

Ανίχνευση ανωμαλιών σε πλοίο που βασίζεται σε νευρωνικά δίκτυα και καινοτόμους KPIs

Παναγιώτης Θεοδωρόπουλος
[Αριθμός Μητρώου 1054485]

Πίνακας ξενόγλωσσης ορολογιών

ANN:	Artificial Neural Network
FFNN:	Feed Forward Neural Network
FO:	Fuel Oil
FOC:	Fuel Oil Consumption
KPI:	Key Performance Indicator
LSTM:	Long Short-Term Memory
ISO:	International Organization Standardization
ME:	Main Engine
RNN:	Recurrent Neural Network
SMA:	Simple Moving Average

Σπουδαστική Εργασία

1. Εισαγωγή

Η παρούσα μελέτη στοχεύει στην παρακολούθηση του σήματος δεδομένων χαρακτηριστικών στόχων που περιγράφουν το επιχειρησιακό προφίλ ενός πλοίου. Πιο συγκεκριμένα, ο εκφυλισμός του κύτους-έλικα της αποτελεσματικότητας του πλοίου που προκαλείται από ένα στιγμιαίο συμβάν ενεργοποίησης είναι ο τύπος ζημίας που επιδιώκεται να εντοπίσει στο πλαίσιο αυτής της μελέτης, παρακολουθώντας τη μοναδική διάσταση των διαφόρων λειτουργικών παραμέτρων. Αυτές οι λειτουργίες χρησιμοποιούνται ως είσοδος στα μοντέλα μας και επιχειρείται να δημιουργηθεί ένα μοντέλο που είναι ικανό να παράγει πολύ ακριβείς εκτιμήσεις των πραγματικών τιμών ορισμένων λειτουργικών χαρακτηριστικών και επίσης να εντοπίζει την απόκλιση από την αναμενόμενη συμπεριφορά είναι εύλογη και μπορεί να αναγνωριστεί. Οι λειτουργικές παράμετροι που επιλέγονται ως χαρακτηριστικά στόχου είναι η ισχύς πρόωσης και η κατανάλωση καυσίμου. Η κατάσταση λειτουργίας που στοχεύουμε σε αυτή τη μελέτη να είναι σταθερή κατάσταση, για παράδειγμα με το πλοίο να πλέει στην ανοιχτή θάλασσα. Με αυτόν τον τρόπο, το υπό μελέτη σκάφος αξιολογείται σε περιπτώσεις μέγιστης ισχύος, απορρίπτοντας παρατηρήσεις δεδομένων που αντανακλούν την πλεύση κοντά στο λιμάνι. Η ανίχνευση που πραγματοποιείται αφορά επιχειρησιακές παραμέτρους των οποίων η απόκλιση από την αναμενόμενη κατάσταση είναι ενδεικτική της υποβάθμισης που επηρεάζει την αποτελεσματικότητα του πλοίου. Ο επιθεωρούμενος τύπος ζημίας αφορούσε βλάβη που σχετίζεται με το κύτος και επηρεάζει τη βέλτιστη κατάσταση που αναμένεται από τις θαλάσσιες δοκιμές, που πιθανώς προκαλείται από μια ξαφνική, απρόβλεπτη πηγή, όπως η επίδραση του πλοίου με οποιοδήποτε αντικείμενο, με αποτέλεσμα την εναλλαγή του υδροδυναμικού σχήματος του.

2. Προετοιμασία δεδομένων

Για τη συλλογή των δεδομένων, χρησιμοποιήθηκε το σύστημα LAROS. Αναλυτικότερα, οι «Έξυπνοι Συλλέκτες» εξασφαλίζουν μέσω ενός ασύρματου δικτύου μέσα στο σκάφος για 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 δεξαμενόπλοιο.

Το δεδομένο σύνολο δεδομένων έπρεπε να υποβληθεί σε διαδικασία προεπεξεργασίας 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 = 264.00
- Πλάτος= 50.00 (m)
- Βάθος= 23.10 (m)
- Ονομαστική ισχύς κύριας μηχανής = 18666 (kW) @ 91 RPM

3. Μεθοδολογία

Στοχεύεται η δημιουργία μοντέλων πρόβλεψης που επιτυγχάνουν ακριβείς εκτιμήσεις σε δύο σήματα, τα οποία θεωρούνται επαρκή για να εκφράσουν συνολικά το προφίλ του σκάφους. Συγκεκριμένα, οι δύο παράμετροι είναι: η προωθητική ισχύς του σκάφους από τον κύριο άξονα του κινητήρα και η κατανάλωση καυσίμου από τον κύριο κινητήρα.

Ο τύπος βλάβης που σκοπεύει να ανιχνεύσει σε αυτή τη μελέτη αφορά ένα στιγμιαίο συμβάν που προκαλεί υποβάθμιση της απόδοσης ισχύος. Αυτή η υποβάθμιση μπορεί να αποδοθεί σε πολλούς λόγους. Για παράδειγμα, μία εξέχουσα περίπτωση θα μπορούσε να είναι ένας εκφυλισμός στο κύτος ή στο σύστημα μετάδοσης κίνησης, στο σύστημα ή και στο σύστημα έλικα-άξονα του υπό μελέτη σκάφους. Το αποτέλεσμα αυτών των περιπτώσεων είναι η αλλοίωση του υδροδυναμικού σχήματος του πλοίου αυξάνοντας την αντίσταση στο νερό, προκαλώντας σημαντική επιδείνωση της αποτελεσματικότητας του πλοίου, καθώς η ώθηση μειώνεται και απαιτείται κατανάλωση πολύ περισσότερης ποσότητας καυσίμου σε αντίθεση με την κατάσταση πριν από την εκδήλωση.

Στην παρούσα μελέτη, η ανίχνευση ανωμαλίας που υποδηλώνει την υποβάθμιση της ισχύος πραγματοποιήθηκε με την ανάπτυξη ενός μοντέλου που είναι ικανά να επιτύχει εξαιρετικά ακριβείς προβλέψεις του παρακολουθούμενου σήματος, επιτρέποντάς μας έτσι να εντοπίζουμε ακόμη και τα πιο λεπτά σημάδια που σχετίζονται με την υποβάθμιση στην απόδοση του πλοίου. Για αυτό το σκοπό δύο είδη νευρωνικών δικτύων αναπτύσσονται και το πιο ακριβές επιλέγεται να τροφοδοτήσει τις εκτιμήσεις του, σε δύο δείκτες απόδοσης που ορίζονται στο πλαίσιο αυτής της εργασίας και βασίζονται σε επαληθευμένα KPI που εισήχθησαν στη σχετική βιβλιογραφία. Βασισμένα στο ISO 19030, ως μέτρο για την αξιολόγηση της κατάστασης λειτουργίας του υπό μελέτη σκάφους. Στο πλαίσιο αυτής της μελέτης, ορίζονται δύο KPI που αφορούν την απόκλιση των δύο μεταβλητών του σκάφους που αναφέρθηκαν πριν.

Υποτίθεται ότι το αρχικό σύνολο δεδομένων που συλλέχθηκε από το LAROS αντιπροσωπεύει το υπό μελέτη σκάφος, ενώ βρίσκεται στην υγιή του κατάσταση. Για τους σκοπούς της μελέτης μας, πρέπει να προκαλέσουμε σημάδια υποβάθμισης στην απόδοση του σκάφους, επεμβαίνοντας στο σύνολο δεδομένων, προσπαθώντας να προσομοιώσουμε

τον ξαφνικό και συνεχή εκφυλισμό στην απόδοση του πλοίου. Η υλοποίηση αυτής της προσπάθειας γίνεται με την επιλογή ενός σημείου εκκίνησης της πτώσης απόδοσης του σκάφους, και από αυτό το σημείο δεδομένων και μετά, οι τιμές των μεταβλητών της προωθητικής ισχύος και της κατανάλωσης καυσίμου, πολλαπλασιάζονται με συντελεστή k , με k μεγαλύτερο από 1. Αυτή η ενέργεια συνεπάγεται ότι απαιτείται περισσότερη ισχύς για το σκάφος να διατηρήσει την ίδια ταχύτητα και, στη συνέχεια, χρειάζεται περισσότερη κατανάλωση καυσίμου για τη διατήρηση της ίδιας λειτουργίας προφίλ.

Με βάση την υποβάθμιση που προκαλείται τεχνητά όπως περιγράφεται παραπάνω, επιλέγεται ένα αντίστοιχο κατώφλι για να προσδιοριστεί εάν έχουμε ανωμαλία στην απόδοση ισχύος. Πιο συγκεκριμένα, για την περίπτωση της μελέτης μας, το κατώτατο όριο έχει οριστεί να είναι ίσο με τον παράγοντα k του πολλαπλασιασμού του σήματος για προσομοίωση της ανεπάρκειας.

Τέλος, προκειμένου να αναγνωριστεί ένα συμβάν ως υποβάθμιση και οι δύο δείκτες πρέπει να υποδεικνύουν ελαττωματική κατάσταση λειτουργίας στο ίδιο χρονικό σημείο. Η εξίσωση 1 εκφράζει την έξοδο απόφασης, με την τιμή 1 που αντιστοιχεί στην ανίχνευση βλάβης, ενώ η τιμή 0 σημαίνει ότι το σκάφος βρίσκεται εντός της αποδεκτής περιοχής απόκλισης.

$$\begin{aligned} \text{Κατάσταση} &= 1 \text{ (Ελαττωματικό), αν } KPI < \text{κατώφλι} = k \\ &\text{else} \\ \text{Κατάσταση} &= 0 \text{ (Υγιές)} \end{aligned} \quad (1)$$

$$\text{Αποτέλεσμα} = KPI_{\text{Καταν.καυσίμου}} \cap KPI_{\text{ισχύς}} \quad (2)$$

4. Προεπεξεργασία Δεδομένων

Τα δεδομένα του πραγματικού κόσμου είναι συχνά ελλιπή, ασυνεπή ή / και λείπουν σε συγκεκριμένες συμπεριφορές ή τάσεις και είναι πιθανό να περιέχουν πολλά σφάλματα. Στην προεπεξεργασία δεδομένων, τέτοια ζητήματα αντιμετωπίζονται, με τον καθαρισμό των δεδομένων να απαρτίζεται από τα εξής βήματα:

Φιλτράρισμα: Διατηρήθηκαν μόνο τμήματα των δεδομένων που αντανakλούν τα ταξίδια στην ανοιχτή θάλασσα. **Αφαίρεση ακραίων τιμών:** Κατά πάσα πιθανότητα πρόκειται για λανθασμένες τιμές που προέκυψαν από λάθος κατά την μέτρηση. **Εξομάλυνση Σήματος:** Κατά την εξομάλυνση των δεδομένων εφαρμόζεται ο αλγόριθμος του απλού κινούμενου μέσου όρου (Simple Moving Average). Ο σκοπός της εφαρμογής του κινούμενου μέσου όρου είναι να εξομαλύνει τυχόν βραχυπρόθεσμες διακυμάνσεις ενώ εξακολουθεί να καταγράφει σημαντικά μοτίβα, ή να αυξήσει συνοπτικά την αναλογία σήματος έναντι θορύβου. **Δημιουργία παραμέτρων:** Σε αυτό το μέρος της διερευνητικής ανάλυσης δεδομένων, εμφανίζονται νέες παράμετροι που διευκολύνουν την ακριβέστερη μοντελοποίηση των λειτουργιών του πλοίου.

5. Αποτελέσματα Νευρωνικών

5.1 Προστροφοδοτούμενα Νευρωνικά Δίκτυα (Feed Forward Neural Networks)

Σε αυτό το μέρος της μελέτης, θα προσπαθήσουμε να προσομοιώσουμε ρεαλιστικές συνθήκες και να δούμε πώς θα ανταποκρίνεται το μοντέλο και ποια θα είναι η απόδοσή του κάτω από αόρατα δεδομένα, εισερχόμενα σε «πραγματικό χρόνο». Διαθέτουμε 270.000 δείγματα για την εκπαίδευση των μοντέλων και προσπαθήσαμε προβλέψουμε 74.600 δείγματα. Ουσιαστικά, θα ζητήσουμε από το μοντέλο μας να εκτελέσει τις δειγματοληπτικές

προβλέψεις. Πρώτον, παρουσιάστηκε η απόδοση των προστροφοδοτούμενων μοντέλων. Αποδείχθηκε πως τα FFNN δεν μπορούν να χειριστούν με ακρίβεια προβλέψεις σε πολλά δείγματα. Φάνηκε στις προβλέψεις ως προς και τις δύο μεταβλητές, ότι μέχρι 20.000 δείγματα το μοντέλο είναι αποδίδει ικανοποιητικά, καθώς υπάρχει μικρό σφάλμα μεταξύ των προβλεπόμενων τιμών και των πραγματικών. Ωστόσο, για μεγέθη μεγαλύτερα από αυτό, αρχίζει να εμφανίζεται απόκλιση μεταξύ των προβλεπόμενων και των πραγματικών. Η συνεχής αύξηση σφάλματος καθιστά τα μοντέλα FFNN ως ανεπαρκή για την πρόβλεψη αμφοτέρων των μεταβλητών που εξετάστηκαν.

5.2 Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks)

Τα αναδρομικά μοντέλα που αναλαμβάνουν την ίδια εργασία φάνηκε να αποδίδουν πολύ καλύτερα. Τα μοντέλα πρόβλεψης ισχύος και κατανάλωσης καυσίμου με τα κελιά LSTM ήταν ικανά να συλλάβουν με πολύ υψηλή ακρίβεια τις διακυμάνσεις που εμφανίζονταν στο αντίστοιχο σήμα. Τα μοντέλα LSTM καταφέρνουν να διατηρήσουν τόσο το σφάλμα όσο και την τυπική απόκλιση του σφάλματος κάτω από 0,5% και 2% αντίστοιχα καθ' όλη τη διάρκεια των προβλέψεων. Διατηρείται η ίδια διαίρεση συνόλων δεδομένων, που σημαίνει ότι έχουμε εκπαιδεύσει το μοντέλο σε περίπου 270.000 δείγματα και προσπαθήσαμε προβλέψουμε 74.600 δείγματα. Εν κατακλείδι, σε αντίθεση με τα μοντέλα ANN, τα μοντέλα LSTM προβλέπουν με μεγαλύτερη ακρίβεια τις πραγματικές τιμές της παραγόμενης ισχύος.

5.3 Σύγκριση μοντέλων

Όπως φάνηκε στις προηγούμενες ενότητες, τα μοντέλα LSTM ξεπέρασαν ως προς την απόδοση τα αντίστοιχα FFNN. Τα μοντέλα LSTM εκπαιδεύονται για αυτόν ακριβώς τον σκοπό να προβλέπουν με βάση τις προηγούμενες τιμές της δυνατότητας στόχου, αξιοποιώντας την χρονική εξάρτηση των δεδομένων.

6. Δείκτες Απόδοσης (KPI)

Μια κρίσιμη πτυχή που πρέπει να καταλάβει ο δείκτης μας είναι η απόδοση που σχετίζεται με την υποβάθμιση του κύτους και της έλικα. Από σχετική βιβλιογραφία, ορίζεται δείκτης απόδοσης κατάσταση σκάφους, με βάση τη διαδικασία ISO 19030 **K3 - Κατάσταση σκαφών** ως η ποσοστιαία (%) διαφορά μεταξύ της μετρούμενης και της αναμενόμενης ισχύος για την ταχύτητα ενός συγκεκριμένου πλοίου:

$$K3 = (P_m - P_e)/P_e$$

Η αναμενόμενη ισχύς P_e διαβάζεται από μια καμπύλη αναφοράς ταχύτητας-ισχύος του πλοίου που δίνεται από τον κατασκευαστή. Από αυτήν την άποψη, εισάγουμε έναν τροποποιημένο δείκτη, με στόχο να εκφράσουμε την κατάσταση του σκάφους χρησιμοποιώντας τις εκτιμώμενες τιμές της ισχύος και της FOC που παράγονται από τα μοντέλα βαθιάς μάθησης, και τις μετρούμενες τιμές που αποκτήθηκαν από τα συστήματα παρακολούθησης επί του σκάφους ως εξής:

- Modified- Power K_3 (*m-Power K_3*), which is defined as the % difference between the measured and the predicted power for a specific ship's speed:

$$m - Power K3 = \frac{P_{meas} - P_{pr}}{P_{meas}} \cdot 100\% \quad (6)$$

- Modified- FOC K_3 ($m-K_3$), which is defined as the % difference between the measured and the predicted power for a specific ship's speed:

$$m - FOC K3 = \frac{FOC_{meas} - FOC_{pr}}{FOC_{meas}} \cdot 100\% \quad (6)$$

Και στους δύο δείκτες οι προβλεπόμενες τιμές προέρχονται από τα νευρικά δίκτυα. Ένα πλεονέκτημα που προσφέρεται από την προτεινόμενη εφαρμογή χρησιμοποιώντας νευρωνικά δίκτυα είναι ότι δεν χρειάζεται να φιλτράρετε και να διορθώσετε τις συνθήκες αναφοράς, καθώς τα μοντέλα βαθιάς μάθησης παράγουν ακριβείς εκτιμήσεις στις ακριβείς μετρημένες συνθήκες. Αυτά τα KPI στοχεύουν στον εντοπισμό ανωμαλιών που παρακολουθούν λειτουργικά χαρακτηριστικά που θα μπορούσαν να προκληθούν εύλογα από την υποβάθμιση της απόδοσης του σκάφους. Όπως περιεγράφηκε νωρίτερα, προκειμένου να εισαχθεί ανεπάρκεια, το σήμα των χαρακτηριστικών στόχου πολλαπλασιάζεται με έναν παράγοντα k μεγαλύτερο από 1, υποδεικνύοντας ότι απαιτείται περισσότερη ισχύς και καύσιμο για το σκάφος να διατηρήσει την ίδια ταχύτητα και στη συνέχεια, περισσότερο. Το λάδι πρέπει να καταναλωθεί προκειμένου να διατηρηθεί το ίδιο λειτουργικό προφίλ. Ο παράγοντας k , με τον οποίο πολλαπλασιάζουμε τα εναλλασσόμενα σημεία δεδομένων για να προσομοιώσουμε την εκφυλισμένη κατάσταση του σκάφους, είναι $k = 1,0075$, δηλαδή προκαλώντας υποβάθμιση 0,75%. Στη συνέχεια, παρατηρώντας τα αποτελέσματα που λάβαμε παρατηρούμε ότι η προαναφερθείσα απόκλιση των δύο σημάτων συλλαμβάνεται στο γράφημα απόκλισης αύξησης ισχύος με μια απότομη αλλαγή της καμπύλης. Δεδομένου ότι ο συντελεστής εκφυλισμού που εφαρμόστηκε ήταν μια σταθερή τιμή $k = 1,0075$, ορίσαμε μια τιμή κατωφλίου για ανίχνευση ανωμαλιών στο 0,75%, έτσι ώστε οποιαδήποτε τιμή που ξεπερνάει να αναγνωρίζεται ως επιδείνωση της απόδοσης και επαληθεύτηκε πως ο δείκτης που ορίσαμε ανίχνευσε επιτυχώς την ανωμαλία στην απόδοση του σκάφους.

7. Συμπεράσματα Μελέτης

Η τρέχουσα εργασία επικεντρώνεται στη δημιουργία μοντέλων βαθιάς μάθησης βελτιστοποιημένης απόδοσης για την εκτίμηση και την πρόβλεψη των χαρακτηριστικών στόχου. Παρουσιάστηκαν δύο βασικά διαφορετικές προσεγγίσεις, καθεμία από τις οποίες υλοποιήθηκε με διαφορετικούς τύπους μοντέλων βαθιάς μάθησης. Παρουσιάστηκε η πρώτη δημιουργία μοντέλων ANN και στη συνέχεια, εφαρμόστηκαν μοντέλα RNN και πιο συγκεκριμένα, μοντέλα με κελί LSTM, αξιοποιώντας τη χρονική αλληλουχία του dataset μας.

Επιπλέον, επιχειρήθηκε μια πρόταση για ένα νέο, εύλογο και εύκολο να ερμηνευτεί δείκτη απόδοσης κατάστασης του πλοίου, προκειμένου να παρακολουθεί την ενεργειακή απόδοση του πλοίου και να εντοπίζει οποιαδήποτε ανωμαλία που σχετίζεται με την υποβάθμιση της απόδοσης. Η προσέγγιση που ακολουθήθηκε για να επιτευχθεί αυτό ήταν η ανάπτυξη μοντέλων βάσει δεδομένων των οποίων τα αποτελέσματα θα χρησιμεύσουν ως το θεμέλιο του ορισμού KPI μας. Η επιλογή LSTM παρείχε εξαιρετική ακρίβεια πρόβλεψης, εγγενώς ήμασταν σε θέση να εντοπίσουμε την εμφάνιση υποβάθμισης στην απόδοση του πλοίου.