista, and M. Zorzi, "Internet of things for smart cities," *IEEE Internet of Things Journal*, vol. 1, no. 1, pp. 22-32, 2014.
- M. L. Tseng, Y. H. Huang, C. F. Lu, and S. K. Chen, "Predicting equipment failure using machine learning techniques in the semiconductor manufacturing process," *IEEE Transactions on Semiconductor Manufacturing*, vol. 32, no. 4, pp. 587-595, 2019.
- M. Abdulrahman and B. Khaleel, "Smart maintenance management systems: A review," *Journal of Quality in Maintenance Engineering*, vol. 24, no. 4, pp. 390-413, 2018.
- F. Garcia-Sanchez, J. F. Villa-Mejia, and M. A. Zamora-Izquierdo, "Predictive maintenance in industry 4.0: A review," *IEEE Access*, vol. 8, pp. 168547-168567, 2020.

- Li, H., Liu, Y., Wang, L., & Zhang, Y. (2020). Application of Random Forest algorithm in predictive maintenance of equipment. *IEEE Access*, 8, 118852-118862. doi: 10.1109/ACCESS.2020.3005143
- Liu, Y., Lin, J., & Guo, X. (2021). Predictive maintenance for CNC machine tools based on deep learning. *Journal of Ambient Intelligence and Humanized Computing*, 12(9), 10437-10446. doi: 10.1007/s12652-021-03663-4
- Shi, Y., Luo, M., Qiu, M., Hu, B., & Li, K. (2019). Predictive maintenance for rotating machinery using machine learning: A review. *Mechanical Systems and Signal Processing*, 115, 475-493. doi: 10.1016/j.ymsp.2018.06.009
- Wang, L., Li, J., Liu, J., & Song, X. (2021). Predictive maintenance of chemical equipment based on deep learning. *Applied Sciences*, 11(8), 3702. doi: 10.3390/app11083702
- Xu, J., Shao, S., Li, W., & Li, S. (2020). Predicting equipment failure in the aerospace industry using deep learning. *Aerospace Science and Technology*, 96, 105583. doi: 10.1016/j.ast.2019.105583
- Xue, Y., Li, Z., & Chen, D. (2018). A novel method for predicting equipment failure in power plants using machine learning techniques. *Applied Energy*, 210, 981-993. doi: 10.1016/j.apenergy.2017.10.104
- Yang, Y., & Lee, J. (2020). Data-driven prognostics and health management: A review of algorithms, methodologies, and applications. *IEEE Transactions on Industrial Electronics*, 67(5), 4067-4081. doi: 10.1109/TIE.2019.2927799

- Zhang, J., Zhang, J., Hu, C., & Yu, S. (2019). Predictive maintenance for equipment in the oil and gas industry using deep learning. *Journal of Petroleum Science and Engineering*, 183, 106370. doi: 10.1016/j.petrol.2019.106370
- Zhang, X., Wang, Y., Zhang, Y., & Liu, G. (2021). Predictive maintenance of conveyor belt systems using machine learning. *Processes*, 9(4), 706. doi: 10.3390/pr9040706
- Zhao, S., He, Y., & Guo, F. (2019). Predicting bearing failure in wind turbines using machine learning. *Renewable Energy*, 138, 45-55. doi: 10.1016/j.renene.2019.01.129