

Αξιολόγηση καινοτόμων μεθοδολογιών βαθιάς μάθησης για την παρακολούθηση της κατάστασης σκαφών θαλάσσης

Παναγιώτης Θεοδωρόπουλος
[Αριθμός Μητρώου 1054485]

Πίνακας ξενόγλωσσων ορολογιών

Internet of Things (IoT): Διαδίκτυο των πραγμάτων
Fault Detection (FD): Διάγνωση βλαβών
Convolutional Neural Networks (CNN): Συνελικτικά Νευρωνικά Δίκτυα
Contours: Διαγράμματα περιγράμματος
Condition Based Monitoring (CBM): Παρακολούθηση κατάστασης
Support Vector Classifier (SVC): Είδος ταξινομητή μηχανικής μάθησης
Random Forest Classifier (RFC): Είδος ταξινομητή μηχανικής μάθησης
Simple Moving Average (SMA): Αλγόριθμος απλού κινούμενου μέσου όρου
Heickel Coefficient: Συντελεστής Heickel, εκφράζει την απόδοση του πλοίου
Froude Number: Αδιαστατοποιημένη έκφραση της ταχύτητας του πλοίου
SoftMax Activation Function: Συνάρτηση ενεργοποίησης τελευταίου στρώματος σε ένα δίκτυο που παράγει τις τελικές εκτιμήσεις
TensorFlow: Μαθηματική βιβλιοθήκη τεχνητής νοημοσύνης

Διπλωματική Εργασία

1. Εισαγωγή

Παρά τον ζωτικό ρόλο της ναυτιλιακής βιομηχανίας στη μεταφορά και τη διανομή αγαθών παγκοσμίως, μόλις πρόσφατα έχουν αρχίσει να εξετάζονται νέες προσεγγίσεις που διερευνούν τη βελτίωση της αξιοπιστίας, της διαθεσιμότητας των πλοίων. Στη σημερινή εποχή, το Internet of Things (IoT) έχει φέρει επανάσταση σε τεχνικές που βασίζονται σε δεδομένα και ο όγκος πληροφοριών και πληροφοριών που μπορούν να αντληθούν από δεδομένα μηχανημάτων επιτρέπει σε ένα σύστημα Condition Based Monitoring (CBM) ως εργαλείο για την αξιολόγηση της κατάστασης του συστήματος και εκτέλεση προγνωστικών αναλύσεων για διάγνωση βλαβών (Fault Detection), με στόχο τη μείωση του χρόνου που δεν λειτουργεί το υπό μελέτη σύστημα, αλλά και της περιττής εργασίας συντήρησης. Η πρόβλεψη συντήρησης αντιπροσωπεύει μία από τις τελευταίες τάσεις στη θαλάσσια συντήρηση, διασφαλίζοντας επαρκώς ικανοποιητική και λειτουργική κατάσταση των πλοίων. Εφαρμογή προγνωστικών αναλυτικών εφαρμογών ανίχνευσης σφαλμάτων, που εξυπηρετούν τη δυνατότητα εντοπισμού έγκαιρης ανίχνευσης σφαλμάτων, επιτρέπουν την πραγματοποίηση πιο αποτελεσματικής λειτουργίας αποστολής. Εργαζόμενοι προς αυτήν την κατεύθυνση, στην προηγούμενη μελέτη μας, διερευνήσαμε πώς διαφορετικά μοντέλα

βαθιάς μάθησης θα μπορούσαν να παρέχουν βελτιωμένες πληροφορίες για την υποστήριξη της λήψης αποφάσεων. Προχωρώντας ένα βήμα παραπέρα στην τρέχουσα μελέτη στοχεύουμε να εισαγάγουμε μεθοδολογίες συνελικτών νευρωνικών δικτύων (Convolutional Neural Networks) για την έγκαιρη ανίχνευση και την αποτελεσματική πρόβλεψη ελαττωματικών επιχειρησιακών καταστάσεων εν πλω. Πιο συγκεκριμένα, οι τύποι νευρωνικών δικτύων που εξετάστηκαν είναι:

- Ένα δισδιάστατο συνελικτικό νευρωνικό δίκτυο (CNN) για επεξεργασία εικόνας σε εικόνες περιγράμματος που εξάγονται από το σύνολο δεδομένων
- Ένα μονοδιάστατο συνελικτικό νευρωνικό δίκτυο για ανάλυση χρονοσειρών στο σύνολο δεδομένων.

Και οι δύο μέθοδοι εφαρμόστηκαν σε πραγματικά δεδομένα που συλλέχθηκαν και υποβάλλονται σε διαδικασία προ επεξεργασίας. Πραγματοποιούνται συγκρίσεις μεταξύ των δύο μοντέλων για τον προσδιορισμό των πλεονεκτημάτων και των αδυναμιών κάθε μοντέλου. Η προτεινόμενη μεθοδολογία αποδείχθηκε γρήγορη και αποτελεσματική, με αποτέλεσμα ένα αποτελεσματικό και ικανό σύστημα για την ανίχνευση αστοχίας με σχεδόν πραγματικό χρόνο.

2. Ειδικό Πρόβλημα και Μεθοδολογία

Για τη συλλογή των δεδομένων, χρησιμοποιήθηκε το σύστημα LAROS της Πρίσμα Ηλεκτρονικά. Αναλυτικότερα, οι «Έξυπνοι Συλλέκτες» εξασφαλίζουν μέσω ενός ασύρματου δικτύου μέσα στο σκάφος τη μετάδοση των επεξεργασμένων δεδομένων με ρυθμό δειγματοληψίας που καθορίζεται από το χρήστη και τη δυνατότητα να τα διατηρεί και να τα προσαρμόζει από απόσταση. Το εξεταζόμενο σκάφος της παρούσας μελέτης είναι πλοίο τύπου μπαλκ κάριερ.

Το δεδομένο σύνολο δεδομένων έπρεπε να υποβληθεί σε διαδικασία προ επεξεργασίας δεδομένων για να βελτιώσει την ποιότητα των δεδομένων που εισήχθησαν στα νευρικά δίκτυα, καθώς έχει αποδειχθεί ότι η εκπαίδευση μοντέλων βαθιάς μάθησης χρησιμοποιώντας ακατέργαστα δεδομένα είναι μια προβληματική προσέγγιση. Επιπλέον, τα χαρακτηριστικά του υπό-μελέτη σκάφους είναι τα εξής:

- Μήκος = 300.00
- Πλάτος = 50.00 (m)
- Βάθος = 25.00 (m)

Το σύνολο δεδομένων αντικατοπτρίζει το προφίλ του σκάφους σε διάστημα 32 μηνών. Επιπλέον, το σήμα κάθε παραμέτρου αποτελείται ρητά από τον ίδιο αριθμό παρατηρήσεων. Πριν από οποιαδήποτε προ επεξεργασία στο σύνολο δεδομένων, κάθε παράμετρος περιείχε 1.382.400 σημεία δεδομένων. Ωστόσο, όπως θα περιγραφεί, η εκπαίδευση ενός μοντέλου βαθιάς μάθησης με ακατέργαστα δεδομένα έχει αποδειχθεί ότι είναι μια προβληματική προσέγγιση, επομένως εφαρμόστηκε ένας αγωγός προ επεξεργασίας. Ακολουθώντας αυτήν τη διαδικασία, το σύνολο δεδομένων περιλάμβανε 886.449 για κάθε παράμετρο. Επίσης, οι παράμετροι που απαρτίζουν το dataset είναι αρχικά 10 ενώ έπειτα από την διαδικασία της προ επεξεργασίας των δεδομένων θα δημιουργηθούν επιπλέον 3.

Στο πλαίσιο της μελέτης μας, επιδιώκεται να αναπτυχθούν συστήματα Condition Based Monitoring (CBM) που παρακολουθούν την κατάσταση του υπό μελέτη σκάφους και εντοπίζουν ύποπτα μοτίβα που υποδεικνύουν την προδιάθεση της αποτυχίας. Δύο ξεχωριστές εφαρμογές εξετάζονται με διαφορετικούς χρονικούς ορίζοντες επιθεώρησης. Πιο

συγκεκριμένα, το πρώτο σύστημα πραγματοποιεί μια βραχυπρόθεσμη επιθεώρηση αστοχίας, παρακολουθώντας το σήμα της θερμοκρασίας καυσαερίων των κυλίνδρων του κύριου κινητήρα, προσπαθώντας να ανιχνεύσει σημάδια που υποδηλώνουν την εμφάνιση βλάβης της κύριας μηχανής. Αιτίες που προκαλούν τέτοιου είδους ζημιές είναι για παράδειγμα, υπό λίπανση σε έναν από τους κυλίνδρους του κύριου κινητήρα, που προκαλείται δυσμορφία αυτού του κυλίνδρου υπό συνθήκες υψηλής πίεσης και θερμοκρασίας. Αυτός ο τύπος δυσλειτουργίας που προκύπτει από την αστοχία της βλάβης στο σύστημα του κύριου κινητήρα εκφράζεται στο σήμα της θερμοκρασίας καυσαερίων των κυλίνδρων από το επαυξημένη διακύμανση στο σήμα.

Το δεύτερο σύστημα πραγματοποιεί ανίχνευση βλάβης με μακροπρόθεσμο ορίζοντα, προσπαθώντας να εντοπίσει σημάδια που υποδηλώνουν υποβάθμιση και εμφανίζονται σταδιακά. Αυτή η CBM εφαρμογή χρησιμοποιείται για την παρακολούθηση της αποτελεσματικότητας του σκάφους. Αυτή η έλλειψη ισχύος μπορεί να αποδοθεί σε πολλούς λόγους. Για παράδειγμα, μια εξέχουσα περίπτωση θα μπορούσε να είναι ένας εκφυλισμός στο κύτος ή στο σύστημα μετάδοσης κίνησης και έλικα άξονα του υπό μελέτη σκάφους. Στη σχετική βιβλιογραφία ο όρος αποδόμηση του «κύτους-έλικα» χρησιμοποιείται ευρέως επειδή στο πλαίσιο της ανάλυσης αποτελεσματικότητας η διάκριση μεταξύ των προαναφερθέντων συστημάτων είναι πολύ δύσκολη, συνεπώς θεωρείται η ένωση των δύο. Για παράδειγμα, τέτοιες περιπτώσεις υποβάθμισης θεωρούνται: αυξημένη τραχύτητα στο κύτος ή/και στην έλικα ως συνέπεια της διάβρωσης που εναλλάσσει την υφή της επιφάνειας του πλοίου με αποτέλεσμα την εναλλαγή του υδροδυναμικού σχήματος του πλοίου αυξάνοντας την αντίσταση στο νερό, προκαλώντας σημαντική επιδείνωση απόδοσης του πλοίου, καθώς η ώθηση μειώνεται και απαιτείται πολύ μεγαλύτερη κατανάλωση καυσίμου. Αυτή η κατάσταση υποδηλώνει ότι απαιτείται παραγωγή περισσότερης ισχύος για το σκάφος να διατηρεί την ίδια ταχύτητα και, στη συνέχεια, πρέπει να καταναλώνεται περισσότερο μαζούτ προκειμένου να διατηρηθεί το ίδιο λειτουργικό προφίλ. Στη μελέτη μας, η έκφραση για την απόδοση του πλοίου παρέχεται από ένα παράγωγο χαρακτηριστικό. Αυτή η παράμετρος είναι ο συντελεστής Heickel που αποτελεί έκφραση της απόδοσης του πλοίου.

Στη μελέτη μας, τα δύο συστήματα CBM υλοποιούνται με 2 μοντέλα CNN που αξιολογούν διαφορετικές πτυχές το λειτουργικού προφίλ του υπό μελέτη πλοίου. Το πρώτο είδος είναι ένα μονοδιάστατο CNN που αναλαμβάνει την παρακολούθηση της κατάστασης του κύριου κινητήρα ελέγχοντας το σήμα της θερμοκρασίας καυσαερίων των κυλίνδρων του κύριου κινητήρα. Αυτό το σύστημα CBM διευκολύνει την εφαρμογή μιας βραχυπρόθεσμης προσέγγισης, καθώς οι χρονοσειρές μπορούν να χωριστούν σε μικρότερες παρτίδες χωρίς να επηρεαστεί αρνητικά η απόδοση του μοντέλου. Σε αυτήν την περίπτωση, προσπαθούμε να ταξινομήσουμε το σήμα που λαμβάνεται από τη θερμοκρασία καυσαερίων των 6 κυλίνδρων του κύριου κινητήρα του πλοίου, εντοπίζοντας απόκλιση από την υγιή κατάσταση, που προκαλείται από υποβάθμιση και φθορά. Αυτή η μορφή ανεπάρκειας εκφράζεται τυπικά ως αυξημένη διακύμανση του παρακολουθούμενου σήματος.

Το δεύτερο είδος είναι ένα δισδιάστατο CNN που παρακολουθεί την αποτελεσματικότητα του πλοίου επιθεωρώντας εικόνες που αντιπροσωπεύουν την απόδοση του πλοίου, προσπαθώντας να εντοπίσει την υποβάθμιση. Σε αυτό το μοντέλο παρέχονται διαγράμματα τύπου contours ως είσοδος, και επιχειρείται να εκπαιδευτεί τα μοντέλα να αναγνωρίσουν μοτίβα υποβάθμισης της αποδοτικότητας του σκάφους. Αυτό θεωρείται μια τεχνική ταυτοποίησης μακροπρόθεσμης βλάβης, καθώς η χρήση περιγραμμάτων contours επιτρέπει την αναπαράσταση πληροφοριών που αντιστοιχούν σε

ευρύτερα χρονικά παράθυρα, ενώ επίσης ο σχηματισμός τους απαιτεί την ενσωμάτωση επαρκών πληροφοριών, για να καταστεί το γράφημα ουσιαστικό.

Μια σημαντική πρόκληση προκύπτει από την υπόθεση ότι το σύνολο δεδομένων που αποκτήθηκε από το LAROS CMS αντιπροσώπευε το υπό μελέτη σκάφος όταν ήταν σε υγιή κατάσταση, χωρίς σημάδια φθοράς ή υποβάθμισης. Ωστόσο, η ύπαρξη παρατηρήσεων που αντικατοπτρίζουν κάθε κατάσταση που επιδιώκεται να αναγνωριστεί από το δίκτυο είναι απαραίτητη στο πλαίσιο των εργασιών ταξινόμησης, καθώς τα δίκτυα απαιτούν εκπαίδευση σε κάθε κατάσταση που θα τους ζητηθεί να αξιολογήσουν. Επομένως, η τεχνητή επαγόμενη υποβάθμιση έπρεπε να προκληθεί για να προσομοιώσει με ρεαλιστικό τρόπο τα ελαττωματικά μοτίβα που συναντώνται σε πραγματικές εφαρμογές. Στο πλαίσιο αυτής της μελέτης, τα δύο είδη CNN επιθεωρούν διαφορετικούς τύπους υποβάθμισης, συνεπώς σχεδιάστηκαν και χρησιμοποιήθηκαν δύο τύποι βλαβών.

Για το πρώτο είδος του CNN, για την περίπτωση της βραχυπρόθεσμης ανίχνευσης φθοράς μέσω της εφαρμογής 1D CNN, ένα λευκό σήμα θορύβου υπεισέρχεται στο αρχικό σήμα ενός κυλίνδρου εκδηλώνοντας τα μοτίβα υποβάθμισης. Η μέση τιμή του λευκού σήματος θορύβου είναι ίση με την αντίστοιχη τιμή του σήματος που λειτουργεί σωστά, δηλαδή την τιμή που θα είχε αν δεν είχαμε παρέμβει, και η τυπική απόκλιση του είναι ίση με το πολλαπλάσιο του τυπική απόκλιση του υγιούς σήματος του αντίστοιχου χαρακτηριστικού. Με άλλα λόγια, ο λευκός θόρυβος που ρυθμίζεται διέπεται από μια κατανομή

$$W.N. \sim N(i.s., k * \sigma_{i.s.})$$

Όπου *i.s.* σημαίνει το αρχικό σήμα της παραμέτρου που μεταβάλλεται, σ είναι η τυπική απόκλιση αυτής της συγκεκριμένης παραμέτρου σε ολόκληρο το σύνολο δεδομένων και το k είναι ο παράγοντας που πολλαπλασιάζεται με την τυπική απόκλιση, η οποία προκαλεί τον πληθωρισμό του αρχικού σήματος που προσπαθούμε να εντοπίσουμε. Οι επιθεωρούμενες τιμές του συντελεστή πληθωρισμού είναι 1%, 2% και 5%.

Στη συνέχεια, η επαγόμενη αποδόμηση προσπαθεί να μοιάζει με σταδιακό σταθερό εκφυλισμό της αποτελεσματικότητας του αγγείου. Για το θέμα αυτό, χρησιμοποιείται ο συντελεστής Heickel που έχει εισαχθεί σε προηγούμενη παράγραφο. Αυτή η παράμετρος ουσιαστικά είναι μια μη διαστασιολογημένη μορφή έκφρασης της απόδοσης του σκάφους. Επομένως, το σήμα του συντελεστή Heickel μετατοπίζεται πολλαπλασιάζοντάς το με έναν σταθερό συντελεστή $k < 1$, υποδηλώνοντας πτώση $(1-k)\%$ της απόδοσης. Στοχεύοντας να παρουσιάσουμε μια παραμετρική μεθοδολογία, να αναγνωρίσουμε με επιτυχία τα ύποπτα μοτίβα που δείχνουν την αποτυχία, θα δοκιμαστούν πολυάριθμες τιμές για να επιτευχθεί καλύτερη κατανόηση της επίδρασης του βαθμού υποβάθμισης στην αποτελεσματικότητα του μοντέλου και της ικανότητάς του να αναγνωρίζει την ύπαρξη βλάβης. Οι τιμές k που ελέγχθηκαν στην παραμετρική μελέτη ήταν 2%, 5% και 10%.

Στη συνέχεια, απαιτείται η τμηματοποίηση των σημάτων του συνόλου δεδομένων σε μικρότερες παρτίδες για να σχηματιστούν τα δείγματα που λαμβάνουν τα CNN. Και στις δύο περιπτώσεις μελέτης, το σύνολο δεδομένων διαιρείται, σε σχέση με ένα χρονικό παράθυρο που δημιουργεί συστάδες δεδομένων που θα χρησιμοποιηθούν είτε με τη μορφή δειγμάτων χρονοσειρών, τροφοδοτούμενα στα μονοδιάστατα CNN, είτε αποτελούν τη βάση για τη δημιουργία εικόνων contours, που είναι η είσοδος για τα δισδιάστατα CNN. Αυτή η τμηματοποίηση πραγματοποιείται σε σχέση με ένα συγκεκριμένο χρονικό πλαίσιο, το οποίο σε κάθε παρουσία υλοποίησης παραμένει σταθερό, με αποτέλεσμα παρτίδες σταθερού μήκους. Επηρεάζει εγγενώς τον αριθμό των διαθέσιμων δειγμάτων για την εκπαίδευση και

τη δοκιμή των μοντέλων, καθώς και την ποσότητα των επιχειρησιακών πληροφοριών που ενσωματώνονται σε κάθε δείγμα. Σε κάθε περίπτωση μελέτης χρησιμοποιήθηκαν πολλαπλά παράθυρα εισόδου για να εξεταστεί η επίδρασή της στην αποτελεσματικότητα του μοντέλου

Έτσι λοιπόν συμπεραίνεται πως θα εξετασθούν στο πλαίσιο παραμετρικής έρευνας, για τον προσδιορισμό της επίδρασης των παραπάνω παραμέτρων στην αποτελεσματικότητα των μοντέλων. Πιο συγκεκριμένα, διεξάγεται η εκπαίδευση των μοντέλων με τον διαφορετικό βαθμό επαγόμενης υποβάθμισης καθώς και η εκπαίδευση των μοντέλων με το διαφορετικό παράθυρο τμηματοποίησης.

Στο πλαίσιο βελτιστοποίησης κάθε ανεπτυγμένου μοντέλου ο κύριος στόχος είναι η ελαχιστοποίηση της λειτουργίας απώλειας, προκειμένου να επιτευχθούν ακριβείς και σίγουρες προβλέψεις για την κατάσταση του σκάφους. Για αυτό το θέμα, μια άλλη πρόκληση που προκύπτει, από την εφαρμογή μοντέλων βαθιάς μάθησης, είναι η επιλογή των υπερπαραμέτρων. Αυτή η διαδικασία αναγνωρίζεται ως μια σημαντική εργασία που επηρεάζει βαθιά την απόδοση του μοντέλου, αν και επίσης απαιτητική και χρονοβόρα, καθώς τα CNN χαρακτηρίζονται από ένα ποικιλόμορφο σύνολο υπερπαραμέτρων που πρέπει να συντονιστούν κατάλληλα για να ολοκληρώσουν τη βέλτιστη διαμόρφωση που επιτυγχάνει βελτιστοποίηση της παραγόμενης ακρίβειας.

Αφού ολοκληρωθεί τη διαδικασία βελτιστοποίησης μοντέλου, θα προσδιοριστεί η διαμόρφωση των υπερπαραμέτρων που επιτυγχάνει τα καλύτερα αποτελέσματα σε κάθε περίπτωση. Οι βαθμολογίες των βέλτιστων μοντέλων από κάθε παρουσία χρησιμοποιούνται για τη λήψη αποτελεσμάτων σχετικά με την αποτελεσματικότητα της προτεινόμενης μεθοδολογίας με μεταβλητό παράθυρο εισόδου και βαθμό υποβάθμισης. Τέλος, τα αποτελέσματα που ελήφθησαν από την προτεινόμενη μεθοδολογία συγκρίνονται με άλλους ταξινομητές μηχανικής μάθησης. Πιο συγκεκριμένα, οι ταξινομητές που χρησιμεύουν ως σημείο αναφοράς είναι:

1. Support Vector Classifier
2. Random Forest Classifier

Το πλεονέκτημα της χρήσης μοντέλων βαθιάς μάθησης συνελκτικού τύπου έγκειται στο γεγονός ότι τα CNN μπορούν να χρησιμοποιηθούν για την αναγνώριση χαρακτηριστικών να μάθουν, χωρίς να χρειάζεται να διαλεχθούν χειρωνακτικά τα χαρακτηριστικά στα οποία ο αλγόριθμος πρέπει να εκπαιδευτεί, κάτι που πολλές φορές μπορεί να αποδειχθεί πως είναι δύσκολο έργο. Η προτεινόμενη μεθοδολογία είναι ένας γρήγορος και αποτελεσματικός αλγόριθμος που βασίζεται στους δύο προαναφερθέντες τύπους νευρωνικών δικτύων, λόγω της ικανότητας του μοντέλου να ταξινομεί τα σήματα απόκρισης με ακρίβεια χωρίς να απαιτούν σημαντικές διαδικασίες μετά την επεξεργασία, κατά συνέπεια, με αποτέλεσμα ένα αποτελεσματικό και ικανό σύστημα για αποτυχία ανίχνευση με σχεδόν πραγματικό χρόνο. Από αυτή την άποψη, μια φιλοδοξία της μελέτης μας είναι να αναπτύξουμε δύο είδη νευρωνικών δικτύων που επιτυγχάνουν μόνο αξιοσημείωτα αποτελέσματα σε όρους ακατέργαστων αριθμών, αλλά επίσης καταφέρνουν να ξεπεράσουν άλλους καθιερωμένους αλγόριθμους ταξινόμησης μηχανικής μάθησης, ισχυριζόμενοι προφανώς την υπεροχή προτεινόμενη μεθοδολογία

3. Καθαρισμός Δεδομένων

Η προ επεξεργασία δεδομένων είναι ένα βήμα της προσπάθειας δημιουργίας μοντέλων με μεγάλη σημασία. Παρόλο που τα βαθιά νευρωνικά δίκτυα μπορούν να εκτελούν εργασίες

ταξινόμησης από την εισαγωγή ακατέργαστων δεδομένων, συνιστάται ιδιαίτερα η τεχνική να καθαρισθούν πρώτα τα δεδομένα προτού τροφοδοτηθούν στο μοντέλο. Τα δεδομένα είναι συχνά ελλιπή, ασυνεπή και είναι πιθανό να περιέχουν πολλά σφάλματα. Επιπλέον, είναι ένα αρκετά κοινό φαινόμενο, ότι κάθε φορά που συλλέγονται δεδομένα από πολλές πηγές, το σύνολο δεδομένων αποτελείται από εσφαλμένες ή / και ελλείπουσες τιμές, οι οποίες πρέπει να απορριφθούν ή να διορθωθούν. Η εκπαίδευση του μοντέλου σε ανεπεξέργαστα δεδομένα έχει αποδειχθεί ότι αποτελεί αμφισβητήσιμη και προβληματική προσέγγιση στην ανάλυση βάσει δεδομένων, και αποπροσανατολίζει και παραπλανά τον βελτιστοποιητή, κατά τη διάρκεια του σταδίου βελτιστοποίησης, μακριά από το παγκόσμιο ελάχιστο. Στην προεπεξεργασία δεδομένων τέτοια ζητήματα αντιμετωπίζονται, καθώς τα ανεπεξέργαστα δεδομένα είναι έτοιμα να υποβληθούν σε περαιτέρω επεξεργασία μέσω μιας σειράς βημάτων που διασφαλίζουν ότι η βέλτιστη ποιότητα δεδομένων είναι ένα εξαιρετικά σημαντικό θέμα. Ενώ ο κύριος στόχος μας είναι να βελτιώσουμε το σύνολο δεδομένων, στοχεύουμε επίσης να διατηρήσουμε τη διάστασή του όσο το δυνατόν μεγαλύτερη.

Η απόδοση του πλοίου είναι ένα πρόβλημα πολλαπλών παραλλαγών με πολλές μεταβλητές που επηρεάζουν διάφορες πτυχές του. Οι παράμετροι που εμφανίζονται στην ίδια κατηγορία εμφανίζουν παρόμοια συμπεριφορά σε σχέση με το χρόνο. Εν γένει παρατηρούνται 3 κατηγορίες που θα μπορούσαν να διακριθούν εύλογα οι παράμετροι του πλοίου:

1. Λειτουργικές παραμέτρους που σχετίζονται με τη λειτουργία και την αποδοτικότητα του σκάφους,
2. Παραμέτρους κατάστασης φόρτωσης που σχετίζονται με το βάρος του φορτίου και τον τρόπο διανομής του στο πλοίο
3. Περιβαλλοντικές παράμετροι, σχετικά με τα περιβάλλοντα του σκάφους.

Ο καθαρισμός των δεδομένων απαρτίζεται από τα εξής 5 βήματα:

1. Φιλτράρισμα
2. Συμπλήρωση ή απομάκρυνση ελλειπουσών τιμών
3. Απομάκρυνση ακραίων τιμών
4. Εξομάλυνση των σημάτων
5. Δημιουργία νέων παραμέτρων

3.1 Φιλτράρισμα

Η αρχή της διαδικασίας διασφάλισης της βέλτιστης ποιότητας των δεδομένων αφορά μια σειρά φίλτρων που εφαρμόζονται στο σύνολο δεδομένων για τη διατήρηση μόνο των επιθυμητών τμημάτων του συνόλου δεδομένων, που θεωρούνται πιο χρήσιμα για την εκπαίδευση των δικτύων πάνω σε αυτά. Επί παραδείγματι, είναι επιθυμητό να αντικατοπτρίζεται από το σύνολο δεδομένων το πλοίο εν πλω σε ανοιχτή θάλασσα.

3.2 Συμπλήρωση ή απομάκρυνση ελλειπουσών τιμών

Για αυτήν την ανάλυση, η επιλεγμένη διαδρομή επιλέγεται ένας συνδυασμός μεθόδων. Πρώτα, εφαρμόζεται ένας μηχανισμός συμπλήρωσης, προκειμένου να γεμίσει όσο το δυνατόν περισσότερα κενά σημεία και να διατηρηθούν όσο το δυνατόν περισσότερα σημεία δεδομένων. Για παράδειγμα, διαπιστώθηκε ότι η παράμετρος της ταχύτητας του πλοίου

συνίστατο από πολλές ελλείπουσες τιμές, επομένως η απόρριψη των παρατηρήσεων συμπεριλαμβανομένων των μετρήσεων που λείπουν θα επηρέαζε βαθιά το σύνολο δεδομένων μας και η διάσωση όσο το δυνατόν περισσότερων δειγμάτων ήταν μια σημαντική εργασία που πρέπει να αντιμετωπιστεί .

Ο προτεινόμενος μηχανισμός υπολογισμού είναι ελαφρώς πιο περίπλοκος από την αντικατάσταση με το μέσο όρο. Λαμβάνοντας υπόψη τη δυναμική των πλοίων, τη συχνότητα δειγματοληψίας του συνόλου δεδομένων μας, καταλήξαμε σε έναν έγκυρο μηχανισμό υπολογισμού, υποθέτοντας ότι σε σύντομο χρονικό διάστημα λίγων λεπτών οι τιμές που λείπουν θα μπορούσαν να προσεγγιστούν γραμμικά χρησιμοποιώντας όρια γνωστών τιμών. Επομένως, συμπληρώσαμε τα κενά σημεία παρεμβάλλοντας γραμμικά μεταξύ των τιμών που πέτυχαν και προχωρήσαμε στη σειρά των τιμών που λείπουν, σε περιοχές του συνόλου δεδομένων με λιγότερες από 15 διαδοχικές τιμές που λείπουν. Για να είμαστε πιο σαφείς, σε περιπτώσεις όπου η συσκευή παρακολούθησης δεν καταγράφει τη μέτρηση για έως και 15 λεπτά, ο προτεινόμενος μηχανισμός μας μπορεί να διορθώσει αυτήν την ανεπάρκεια. Οι υπόλοιπες παρατηρήσεις που περιέχουν μια τιμή που λείπει απορρίφθηκαν από το σύνολο δεδομένων

3.3 Απομάκρυνση ακραίων τιμών

Το επόμενο βήμα στη διαδικασία προ επεξεργασίας είναι ο εντοπισμός και, στη συνέχεια, η απομάκρυνση των ακραίων τιμών. Οι ακραίες τιμές είναι ακραίες τιμές που αποκλίνουν σημαντικά από άλλες παρατηρήσεις. Με άλλα λόγια, ένα ακραίο σημείο είναι μια ανώμαλη παρατήρηση που αποκλίνει από ένα συνολικό μοτίβο και βρίσκεται πολύ μακριά από άλλες τιμές. Η εμφάνιση των ακραίων τιμών μπορεί να αποδοθεί σε πολλούς λόγους, όπως δυσλειτουργίες συσκευών παρακολούθησης ή / και ανεπάρκεια κατά τη διαδικασία μετάδοσης δεδομένων. Είναι σίγουρα μια καλή πρακτική να απορρίπτουμε τέτοιες παρατηρήσεις, που περιέχουν λανθασμένες μετρήσεις από το σύνολο δεδομένων, καθώς δεν σχετίζονται με τις στατιστικές κατανομές που εν γένει διέπουν το σύνολο δεδομένων μας, τείνοντας έτσι να αποπροσανατολίζουν τη διαδικασία βελτιστοποίησης των μοντέλων.

Για την αφαίρεση αυτών των τιμών απαιτείται ο υπολογισμός των τιμών z για τα δείγματα των παραμέτρων που μας βοηθά να τα τοποθετήσουμε κάτω από το κατανομή Gauss. Με αυτόν τον τρόπο, οι τιμές που βρίσκονται στην ουρά της κατανομής εύλογα θεωρούνται ακραίες τιμές.

Πιο συγκεκριμένα, η εφαρμοζόμενη διαδικασία είναι η ακόλουθη:

1. Η επιλογή μίας παραμέτρου που θεωρείται ότι έχει μεγάλη σημασία για τη μελέτη μας. Για παράδειγμα οι στροφές της κύριας μηχανής του πλοίου επιλέγονται ως η κύριο παράμετρος μας και στην συνέχεια ακολουθεί τμηματοποίηση με βάση αυτή την παράμετρο αναφορικά με τις τιμές του. (πχ, ανά 5 RPM)
2. Κάθε παρατήρηση ανατίθεται στο αντίστοιχο διάστημα ακολουθώντας την τιμή της πρωτεύουσας παραμέτρου.
3. Υπολογίζεται η μέση και τυπική απόκλιση των δευτερευόντων παραμέτρων σε κάθε ομάδα δεδομένων. (Εστω τα μ , σ υποδηλώσουν τη μέση και την τυπική απόκλιση αντίστοιχα)
4. Αυθαίρετα επιλεγμένος συντελεστής k , με τον οποίο πολλαπλασιάζεται η τυπική απόκλιση, θέτοντας ένα κατώτατο και ανώτατο όριο. Στην περίπτωσή μας η

επιλεγμένη τιμή ήταν 3, η οποία αντιστοιχεί σε ένα σχετικά μέτριο κριτήριο ανίχνευσης ακραίων τιμών.

5. Η ανισότητα για κάθε σημείο δεδομένων που ακολουθεί καθορίζει εάν το δεδομένο σημείο δεδομένων είναι μια ακραία τιμή.

$$| (data_point) - m | > k * s$$

3.4 Εξομάλυνση σήματος

Στους τομείς της στατιστικής μάθησης, η εξομάλυνση του συνόλου δεδομένων είναι κοινή πρακτική. Ο σκοπός της εφαρμογής οποιασδήποτε λειτουργίας προσέγγισης είναι να εξομαλύνει τυχόν βραχυπρόθεσμες διακυμάνσεις, ενώ εξακολουθεί να περιλαμβάνει βασικά μοτίβα, ή αντίστοιχα στοχεύεται η αύξηση της αναλογίας του σήματος έναντι θορύβου. Επομένως, το επόμενο βήμα της διαδικασίας της προ επεξεργασίας των δεδομένων αφορά την εξομάλυνση του σήματος εφαρμόζοντας τον αλγόριθμο του Απλού Κινούμενου Μέσου Όρου (Simple Moving Average -- SMA). Το SMA είναι ένας μη σταθμισμένος μέσος όρος των τελευταίων n δειγμάτων και επειδή η συχνότητα δειγματοληψίας παραμένει σταθερή, ο αριθμός των τελευταίων n δειγμάτων συμπίπτει με το χρονικό παράθυρο του κυλιόμενου μέσου. Μια σημαντική πτυχή αυτής της διαδικασίας είναι η επιλογή του κατάλληλου μεγέθους παραθύρου εξομάλυνσης. Στη σχετική βιβλιογραφία, χρησιμοποιούνται πολύ συχνά χρονικά διαστήματα 10 έως 15 λεπτών. Στην περίπτωση χρήσης μας, για να προσδιορίσουμε την καλύτερη επιλογή για ένα χρονικό διάστημα, πειραματιστήκαμε με πολλές τιμές και εξετάστηκε η ικανότητά τους να εξαλείψουν το θόρυβο που υπάρχει στο σύνολο δεδομένων, διατηρώντας παράλληλα όσο το δυνατόν περισσότερες πληροφορίες και βασικά μοτίβα από το αρχικό σύνολο δεδομένων.

Δεδομένου ότι ο θόρυβος αφαιρείται εν μέρει με την εφαρμογή του αλγορίθμου SMA, εγγενώς η διακύμανση του μειώνεται. Ωστόσο, ένα μέρος των αρχικών πληροφοριών χάνεται και αυξάνεται η μεροληψία του εκτιμητή, δηλαδή, η διαφορά μεταξύ της εκτιμώμενης και της πραγματικής τιμής της παραμέτρου που εκτιμάται. Ως εκ τούτου, είναι γενικά επιθυμητό να διατηρείται το παράθυρο σχετικά μικρό για να καταγράφονται αλλαγές στη δυναμική του σκάφους και πώς επηρεάζουν την απόδοσή του, αλλά και αρκετά μεγάλο ώστε να εξαλείφεται μεγάλο μέρος της αστάθειας που σχετίζεται με τον θόρυβο. Συγκρίνοντας το αρχικό σήμα με το αντίστοιχο εξομαλυνόμενο για διάφορες τιμές παραθύρου μέσου όρου, καταλήξαμε ότι το παράθυρο λαμβάνοντας το μέσο όρο των 15 λεπτών είναι επαρκές, αφαιρώντας το μεγαλύτερο μέρος του θορύβου, ενώ ταυτόχρονα καταφέρουμε να περιορίσουμε την απώλεια πληροφοριών και να είμαστε ικανοί να παρακολουθούμε ικανοποιητικά τις τοπικές τάσεις.

Δημιουργία νέων παραμέτρων

Αν και στην περίπτωση των μονοδιάστατων CNN, οι παρτίδες χρονοσειρών αποτελούν τα δείγματα εισόδου που τροφοδοτούνται απευθείας στα δίκτυα, τα 2D CNN απαιτούν περαιτέρω προκαταρκτική προετοιμασία για την κατασκευή των δειγμάτων εικόνας. Η απουσία δεδομένων υψηλής συχνότητας κατέστη την επιλογή σπεκτρογραμμάτων, μεταφέροντας τα δεδομένα στο πεδίο συχνοτήτων, μη εφικτή επιλογή. Η εναλλακτική λύση για τις εικόνες εισόδου στο 2D μοντέλο προήλθε από σχετική βιβλιογραφία, όπου στη θαλάσσια μηχανική είναι μια μάλλον κοινή τεχνική μέσω της δημιουργίας contours. Δημιουργούνται νέες παράμετροι για την αναπαράσταση των λειτουργιών του σκάφους,

όπου επιχειρείται να παρέχουμε ολοκληρωμένη αναπαράσταση της αποτελεσματικότητας του πλοίου μέσω αυτών των διαγραμμάτων και να εκπαιδεύσουμε τα μοντέλα να εντοπίσουν contours που αντιπροσωπεύουν ένα υγιές σκάφος ή αντίστροφα ένα σκάφος που υποδεικνύει μοτίβα που σχετίζονται με την υποβάθμιση. Η δημιουργία των περιγραμμάτων περιγράμματος απαιτεί 4 επιπλέον παραμέτρους. Η διαδικασία δημιουργίας χαρακτηριστικών είναι το τελευταίο βήμα της διαδικασίας προεπεξεργασίας και καθαρισμού δεδομένων. Η μηχανική των παραμέτρων (Feature Engineering) είναι η διαδικασία εφαρμογής τεχνογνωσίας τομέα για τη δημιουργία νέων δυνατοτήτων ή / και την εξάλειψη περιττών χαρακτηριστικών. Στην περίπτωση της μελέτης μας, χρειαζόμασταν να δημιουργήσουμε νέες μεταβλητές που είναι απαραίτητες για τη δημιουργία των περιγραμμάτων που θα είναι η είσοδος των δισδιάστατων συνελικτικών δικτύων.

- Συντελεστής Heickel: $Heickel = V \left(\frac{\sqrt{\Delta}}{P} \right)^{1/3}$, όπου V είναι η ταχύτητα του δοχείου, το P είναι η προωστική ισχύς και το Δ είναι η μετατόπιση του νερού.
- Αριθμός Froude: $Fr = \frac{V}{\sqrt{gL_w}}$, όπου g είναι η επιτάχυνση της βαρύτητας και Lw είναι το μήκος της γραμμής νερού του σκάφους.
- Διαφορά Βύθισης μπροστινού και πίσω μέρους του σκάφους:

$$\text{Trim} = (\text{Draft Aft}) - (\text{Draft Fore})$$
- State: Δείχνει την κατάσταση λειτουργίας του σκάφους Κατά την εφαρμογή των 2D CNNs, χρησιμοποιείται ως δυαδική μεταβλητή, όπου η τιμή 0 μηδέν υποδεικνύει ένα λειτουργικό προφίλ λειτουργίας του σκάφους και αντίστροφα η τιμή του 1 υποδηλώνει ελαττωματική απόδοση. Με την ευκαιρία των 1D CNN, χρησιμοποιείται ως μεταβλητή πολλαπλών κλάσεων, όπου επίσης η τιμή των 0 μηδέν δείχνει ότι δεν έχει ανιχνευθεί υποβάθμιση και οι τιμές 1-6 δείχνουν ότι ο αντίστοιχος κύλινδρος έχει καταδείξει ελαττωματικά μοτίβα.

4. Αποτελέσματα νευρωνικών δικτύων

Τυπικά, τα συνελικτικά νευρωνικά δίκτυα αποτελούνται από τα συνελικτικά στρώματα που αναλαμβάνουν το έργο της αναγνώρισης χαρακτηριστικών στα δείγματα που θα βοηθήσουν στην συνέχεια την ταξινόμηση τους, αλλά και τα κλασικά πλήρως συνδεδεμένα προστροφοδοτούμενα δίκτυα που είναι υπεύθυνα για το έργο της ταξινόμησης λαμβάνοντας τα χρήσιμα χαρακτηριστικά από τα συνελικτικά στρώματα. Βέβαια, αυτά τα στοιχεία των δικτύων περιλαμβάνουν κάποιες χαρακτηριστικές παραμέτρους των οποίων οι τιμές πρέπει να καθορισθούν πριν την έναρξη της εκπαίδευσης των δικτύων. Αυτές οι παράμετροι λέγονται υπερπαραμέτροι.

Ο καθορισμός των μοντέλων υπερπαραμέτρων είναι μια δύσκολη υπόθεση. Είναι πολύ γνωστό ότι η επιλεγμένη διαμόρφωση των υπερπαραμέτρων έχει πολύ ισχυρό αντίκτυπο στην αποτελεσματικότητα του μοντέλου, επομένως είναι ένα θέμα που καλύπτεται διεξοδικά και εξετάζεται σε αυτήν τη μελέτη και για αυτό το λόγο δόθηκε μεγάλη έμφαση στην μελέτη μας για την εύρεση της σωστής ρύθμισης τιμών τους. Το πλήθος των

συνδυασμών καθιστά εμφανές ότι ο χειροκίνητος έλεγχος για την καλύτερη διαμόρφωση δεν είναι πρακτικός. Επομένως, απαιτείται ένας αυτοματοποιημένος αλγόριθμος για αυτήν την προσπάθεια. Δύο πολύ ευρέως γνωστοί και χρησιμοποιημένοι αλγόριθμοι για το σκοπό αυτό είναι η αναζήτηση πλέγματος και η τυχαιοποιημένη αναζήτηση, που συνεπάγονται και τα πλεονεκτήματα και τις αδυναμίες τους. Πιο συγκεκριμένα, ενώ η αναζήτηση πλέγματος αναζητά διεξοδικά το βέλτιστο σε ολόκληρο το επίπεδο υπερπαραμέτρων, θεωρείται ότι είναι πολύ πιο υπολογιστικά απαιτητικό από την τυχαιοποιημένη αναζήτηση, η οποία, από την άλλη πλευρά, εκτελεί n διευρυνήσεις, όπου το n καθορίζεται από τον χρήστη, ωστόσο, δεν εγγυάται την εύρεση της καλύτερης ρύθμισης. Ο πειραματισμός και με τους δύο αλγόριθμους μας ώθησε να αποφασίσουμε ότι η αναζήτηση πλέγματος είναι υπολογιστικά προσιτή και έτσι επιλέχθηκε. Ανεξάρτητα από τον τύπο του συνελκτικού δικτύου, η ακολουθούμενη προσέγγιση για την προσπάθεια ανάπτυξης δικτύου παραμένει η ίδια και οι ενέργειες που λαμβάνονται για τη ρύθμιση οποιουδήποτε δικτύου που παρουσιάζεται σε αυτό το κεφάλαιο παρατίθενται παρακάτω:

1. Για αυτά τα προβλήματα ταξινόμησης, η σχετική βιβλιογραφία έχει δείξει ότι ο βελτιστοποιητής «Adam» θεωρείται ως η καλύτερη επιλογή. Επιπλέον, και πάλι από τη σχετική βιβλιογραφία, καθώς και από την TensorFlow, οι συνιστώμενες επιλογές για τη συνάρτηση ενεργοποίησης του τελευταίου κρυφού στρώματος και τη συνάρτηση απώλειας επιλέγονται. Πιο συγκεκριμένα, σε προβλήματα ταξινόμησης, η ενδεικνυόμενη συνάρτηση ενεργοποίησης είναι η SoftMax που επιστρέφει την πιθανότητα να ισχύει καθεμία από τις πιθανές καταστάσεις. Επίσης, για την επιλογή συνάρτησης απωλειών επιλέγεται η categorical cross-entropy για την ποσοτικοποίηση των αποκλίσεων μεταξύ των εκτιμήσεων των μοντέλων μας και των πραγματικών τιμών.

2. Αφού καθορισθούν οι υπερπαραμέτροι που δεν θα εξεταστούν, ξεκινά η διερεύνηση των υπερπαραμέτρων που θα εξεταστούν. Ελέγχονται τα πρώτα δομικά χαρακτηριστικά, όπως το πλήθος κάθε κατηγορίας στρωμάτων, δηλαδή τα συνελκτικά, συγκέντρωσης και τα πλήρως συνδεδεμένα, που συναντώνται στο μοντέλο, καθώς και ο αριθμός κόμβων ανά στρώμα πλήρως συνδεδεμένων στο προστροφοδοτούμενο, καθώς και η διάσταση των παραθύρων που σαρώνουν την είσοδο στα στρώματα συνέλιξης και συγκέντρωσης. Κατά τη διάρκεια αυτής της πρώτης διερεύνησης, επιλέχθηκαν αρχικές τιμές για το ποσοστό εκμάθησης, τον αριθμό των εποχών και το μέγεθος της παρτίδας, μετά από μικρό πειραματισμό και υλοποίηση συστάσεων από την σχετική βιβλιογραφία.

3. Έχοντας καταλήξει στις βέλτιστες τιμές των υπερπαραμέτρων που σχετίζονται με τη δομή, το υπόλοιπο του συνόλου υπερπαραμέτρων επανεξετάζεται, δηλαδή το ποσοστό εκμάθησης, το μέγεθος παρτίδας και τον αριθμό των εποχών.

Όπως αναφέρθηκε προηγουμένως, όταν εκπαιδεύουμε ένα μοντέλο, το βασικό μας μέλημα είναι η ελαχιστοποίηση της συνάρτησης απωλειών εξασφαλίζοντας ένα δίκτυο, το οποίο παράγει εκτιμήσεις με αρκετή βεβαιότητα και στη συνέχεια μέσω αποτελεσματικής εκπαίδευσης οδηγεί επίσης σε ένα ακριβές μοντέλο. Ωστόσο, η ερμηνεία της categorical cross-entropy είναι μια δύσκολη εργασία και λιγότερο διαισθητική από την ερμηνεία των άλλων μετρήσεων που προσφέρουν καλύτερη αντίληψη για την προσπάθεια βελτιστοποίησης. Ως εκ τούτου, αποφασίζεται να βασιστεί η βέλτιστη διαμόρφωσή μας και στην ακρίβεια που αποδίδεται από κάθε διάταξη.

4.1 1D CNN

Σε αυτό το σημείο παρουσιάζονται τα αποτελέσματα που λάβαμε από τις παραμετρικές διερεύνησης των μονοδιάστατων στην υλικών δίκτυων. Για αυτό το ζήτημα επιστρατεύτηκαν οι χαρακτηριστικές καμπύλες ROC και υπολογίσθηκαν και οι αντίστοιχες τιμές της περιοχής κάτω από την καμπύλη AUC για την διευκόλυνση της σύγκρισης μεταξύ των διαφόρων αναπτυχθέντων μοντέλων. Να αναφερθεί πως τα παράθυρα εισόδου που εξετάσθηκαν στο πλαίσιο της παραμετρικής έρευνας είναι:

- 8 ωρών
- 1 ημέρας
- 3 ημερών

Ενώ οι συντελεστές υποβάθμισης της λειτουργίας των κυλίνδρων που θα εισάγουν την αυξημένη διακύμανση στο σήμα των κυλίνδρων είναι:

- 1%
- 2%
- 5%

Ξεκινάμε με τη σύγκριση των δικτύων με τον ποικίλο βαθμό υποβάθμισης. Υπενθυμίζεται ότι στην περίπτωση της ταξινόμησης σήματος 1D, επιθεωρήθηκε το σήμα της θερμοκρασίας των 6 κυλίνδρων του κύριου κινητήρα, ως εκ τούτου ζητήθηκε από τα δίκτυα να εντοπίσουν 6 πιθανές ετικέτες σχετικές με την υποβάθμιση συν, μία ακόμη σε περίπτωση που δεν βρέθηκε υποβάθμιση, φτάνοντας συνολικά στις 7 ετικέτες. Προχωράμε στον υπολογισμό των τιμών AUC και σχεδιάζουμε τις αντίστοιχες καμπύλες ROC. Ωστόσο για την αξιοποίηση αυτών των εργαλείων είναι απαραίτητη η εισαγωγή της δυαδικής αναγνώρισης. Θεωρούμε ένα δυαδικό σχήμα ανίχνευσης με δύο πιθανές ετικέτες εξόδου που υποδεικνύουν εάν έχει εντοπιστεί εκφυλισμός, ανεξάρτητα από τη θέση της ζημιάς, υποδεικνύοντας εάν τα μοντέλα αναγνωρίζουν σωστά υποβαθμισμένα μοτίβα στο σήμα των κυλίνδρων ή όχι.

Παρατηρήθηκε ότι κάθε περίπτωση επιτυγχάνει πολύ ακριβείς προβλέψεις στο σύνολο δοκιμών, ξεπερνώντας το 99% της μέσης ακρίβειας σε κάθε περίπτωση. Ωστόσο, μια ενίσχυση της απόδοσης αποδεικνύεται, καθώς ο βαθμός των εμπλεκόμενων λευκών αυξήσεων, επιβεβαιώνει τη διαίσθησή μας σε αυτό το θέμα. Επιπλέον, παρατηρείται επίσης ότι το μοντέλο που εκπαιδεύτηκε για να ανιχνεύσει την απόδοση αποδόμησης 5% ακρίβεια 100%, ταξινομεί σωστά όλα τα δείγματα στο σύνολο δοκιμών. Επιπλέον, τα δίκτυα φαίνονται εξίσου ανοσοποιητικά και στους δύο τύπους σφαλμάτων, όσον αφορά την ψευδή πρόβλεψη της λειτουργίας του πλοίου.

Στη συνέχεια, παρουσιάζονται τα αποτελέσματα από την επόμενη παραμετρική έρευνα, σχετικά με τα μοντέλα με ποικίλα διαστήματα εισόδου που αντικατοπτρίζονται από τις παρτίδες δειγμάτων χρονοσειρών. Επιπλέον, χρησιμοποιείται και εδώ η δυαδική ανίχνευση, επιτρέποντάς μας να κατασκευάσουμε σχήματα καμπυλών ROC, προσαρμόζοντας τη σύγκριση. Ακόμα κι αν και τα 3 μοντέλα με το διαφορετικό χρόνο εισαγωγής θεωρούνται επαρκή, επιτυγχάνοντας αξιοσημείωτες βαθμολογίες σε όλες τις περιπτώσεις. Μπορεί να διακριθεί ένα μοτίβο, σχετικά με την απόδοση των μοντέλων και τον ορίζοντα εισόδου, καθώς η συμπεριφορά των μοντέλων τείνει να βελτιωθεί με τη συρρίκνωση του διαστήματος. Παρατηρώντας περαιτέρω τα ακόλουθα συγκεντρωμένα αποτελέσματα, το δίκτυο που λαμβάνει το μικρότερο διάστημα, δηλαδή αυτό των 8 ωρών, επιτυγχάνει μια εμφανή απόδοση με ακρίβεια 100% αξιολογώντας σωστά κάθε δείγμα στο σετ δοκιμών, ενώ το μοντέλο με το διάστημα εισόδου 3 ημερών φαίνεται να λειτουργεί αισθητά χειρότερο τα

άλλα δύο δίκτυα, υποδηλώνοντας ότι για αυτόν τον μηχανισμό ανίχνευσης αστοχίας που χαρακτηρίζεται βραχυπρόθεσμα, είναι πιο σημαντικό για την αποτελεσματικότητα της μεθοδολογίας να αναλυθεί με μικρότερο χρονικό διάστημα, δημιουργώντας έτσι περισσότερα διαθέσιμα δείγματα για εκπαίδευση, αντί να συγκεντρώνουμε περισσότερες πληροφορίες σχετικά με τις λειτουργίες του σκάφους σε μία παρτίδα μεμονωμένων χρονοσειρών.

Αν και τα αποτελέσματα που παρουσιάζονται παραπάνω θεωρούνται ικανοποιητικά, τα μεμονωμένα αποτελέσματα μιας μοναδικής μεθοδολογίας δεν μπορούν να μεταφέρουν πλήρως την ικανότητα και την αποτελεσματικότητά της. Επομένως, αφού περιγράψαμε την παραμετρική έρευνα, καθώς και το πώς οι ελεγχόμενες παράμετροι επηρεάζουν τα δίκτυα και έχοντας αποκτήσει καλύτερη κατανόηση της συμπεριφοράς των μοντέλων μαζί με τις αξιοσημείωτες βαθμολογίες τους στο υποσύνολο δοκιμών, προχωράμε στην εξέταση της αποτελεσματικότητας της καθιερωμένης μηχανικής μάθησης αλγόριθμοι στην ίδια εργασία, συγκρίνοντας την με την προτεινόμενη μεθοδολογία και στη συνέχεια αναγνωρίζεται η μεθοδολογία με την καλύτερη απόδοση. Η υλοποίηση με τους ταξινομητές αναφοράς έγινε με την αναπαραγωγή των δικτύων της παραμετρικής ανάλυσης κάθε 1N CNN. Υπενθυμίζεται πως οι ταξινομητές που χρησιμεύουν ως σημείο αναφοράς είναι:

1. Support Vector Classifier
2. Random Forest Classifier

Το σύνολο δεδομένων που χρησιμοποιείται παραμένει το ίδιο με αυτό που χρησιμοποιείται για την εφαρμογή των προτεινόμενων μοντέλων CNN. Η κατανομή ποσοστών του συνόλου δεδομένων που διανέμει τις παρατηρήσεις στο αντίστοιχο υποσύνολο παρέμεινε επίσης ανέπαφη στο 70% -10% -20% για εκπαίδευση, επικύρωση και σύνολο δοκιμών αντίστοιχα, και οι συγκρίσεις πραγματοποιήθηκαν, με βάση την απόδοση των ταξινομητών στο σύνολο δοκιμών. Έτσι λοιπόν, λαμβάνοντας τον μέσο όρο των βαθμολογιών των δικτύων στις 7 συνολικά επιθεωρηθείσες περιπτώσεις για κάθε μοντέλο, αλλά και εφαρμόζοντας τη δυαδική ταξινόμησης μπορέσαμε να υπολογίσουμε τις τιμές AUC και να σχηματίσουμε τις ακόλουθες καμπύλες ROC για την διευκόλυνση των 3 ταξινομητών στα 5 σενάρια που εξετάζονται. Από την απλή παρατήρηση, των εν λόγω σχημάτων, επιβεβαιώνεται η υπεροχή των προτεινόμενων, επιτυγχάνοντας βαθμολογίες σχεδόν τέλεια ακρίβεια και στις 5 περιπτώσεις, ενώ παράλληλα παρατηρείται και η σημαντικά χαμηλή απόδοση που επιδεικνύουν οι ταξινομητές ML.

4.2 2D CNN

Σε αυτό το σημείο παρουσιάζονται τα αποτελέσματα που λάβαμε από τις παραμετρικές διερεύνησης των μονοδιάστατων στην υλικών δικτύων. Για αυτό το ζήτημα επιστρατεύτηκαν οι χαρακτηριστικές καμπύλες ROC και υπολογίσθηκαν και οι αντίστοιχες τιμές της περιοχής κάτω από την καμπύλη AUC για την διευκόλυνση της σύγκρισης μεταξύ των διαφόρων αναπτυχθέντων μοντέλων. Να αναφερθεί πως τα παράθυρα εισόδου που εξετάσθηκαν στο πλαίσιο της παραμετρικής έρευνας είναι:

- 2 ημερών
- 10 ημερών
- 30 ημερών

Ενώ οι συντελεστές υποβάθμισης της λειτουργίας των κυλίνδρων που θα εισάγουν την αυξημένη διακύμανση στο σήμα των κυλίνδρων είναι:

- 2%
- 5%
- 10%

Ξεκινάμε με τη σύγκριση των δικτύων με τον ποικίλο βαθμό υποβάθμισης. Όπως αποδείχθηκε στην προκειμένη περίπτωση, η ακρίβεια του δικτύου αυξάνεται καθώς η επαγόμενη υποβάθμιση γίνεται πιο έντονη. Επιπλέον, τα προτεινόμενα μοντέλα είναι πιο ευαίσθητα σε ψευδείς ενδείξεις ελαττωματικής συμπεριφοράς του πλοίου, όπως φαίνεται από τις σχετικά χαμηλότερες βαθμολογίες του μετρητικού «Recall». Ωστόσο, εν τέλει, η απόδοση των ανεπτυγμένων μοντέλων θεωρείται ικανοποιητική.

Στη συνέχεια, παρουσιάζονται τα αποτελέσματα από την επόμενη παραμετρική έρευνα, σχετικά με τα μοντέλα με ποικίλα διαστήματα εισόδου που αντικατοπτρίζονται από τα contour plots. Αποδεικνύεται ότι η συνολική απόδοση των δικτύων αυξάνεται σημαντικά καθώς ο ορίζοντας εισόδου επεκτείνεται, παρόλο που το δίκτυο έχει εκπαιδευτεί με λιγότερα δείγματα. Σε αυτό το πλαίσιο, η παρατήρηση των παρακάτω αποτελεσμάτων δείχνει ότι το μοντέλο που λαμβάνει περιγράμματα που αντιπροσωπεύουν 30 ημέρες επιχειρησιακών δεδομένων που έχουν επιτευχθεί κατάφερε να ταξινομήσει σωστά όλα τα δείγματα στο σύνολο δοκιμών, υποδεικνύοντας ότι σε αυτόν τον μηχανισμό παρακολούθησης που έχει μεγαλύτερη σημασία και αντίκτυπο στην καλή απόδοση των μοντέλων, τα contour plots να ενσωματώνουν περισσότερα λειτουργικές πληροφορίες, παρόλο που συνεπάγεται λιγότερες εικόνες διαθέσιμες για την εκπαίδευση των δικτύων.

Το τελευταίο μέρος της παρουσίασης των αποτελεσμάτων αφορά την σύγκριση των αποτελεσμάτων από τα 2D CNNs με τα μοντέλα αναφοράς, έτσι ώστε να αποκτήσουμε καλύτερη και βαθύτερη κατανόηση της αξίας και της καινοτομίας της προτεινόμενης μεθοδολογίας. Σε αυτό το πλαίσιο, επαναλάβαμε τα 5 μοντέλα που δημιουργήθηκαν με τα 2D CNN, σε μια προσπάθεια να παρουσιάσουμε μια λεπτομερή σύγκριση και να εξετάσουμε την απόδοση των μοντέλων αναφοράς στις ίδιες εργασίες για τις οποίες χρησιμοποιήθηκαν τα CNN. Τέλος, πριν προχωρήσουμε στη σύγκριση μεταξύ των διαφορετικών αλγορίθμων, αξίζει να σημειωθεί ότι τα μοντέλα αναφοράς δεν έλαβαν εικόνες ως είσοδο, καθώς η αρχιτεκτονική τους έθεσε περιορισμούς στις διαστάσεις των δεδομένων εισόδου. Για αυτό τον λόγο, τα δείγματα εισόδου που δέχονταν ήταν τα αντίστοιχα δεμάτια της χρονοσειράς του συντελεστή Heickel, που φέρει την υποβάθμιση και χρησιμοποιήθηκε για τον χρωματισμό των εικόνων. Το χρησιμοποιούμενο σύνολο δεδομένων είναι το ίδιο με αυτό που χρησιμοποιήσαμε για την εφαρμογή της προτεινόμενης μεθοδολογίας και τα ίδια ποσοστά για τη κατανομή των δειγμάτων στα τρία υποσύνολα, δηλαδή τα υποσύνολα για την επικύρωση, την εκπαίδευση, αλλά και το σύνολο δοκιμών, παρέμειναν τα ίδια, στο 70% -10% -20%.

Για την διευκόλυνση της σύγκρισης των 3 διαφορετικών ταξινομητών σε καθεμία από τις 5 περιπτώσεις της παραμετρικής έρευνας χρησιμοποιήθηκαν οι χαρακτηριστικές καμπύλες ROC, ενώ επίσης υπολογίσθηκαν και οι αντίστοιχες περιοχές κάτω από την καμπύλη. Φάνηκε ξεκάθαρα η υπεροχή της μεθοδολογίας CNN για την αναγνώριση της κατάστασης του σκάφους και στις 5 περιπτώσεις που επιθεωρήθηκαν, μέσα από τις υψηλότερες βαθμολογίες μετρήσεων, αλλά και από τις μεγαλύτερες τιμές AUC που παράγονται. Επιπλέον, η περαιτέρω παρατήρηση της συμπεριφοράς των μοντέλων αναφοράς επιβεβαιώνει τα μοτίβα που παρατηρούνται και στη μεθοδολογία μας. Για παράδειγμα, η απόδοση αυξάνεται, καθώς το χρονικό διάστημα εισόδου επεκτάθηκε. Επιπλέον, παρατηρείται αύξηση της ακρίβειας των αξιολογήσεων στη δοκιμή των μοντέλων αναφοράς στην περίπτωση της πιο επιδεινωμένης ανεπάρκειας, καταφέροντας να

ταξινομήσουμε πιο σωστά από το αντίστοιχο μοντέλο CNN τα θετικά επισημασμένα δείγματα, που αποδεικνύονται από τις υψηλότερες τιμές ανάκλησης. Συνάγεται το συμπέρασμα ότι τα μοντέλα αναφοράς θα μπορούσαν να αποτελέσουν τη βάση ενός αξιόπιστου συστήματος CBM, αν και εντοπίζουν μόνο εξαιρετικά επιδεινωμένες ελλείψεις. Αντίθετα, η προτεινόμενη μεθοδολογία που βασίζεται στο CNN καταδεικνύει αξιοσημείωτη απόδοση σε όλο το φάσμα των βαθμών αποδόμησης.

5. Συμπεράσματα Μελέτης

Η εξέλιξη της 4^{ης} βιομηχανικής επανάστασης έφερε στην επιφάνεια την δυνατότητα για ανάπτυξη αποτελεσματικών συστημάτων ανάλυσης δεδομένων, ικανών να χειριστούν μια τεράστια ποσότητα δεδομένων, παρέχοντας ενισχυμένη υποστήριξη αποφάσεων. Τα συμπεράσματα που προέκυψαν από αυτήν τη μελέτη μπορούν να συνοψιστούν στα εξής σημεία:

- **Εφαρμογή και λεπτομερής επιθεώρηση των CNN στην CBM.** Το κύριο μέλημα αυτής της διατριβής αφορούσε τη δυνατότητα εφαρμογής των μοντέλων CNN στο σύστημα CBM για ανίχνευση αστοχίας στα πλοία αποδείχθηκε με επιτυχία. Η τρέχουσα εργασία επικεντρώνεται στην ανάπτυξη 2 μοντέλων βαθιάς μάθησης για παρακολούθηση της κατάστασης του πλοίου και αναγνωρίζοντας σημάδια που υποδηλώνουν υποβάθμιση. Πριν προχωρήσουμε στην ανάπτυξη των μοντέλων πρόβλεψης, της φάσης προ επεξεργασίας, του βήματος δημιουργίας χαρακτηριστικών καθώς και του τρόπου ανάλυσης του συνόλου δεδομένων και προετοιμάστηκαν για να σχηματίσουν τα δείγματα εισόδου των μοντέλων CNN, καταφέραμε να δημιουργήσουμε έναν επαρκή αριθμό δειγμάτων και στις δύο περιπτώσεις μελέτης.

Το πρώτο είδος αφορούσε ένα μοντέλο 2D CNN, το οποίο ελέγχει τα contour plots που σχετίζονται με την αποτελεσματικότητα του υπό μελέτη σκάφους, προσφέροντας μακροπρόθεσμη ανίχνευση υποβάθμισης. Σε αντίθεση με τις εφαρμογές που παρουσιάζονται στη σχετική βιβλιογραφία, όπου τα 2D CNN λαμβάνουν σπεκτρογράμματα, στην περίπτωση μας η έλλειψη δεδομένων υψηλής συχνότητας που καθίστανται μη διαθέσιμες τέτοιες επιλογές, με αποτέλεσμα να μας εξετάσει την εναλλακτική λύση των περιγραμμάτων.

Στη συνέχεια, προτάθηκε επίσης ένας βραχυπρόθεσμος μηχανισμός CBM, μέσω της εφαρμογής του 1D CNN με στόχο τον εντοπισμό των μοτίβων υποβάθμισης που παρατηρούνται στο σήμα των λειτουργικών παραμέτρων του πλοίου. Στην περίπτωση μας, εξετάστηκαν οι κύλινδροι των πλοίων.

Συμπερασματικά, βρέθηκε ότι και τα δύο μοντέλα CNN, μετά τη βελτιστοποίησή τους, ήταν σε θέση να δημιουργήσουν πολύ ακριβείς προβλέψεις στο σύνολο δοκιμών, επιτυγχάνοντας να δημιουργήσουν ακόμη και 100% σωστές προβλέψεις στο σύνολο δοκιμών. Ωστόσο, πρέπει να σημειωθεί η πολύ μεγάλη σημασία της διαδικασίας βελτιστοποίησης των δικτύων που οργανώνουν τη βέλτιστη διαμόρφωση των υπερπαραμέτρων, κάτι που συνιστάται ιδιαίτερα.

Έχοντας εξασφαλίσει αξιοσημείωτη ακρίβεια στα αποτελέσματα που προκύπτουν από την προτεινόμενη μεθοδολογία, συγκρίνουμε τα μοντέλα CNN και στις δύο περιπτώσεις μελέτης με τους καθιερωμένους αναγνωρισμένους ML ταξινομητές. Τελικά, η υπεροχή των CNN αποδείχθηκε, ξεπερνώντας σχεδόν σε κάθε μέτρηση τα μοντέλα ML, δημιουργώντας πιο ακριβείς αξιολογήσεις σχετικά με το επιχειρησιακό προφίλ του πλοίου, ειδικά στην

περίπτωση της ζημιάς που επιθεωρήθηκε από το 1D CNN σχετικά με την κατάσταση λειτουργίας των κυλίνδρων του κύριου κινητήρα .

Περιγράμματα για εικόνες εισόδου. Όπως αναφέρθηκε παραπάνω, από σχετική βιβλιογραφία, φασματογραφήματα που προέρχονταν από δεδομένα υψηλής συχνότητας χρησιμοποιήθηκαν σε μελέτες SHM και CBM. Ωστόσο, αυτό το έργο παρουσίασε μια νέα περίπτωση περιγράμματος, έναν πολύ δημοφιλή τρόπο αναπαράστασης χαρακτηριστικών ενδιαφέροντος στη ναυτιλία, που χρησιμοποιείται ως είσοδος στα μοντέλα 2D CNN. Διαπιστώθηκε ότι η απεικόνιση περιγράμματος είναι μια έγκυρη εναλλακτική λύση για την απεικόνιση δεδομένων χαμηλής συχνότητας, δείχνοντας ταυτόχρονα ότι τα δεδομένα υψηλής συχνότητας δεν είναι απαραίτητα για σχήματα CBM.

Εντοπισμός της ζημιάς με 1D CNN. Αποδεικνύεται ότι τα 1D CNN καταφέρνουν όχι μόνο να αναγνωρίσουν υποβαθμισμένα μοτίβα, αλλά επίσης είναι σε θέση να προσδιορίσουν ποιος κύλινδρος είναι αυτός που υποδεικνύει αυτήν τη συμπεριφορά.

Παραμετρική μελέτη. Επιπλέον, ένας ακόμα πολύ σημαντικός στόχος αυτής της μελέτης ήταν η διερεύνηση της επίδρασης πολλαπλών μεταβλητών στην απόδοση των μοντέλων. Σε αυτό το πλαίσιο, και οι δύο περιπτώσεις μελέτης υποβλήθηκαν σε παραμετρική διερεύνηση σε μια προσπάθεια να προσδιοριστεί η επίδραση των επαγόμενων επιπέδων εκφυλισμού και το πως τα διαφορετικά επίπεδα υποβάθμισης επηρεάζουν την αποτελεσματικότητα των μοντέλων, καθώς και η επίδραση του χρονικού διαστήματος εισόδου στην αποτελεσματικότητα των προτεινόμενων δικτύων. Οι ακόλουθες παρατηρήσεις σχεδιάστηκαν για αυτήν τη μελέτη:

Πρώτον, αποδείχθηκε ότι και στις δύο περιπτώσεις μελέτης, η προτεινόμενη μεθοδολογία εντόπιζε την επαγόμενη βλάβη με μεγαλύτερη ακρίβεια, καθώς ο βαθμός υποβάθμισης αυξανόταν, καθιστώντας την εν λόγω βλάβη πιο σημαντική και έντονη. Ωστόσο, μπορούμε να ισχυριστούμε πως όλα τα εξεταζόμενα επίπεδα τεχνητής υποβάθμισης εντοπίστηκαν επαρκώς, υποδεικνύοντας την αποτελεσματικότητα της προτεινόμενης μεθοδολογίας για την έγκαιρη ανίχνευση αστοχίας.

Όσον αφορά το χρονικό διάστημα εισαγωγής των δύο μεθόδων, συνήχθη το συμπέρασμα ότι το μακροπρόθεσμο σχήμα FD είχε καλύτερη απόδοση καθώς το παράθυρο αυξήθηκε, ενώ αντίστροφα για τον βραχυπρόθεσμο μηχανισμό FD, η συρρίκνωση του παραθύρου εισόδου αύξησε σημαντικά την ακρίβεια στις προβλέψεις στο σετ δοκιμών.