

ΠΑΝΕΠΙΣΤΗΜΙΟ ΑΙΓΑΙΟΥ

**ΣΧΟΛΗ ΕΠΙΣΤΗΜΩΝ ΔΙΟΙΚΗΣΗΣ
ΤΜΗΜΑ ΝΑΥΤΙΛΙΑΣ ΚΑΙ ΕΠΙΧΕΙΡΗΜΑΤΙΚΩΝ
ΥΠΗΡΕΣΙΩΝ**



**«ΣΥΓΧΡΟΝΕΣ ΕΦΑΡΜΟΓΕΣ ΤΗΣ ΤΕΧΝΗΤΗΣ
ΝΟΗΜΟΣΥΝΗΣ ΣΤΗ ΝΑΥΤΙΛΙΑ»**

Πτυχιακή Εργασία για το Προπτυχιακό Πρόγραμμα Σπουδών

ΧΙΛΙΑΣ ΓΕΩΡΓΙΟΣ

ΙΑΝΟΥΑΡΙΟΣ 2023

ΧΙΟΣ

Χίλιας Γεώργιος

**«Σύγχρονες Εφαρμογές της Τεχνητής Νοημοσύνης στη
Ναυτιλία»**

Ιανουάριος 2023

Πτυχιακή Εργασία για το Προπτυχιακό Πρόγραμμα Σπουδών

Τμήμα Ναυτιλίας και Επιχειρηματικών Υπηρεσιών

Συγγραφέας: Χίλιας Γεώργιος

Επιβλέπουσα: Λάμπρου Μαρία

ΧΙΟΣ

Περίληψη

Στον σημερινό ταχέως εξελισσόμενο τεχνολογικό κόσμο, η τεχνητή νοημοσύνη και η μηχανική μάθηση έχουν επικρατήσει όλο και περισσότερο σε πολλούς επιχειρηματικούς τομείς. Η ναυτιλία δεν αποτελεί εξαίρεση, καθώς αυτές οι προηγμένες τεχνολογίες έχουν αποδειχθεί αποτελεσματικές στην αντιμετώπιση διαφόρων προκλήσεων, όπως η οικολογική αποδοτικότητα, το υψηλό κόστος καυσίμων και η αποφυγή συγκρούσεων. Στόχος αυτής της εργασίας είναι να διερευνήσει τους τομείς της ναυτιλιακής βιομηχανίας στους οποίους η τεχνητή νοημοσύνη και η μηχανική μάθηση μπορούν να αποφέρουν θετικά αποτελέσματα, όπως η αυξημένη αποδοτικότητα, η ενίσχυση της ασφάλειας και η μείωση του λειτουργικού κόστους. Εξετάζει επίσης τις μεθόδους που χρησιμοποιούνται για την επίτευξη αυτών των αποτελεσμάτων.

Abstract

In today's fast-paced technological world, AI and machine learning have become increasingly prevalent in various industries. The shipping industry is no exception, as these advanced technologies have proven to be effective in addressing various challenges such as eco-efficiency, high fuel costs and collision prevention. The aim of this paper is to explore the areas within the shipping industry where artificial intelligence and machine learning can deliver positive outcomes, such as increased efficiency, improved safety, and reduced costs. It also examines the methods used to achieve these outcomes.

Περιεχόμενα

1. ΕΙΣΑΓΩΓΗ	6
2. ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ.....	7
2.1 ΟΡΙΣΜΟΣ ΤΕΧΝΗΤΗΣ ΝΟΗΜΟΣΥΝΗΣ	7
2.2 ΙΣΤΟΡΙΚΗ ΕΞΕΛΙΞΗ.....	8
2.3 ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ	9
2.4 ΒΑΘΙΑ ΜΑΘΗΣΗ (DEEP LEARNING).....	10
2.5 INTERNET OF THINGS	11
2.6 ΚΥΒΕΡΝΟ-ΦΥΣΙΚΑ ΣΥΣΤΗΜΑΤΑ (CYBER-PHYSICAL SYSTEMS)	12
3. ΕΦΑΡΜΟΓΕΣ ΑΛΓΟΡΙΘΜΩΝ DEEP LEARNING ΣΤΗΝ ΝΑΥΤΙΑΙΑ	13
3.1 ΑΛΓΟΡΙΘΜΟΙ ΑΝΙΧΝΕΥΣΗΣ, ΕΝΤΟΠΙΣΜΟΥ & ΠΑΡΑΚΟΛΟΥΘΗΣΗΣ	13
3.1.1 Υπολογιστική Όραση	13
3.1.2 Συνελκτικό Νευρωνικό Δίκτυο (Convolutional Neural Network – CNN) ...	15
3.1.3 Αλγόριθμος SVM (Support Vector Machines)	16
3.1.4 Αλγόριθμος R-CNN (Regions with CNN)	17
3.1.5 Αλγόριθμος Fast R-CNN.....	18
3.1.6 Αλγόριθμος Faster R-CNN	19
3.1.7 Αλγόριθμος YOLO (You Only Look Once)	20
3.1.8 Αλγόριθμος SSD (Single Shot MultiBox Detector).....	21
3.1.9 Αποτελέσματα.....	22
3.2 ΑΛΓΟΡΙΘΜΟΙ ΕΥΡΕΣΗΣ ΒΕΛΤΙΣΤΗΣ ΔΙΑΔΡΟΜΗΣ	24
3.2.1 Πρόβλημα του Πλανόδιου Πωλητή (Traveling Salesman Problem – TSP) .	24
3.2.2 Αλγόριθμος Branch-and-Bound.....	25
3.2.3 Τεχνητό Νευρωνικό Δίκτυο (Artificial Neural Network – ANN)	26
3.2.4 Real-coded Genetic Algorithm (RCGA)	27
3.2.5 Αποτελέσματα.....	28
3.3 ΑΛΓΟΡΙΘΜΟΙ ΑΠΟΦΥΓΗΣ ΣΥΓΚΡΟΥΣΕΩΝ.....	30
3.3.1 Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Network – RNN).....	31
3.3.2 Δίκτυα Μακράς Βραχύχρονης Μνήμης (Long Short-term Memory – LSTM)	32
3.3.3 Αποτελέσματα.....	32
3.4 ΑΥΤΟΝΟΜΑ ΠΛΟΙΑ.....	35
3.4.1 Yara Birkeland	35
4. ΣΥΜΠΕΡΑΣΜΑ.....	37
ΒΙΒΛΙΟΓΡΑΦΙΑ	38

1. Εισαγωγή

Η Τεχνητή Νοημοσύνη εξελίσσεται ραγδαία τα τελευταία χρόνια και θεωρείται μία από τις σημαντικότερες τεχνολογικές εξελίξεις της τελευταίας δεκαετίας. Οι δυνατότητες της φέρνουν επανάσταση σε διάφορους κλάδους της αγοράς και έχουν οδηγήσει σε αυξημένα ποσοστά υιοθέτησης από πολλές εταιρείες παγκοσμίως. Σύμφωνα με την IBM (2022), ένα σημαντικό μέρος των εταιρειών, συγκεκριμένα το 35%, έχει ήδη υιοθετήσει την τεχνητή νοημοσύνη και ένα επιπλέον 42% δραστηριοποιείται ενεργά για την ενσωμάτωσή της στις δραστηριότητές του. Η τάση αυτή δεν περιορίζεται σε κάποιον συγκεκριμένο κλάδο και οι πιθανές εφαρμογές της είναι πολλές, από την αυτοματοποίηση εργασιών ρουτίνας έως την παροχή πληροφοριών και τη λήψη αποφάσεων σε πραγματικό χρόνο.

Τα πλεονεκτήματα που μπορεί να προκύψουν από την υιοθέτηση της τεχνητής νοημοσύνης έχουν συζητηθεί και προβλεφθεί ευρέως από μεγάλα ινστιτούτα όπως το McKinsey Global Institute. Το ινστιτούτο ανέφερε ότι οι εταιρείες που θα υιοθετήσουν πλήρως την τεχνητή νοημοσύνη εντός της επόμενης δεκαετίας έχουν τη δυνατότητα να βελτιώσουν σημαντικά τις οικονομικές τους επιδόσεις, συγκεκριμένα τον διπλασιασμό των ταμειακών τους ροών. Η πρόβλεψη αυτή αναδεικνύει τα σημαντικά οικονομικά οφέλη που μπορούν να αποκομίσουν οι εταιρείες από την επένδυση στην τεχνητή νοημοσύνη (Bughin, Seong, Manyika, Chui & Joshi, 2018).

Αξίζει επίσης να αναφερθεί ότι τα οφέλη της τεχνητής νοημοσύνης δεν περιορίζονται μόνο στις οικονομικές επιδόσεις, η τεχνητή νοημοσύνη μπορεί να επιφέρει μείωση του κόστους, αύξηση της αποδοτικότητας και της παραγωγικότητας, καθώς και μεγαλύτερη ασφάλεια. Η ναυτιλιακή βιομηχανία δεν αποτελεί επίσης εξαίρεση σε αυτή την τάση, καθώς η τεχνητή νοημοσύνη μπορεί να διαδραματίσει σημαντικό ρόλο στην αντιμετώπιση των προκλήσεων του κλάδου, όπως το αυξανόμενο κόστος καυσίμων, ο αυξημένος ανταγωνισμός και οι περιβαλλοντικοί κανονισμοί. Η εφαρμογή της τεχνητής νοημοσύνης στη ναυτιλιακή βιομηχανία μπορεί να αποφέρει σημαντικά οφέλη για τον κλάδο και την κοινωνία στο σύνολό της.

Μία από τις σημαντικότερες εφαρμογές της τεχνητής νοημοσύνης στη ναυτιλία είναι η ανάπτυξη αυτόνομων πλοίων. Τα πλοία αυτά λειτουργούν χωρίς ανθρώπινη παρέμβαση και βασίζονται σε προηγμένες τεχνολογίες όπως η τεχνητή νοημοσύνη, οι αισθητήρες και το διαδίκτυο των πράγματος (Internet of Things) για την πλοήγηση και την εκτέλεση πολύπλοκων λειτουργιών. Το Yara Birkeland της Νορβηγίας είναι ένα χαρακτηριστικό παράδειγμα αυτόνομου πλοίου καθώς είναι το πρώτο ηλεκτρικό και μη επανδρωμένο πλοίο μεταφοράς εμπορευματοκιβωτίων στην αγορά (Yara, n.d.).

Η ανάπτυξη αυτόνομων πλοίων έχει ως στόχο να επιφέρει πλήθος πλεονεκτημάτων στη ναυτιλιακή βιομηχανία, όπως η μείωση του περιβαλλοντικού κόστους, του λειτουργικού κόστους και η ενίσχυση της ασφάλειας. Τα αυτόνομα πλοία μπορούν να προγραμματιστούν ώστε να ακολουθούν τις πιο αποδοτικές διαδρομές, μειώνοντας το αποτύπωμα άνθρακα του πλοίου και το κόστος των καυσίμων. Επιπλέον, εξαλείφοντας την ανάγκη για ανθρώπινο πλήρωμα, τα αυτόνομα πλοία μπορούν επίσης να μειώσουν το λειτουργικό κόστος του πλοίου, καθιστώντας τα πιο αποδοτικά. Ακόμα, με τη χρήση

τεχνητής νοημοσύνης, τα αυτόνομα πλοία μπορούν να λαμβάνουν αποφάσεις σε πραγματικό χρόνο και να ανταποκρίνονται γρήγορα σε απροσδόκητες καταστάσεις, γεγονός που με τη σειρά του ενισχύει την ασφάλεια και μειώνει τον κίνδυνο ατυχημάτων.

Η τεχνητή νοημοσύνη αποδεικνύεται επίσης, πολύτιμο εφόδιο στην επιχειρησιακή στρατηγική των ναυτιλιακών δραστηριοτήτων. Χρησιμοποιείται σε διάφορους τομείς, όπως η βελτιστοποίηση του ενεργητικού, ο σχεδιασμός στόλου και η ναύλωση, για τη βελτίωση της παραγωγικότητας, της απόδοσης και της λήψης αποφάσεων. Επιπλέον, η τεχνητή νοημοσύνη χρησιμοποιείται σε «έξυπνες» ναυτιλιακές εφαρμογές για την παρακολούθηση της ενεργειακής κατανάλωσης και τη συμμόρφωση με τους περιβαλλοντικούς κανονισμούς (Lambrou, Watanabe & Iida, 2019).

2. Τεχνητή Νοημοσύνη

2.1 Ορισμός Τεχνητής Νοημοσύνης

Η τεχνητή νοημοσύνη, όρος που επινοήθηκε από τον καθηγητή του Stanford John McCarthy το 1955 (Manning, 2020), ορίστηκε από τον ίδιο ως "η επιστήμη και η μηχανική της κατασκευής ευφών μηχανών" (McCarthy, 2007). Ο ορισμός αυτός αποτυπώνει την ουσία του πεδίου της τεχνητής νοημοσύνης, το οποίο επιδιώκει την ανάπτυξη υπολογιστικών συστημάτων που μπορούν να εκτελούν εργασίες που απαιτούν ανθρώπινη νοημοσύνη, όπως η κατανόηση της φυσικής γλώσσας, η αναγνώριση εικόνων και η λήψη αποφάσεων.

Οι ρίζες της τεχνητής νοημοσύνης μπορούν να εντοπιστούν στην αρχαία ιστορία, με παραδείγματα αυτόματων και μηχανικών συσκευών που μιμούνται την ανθρώπινη συμπεριφορά. Ωστόσο, μόνο με την ανάπτυξη των ψηφιακών υπολογιστών στα μέσα του 20ου αιώνα άρχισε πραγματικά η τεχνητή νοημοσύνη να παίρνει διαστάσεις ως πεδίο έρευνας.

Το 1956, ο McCarthy, ο Marvin Minsky, ο Nathaniel Rochester και ο Claude Shannon διοργάνωσαν το συνέδριο του Dartmouth, το οποίο θεωρείται η γέννηση της τεχνητής νοημοσύνης. Το συνέδριο αυτό συγκέντρωσε ερευνητές από διάφορα πεδία, όπως η επιστήμη των υπολογιστών, η ψυχολογία και τα μαθηματικά, για να διερευνήσουν τις δυνατότητες κατασκευής "σκεπτόμενων μηχανών" (Dartmouth College, 1956). Αν και ο όρος "τεχνητή νοημοσύνη" εμφανίστηκε στο συνέδριο του 1956, ο τομέας της τεχνητής νοημοσύνης υπήρχε ήδη πριν από το 1956. Μια από τις βασικές μορφές στην πρώιμη ιστορία της τεχνητής νοημοσύνης είναι ο Alan Turing, Βρετανός μαθηματικός και επιστήμονας υπολογιστών.

Ο Turing θεωρείται ο πατέρας της θεωρητικής επιστήμης των υπολογιστών και το έργο του έθεσε τα θεμέλια για την ανάπτυξη των σύγχρονων υπολογιστών. Το 1950, δημοσίευσε το

σύγγραμμα με τίτλο "Computing Machinery and Intelligence", στο οποίο πρότεινε το Turing Test ως μέτρο της ικανότητας μιας μηχανής να επιδεικνύει νοήμων συμπεριφορά. Η δοκιμή Turing προτείνει ότι αν ένας ανθρώπινος αξιολογητής δεν είναι σε θέση να ξεχωρίζει τις απαντήσεις μιας μηχανής από εκείνες ενός ανθρώπου, τότε η μηχανή μπορεί να θεωρηθεί ότι διαθέτει ανθρώπινη νοημοσύνη. Ο Turing πρότεινε επίσης ότι μια μηχανή μπορεί να προγραμματιστεί ώστε να μιμείται τα βήματα επίλυσης προβλημάτων που θα ακολουθούσε ένας άνθρωπος για την επίλυση ενός προβλήματος. Αυτή η ιδέα αποτέλεσε τη βάση για την πρώιμη έρευνα της τεχνητής νοημοσύνης που επικεντρώθηκε στην προσπάθεια να κάνει τους υπολογιστές να συμπεριφέρονται όπως οι άνθρωποι εγκέφαλοι στην επίλυση προβλημάτων (Turing, 1950).

2.2 Ιστορική Εξέλιξη

Ένα από τα πρώτα παραδείγματα έρευνας πάνω στην τεχνητή νοημοσύνη κατά την περίοδο αυτή ήταν το Logic Theorist, ένα πρόγραμμα που αναπτύχθηκε από τους Allen Newell, Herbert A. Simon και Cliff Shaw το 1955 (McCorduck, 2004). Το Logic Theorist ήταν ικανό να αποδεικνύει μαθηματικά θεωρήματα μέσω αναζήτησης σε ένα σύνολο αξιωμάτων και κανόνων. Θεωρήθηκε σημαντικό επίτευγμα, καθώς ήταν σε θέση να επιλύει προβλήματα που προηγουμένως μπορούσαν να επιλυθούν μόνο από ανθρώπους.

Ένα άλλο αξιοσημείωτο επίτευγμα κατά τη διάρκεια αυτής της περιόδου ήταν η ανάπτυξη του Γενικού Επιλύτη Προβλημάτων (General Problem Solver – GPS) από τους Allen Newell και Herbert A. Simon το 1957 (Newell, 1963). Το GPS σχεδιάστηκε ως ένα γενικό πρόγραμμα επίλυσης προβλημάτων που θα μπορούσε να εφαρμοστεί σε ένα μεγάλο φάσμα εργασιών. Χρησιμοποιούσε means-ends analysis (MEA) για την ανάλυση ενός προβλήματος σε μικρότερα υποπροβλήματα και στη συνέχεια εφαρμόζε ένα σύνολο τεχνικών επίλυσης προβλημάτων σε κάθε υποπρόβλημα.

Κατά τις δεκαετίες του 1970 και 1980, ο τομέας της τεχνητής νοημοσύνης γνώρισε μια περίοδο μειωμένης χρηματοδότησης και ενδιαφέροντος, γνωστή ως ο πρώτος χειμώνας της τεχνητής νοημοσύνης. Η περίοδος αυτή χαρακτηρίστηκε από έλλειψη προόδου και μείωση της χρηματοδότησης σε έργα βασισμένα στην τεχνητή νοημοσύνη. Ένας από τους λόγους για τη μείωση της χρηματοδότησης ήταν η αποτυχία των προγραμμάτων που βασίζονταν στην προσέγγιση Good Old-Fashioned Artificial Intelligence (GOF AI), η οποία βασιζόταν στον προγραμματισμό υπολογιστών με τεράστιες ποσότητες γνώσεων και κανόνων (Russel & Norvig, 2009). Στα τέλη της δεκαετίας του 1980 και στις αρχές της δεκαετίας του 1990, αναζωπυρώθηκε το ενδιαφέρον για την τεχνητή νοημοσύνη, λόγω των προόδων στο υλικό των υπολογιστών και της ανάπτυξης νέων τεχνικών, όπως τα συστήματα εμπειρογνομώνων, τα συστήματα βασισμένα σε κανόνες και το case-based reasoning.

Κατά τη δεκαετία του 1990, η ερευνά της τεχνητής νοημοσύνης επικεντρώθηκε στην ανάπτυξη ευφύων πρακτόρων (Intelligent Agent) και συστημάτων πολλαπλών πρακτόρων (Multi-agent Systems). Οι ευφείς πράκτορες είναι προγράμματα υπολογιστών που μπορούν να εκτελούν αυτόνομα εργασίες σε ένα περιβάλλον και τα συστήματα πολλαπλών πρακτόρων είναι μια συλλογή ευφύων πρακτόρων που συνεργάζονται για την επίτευξη

ενός κοινού στόχου (Russel & Norvig, 2009). Η έρευνα αυτή έθεσε τα θεμέλια για την ανάπτυξη αυτόνομων συστημάτων, όπως τα αυτόνομα αυτοκίνητα και τα μη επανδρωμένα αεροσκάφη.

Στις αρχές της δεκαετίας του 2000, μια νέα προσέγγιση της τεχνητής νοημοσύνης που ονομάζεται μηχανική μάθηση (Machine Learning), η οποία βασίζεται στην ιδέα της εκπαίδευσης υπολογιστικών συστημάτων να μαθαίνουν μονά τους από δεδομένα, άρχισε να ακμάζει (IBM, n.d.). Η προσέγγιση αυτή οδήγησε σε σημαντικές ανακαλύψεις σε τομείς όπως η αναγνώριση εικόνων, η αναγνώριση ομιλίας και η επεξεργασία φυσικής γλώσσας.

Τα τελευταία χρόνια έχει σημειωθεί σημαντική πρόοδος στην τεχνητή νοημοσύνη, κυρίως λόγω της ανάπτυξης της βαθιάς μάθησης (Deep Learning). Η βαθιά μάθηση είναι ένας τύπος μηχανικής μάθησης που χρησιμοποιεί νευρωνικά δίκτυα με πολλαπλά επίπεδα, γνωστά και ως βαθιά νευρωνικά δίκτυα (Deep Neural Networks – DNN). Η βασική ιδέα πίσω από τη βαθιά μάθηση είναι η εκπαίδευση ενός υπολογιστή να μαθαίνει από δεδομένα, χωρίς να έχει προγραμματιστεί ρητά να εκτελεί μια συγκεκριμένη εργασία (IBM, n.d.). Η προσέγγιση της βαθιάς μάθησης επιτρέπει στο σύστημα να μαθαίνει από δεδομένα, να εντοπίζει μοτίβα και να κάνει προβλέψεις ή να λαμβάνει αποφάσεις. Η τεχνητή νοημοσύνη χρησιμοποιείται ολοένα και περισσότερο σε κλάδους όπως η υγειονομική περίθαλψη, η χρηματοοικονομική και οι μεταφορές. Ο τομέας της τεχνητής νοημοσύνης θεωρείται πλέον ένας από τους πιο σημαντικούς και ταχέως αναπτυσσόμενους τομείς της τεχνολογίας με τη δυνατότητα να φέρει επανάσταση σε πολλές πτυχές της ζωής μας.

2.3 Μηχανική Μάθηση

Παρόλο που η μηχανική μάθηση άρχισε να γίνεται δημοφιλής στα τέλη της δεκαετίας του 1990 και στις αρχές της δεκαετίας του 2000, η ιστορία της χρονολογείται από τις δεκαετίες του 1940 και 1950. Το 1955, ένας πρωτοπόρος στον τομέα της μηχανικής μάθησης, ο Arthur Samuel, ανέπτυξε το πρώτο πρόγραμμα αυτοεκμάθησης για υπολογιστές που έπαιζε ντάμα. Το ονόμασε "Samuel Checkers-Playing Program" και είχε την δυνατότητα να βελτιώνει την απόδοσή του μαθαίνοντας από τα ίδια του τα λάθη (Samuel, 1959).

Στα τέλη της δεκαετίας του 1950 και στις αρχές της δεκαετίας του 1960, οι ερευνητές άρχισαν να αναπτύσσουν αλγόριθμους για να μαθαίνουν οι υπολογιστές από δεδομένα, όπως ο αλγόριθμος Perceptron, ο οποίος παρουσιάστηκε από τον Frank Rosenblatt το 1958. Ο αλγόριθμος Perceptron ήταν ένας απλός αλγόριθμος για μηχανική μάθηση με επίβλεψη και χρησιμοποιήθηκε για να εκπαιδεύσει μια μηχανή να αναγνωρίζει μοτίβα σε δεδομένα (Rosenblatt, 1958).

Στα τέλη της δεκαετίας του 1960 και στις αρχές της δεκαετίας του 1970, οι ερευνητές άρχισαν να αναπτύσσουν πιο εξελιγμένους αλγόριθμους μηχανικής μάθησης, όπως τα δέντρα αποφάσεων και τα δίκτυα Bayes (Russel & Norvig, 2009). Αυτοί οι αλγόριθμοι χρησιμοποιήθηκαν για την επίλυση πιο σύνθετων προβλημάτων, όπως η αναγνώριση ομιλίας και η επεξεργασία φυσικής γλώσσας. Στη δεκαετία του 1980, ο τομέας της μηχανικής μάθησης γνώρισε μια αναζωπύρωση του ενδιαφέροντος, λόγω των εξελίξεων

στο υλικό των υπολογιστών και της διαθεσιμότητας μεγάλου όγκου δεδομένων. Οι ερευνητές άρχισαν να αναπτύσσουν πιο ισχυρούς αλγόριθμους, όπως τα νευρωνικά δίκτυα.

Στα τέλη της δεκαετίας του 1990 και στις αρχές της δεκαετίας του 2000, αναπτύχθηκαν αλγόριθμοι μηχανικής μάθησης, όπως ο Random Forest (Ho, 1995) και ο Gradient Boosting (Friedman, 1999), μέθοδοι μάθησης συνόλου που χρησιμοποιούνται για τη βελτίωση της απόδοσης των μοντέλων μηχανικής μάθησης. Χρησιμοποιούνται κυρίως σε εφαρμογές ταξινόμησης και παλινδρόμησης. Ο Random Forest δημιουργεί πολλαπλά δέντρα αποφάσεων, καθένα από τα οποία εκπαιδεύεται σε διαφορετικό υποσύνολο δεδομένων, και στη συνέχεια συνδυάζει τις προβλέψεις όλων των δέντρων για να κάνει μια τελική πρόβλεψη. Ο Gradient Boosting είναι ένας επαγωγικός αλγόριθμος που δημιουργεί μια ακολουθία βασικών μοντέλων, όπου κάθε μοντέλο εκπαιδεύεται για να διορθώσει τα σφάλματα του προηγούμενου μοντέλου.

Τα τελευταία χρόνια, ο τομέας της μηχανικής μάθησης έχει σημειώσει ραγδαία πρόοδο, η οποία οφείλεται στη διαθεσιμότητα μεγάλων ποσοτήτων δεδομένων, ισχυρών υπολογιστικών πόρων και νέων τεχνικών, όπως η βαθιά μάθηση. Αυτό έχει οδηγήσει στην ανάπτυξη μοντέλων μηχανικής μάθησης υψηλής ακρίβειας που χρησιμοποιούνται σε πλήθος εφαρμογών, όπως η υπολογιστική όραση και τα αυτόνομα οχήματα.

2.4 Βαθιά Μάθηση (Deep Learning)

Η βαθιά μάθηση είναι μια εξειδικευμένη μορφή μηχανικής μάθησης που χρησιμοποιεί μια ιεραρχία εννοιών και ιδεών για την ερμηνεία και την κατανόηση δεδομένων. Αυτή η προσέγγιση επιτρέπει στα μοντέλα βαθιάς μάθησης να είναι πιο ισχυρά και ευέλικτα, αναλύοντας τις πολύπλοκες πληροφορίες σε απλούστερα μέρη. Η δομή αυτή την καθιστά ιδανική προσέγγιση για τη δημιουργία συστημάτων τεχνητής νοημοσύνης που μπορούν να χειριστούν πολύπλοκα και απρόβλεπτα σενάρια του πραγματικού κόσμου (Bengio, Goodfellow & Courville, 2016). Τα συστήματα αυτά αποτελούνται από πολλαπλά επίπεδα διασυνδεδεμένων κόμβων, που ονομάζονται τεχνητοί νευρώνες και επιτρέπουν στα μοντέλα βαθιάς μάθησης να μαθαίνουν και να γενικεύουν από μεγάλες ποσότητες σύνθετων και πολυδιάστατων δεδομένων, όπως εικόνες, ήχος και κείμενο.

Με τον αυξανόμενο όγκο δεδομένων που παράγονται καθημερινά, είναι απαραίτητο να υπάρχουν προηγμένοι αλγόριθμοι για την ανάλυση και την εξαγωγή πληροφοριών από αυτά τα δεδομένα. Τα περισσότερα από τα παραγόμενα δεδομένα σήμερα έχουν τη μορφή εικόνων, κειμένου και μη δομημένων στοιχείων (Sagiroglu & Sinanc, 2013).

Η βαθιά μάθηση αποκτά ολοένα και μεγαλύτερη σημασία στην σημερινή εποχή, καθώς έχει τη δυνατότητα να επεξεργάζεται και να κατανοεί εικόνες, κείμενα και άλλες μορφές μη αριθμητικών δεδομένων καλύτερα από τις παραδοσιακές μεθόδους μηχανικής μάθησης.

2.5 Internet of Things

Το Internet of Things (IoT) είναι μια σύγχρονη έννοια που αναφέρεται στην ενσωμάτωση του διαδικτύου και των υπολογιστικών λειτουργιών σε καθημερινά αντικείμενα, μικροσυσκευές και αισθητήρες. Αυτό επιτρέπει σε αυτές τις συσκευές να αλληλοεπιδρούν, να μοιράζονται δεδομένα και να ολοκληρώνουν εργασίες με ελάχιστη ανθρώπινη παρέμβαση. Η φράση Internet of Things χρησιμοποιείται για να περιγράψει μια πληθώρα εφαρμογών, συμπεριλαμβανομένων των έξυπνων σπιτιών, του βιομηχανικού αυτοματισμού, της υγειονομικής περίθαλψης και των μεταφορών. Επειδή το Internet of Things είναι μια ταχέως εξελισσόμενη τεχνολογία, δεν υπάρχει ένας ενιαίος παγκοσμίως αναγνωρισμένος ορισμός για το τι είναι και τι συνεπάγεται (Rose, Eldridge & Chapin, 2015)

Οραματίζεται ως ένα παγκόσμιο δίκτυο διασυνδεδεμένων συσκευών και αντικειμένων, το οποίο επιτρέπει τον απομακρυσμένο έλεγχο και την επικοινωνία. Το αισθητήριο τμήμα του Internet of Things αποτελείται από έξυπνα συστήματα και αισθητήρες που μπορούν να ανιχνεύουν και να συλλέγουν αυτόματα πληροφορίες από το περιβάλλον και να τις μοιράζονται μεταξύ των συσκευών. Τα τελευταία χρόνια, οι εξελίξεις στις τεχνολογίες ανίχνευσης και επικοινωνίας έχουν καταστήσει πιο εφικτή την εφαρμογή του Internet of Things, καθιστώντας δυνατή τη μοναδική αναγνώριση και παρακολούθηση αντικειμένων με RFID (Radio Frequency Identification) ή αισθητήρες. Αυτά τα αντικείμενα διαθέτουν μια ψηφιακή ταυτότητα, γνωστή ως UUID (Universally Unique Identifier), η οποία είναι κρίσιμη για την επιτυχή ανάπτυξη υπηρεσιών σε ένα τεράστιο δίκτυο όπως το Internet of Things (Li, Xu & Zhao, 2015).

Η τεχνητή νοημοσύνη μπορεί να ενσωματωθεί στο Internet of Things για να αυξήσει τη «νοημοσύνη» και τη λειτουργικότητα των συστημάτων Internet of Things. Ένα σύστημα Internet of Things χωρίς τεχνητή νοημοσύνη θα έχει περιορισμένες δυνατότητες. Αντιθέτως, ένα σύστημα Internet of Things με τεχνητή νοημοσύνη θα έχει τη δυνατότητα να εξελίσσεται και να προσαρμόζεται στα μεταβαλλόμενα δεδομένα, επιτρέποντάς του να επιτύχει τον στόχο της αυτοματοποίησης και της προσαρμοστικότητας. Ορισμένα παραδείγματα σημερινών υπηρεσιών Internet of Things που χρησιμοποιούν τεχνητή νοημοσύνη περιλαμβάνουν:

- **Φωνητικοί Βοηθοί (Voice Assistants):** Φωνητικές υπηρεσίες με δυνατότητα Internet of Things, οι οποίες βασίζονται στο υπολογιστικό νέφος (Cloud Computing), λειτουργούν ως προσωπικοί βοηθοί για τους χρήστες, είναι συσκευές που μπορούν να εκτελούν διάφορες λειτουργίες χρησιμοποιώντας εφαρμογές τρίτων και άλλες έξυπνες συσκευές που βρίσκονται κοντά τους. Ανταποκρίνονται σε φωνητικές εντολές και μπορούν να εκτελούν εργασίες όπως η απάντηση ερωτήσεων, η πραγματοποίηση κρατήσεων, η αναπαραγωγή μουσικής και ο έλεγχος έξυπνου φωτισμού, μεταξύ άλλων.

- **Ρομπότ:** Οι πρόσφατες εξελίξεις στη ρομποτική έχουν οδηγήσει στη δημιουργία ρομπότ που έχουν ανθρωπόμορφη εμφάνιση και μπορούν να αλληλοεπιδρούν με τον άνθρωπο, ενώ αναγνωρίζουν, ανταποκρίνονται και εκφράζουν ορισμένα ανθρώπινα συναισθήματα. Αυτά τα ρομπότ αποτελούν από μόνα τους ένα παράδειγμα Internet of Things, καθώς είναι εξοπλισμένα με πολλαπλούς αισθητήρες και ενεργοποιητές, καθώς και με τεχνητή νοημοσύνη, η οποία τους επιτρέπει να μαθαίνουν συνεχώς και να προσαρμόζονται με την πάροδο του χρόνου.
- **Έξυπνες Συσκευές (Smart Devices):** Εκτός από τους φωνητικούς βοηθούς και τα ρομπότ, το Internet of Things περιλαμβάνει επίσης άλλες συσκευές και συστήματα που διευκολύνουν τους ανθρώπους. Αυτές οι συσκευές είναι συχνά εξοπλισμένες με τεχνητή νοημοσύνη και χρησιμοποιούν μια ποικιλία εφαρμογών, όπως αναγνώριση αντικειμένων, αναγνώριση προσώπου, αναγνώριση φωνής και ομιλίας, αναγνώριση εκφράσεων, βαθιά νευρωνικά δίκτυα και υπολογιστική όραση για να εκτελέσουν τα καθήκοντά τους.
- **Βιομηχανία:** Εκτός από τη χρήση σε έξυπνα σπίτια, το Internet of Things βρίσκει εφαρμογές σε διάφορους βιομηχανικούς τομείς. Αυτές οι εφαρμογές χρησιμοποιούν στατιστική και χρηματοοικονομική ανάλυση για να αποκτήσουν πληροφορίες σχετικά με την απόδοση μιας εταιρείας και να κάνουν προβλέψεις χρησιμοποιώντας αλγόριθμους τεχνητής νοημοσύνης και μηχανικής μάθησης (Ghosh, Chakraborty & Law, 2018).

2.6 Κυβερνο-φυσικά Συστήματα (Cyber-physical Systems – CPS)

Τα κυβερνο-φυσικά συστήματα είναι ένας συνδυασμός τεχνολογίας πληροφοριών και επικοινωνιών (Information and Communication Technology) και λογισμικού με φυσικά τμήματα. Τα συστήματα αυτά μπορούν να δημιουργηθούν με τη σύνδεση ενσωματωμένων συστημάτων στο διαδίκτυο. Το Εθνικό Ίδρυμα Επιστημών των ΗΠΑ εγκαινίασε το πρώτο μεγάλο ερευνητικό πρόγραμμα για τα CPS το 2006, ορίζοντας τα ως "στενή σύζευξη και συντονισμός μεταξύ υπολογιστικών και φυσικών πόρων" (Veith, Fischer, Tröschel & Nieße, 2019). Ο ορισμός του Εθνικού Ιδρύματος Επιστημών των ΗΠΑ για τα κυβερνο-φυσικά συστήματα όμως δεν αναφέρει ρητά την τεχνητή νοημοσύνη ως απαραίτητο συστατικό για να θεωρηθεί ένα ενσωματωμένο σύστημα, κυβερνο-φυσικό. Ωστόσο, η διαθεσιμότητα αισθητηριακών δεδομένων, ένα σύστημα επικοινωνιών και η δυνατότητα λήψης αποφάσεων στον φυσικό κόσμο υποδηλώνουν ότι η αύξηση της "νοημοσύνης" του συνολικού συστήματος μπορεί να επιτευχθεί μέσω της τεχνητής νοημοσύνης. Παραδείγματα CPS περιλαμβάνουν βιομηχανικά συστήματα ελέγχου, υπολογιστικά συστήματα ελέγχου οχημάτων και αεροσκαφών, ασύρματα δίκτυα αισθητήρων, έξυπνα δίκτυα και συσκευές που περιλαμβάνονται στο Internet of Things. Πολλές ιατρικές συσκευές όπως οι βηματοδότες, μετατρέπονται επίσης σε κυβερνο-φυσικά συστήματα.

3. Εφαρμογές Αλγορίθμων Deep Learning στην Ναυτιλία

3.1 Αλγόριθμοι Ανίχνευσης, Εντοπισμού & Παρακολούθησης

Πρόσφατα, η ναυτιλία έχει αρχίσει να ενδιαφέρεται όλο και περισσότερο για τα μη επανδρωμένα και αυτόνομα πλοία. Αυτή η εξέλιξη της τεχνολογίας έφερε στο φως την κρίσιμη ανάγκη για προηγμένα συστήματα ικανά να ανιχνεύουν και να ταυτοποιούν αυτόματα αντικείμενα που βρίσκονται στην εμβέλεια των πλοίων, προκειμένου να διασφαλίζεται η ασφαλής ναυσιπλοΐα.

Παραδοσιακά, τα πλοία βασίζονταν στη χρήση δεδομένων του Αυτόματου Συστήματος Αναγνώρισης (AIS) και αισθητήρων όπως το RADAR (RADio Detection And Ranging) και το LIDAR (LIght Detection And Ranging) για τη συλλογή πληροφοριών σχετικά με το περιβάλλον τους. Ωστόσο, αυτές οι παραδοσιακές μέθοδοι έχουν τους δικούς τους περιορισμούς. Για παράδειγμα, το AIS μπορεί να ανιχνεύσει μόνο πλοία που διαθέτουν εξοπλισμό AIS, γεγονός που αποκλείει τα μικρά σκάφη και οποιοδήποτε άλλο αντικείμενο πάνω στην θάλασσα. Το RADAR, αν και μπορεί να ανιχνεύει αντικείμενα σε μεγάλες αποστάσεις, είναι περιορισμένο ως προς την ποσότητα των πληροφοριών που παρέχει και έχει αργό ρυθμό ενημέρωσης. Το LIDAR, αν και υψηλής ακρίβειας, έχει περιορισμένη εμβέλεια και μπορεί να προκαλέσει αντανάκλασεις στην επιφάνεια του νερού.

Δεδομένων αυτών των περιορισμών, υπάρχει αυξανόμενη ανάγκη για την ανάπτυξη τεχνολογίας ανίχνευσης και εντοπισμού βασισμένη στην εικόνα, η οποία μπορεί να ανιχνεύει αντικείμενα, να παρατηρεί τον γύρο χώρο σε πραγματικό χρόνο και να αξιοποιεί τα διάφορα δεδομένα που συλλεγεί από τις φωτογραφίες και τα βίντεο των καμερών. Η τεχνολογία αυτή σκοπεύει να αντισταθμίσει τις ελλείψεις των παραδοσιακών μεθόδων και να βελτιώσει τη συνολική ασφάλεια και αποτελεσματικότητα της ναυσιπλοΐας.

3.1.1 Υπολογιστική Όραση

Η υπολογιστική όραση, ένας τομέας της τεχνητής νοημοσύνης, είναι μια απίστευτα συναρπαστική και ταχέως αναπτυσσόμενη τεχνολογία που έχει ως στόχο να δώσει στους υπολογιστές την ικανότητα να κατανοούν και να αναλύουν οπτικές πληροφορίες όπως εικόνες και βίντεο με παρόμοιο τρόπο όπως η ανθρώπινη όραση. Στην ουσία, πρόκειται για τη διαδικασία που επιτρέπει στους υπολογιστές και τα συστήματα να εξάγουν σημαντικές πληροφορίες από ψηφιακές εικόνες, βίντεο και άλλες οπτικές εισροές και να λαμβάνουν αποφάσεις με βάση αυτές τις πληροφορίες.

Η ανθρώπινη όραση έχει το πλεονέκτημα ότι διαθέτει ένα προβάδισμα εκατομμυρίων χρόνων για να επιτύχει αυτό το αποτέλεσμα. Η μηχανική όραση ωστόσο πρέπει να το καταφέρει σε πολύ λιγότερο χρόνο. Αντί για αμφιβληστροειδή, οπτικά νεύρα και οπτικό φλοιό, η υπολογιστική όραση εκπαιδεύει μηχανές να εκτελούν αυτές τις λειτουργίες χρησιμοποιώντας κάμερες, δεδομένα και αλγόριθμους.

Το πλεονέκτημα όμως της υπολογιστικής όρασης είναι ότι μπορεί να αναλύσει χιλιάδες εικόνες σε ένα λεπτό, παρατηρώντας ελαττώματα ή προβλήματα που είναι απαρατήρητα στον άνθρωπο. Αυτή η ικανότητα γρήγορης επεξεργασίας και ανάλυσης μεγάλων ποσοτήτων οπτικών δεδομένων είναι που καθιστά την υπολογιστική όραση ένα τόσο ισχυρό εργαλείο.

Η υπολογιστική όραση χρησιμοποιείται σε μεγάλο πλήθος εφαρμογών, από την αναγνώριση αντικειμένων και προσώπων έως την πλοήγηση αυτονόμων αυτοκινήτων, την ιατρική απεικόνιση και πολλά άλλα. Οι δυνατότητες είναι απεριόριστες και ο ενδεχόμενος αντίκτυπος στην κοινωνία είναι τεράστιος. Δεν είναι τυχαίο ότι η υπολογιστική όραση θεωρείται ένας από τους πιο υποσχόμενους τομείς της τεχνητής νοημοσύνης, με όλο και περισσότερη έρευνα και ανάπτυξη να αφιερώνεται καθημερινά σε αυτόν τον τομέα (IBM, n.d.).

Η υπολογιστική όραση είναι ικανή να φέρει εις πέρας τις ακόλουθες εργασίες:

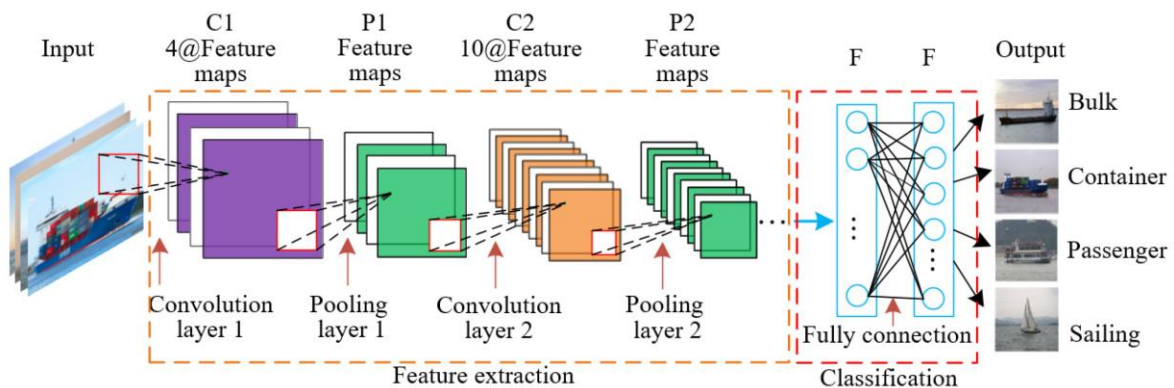
- **Ανίχνευση (Detection):** Η ανίχνευση αντικειμένων είναι ένας τομέας της υπολογιστικής όρασης που περιλαμβάνει τη χρήση νευρωνικών δικτύων για την ανίχνευση και τον εντοπισμό αντικειμένων σε μια εικόνα ή ένα βίντεο. Χρησιμοποιεί αλγορίθμους βαθιάς μάθησης για να μαθαίνει από ένα μεγάλο σύνολο επισημασμένων εικόνων, όπου τα αντικείμενα ενδιαφέροντος αναγνωρίζονται και εντοπίζονται με τη χρήση οριοθετημένων πλαισίων (bounding box). Τα πλαίσια οριοθέτησης είναι οι συντεταγμένες του ορθογωνίου που περιβάλλουν το αντικείμενο. Τα νευρωνικά δίκτυα εκπαιδεύονται ώστε να μαθαίνουν τα χαρακτηριστικά και τα μοτίβα των αντικειμένων και μαθαίνουν να τα εντοπίζουν σε νέες εικόνες ή βίντεο. Υπάρχουν διάφορες αρχιτεκτονικές νευρωνικών δικτύων που μπορούν να χρησιμοποιηθούν για την ανίχνευση αντικειμένων, όπως οι μέθοδοι δύο σταδίων (R-CNN και οι παραλλαγές του) και οι μέθοδοι ενός σταδίου (όπως το YOLO και το SSD) (Zhao, Zheng, Xu & Wu, 2019).
- **Εντοπισμός (Localization):** Ο εντοπισμός αντικειμένων είναι μια άλλη κατηγορία της υπολογιστικής όρασης που αποσκοπεί στον εντοπισμό της ακριβούς θέσης ενός αντικειμένου μέσα σε μια εικόνα ή ένα βίντεο με τη χρήση νευρωνικών δικτύων. Αυτή η διαδικασία περιλαμβάνει συνήθως τον εντοπισμό των συντεταγμένων του αντικειμένου εντός της εικόνας. Όπως και η ανίχνευση αντικειμένων, ο εντοπισμός αντικειμένων μπορεί να πραγματοποιηθεί με τη χρήση διάφορων αρχιτεκτονικών νευρωνικών δικτύων, όπως μέθοδοι δύο σταδίων και μέθοδοι ενός σταδίου, και τα Συνελκτικά Νευρωνικά Δίκτυα (CNN). Ωστόσο ο εντοπισμός αντικειμένων αναφέρεται μόνο στον προσδιορισμό της θέσης του αντικειμένου εντός της εικόνας ή του βίντεο.

- Παρακολούθηση (Tracking):** Η παρακολούθηση αντικειμένων είναι η διαδικασία συνεχούς εντοπισμού ενός αντικειμένου σε μια ακολουθία εικόνας ή βίντεο με τη χρήση νευρωνικών δικτύων. Είναι ένας συνδυασμός τεχνικών ανίχνευσης αντικειμένων και εντοπισμού αντικειμένων, όπου ο στόχος είναι η παρακολούθηση ενός αντικειμένου με την πάροδο του χρόνου. Ο αλγόριθμος ανιχνεύει το αντικείμενο στην πρώτη εικόνα και στη συνέχεια το παρακολουθεί στις μεθεπόμενες εικόνες εκτιμώντας τη θέση του αντικειμένου την παρούσα στιγμή με βάση την προηγούμενη θέση του. Υπάρχουν διάφορες αρχιτεκτονικές νευρωνικών δικτύων που μπορούν να χρησιμοποιηθούν για την παρακολούθηση αντικειμένων, ένα από αυτά είναι το Αναδρομικό Νευρωνικό Δίκτυο (RNN). Το RNN έχει κύριο σκοπό την μοντελοποίηση της χρονικής δυναμικής του αντικειμένου και την πρόβλεψη της μελλοντικής του θέσης (Lecrosnier, Khemmar, Ragot, Decoux, Rossi, Kefi & Ertaud, 2021).

3.1.2 Συνελκτικό Νευρωνικό Δίκτυο (Convolutional Neural Network – CNN)

Το Συνελκτικό Νευρωνικό Δίκτυο (CNN), είναι ένας τύπος νευρωνικού δικτύου που αποτελείται από πολλαπλά διασυνδεδεμένα επίπεδα. Αυτά τα επίπεδα συνεργάζονται για να επεξεργαστούν εισροές και να τις μεταβιβάσουν στο επόμενο επίπεδο, με κάθε επίπεδο να γίνεται όλο και πιο αφηρημένο και ικανό να εκτελεί πιο σύνθετες εργασίες.

Στο επίκεντρο ενός CNN βρίσκονται τα φίλτρα, τα οποία είναι υπεύθυνα για την αναγνώριση μοτίβων. Αυτά τα φίλτρα έχουν συνήθως τη μορφή ενός μπλοκ 3 x 3 και μπορούν να ρυθμιστούν ώστε να αναζητούν συγκεκριμένα μοτίβα σε μια εικόνα. Στη συνέχεια, το φίλτρο θα αναλύσει την ισοδύναμη περιοχή 3 x 3 στην εικόνα και θα αποδώσει μια αριθμητική βαθμολογία με βάση το πόσο πολύ ταιριάζει η εικόνα με το μοτίβο του φίλτρου. Κατόπιν, το φίλτρο θα μετακινηθεί μια στήλη προς τα δεξιά και θα επαναλάβει τη διαδικασία μέχρι να χαρτογραφήσει κάθε μπλοκ 3 x 3 στην εικόνα.



Εικόνα 1 Τυπική δομή συνελκτικού νευρωνικού δικτύου (CNN) (Ren, Yang, Zhang & Guo, 2019).

Προσθέτοντας περισσότερα φίλτρα με διαφορετικά μοτίβα και συνδυάζοντας όλους τους αριθμητικούς πίνακες από όλα τα φίλτρα μαζί, μπορούμε να κατανοήσουμε καλύτερα τι περιέχει η εικόνα. Αυτή η τεχνική είναι γνωστή ως συγκέντρωση (Pooling).

Το πρώτο επίπεδο του νευρωνικού δικτύου είναι υπεύθυνο για βασικές εργασίες επεξεργασίας εικόνας, όπως η ανάλυση των διαφόρων εικονοστοιχείων σε μια εικόνα. Καθώς προχωράμε βαθύτερα στο δίκτυο, τα επίπεδα γίνονται όλο και πιο αφηρημένα και είναι σε θέση να εκτελούν πιο εξελιγμένες λειτουργίες. Για παράδειγμα, το δεύτερο επίπεδο φίλτρων μπορεί να αναγνωρίσει βασικά αντικείμενα όπως εμπορευματοκιβώτια, πανιά ή υπερκατασκευές. Καθώς συνεχίζουμε να εμβαθύνουμε στο δίκτυο, τα φίλτρα μπορούν να εκτελέσουν ακόμη πιο αφηρημένες λειτουργίες, όπως να προσδιορίσουν ένα φορτηγό πλοίο, ένα ιστιοφόρο ή ένα κρουαζιερόπλοιο (Shea & Nash, 2015).

Συμπερασματικά, τα CNN είναι ισχυρά νευρωνικά δίκτυα που μπορούν να χρησιμοποιηθούν για επεξεργασία εικόνας, όπως η αναγνώριση προσώπων, η κατανόηση χειρόγραφων εγγράφων και η αναγνώριση αντικειμένων. Όσο πιο βαθύ είναι το δίκτυο, τόσο πιο αφηρημένες είναι οι εργασίες που μπορεί να εκτελέσει.

3.1.3 Αλγόριθμος SVM (Support Vector Machines)

Στο πεδίο της μηχανικής μάθησης, μία από τις πιο βασικές διαδικασίες είναι η ταξινόμηση αντικειμένων σε δύο ή περισσότερες κατηγορίες. Για παράδειγμα, προσδιορίζοντας αν μια εικόνα περιέχει ένα πλοίο ή όχι. Μια από τις πιο απλές και αποτελεσματικές μεθόδους για την επίτευξη αυτού του στόχου είναι η χρήση των Μηχανών Διανυσμάτων Υποστήριξης (SVM).

Κάθε αντικείμενο που πρόκειται να ταξινομηθεί αναπαρίσταται ως ένα σημείο σε έναν n -διάστατο χώρο, με τις συντεταγμένες αυτού του σημείου να αναφέρονται ως χαρακτηριστικά (Features). Οι SVM εκτελούν το έργο της ταξινόμησης σχεδιάζοντας ένα υπερεπίπεδο, το οποίο είναι ουσιαστικά μια γραμμή στον $2D$ χώρο ή ένα επίπεδο στον $3D$ χώρο. Αυτό το υπερεπίπεδο τοποθετείται με τέτοιο τρόπο ώστε όλα τα αντικείμενα μιας κατηγορίας να εμπίπτουν στη μία πλευρά του επιπέδου, ενώ όλα τα αντικείμενα της άλλης κατηγορίας να εμπίπτουν στην άλλη πλευρά.

Είναι πιθανό να υπάρχουν πολλά υπερεπίπεδα που θα μπορούσαν να χωρίσουν τις δύο κατηγορίες, οπότε οι SVM προσπαθούν να βρουν αυτό που διαχωρίζει καλύτερα τις δύο κατηγορίες μεγιστοποιώντας την απόσταση, γνωστή ως περιθώριο (Margin), μεταξύ των αντικειμένων της μίας κατηγορίας και των αντικειμένων της άλλης κατηγορίας. Τα σημεία που εμπίπτουν ακριβώς στο περιθώριο είναι γνωστά ως διανύσματα υποστήριξης (Support Vectors).

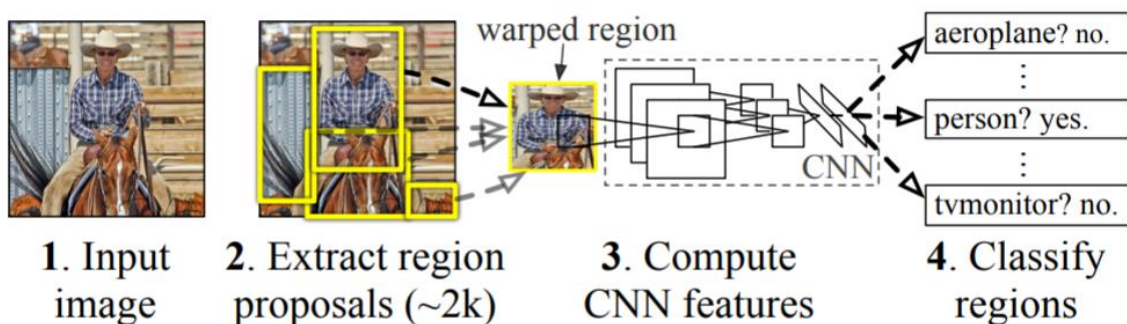
Για να βρει αρχικά αυτά τα σημεία, ο αλγόριθμος SVM απαιτεί ένα σετ εκπαίδευσης, το οποίο είναι ένα σύνολο σημείων που έχουν ήδη επισημανθεί με τη σωστή κατηγορία. Αυτός είναι και ο λόγος για τον οποίο οι SVM θεωρούνται αλγόριθμοι μάθησης με επίβλεψη. Τα πλεονεκτήματα της χρήσης των SVM είναι ότι είναι εύκολο να κατανοηθούν, να εφαρμοστούν, να χρησιμοποιηθούν, να ερμηνευτούν και απαιτούν ένα σχετικά μικρό

σύνολο δεδομένων εκπαίδευσης. Ωστόσο, ένα από τα σημαντικότερα μειονεκτήματα των SVM είναι η απλότητα τους, καθώς πολλές φορές τα αντικείμενα δεν μπορούν να διαχωριστούν από ένα μόνο υπερεπίπεδο. Οι SVM έχουν αποδειχθεί χρήσιμοι σε ένα ευρύ φάσμα εφαρμογών, όπως η αναγνώριση προσώπων, η ανίχνευση κειμένου και η αναγνώριση αντικειμένων (Cortes & Vapnik, 1995).

3.1.4 Αλγόριθμος R-CNN (Regions with CNN)

Το R-CNN είναι ένας τύπος αλγόριθμου βαθιάς μάθησης για την ανίχνευση αντικειμένων σε εικόνες. Ο αλγόριθμος λειτουργεί σε τρία στάδια:

- Το πρώτο στάδιο είναι υπεύθυνο για τη δημιουργία προτάσεων περιοχών (Region Proposals), οι οποίες αποτελούν ουσιαστικά ένα σύνολο πιθανών περιοχών ή οριοθετημένων πλαισίων που θα μπορούσαν να περιέχουν ένα αντικείμενο ενδιαφέροντος.
- Το δεύτερο στάδιο του συστήματος αποτελείται από ένα μεγάλο CNN, το οποίο χρησιμοποιείται για την εξαγωγή ενός διανύσματος χαρακτηριστικών σταθερού μήκους από κάθε περιοχή που προτείνεται από τις προτάσεις περιοχών στο πρώτο στάδιο. Το CNN εκπαιδεύεται να αναλύει τις περιοχές και να εξάγει σημαντικά χαρακτηριστικά που περιγράφουν την περιοχή. Αυτά τα χαρακτηριστικά χρησιμοποιούνται στη συνέχεια στο τρίτο και τελευταίο στάδιο του συστήματος, το οποίο αποτελείται από ένα σύνολο SVM για συγκεκριμένες κλάσεις.
- Οι SVM είναι υπεύθυνοι για την ταξινόμηση των περιοχών που προτείνονται στο πρώτο στάδιο. Λαμβάνουν τα χαρακτηριστικά από το CNN ως εισροή και τα χρησιμοποιούν για να ταξινομήσουν τις περιοχές στις διάφορες κλάσεις αντικειμένων (Girshick, 2015).



Εικόνα 2 Επισκόπηση του συστήματος ανίχνευσης αντικειμένων (Girshick, Donahue, Darrel & Malik, 2013)

Συνοψίζοντας, ο αλγόριθμος R-CNN είναι μια διαδικασία πολλαπλών βημάτων που περιλαμβάνει τη δημιουργία προτάσεων περιοχών, την εξαγωγή χαρακτηριστικών από αυτές τις περιοχές και στη συνέχεια, την ταξινόμηση αυτών των περιοχών σε διάφορες κατηγορίες αντικειμένων. Αυτό το ισχυρό και εξελιγμένο σύστημα είναι σε θέση να ανιχνεύει αντικείμενα σε εικόνες με υψηλή ακρίβεια και αποτελεσματικότητα, καθιστώντας το πολύτιμο εργαλείο σε ένα ευρύ φάσμα εφαρμογών.

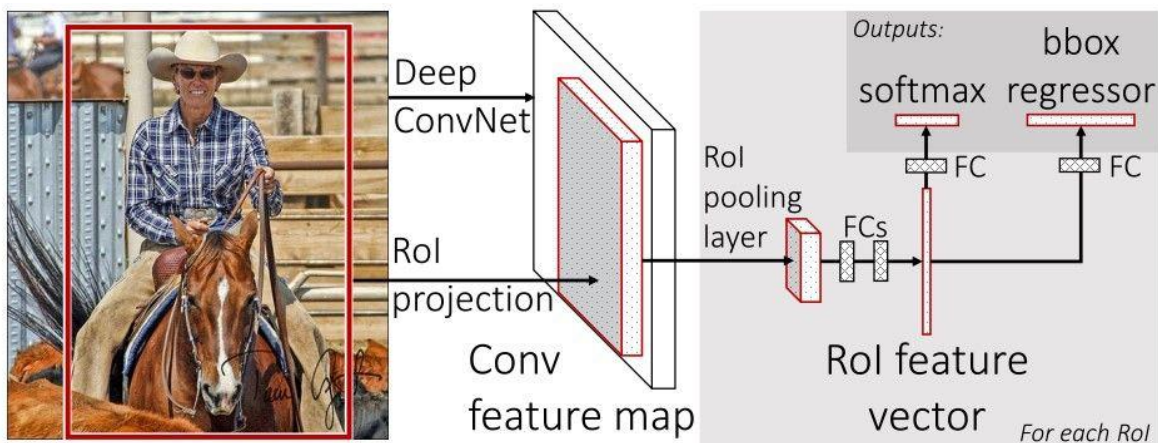
3.1.5 Αλγόριθμος Fast R-CNN

Ο αλγόριθμος Fast R-CNN αναπτύχθηκε με σκοπό τη βελτίωση του αλγορίθμου R-CNN λόγω των περιορισμών που αντιμετώπιζε. Ένα από τα σημαντικότερα προβλήματα με τον R-CNN είναι ότι η διαδικασία εκπαίδευσής του είναι χρονοβόρα και απαιτητική σε πόρους. Ο αλγόριθμος R-CNN πρώτα συντονίζει ένα CNN σε προτάσεις αντικειμένων και στη συνέχεια προσαρμόζει SVM στα χαρακτηριστικά του CNN. Αυτή η διαδικασία απαιτεί μεγάλη υπολογιστική ισχύ και αποθηκευτικό χώρο.

Για παράδειγμα, όταν χρησιμοποιείται ένα πολύ βαθύ δίκτυο, η διαδικασία εξαγωγής χαρακτηριστικών από κάθε πρόταση περιοχής και η εγγραφή τους στο δίσκο απαιτεί 2,5 ημέρες GPU για τις 5000 εικόνες του συνόλου εκπαιδευτικών δοκιμών και τα ίδια τα χαρακτηριστικά απαιτούν εκατοντάδες gigabyte αποθηκευτικού χώρου. Επιπλέον, η ανίχνευση αντικειμένων με το R-CNN είναι σχετικά αργή, καθώς διαρκεί 47 δευτερόλεπτα ανά εικόνα.

Ένα από τα βασικά πλεονεκτήματα που έχει ο Fast R-CNN σε σχέση με τον R-CNN είναι η χρήση ενός νέου επιπέδου στο CNN που ονομάζεται RoI (Region of Interest) Pooling, το οποίο επιτρέπει στον αλγόριθμο να υπολογίζει όλες τις προτάσεις περιοχής ταυτόχρονα σε ένα στάδιο. Αυτό αυξάνει σημαντικά την ταχύτητα και την ακρίβεια του αλγορίθμου.


Επίσης το Fast R-CNN δεν αποθηκεύει τα εξαγόμενα χαρακτηριστικά στην μνήμη, πράγμα που σημαίνει ότι δεν απαιτεί τόσο μεγάλο αποθηκευτικό χώρο στο δίσκο όσο το R-CNN (Girshick, 2015).



Εικόνα 3 Η αρχιτεκτονική του Fast R-CNN (Girshick, 2015)

3.1.6 Αλγόριθμος Faster R-CNN

Ο Faster R-CNN είναι μια ταχύτερη και αποδοτικότερη έκδοση του αλγορίθμου Fast R-CNN. Ο Faster R-CNN, είναι κατασκευασμένος χρησιμοποιώντας δύο κύριες μονάδες. Η πρώτη μονάδα είναι ένα βαθύ, προεκπαιδευμένο δίκτυο που ονομάζεται Δίκτυο Προτάσεων Περιοχής (Region Proposal Network – RPN) που είναι υπεύθυνο για την δημιουργία προτάσεων περιοχής. Η δεύτερη μονάδα είναι ένα δίκτυο Fast R-CNN, το οποίο χρησιμοποιεί τις προτεινόμενες περιοχές για την ανίχνευση αντικειμένων (Ren, He, Girshick & Sun, 2015).



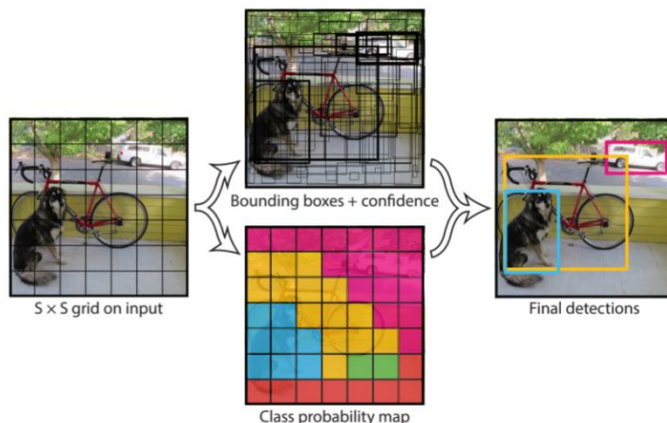
Εικόνα 4 Αρχιτεκτονική Faster R-CNN (Ren, He, Girshick & Sun, 2016)

3.1.7 Αλγόριθμος YOLO (You Only Look Once)

Ο YOLO είναι ένας αλγόριθμος που μπορεί να αναγνωρίσει αντικείμενα σε εικόνες και βίντεο σε πραγματικό χρόνο. Παρουσιάστηκε για πρώτη φορά το 2016 και έκτοτε έχουν αναπτυχθεί διάφορες παραλλαγές, όπως οι YOLOv2, YOLOv3 κ.λπ. Η βασική ιδέα πίσω από τον YOLO είναι να διαιρεί την εικόνα εισόδου σε ένα πλέγμα κελιών και να προβλέπει τα πλαίσια οριοθέτησης και τις πιθανότητες κλάσης για κάθε κελί. Οι πιθανότητες κλάσης είναι η πιθανότητα το αντικείμενο να ανήκει σε μια συγκεκριμένη κλάση (π.χ. πλοίο, αυτοκίνητο κ.λπ.).

Τα βήματα που ακολουθεί ο YOLO για την αναγνώριση ενός αντικειμένου είναι:

- **Διαίρεση της εικόνα σε πλέγμα:** Το πρώτο βήμα είναι η διαίρεση της εικόνας εισροής σε ένα πλέγμα κελιών. Κάθε κελί είναι υπεύθυνο για την αναγνώριση αντικειμένων που βρίσκονται μέσα στην περιοχή του. Το μέγεθος του πλέγματος μπορεί να μεταβάλλεται ανάλογα με το μέγεθος των προς αναγνώριση αντικειμένων και το μέγεθος της εικόνας εισροής.
- **Πρόβλεψη πιθανοτήτων κλάσεων και οριοθετημένων πλαισίων:** Για κάθε κελί, ο αλγόριθμος προβλέπει τις πιθανότητες κλάσης και τα πλαίσια οριοθέτησης των αντικειμένων που βρίσκονται εντός της περιοχής του κελιού.
- **Non-max suppression:** Μια τεχνική που ονομάζεται non-max suppression χρησιμοποιείται για την αφαίρεση των περιττών προβλέψεων. Αυτή η τεχνική αφαιρεί τα επικαλυπτόμενα οριοθετημένα πλαίσια που έχουν χαμηλότερο βαθμό εμπιστοσύνης.
- **Εκροή:** Η τελική εκροή του αλγορίθμου είναι ένας κατάλογος οριοθετημένων πλαισίων και πιθανοτήτων κλάσης για κάθε αντικείμενο που ανιχνεύεται στην εικόνα.



Εικόνα 5 Το μοντέλο του αλγορίθμου YOLO (Redmon, Divvala, Girshick & Farhadi, 2016)

Ο YOLO, χρησιμοποιεί ένα μοναδικό νευρωνικό δίκτυο το οποίο είναι ικανό να προβλέπει οριοθετημένα πλαίσια και πιθανότητες κλάσης απευθείας από πλήρεις εικόνες σε μία μόνο αξιολόγηση. Αυτό εξαλείφει την ανάγκη για πολλαπλά στάδια ή ξεχωριστές δομές και επιτρέπει τη βελτιστοποίηση ολόκληρου του δικτύου ανίχνευσης από άκρη σε άκρη για μέγιστη απόδοση.

Ένα από τα κύρια πλεονεκτήματα αυτού του συστήματος είναι η ταχύτητα και η αποτελεσματικότητά του. Το βασικό μοντέλο YOLO είναι σε θέση να επεξεργάζεται εικόνες σε πραγματικό χρόνο με ταχύτητα 45 εικόνες το δευτερόλεπτο (Frames Per Second – FPS). Μια μικρότερη έκδοση του δικτύου, που ονομάζεται Fast YOLO, είναι ακόμη πιο εντυπωσιακή, με ρυθμό επεξεργασίας 155 FPS, ενώ εξακολουθεί να επιτυγχάνει διπλάσια μέση ακρίβεια (mAP) από άλλους αλγορίθμους πραγματικού χρόνου.

Ο YOLO και οι παραλλαγές του (YOLOv2, YOLOv3 κ.λπ.) διαφέρουν ως προς την αρχιτεκτονική του CNN, τους χάρτες χαρακτηριστικών, το μέγεθος του πλέγματος, τη συνάρτηση απώλειας που βελτιστοποιούν και τον αριθμό των αγκυρών (anchors) που χρησιμοποιούν. Είναι επίσης σημαντικό να σημειωθεί ότι οι παραλλαγές του YOLO (v2, v3 κ.λπ.) βελτιώνουν το αρχικό YOLO χρησιμοποιώντας πιο ισχυρά CNN, μικρότερα μεγέθη πλέγματος και κουτιά αγκυρών, γεγονός που τους επιτρέπει να ανιχνεύουν μικρότερα αντικείμενα και αντικείμενα με διαφορετικές αναλογίες διαστάσεων (Redmon, Divvala, Girshick & Farhadi, 2016).

3.1.8 Αλγόριθμος SSD (Single Shot MultiBox Detector)

Ο αλγόριθμος SSD είναι ένα άλλο παράδειγμα αλγορίθμου ανίχνευσης αντικειμένων που χρησιμοποιεί ένα νευρωνικό δίκτυο. Έχει σχεδιαστεί για να είναι γρήγορος και αποτελεσματικός και χρειάζεται μόνο μια εικόνα εισροής και πληροφορίες σχετικά με τη θέση των αντικειμένων στην εικόνα αυτή (οι πληροφορίες αυτές ονομάζονται ground truth boxes) κατά την εκπαίδευση.

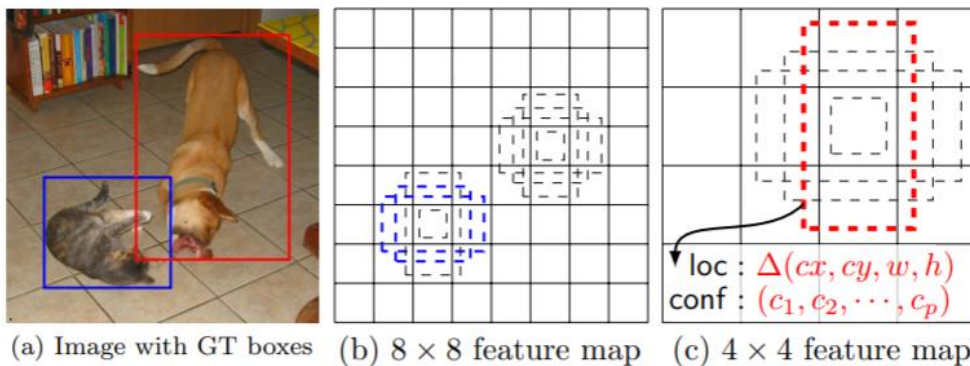
Ο SSD αξιολογεί ένα μικρό σύνολο προεπιλεγμένων κουτιών διαφορετικών σχημάτων και μεγεθών (που ονομάζονται αναλογίες διαστάσεων) στους χάρτες χαρακτηριστικών σε διαφορετικές κλίμακες. Για κάθε προεπιλεγμένο πλαίσιο, ο αλγόριθμος προβλέπει το σχήμα του αντικειμένου και το επίπεδο εμπιστοσύνης.

Τα βήματα που ακολουθεί ο SSD για την αναγνώριση είναι:

- **Εξαγωγή χαρακτηριστικών:** Το πρώτο βήμα είναι η εισαγωγή της εικόνας σε ένα βαθύ CNN για την εξαγωγή χαρτών χαρακτηριστικών. Αυτοί οι χάρτες χαρακτηριστικών χρησιμοποιούνται στο επόμενο βήμα σαν εισροές.

- **Συνελικτικά επίπεδα:** Οι χάρτες χαρακτηριστικών περνάνε μέσα από συνελικτικά επίπεδα που είναι ειδικά σχεδιασμένα για να προβλέπουν την κατηγορία και τη θέση των αντικειμένων στην εικόνα. Αυτά τα επίπεδα συνελικτικής ανάλυσης ονομάζονται "πρόσθετα επίπεδα" και προστίθενται πάνω στο προεκπαιδευμένο CNN.
- **Πρόβλεψη:** Η εκροή των προηγούμενων επιπέδων περνάει στη συνέχεια από διάφορα επίπεδα πρόβλεψης που προβλέπουν την κατηγορία και τη θέση των αντικειμένων στην εικόνα. Αυτές οι προβλέψεις γίνονται σε πολλαπλές κλίμακες, επιτρέποντας στον αλγόριθμο να ανιχνεύει αντικείμενα διαφορετικών μεγεθών.
- **Non-max suppression:** Γίνεται χρήση non-max suppression για την αφαίρεση των επικαλυπτόμενων πλαισίων οριοθέτησης που έχουν χαμηλότερο βαθμό εμπιστοσύνης.
- **Εκροή:** Η τελική εκροή του αλγορίθμου είναι ένας κατάλογος οριοθετημένων κουτιών και πιθανοτήτων κλάσης για κάθε αντικείμενο που ανιχνεύεται στην εικόνα.

Ο SSD έχει σχεδιαστεί για να είναι γρήγορος και αποτελεσματικός, χρησιμοποιεί ένα μόνο CNN για την πρόβλεψη της κατηγορίας και της θέσης των αντικειμένων στην εικόνα και μπορεί να ανιχνεύει αντικείμενα διαφορετικών μεγεθών χρησιμοποιώντας πολλαπλές κλίμακες και χάρτες χαρακτηριστικών (Liu, Anguelov, Erhan, Szegedy, Reed, Fu & Berg, 2016).



Εικόνα 6 Το πλαίσιο του αλγορίθμου SSD (Liu, Anguelov, Erhan, Szegedy, Reed, Fu & Berg, 2016)


3.1.9 Αποτελέσματα

Στη ναυτιλιακή βιομηχανία, όπου ο εντοπισμός άλλων πλοίων σε πραγματικό χρόνο είναι κρίσιμος, είναι σημαντικό να χρησιμοποιείται ένας γρήγορος και ακριβής αλγόριθμος.

Μεταξύ των δημοφιλών αλγορίθμων ανίχνευσης αντικειμένων, ο Faster R-CNN φαίνεται να είναι ο πιο αργός αλλά ο πιο ακριβής. Κατά την αξιολόγηση του αλγορίθμου, διαπιστώθηκε ότι ο Faster R-CNN είχε mAP 87,69%. Ωστόσο, η ταχύτητα ανίχνευσης ήταν μόνο 7 FPS. Από την άλλη πλευρά, ο YOLO και οι παραλλαγές του, όπως ο YOLOv3, είναι γνωστοί για την ταχύτητά τους. Συγκεκριμένα, ο YOLOv3 είχε ταχύτητα ανίχνευσης 51 FPS, αλλά η mAP του ήταν 80,17%. Ο αλγόριθμος SSD είχε επίσης καλές επιδόσεις, με mAP 82,41% και ταχύτητα ανίχνευσης 32 FPS (Tan, Huangfu, Wu & Chen, 2020).

Η ανίχνευση πλοίων από ψηφιακές εικόνες προσφέρει μεγαλύτερη ακρίβεια από την ανίχνευση με χρήση SAR (Synthetic Aperture Radar) και SOI (Spaceborne Optical Images). Η υψηλή ακρίβεια και η ανίχνευση σε πραγματικό χρόνο βρίσκει εφαρμογές στην διαχείριση λιμένων, τη διασυνοριακή ανίχνευση πλοίων, στα αυτόνομα πλοία και στην ασφαλή πλοήγηση.

Ο αλγόριθμος YOLOv3 συγκεκριμένα μπορεί να χρησιμοποιηθεί για την ανίχνευση πλοίων σε πραγματικό χρόνο και μπορεί να χρησιμοποιηθεί στην παρακολούθηση, την ακριβή ταξινόμηση και τον εντοπισμό έξι τύπων πλοίων, ore carriers, bulk carriers, πλοία γενικού φορτίου, πλοία εμπορευματοκιβωτίων, αλιευτικά και επιβατηγά πλοία (Li, Deng, Yang, Liu & Gu, 2021).



Εικόνα 7 Ανίχνευση πλοίων μέσω υπολογιστικής όρασης (Li, Deng, Yang, Liu & Gu, 2021)

3.2 Αλγόριθμοι Εύρεσης Βέλτιστης Διαδρομής

Οι δαπάνες λειτουργίας ενός πλοίου περιλαμβάνουν τους μισθούς του πληρώματος, την συντήρηση και επισκευή του πλοίου, την θαλάσσια ασφάλιση, τις προμήθειες, τα ανταλλακτικά και τα καύσιμα. Από αυτές τις δαπάνες, η κατανάλωση καυσίμων είναι η σημαντικότερη, χαρακτηριστικά μπορεί να φτάσει το 60% (Stratiotis, 2018) των συνολικών λειτουργικών δαπανών. Οι αυξανόμενες και κυμαινόμενες τιμές των καυσίμων έχουν γίνει μείζον θέμα ανησυχίας για τις ναυτιλιακές εταιρείες, καθώς έχουν άμεσο αντίκτυπο στην κερδοφορία τους. Για να περιορίσουν αυτή την ανησυχία, οι ναυτιλιακές εταιρείες αναζητούν τρόπους βελτιστοποίησης των λειτουργιών τους και μείωσης της κατανάλωσης καυσίμων. Μια αποτελεσματική στρατηγική για την επίτευξη αυτού του στόχου είναι η βελτιστοποίηση της διαδρομής του πλοίου προκειμένου να ελαχιστοποιηθεί η κατανάλωση καυσίμων. Η εύρεση της βέλτιστης διαδρομής μπορεί να μειώσει σημαντικά το κόστος των καυσίμων και να βοηθήσει τις ναυτιλιακές εταιρείες να παραμείνουν ανταγωνιστικές στην αγορά. Με τη μείωση της κατανάλωσης καυσίμων, τα πλοία εκπέμπουν λιγότερους ρύπους και αέρια του θερμοκηπίου στην ατμόσφαιρα, συμβάλλοντας στη μείωση της ατμοσφαιρικής ρύπανσης και της υπερθέρμανσης του πλανήτη. Αυτό μπορεί να βοηθήσει τις ναυτιλιακές εταιρείες να ανταποκριθούν στους όλο και πιο αυστηρούς περιβαλλοντικούς κανονισμούς και να βελτιώσουν τη βιωσιμότητα και την κοινωνική τους ευθύνη (Duy & Minh, 2021).

3.2.1 Πρόβλημα του Πλανόδιου Πωλητή (Traveling Salesman Problem – TSP)

Το Πρόβλημα του Πλανόδιου Πωλητή είναι ένα κλασικό πρόβλημα βελτιστοποίησης που θέτει το ακόλουθο ερώτημα: "Δίνεται μια λίστα πόλεων και η απόσταση μεταξύ κάθε ζεύγους πόλεων, ποια είναι η συντομότερη δυνατή διαδρομή που επισκέπτεται κάθε πόλη ακριβώς μία φορά και επιστρέφει στην πόλη εκκίνησης;" Το πρόβλημα μπορεί να περιγραφεί μαθηματικά ως ένα πρόβλημα βελτιστοποίησης όπου ο στόχος είναι η ελαχιστοποίηση της συνολικής απόστασης που διανύεται κατά την επίσκεψη ενός συνόλου πόλεων. Το TSP θεωρείται NP-Hard πρόβλημα, που σημαίνει ότι δεν υπάρχει γνωστός αλγόριθμος που να μπορεί να λύσει το πρόβλημα σε πολυωνυμικό χρόνο για μεγάλο αριθμό πόλεων. Αυτό καθιστά το TSP ένα δύσκολο πρόβλημα για επίλυση και έχουν αναπτυχθεί διάφορες μέθοδοι για την εξεύρεση προσεγγιστικών λύσεων.

Το Ασύμμετρο Πρόβλημα του Πλανόδιου Πωλητή (ATSP) είναι μια παραλλαγή του κλασικού TSP, όπου η απόσταση μεταξύ πόλεων δεν είναι συμμετρική, δηλαδή η απόσταση από την πόλη A στην πόλη B δεν είναι απαραίτητα η ίδια με την απόσταση από την πόλη B στην πόλη A (Gutin & Punnen, 2002). Αυτή η παραλλαγή είναι πιο κατάλληλη για προβλήματα του πραγματικού κόσμου, όπως η ναυτιλία, όπου η απόσταση μεταξύ δύο τοποθεσιών μπορεί να επηρεάζεται από παράγοντες όπως ο καιρός, οι συνθήκες της θάλασσας και το φορτίο. Στο πλαίσιο της ναυτιλίας, η λύση του ATSP μπορεί να χρησιμοποιηθεί για την εύρεση της πιο αποδοτικής διαδρομής που πρέπει να ακολουθήσει ένα πλοίο, λαμβάνοντας υπόψη την ασύμμετρη απόσταση μεταξύ των λιμένων. Ο στόχος

είναι η ελαχιστοποίηση της συνολικής διανυόμενης απόστασης και της κατανάλωσης καυσίμου, λαμβάνοντας υπόψη τους περιορισμούς του φορτίου και του πλοίου.

Μια από τις πιο συνηθισμένες προσεγγίσεις για την επίλυση του TSP είναι η χρήση μιας τεχνικής που ονομάζεται branch-and-bound. Η τεχνική αυτή περιλαμβάνει τη δημιουργία ενός δέντρου πιθανών λύσεων, όπου κάθε κόμβος του δέντρου αντιπροσωπεύει μια μερική λύση. Ο αλγόριθμος ξεκινά με τη διερεύνηση όλων των πιθανών διαδρομών από την αρχική πόλη και στη συνέχεια διακλαδίζεται για να διερευνήσει όλες τις πιθανές διαδρομές από κάθε μία από τις πόλεις που επισκέφθηκε. Στη συνέχεια, ο αλγόριθμος χρησιμοποιεί κατώτερα και ανώτερα όρια της συνολικής απόστασης για να κλαδέψει το δέντρο αναζήτησης και να αποφύγει την εξερεύνηση διαδρομών που είναι εγγυημένα χειρότερες από την τρέχουσα καλύτερη λύση. Μια άλλη δημοφιλής προσέγγιση για την επίλυση του TSP είναι η χρήση ευρετικών αλγορίθμων, όπως η προσομοιωμένη απόκτηση, οι γενετικοί αλγόριθμοι και η βελτιστοποίηση αποικιών μυρμηγκιών. Αυτοί οι αλγόριθμοι χρησιμοποιούν τεχνικές εμπνευσμένες από φυσικές διαδικασίες για να εξερευνήσουν το χώρο λύσεων και να βρουν σχεδόν βέλτιστες λύσεις. Το TSP μπορεί επίσης να επιλυθεί με τη χρήση ακριβών αλγορίθμων, όπως οι αλγόριθμοι branch-and-cut, branch-and-price και δυναμικού προγραμματισμού. Αυτοί οι αλγόριθμοι είναι σε θέση να βρουν την ακριβή λύση του προβλήματος. (Gutin & Punnen, 2002).

3.2.2 Αλγόριθμος Branch-and-Bound


Ο αλγόριθμος Branch-and-bound είναι μια τεχνική που χρησιμοποιείται για την επίλυση προβλημάτων βελτιστοποίησης, όπως το ATSP. Πρόκειται για μια μέθοδο που περιλαμβάνει τη δημιουργία ενός δέντρου πιθανών λύσεων, όπου κάθε κόμβος του δέντρου αντιπροσωπεύει μια μερική λύση. Ο αλγόριθμος ξεκινά με τη διερεύνηση όλων των πιθανών διαδρομών από την αρχική πόλη και στη συνέχεια διακλαδίζεται για να διερευνήσει όλες τις πιθανές διαδρομές από κάθε μία από τις πόλεις που επισκέφθηκε. Ο αλγόριθμος λειτουργεί διατηρώντας ένα σύνολο κατώτερων και ανώτερων ορίων για τη συνολική απόσταση της λύσης. Το κατώτερο όριο είναι ένα εγγυημένο κατώτερο όριο της συνολικής απόστασης της λύσης και υπολογίζεται με τη χρήση μιας προσέγγισης του προβλήματος. Το ανώτερο όριο είναι μια εκτίμηση της καλύτερης λύσης που έχει βρεθεί μέχρι στιγμής. Για κάθε πόλη που επισκέπτεται, ο αλγόριθμος διακλαδίζεται για να εξερευνήσει όλες τις πιθανές διαδρομές από την πόλη αυτή. Καθώς ο αλγόριθμος εξερευνά τον χώρο λύσεων, χρησιμοποιεί τα κατώτερα και ανώτερα όρια για να κλαδέψει το δέντρο αναζήτησης και να αποφύγει την εξερεύνηση διαδρομών που είναι εγγυημένα χειρότερες από την τρέχουσα καλύτερη λύση. Ο αλγόριθμος συνεχίζει να εξερευνά το χώρο λύσεων μέχρι να φτάσει σε έναν κόμβο φύλλων, ο οποίος αντιπροσωπεύει μια ολοκληρωμένη λύση. Σε αυτό το σημείο, ο αλγόριθμος συγκρίνει τη λύση με την τρέχουσα καλύτερη λύση και ενημερώνει το ανώτερο όριο εάν η λύση είναι καλύτερη. Στη συνέχεια, ο αλγόριθμος επιστρέφει στον προηγούμενο κόμβο και συνεχίζει την αναζήτηση (Mamat & Bon, 2019).

Ο αλγόριθμος branch-and-bound είναι μια ισχυρή τεχνική για την επίλυση προβλημάτων βελτιστοποίησης, όπως το ATSP. Είναι ένας ακριβής αλγόριθμος που εγγυάται την εύρεση της βέλτιστης λύσης, αλλά μπορεί να μην είναι πρακτικός για μεγάλες περιπτώσεις του

προβλήματος. Ο αλγόριθμος μπορεί να είναι αργός λόγω του μεγάλου αριθμού μερικών λύσεων που πρέπει να διερευνηθούν, αλλά είναι εγγυημένη η εύρεση της βέλτιστης λύσης. Ένα από τα πλεονεκτήματα της χρήσης του αλγορίθμου branch-and-bound είναι ότι μπορεί να κλαδέψει το δέντρο αναζήτησης εξαλείφοντας τα κλαδιά που δεν οδηγούν σε βέλτιστη λύση, με αυτόν τον τρόπο ο αλγόριθμος μπορεί να αποφύγει την εξερεύνηση διαδρομών που είναι εγγυημένα χειρότερες από την τρέχουσα βέλτιστη λύση.

3.2.3 Τεχνητό Νευρωνικό Δίκτυο (Artificial Neural Network – ANN)

Το ANN είναι ένα νευρωνικό δίκτυο που έχει ως πρότυπο τη δομή και τη λειτουργία του ανθρώπινου εγκεφάλου. Αποτελείται από διασυνδεδεμένους νευρώνες που επεξεργάζονται και μεταδίδουν πληροφορίες. Ένα ANN αποτελείται από επίπεδα διασυνδεδεμένων νευρώνων που δέχονται εισροές, εκτελούν υπολογισμούς και παράγουν εκροές. Οι εισροές του δικτύου αναφέρονται συχνά ως επίπεδο εισόδου, ενώ οι εκροές ως επίπεδο εξόδου. Υπάρχει ακόμα ένα επίπεδο μεταξύ τους που ονομάζεται κρυφό επίπεδο. Κάθε νευρώνας στο δίκτυο λαμβάνει εισροή από άλλους νευρώνες, εκτελεί έναν υπολογισμό πάνω στη συγκεκριμένη εισαγωγή και, στη συνέχεια, μεταδίδει το αποτέλεσμα σε άλλους νευρώνες στο επόμενο επίπεδο. Ο υπολογισμός που εκτελεί ένας νευρώνας είναι γνωστός ως συνάρτηση ενεργοποίησης και έχει σχεδιαστεί για να επιφέρει μη γραμμικότητα στο δίκτυο, επιτρέποντάς του να μοντελοποιεί πολύπλοκες σχέσεις μεταξύ εισροών και εκροών. Η ισχύς της σύνδεσης μεταξύ των νευρώνων αντιπροσωπεύεται από ένα βάρος, το οποίο είναι μια τιμή που αποδίδεται σε κάθε εισροή. Αυτά τα βάρη προσαρμόζονται κατά τη διάρκεια της διαδικασίας εκπαίδευσης για τη βελτιστοποίηση της απόδοσης του δικτύου.



Εικόνα 8 Ένα ANN με δύο κρυφά επίπεδα (Dertat, 2017).

Ο πιο συνηθής τύπος ANN είναι το νευρωνικό δίκτυο τροφοδότησης, το οποίο αποτελείται από επίπεδα νευρώνων που συνδέονται σε ένα κατευθυνόμενο άκυκλο γράφημα. Η πληροφορία ρέει μέσω του δικτύου προς μία κατεύθυνση, από το επίπεδο εισόδου προς το

επίπεδο εξόδου. Μπορούν να εκπαιδευτούν χρησιμοποιώντας διάφορες τεχνικές, όπως η μέθοδος ανάστροφης διάδοσης η οποία είναι και η πιο συνηθισμένη μέθοδος που χρησιμοποιείται για την εκπαίδευση των ANN (Zhang, Patuwo & Hu, 1998).

Τα ANN μπορούν να χρησιμοποιηθούν για τη βελτιστοποίηση των δρομολογίων στη ναυτιλία, χρησιμοποιώντας ιστορικά δεδομένα για την πρόβλεψη της βέλτιστης διαδρομής για ένα πλοίο. Η διαδικασία περιλαμβάνει συνήθως τα ακόλουθα βήματα:

- **Συλλογή και επεξεργασία ιστορικών δεδομένων:** Αυτό περιλαμβάνει πληροφορίες όπως οι καιρικές συνθήκες, η θαλάσσια κυκλοφορία και τα χαρακτηριστικά των σκαφών. Τα δεδομένα αυτά χρησιμοποιούνται για την εκπαίδευση του ANN.
- **Σχεδιασμός της αρχιτεκτονικής του ANN:** Γίνεται διαμόρφωση του αριθμού των επιπέδων και του αριθμού των νευρώνων σε κάθε επίπεδο. Η αρχιτεκτονική θα πρέπει να σχεδιαστεί έτσι ώστε να μοντελοποιεί αποτελεσματικά τις σχέσεις μεταξύ εισροών και εκροών.
- **Εκπαίδευση του ANN:** Το ANN εκπαιδεύεται χρησιμοποιώντας τα ιστορικά δεδομένα και έναν αλγόριθμο βελτιστοποίησης, όπως η κάθοδος κλίσης. Στόχος της διαδικασίας εκπαίδευσης είναι η προσαρμογή των βαρών του δικτύου ώστε να μπορεί να προβλέπει με ακρίβεια τη βέλτιστη διαδρομή για ένα δεδομένο σύνολο εισροών.
- **Χρήση του εκπαιδευμένου ANN:** Μόλις το ANN εκπαιδευτεί, μπορεί να χρησιμοποιηθεί για να προβλέψει τη βέλτιστη διαδρομή για ένα πλοίο, λαμβάνοντας υπόψη νέες εισροές, όπως οι τρέχουσες καιρικές συνθήκες και η θαλάσσια κυκλοφορία (Beşikçi, Arslan, Turan & Ölçer, 2016).

Πρέπει να σημειωθεί ότι η ακρίβεια των προβλέψεων του ANN εξαρτάται από την ποιότητα των δεδομένων και το σχεδιασμό του δικτύου. Είναι επίσης σημαντικό να ληφθεί υπόψη ότι οι ναυτιλιακές διαδρομές επηρεάζονται από πολλές μεταβλητές και παράγοντες, όπως οι καιρικές συνθήκες, η θαλάσσια κυκλοφορία και τα χαρακτηριστικά των πλοίων, οπότε το ANN πρέπει να εκπαιδευτεί με αρκετά δεδομένα που μπορούν να καλύψουν όλες αυτές τις μεταβλητές για να κάνει ακριβείς προβλέψεις.

3.2.4 Real-coded Genetic Algorithm (RCGA)

Ο RCGA είναι ένας τύπος αλγορίθμου βελτιστοποίησης που εμπνέεται από τη διαδικασία της φυσικής επιλογής. Χρησιμοποιείται για την εύρεση της βέλτιστης λύσης σε ένα πρόβλημα προσομοιώνοντας τη διαδικασία της εξέλιξης και επιλέγοντας τις καλύτερες λύσεις με βάση την αρμοστικότητα τους. Όσον αφορά τον υπολογισμό του ελάχιστου χρόνου ταξιδιού ή της βέλτιστης διαδρομής για ένα πλοίο, ο RCGA μπορεί να χρησιμοποιηθεί για την εύρεση της πιο αποδοτικής διαδρομής που πρέπει να ακολουθήσει

ένα πλοίο με βάση διάφορους περιορισμούς, όπως οι καιρικές συνθήκες, οι συνθήκες της θάλασσας και οι θαλάσσιες οδοί.

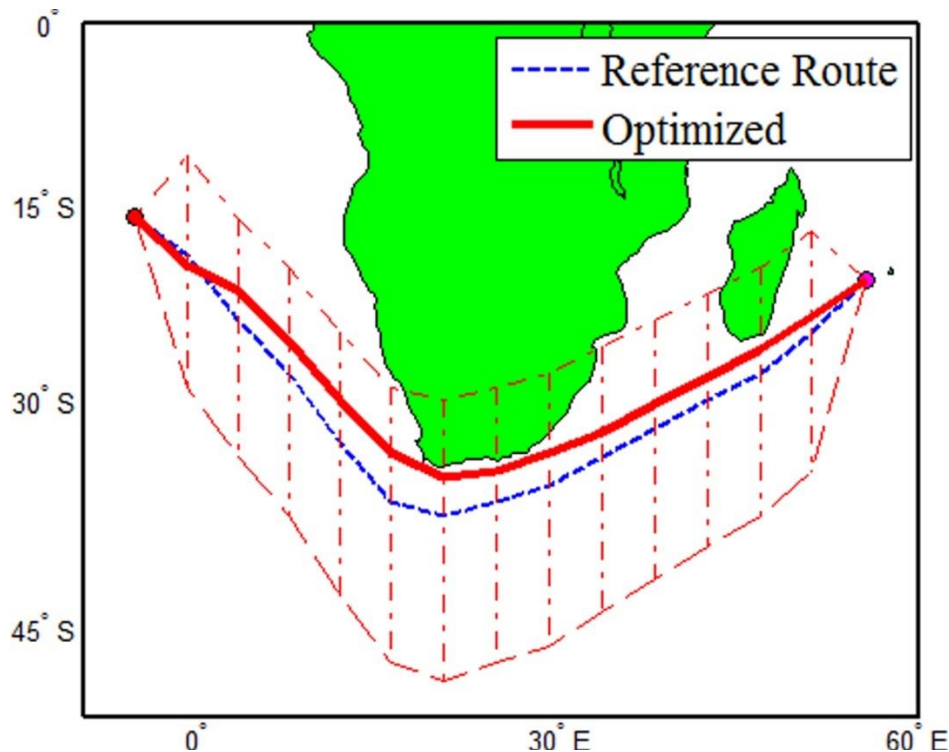
Η βασική διαδικασία του RCGA έχει ως εξής:

- **Αρχικοποίηση:** Ο αλγόριθμος ξεκινά με τη δημιουργία ενός πληθυσμού πιθανών λύσεων, που ονομάζονται χρωμοσώματα. Κάθε χρωμόσωμα αντιπροσωπεύει μια πιθανή διαδρομή που μπορεί να ακολουθήσει το πλοίο και κωδικοποιείται ως ένα σύνολο πραγματικών αριθμών που αντιπροσωπεύουν τις συντεταγμένες των διαφόρων σημείων διαδρομής.
- **Αξιολόγηση:** Η αρμοστικότητα κάθε χρωμοσώματος αξιολογείται με βάση το πόσο καλά ανταποκρίνεται στους στόχους του προβλήματος. Για παράδειγμα, ο συνολικός χρόνος ταξιδιού, η διανυόμενη απόσταση και ο αριθμός των περιορισμών.
- **Επιλογή:** Επιλέγονται τα χρωμοσώματα με την υψηλότερη αρμοστικότητα για χρήση στην επόμενη γενιά.
- **Διασταύρωση:** Δημιουργούνται νέα χρωμοσώματα απογόνων συνδυάζοντας τα επιλεγμένα χρωμοσώματα. Αυτό μιμείται τη διαδικασία του γενετικού ανασυνδυασμού που συμβαίνει στους φυσικούς οργανισμούς που ονομάζετε διασταύρωση.
- **Μετάλλαξη:** Τα χρωμοσώματα που προκύπτουν υποβάλλονται στη συνέχεια σε μια μικρή τυχαία τροποποίηση που ονομάζεται μετάλλαξη. Πρόκειται για μια προσομοίωση της διαδικασίας γενετικής μετάλλαξης που συμβαίνει στους φυσικούς οργανισμούς.
- **Επανάληψη την διαδικασίας:** Η διαδικασία επαναλαμβάνεται για αρκετές γενιές, με κάθε γενιά να παράγει νέα χρωμοσώματα απογόνων που αξιολογούνται, επιλέγονται και χρησιμοποιούνται για τη δημιουργία της επόμενης γενιάς.
- **Τερματισμός:** Ο αλγόριθμος σταματά όταν βρεθεί μια ικανοποιητική λύση ή όταν ικανοποιηθεί ένα κριτήριο τερματισμού, όπως η επίτευξη ενός μέγιστου αριθμού γενεών ή ενός ικανοποιητικού επιπέδου σύγκλισης (Herrera, Lozano & Verdegay, 1998).

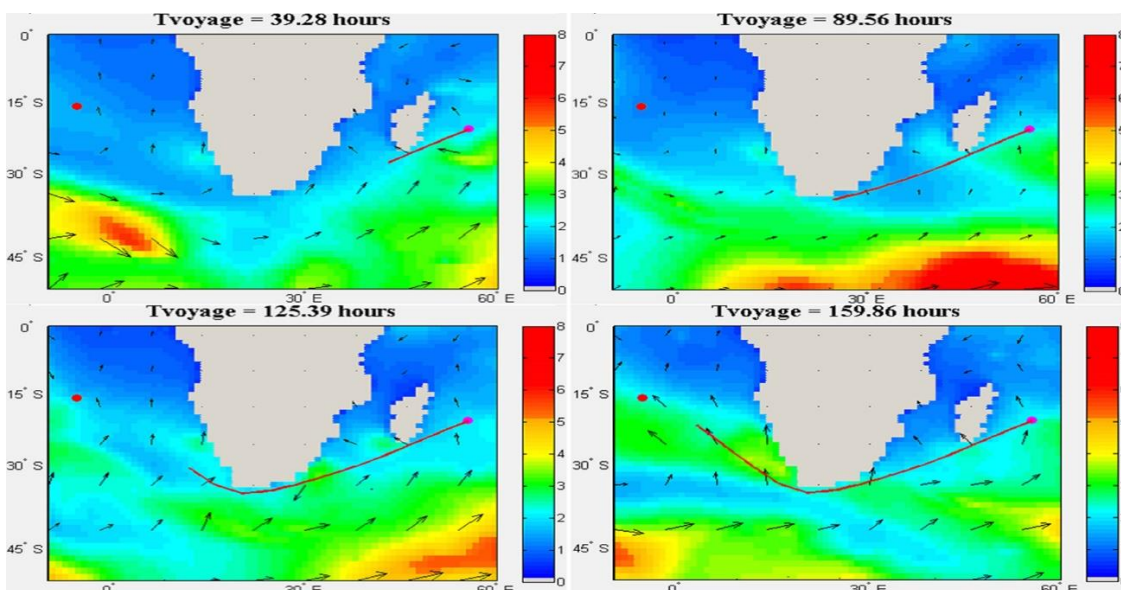
3.2.5 Αποτελέσματα

Μια πρόσφατη έρευνα (Wang, Li, Li, Veremey & Sotnikova, 2018) έχει αναδείξει τις δυνατότητες του RCGA όχι μόνο στη βελτιστοποίηση του χρόνου ταξιδιού αλλά και στη σχεδίαση ναυτιλιακών διαδρομών που αποφεύγουν επικίνδυνες καιρικές συνθήκες. Πρόκειται για ένα σημαντικό εύρημα, διότι υποδηλώνει ότι ο αλγόριθμος έχει την

ικανότητα να εντοπίζει και να παρακάμπτει πιθανούς κινδύνους, κάτι που είναι ζωτικής σημασίας στη ναυτιλιακή βιομηχανία για την ασφάλεια του πλοίου, του πληρώματος και του φορτίου. Τα αποτελέσματα της μελέτης καταδεικνύουν ότι ο RCGA μπορεί να αποτελέσει ένα πολύτιμο εργαλείο για τις ναυτιλιακές εταιρείες για τη βελτιστοποίηση των δρομολογίων των πλοίων τους. Με τη δυνατότητα ελαχιστοποίησης του χρόνου ταξιδιού και αποφυγής επικίνδυνων καιρικών συνθηκών, ο RCGA μπορεί να βοηθήσει τις ναυτιλιακές εταιρείες να αυξήσουν την αποδοτικότητά τους και να μειώσουν τον κίνδυνο ατυχημάτων. Επιπλέον, ο αλγόριθμος μπορεί να προσαρμοστεί ώστε να συμπεριλάβει και άλλα κριτήρια βελτιστοποίησης, όπως η κατανάλωση καυσίμων και η συνολική απόσταση, για να βελτιώσει περαιτέρω την αποτελεσματικότητα.



Εικόνα 9 Αποτελέσματα βέλτιστης διαδρομής (Wang, Li, Li, Veremey & Sotnikova, 2018).



Εικόνα 10 Στιγμιότυπα της βέλτιστης διαδρομής σε διαφορετικούς χρόνους ταξιδιού (Wang, Li, Li, Veremey & Sotnikova, 2018).

3.3 Αλγόριθμοι Αποφυγής Συγκρούσεων


Με την ραγδαία αύξηση του αριθμού των πλοίων για θαλάσσιες μεταφορές και την πολυπλοκότητα των θαλάσσιων διαδρομών, έχει αυξηθεί αντίστοιχα και ο αριθμός των ναυτικών ατυχημάτων που προκαλούνται από ανθρώπινα λάθη. Το γεγονός αυτό έχει αναδείξει την ανάγκη για προηγμένη τεχνολογία, όπως τα αυτόνομα συστήματα πλοήγησης, για τη βελτίωση της ασφάλειας στη ναυτιλιακή βιομηχανία. Τα αυτόνομα συστήματα πλοήγησης έχουν σχεδιαστεί για να προβλέπουν τους πιθανούς κινδύνους από δυναμικά εμπόδια, όπως άλλα πλοία, σε πολύπλοκες καταστάσεις και να παρέχουν μια ασφαλή διαδρομή. Τα συστήματα αυτά χρησιμοποιούν προηγμένους αλγορίθμους, όπως η βαθιά μάθηση και η μηχανική μάθηση, για να αναλύουν δεδομένα αισθητήρων και να κάνουν προβλέψεις σχετικά με τις κινήσεις άλλων πλοίων. Μπορούν επίσης να χρησιμοποιούν δεδομένα από τα συστήματα πλοήγησης του πλοίου, όπως το GPS, για να προβλέπουν τις κινήσεις του πλοίου και να εντοπίζουν πιθανές συγκρούσεις. Η χρήση αυτόνομων συστημάτων πλοήγησης μπορεί να μειώσει σημαντικά τον κίνδυνο σύγκρουσης και να βελτιώσει την ασφάλεια των ναυτιλιακών εργασιών. Μπορεί επίσης να αυξήσει την αποδοτικότητα των ναυτιλιακών επιχειρήσεων μειώνοντας την ανάγκη για ανθρώπινη παρέμβαση και επιτρέποντας στα πλοία να προηγούνται σε δύσβατα ύδατα και δυσμενείς καιρικές συνθήκες.

Η ανάπτυξη αυτόνομων συστημάτων πλοήγησης είναι ένα δύσκολο έργο και απαιτεί πολλή έρευνα και ανάπτυξη. Ωστόσο, με τις εξελίξεις στην τεχνολογία της βαθιάς μάθησης είναι δυνατή η δημιουργία συστημάτων που είναι ικανά να χειρίζονται πολύπλοκα σενάρια και να κάνουν ακριβείς προβλέψεις.

3.3.1 Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Network – RNN)

Ένα RNN είναι ένας τύπος αλγορίθμου βαθιάς μάθησης που έχει σχεδιαστεί για να λειτουργεί με διαδοχικά δεδομένα, όπως δεδομένα χρονοσειρών. Τα RNN είναι κατάλληλα για εργασίες που περιλαμβάνουν ακολουθίες δεδομένων, όπως η αναγνώριση ομιλίας, η επεξεργασία φυσικής γλώσσας και η πρόβλεψη χρονοσειρών. Σε αντίθεση με τα παραδοσιακά νευρωνικά δίκτυα, τα οποία έχουν σταθερό αριθμό εισροών και εκροών, τα RNN έχουν κυκλική σύνδεση μεταξύ των νευρώνων, η οποία τους επιτρέπει να διατηρούν μια κρυφή κατάσταση που μπορεί να ενημερώνεται σε κάθε χρονικό βήμα. Αυτή η κρυφή κατάσταση επιτρέπει στο δίκτυο να θυμάται πληροφορίες από προηγούμενα χρονικά βήματα, πράγμα που είναι ζωτικής σημασίας για εργασίες που περιλαμβάνουν ακολουθίες δεδομένων.

Η δομή ενός RNN μπορεί να αναπαρασταθεί ως ένας βρόχος που συνδέει την εκροή ενός νευρώνα με την εισροή του. Αυτός ο βρόχος επιτρέπει στο δίκτυο να επεξεργάζεται πληροφορίες για μια εκτεταμένη χρονική περίοδο και επιτρέπει στο δίκτυο να κάνει προβλέψεις για μελλοντικά γεγονότα με βάση ιστορικά δεδομένα. Τα RNN μπορούν να εκπαιδευτούν χρησιμοποιώντας διάφορες τεχνικές, όπως η Οπισθοδιάδοση Μέσω του Χρόνου (Backpropagation through Time – BPTT) και τα Δίκτυα Μακράς Βραχύχρονης Μνήμης (Long Short-term Memory – LSTM) (Medsker & Jain, 2001).



Εικόνα 11 Η δομή ενός απλού RNN (Biswal, 2022)

Όσον αφορά τη ναυτιλία, τα RNN μπορούν να χρησιμοποιηθούν στη ναυτιλιακή βιομηχανία για την ανάλυση δεδομένων από τα συστήματα πλοήγησης των πλοίων, όπως το GPS, για την πρόβλεψη των κινήσεων των πλοίων και τον εντοπισμό πιθανών συγκρούσεων. Μπορούν επίσης να χρησιμοποιηθούν για την ανάλυση δεδομένων αισθητήρων, όπως τα ραντάρ και το AIS, για τον εντοπισμό και την ταξινόμηση πλοίων και άλλων αντικειμένων στο νερό και την πρόβλεψη της πορείας τους (Gao, Shi & Li, 2018). Τα RNN μπορούν επίσης να χρησιμοποιηθούν για την ανάλυση δεδομένων καιρού (Han, Ang, Malkawi & Samuelson, 2021), για την πρόβλεψη των συνθηκών που θα συναντήσουν τα πλοία στο ταξίδι τους και τον ανάλογο σχεδιασμό της διαδρομής.

3.3.2 Δίκτυα Μακράς Βραχύχρονης Μνήμης (Long Short-term Memory – LSTM)

Τα LSTM είναι ένας τύπος επαναλαμβανόμενων νευρωνικών δικτύων RNN που έχουν σχεδιαστεί για να μαθαίνουν και να θυμούνται μακροπρόθεσμες συσχετίσεις σε διαδοχικά δεδομένα. Τα LSTM είναι ιδιαίτερα χρήσιμα για εργασίες που περιλαμβάνουν ακολουθίες δεδομένων με πολύπλοκες χρονικές εξαρτήσεις, όπως η επεξεργασία φυσικής γλώσσας, η αναγνώριση ομιλίας και η πρόβλεψη χρονοσειρών. Η βασική διαφορά μεταξύ των LSTM και των παραδοσιακών RNN είναι η χρήση ενός εσωτερικού κελιού μνήμης, το οποίο επιτρέπει στα LSTM να θυμούνται πληροφορίες για μεγαλύτερα χρονικά διαστήματα. Το κύτταρο μνήμης ελέγχεται από τρεις πύλες: την πύλη εισόδου, την πύλη λήθης και την πύλη εξόδου. Αυτές οι πύλες επιτρέπουν στο δίκτυο να ενημερώνετε επιλεκτικά, να διατηρεί ή να εξάγει πληροφορίες από το κύτταρο μνήμης, με βάση την είσοδο και την προηγούμενη κατάσταση του δικτύου. Η πύλη εισόδου ελέγχει τη ροή νέων πληροφοριών στο κύτταρο μνήμης, η πύλη λήθης ελέγχει τη ροή πληροφοριών από το κύτταρο μνήμης και η πύλη εξόδου ελέγχει τη ροή πληροφοριών από το κύτταρο μνήμης στην έξοδο. Αυτές οι πύλες ελέγχονται από την εισροή και την προηγούμενη κατάσταση του δικτύου και μπορούν να ρυθμιστούν κατά τη διάρκεια της διαδικασίας εκπαίδευσης για τη βελτιστοποίηση της απόδοσης του δικτύου (Hochreiter & Schmidhuber, 1997).

3.3.3 Αποτελέσματα

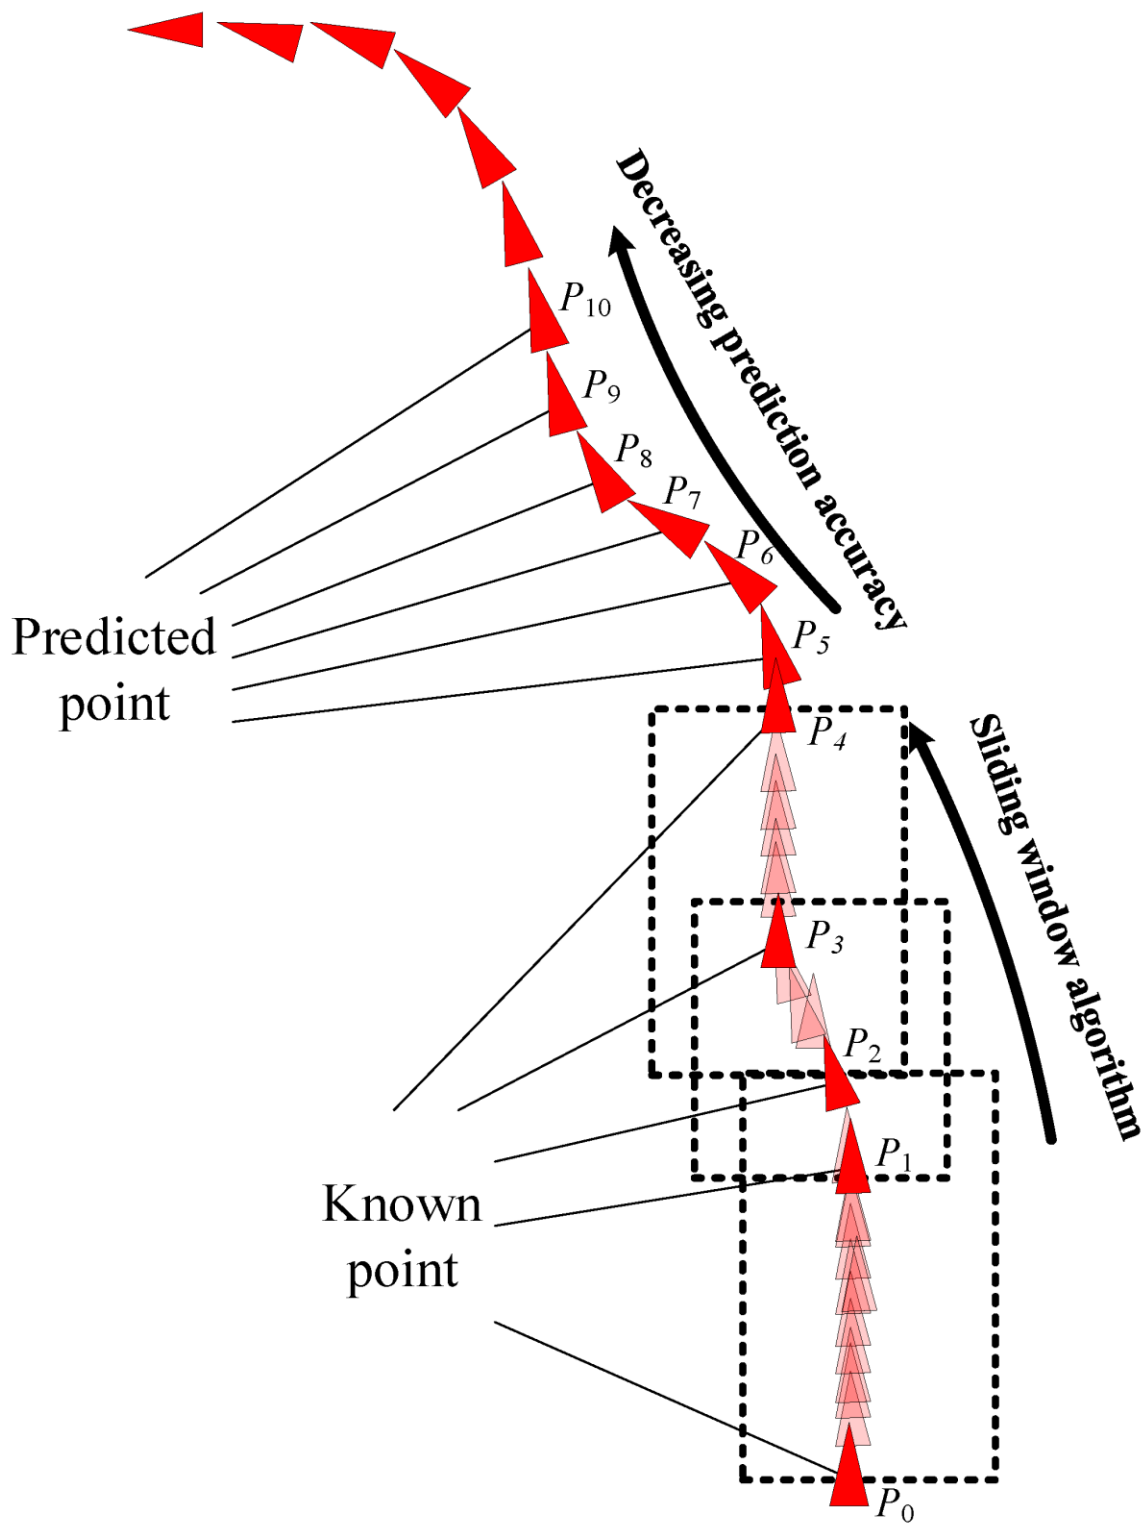
Τα RNN και τα LSTM μπορούν να χρησιμοποιηθούν από κοινού για την ανάλυση διαδοχικών δεδομένων και την πραγματοποίηση προβλέψεων. Αυτός ο συνδυασμός είναι χρήσιμος όταν πρόκειται για εργασίες που περιλαμβάνουν τόσο βραχυπρόθεσμες όσο και μακροπρόθεσμες εξαρτήσεις στα δεδομένα. Ο συνδυασμός αυτός ονομάζεται BI-LSTM-RNN (Bi-directional Long Short-term Memory Recurrent Neural Network) και μπορεί να εφαρμοστεί για την πρόβλεψη της πορείας παρέχοντας ένα υψηλό επίπεδο ασφάλειας στην ναυσιπλοΐα και βοηθάει στο σχεδιασμό της διαδρομής και στην παρακολούθηση των κινδύνων. Αυτή η καινοτόμος προσέγγιση έχει τη δυνατότητα να φέρει επανάσταση στη ναυτιλιακή βιομηχανία, παρέχοντας μια θεωρητική βάση για το σχεδιασμό ευφών συστημάτων αποφυγής συγκρούσεων για μη επανδρωμένα πλοία καθώς και για την πρόβλεψη της συμπεριφοράς των άλλων πλοίων και τον μετριασμό των κινδύνων για τις Υπηρεσίες Θαλάσσιας Κυκλοφορίας (VTS).

Ένα από τα βασικά πλεονεκτήματα του BI-LSTM-RNN είναι η ικανότητά του να αναλύει δεδομένα τόσο προς τα εμπρός όσο και προς τα πίσω, γεγονός που επιτρέπει στο δίκτυο να κατανοεί καλύτερα το πλαίσιο των δεδομένων εισόδου, το οποίο είναι ζωτικής σημασίας για εργασίες όπως η πρόβλεψη πορείας. Το δίκτυο μπορεί επίσης να αναλύσει μεγάλες ποσότητες δεδομένων και να κάνει προβλέψεις για μελλοντικά γεγονότα. Το BI-LSTM-RNN είναι κατάλληλο για τον εντοπισμό και την ανίχνευση, την ταξινόμηση πλοίων και την αναγνώριση πλοίων. Η καθορισμένη κατάσταση του πλοίου μπορεί να χρησιμοποιηθεί για την εκτίμηση της μελλοντικής πορείας, η οποία τελικά βοηθά στην πρόβλεψη της

μελλοντικής συμπεριφοράς και των προθέσεων ενός πλοίου και στη δημιουργία μιας ακριβούς στρατηγικής αποφυγής συγκρούσεων (Gao, Shi & Li, 2018).



Εικόνα 12 Απεικόνιση της πρόβλεψης της συμπεριφοράς του πλοίου (Gao, Shi & Li, 2018).



Εικόνα 13 Διάγραμμα πρόβλεψης πορείας BI-LSTM-RNN (Gao, Shi & Li, 2018).

3.4 Αυτόνομα Πλοία

Η χρήση αυτόνομων πλοίων, γνωστών και ως μη επανδρωμένων πλοίων, αποτελεί μια ταχέως αναπτυσσόμενη τάση στη ναυτιλιακή βιομηχανία, με γνώμονα την επιθυμία για αύξηση της αποτελεσματικότητας, της ασφάλειας και των εσόδων. Τα αυτόνομα πλοία είναι εξοπλισμένα με προηγμένες τεχνολογίες τεχνητής νοημοσύνης όπως η αναγνώριση αντικειμένων, ο σχεδιασμός διαδρομών και οι αλγόριθμοι αποφυγής συγκρούσεων. Αυτές οι τεχνολογίες επιτρέπουν στα πλοία να πλοηγούνται με ασφάλεια και αποτελεσματικότητα χωρίς την ανάγκη ανθρώπινης παρέμβασης. Η ενσωμάτωση αυτών των αλγορίθμων με άλλες τεχνολογίες, όπως το RADAR, το AIS και με αισθητήρες συλλογής εικόνων και βίντεο επιτρέπει στα αυτόνομα πλοία να ανιχνεύουν, να ταξινομούν και να προβλέπουν τις πορείες άλλων πλοίων και τα εμπόδια στην θάλασσα.

Η χρήση αυτόνομων πλοίων δεν είναι μόνο επωφελής για τις ναυτιλιακές εταιρείες, αλλά έχει επίσης τη δυνατότητα να ενισχύσει σημαντικά την ασφάλεια στη ναυτιλιακή βιομηχανία. Η απώλεια ανθρώπινων ζωών σε ναυτικά ατυχήματα είναι ένα ανεκτίμητο κόστος που μπορεί να εξαλειφθεί πλήρως με τη χρήση αυτόνομων πλοίων. Επιπλέον, η χρήση αυτόνομων πλοίων έχει θετικό αντίκτυπο στο περιβάλλον, μειώνοντας τις εκπομπές και την κατανάλωση καυσίμων. Καθώς η ναυτιλιακή βιομηχανία συνεχίζει να εξελίσσεται και η ζήτηση για βιώσιμες και αποδοτικές μεταφορές αυξάνεται, η χρήση αυτόνομων πλοίων αποκτά όλο και μεγαλύτερη σημασία.

Συνολικά, η χρήση αυτόνομων πλοίων είναι μια πολλά υποσχόμενη τάση στη ναυτιλιακή βιομηχανία που έχει τη δυνατότητα να βελτιώσει την αποτελεσματικότητα, την ασφάλεια και τα έσοδα, ενώ παράλληλα έχει θετικό αντίκτυπο και στο περιβάλλον. Καθώς η τεχνολογία συνεχίζει να εξελίσσεται, αναμένεται ότι ένας αυξανόμενος αριθμός εταιρειών θα επενδύσει σε αυτή την τεχνολογία στο μέλλον.

3.4.1 Yara Birkeland

Η Yara, μία από τις κορυφαίες εταιρείες παγκοσμίως στον τομέα του λιπάσματος, και η εταιρεία τεχνολογίας KONGSBERG ένωσαν τις δυνάμεις τους για την κατασκευή του πρώτου αυτόνομου και μηδενικών εκπομπών ρύπων πλοίου μεταφοράς εμπορευματοκιβωτίων στον κόσμο, το Yara Birkeland. Αυτό το επαναστατικό πλοίο έχει σχεδιαστεί για να αντικαταστήσει 40.000 διαδρομές φορτηγών με ντίζελ κάθε χρόνο. Αυτό θα μειώσει τις εκπομπές NOx (οξειδίων του αζώτου) και CO₂, θα βελτιώσει την οδική ασφάλεια και θα μειώσει την οδική σκόνη και τον κυκλοφοριακό θόρυβο. Το ορυκτό λίπασμα θα μεταφέρεται από την τοποθεσία παραγωγής της Yara στο Porsgrunn της Νορβηγίας στο περιφερειακό λιμάνι εξαγωγής στο Brevik χρησιμοποιώντας αυτή την υπερσύγχρονη τεχνολογία. Η KONGSBERG, παγκόσμιος ηγέτης στη θαλάσσια τεχνολογία, είναι υπεύθυνη για την ανάπτυξη και την παράδοση όλων των βασικών τεχνολογιών για τη Yara Birkeland. Αυτό περιλαμβάνει τους αισθητήρες και την ενσωμάτωση που απαιτούνται για την απομακρυσμένη και αυτόνομη λειτουργία, καθώς και τα συστήματα ηλεκτρικής προώθησης, μπαταρίας και ελέγχου. Αυτή η προηγμένη

τεχνολογία θα επιτρέψει στο σκάφος να κινείται στις θάλασσες με ασφάλεια και αποτελεσματικότητα χωρίς την ανάγκη ανθρώπινης παρέμβασης.

Η Yara Birkeland τέθηκε σε εμπορική λειτουργία στο Porsgrunn την άνοιξη του 2022. Κατά τη διάρκεια των δύο πρώτων ετών λειτουργίας, το πλοίο θα περάσει από μια σταδιακή μετάβαση προς την πλήρη αυτόνομη πλεύση, καθώς η τεχνολογία δοκιμάζεται και τελειοποιείται για να διασφαλιστεί η μέγιστη δυνατή ασφάλεια και αποτελεσματικότητα (Skredderberget, n.d.). Αυτή η συνεργασία μεταξύ της Yara και της KONGSBERG είναι ένα σημαντικό βήμα προς μια πιο βιώσιμη και αποτελεσματική ναυτιλιακή βιομηχανία. Η χρήση αυτόνομων και μηδενικών εκπομπών πλοίων έχει τη δυνατότητα να μειώσει σημαντικά τις περιβαλλοντικές επιπτώσεις της ναυτιλιακής βιομηχανίας και να βελτιώσει την ασφάλεια των θαλάσσιων μεταφορών. Επιπλέον, το έργο αυτό αποτελεί επίσης ένα σαφές παράδειγμα του τρόπου με τον οποίο η χρήση της τεχνολογίας και της καινοτομίας μπορεί να βοηθήσει τις εταιρείες να επιτύχουν τους στόχους βιωσιμότητας, μειώνοντας τις εκπομπές, βελτιώνοντας την ασφάλεια και αυξάνοντας την αποδοτικότητα. Η εμπορική λειτουργία του Yara Birkeland αναμένεται να θέσει ένα νέο πρότυπο στη ναυτιλιακή βιομηχανία και αναμένεται ότι περισσότερες εταιρείες θα ακολουθήσουν αυτό το παράδειγμα στο μέλλον.



Εικόνα 14 Απεικονίζετε το Yara Birkeland (Knut Brevik Andersen - Wilhelmsen Ship Service, 2020)

4. Συμπέρασμα

Ο ναυτιλιακός τομέας έχει τη δυνατότητα να επωφεληθεί σημαντικά από την ενσωμάτωση προηγμένων μεθόδων τεχνητής νοημοσύνης. Αν και αυτές οι τεχνολογίες βρίσκονται ακόμη σε πειραματικό στάδιο, τα αποτελέσματα από τις πειραματικές δοκιμές είναι θετικά και ελπιδοφόρα. Η χρήση της τεχνητής νοημοσύνης στην ναυτιλία αναμένεται να διαδραματίσει καθοριστικό ρόλο στην ανάπτυξη του κλάδου κατά την επόμενη δεκαετία.

Ένα από τα βασικά πλεονεκτήματα της τεχνητής νοημοσύνης στον τομέα της ναυτιλίας είναι η ικανότητά της να βελτιώνει την αποδοτικότητα και να μειώνει το κόστος σχεδόν σε όλες τις λειτουργίες του πλοίου. Όπως χαρακτηριστικά παρουσιάστηκε, η χρήση αλγορίθμων βελτιστοποίησης δρομολογίων, συμβάλει στην ελαχιστοποίηση της κατανάλωσης καυσίμων και του χρόνου ταξιδιού, μειώνοντας συνολικά το λειτουργικό κόστος και αυξάνοντας την αποδοτικότητα. Ομοίως, η χρήση αλγορίθμων αποφυγής συγκρούσεων και ανίχνευσης αντικειμένων αυξάνει άμεσα την ασφάλεια και συμβάλει στη μείωση του κινδύνου ατυχημάτων.

Εάν και η πορεία προς την πλήρη αυτοματοποίηση μπορεί να μην είναι ακόμη εφικτή σε εμπορικό στάδιο, η ενσωμάτωση της τεχνητής νοημοσύνης ως υποστηρικτικό σύστημα είναι απολύτως ρεαλιστική. Τα αποτελέσματα είναι ξεκάθαρα, η ναυτιλιακή βιομηχανία βρίσκεται στα πρόθυρα μιας τεχνολογικής επανάστασης και η ενσωμάτωση της τεχνητής νοημοσύνης θα αποτελέσει ένα κρίσιμο βήμα προς τη σωστή κατεύθυνση.

Βιβλιογραφία

1. Beşikçi B. E, Arslan O., Turan O. & Ölçer A. I. (2016). *An artificial neural network based decision support system for energy efficient ship operations*. Computers & Operations Research Volume 66, February 2016, Pages 393-401.
2. Biswal A. (2022). *Recurrent Neural Network (RNN) Tutorial: Types, Examples, LSTM and More*. Simplilearn.
3. Bughin J., Seong J., Manyika J., Chui M. & Joshi R. (2018). *Notes from the AI frontier: Modeling the impact of AI on the world economy*. McKinsey Global Institute.
4. Bui-Duy L. & Vu-Thi-Minh N. (2021). *Utilization of a deep learning-based fuel consumption model in choosing a liner shipping route for container ships in Asia*. The Asian Journal of Shipping and Logistics Volume 37, Issue 1, March 2021, Pages 1-11.
5. Cortes C. & Vapnik V. (1995). *Support-vector networks*. Machine Learning volume 20, pages 273–297 (1995).
6. Dartmouth College (1956). *The Dartmouth Summer Research Project on Artificial Intelligence*.
7. Dertat A. (2017). *Applied Deep Learning - Part 1: Artificial Neural Networks*. Towards Data Science.
8. Friedman H. J. (1999). *Greedy Function Approximation: A Gradient Boosting Machine*. IMS 1999 Reitz Lecture.
9. Gao M., Shi G. & Li S. (2018). *Online Prediction of Ship Behavior with Automatic Identification System Sensor Data Using Bidirectional Long Short-Term Memory Recurrent Neural Network*. Sensors 2018, 18(12), 4211.
10. Ghosh A., Chakraborty D. & Law A. (2018). *Artificial intelligence in Internet of things*.
11. Girshick R. (2015). *Fast R-CNN*.
12. Goodfellow I., Bengio Y. & Courville A. (2016). *Deep Learning*. The MIT Press.

13. Gutin G. & Punnen A. (2002). *THE TRAVELING SALESMAN PROBLEM AND ITS VARIATIONS*. Kluwer Academic Publishers.
14. Han J., Ang Yu., Malkawi A. & Samuelson H. (2021). *Using recurrent neural networks for localized weather prediction with combined use of public airport data and on-site measurements*. Building and Environment Volume 192, April 2021, 107601.
15. Herrera F., Lozano M. & Verdegay J.L. (1998). *Tackling Real-Coded Genetic Algorithms: Operators and Tools for Behavioural Analysis*. Artificial Intelligence Review 12: 265–319, 1998.
16. Ho K. T. (1995). *Random decision forests*. Proceedings of 3rd International Conference on Document Analysis and Recognition.
17. Hochreiter S. & Schmidhuber J. (1997). *Long Short-term Memory*. Neural Computation 9(8):1735-80.
18. Huang H., Sun D., Wang R., Zhu C. & Liu B. (2020). *Ship Target Detection Based on Improved YOLO Network*. Mathematical Problems in Engineering, vol. 2020, Article ID 6402149, 10 pages, 2020.
19. IBM (2022). *IBM Global AI Adoption Index 2022*.
20. IBM (n.d.). *What is computer vision?*
21. Lambrou M., Watanabe D., Iida J. (2019). *Shipping digitalization management: conceptualization, typology, and antecedents*. Journal of Shipping and Trade volume 4.
22. Lecrosnier L., Khemmar R., Ragot N., Decoux B., Rossi R., Kefi N. & Ertaud J. (2021). *Deep Learning-Based Object Detection, Localisation and Tracking for Smart Wheelchair Healthcare Mobility*. Int. J. Environ. Res. Public Health 2021, 18, 91.
23. Li H., Deng L., Yang C., Liu J. & Gu Z. (2021). *Enhanced YOLO v3 Tiny Network for Real-Time Ship Detection From Visual Image*. Digital Object Identifier 10.1109/ACCESS.2021.3053956.
24. Li S., Xu D. L. & Zhao S. (2015). *The internet of things: a survey*. Information Systems Frontiers volume 17, pages 243–259 (2015).

25. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C. & Berg A. (2016). *SSD: Single Shot MultiBox Detector*.
26. Mamat M. & Bon A. (2019). *Solving traveling salesman problems using branch and bound methods*.
27. Manning C. (2020). *Artificial Intelligence Definitions*. Stanford University.
28. McCarthy J. (2007). *What is artificial intelligence?*. Computer Science Department Stanford University.
29. McCorduck P. (2004). *Machines Who Think. A Personal Inquiry into the History and Prospects of Artificial Intelligence*. A K Peters/CRC Press.
30. Medsker L. & Jain L. (2001). *Recurrent Neural Networks Design and Applications*. CRC Press LLC.
31. Newell A. (1963). *A GUIDE TO THE GENERAL PROBLEM-SOLVER PROGRAM GPS-2-2*. The RAND Corporation.
32. Redmon J., Divvala S., Girshick R. & Farhadi A. (2016). *You Only Look Once: Unified, Real-Time Object Detection*.
33. Ren S., He K., Girshick R. & Sun J. (2015). *Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*.
34. Rose K., Eldridge S. & Chapin L. (2015). *THE INTERNET OF THINGS: AN OVERVIEW Understanding the Issues and Challenges of a More Connected World*. The Internet Society.
35. Rosenblatt F. (1958). *The Perceptron: A Probabilistic Model For Information Storage and Organization in the Brain*. Psychological Review, 65(6), 386–408.
36. Russel J. S., Norvig P. (2009). *Artificial Intelligence A Modern Approach Third Edition*. Pearson Education, Inc.
37. Sagirolu S. & Sinanc D. (2013). *Big Data: A Review*. Gazi University Department of Computer Engineering, Faculty of Engineering.
38. Samuel L. A. (1959). *Some Studies in Machine Learning Using the Game of Checkers*. IBM Journal.
39. Shea O. & Nash R. (2015). *An Introduction to Convolutional Neural Networks*.

40. Skredderberget A. (n.d.). *The first ever zero emission, autonomous ship*. Yara.
41. Stratiotis E. (2018). *Fuel Costs in Ocean Shipping*. More Than Shipping.
42. Turing M. A. (1950). *Computing Machinery and Intelligence*. *Mind*, New Series, Vol. 59, No. 236 (Oct. 1950), pp. 433-460.
43. Veith M. E., Fischer L., Tröschel M. & Nieße A. (2019). *Analyzing Cyber-Physical Systems from the Perspective of Artificial Intelligence*. AIRC '19: Proceedings of the 2019 International Conference on Artificial Intelligence, Robotics and Control.
44. Wang H., Li X., Li P., Veremey E. & Sotnikova M. (2018). *Application of Real-Coded Genetic Algorithm in Ship Weather Routing*. *The Journal of Navigation*, Volume 71, Issue 4, July 2018, pp. 989 – 1010.
45. Yara (n.d.). *MV Yara Birkeland*.
46. Zhang G., Patuwo E. B. & Hu Y. M. (1998). *Forecasting with artificial neural networks: The state of the art*. *International Journal of Forecasting* Volume 14, Issue 1, 1 March 1998, Pages 35-62.
47. Zhao Z., Zheng P., Xu S. & Wu X. (2019). *Object Detection with Deep Learning: A Review*.