



**ΠΑΝΕΠΙΣΤΗΜΙΟ
ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ**

Τμήμα Μηχανικών Βιομηχανικής
Σχεδίασης και Παραγωγής

&

**ΠΑΝΕΠΙΣΤΗΜΙΟ
ΑΙΓΑΙΟΥ**

Τμήμα Ναυτιλίας και
Επιχειρηματικών Υπηρεσιών



**ΔΙΔΡΥΜΑΤΙΚΟ
ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ
«ΝΕΕΣ ΤΕΧΝΟΛΟΓΙΕΣ ΣΤΗ ΝΑΥΤΙΛΙΑ ΚΑΙ ΤΙΣ ΜΕΤΑΦΟΡΕΣ»**

ΤΙΤΛΟΣ

Εφαρμογή αλγορίθμων μηχανικής μάθησης και νευρωνικών δικτύων για την ταξινόμηση υπερηχητικών σημάτων sonar

ΤΙΤΛΟΣ ΑΓΓΛΙΚΑ

Implementation of machine learning algorithms and neural networks for the classification of sonar signals

Όνοματεπώνυμο Σπουδαστή:

Μακρυγιώργος Χαρίλαος

Όνοματεπώνυμο Υπεύθυνου Καθηγητή:

Λέκτορας Νικολάου Γρηγόριος

ΔΙΑΤΡΙΒΗ

Φεβρουάριος 2021

Μέλη Εξεταστικής Επιτροπής

Νικολάου Γρηγόριος

Παπουτσιδάκης Μιχαήλ

Δρόσος Χρήστος

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΜΕΤΑΠΤΥΧΙΑΚΗΣ ΕΡΓΑΣΙΑΣ

Ο κάτωθι υπογεγραμμένος Μακρυγιώργος Χαρίλαος του Μενελάου, με αριθμό μητρώου 65 φοιτητής του Διϊδρυματικού Προγράμματος Μεταπτυχιακών Σπουδών «Νέες Τεχνολογίες στη Ναυτιλία και τις Μεταφορές» του Τμήματος Μηχανικών Βιομηχανικής Σχεδίασης και Παραγωγής της Σχολής Μηχανικών Πανεπιστημίου Δυτικής Αττικής, δηλώνω υπεύθυνα ότι:

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

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

Ο Δηλών

Μακρυγιώργος Χαρίλαος

ΤΙΤΛΟΣ

**Εφαρμογή αλγορίθμων μηχανικής μάθησης για την ταξινόμηση
υπερηχητικών σημάτων**

ΟΝΟΜΑ ΦΟΙΤΗΤΗ

Μακρυγιώργος Χαρίλαος

**Μεταπτυχιακή Διατριβή που υποβάλλεται στο καθηγητικό σώμα για την μερική
εκπλήρωση των υποχρεώσεων απόκτησης του μεταπτυχιακού τίτλου του
Διδρυματικού Προγράμματος Μεταπτυχιακών Σπουδών «Νέες Τεχνολογίες
στη Ναυτιλία και τις Μεταφορές» του Τμήματος Ναυτιλίας και
Επιχειρηματικών Υπηρεσιών του Πανεπιστημίου Αιγαίου και του Τμήματος
Μηχανικών Βιομηχανικής Σχεδίασης και Παραγωγής του Πανεπιστημίου
Δυτικής Αττικής.**

Περίληψη

Στην παρούσα διπλωματική εργασία επιχειρήθηκε η εξέταση βελτίωσης της ακρίβειας πρόβλεψης όσον αφορά την επεξεργασία, αναγνώριση και ταξινόμηση στόχων που προέρχονται από υπερηχητικά σήματα Sonar. Η εργασία εντάσσεται στην ευρύτερη περιοχή της Τεχνητής Νοημοσύνης και επί το πλείστον της Μηχανικής Μάθησης ως εργαλείο βελτίωσης εφαρμογών που σχετίζονται με την επεξεργασία ηχητικών σημάτων (signal processing). Αξίζει να σημειωθεί ότι η παρούσα έρευνα βασίστηκε πάνω στα δεδομένα προηγούμενης έρευνας των Gorman & Sejnowski, (1988), οι οποίοι για πρώτη φορά μελέτησαν τη συγκεκριμένη σειρά δεδομένων και η οποία αφορούσε την ταξινόμηση επιστροφών Sonar από δύο διαφορετικά υποθαλάσσια αντικείμενα, ένα μεταλλικό με την ετικέτα “Mine” και ένα βράχο με την ετικέτα “Rock” χρησιμοποιώντας νευρωνικά δίκτυα.

Το θεωρητικό πλαίσιο που εφαρμόστηκε εστιάζει κυρίως στη μηχανική μάθηση και στην αξιοποίηση μιας σειράς αλγόριθμων κατάλληλων σε προβλήματα ταξινόμησης εποπτευόμενης μάθησης (classification problems), που έχουν ως στόχο την ανάπτυξη μοντέλων, ικανών να εντοπίζουν θαλάσσιους στόχους λαμβάνοντας υπόψη βασικά χαρακτηριστικά τους.

Από την ανάλυση του συνόλου του δείγματος που ακολουθήθηκε και αφορά στην ταξινόμηση 208 ηχητικών σημάτων sonar καθώς και από την επιλογή του καταλληλότερου μοντέλου που απέδωσε καλύτερα στα προς μελέτη δεδομένα και παρείχε το μεγαλύτερο ποσοστό πρόβλεψης, προέκυψαν ορισμένα ενδιαφέροντα αποτελέσματα τα οποία ανέδειξαν σε ικανοποιητικό βαθμό, την ικανότητα των μοντέλων μηχανικής μάθησης καθώς και των νευρωνικών δικτύων στην επίλυση ζητημάτων ταξινόμησης. Συγκεκριμένα την μεγαλύτερη απόδοση όσον αφορά τους αλγόριθμους μηχανικής μάθησης κατείχε ο Support Vector Classifier με ποσοστό 91%, εκπαιδευόμενος σε 169 δείγματα και ποσοστό 88% ταξινομώντας ορθά 37 από τα 42 άγνωστα δείγματα του σετ δοκιμής. Επιπλέον, η αξιοποίηση της αρχιτεκτονικής νευρωνικών δικτύων συνέβαλε επιτυχώς στην ταξινόμηση των υπερηχητικών επιστροφών του ηχοβολιστικού, συγκεντρώνοντας ποσοστό 98.4% σε 169 δείγματα εκπαίδευσης (80% των συνολικών δεδομένων), αξιολογούμενα στο σετ επικύρωσης (validation test) με 21 δείγματα και στο άγνωστο σετ δοκιμής (test data) 21 δειγμάτων συγκεντρώνοντας ποσοστό 95.2 %.

ΘΕΜΑΤΙΚΗ ΠΕΡΙΟΧΗ: Μηχανική Μάθηση

ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ: Τεχνητή Νοημοσύνη, Μηχανική Μάθηση, εποπτευόμενη μάθηση, ταξινόμηση, επεξεργασία σήματος, σόναρ

Πίνακας περιεχομένων

1. Εισαγωγή	- 7 -
2. Θεωρητικό πλαίσιο	- 9 -
2.1 Sonar	- 9 -
2.2 Τεχνητή Νοημοσύνη (Artificial Intelligence).....	- 11 -
2.3 Μηχανική μάθηση (Machine Learning).....	- 12 -
2.3.1 Εξέλιξη της Μηχανικής Μάθησης.....	- 16 -
2.3.2 Προβλήματα επίλυσης & τύποι Μηχανικής Μάθησης.....	- 18 -
2.3.3 Εφαρμογές μηχανικής μάθησης.....	- 24 -
2.4 Αλγόριθμοι μηχανικής μάθησης	- 29 -
2.5 Ανασκόπηση της βιβλιογραφίας	- 37 -
2.5.1 Ανασκόπηση βιβλιογραφιών με βάση τα δεδομένα της παρούσας διπλωματικής εργασίας.....	- 41 -
3. Μεθοδολογία.....	- 42 -
3.1 Το αντικείμενο της έρευνας	- 42 -
3.2 Ερευνητικά ερωτήματα	- 45 -
3.3 Σχεδιασμός της έρευνας	- 47 -
3.3.1 Ερευνητικά δεδομένα	- 47 -
3.3.2 Συλλογή και ανάλυση δεδομένων.....	- 51 -
4. Αποτελέσματα-Ευρήματα.....	- 82 -
4.1 Ευρήματα με βάση τα ερευνητικά ερωτήματα	- 82 -
4.1.1 Ερευνητικό ερώτημα Νο1.....	- 82 -
4.1.2 Ερευνητικό ερώτημα Νο2.....	- 90 -
4.1.3 Ερευνητικό ερώτημα Νο3.....	- 92 -
4.1.4 Ερευνητικό ερώτημα Νο4.....	- 96 -
5. Κριτική ανάλυση αποτελεσμάτων – Σύνοψη	- 99 -
6. Συμπεράσματα	- 103 -
7. Περιορισμοί και προτάσεις	- 105 -
8. Βιβλιογραφία	- 106 -
9. Παραρτήματα.....	- 114 -
9.1 Παράρτημα 1: [PAPER ENGLISH]	- 114 -

1. Εισαγωγή

Η τεχνητή νοημοσύνη (AI) είναι μία από τις βασικές τεχνολογικές καινοτομίες του παρόντος αλλά και του μέλλοντος που μπορεί να διαδραματίσει σημαντικό ρόλο στην πραγματοποίηση σημαντικών αλλαγών στον κόσμο καθώς και στον μετασχηματισμό και την ανάπτυξη της σύγχρονης κοινωνίας. Η Μηχανική Μάθηση, ως κλάδος της τεχνητής νοημοσύνης αποτελεί ενδεχομένως τον πιο εξελισσόμενο τομέα καθώς τα τελευταία χρόνια, ειδικά μετά την έλευση της Βαθιάς Μάθησης, έχει προσφέρει πληθώρα μεθόδων και τεχνικών με πολύ καλά έως εντυπωσιακά αποτελέσματα σε όλες σχεδόν τις εφαρμογές που απαιτούν ευφυΐα. (Long & Dhillon, 2020)(σελ. 1067-1072) Η παρούσα διπλωματική εργασία σχετίστηκε με τη μελέτη τέτοιων τεχνολογιών, εστιάζοντας το ενδιαφέρον της κυρίως στην ανάλυση, επεξεργασία και ταξινόμηση στόχων που προέρχονται από υπερηχητικά σήματα Sonar. Η εργασία εντάσσεται στην ευρύτερη περιοχή της Τεχνητής Νοημοσύνης και επί το πλείστον της Μηχανικής Μάθησης ως εργαλείο βελτίωσης εφαρμογών που σχετίζονται με την επεξεργασία σημάτων (signal processing).

Στο 2^ο κεφάλαιο γίνεται αναφορά στο θεωρητικό πλαίσιο που επιλέχθηκε για τη παρούσα εργασία. Αναφέρονται εκτενώς έννοιες όπως τι είναι Sonar (2.1), τεχνητή νοημοσύνη (2.2) και μηχανική εκμάθηση (2.3). Υπογραμμίζονται τα διάφορα στάδια εξέλιξης την μηχανικής μάθησης (2.3.1) κατά τη διάρκεια των ετών σημειώνοντας τους κυριότερους σταθμούς που σημειώθηκε σημαντική πρόοδος. Επιπλέον, αναφέρονται οι εγγενείς ικανότητες της μηχανικής μάθησης ώστε να ανταποκρίνεται επαρκώς στις προκλήσεις που αντιμετωπίζει η επιστήμη δεδομένων καθώς παρουσιάζονται οι κύριες κατηγορίες προβλημάτων της επιστήμης δεδομένων (2.3.2) και οι εφαρμογές της μηχανικής μάθησης γενικότερα σε διάφορους τομείς (2.3.3) αλλά και ειδικότερα σε στρατιωτικό επίπεδο (2.3.3.1) . Παρακάτω αναλύονται οι αλγόριθμοι μηχανικής μάθησης που χρησιμοποιήθηκαν στην παρούσα εργασία (2.4). Πρόκειται για αλγόριθμους οι οποίοι συγκαταλέγονται στην

κατηγορία της εποπτευόμενης μάθησης (supervised learning) και η φύση του ζητήματος στο οποίο εφαρμόζονται αφορά στο κομμάτι της ταξινόμησης (classification). Το κεφάλαιο ολοκληρώνεται με την ανασκόπηση της βιβλιογραφίας (2.5) επισημαίνοντας ότι η εκτεταμένη χρήση εφαρμογών, σε βιομηχανικό αλλά και σε στρατιωτικό επίπεδο, βασιζόμενων σε ηχητικά σήματα (Sonar) έχει απασχολήσει πληθώρα ερευνητών, οι οποίοι κινητοποιούνται ολοένα και περισσότερο για τη βελτίωση τους. Η βελτίωση αποσκοπεί κυρίως στην μεγαλύτερη αποδοτικότητα, στην αυτοματοποίηση καθώς και στη μείωση χρόνου επεξεργασίας των εφαρμογών. Επιπλέον, υποκεφάλαιο της ανασκόπησης αποτελεί η βιβλιογραφία πληθώρα ερευνών που βασίζονται στη μελέτη και ταξινόμηση των δεδομένων Sonar dataset (Mines vs Rocks) ,αναδεικνύοντας τη σημαντικότητα του ενδιαφέροντος μελέτης του συγκεκριμένου είδους δεδομένων.

Στο 3^ο κεφάλαιο περιγράφεται η μεθοδολογία της έρευνας που ακολουθήθηκε. Συγκεκριμένα, αποτυπώνεται το αντικείμενο της έρευνας (3.1) . Η εργασία εντάσσεται στην ευρύτερη περιοχή της Τεχνητής Νοημοσύνης και επί το πλείστον της Μηχανικής Μάθησης ως εργαλείο βελτίωσης εφαρμογών που σχετίζονται με την ταξινόμηση ηχητικών σημάτων. Η παρούσα έρευνα βασίστηκε πάνω στα δεδομένα από προηγούμενη έρευνα των Gorman & Sejnowski, (1988), οι οποίοι για πρώτη φορά μελέτησαν τη συγκεκριμένη σειρά δεδομένων, η οποία αφορούσε την ταξινόμηση επιστροφών Sonar από δύο διαφορετικά υποθαλάσσια αντικείμενα, ένα μεταλλικό με την ετικέτα “Mine” και ένα βράχο με την ετικέτα “Rock” χρησιμοποιώντας νευρωνικά δίκτυα. Έπειτα ακολουθεί η διατύπωση των ερευνητικών ερωτημάτων (3.2). Τα ερευνητικά ερωτήματα που τέθηκαν εστιάζουν κυρίως στη διερεύνηση μεθόδων βελτίωσης της απόδοσης μοντέλων μηχανικής μάθησης και νευρωνικών δικτύων με σκοπό την ταξινόμηση και αναγνώριση στόχων με βάση τα προς μελέτη δεδομένα και τεχνικών προεπεξεργασίας των δεδομένων που συμβάλουν στην επιδίωξη αυτή. Επιπλέον, μέρος του κεφαλαίου αποτελεί ο σχεδιασμός της έρευνας (3.3) στον οποίο συμπεριελήφθη το δείγμα της έρευνας (3.3.1), η συλλογή και ανάλυση των δεδομένων (3.3.1) στην οποία αναπτύσσονται τα στάδια της ερευνητικής διαδικασίας των μοντέλων ανάλυσης που ακολουθήθηκε.

Στο 4^ο κεφάλαιο παρουσιάζονται τα αποτελέσματα της μελέτης, η οποία βασίστηκε στην ταξινόμηση επιστροφών σημάτων σόναρ που συλλέχθηκαν από ένα μεταλλικό κύλινδρο και ένα κυλινδρικό σχήμα βράχου. Ένα σύνολο από 208 επιστροφές και συγκεκριμένα 111 επιστροφές από μεταλλικό κύλινδρο και 97 επιστροφές από βράχο επιλέχθηκαν με βάση την ένταση της κατοπτρικής επιστροφής έτσι όπως αποτυπώνονται και στην πρωταρχική μελέτη των Gorman & Sejnowski (1988), καθώς και τα επιμέρους ευρήματα με βάση τα ερευνητικά ερωτήματα (4.1) που τέθηκαν. Τελευταίο μέρος του κεφαλαίου αποτελούσε η κριτική ανάλυση των αποτελεσμάτων (4.2), η οποία παρουσιάζει τη σύνοψη των ευρημάτων της έρευνας και η οποία είχε ως στόχο τη διευκόλυνση της κριτικής θεώρησης των αποτελεσμάτων.

Στο 5^ο κεφάλαιο παρουσιάζονται τα συμπεράσματα τα οποία προέκυψαν από την ανάλυση της απόδοσης των μοντέλων, αναφέρθηκαν πιθανές διαπιστώσεις και ερμηνείες σχετικά με την συνολική αποτίμηση των αποτελεσμάτων καθώς και απαντήσεις για κάθε ερευνητικό ερώτημα ξεχωριστά.

Στο 6^ο κεφάλαιο επισημαίνονται οι περιορισμοί της παρούσας έρευνας που αφορούσαν το κομμάτι της αξιοπιστίας και της εγκυρότητας της και αναπτύσσονται μελλοντικές προτάσεις που αποσκοπούν σε μια περισσότερο ολοκληρωμένη εικόνα και ερμηνεία των προς μελέτη ζητημάτων. Τέλος, το 7ο κεφάλαιο αφορά τους βιβλιογραφικούς πόρους από τους οποίους αντλήθηκε γνωστικό υλικό και αξιοποιήθηκε στην παρούσα εργασία και στο 8^ο κεφάλαιο περιλαμβάνονται τα παραρτήματα της εργασίας.

2. Θεωρητικό πλαίσιο

2.1 Sonar


Ο αγγλικός όρος SONAR, προέρχεται από τις λέξεις **S**ound **N**avigation **A**nd **R**anging, δηλαδή πλοήγηση μέσω της διάδοσης του ήχου. Εναλλακτική του ονομασία αποτελεί το ηχοβολιστικό σύστημα. Οι εφαρμογές του εκτείνονται σε ένα μεγάλο εύρος, υδάτινων κυρίως δραστηριοτήτων. Το σύστημα αυτό αξιοποιεί τη

διάδοση του ήχου για τη μεταφορά των σημάτων και ως μέσο το νερό, για πλοήγηση, επικοινωνία ή ανίχνευση αντικειμένων, πάνω ή κάτω από την επιφάνεια του νερού.

Δύο τύποι τεχνολογίας αφορούν μέρη του ηχοβολιστικού συστήματος . Στον ενεργό τύπο (active sonar), οι ενεργοί αισθητήρες sonar εκπέμπουν ηχητικό σήμα στο νερό. Όταν αυτό το σήμα συναντηθεί με ένα αντικείμενο μέσα στο νερό, το οποίο βρίσκεται στη διαδρομή του, τότε ο ήχος προσπίπτει στο αντικείμενο και ανακλάται, επιστρέφοντας μια ποσότητα του, πίσω στο δέκτη του sonar ως "ηχώ". Ο υπολογισμός του χρόνου μεταξύ της εκπομπής του σήματος και της λήψης του, καθορίζει την απόσταση και τη διόπτρευση του αντικειμένου. Από την άλλη, ο άλλος τύπος σόναρ είναι το παθητικό (passive sonar), το οποίο λειτουργεί για την ανίχνευση θορύβου από θαλάσσια αντικείμενα (όπως υποβρύχια ή πλοία) και θαλάσσια ζώα, όπως φάλαινες. Η κύρια διαφορά του με το ενεργό σόναρ βασίζεται στο ότι δεν εκπέμπει το δικό του σήμα, γεγονός το οποίο αποτελεί προνόμιο κυρίως για στρατιωτικού ενδιαφέροντος αποστολές, στις οποίες τα πλοία, αεροπλάνα ή υποβρύχια το χρησιμοποιούν, είτε με σκοπό την αποφυγή εντοπισμού από τον εχθρό είτε για ερευνητικές αποστολές που επικεντρώνονται στην ήρεμη "ακρόαση" του βυθού. Αντιθέτως, ανιχνεύει μόνο τα σήματα που λαμβάνονται από αυτό. Επιπλέον, το παθητικό σόναρ δεν μπορεί από μόνο του να υπολογίσει την απόσταση ενός αντικειμένου εκτός αν χρησιμοποιηθεί η μέθοδος της τριγωνοποίησης, δηλαδή υπολογισμού της απόστασης μέσα από τη διόπτρευση τουλάχιστον δύο ή περισσότερων παθητικών συσκευών.

Τα sonar επίσης, αξιοποιούνται και στον αέρα για πλοήγηση αυτόνομων οχημάτων. Βέβαια η διάδοση τους, δεν είναι τόσο αποτελεσματική όπως στο νερό διότι η υπερηχητική ενέργεια έχει την τάση να μειώνεται πιο γρήγορα στον αέρα. Οι ακουστικές συχνότητες που χρησιμοποιούνται στα συστήματα sonar ποικίλλουν από πολύ χαμηλή έως εξαιρετικά υψηλή και είναι από μερικές δεκάδες kHz μέχρι κάποιες εκατοντάδες kHz. Η λειτουργία ενός sonar παρουσιάζεται στην παρακάτω **Εικόνα 1**. (Jade κ.ά., 2013) Τέλος όσον αφορά τον υπολογισμό της απόστασης ενός υποβρύχιου αντικειμένου, δύο βασικά υδάτινα χαρακτηριστικά, η αλμυρότητα και το

βάθος επηρεάζουν χαρακτηριστικά τη μέτρηση. Επίσης, η μικρή ταχύτητα του ήχου επιδρά αρνητικά επίσης και στο μέγιστο αριθμό μετρήσεων που μπορούν να συλλεχθούν ανά μονάδα χρόνου.

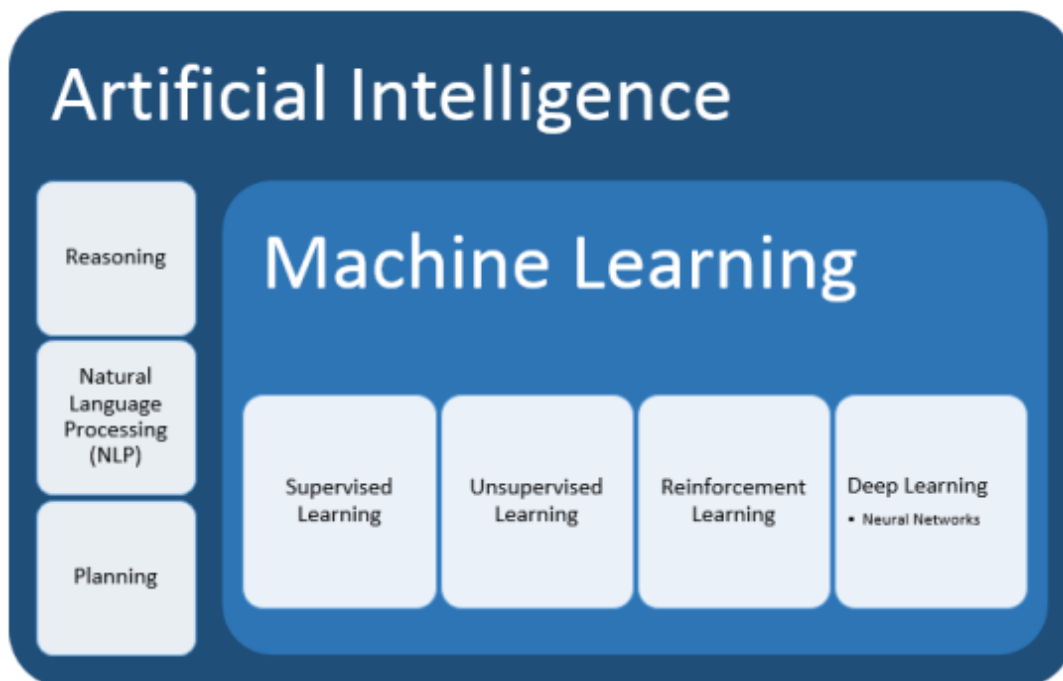


Εικόνα 1. Βασική λειτουργία ενός Sonar (Jade κ.ά., 2013)

2.2 Τεχνητή Νοημοσύνη (Artificial Intelligence)

Η τεχνητή νοημοσύνη (AI) αφορά κλάδο της πληροφορικής, στον οποίο περιλαμβάνεται η σχεδίαση και η δημιουργία υπολογιστικών συστημάτων τα οποία μπορούν στοιχειωδώς να «σκεφτούν», μιμούμενα τον τρόπο που συμπεριφέρεται ο άνθρωπος. Τέτοιου είδους συμπεριφορές περιλαμβάνουν τα χαρακτηριστικά της εκμάθησης, προσαρμοστικότητας, απόσπασης συμπερασμάτων, αφομοίωσης από συμφραζόμενα και αντιμετώπισης προβλημάτων. Ο Τζον Μακάρθι, όρισε τον τομέα αυτόν ως «επιστήμη και μεθοδολογία της δημιουργίας νοημόνων μηχανών». (‘Τεχνητή νοημοσύνη’, 2020) Επιπλέον, η τεχνητή νοημοσύνη χρησιμοποιείται για την βελτίωση πολύπλοκων διεργασιών μέσω της αυτοματοποίησης τους, συμβάλλοντας και στη βελτίωση της απόδοσης των συστημάτων. Οι διεργασίες περιλαμβάνουν την ικανότητα αντίληψης (perception), όπως επεξεργασία εικόνας και ήχου (sound and image processing), συλλογιστική (reasoning) για επίλυση προβλημάτων (problem solving), αναπαράσταση γνώσης για μοντελοποίηση (modeling), σχεδιασμό και επικοινωνία, όπως είναι η επεξεργασία γλώσσας

(language processing) καθώς και αυτόνομα συστήματα (ρομπότ). (Long & Dhillon, 2020, σελ. 1067) Στο παρακάτω σχήμα παρουσιάζονται οι τέσσερις κύριοι τομείς, οι οποίοι απαρτίζουν την τεχνητή νοημοσύνη.



Σχήμα 1. Τεχνητή νοημοσύνη και οι κατηγορίες που περιλαμβάνει (Hurwitz, 2018)

Μια από τις υποκατηγορίες της τεχνητής νοημοσύνης είναι η μηχανική μάθηση, η οποία αφορά στη «βελτίωση της γνώσης και της απόδοσης της μηχανής μέσω αλληλεπιδράσεων με το περιβάλλον, δεδομένων, ατόμων κ.α.». Χαρακτηριστικά, ο Tom Mitchell αναφέρει ότι η μηχανική μάθηση είναι «Ένας κλάδος της τεχνητής νοημοσύνης», και είναι «μια επιστημονική πειθαρχία που ασχολείται με το σχεδιασμό και την ανάπτυξη αλγορίθμων που επιτρέπουν στους υπολογιστές να αναπτύξουν συμπεριφορές με βάση εμπειρικά δεδομένα». (Fossaceca & Young, 2018)

2.3 Μηχανική μάθηση (Machine Learning)

Η μάθηση γενικότερα αποτελεί ένα εκτενές πεδίο έρευνας. Ως διαδικασία, αφορά στην απόκτηση νέων ή στην τροποποίηση ήδη υπαρχόντων συμπεριφορών, αξιών, δεξιοτήτων και προτιμήσεων. Έχουν επίσης αναδειχθεί διάφορες θεωρίες και

μοντέλα εκμάθησης όπως ο Συμπεριφορισμός, Γνωστικισμός, Κονστрукτιβισμός, Βιωματισμός και η Κοινωνική Μάθηση, τα οποία ορίζουν μια ολοκληρωμένη και συστηματική άποψη για τη φύση της διαδικασίας του πώς ένας άνθρωπος μαθαίνει και αλληλεπιδρά με τον ίδιο αλλά και με το περιβάλλον του.(Alzubi κ.ά., 2018) Είναι χαρακτηριστικό ότι, από την έναρξη της εποχή των υπολογιστών, οι ερευνητές στο χώρο της επιστήμης, μελετούν και προσπαθούν να εμφυτεύσουν δυνατότητες μάθησης σε υπολογιστές.(Carbonell κ.ά., 1983) Οι μελέτες αυτές αναδύουν τον τομέα της μηχανικής μάθησης, η οποία σε ένα θεμελιώδες επίπεδο, αποτελεί κατηγορία της τεχνητής νοημοσύνης που επιτρέπει στους υπολογιστές να σκέφτονται και να μαθαίνουν από μόνοι τους. Διάφοροι ερευνητές ενίοτε έχουν προσεγγίσει την έννοια αυτή, δίνοντας διαφορετικούς ορισμούς και φωτίζοντας κάθε φορά μερικές χρήσιμες και ποικίλες προοπτικές του τομέα αυτού. Ενδεικτικά θα γίνει αναφορά σε ορισμένους από αυτούς. Αρχικά, ο όρος επινοήθηκε από τον Arthur Samuel το 1959, ο οποίος όρισε τη μηχανική μάθηση, ως ένα πεδίο σπουδών που παρέχει μαθησιακή ικανότητα στους υπολογιστές χωρίς να έχει προγραμματιστεί ρητά.(Samuel, 1959 όπ. ανάφ. στο (Alzubi κ.ά., 2018). Πιο πρόσφατα, ο Mitchell (1997) αναφέρει:

« Ο τομέας της μηχανικής μάθησης ασχολείται με το ζήτημα του τρόπου κατασκευής προγραμμάτων υπολογιστών που βελτιώνονται αυτόματα με την εμπειρία.» (σελ. preface xv)

Παρακάτω στο βιβλίο του Machine Learning, δίνει τον ορισμό για την μηχανική μάθηση ως εξής:

«Ένα πρόγραμμα υπολογιστή λέγεται ότι μαθαίνει από την εμπειρία E σε σχέση με κάποια κατηγορία εργασιών T και απόδοσης μέτρου P, εάν η απόδοσή του σε εργασίες στο T, όπως μετράται από το P, βελτιώνεται με την εμπειρία E.» (σελ. 2)

Ο παραπάνω ορισμός ορίζει την τυπική διαδικασία της μηχανικής μάθησης, η οποία φαίνεται να αποτελεί έναν οδηγό σχεδίασης εργαλείου, του οποίου πρέπει να λάβουμε υπόψη. Δηλαδή τα σωστά δεδομένα που θα εισάγουμε (E) , ποιές

αποφάσεις πρέπει να λάβει το λογισμικό (T) και πώς θα αξιολογήσουμε τα αποτελέσματά του (P). (Brownlee, 2013)

Μια ακόμα ερμηνεία της μηχανικής μάθησης δίνεται από τους (Herbrich & Graepel, 2015) στο βιβλίο “Machine Learning. An Algorithm Perspective”:

«Ένα από τα πιο ενδιαφέροντα χαρακτηριστικά της μηχανικής μάθησης είναι ότι βρίσκεται στα όρια πολλών διαφορετικών ακαδημαϊκών κλάδων, κυρίως της επιστήμης των υπολογιστών, των στατιστικών, των μαθηματικών και της μηχανικής. ... Η μηχανική μάθηση μελετάται συνήθως ως μέρος της τεχνητής νοημοσύνης, η οποία την τοποθετεί σταθερά στην επιστήμη των υπολογιστών... κατανοώντας γιατί αυτοί οι αλγόριθμοι λειτουργούν και απαιτούν ένα ορισμένο ποσό στατιστικής και μαθηματικής πολυπλοκότητας που συχνά λείπει από τους προπτυχιακούς φοιτητές της επιστήμης των υπολογιστών.» (σελ. xix)

Εδώ από τους συγγραφείς υπογραμμίζονται ορισμένες διαπιστώσεις για την μηχανική μάθηση.

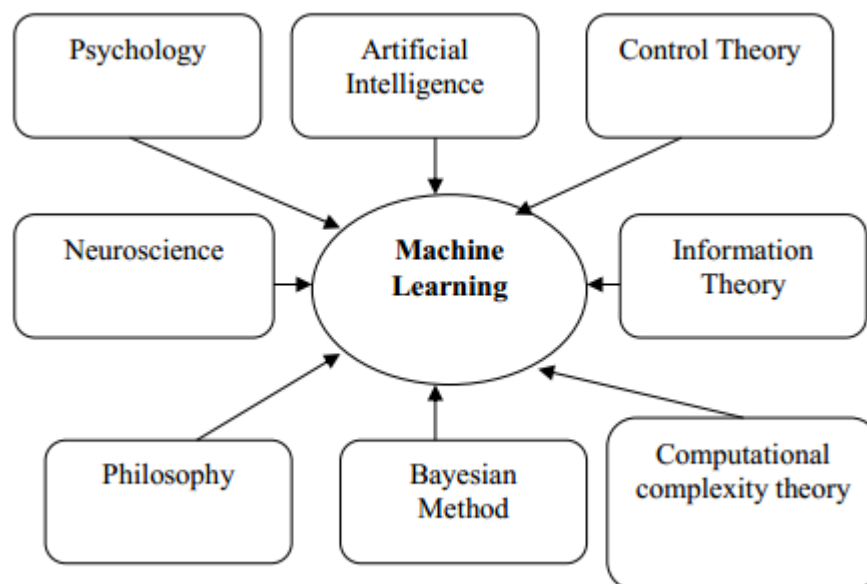
1. Ο διεπιστημονικός της χαρακτήρας ο οποίος αντλείται από κάθε είδους επιστήμες πληροφοριών. (βλ. **Εικόνα 2**)
2. Τον κίνδυνο του ερευνητή να επιμένει σε μια δεδομένη οπτική του αλγόριθμου πολύ έντονα, αδιαφορώντας για τις υπόλοιπες. (π.χ η περίπτωση ενός προγραμματιστή ο οποίος απομακρύνεται από τις μαθηματικές εσωτερικές λειτουργίες μιας μεθόδου που χρησιμοποιεί ο αλγόριθμος, ενδιαφέροντας τον αποκλειστικά η σωστή εκτέλεση του, σχετικά με τον κώδικα που χρησιμοποιεί)

Ένας τελευταίος ορισμός, έτσι όπως αποτυπώνεται στο βιβλίο “The Elements of Statistical Learning: Data Mining, Inference, and Prediction” από τους Hastie, Tibshirani & Friedman (2016) διατυπώνεται ως εξής :

«Τεράστιες ποσότητες δεδομένων δημιουργούνται σε πολλά πεδία και η δουλειά των στατιστικολόγων είναι να τα κατανοήσουν όλα: να εξάγουν σημαντικά

μοτίβα και τάσεις και να κατανοήσουν "τι λένε τα δεδομένα". Αυτό το ονομάζουμε εκμάθηση από τα δεδομένα.» (σελ. xi)

Καθίσταται σαφές, ότι κύριος ρόλος του στατιστικολόγου είναι η ερμηνεία των δεδομένων, η παρουσίαση και η ανάλυση τους, εφαρμόζοντας στατιστικές μεθόδους και στατιστικά εργαλεία με στόχο την εξαγωγή συμπερασμάτων και προβλέψεων, απαραίτητων για τη λήψη ορθών αποφάσεων. (Παπακωνσταντίνου & Καϊτσα, 1997) Οι συγγραφείς με βάση τον παραπάνω ορισμό φαίνεται να θεωρούν το κομμάτι της μηχανικής μάθησης, ως ένα μέσο για την επίδωξη αυτή. (Brownlee, 2013). Επιπλέον, Η προσομοίωση των μοντέλων μηχανικής μάθησης σχετίζεται σημαντικά με τις Υπολογιστικές Στατιστικές (Computational Statistics), των οποίων ο βασικός ρόλος είναι η πραγματοποίηση προβλέψεων μέσω υπολογιστών. Συνδέεται επίσης με τη Μαθηματική Βελτιστοποίηση (Mathematical Optimization), η οποία ενσωματώνει μοντέλα, εφαρμογές και τεχνολογικό πλαίσιο στον τομέα των στατιστικών.(Alzubi κ.ά., 2018)



Εικόνα 2. Διεπιστημονικός χαρακτήρας της Μηχανικής Μάθησης (Alzubi κ.ά., 2018)

2.3.1 Εξέλιξη της Μηχανικής Μάθησης

Γενικότερα, οι έννοιες της Τεχνητής Νοημοσύνης και της Μηχανικής Μάθησης δεν είναι πρόσφατες στο επιστημονικό πεδίο. Έχουν μελετηθεί, χρησιμοποιηθεί και ερευνώνται εκ νέου από επιστήμονες υπολογιστών (computer scientist), μηχανικούς (engineers), ερευνητές (researchers), φοιτητές (students) και επαγγελματίες (professionals) για παραπάνω από μισό αιώνα. Το μαθηματικό υπόβαθρο της μηχανικής μάθησης περιλαμβάνεται στην άλγεβρα, στη στατιστική και στη θεωρία των πιθανοτήτων. Αφετηρία στην ουσιαστική ανάπτυξη της, αποτέλεσε η συμβολή ερευνητών όπως ο Alan Turing, ο John McCarthy, ο Arthur Samuels, Alan Newell και Frank Rosenblatt κατά τη δεκαετία 1950 και του 60. Ο Samuel πρότεινε το πρώτο μοντέλο μηχανικής μάθησης για την βελτιστοποίηση ενός προγράμματος εφαρμογής σε παιχνίδι checkers. Κατόπιν, ο Rosenblatt δημιούργησε το Perceptron, έναν δημοφιλή αλγόριθμο μηχανικής μάθησης ο οποίος πηγάζει από τους ανθρώπινους βιολογικούς νευρώνες και με αυτό τον τρόπο έθεσε τις βάσεις δημιουργίας του Τεχνητού Νευρωνικού Δικτύου. (N. dhage & Raina, 2016; Royal Society (Great Britain), 2017). Ο παρακάτω **Πίνακας 1** παρουσιάζει συνοπτικά την εξέλιξη της μηχανικής μάθησης κατά την διάρκεια των ετών, υπογραμμίζοντας τους κυριότερους σταθμούς.

1950	Δοκιμή Turing. Ο Alan Turing εφάρμοσε ένα test στο οποίο μια μηχανή κατείχε νοημοσύνη εφόσον μπορούσε να πείσει έναν άνθρωπο ότι συμπεριφέρεται σαν αυτόν.
1950	Ο Samuel πειραματίστηκε έναν αλγόριθμο ικανό να μπορεί να παίζει ένα παιχνίδι (Checkers) με τον εαυτό του και να αυτό-εκπαιδεύεται.
1952	Ο Martin Minsky, John McCarty, Claude Shannon και ο Nathan Rochester οργάνωσαν ένα συνέδριο στο Dartmouth το 1956 χάρη στο οποίο ο όρος «Τεχνητή Νοημοσύνη» εμφανίστηκε για πρώτη φορά.
1956	Frank Rosenblatt created Perceptron, which laid the foundation stone for the development of Artificial Neural Network (ANN).

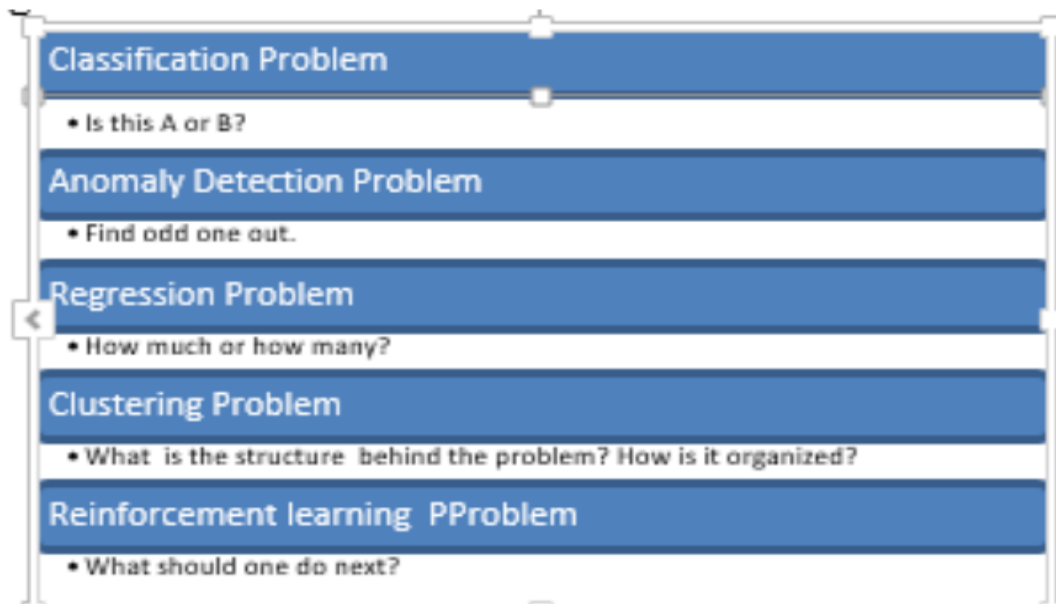
1958	Ο αλγόριθμος «Κοντινοί Γείτονες» (Nearest Neighbor) προτάθηκε για πρώτη φορά για ζητήματα «Αναγνώρισης μοτίβων» (Pattern Recognition).
1967	Μαθητές του πανεπιστημίου του Stanford ανέπτυξαν ρομπότ (Stanford Cart) το οποίο είχε την δυνατότητα να κινηθεί μέσα σε ένα δωμάτιο αποφεύγοντας εμπόδια που συναντάει στο δρόμο του.
1979	Ο Gerald Dejong πρότεινε το μοντέλο της μάθησης μέσω εξήγησης (Explanation Based Learning (EBL)), όπου ένας υπολογιστής μπορεί να αναλύσει τα δεδομένα εκπαίδευσης και να δημιουργήσει κανόνες για την απόρριψη των άχρηστων δεδομένων.
1981	Το NetTalk εφευρέθηκε από τον Terry Sejnowski, ο οποίος έμαθε να προφέρει αγγλικές λέξεις με τον ίδιο τρόπο που μαθαίνουν τα παιδιά.
1985	Το επίκεντρο της Μηχανικής Μάθησης μετατοπίστηκε από τη γνώση στα δεδομένα. Η Μηχανική Εκμάθηση εφαρμόστηκε για την ανάλυση μεγάλων κομματιών δεδομένων καθώς και την εξαγωγή συμπερασμάτων από αυτά.
1990s	Η IBM εφηύρε τον υπολογιστή Deep Blue που κατάφερε να νικήσει τον Παγκόσμιο Πρωταθλητή Σκακιού Gary Kasparov.
1997	Ο όρος «Deep Learning» επινοήθηκε από τον Geoffery Hinton που αναφέρεται σε μια νέα αρχιτεκτονική νευρωνικών δικτύων που χρησιμοποίησαν πολλαπλά στρώματα νευρώνων μάθησης.
2006	Ο υπολογιστής της IBM Watson κατασκευάστηκε για να απαντά σε ερωτήσεις που τίθενται σε φυσική γλώσσα και νίκησε υπέρ ενός ανθρώπου σε ένα παιχνίδι («Jeopardy Game»).
2011	Ο Jeff Dean από τη Google, ανέπτυξε την εφαρμογή GoogleBrain, η οποία είναι ένα βαθύ νευρωνικό δίκτυο (Deep Neural Network) με σκοπό την αναγνώριση μοτίβων σε οπτικοακουστικό υλικό και εικόνες.
2012	Η εταιρεία Facebook δημιούργησε τον αλγόριθμο “DeepFace” βασισμένο στα νευρωνικά δίκτυα (Deep Neural Networks) ικανό να αναγνωρίζει ανθρώπινα πρόσωπα σε φωτογραφίες.
2014	Η Amazon πρότεινε τη δική της πλατφόρμα μηχανικής εκμάθησης. Η

	<p>Microsoft δημιούργησε το "Distlance Machine Learning Toolkit" για αποτελεσματική διανομή προβλημάτων μηχανικής μάθησης σε πολλούς υπολογιστές, εργαζόμενη παράλληλα για να βρουν λύση.</p> <p>Ο Elon Musk και ο Sam Altman, δημιούργησε έναν μη κερδοσκοπικό οργανισμό, τον OoeaAI, με σκοπό τη χρήση Τεχνητής Νοημοσύνης για την εξυπηρέτηση των ανθρώπων.</p>
2015	<p>Η Google πρότεινε το DeepMind που θεωρείται ως το πιο περίπλοκο επιτραπέζιο παιχνίδι. Το πρόγραμμα Google AlphaGo γίνεται το πρώτο πρόγραμμα που κέρδισε έναν επαγγελματία ανθρώπινο παίκτη.</p> <p>Βασίζεται στον συνδυασμό μηχανικής μάθησης και τεχνικών αναζήτησης δέντρων. («Tree searching techniques»)</p>
2016	<p>Η Google παρουσίασε τηλέφωνα όπως τα proposed Google Lens, Google Clicks, Google Home Mini and Google Nexus, τα οποία χρησιμοποιούν αλγόριθμους μηχανικής μάθησης και νευρωνικά δίκτυα.</p> <p>Η Nvidia δημιούργησε την κάρτα γραφικών NVIDIA GPUs-Την μηχανή Deep Learning. Επιπλέον η Apple παρουσίασε το Home Pod το οποίο είναι μια συσκευή διαδραστικής μηχανικής μάθησης.</p>

Πίνακας 1. Ιστορική αναδρομή της μηχανικής μάθησης (Alzubi κ.ά., 2018)

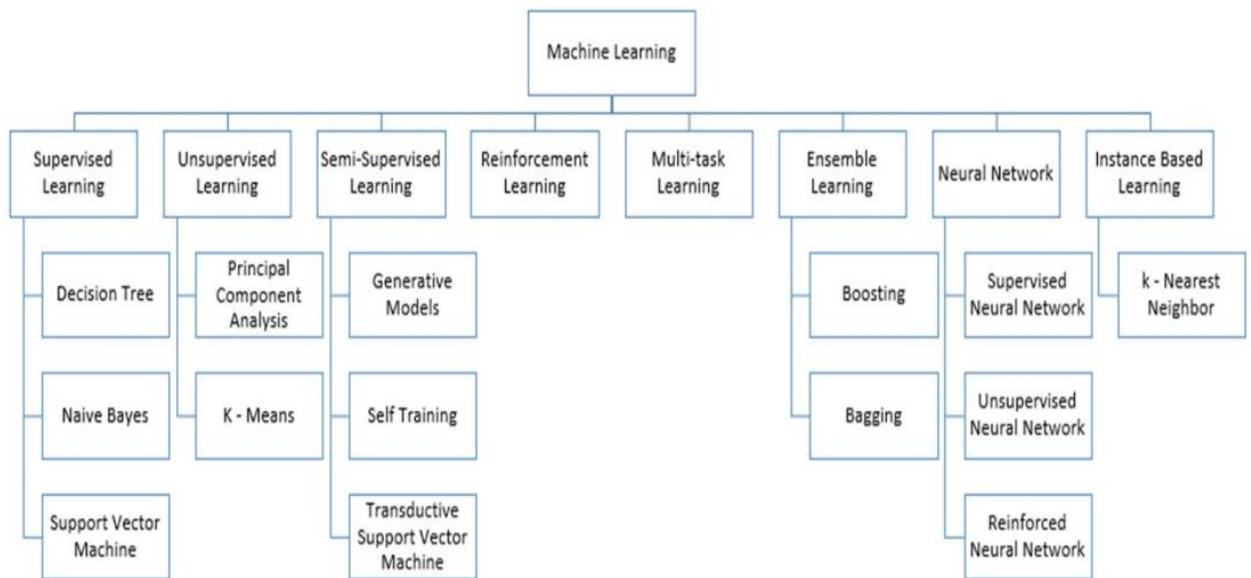
2.3.2 Προβλήματα επίλυσης & τύποι Μηχανικής Μάθησης

Η μηχανική μάθηση κατέχει τις εγγενείς ικανότητες ώστε να ανταποκρίνεται επαρκώς στις προκλήσεις που αντιμετωπίζει η επιστήμη δεδομένων. Οι Hayashi και Chikio (1998 όπ. ανάφ στο (Alzubi κ.ά., 2018) ορίζουν την επιστήμη των δεδομένων ως «μια έννοια για την ενοποίηση στατιστικών, την ανάλυση δεδομένων, τη μηχανική μάθηση και τις σχετικές μεθόδους τους, για να κατανοήσουν και να αναλύσουν τα πραγματικά φαινόμενα με δεδομένα». Επιπλέον, έχοντας πάντα ως στόχο την επίλυση, τα προβλήματα κατηγοριοποιούνται κατάλληλα, έτσι ώστε να εφαρμόζεται κάθε φορά η βέλτιστη επιλογή αλγορίθμου Μηχανικής Μάθησης. Στην παρακάτω **Εικόνα 3** παρουσιάζονται πέντε κύριες κατηγορίες προβλημάτων της επιστήμης δεδομένων.



Εικόνα 3. Τύποι προβλημάτων της επιστήμης δεδομένων (Alzubi κ.ά., 2018)

Παρόλα αυτά, αρκετές μελέτες από προγραμματιστές και μαθηματικούς έχουν πραγματοποιηθεί στο πώς οι μηχανές μπορούν να μαθαίνουν από τον εαυτό τους και να συμβάλουν στην επίλυση διάφορων ζητημάτων.(Dey, 2016) Όλες οι τεχνικές που εφαρμόζει η μηχανική μάθηση αποτυπώνονται στο παρακάτω **Σχήμα 2**:



Σχήμα 2 Τύποι Μηχανικής Μάθησης

Για το λόγο ότι στην παρούσα διπλωματική που αφορά στην ταξινόμηση ηχητικών σημάτων (sonar), αξιοποιούνται αλγόριθμοι εποπτευόμενης μάθησης (supervised learning) καθώς και νευρωνικά δίκτυα (neural networks), θα γίνει εκτενής αναφορά αποκλειστικά σε αυτούς. Οι υπόλοιποι τύποι μάθησης είναι πέρα από τα όρια αυτής της εργασίας.

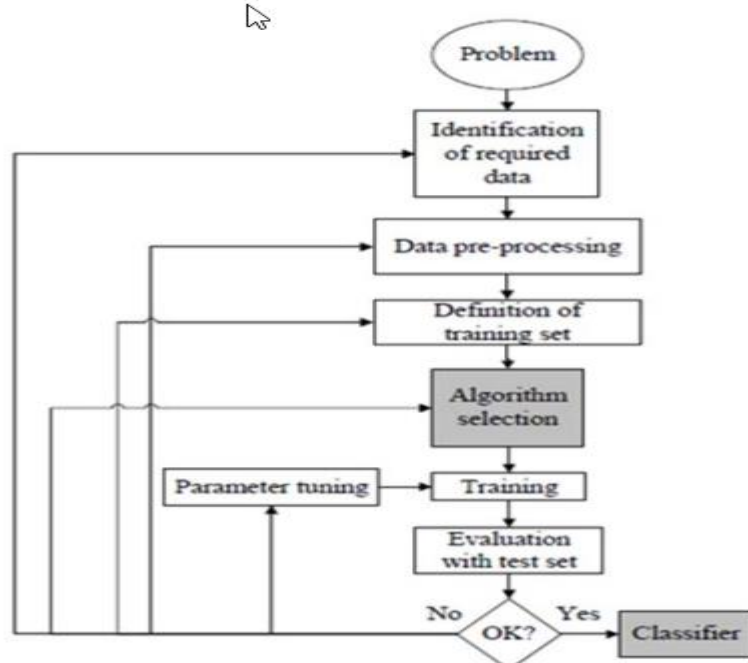
Εποπτευόμενη μάθηση (Supervised learning)

Η εποπτευόμενη μάθηση καλείται συχνά και ως μάθηση μέσα από παραδείγματα. (Alzubi κ.ά., 2018) Τυπικά ξεκινά με ένα καθιερωμένο σύνολο δεδομένων και μια ορισμένη κατανόηση του τρόπου ταξινόμησης αυτών των δεδομένων. Σκοπός της μάθησης αυτής είναι η εύρεση μοτίβων (patterns) στα δεδομένα, τα οποία έπειτα μπορούν να εφαρμοστούν στην αναλυτική διαδικασία. Επίσης, τα δεδομένα αυτά χαρακτηρίζονται από επιμέρους ετικέτες, οι οποίες ορίζουν την ερμηνεία που αυτά υποδηλώνουν. Για παράδειγμα, τα δεδομένα που χρησιμοποιούνται στην παρούσα εργασία διαχωρίζονται σε δύο κύριες ετικέτες-χαρακτηριστικά: Βράχος (Rock) και Νάρκη-μεταλλική επιφάνεια (Mine). Έτσι, από το σύνολο των δεδομένων υπάρχουν παραδείγματα δεδομένων (instances) που αντικατοπτρίζουν την ετικέτα «Βράχος» ενώ τα υπόλοιπα αφορούν την ετικέτα «Νάρκη-μεταλλική» επιφάνεια. Εάν λοιπόν τροφοδοτήσουμε έναν αλγόριθμο

εποπτευόμενης μάθησης με αυτά τα δεδομένα για να τον εκπαιδεύσουμε , ο αλγόριθμος έχει την ικανότητα να ερμηνεύσει τη σχέση των δεδομένων με τα χαρακτηριστικά των ετικετών τους (labels) και να δημιουργήσει ένα μοντέλο το οποίο ταιριάζει στη σχέση αυτή. Τότε λέμε ότι ο αλγόριθμος ταιριάζει τα δεδομένα («fits the training data»).

Όσον αφορά την διαδικασία της εποπτευόμενης μηχανικής μάθησης, οι αλγόριθμοι εκπαιδεύονται με δεδομένα εκπαίδευσης (training data) τα οποία προηγουμένως έχουν υποστεί πρότερη επεξεργασία (preprocessing), ενώ οι επιδόσεις των αλγορίθμων αξιολογούνται με άγνωστα σε αυτούς δεδομένα, πανομοιότυπων χαρακτηριστικών (test data). (Dey, 2016) Είναι χαρακτηριστικό ότι τα μοτίβα που έχουν εντοπιστεί από έναν αλγόριθμο, αφορούν αποκλειστικά το συγκεκριμένο αριθμό δεδομένων με τα οποία έχει εκπαιδευτεί ο αλγόριθμος. Επομένως, στην περίπτωση περισσότερων δεδομένων εκπαίδευσης είναι σαφές ότι τα μοτίβα αυτά θα είναι εντελώς διαφορετικά. Αξίζει να σημειωθεί ότι όσο περισσότερα δεδομένα διαθέτουμε για την εκπαίδευση του αλγόριθμου τόσο καλύτερη θα είναι και η επίδοση του σε άγνωστα δεδομένα. Επιπλέον, η σημασία των άγνωστων δεδομένων (testing data) είναι καθοριστική για την σωστή εκτέλεση του αλγόριθμου διότι με αυτόν τον τρόπο αποφεύγονται ζητήματα απόλυτου ταιριάσματος (overfitting). Η έννοια του «Overfitting» σημαίνει ότι το μοντέλο που έχει δημιουργήσει ο αλγόριθμος βρίσκεται σε απόλυτο συντονισμό (precisely tuned) με τα δεδομένα εκπαίδευσης (training data), ωστόσο υπάρχει το ενδεχόμενο να μην μπορεί να εφαρμοστεί κάνοντας επιτυχημένες προβλέψεις σε άγνωστα δεδομένα. Πρόβλημα γενικευσιμότητας. (Hurwitz, 2018)

Στο παρακάτω **Σχήμα 3** παρουσιάζεται ένα διάγραμμα ροής εργασίας ενός αλγόριθμου εποπτευόμενης μάθησης:




Σχήμα 3. Διάγραμμα ροής εργασιών αλγορίθμου εποπτευόμενης μάθησης (Dey, 2016)

Νευρωνικά δίκτυα (Neural networks)

Τα νευρωνικά δίκτυα έχουν δημιουργηθεί με τρόπο τέτοιο ώστε να μιμούνται την λειτουργία του ανθρώπινου εγκεφάλου. Η λειτουργία αυτή, προσεγγίζει τα διάφορα προβλήματα χρησιμοποιώντας επίπεδα αλληλοσυνδεδεμένων μονάδων, μαθαίνοντας και συνάγοντας σχέσεις με βάση τα παρατηρούμενα δεδομένα. Ένα τέτοιο δίκτυο μπορεί να έχει πολλά συνδεδεμένα στρώματα. Όταν διακρίνονται περισσότερα από ένα ενδιάμεσα στρώματα σε ένα νευρωνικό δίκτυο τότε μιλάμε για «Βαθιά μάθηση» (Deep Learning). (Hurwitz, 2018)


Τα νευρωνικά δίκτυα ή αλλιώς τεχνητά νευρωνικά δίκτυα (artificial neural networks- ANN) κατέχουν την ονομασία τους από το δόμημα των βιολογικών νευρώνων. Ένας νευρώνας είναι μια κυτταρική δομή η οποία βρίσκεται στον εγκέφαλο. Για την κατανόηση ενός δικτύου νευρώνων θα πρέπει πρώτα να κατανοηθεί η λειτουργία ενός από αυτών. Στην παρακάτω **Εικόνα 4** απεικονίζεται η δομή ενός νευρώνα.



Εικόνα 4 Δομή ενός νευρώνα (Dey, 2016)

Σχετικά με την δομή και τη λειτουργία του, ένας νευρώνας αποτελείται από τους δενδρίτες (dendrites), το κύριο σώμα (soma), τον πυρήνα (nucleus), τον νευράξονα (axon) και τις νευραξονικές απολήξεις. Οι δενδρίτες δέχονται ηλεκτρικά σήματα και αφορούν τις εισόδους του νευρώνα. Η διαδικασία εξόδου περιλαμβάνει την μεταφορά του σήματος μέσω του νευράξονα στις νευρικές απολήξεις και έπειτα στον επόμενο νευρώνα. Ο πυρήνας είναι η καρδιά του νευρώνα. Η διασύνδεση των νευρώνων μεταξύ τους δημιουργεί ένα νευρωνικό δίκτυο του οποίου τα ηλεκτρικά ερεθίσματα ταξιδεύουν σε όλο τον εγκέφαλο.

Παρόμοια συμπεριφορά λειτουργίας συμβαίνει και στο τεχνητό νευρωνικό δίκτυο. (βλ. *Εικόνα 5*)



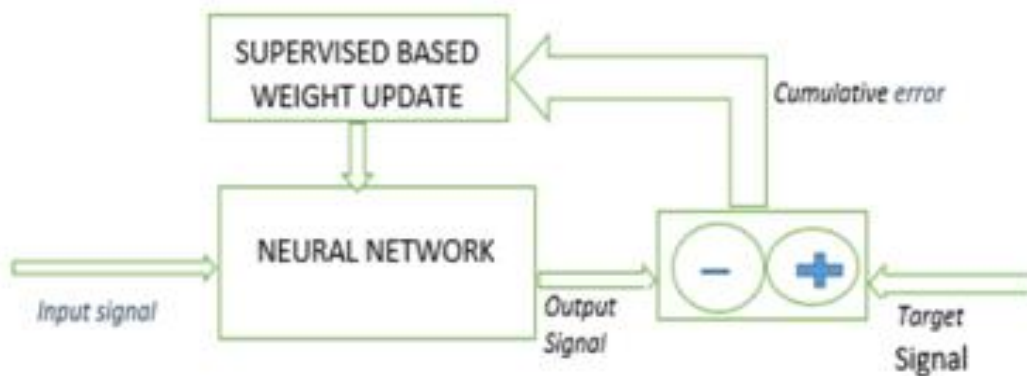
Εικόνα 5. Δομή τεχνητού νευρωνικού δικτύου

Το τεχνητό αυτό δίκτυο απαρτίζεται από τρία βασικά στρώματα. Το στρώμα

εισόδου το οποίο δέχεται τα σήματα εισόδου όπως συμβαίνει και με τους δενδρίτες, το ενδιάμεσο στρώμα, το οποίο επεξεργάζεται τα σήματα που προέρχονται από το στρώμα εισόδου και τέλος το στρώμα εξόδου το οποίο στέλνει την υπολογισμένη έξοδο όπως συμβαίνει και στις νευρικές απολήξεις. (Dey, 2016; Hurwitz, 2018)

Εποπτευόμενα νευρωνικά δίκτυα (Supervised neural networks)

Στο εποπτευόμενο νευρικό δίκτυο, η έξοδος της εισόδου είναι ήδη γνωστή. Η έξοδος την οποία έχει προβλέψει το τεχνητό νευρωνικό δίκτυο, συγκρίνεται με το πραγματική έξοδο. Βασιζόμενοι στο σφάλμα μεταξύ πραγματικής και προβλεπόμενης εξόδου, οι παράμετροι (weights) αναπροσαρμόζονται και στη συνέχεια τροφοδοτούνται εκ νέου στο νευρικό δίκτυο. Στο παρακάτω **Σχήμα 4** συνοψίζεται η όλη διαδικασία. (Alzubi κ.ά., 2018; Dey, 2016)



Σχήμα 4. Εποπτευόμενο νευρωνικό δίκτυο (Dey, 2016)

2.3.3 Εφαρμογές μηχανικής μάθησης

Η μηχανική μάθηση υποστηρίζει ήδη μια σειρά εφαρμογών ενώ η δυναμική της φαίνεται να επεκτείνεται πολύ παραπάνω. Σε τομείς, όπως η υγειονομική περίθαλψη και η εκπαίδευση καθώς και ο τομέας των μεταφορών, των κοινωνικών υπηρεσιών και μέσων, η μηχανική μάθηση είναι ικανή να συντελέσει στην βελτίωση της αποτελεσματικότητας των προϊόντων και των υπηρεσιών μέσω της αυξημένης

ακρίβειας και των ουσιαστικότερων προσαρμοστικών λύσεων που θα αναδείξει μέσω των προβλέψεων της. Λόγω των διαταραχών που επιφέρει η τεχνολογία σε πολλά επιχειρηματικά πεδία εξαιτίας των ταχύτατων αλλαγών της, η μηχανική μάθηση θα μπορούσε να ανταποκριθεί είτε αλλάζοντας τον τρόπο με τον οποίο οι επιχειρήσεις είναι οργανωμένες, είτε επηρεάζοντας τα διάφορα επιχειρηματικά μοντέλα που χρησιμοποιούν.(Royal Society (Great Britain), 2017)

Παρακάτω αναφέρονται συνοπτικά ορισμένοι τομείς που μπορούν να αναπτυχθούν ή αναπτύσσονται ήδη εφαρμογές της μηχανικής μάθησης.

Υγεία: Στην υγειονομική περίθαλψη, η μηχανική μάθηση θα μπορούσε να βοηθήσει παρέχοντας ακριβέστερες διαγνώσεις και πολλές άλλες αποτελεσματικές υπηρεσίες υγειονομικής περίθαλψης, μέσω προηγμένης ανάλυσης που βελτιώνει τη λήψη αποφάσεων. Χαρακτηριστικό παράδειγμα αποτελεί η περίπτωση της διάγνωσης ή εξάπλωσης του καρκίνου σε αρκετά πρώιμο στάδιο μέσω “image recognition”. Επίσης, άλλες τεχνικές μηχανικές εκμάθησης, όπως η επεξεργασία φυσικής γλώσσας (natural language processing), μπορούν να συμβάλουν στη καλύτερη λήψη αποφάσεων από πλευράς ιατρικού προσωπικού, επιτρέποντας στους υπολογιστές να επεξεργάζονται γραπτές ή προφορικές πληροφορίες από διάφορες πηγές.

Εκπαίδευση: Στην εκπαίδευση, η μηχανική μάθηση μπορεί να υποστηρίξει νέους τρόπους παράδοσης διδακτικού υλικού, ειδικά στο διαδικτυακό περιβάλλον και μπορεί να βοηθήσει τους εκπαιδευτικούς να παρέχουν εξατομικευμένη μάθηση σε μαθητές.

Μεταφορές και εφοδιαστική αλυσίδα: Στον τομέα αυτό, αναδεικνύεται η παρουσία των αυτόνομων οχημάτων (autonomous vehicles), τα οποία πρέπει να είναι σε θέση να αναγνωρίζουν ένα μεγάλο μέρος περιβαλλοντικών χαρακτηριστικών όπως εμπόδια, οδικές πινακίδες, πεζούς και άλλα οχήματα. Το εύρος και η μεταβλητότητα των παραπάνω χαρακτηριστικών υποδηλώνει ότι δεν είναι μόνο εφικτό αλλά και αναγκαίο να επινοηθούν αυστηροί κανόνες

κωδικοποίησης, οι οποίοι να καθορίζουν τον τρόπο συμπεριφοράς του οχήματος. Πάνω σε αυτή τη συνθήκη, η μηχανική μάθηση πρόκειται να επιτρέψει στο όχημα να προσαρμοστεί σε ένα εύρος χαρακτηριστικών και να ανταποκρίνεται ανάλογα. Περαιτέρω εξελίξεις στην πολυπλοκότητα των αυτόνομων οχημάτων αφορούν εφαρμογές και πρακτικές σε βιομηχανικό επίπεδο.

Οικονομία: Η μηχανική μάθηση εφαρμόζεται ήδη στο τραπεζικό σύστημα και στην οικονομία γενικότερα . Παράδειγμα αποτελούν τραπεζικές εφαρμογές εντοπισμού ασυνήθιστων ή ύποπτων συναλλαγών καθώς και συστημάτων αναγνώρισης χειρόγραφου (handwriting-recognition systems), που επιτρέπουν αυτοματοποιημένες ταμειακές μηχανές για ανάγνωση επιταγών που έχουν κατατεθεί.

Ενέργεια: Η μηχανική εκμάθηση μπορεί να χρησιμοποιηθεί για τη βελτιστοποίηση των ενεργειακών υποδομών. Μπορεί να αναλύσει μοτίβα ενεργειακής χρήσης καθώς και να τα αξιολογεί κατάλληλα για το σχεδιασμό συστημάτων, τα οποία δύναται να ανταποκριθούν πιο αποτελεσματικά σε υψηλότερα αιτήματα του τομέα αυτού.

Βιομηχανοποίηση: Στον τομέα αυτό, η μηχανική μάθηση είτε προσφέρει ευκαιρίες αυτοματοποιημένων διαδικασιών, είτε βελτιώνει την αποδοτικότητα τους. Επιπλέον δημιουργεί εξατομικευμένα προϊόντα ή επιτρέπει εφαρμογές προληπτικής συντήρησης. (Royal Society (Great Britain), 2017)

2.3.3.1 Εφαρμογές μηχανικής μάθησης στο στρατιωτικό πεδίο

Όσον αφορά τον στρατιωτικό τομέα, η δυναμική της τεχνητής νοημοσύνης και κατ επέκταση της μηχανικής μάθησης υπάρχει σε όλους τους τομείς, οι οποίοι περιλαμβάνουν όλες τις κατηγορίες πολέμων. Δεν περιλαμβάνουν αποκλειστικά πολιτικές και οικονομικές πτυχές, αλλά επίσης καλύπτουν και πτυχές της στρατιωτικής στρατηγικής, των επιχειρήσεων και της τακτικής. Για παράδειγμα στην περίπτωση των εναλλακτικών μορφών πολέμου , όπως η πολιτική, τα οικονομικά και η διπλωματία , η τεχνητή νοημοσύνη μπορεί να αποσταθεροποιήσει τα συστήματα

που σχετίζονται με τον αντίπαλο, παράγοντας και απελευθερώνοντας ένα μεγάλο όγκο ψευδών πληροφοριών. Σε τέτοια σενάρια, το ΑΙ είναι πιθανώς ο καλύτερος υπέρμαχος ενάντια τέτοιων επιθέσεων. Επιπλέον η συμβολή της μηχανικής μάθησης ως τεχνικό εργαλείο στη τεχνητή νοημοσύνη (Lüch, 2019) μπορεί να βελτιώσει την αυτόνομη απόδοση ελέγχου των μη επανδρωμένων συστημάτων εντός τακτικών επιχειρήσεων, αυξάνοντας την ακρίβεια και την ταχύτητα συλλογής, επεξεργασίας και ανάλυσης δεδομένων. Είναι χαρακτηριστικό ότι η μηχανική μάθηση είναι μια βελτιωμένη προσέγγιση που συμβάλει στην επίλυση προβλημάτων, χρησιμοποιώντας βασική γνώση ,μηχανικούς αλγόριθμους εκμάθησης και δεδομένα για την εκπαίδευση τους. Μια τέτοια προσέγγιση είναι δυνατή να ωθήσει την τεχνητή νοημοσύνη και της ρομποτική στις επόμενες βελτιωμένες γενιές εφαρμογών τους.(Alzubi κ.ά., 2018)

Επιπλέον, η τεχνητή νοημοσύνη προσδίδει σημαντικά χαρακτηριστικά σε όλες τις πτυχές στρατιωτικών εφαρμογών με υψηλή απόδοση εντολών (high command efficiency), ακρίβεια στόχου, αυτόματη λειτουργία και έξυπνα όπλα (intelligent weapons). Στρατιωτικές εφαρμογές όπως ως επιτήρηση, αναγνώριση, αξιολόγηση απειλών, ασφάλεια στον κυβερνοχώρο, ανάλυση πληροφοριών, εντολή και έλεγχο, καθώς και τομείς εκπαίδευσης και κατάρτισης δύναται να αξιοποιήσουν κατάλληλα τις τεχνικές της Τεχνητής Νοημοσύνης και Μηχανικής Μάθησης. Επιπλέον, εφαρμογές προσδιορισμού αντικειμένων, φαινομένων και αλλαγών με την πάροδο του χρόνου στις δορυφορικές εικόνες, στις εγγραφές βίντεο ή σε δεδομένα που αφορούν ηλεκτρομαγνητικά σήματα (χρήση Radar) ή ακουστικούς αισθητήρες (sonar) βελτιώνονται με τη χρήση μηχανικής μάθησης.(Lüch, 2019)

Παρακάτω παρουσιάζονται συνοπτικά τρεις μεγάλες κατηγορίες στρατιωτικών εφαρμογών.

- Ξηρά

Δίνεται ιδιαίτερα η έμφαση στην ανάπτυξη αυτόνομων οχημάτων βασισμένα σε τεχνικές υπολογιστικής όρασης και αναγνώρισης εικόνας. Αυτού του

είδους οχήματα θα έχουν τη δυνατότητα να αποφασίζουν αυτόνομα τη διαδρομή που θα ακολουθήσουν.(Long & Dhillon, 2020)

Μια άλλη εφαρμογή αφορά στις χερσαίες τηλεπικοινωνίες μεταξύ των στρατιωτών και των οχημάτων τους. Η αποτελεσματική αξιοποίηση του διαθέσιμου φάσματος συχνοτήτων και αυτοματοποίηση της εκχώρησης συχνότητας μειώνουν σε μεγάλο βαθμό τον χρόνο εγκατάστασης επικοινωνιών στο πεδίο της μάχης γεγονός το οποίο προσδίδει πολεμικό πλεονέκτημα.

Το εμπόριο συμβατικών όπλων αποτελεί άλλο ένα σημαντικό ζήτημα στις μέρες μας. Άλλη μια εφαρμογή της μηχανικής μάθησης θα μπορούσε να χρησιμοποιήσει ακτίνες X για τον εντοπισμό εξοπλισμών σε αμέτρητα σφραγισμένα δοχεία. Ενώ οι άνθρωποι θα μπορούσαν να ερμηνεύσουν τις εικόνες των περιεχομένων που δημιουργήθηκαν από τους αισθητήρες, η μηχανική μάθηση μπορεί να συλλάβει τα δεδομένα πολύ πιο γρήγορα, να αναγνωρίσει μοτίβα στα δεδομένα και να παράγει μια εκτίμηση πιθανότητας για τον τύπο του περιεχομένου. (Thampi κ.ά., 2014)

- Αέρας- Έξυπνος βοηθός πιλότου

Ο έξυπνος βοηθός πιλότου, έχει σχεδιαστεί να παρέχει εμπειρογνωμοσύνη σε μεμονωμένους πιλότους μαχητικών. Αντί να αυτοματοποιεί τις κανονικές λειτουργίες του αεροσκάφους, η εφαρμογή παρέχει εξειδίκευση σε συγκεκριμένους τομείς ενσωματώνοντας την έννοια του πιλοτηρίου. Το σύστημα αποτελείται από τέσσερα κύρια διαδραστικά, εξειδικευμένα υποσυστήματα, όπως το σύστημα διαχείρισης εκτίμησης κατάστασης, σύστημα διαχείρισης τακτικού σχεδιασμού, προγραμματισμός αποστολών, σύστημα διαχείρισης και σύστημα διαχείρισης κατάστασης συστήματος. Ιδιαίτερη έμφαση δίνεται στη διεπαφή οδήγησης, η οποία περιλαμβάνει έλεγχο αναγνώρισης φωνής, τεχνολογία αυτοματοποιημένης απεικόνισης, κατανόηση φυσικής γλώσσας και σύνθεση ομιλίας.

- Θάλασσα- Διαχείριση ναυτικών επιχειρήσεων

Ο στόχος της διαχείρισης ναυτικών επιχειρήσεων είναι να χρησιμοποιήσει τεχνικές τεχνητής νοημοσύνης, ιδιαίτερα εξειδικευμένα συστήματα και κατανόηση φυσικής γλώσσας, με στόχο την ενίσχυση αυτοματοποιημένων εργαλείων λήψης αποφάσεων πολύπλοκων συστημάτων. Οι εφαρμογές επιχειρησιακών λειτουργιών διαχείρισης περιλαμβάνουν απαιτήσεις δυναμικού, αξιολογήσεις ικανότητας, προσομοιώσεις παιγνίων και στρατηγικές αξιολογήσεις. (Long & Dhillon, 2020)

Άλλες εφαρμογές που σχετίζονται με το υδάτινο περιβάλλον αφορούν αποστολές συγκεκριμένου στρατιωτικού, επιστημονικού ή βιομηχανικού ενδιαφέροντος όπως είναι ο εντοπισμός νάρκης (McCarthy, 2000 όπ. ανάφ. στο (Howell, 2004), η τοποθέτηση καλωδίων τηλεπικοινωνιών (Asakawa, 1996) ή ο εντοπισμός υποβρυχίων (Gorman, 1988). Η ανάγκη μείωσης του κόστους μέσω της ανάπτυξη αυτόνομων συστημάτων, για την εκτέλεση μακροπρόθεσμης συλλογής και επεξεργασίας δεδομένων με ελάχιστη ανθρώπινη παρέμβαση (Πόρτο, 2000), η μεγαλύτερη ακρίβεια η οποία μπορεί να συμπληρώσει ανθρώπινες εκτιμήσεις και προβλέψεις και ταυτόχρονα να επιταχύνει το χρόνο επεξεργασίας και λήψης αποφάσεων, αποτελούν καθοριστικούς παράγοντες, επιτρέποντας στην ηγεσία να κατανοεί και να αναλύει καταστάσεις πολύ πιο γρήγορα από ό, τι πριν. (Masuhr, 2019).

2.4 Αλγόριθμοι μηχανικής μάθησης

Στην ενότητα αυτή, παρουσιάζονται οι αλγόριθμοι μηχανικής μάθησης που χρησιμοποιήθηκαν στην παρούσα εργασία. Πρόκειται για αλγόριθμους οι οποίοι συγκαταλέγονται στην κατηγορία της εποπτευόμενης μάθησης (supervised learning) και η φύση του ζητήματος στο οποίο εφαρμόζονται, αφορά στο κομμάτι της ταξινόμησης.

Υπάρχουν δύο κύριες κατηγορίες προβλημάτων εποπτευόμενης μάθησης, η ταξινόμηση (classification) και η παλινδρόμηση (regression). Στην ταξινόμηση, ο


στόχος είναι να προβλεφθεί μια ετικέτα τάξης (class label), η οποία είναι μια επιλογή από ένα προκαθορισμένο κατάλογο όλων των πιθανών δυνατοτήτων. Η ταξινόμηση διαχωρίζεται ορισμένες φορές σε δυαδική (binomial) ταξινόμηση, που είναι η ειδική περίπτωση διάκρισης μεταξύ ακριβώς δύο κατηγοριών και ταξινόμηση πολλαπλών κλάσεων (multiclass), που είναι ταξινόμηση μεταξύ περισσότερων από δύο κατηγοριών. Η δυαδική ταξινόμηση μπορεί να εκφραστεί ως προσπάθεια απάντησης σε ερώτηση ναι / όχι.(Alzubi κ.ά., 2018; Muller & Guido, 2016)

- **Logistic Regression**

Αυτό το είδος αλγόριθμου ανήκει στη μεγαλύτερη κατηγορία αλγόριθμων ανάλυσης παλινδρόμησης (regression analysis). Η ανάλυση παλινδρόμησης είναι τεχνική μοντέλων πρόβλεψης, η οποία εξετάζει την σχέση μεταξύ μιας εξαρτημένης μεταβλητής-στόχος (dependent variable-target) και μιας ανεξάρτητης μεταβλητής-παράγοντας πρόβλεψης (independent variable-predictor). Είναι ένα σημαντικό εργαλείο για την ανάλυση και μοντελοποίηση δεδομένων. Σε αυτή τη μέθοδο, προσπαθούμε να προσαρμόσουμε τη γραμμή / καμπύλη για κάθε δεδομένο με σκοπό την ελαχιστοποίηση των διαφορών των αποστάσεων μεταξύ δεδομένων και καμπύλης ή γραμμής.(Alzubi κ.ά., 2018) Ο Πετρίδης (2015) χαρακτηριστικά αναφέρει:

« Η λογιστική παλινδρόμηση (Logistic regression) αποτελεί ένα μοντέλο ταξινόμησης των τιμών μιας μεταβλητής απόκρισης Y με βάση τη θεωρία των πιθανοτήτων. Στο μοντέλο αυτό, όπου η μεταβλητή Y συνήθως έχει δυαδικό χαρακτήρα (λαμβάνει δύο τιμές), εκτιμάται η πρόβλεψη της έκβασης αυτής από ένα πλήθος προβλεπτικών μεταβλητών που μπορεί να είναι ονομαστικές, τακτικές ή ποσοτικές. Η σημαντικότερη διαφοροποίηση μεταξύ λογιστικής και γραμμικής παλινδρόμησης βασίζεται στη φύση της επιλεγμένης μεταβλητής απόκρισης, η οποία στην μεν πρώτη μπορεί να είναι κατηγορική, (τακτική ή ονομαστική/0, στη δε δεύτερη αποκλειστικά ποσοτική.»


Στη στατιστική, η λογιστική παλινδρόμηση προβλέπει με βάση την πιθανότητα εμφάνισης ενός φαινομένου ταιριάζοντας τα δεδομένα πάνω στην εξίσωση της καμπύλης, όπως απεικονίζεται στο παρακάτω **Σχήμα 5**.



Σχήμα 5. Λογιστική καμπύλη (Πετρίδης, 2015)

- **K-Nearest Neighbors- KNN (Κοντινότεροι Γείτονες)**


Ο αλγόριθμος «Κοντινότεροι γείτονες» ανήκει στην ευρύτερη οικογένεια αλγορίθμων μάθησης βασισμένων στο παράδειγμα (instance based learning), ο οποίος αντί να εκτελεί ρητή γενίκευση, συγκρίνει τις νέες περιπτώσεις δεδομένων με περιπτώσεις που εμφανίζονται στην εκπαίδευση (training data) και έχουν αποθηκευτεί στη μνήμη. ('Instance-Based Learning', 2020) Ο αλγόριθμος K-NN αποτελεί τον απλούστερο αλγόριθμος μηχανικής μάθησης. Κατά την εφαρμογή του το μοντέλο αποθηκεύει στη μνήμη όλα τα δεδομένα εκπαίδευσης. Για την πρόβλεψη ενός νέου δεδομένου (data point), ο αλγόριθμος βρίσκει το κοντινότερο σημείο από τα δεδομένα εκπαίδευσης σε σύγκριση με το νέο εισαγόμενο παράδειγμα (data instance), δηλαδή τον κοντινότερο του γείτονα. Στην παρακάτω **Εικόνα 6** παρουσιάζεται ο τρόπος πρόβλεψης του αλγόριθμου σε ένα πρόβλημα ταξινόμησης. (Muller & Guido, 2016)



Εικόνα 6. Ταξινόμηση νέων δεδομένων μέσω του KNN αλγόριθμου (Muller & Guido, 2016)

- **Support Vector Machine (SVM,SVC, Linear SVC)**

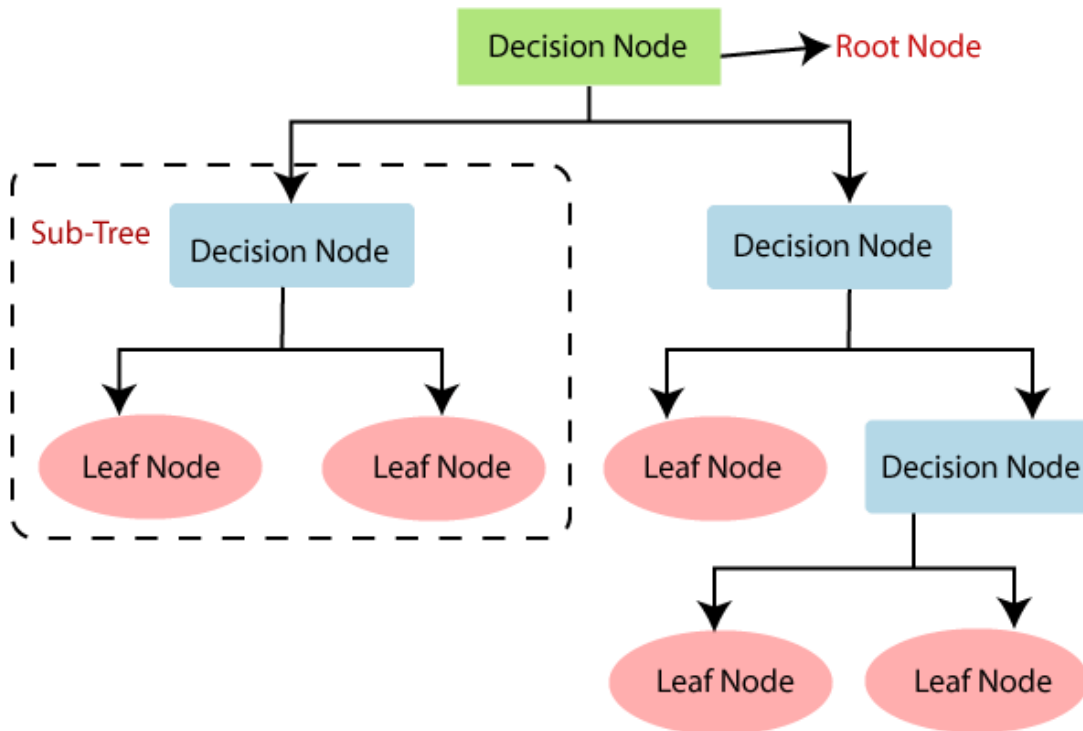
Οι SVM αλγόριθμοι μπορούν να χρησιμοποιηθούν είτε για προβλήματα παλινδρόμησης (regression), είτε για ταξινόμησης (classification) όπως δηλαδή αξιοποιούνται και στην παρούσα εργασία. Λειτουργούν με βάση τον υπολογισμό περιθωρίων (margin calculation). Σε αυτό τον αλγόριθμο, κάθε δεδομένο αναπαρίσταται ως ένα σημείο μέσα σε ένα πολλαπλών διαστάσεων χώρο (n-dimensional space, όπου n είναι ο αριθμός των χαρακτηριστικών-μεταβλητών που έχουμε στο σετ δεδομένων. Η αξία του κάθε επιμέρους χαρακτηριστικού ορίζεται από τη θέση του μέσα στο χώρο αυτό. Ο τρόπος ταξινόμησης των δεδομένων σε κλάσεις βασίζεται στη δημιουργία μιας γραμμής (hyper plane) και δουλεύει μεγιστοποιώντας τις αποστάσεις μεταξύ του κοντινότερου σημείου, δεδομένου για κάθε κλάση και της γραμμής (hyperplane). Αυτές οι αποστάσεις καλούνται περιθώρια. (Alzubi κ.ά., 2018) (βλ. *Εικόνα 7*)



Εικόνα 7. Λειτουργία ενός SVM αλγόριθμου (*Support Vector Machine (SVM) Algorithm, 2020*)

- **Decision Trees Classifiers** (DecisionTreeClassifier)

Οι αλγόριθμοι δέντρων αποφάσεων χρησιμοποιούν μια δομή διακλάδωσης για να απεικονίσουν το αποτέλεσμα μιας απόφασης. Τα δέντρα αποφάσεων μπορούν να χρησιμοποιηθούν για τη χαρτογράφηση των πιθανών αποτελεσμάτων μιας απόφασης. Κάθε κόμβος ενός δέντρου αποφάσεων αντιπροσωπεύει ένα πιθανό αποτέλεσμα. Τα ποσοστά εκχωρούνται σε κόμβους (nodes) με βάση την πιθανότητα εμφάνισης του αποτελέσματος. Στο παρακάτω **Σχήμα 6** παρουσιάζονται τα χαρακτηριστικά ενός δέντρου αποφάσεων.



Σχήμα 6. Δέντρο αποφάσεων (*Machine Learning Decision Tree Classification Algorithm - Javatpoint, 2020*)

- **Ensemble methods** (ExtraTreesClassifier, AdaBoostClassifier, RandomForestClassifier, XGBoost classifier, GradientBoostingClassifier)

Τα σύνολα μεθόδων (Ensemble methods) συνδυάζουν πολλαπλά μοντέλα μηχανικής μάθησης για τη δημιουργία ισχυρότερων μοντέλων. Υπάρχουν πολλά μοντέλα στη βιβλιογραφία της μηχανικής μάθησης που ανήκουν σε αυτήν την κατηγορία. (Muller & Guido, 2016) Δύο μεγάλες κατηγορίες τέτοιων μεθόδων διακρίνονται σε:

- Μεθόδους που δίνουν έμφαση στο μέσο όρο (averaging methods)

Η βασική αρχή είναι να δημιουργηθούν αρκετοί ανεξάρτητοι αλγόριθμοι-εκτιμητές και στη συνέχεια να μετρήσουμε τις προβλέψεις τους. Ο κατά μέσο όρο συνδυασμένος εκτιμητής είναι συνήθως καλύτερος από οποιονδήποτε απλό εκτιμητή βάσης, επειδή η διακύμανση

του είναι μειωμένη. Χαρακτηριστικό παράδειγμα αυτής της κατηγορίας αποτελεί ο αλγόριθμος Random forest.

- Μέθοδοι ενίσχυσης (Boosting methods)

Αντίθετα, στις μεθόδους ενίσχυσης, οι βασικοί εκτιμητές-αλγόριθμοι κατασκευάζονται και χρησιμοποιούνται διαδοχικά, ο ένας μετά τον άλλον, διορθώνοντας ο τελευταίος κάθε φορά τον προηγούμενο με απώτερο σκοπό την μείωση του σφάλματος (bias) . Το κίνητρο είναι να συνδυαστούν αρκετά αδύναμα μοντέλα με στόχο την δημιουργία ενός ισχυρότερου συνόλου μοντέλων. Σε αυτή την κατηγορία ανήκουν οι αλγόριθμοι AdaBoostClassifier ,XGBoost classifier, GradientBoostingClassifier)

- **Naïve Bayes classifiers (GaussianNB)**

Η κατηγορία αυτή αλγόριθμων ταξινομούν με βάση το θεώρημα πιθανοτήτων του Bayes . Το θεώρημα αυτό υπολογίζει την δεσμευμένη πιθανότητα ενός γεγονότος (A) δεδομένου ενός προηγούμενου γεγονότος (B). Ο τύπος της δεσμευμένης πιθανότητας είναι ο ακόλουθος:

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)}$$

όπου

- A,B είναι τα γεγονότα-ενδεχόμενα
- P(A), P(B) είναι οι πιθανότητες των A, B και είναι ανεξάρτητες μεταξύ τους
- P(A|B) είναι η δεσμευμένη πιθανότητα του A δεδομένου του B να είναι αληθές.

- $P(B|A)$ είναι η δεσμευμένη πιθανότητα του B δεδομένου του A να είναι αληθές.(Alzubi κ.ά., 2018)

- **Gaussian Process Classifier**

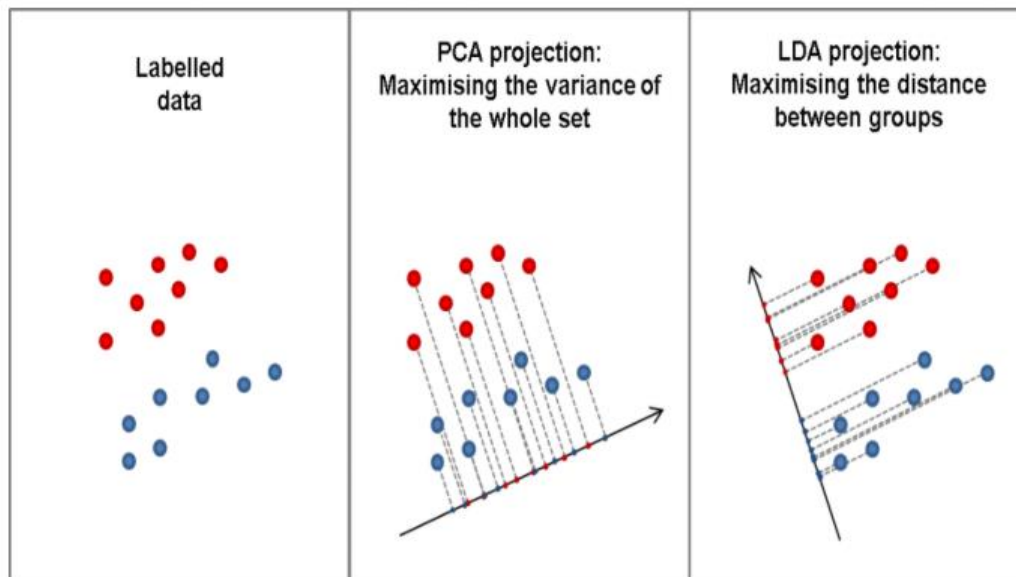
Ο Gaussian Process Classifier είναι ένας αλγόριθμος μηχανικής εκμάθησης ταξινόμησης. Οι γκαουσιανές μέθοδοι είναι μια γενίκευση της κατανομής πιθανοτήτων του Gauss και μπορούν να χρησιμοποιηθούν ως βάση για εξελιγμένους, μη παραμετρικούς αλγόριθμους μηχανικής μάθησης για ταξινόμηση και παλινδρόμηση. Είναι ένας τύπος μοντέλου πυρήνα (kernel), όπως οι SVM και σε αντίθεση με αυτούς, είναι σε θέση να προβλέψει σε ικανοποιητικό βαθμό τις πιθανότητες της κάθε κλάσης. Η σωστή επιλογή και η διαμόρφωση του πυρήνα θεωρείται η καρδιά της μεθόδου η οποία είναι ιδιαίτερα δύσκολη.

Οι συναρτήσεις κατανομής πιθανοτήτων του Gauss συνοψίζουν την κατανομή τυχαίων μεταβλητών, ενώ οι διαδικασίες συνοψίζουν τις ιδιότητες των συναρτήσεων, π.χ. τις παραμέτρους των συναρτήσεων. Ως εκ τούτου, οι γκαουσιανές διαδικασίες μπορούν να νοηθούν ως ένα επίπεδο αφαίρεσης πάνω στις γκαουσιανές συναρτήσεις.(Brownlee, 2020c)

- **Discriminant Analysis (Linear, Quadratic)**

Η Γραμμική Διακριτή Ανάλυση (Linear Discriminant Analysis-LDA) είναι ένας αλγόριθμος ταξινόμησης. Είναι μια γενίκευση της γραμμικής διάκρισης του Fisher, μια μέθοδο που χρησιμοποιείται σε στατιστικά και άλλα πεδία, για την εύρεση ενός γραμμικού συνδυασμού χαρακτηριστικών που χαρακτηρίζει ή διαχωρίζει δύο ή περισσότερες κατηγορίες αντικειμένων ή γεγονότων. (wikipedia, 2020) Λειτουργεί υπολογίζοντας συνοπτικά στατιστικά στοιχεία για κάθε χαρακτηριστικό εισόδου (input feature) ανά ετικέτα κλάσης (class label), όπως η μέση τιμή και η τυπική απόκλιση. Αυτά τα στατιστικά μέτρα θέσης αντιπροσωπεύουν το μοντέλο που δημιουργείται από τα δεδομένα εκπαίδευσης.

Στην πράξη, η γραμμική άλγεβρα χρησιμοποιείται για τον υπολογισμό των απαιτούμενων ποσοτήτων μέσω της αποσύνθεσης πινάκων (matrix decomposition). Οι προβλέψεις του αλγόριθμου υλοποιούνται προσεγγίζοντας την πιθανότητα ότι ένα νέο παράδειγμα θα ανήκει σε μια από τις κλάσεις, συνυπολογίζοντας τις τιμές που προκύπτουν από όλα τα χαρακτηριστικά εισόδου (input feature). Χαρακτηριστικό στοιχείο του LDA είναι ότι επιδιώκει στην μεγιστοποίηση του διαχωρισμού ανάμεσα σε δύο κατηγορίες κλάσεων, μειώνοντας τις διαστάσεις των δεδομένων (dimensionality reduction). Προϋπόθεση για την ορθή εφαρμογή του αλγόριθμου είναι ότι κάθε χαρακτηριστικό των δεδομένων θα πρέπει να ακολουθεί κανονική κατανομή και ίδια διακύμανση. Εάν τα δεδομένα δεν διαθέτουν αυτές τις προϋποθέσεις, υπάρχει απαίτηση προεπεξεργασίας (preprocessing) για τον μετασχηματισμό τους σε κανονική μορφή και standardization. (Brownlee, 2020b) Η παρακάτω εικόνα παρουσιάζει τον τρόπο που εργάζεται ο LDA αλγόριθμος σε σχέση με την Principal Component Analysis (PCA) η οποία έχει παρόμοια λειτουργία.



Εικόνα 8. Λειτουργία LDA (Pelliccia, 2018)

2.5 Ανασκόπηση της βιβλιογραφίας

Είναι χαρακτηριστικό ότι η εκτεταμένη χρήση εφαρμογών, σε βιομηχανικό αλλά και σε στρατιωτικό επίπεδο, βασιζόμενων σε ηχητικά σήματα (Sonar) έχει

απασχολήσει πληθώρα ερευνητών, οι οποίοι κινητοποιούνται ολοένα και περισσότερο για τη βελτίωση τους. Η βελτίωση αποσκοπεί κυρίως στην μεγαλύτερη αποδοτικότητα, στην αυτοματοποίηση καθώς και στη μείωση χρόνου επεξεργασίας των εφαρμογών. (Atallah, 2005) Η υποβρύχια ακουστική, η οποία είναι ο τομέας που αντιμετωπίζει φαινόμενα που σχετίζονται με τη δημιουργία, διάδοση και λήψη ήχου στο νερό, έχει εφαρμοστεί κυρίως στην έρευνα για τη χρήση συστημάτων ηχητικής πλοήγησης και εμβέλειας (SONAR) για υποβρύχια επικοινωνία, ανίχνευση στόχων, διερεύνηση θαλάσσιων πόρων, χαρτογράφηση περιβάλλοντος, μέτρηση και ανάλυση ηχητικών πηγών στο νερό. (Yang κ.ά., 2020) Επιπλέον, το κόστος της επανδρωμένης εξερεύνησης του υδάτινου περιβάλλοντος παραμένει υψηλό, επομένως οι περισσότερες αποστολές και όργανα εξερεύνησης επικεντρώνονται σε συγκεκριμένες στρατιωτικές, επιστημονικές ή βιομηχανικές εφαρμογές, όπως ο εντοπισμός ναρκών (McCarthy, 2000), η τοποθέτηση καλωδίων τηλεπικοινωνιών (Asakawa, 1996) ή η ανίχνευση υποβρυχίων (Gorman, 1988). Υπάρχει ανάγκη μείωσης του κόστους με την ανάπτυξη αυτόνομων συστημάτων για την εκτέλεση μακροπρόθεσμης συλλογής και επεξεργασίας δεδομένων με ελάχιστη ανθρώπινη παρέμβαση (Porto, 2000). Έχουν εξελιχθεί επίσης αρκετές παραλλαγές αυτόνομων οχημάτων, όπως η σειρά Hugin για εργασίες βαθέων υδάτων (Hagen, 2003) και Remus για παράκτια χρήση (Purcell, 2000). Άλλα οχήματα χρησιμοποιούνται όπως το Ocean Voyager (An, 1996) και Urashima (Tamura, 2000). Επιπλέον έρευνες έχουν πραγματοποιηθεί όσον αφορά την ταξινόμηση βαθυμετρικών δεδομένων (Atallah, 2005). Εφαρμογές που βασίζονται στην πλοήγηση έχοντας ως αναφορά το βυθό αξιοποιούν τοπογραφικά δεδομένα με σκοπό τη διόρθωση σφαλμάτων μετατόπισης ή αδρανειακής πλοήγησης (Kim κ.ά., 2018).

Επιπλέον, πληθώρα ερευνών επικεντρώνονται στην χρήση νευρωνικών δικτύων για την ανίχνευση και ταξινόμηση ηχητικών σημάτων sonar (Baran, 1991; (Baran & Coughlin, 1991); Casselman, 1991; Solinsky 1991; Cottle, 1991; Porto, 2000). Συγκεκριμένα, νευρωνικά δίκτυα αξιοποιούνται για τη δημιουργία βασικών μπλοκ για την ανίχνευση και την ταξινόμηση μιας ποικιλίας εισόδων αισθητήρα καθώς και για τον έλεγχο υδάτινων οχημάτων σε θαλάσσιες επιχειρήσεις. Τέτοιου είδους έρευνες μπορούν στη συνέχεια να χρησιμοποιηθούν για την εφαρμογή

πλήρους αυτόνομων συστημάτων ανίχνευσης και πλοήγησης, για χρήση στο θαλάσσιο περιβάλλον. (Howell, 2004) Άλλη έρευνα αφορά την ταξινόμηση των υποβρύχιων παθητικών σημάτων σόναρ τα οποία εκπέμπονται από πλοία που χρησιμοποιούν νευρωνικά δίκτυα.(Chin-Hsing κ.ά., 1998) Παρόμοια έρευνα για αυτόματη αναγνώριση στόχου που χρησιμοποιεί αυτόνομα υποβρύχια οχήματα και περιλαμβάνει εικόνες σόναρ πλευρικής σάρωσης, έχει σημαντικό ενδιαφέρον τόσο για στρατιωτικές όσο και για εμπορικές εφαρμογές. Με βάση αυτή, εκπαιδεύτηκαν νευρωνικά δίκτυα με στόχο τη μάθηση ,βασισμένα στην ένταση των pixel για χαρακτηριστικά των ανωμαλιών του πυθμένα σε εικόνες σόναρ.(Anitha & Malarkkan, 2018; Einsidler κ.ά., 2018; Pruijm κ.ά., 2019) Επίσης, ιδιαίτερα ενδιαφέρουσα είναι αναγνώριση γεωμετρικών αναφορών βάσει νευρικού δικτύου που εφαρμόζεται σε σήματα υπερήχων. Τα συστήματα ανίχνευσης υπερήχων χρησιμοποιούνται συχνά στη ρομποτική για σκοπούς πλοήγησης, όπως η αποφυγή εμποδίων και για μετρήσεις αποστάσεων. Ωστόσο, ένα πολύ επιθυμητό αλλά δύσκολο έργο είναι η ανίχνευση και αναγνώριση γεωμετρικών αναφορών. Η εφαρμογή νευρωνικών δικτύων στην αναγνώριση γεωμετρικών αναφορών μέσω υπερήχων έδωσε πολύ καλά αποτελέσματα. (De Almeida κ.ά., 2000)

Όσον αφορά τη βιβλιογραφία για την υποστήριξη επιχειρήσεων εκκαθάρισης Στρατιωτικού Ναρκοπεδίου (MIW) για ασφαλή διέλευση πλοίων, υπάρχει απαίτηση για ένα σύστημα να εκτελέσει ανίχνευση και ταξινόμηση αλλαγών σε πραγματικό χρόνο. Οι αναλυτές εκτελούν αλλαγές όσον αφορά τον εντοπισμό ενός αντικειμένου στο βυθό, συγκρίνοντας οπτικά τα ιστορικά δεδομένα που περιείχαν υψηλής ανάλυσης εικόνες σόναρ πλευρικής σάρωσης (SSI) με νεότερες που συλλέχθηκαν πρόσφατα σε μια προσπάθεια αναγνώρισης νέων τοποθετημένων αντικειμένων. Αυτή η διαδικασία πραγματοποιείται σε πραγματικό χρόνο με ταυτόχρονη εγγραφή νέων και ιστορικών εικόνων, χρησιμοποιώντας αυτοματοποιημένο αλγόριθμο εντοπισμού αλλαγών.(Gendron & Lohrenz, 2007) Επιπλέον σε άλλη έρευνα αντιμετωπίζεται το πρόβλημα της αυτόματης ανίχνευσης και ταξινόμησης των υποβρύχιων ναρκών σε εικόνες που δημιουργούνται από ένα Synthetic Aperture Sonar (SAS). (Denos κ.ά., 2017) Μια ακόμα έρευνα σε πραγματικό χρόνο ασχολείται με την επιβλεπόμενη ανίχνευση και ταξινόμηση στόχων με εκπαίδευση

σε δεδομένα επαυξημένης πραγματικότητας. Τέλος, η αυτόματη επεξεργασία ανοίγει επίσης τη δυνατότητα για τα AUV να προσαρμόζουν το σχέδιο έρευνας στον τύπο των αντικειμένων που παρατηρούνται σε πραγματικό χρόνο. (Coiras κ.ά., 2007)

Στον ανθυποβρυχιακό τομέα η λειτουργία σόναρ υψηλής ευκρίνειας, ευρυζωνικών, αντι-υποβρυχίων πολέμων στα παράκτια νερά είναι δύσκολη, καθώς η παρουσία θαλάσσιων βράχων, υποβρύχιων κορυφογραμμών και άλλων τοπογραφικών χαρακτηριστικών προκαλούν αυξημένους ρυθμούς ψευδών συναγεργμών και για αυτό το λόγο οι Hjelmervik κ.ά., (2020) πρότειναν μια μέθοδο για την πρόβλεψη του ρυθμού ψευδούς συναγεργμού (false alarm rate). Η ψευδής μείωση του ρυθμού συναγεργμού είναι ένα από τα πιο απαιτητικά ζητήματα στο συστήματα σόναρ. Σε άλλη έρευνα χρησιμοποιήθηκε η τεχνική ταξινόμησης για τον εντοπισμό πραγματικών στόχων από ψευδείς συναγεργμούς. (Ravakhah κ.ά., 2017)

Άλλες ακόμα έρευνες βασίζονται σε συστήματα sonar και χρησιμοποιούν μηχανική μάθηση για την ταξινόμηση και των εντοπισμό στόχων σε διάφορα βάθη, είτε αυτά αφορούν ηχητικά σήματα σύνθετων στόχων βυθού, είτε επιφάνειας σε κυματοδηγούς ρηχών νερών. (Guicking κ.ά., 1992);Giddings & Shirron, 2008) Ένα διαφορετικό είδος έρευνας αφορά την αναγνώριση στόχων sonar ενσωματωμένων σε ιζήματα. Στην έρευνα αυτή περιγράφονται τρία πειράματα στα οποία το σύστημα χρησιμοποιήθηκε για τη διάκριση ενός μικρού ανοξείδωτου χάλυβα, ενός κυλίνδρου ίδιου μεγέθους από κοίλο αλουμίνιο και αφρώδες αλουμίνιο και κοραλλιογενών βράχων ενσωματωμένων σε ρητίνη. Κάθε ένας από τους στόχους παρουσιάστηκε θαμμένος σε λάσπη σε βάθος αρκετών εκατοστών. Το σύστημα αποδείχθηκε εξαιρετικά αποτελεσματικό στην αναγνώριση αυτών των θαμμένων στόχων. (Roitblat κ.ά., 1995) Τέλος, η συνεχής αναγνώριση στόχων σόναρ χρησιμοποιώντας Νευρωνικά Δίκτυα (Venugopal κ.ά., 1991), για ανίχνευση στόχου σόναρ πλευρικής σάρωσης (Dzwonczyk κ.ά., 1991; Seo κ.ά., 2019) αφορούν έρευνες κοινού ενδιαφέροντος.

2.5.1 Ανασκόπηση βιβλιογραφιών με βάση τα δεδομένα της παρούσας διπλωματικής εργασίας

Οι έρευνες που βασίζονται στη μελέτη και ταξινόμηση των δεδομένων Sonar dataset (Mines vs Rocks) είναι πολλές και αυτό το γεγονός αναδεικνύει τη σημαντικότητα μελέτης του συγκεκριμένου είδους δεδομένων. Το σύνολο των δεδομένων αφορά στη συλλογή αναφοράς από τον Terry Sejnowski και συλλέχθηκε από το Ινστιτούτο Salk και το Πανεπιστήμιο της Καλιφόρνια στο San Deigo. Το σύνολο των δεδομένων αναπτύχθηκε σε συνεργασία με τον R. Paul Gorman του Allied-Signal Aerospace Technology Center. (UCI Machine Learning Repository, 2020) Εξίσου σημαντικά είναι και τα αποτελέσματα που απορρέουν από τις εν λόγω έρευνες πάνω στο συγκεκριμένο σετ δεδομένων.

Οι (Khishe & Safari, 2019) στην έρευνα τους, οι στόχοι σόναρ κατηγοριοποιήθηκαν χρησιμοποιώντας Multi Layer Perceptron νευρωνικά δίκτυα, αξιοποιώντας εξειδικευμένους αλγόριθμους «Dragonfly» για την ρύθμιση των βαρών (weights) των νευρώνων του δικτύου. Τα αποτελέσματα ανέδειξαν ποσοστό ορθότητας ταξινόμησης 92,14%. Σε παρόμοια έρευνα οι (Mohammad Reza Mosavi, Khishe, & Ghamgosar, 2016) αξιοποιώντας διαφορετικό αλγόριθμο εκπαίδευσης βαρών (optimization: gray wolf algorithm) βρήκαν αποδεκτά αποτελέσματα με βάση τη μέθοδο μέτρησης του μέσου σφάλματος τετραγώνων «MSE» (mean squared error): 0.049175, Variance: 0.0015, p-value: 1. Επιπλέον σε άλλη έρευνα που πραγματοποίησαν πάνω στα ίδια δεδομένα, ανέδειξαν ποσοστό ορθότητας ταξινόμησης 97,05% χρησιμοποιώντας τη μέθοδο Online Multi Kernel Classification (OMKC), η οποία χρησιμοποιεί μια ομάδα προκαθορισμένων πυρήνων, στην οποία οι επιλεγμένοι πυρήνες, μέσω ενός καθορισμένου αλγόριθμου συνδυάζονται με προκαθορισμένα βάρη τα οποία επίσης ενημερώνονται ταυτόχρονα χρησιμοποιώντας ένα διαφορετικό αλγόριθμο. Οι (Fong, Deb, Wong, κ.ά., 2014) στο άρθρο τους «Underwater Sonar Signals Recognition by Incremental Data Stream Mining with Conflict Analysis» περιγράφουν μια νέα στρατηγική προεπεξεργασίας που ονομάζεται iDSM-CA και σημαίνει σταδιακή ροή δεδομένων εξόρυξης με ανάλυση συγκρούσεων. Αυτή η μέθοδος εφαρμόστηκε σε συνδυασμό με διάφορους αλγόριθμους. Τα αποτελέσματα έδειξαν ποσοστό 85,18%. Οι Jade κ.ά., (2013)

χρησιμοποίησαν νευρωνικά δίκτυα και SVM αλγόριθμο για την ταξινόμηση των σημάτων. Τα νευρωνικά δίκτυα έδωσαν το καλύτερο δυνατό ποσοστό με 89% ακρίβεια στα δεδομένα εκπαίδευσης και 83% ακρίβεια στα δεδομένα δοκιμών. Ο (Novakovic, 2009) στο άρθρο του «Using Information Gain Attribute Evaluation to Classify Sonar Targets» παρουσίασε αποτελέσματα ακρίβειας 81% ενώ οι (Glette κ.ά., 2007) παρουσίασαν μέση ακρίβεια 91,4% σε ένα σύνολο δεδομένων φάσματος σόναρ. Επιπλέον, οι (Erkmen & Yildirim, 2006) χρησιμοποίησαν μια άλλη κατηγορία νευρωνικών δικτύων κωνικής λειτουργίας (CSFNN) τα οποία είναι ικανά να εξάγουν αποφάσεις με βάση την κατανομή των δεδομένων με ποσοστό επιτυχίας 92,3%. Τέλος, οι (R.P. Gorman & Sejnowski, 1988) στην έρευνα τους όσον αφορά την ταξινόμηση των δεδομένων μεταξύ ναρκών και βράχων (mines vs rocks) χρησιμοποιώντας νευρωνικά δίκτυα παρουσίασαν αποτελέσματα ακρίβειας 100% στα δεδομένα εκπαίδευσης ενώ 90,4% στα δεδομένα δοκιμών.

3. Μεθοδολογία

3.1 Το αντικείμενο της έρευνας

Η κύρια αφορμή για την εκπόνηση της παρούσας διπλωματικής βασίστηκε στη προσπάθεια βελτίωσης της ακρίβειας όσον αφορά την επεξεργασία, αναγνώριση και ταξινόμηση στόχων που προέρχονται από υπερηχητικά σήματα Sonar. Η εργασία εντάσσεται στην ευρύτερη περιοχή της Τεχνητής Νοημοσύνης και επί το πλείστον της Μηχανικής Μάθησης, ως εργαλείο βελτίωσης εφαρμογών που σχετίζονται με την ταξινόμηση ηχητικών σημάτων. Αξίζει να σημειωθεί ότι η παρούσα έρευνα βασίστηκε πάνω στα δεδομένα προηγούμενης έρευνας των Gorman & Sejnowski, (1988), οι οποίοι για πρώτη φορά μελέτησαν τη συγκεκριμένη σειρά δεδομένων, η οποία αφορούσε την ταξινόμηση επιστροφών Sonar από δύο διαφορετικά υποθαλάσσια αντικείμενα, ένα μεταλλικό με την ετικέτα “Mine” και ένα βράχο με την ετικέτα “Rock” χρησιμοποιώντας νευρωνικά δίκτυα.

Είναι χαρακτηριστικό ότι η αναγνώριση ηχητικών σημάτων σόναρ με αποτελεσματική ακρίβεια θεωρείται ένα δύσκολο πρόβλημα (Venugopal κ.ά., 1991) και η συμβολή της είναι ιδιαίτερα σημαντική κυρίως σε στρατιωτικές εφαρμογές. Σε

στρατιωτικό επίπεδο, ηχητικά σήματα χρησιμοποιούνται αντί οπτικών για πλοήγηση σε υποβρύχια καθώς και εντοπισμό εχθρικών υποβρυχίων σε κοντινή απόσταση. Συγκεκριμένα, η ταξινόμηση στην εξόρυξη δεδομένων είναι χρήσιμη στην αναγνώριση σημάτων σόναρ διακρίνοντας τον τύπο της επιφάνειας από την οποία αναπηδούν. Έτσι λοιπόν, η αξιοποίηση ενός σωστού μοντέλου πρόβλεψης από οποιοδήποτε μαχητικό σκάφος ή αεροπλάνο μπορεί να κερδίσει το έδαφος σε μια μάχη, εάν έχει την ικανότητα να εντοπίσει τον εχθρικό στόλο του από μακρινή απόσταση και με μεγαλύτερη ακρίβεια ανίχνευσης.

Ένας σημαντικός παράγοντας ο οποίος επηρεάζει την ακρίβεια αναγνώρισης είναι ο θόρυβος του υποβρυχίου περιβάλλοντος. Ο θόρυβος προκαλεί σύγχυση στην κατασκευή μοντέλων ταξινόμησης. Η παρουσία δεδομένων θορύβου στο σύνολο των δεδομένων εκπαίδευσης δίνουν αντιφατικές πληροφορίες, οι οποίες δεν συμφωνούν στη πλειονότητα των δεδομένων. Αυτή η διαφωνία οδηγεί σε εσφαλμένους κανόνες πρόβλεψης στα μοντέλα ταξινόμησης και διαταράσσει την ομοιογένεια τους ή τα στατιστικά πρότυπα, διαστρεβλώνοντας τα πρότυπα εκπαίδευσης. Άλλοι ερευνητές αναφέρονται στον θόρυβο ως ακραία σημεία εσφαλμένων κατηγοριών σφαλμάτων, που είναι όλοι οι τύποι δεδομένων των οποίων η αφαίρεση τους θα βελτιώσει την ακρίβεια σε ένα μοντέλο ταξινόμησης (outliers). Αν και αυτό το ερευνητικό θέμα μελετήθηκε για δύο δεκαετίες, οι τεχνικές που είχαν προηγουμένως προταθεί για την απομάκρυνση αυτού του θορύβου απαιτούσαν εργασίες προεπεξεργασίας των δεδομένων σε παρτίδες για το πλήρες σύνολο των δεδομένων, διαδικασία η οποία απαιτούσε πολύ χρόνο. Επίσης ο χρόνος ενημέρωσης (update time) μπορεί να γίνει ολόένα και μεγαλύτερος όσο αυξάνεται το σύνολο δεδομένων και συσσωρεύονται νέα δεδομένα. Δεδομένου ότι οι ροές δεδομένων σήματος σόναρ μπορούν δυνητικά να φτάσουν στο άπειρο, είναι σημαντικό να διατηρηθεί ο χρόνος επεξεργασίας δεδομένων σε όσο το δυνατόν μικρότερη κλίμακα για την ανίχνευση και τον εντοπισμό σε **πραγματικό χρόνο**. (Fong, Deb, & Thampi, 2014)

Επιπλέον, τα διαφορετικά υποβρύχια περιβάλλοντα και τα κινούμενα μοτίβα στόχων κάνουν την ανίχνευση σε πραγματικό χρόνο και τη ταξινόμηση να είναι δύσκολη, επισημαίνοντας την ανάγκη για αποτελεσματική ανίχνευση και ταξινόμηση αλγόριθμων σε

ένα τέτοιο περιβάλλον. Η σημαντικότητα της παρούσας έρευνας, η οποία εστιάζει στην μελέτη σημάτων που διαδίδονται μέσω του νερού και αφορούν τον εντοπισμό και την αναγνώριση ταυτότητας στόχων, βασίζεται στην εκπαίδευση διάφορων αλγορίθμων μηχανικής μάθησης καθώς και νευρωνικών δικτύων με απώτερο σκοπό την βελτιστοποίηση των αποτελεσμάτων σε ένα συγκεκριμένο σετ δεδομένων. (ταξινόμηση σημάτων από μεταλλική επιφάνεια- βράχο). Οι προκλήσεις που αναδύονται και χρήζουν μελέτης από τέτοιου είδους περιβάλλοντα είναι οι εξής (Seo κ.ά., 2019):

- Σύνθετο υποβρύχιο περιβάλλον: Η υποβρύχια ανίχνευση στόχου είναι μια πολύπλοκη ταξινόμηση μοτίβων, ένα πρόβλημα που περιλαμβάνει χρονικά μεταβαλλόμενα και μικτά περιβάλλοντα.
- Άγνωστος προσανατολισμός στόχου: Σε κανονικές συνθήκες, ο προσανατολισμός ενός στόχου είναι άγνωστος. Η ισχύς του στόχου εξαρτάται από την πλευρά πρόσπτωσης η οποία οδηγεί σε μεταβλητή αναλογία σήματος προς θόρυβο (SNR) και προκαλεί απώλεια πληροφορίας χαρακτηριστικών (loss of feature information)
- Συνεχής παρακολούθηση στόχων: Η συνεχής ταξινόμηση και παρακολούθηση αδύναμων ηχητικών στόχων είναι επιθυμητή, διότι ένας τέτοιος στόχος μπορεί να είναι πιθανή απειλή η οποία μπορεί να αναλάβει δράση έπειτα όταν αντιληφθεί ότι έχει εντοπιστεί.
- Λιγότερες πληροφορίες χαρακτηριστικών: Το ενεργό σόναρ για ανίχνευση στόχου μεγάλης εμβέλειας έχει δεδομένα χαμηλής ανάλυσης, έτσι ένας αλγόριθμος εξαγωγής διανύσματος χαρακτηριστικών είναι απαραίτητος (feature extraction algorithm)
- Μεγάλο διάστημα ring-to-ring: Για την ανίχνευση στόχων μεγάλου εύρους χρησιμοποιείται ένα μεγάλο διάστημα επανάληψης παλμών (PRI). Αυτό σημαίνει ότι μια σχετικά μικρή ποσότητα δεδομένων αποκτάται με την πάροδο του χρόνου.
- Έλλειψη δεδομένων σε πολλές περιπτώσεις: Είναι δύσκολο να αποκτηθούν επαρκή και αντιπροσωπευτικά δεδομένα από ένα θαλάσσιο περιβάλλον.

Τέλος, λαμβάνοντας υπόψη όλες τις παραπάνω ανάγκες, προνόμια και απαιτήσεις ,αντιλαμβάνεται κανείς το ενδιαφέρον για υποστήριξη και ενίσχυση του συγκεκριμένου ερευνητικού πεδίου. Η ανάγκη για επεξεργασία μεγάλου όγκου δεδομένων στο λιγότερο δυνατό χρόνο ,καλύτερες προβλέψεις σε σχέση με τον άνθρωπο, αποδοτικότερη λήψη αποφάσεων και αμεσότητα των ενεργειών σε ένα πολύπλοκο, συνεχώς μεταβαλλόμενο στρατιωτικό και υδάτινο περιβάλλον αποτελούν καταλυτικούς παράγοντες αυτού του όρου που καλείται ανταγωνιστικό πλεονέκτημα.(Alexandridis κ.ά., 1984; Finlay κ.ά., 2019; Fossaceca & Young, 2018; Long & Dhillon, 2020; Masuhr, 2019; Seo κ.ά., 2019; Waltzman κ.ά., 2020)

Παρόλα αυτά, ο εμπορικός διάλογος τεχνικών Τεχνητής Νοημοσύνης και Μηχανικής Μάθησης δεν έχει βρεθεί ακόμη σε στρατιωτικές εφαρμογές. Έχουν εντοπιστεί ορισμένα κενά σχετικά με την ευρεία εφαρμογή εμπορικών αλγορίθμων Μηχανικής Μάθησης και τις απαιτήσεις που διέπουν το στρατιωτικό επιχειρησιακό πεδίο. Τα παραπάνω κενά αποδίδονται στην έλλειψη τεράστιων παραδειγμάτων δεδομένων στρατιωτικού ενδιαφέροντος, χαρακτηρισμένων με ετικέτες (labeled data) τα οποία είναι σπανίως διαθέσιμα είτε λόγω ότι αποτελούν διαβαθμισμένο υλικό, είτε συχνά δεν επισημαίνονται με ετικέτες και, ως εκ τούτου, δεν είναι κατάλληλα για εκπαίδευση αλγορίθμων εποπτευόμενης μάθησης. Φαίνεται ότι η εξάρτηση της εποπτευόμενης μάθησης είναι δεδομένη εφόσον η τρέχουσα κατάσταση της μάθησης χωρίς επίβλεψη δεν είναι αρκετά ισχυρή (robust) για την αντιμετώπιση στρατιωτικών ζητημάτων. Για να λειτουργήσει η T.N. και η M.M , απαιτείται έρευνα για την ανάπτυξη νέων ημι-εποπτευόμενων και μη εποπτευόμενων αλγορίθμων μάθησης που να είναι λιγότερο ευαίσθητοι στο θόρυβο και οι οποίοι μπορούν να γενικεύσουν αποτελεσματικά και με ακρίβεια χρησιμοποιώντας αραιά σύνολα δεδομένων (sparse data) με ετικέτα είτε εντελώς χωρίς σήμανση. Μια επιπλέον διαπίστωση είναι ότι οι ευφυείς πράκτορες (ρομπότ) δυσκολεύονται να μάθουν από έναν ανθρώπινο χειριστή είτε μέσω παραδείγματος είτε μέσω άμεσης ανατροφοδότησης. Η δημιουργία πραγματικών αυτόνομων δυνατοτήτων σε ρομπότ παραμένει ένα δύσκολο πρόβλημα και αποτελεί έναν ενεργό τομέα έρευνας. Αναφέρεται ότι συχνά, οι αλγόριθμοι μπορούν να χρησιμοποιηθούν για τη λήψη αποφάσεων ή την ταξινόμηση μιας κατάστασης, αλλά δεν είναι σε θέση να εξηγήσουν τι συγκεκριμένα χαρακτηριστικά οδήγησαν τον αλγόριθμο στη λήψη αυτής της απόφασης. Αυτή η ικανότητα «εξήγησης» λείπει στις περισσότερες μεθόδους M.M καθώς και στη βαθιά μάθηση (deep learning). (Fossaceca & Young, 2018)

3.2 Ερευνητικά ερωτήματα

Για την οργάνωση και διατύπωση των ερευνητικών ερωτημάτων λήφθηκαν σοβαρά υπόψη τα ευρήματα προϋπαρχόντων ερευνών, τα οποία αποτελέσαν τη βάση για περαιτέρω διερεύνηση της χρήσης της Μηχανικής Μάθησης σε εφαρμογές ταξινόμησης ηχητικών σημάτων και εντοπισμού στόχων με σκοπό τη μελέτη για τη βελτίωση των προβλέψεων από πλευράς αλγορίθμων και νευρωνικών δικτύων. Τα νέα ερευνητικά ερωτήματα που προέκυψαν έχουν ως στόχο την επέκταση των αποτελεσμάτων είτε σε ζητήματα τα οποία δεν έχουν μελετηθεί εκτενώς ως τώρα, είτε στην εξαγωγή νέων συμπερασμάτων και ανάλυση αυτών καθώς και τη διατύπωση υποθέσεων, ελλείψεων και προβληματισμών που χρήζουν περαιτέρω μελέτης, με κεντρικό σκοπό την αναθεώρηση, ανάδειξη, συγκρότηση και προαγωγή περισσότερων στοιχείων στο πεδίο μελέτης της Μηχανικής Μάθησης και της επεξεργασίας σημάτων (signal processing).

Σύμφωνα με τους Gorman & Senjnowski (1988) η ανάδειξη των ευρημάτων της έρευνας τους καθίσταται περιορισμένη, με τη χρήση κυρίως νευρωνικών δικτύων και ορισμένων αλγορίθμων Μηχανικής Μάθησης για την ταξινόμηση των ηχητικών σημάτων Sonar, κάνοντας σύγκριση αποτελεσμάτων με έμπειρους χειριστές ακουστικών σημάτων. Στην παρούσα έρευνα αξιοποιείται μια ευρεία ατζέντα νέων αλλά και παλαιότερων αλγορίθμων M.M πάνω στα ίδια δεδομένα καθώς και διερευνάται εκ νέου, ποια δομή νευρωνικού δικτύου συμπεριφέρεται καλύτερα στις προβλέψεις σχετικά με την ταξινόμηση στόχων μεταλλικής επιφάνειας και βράχων. Επιπλέον μελετώνται τεχνικές προεπεξεργασίας και τέλος τρόποι βελτίωσης πρόβλεψης αλγορίθμων με σκοπό τον εντοπισμό κυρίως μεταλλικών επιφανειών.

Συνοψίζοντας, η παρούσα μελέτη στρέφει το ενδιαφέρον της στα εξής παρακάτω ερευνητικά ερωτήματα:

Ερευνητικά ερωτήματα

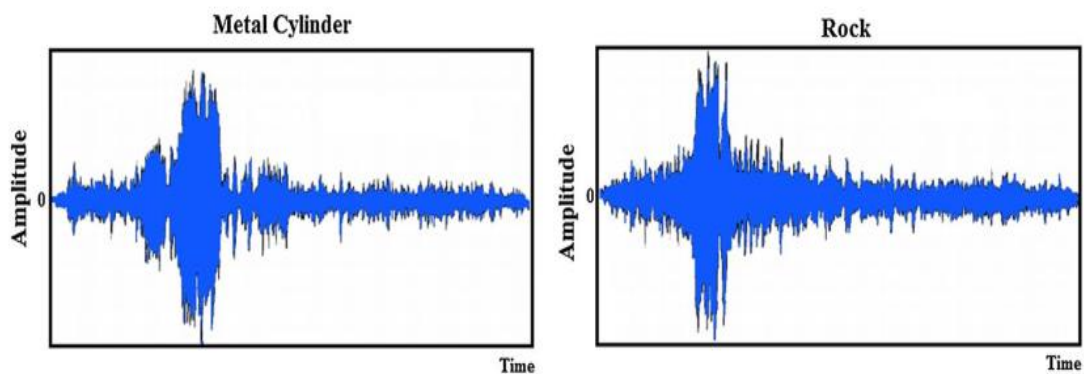
1. Ποιός αλγόριθμος πέτυχε την καλύτερη απόδοση στην ταξινόμηση και αναγνώριση στόχων με βάση τα προς μελέτη δεδομένα;
2. Ποιες τεχνικές προεπεξεργασίας (preprocessing) συμβάλουν στην επιδίωξη αυτή;
3. Πώς μπορεί να βελτιωθεί ο παραπάνω αλγόριθμος ώστε να προβλέπει τις μεταλλικές επιφάνειες έναντι των βράχων;
4. Πώς μπορεί να βελτιωθεί η ταξινόμηση και η αναγνώριση των στόχων με τη χρήση νευρωνικών δικτύων στα προς μελέτη δεδομένα;

3.3 Σχεδιασμός της έρευνας

Ο σχεδιασμός της έρευνας βασίστηκε στις κεντρικές υποθέσεις περί εφαρμογής αλγορίθμων Μηχανικής μάθησης και αξιοποίησης της αρχιτεκτονικής νευρωνικών δικτύων σε ένα πρόβλημα ταξινόμησης ηχητικών σημάτων από επιστροφές Sonar με σημαντικές πρακτικές εφαρμογές στο θαλάσσιο αλλά και υποθαλάσσιο χώρο. Λόγω των πολύπλοκων φυσικών ιδιοτήτων των στόχων sonar, η ταξινόμηση του πραγματικού στόχου και των ψευδών συναγερμών έχει γίνει μια σημαντική και ευρέως χρησιμοποιούμενη περιοχή για ερευνητές που εργάζονται σε αυτόν τον τομέα. Τα ανεπιθύμητα σήματα στο υποβρύχιο περιβάλλον έχουν διάφορες πηγές, όπως θόρυβο, αντήχηση και ακαταστασία. Δεδομένου ότι η αντήχηση έχει τον ίδιο τομέα και είναι ομοιογενής με το αρχικό σήμα, είναι εύκολο να διακριθεί από τον πραγματικό στόχο. Όταν ο βυθός αλλάζει πολύ και όταν υπάρχουν διαφορετικά είδη στρωμάτων βυθού, η ηχώ που επιστρέφει από τον βυθό θα έχει ιδιότητες στόχου, με τρόπο που ακόμη και η πιθανότητα πυκνότητας λειτουργίας του πραγματικού στόχου και του βυθού είναι παρόμοια. Αυτός ο ψευδής συναγερμός ονομάζεται ακαταστασία (clutter). Είναι χαρακτηριστικό ότι η χρήση αλγορίθμων και νευρωνικών δικτύων αποδεικνύει την ικανότητά τους να μαθαίνουν να ταξινομούν τέτοια πολύπλοκα συνεχούς αξίας σήματα (continuous-valued) για διάκριση του στόχου. (Khishe & Safari, 2019)

3.3.1 Ερευνητικά δεδομένα

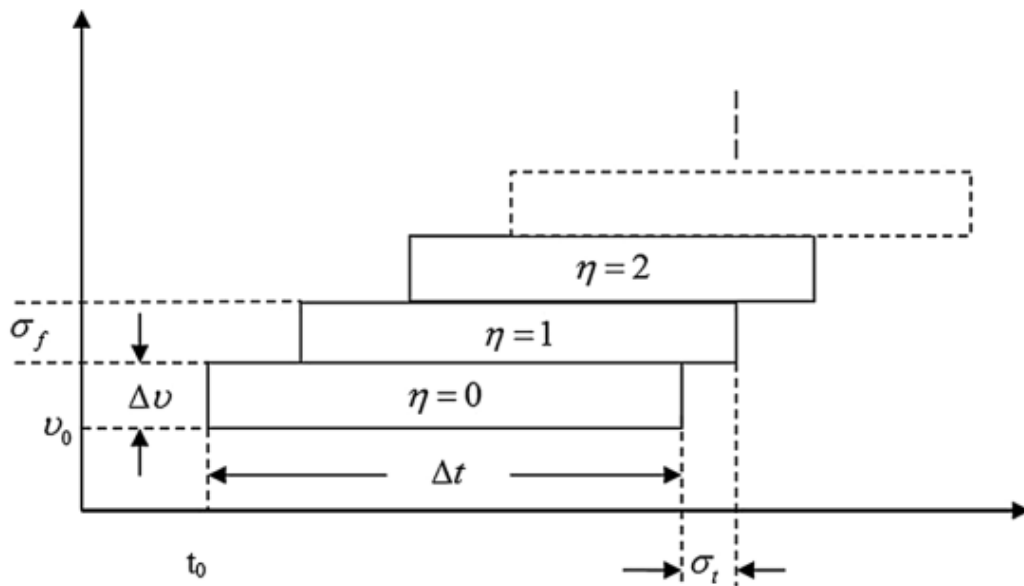
Τα δεδομένα sonar που χρησιμοποιήθηκαν ως δείγμα στην παρούσα μελέτη αφορούσαν επιστροφές σόναρ που συλλέχθηκαν από ένα μεταλλικό κύλινδρο και ένα κυλινδρικό σχήμα βράχου, τοποθετημένα σε θαλάσσιο αμμώδη βυθό. Και οι δύο στόχοι είχαν μήκος περίπου 5 πόδια και ο παλμός πρόσκρουσης ήταν ένα ευρείας ζώνης, γραμμικής διαμόρφωσης συχνότητας (Frequency Modulation) ηχητικό σήμα (chirp ,ka = 55,6). Το μεταδιδόμενο σήμα σόναρ είναι ένα σήμα διαμόρφωσης συχνότητας, που αυξάνεται σε συχνότητα. Οι επιστροφές συλλέχθηκαν σε μια περίμετρο 10 μέτρων ,σε εύρος γωνίας 90 ° από τον κύλινδρο και σε εύρος γωνίας που εκτείνεται σε 180 ° από τον βράχο. Στην παρακάτω εικόνα παρουσιάζονται παραδείγματα επιστροφής ηχούς από μεταλλικό κύλινδρο και βράχο αντίστοιχα.



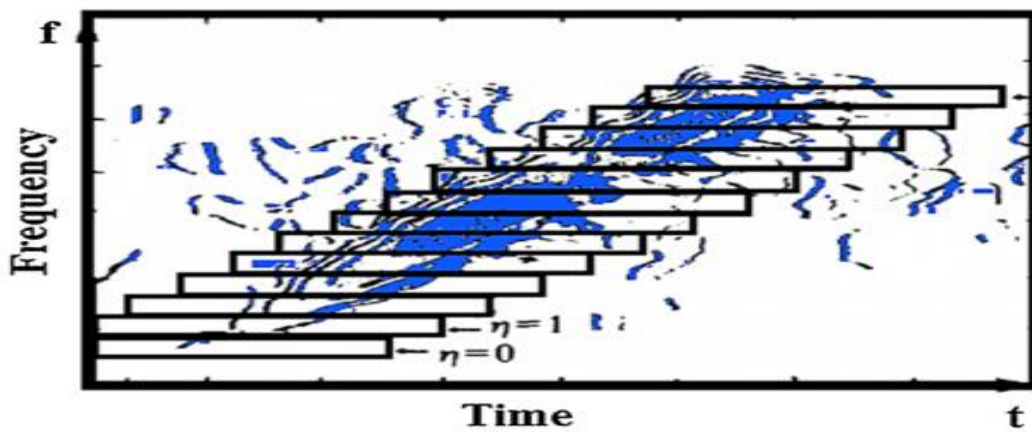
Εικόνα 9. Παραδείγματα επιστροφών σημάτων από μεταλλικό κύλινδρο και βράχο (Khishe & Safari, 2019)

Ένα σύνολο από 208 επιστροφές και συγκεκριμένα 111 επιστροφές από μεταλλικό κύλινδρο και 97 επιστροφές από βράχο επιλέχθηκαν με βάση την ένταση της κατοπτρικής επιστροφής (4.0-15.0 dB λόγος σήματος προς θόρυβο, signal-to-noise ratio) και διασφαλίζοντας ότι οι γωνίες επιστροφής της ήχους αντιπροσωπεύουν όλο το εύρος τιμών. Η επεξεργασμένη αναπαράσταση των δεδομένων επιλέχθηκε ως αποτέλεσμα πρότερων πειραμάτων από έμπειρους ειδικούς επεξεργασίας ακουστικών συχνοτήτων (Gorman & Sawatari, 1987). Όσον αφορά την επεξεργασία των ακατέργαστων δεδομένων, πρώτα εφαρμόστηκε μετασχηματισμός Fourier μικρού χρόνου (Short-time Fourier transform) για το φιλτράρισμα των σημάτων. Ο μετασχηματισμός Fourier μικρού χρόνου, είναι ένας

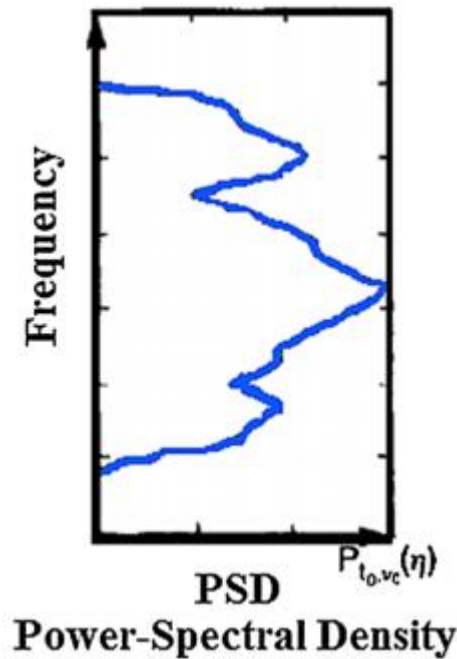
μετασχηματισμός που σχετίζεται με το Fourier, που χρησιμοποιείται για τον προσδιορισμό της ημιτονοειδούς συχνότητας και του περιεχομένου φάσης των τοπικών τμημάτων ενός σήματος καθώς αλλάζει με την πάροδο του χρόνου. Στην πράξη, η διαδικασία υπολογισμού STFT αποτελεί την διαίρεση ενός σήματος μεγαλύτερου χρόνου σε μικρότερα τμήματα ίσου μήκους, ενώ στη συνέχεια υπολογίζεται ο μετασχηματισμός Fourier ξεχωριστά σε κάθε μικρότερο τμήμα. Αυτή η διαδικασία αποκαλύπτει το φάσμα Fourier σε κάθε μικρότερο τμήμα. Στη συνέχεια υπάρχει η δυνατότητα σχεδίασης των μεταβαλλόμενων φασμάτων ως συνάρτηση του χρόνου, γνωστή ως φασματογράφημα. (Wikipedia, Short-time Fourier transform, 2020) Η προεπεξεργασία που χρησιμοποιείται για την απόκτηση της φασματικής ατζέντας υποδεικνύεται σχηματικά στο παρακάτω **Σχήμα 7**, όπου το σύνολο των δειγματικών διαστημάτων αντισταθμίζεται κατάλληλα ώστε να αντιστοιχεί χρονικά με το ηχητικό σήμα. Στο επόμενο **Σχήμα 8** παρουσιάζονται τα διαιρεμένα τμήματα δειγμάτων τα οποία τοποθετούνται πάνω από τη δισδιάστατη απεικόνιση του φασματογραφήματος του μετασχηματισμού Fourier μικρού χρόνου και στο **Σχήμα 9** φαίνεται ο φασματικός φάκελος (spectral envelope) που λαμβάνεται από την ενσωμάτωση όλων των επιμέρους δειγματικών διαστημάτων.



Σχήμα 7. Το σύνολο των δειγματικών κενών αντισταθμίζεται κατάλληλα ώστε να αντιστοιχεί χρονικά με το ηχητικό σήμα. (R.P. Gorman & Sejnowski, 1988)



Σχήμα 8. Εφαρμογή των διαστημάτων ίσου χρόνου στο διδιάστατο φασματογράφημα του μετασχηματισμού Fourier μικρού χρόνου. (Khishe & Safari, 2019)



Σχήμα 9. φασματικός φάκελος (spectral envelope) που λαμβάνεται από την ενσωμάτωση όλων των επιμέρους δειγματικών διαστημάτων. (Khishe & Safari, 2019)

Ο φασματικός φάκελος αποτελείται από 60 δείγματα που έχουν κανονικοποιηθεί στο εύρος 0-1 και αποτελούν το σύνολο των δεδομένων χωρισμένο σε 60 χαρακτηριστικά (features). Κάθε αριθμός αντιπροσωπεύει την ενέργεια σε μια συγκεκριμένη ζώνη συχνοτήτων, ενσωματωμένη για μια συγκεκριμένη χρονική περίοδο. Το διάγραμμα ολοκλήρωσης για υψηλότερες συχνότητες εμφανίζεται αργότερα, δεδομένου ότι αυτές οι συχνότητες μεταδίδονται αργότερα κατά τη διάρκεια του chirp. Η ετικέτα που σχετίζεται με κάθε εγγραφή περιέχει την ένδειξη "Rock" εάν το αντικείμενο είναι βράχος και "Mine" εάν είναι (μεταλλικός κύλινδρος). Οι αριθμοί στις ετικέτες είναι σε αυξανόμενη σειρά γωνίας εύρους επιστροφής, αλλά δεν κωδικοποιούν άμεσα τη γωνία.

3.3.2 Συλλογή και ανάλυση δεδομένων

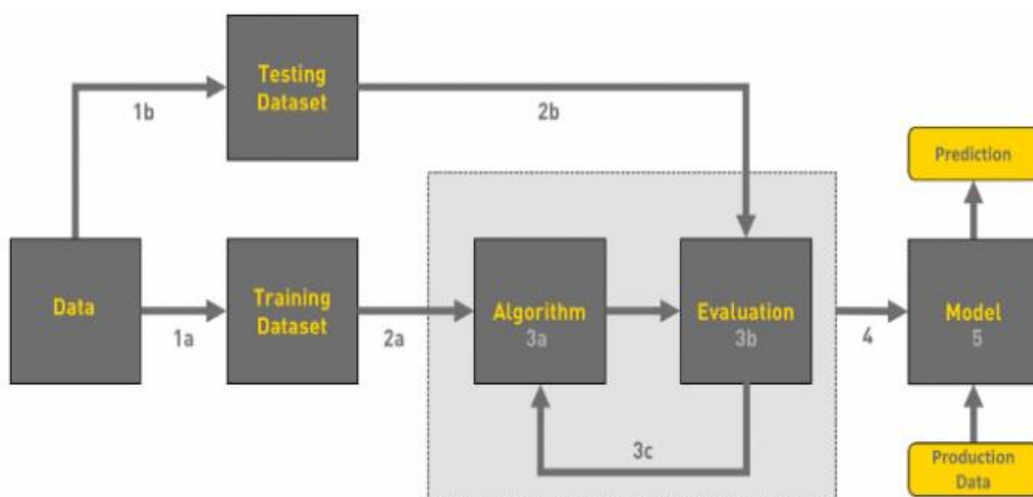
Στο παρόν κεφάλαιο παρουσιάζονται τα στάδια της ερευνητικής διαδικασίας ανάλυσης που ακολουθήθηκε και αφορά στην ταξινόμηση ηχητικών σημάτων sonar, με σκοπό την επιλογή του καταλληλότερου μοντέλου που ταιριάζει καλύτερα στα προς μελέτη δεδομένα και παρέχει το μεγαλύτερο ποσοστό πρόβλεψης. Επιπλέον, θα

παρουσιαστεί αναλυτικά η ανάπτυξη όλης της ροής εργασιών που απαιτήθηκε για την κατασκευή και την εκπαίδευση των αλγόριθμων μηχανικής μάθησης καθώς και της εκπαίδευσης νευρωνικών δικτύων αντιστοίχως στην παρούσα εργασία. Για την επεξεργασία των δεδομένων και την ανάπτυξη της ροής εργασιών αξιοποιήθηκε η γλώσσα προγραμματισμού Python καθώς και οι βασικές βιβλιοθήκες όπως NumPy, Pandas, Sci-kit Learn και Matplotlib.

Η ροή εργασιών διακρίθηκε στα παρακάτω κύρια στάδια:

1. Συλλογή των δεδομένων. (Gathering data)
2. Προετοιμασία και προεπεξεργασία του συνόλου των δεδομένων. (Dataset preparation and preprocessing)
3. Διαχωρισμός δεδομένων (Splitting dataset)
4. Διερεύνηση του μοντέλου που είναι κατάλληλο για τον τύπο δεδομένων. (Modelling)
5. Αξιολόγηση (Evaluation) και Δοκιμή (Testing)

Στο παρακάτω **Σχήμα 10** παρουσιάζεται μια γενική εικόνα της ροής των εργασιών ενός ζητήματος Μηχανικής Μάθησης.



Σχήμα 10. Ροή εργασιών Μηχανικής Μάθησης (Pant, 2019)

1. Συλλογή των δεδομένων. (Gathering data)

Η διαδικασία συλλογής δεδομένων έχει άμεση σχέση με τη μελέτη της φύσης του προβλήματος που χρήζει προς επίλυση. Τα δεδομένα δύναται να συλλεχθούν από διάφορες πηγές όπως αρχεία (files), βάσεις δεδομένων (databases), αισθητήρες (sensors) καθώς και άλλες. Χαρακτηριστικό των παραπάνω δεδομένων είναι ότι καθίστανται ανεπεξέργαστα (raw data) και δεν μπορούν να αξιοποιηθούν απ' ευθείας στην διαδικασία ανάλυσης. Αυτό οφείλεται στο γεγονός ότι τα δεδομένα αυτά πιθανόν να παρουσιάζουν ελλείψεις επιμέρους τιμών στα διάφορα υποπεδία τους (missing values), λάθος ή υπερβολικά μεγάλες τιμές που οφείλονται στον ανθρώπινο παράγοντα, ανοργάνωτα δεδομένα κειμένου (unorganized text data) και θόρυβο (noisy data). Για το λόγο αυτό απαιτείται το επόμενο στάδιο που είναι η προετοιμασία και προεπεξεργασία των δεδομένων.

Όσον αφορά την παρούσα εργασία τα ηχητικά δεδομένα sonar συλλέχθηκαν ήδη επεξεργασμένα από προηγούμενη έρευνα (Gorman and T. Sawatari, 1987) και παρουσιάζονται στη παρακάτω **Εικόνα 10** ως εξής

1	2	3	4	5	6	7	8	9	10	...	52	53	54	55	56	57	58	59	60	Class
0.0200	0.0371	0.0428	0.0207	0.0954	0.0986	0.1539	0.1601	0.3109	0.2111	...	0.0027	0.0065	0.0159	0.0072	0.0167	0.0180	0.0084	0.0090	0.0032	Rock
0.0453	0.0523	0.0843	0.0689	0.1183	0.2583	0.2156	0.3481	0.3337	0.2872	...	0.0084	0.0089	0.0048	0.0094	0.0191	0.0140	0.0049	0.0052	0.0044	Rock
0.0262	0.0582	0.1099	0.1083	0.0974	0.2280	0.2431	0.3771	0.5598	0.6194	...	0.0232	0.0166	0.0095	0.0180	0.0244	0.0316	0.0164	0.0095	0.0078	Rock
0.0100	0.0171	0.0623	0.0205	0.0205	0.0368	0.1098	0.1276	0.0598	0.1264	...	0.0121	0.0036	0.0150	0.0085	0.0073	0.0050	0.0044	0.0040	0.0117	Rock
0.0762	0.0666	0.0481	0.0394	0.0590	0.0649	0.1209	0.2467	0.3564	0.4459	...	0.0031	0.0054	0.0105	0.0110	0.0015	0.0072	0.0048	0.0107	0.0094	Rock
0.0286	0.0453	0.0277	0.0174	0.0384	0.0990	0.1201	0.1833	0.2105	0.3039	...	0.0045	0.0014	0.0038	0.0013	0.0089	0.0057	0.0027	0.0051	0.0062	Rock
0.0317	0.0956	0.1321	0.1408	0.1674	0.1710	0.0731	0.1401	0.2083	0.3513	...	0.0201	0.0248	0.0131	0.0070	0.0138	0.0092	0.0143	0.0036	0.0103	Rock
0.0519	0.0548	0.0842	0.0319	0.1158	0.0922	0.1027	0.0613	0.1465	0.2838	...	0.0081	0.0120	0.0045	0.0121	0.0097	0.0085	0.0047	0.0048	0.0053	Rock
0.0223	0.0375	0.0484	0.0475	0.0647	0.0591	0.0753	0.0098	0.0684	0.1487	...	0.0145	0.0128	0.0145	0.0058	0.0049	0.0065	0.0093	0.0059	0.0022	Rock
0.0164	0.0173	0.0347	0.0070	0.0187	0.0671	0.1056	0.0697	0.0962	0.0251	...	0.0090	0.0223	0.0179	0.0084	0.0068	0.0032	0.0035	0.0056	0.0040	Rock

Εικόνα 10. Οι 10 πρώτες σειρές δεδομένων συνοδευόμενες από τα χαρακτηριστικά (features) και την κλάση-στόχος

2. Προετοιμασία και προεπεξεργασία του συνόλου των δεδομένων.

Το στάδιο αυτό αποτελεί το πιο σημαντικό βήμα της ροής εργασιών που συμβάλει στη δημιουργία μοντέλων μηχανικής εκμάθησης μεγαλύτερης ακρίβειας. Για τους λόγους που προαναφέρθηκαν στο προηγούμενο στάδιο, τα ακατέργαστα δεδομένα, για να είναι λειτουργικά όσον αφορά ένα μοντέλο μηχανικής εκμάθησης, απαιτούν προετοιμασία και «καθάρισμα» (cleaning) ώστε να υπάρχει πρόσφορο έδαφος για ορθότερες προβλέψεις. Βασικό εργαλείο για τον εντοπισμό και τη διόρθωση των εσφαλμένων παραπάνω ζητημάτων που σχετίζονται με τις ελλείψεις των δεδομένων αποτελεί η γραφική αναπαράσταση των δεδομένων (data visualization). Είναι χαρακτηριστικό ότι ένας μεγάλος όγκος πληροφοριών που παρουσιάζονται σε γραφική μορφή είναι ευκολότερο να κατανοηθεί και να αναλυθεί. Η παραπάνω μέθοδος αποτελεί καλή πρακτική για μια συνολική αποτίμηση του βαθμού κατάστασης του συνόλου των δεδομένων καθώς και μιας ταχύτερης διαδικασίας προεπεξεργασίας τους. Με βάση την παραπάνω πρακτική, ιδιαίτερα στην διαδικασία της εποπτευόμενης μάθησης μπορούμε να διακρίνουμε εάν εφαρμόζεται η χρήση ετικέτας (labeling), δηλαδή η ετικέτα-στόχος την οποία πρόκειται να προβλέψει ο αλγόριθμος με βάση ορισμένα χαρακτηριστικά που απορρέουν από το σύνολο των δεδομένων. Επιπλέον, μας δίνεται η δυνατότητα να επιλέξουμε μέρος των δεδομένων από το συνολικό σετ (data selection), τα οποία είναι ικανά για την εισαγωγή τους στο αλγόριθμο και για την επίλυση του συγκεκριμένου προβλήματος. Σχετικά με το κομμάτι της προεπεξεργασίας, οι βελτιώσεις πάνω στα ακατέργαστα δεδομένα αφορούν στη μορφοποίηση τους (data formatting). Η σημασία της μορφοποίησης δεδομένων αυξάνεται όταν τα δεδομένα λαμβάνονται από διάφορες πηγές και από διαφορετικά άτομα. Εδώ, ο ειδικός ελέγχει εάν οι μεταβλητές που αντιπροσωπεύουν κάθε χαρακτηριστικό καταγράφονται με τον ίδιο τρόπο. Διαφορετικό κομμάτι της προεπεξεργασίας αφορά στο «καθάρισμα» των δεδομένων (data cleaning). Αυτό το σύνολο διαδικασιών επιτρέπει την εξάλειψη του θορύβου και τη διόρθωση ασυνεπειών στα δεδομένα. Σε αυτό το σημείο, τα ελλείποντα δεδομένα δύναται να συμπληρωθούν χρησιμοποιώντας τεχνικές καταλογισμού (imputation). Για παράδειγμα, αντικαθιστώντας τιμές που λείπουν με τη μέση τιμή των υπόλοιπων της κατηγορίας στην οποία υπάγονται. Επίσης, άλλη διαδικασία αφορά στον εντοπισμό και διαχείριση των ακραίων τιμών (outliers), δηλαδή παρατηρήσεων που αποκλίνουν σημαντικά από την υπόλοιπη κατανομή των

δεδομένων. Οι ακραίες τιμές συχνά επηρεάζουν την απόδοση πολλών αλγόριθμων για αυτό το λόγο είναι θεμιτό να αφαιρούνται ή να διορθώνονται, εάν αυτό είναι εφικτό. Επιπλέον, όταν αξιοποιούνται δεδομένα τα οποία περιέχουν ευαίσθητες πληροφορίες είναι απαραίτητο τα χαρακτηριστικά τους (features) να ανωνυμοποιούνται ή να αποκλείονται (data anonymization).

Τελευταίο μέρος του σταδίου αποτελεί ο μετασχηματισμός των δεδομένων (data transforming). Σε αυτήν την τελική φάση προεπεξεργασίας, τα δεδομένα μετατρέπονται ή ενοποιούνται σε μια μορφή κατάλληλη για εξόρυξη (δημιουργία αλγορίθμων για τη λήψη πληροφοριών από τα δεδομένα) ή τη μηχανική μάθηση. Τα δεδομένα μπορούν να μετασχηματιστούν μέσω κλιμάκωσης (scaling), αποσύνθεσης χαρακτηριστικών (decomposition) και συγκέντρωσης χαρακτηριστικών (aggregation). Αυτή η φάση ονομάζεται επίσης μηχανική χαρακτηριστικών (feature engineering).

Στην παρούσα μελέτη, η εξερεύνηση για τη φύση των δεδομένων υλοποιήθηκε με παρουσιάσεις πινάκων και διαφορετικών ειδών γραφικών αναπαραστάσεων. Στην παρακάτω **Εικόνα 11** παρουσιάζεται η κατάσταση των τιμών σε κάθε χαρακτηριστικό σχετικά με τον αριθμό και την απουσία ή μη του συνόλου των δεδομένων. Επιπλέον παρατηρείται ο τύπος των δεδομένων σε κάθε χαρακτηριστικό (feature), ο οποίος είναι float δηλαδή αριθμητικός με δεκαδικά ψηφία, ενώ το πεδίο κλάση (Class) είναι τύπος αντικειμένου (object).

```

<class 'pandas.core.frame.DataFrame'> 27 28      208 non-null      float64
RangeIndex: 208 entries, 0 to 207     28 29      208 non-null      float64
Data columns (total 61 columns):       29 30      208 non-null      float64
#   Column  Non-Null Count  Dtype  30 31      208 non-null      float64
---  ---      -
0   1        208 non-null    float64  31 32      208 non-null      float64
1   2        208 non-null    float64  32 33      208 non-null      float64
2   3        208 non-null    float64  33 34      208 non-null      float64
3   4        208 non-null    float64  34 35      208 non-null      float64
4   5        208 non-null    float64  35 36      208 non-null      float64
5   6        208 non-null    float64  36 37      208 non-null      float64
6   7        208 non-null    float64  37 38      208 non-null      float64
7   8        208 non-null    float64  38 39      208 non-null      float64
8   9        208 non-null    float64  39 40      208 non-null      float64
9  10        208 non-null    float64  40 41      208 non-null      float64
10 11        208 non-null    float64  41 42      208 non-null      float64
11 12        208 non-null    float64  42 43      208 non-null      float64
12 13        208 non-null    float64  43 44      208 non-null      float64
13 14        208 non-null    float64  44 45      208 non-null      float64
14 15        208 non-null    float64  45 46      208 non-null      float64
15 16        208 non-null    float64  46 47      208 non-null      float64
16 17        208 non-null    float64  47 48      208 non-null      float64
17 18        208 non-null    float64  48 49      208 non-null      float64
18 19        208 non-null    float64  49 50      208 non-null      float64
19 20        208 non-null    float64  50 51      208 non-null      float64
20 21        208 non-null    float64  51 52      208 non-null      float64
21 22        208 non-null    float64  52 53      208 non-null      float64
22 23        208 non-null    float64  53 54      208 non-null      float64
23 24        208 non-null    float64  54 55      208 non-null      float64
24 25        208 non-null    float64  55 56      208 non-null      float64
25 26        208 non-null    float64  56 57      208 non-null      float64
26 27        208 non-null    float64  57 58      208 non-null      float64
                                     58 59      208 non-null      float64
                                     59 60      208 non-null      float64
                                     60 Class   208 non-null      object
dtypes: float64(60), object(1)
memory usage: 99.2+ KB

```

Εικόνα 11. Πίνακας εξέτασης ελλειπόντων τιμών (missing values)

	1	2	3	4	5	6	7	8	9	10	...
count	208.000000	208.000000	208.000000	208.000000	208.000000	208.000000	208.000000	208.000000	208.000000	208.000000	...
mean	0.029164	0.038437	0.043832	0.053892	0.075202	0.104570	0.121747	0.134799	0.178003	0.208259	...
std	0.022991	0.032960	0.038428	0.046528	0.055552	0.059105	0.061788	0.085152	0.118387	0.134416	...
min	0.001500	0.000600	0.001500	0.005800	0.006700	0.010200	0.003300	0.005500	0.007500	0.011300	...
25%	0.013350	0.016450	0.018950	0.024375	0.038050	0.067025	0.080900	0.080425	0.097025	0.111275	...
50%	0.022800	0.030800	0.034300	0.044050	0.062500	0.092150	0.106950	0.112100	0.152250	0.182400	...
75%	0.035550	0.047950	0.057950	0.064500	0.100275	0.134125	0.154000	0.169600	0.233425	0.268700	...
max	0.137100	0.233900	0.305900	0.426400	0.401000	0.382300	0.372900	0.459000	0.682800	0.710600	...

8 rows x 60 columns

51	52	53	54	55	56	57	58	59	60
208.000000	208.000000	208.000000	208.000000	208.000000	208.000000	208.000000	208.000000	208.000000	208.000000
0.016069	0.013420	0.010709	0.010941	0.009290	0.008222	0.007820	0.007949	0.007941	0.006507
0.012008	0.009634	0.007060	0.007301	0.007088	0.005736	0.005785	0.006470	0.006181	0.005031
0.000000	0.000800	0.000500	0.001000	0.000600	0.000400	0.000300	0.000300	0.000100	0.000600
0.008425	0.007275	0.005075	0.005375	0.004150	0.004400	0.003700	0.003600	0.003675	0.003100
0.013900	0.011400	0.009550	0.009300	0.007500	0.006850	0.005950	0.005800	0.006400	0.005300
0.020825	0.016725	0.014900	0.014500	0.012100	0.010575	0.010425	0.010350	0.010325	0.008525
0.100400	0.070900	0.039000	0.035200	0.044700	0.039400	0.035500	0.044000	0.036400	0.043900

Εικόνα 12. Βασική στατιστική ανάλυση των δεδομένων

Στην παραπάνω *Εικόνα 12*, απεικονίζονται οι περιγραφικοί στατιστικοί δείκτες που περιλαμβάνουν εκείνες τις στατιστικές που συνοψίζουν την κεντρική τάση, διασπορά, σχήμα της κατανομής καθώς και την ύπαρξη ακραίων τιμών (outliers) του συνόλου των ηχητικών δεδομένων sonar.

in:

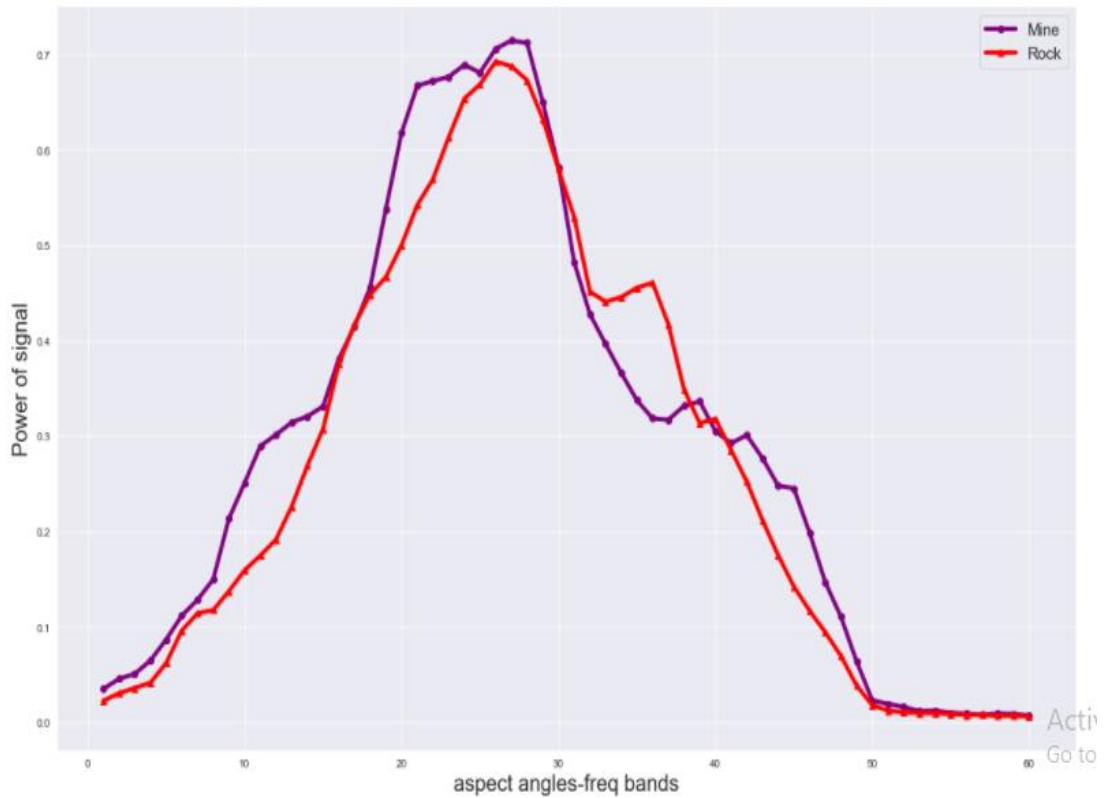
```
sonar_dataset['Class'].value_counts()
```

```
Mine      111
Rock       97
Name: Class, dtype: int64
```

Με την παραπάνω εντολή παρατηρούμε ότι τα δεδομένα μας είναι σχετικά ανισομερώς ταξινομημένα, γεγονός το οποίο πρέπει να ληφθεί υπόψη στην επιλογή του κατάλληλου μέτρου αξιολόγησης μετέπειτα.

in:

```
##mean Sonar signals output difference between Rock and Mine##
fig,axes=plt.subplots(nrows=1,ncols=1,figsize=(15,10))
axes=plt.plot(s_Mines,linewidth=4,marker="o",label='Mine',color='purple')
axes=plt.plot(s_Rocks,linewidth=4,marker="^",label='Rock',color='red')
plt.xlabel("aspect angles-freq bands",fontsize=20)
plt.ylabel("Power of signal",fontsize=20)
plt.legend(prop={'size': 15})
plt.tight_layout()
```



Εικόνα 13.

Στο παραπάνω διάγραμμα της **Εικόνα 12** αναπαριστάται η συχνότητα του ηχητικού σήματος (chirp) σε σχέση με την ισχύ του, όσον αφορά την ηχώ που δημιουργείται από την μεταλλική επιφάνεια (μωβ γραμμή) και την ηχώ του βράχου (κόκκινη γραμμή). Παρατηρείται λοιπόν ότι και για τις δύο επιφάνειες, η ισχύς του σήματος αυξάνει ανάλογα με την συχνότητα του μέχρι το χαρακτηριστικό 28 και στη συνέχεια μειώνεται στις μεγαλύτερες συχνότητες. Η παραπάνω διαπίστωση επιβεβαιώνεται και από το **Σχήμα 9** του κεφάλαιου 3.3.1. Επίσης, το σύνολο δεδομένων περιέχει σήματα που λαμβάνονται από διάφορες γωνίες διαστάσεων, που εκτείνονται 90 μοίρες για τον κύλινδρο και 180 μοίρες για το βράχο.

in:

```
sonar_dataset.hist(sharex=False, sharey=False, xlabelsize=1,
ylabelsize=1, figsize=(20,12), color='purple')
```



Εικόνα 14. Ιστογράμματα για κάθε επιμέρους χαρακτηριστικό (feature)


Με βάση την παραπάνω **Εικόνα 14**, παρατηρούμε ότι οι επιμέρους κατανομές για κάθε χαρακτηριστικό δεν ακολουθούν κανονική κατανομή ενώ κάποιες ακολουθούν εκθετική (exponential-like). Μπορούμε να δούμε ότι πολλά από τα χαρακτηριστικά έχουν μια λοξή κατανομή και αυτό το γεγονός πιθανόν να επηρεάσει την απόδοση ορισμένων αλγόριθμων. Για αυτό το λόγο θεωρείται απαραίτητη η επιλογή ενός μετασχηματισμού στα δεδομένα με σκοπό τη διόρθωση των λοξοτήτων στις κατανομές, ώστε να έχουν μια πιο κανονική μορφή (bell-shaped).


```

in:
fig, axes = plt.subplots(30, 2, figsize=(20, 60))
mine = sonar_dataset[sonar_dataset.Class == 1]
rock = sonar_dataset[sonar_dataset.Class == 0]
ax = axes.ravel()
for i in range(60):
    _, bins = np.histogram(sonar_dataset.iloc[:, i], bins=50)
    ax[i].hist(mine.iloc[:, i], bins=bins, color='purple', alpha=0.5)
    ax[i].hist(rock.iloc[:, i], bins=bins, color='green', alpha=.5)
    ax[i].set_title(sonar_dataset.columns[i])
    ax[i].set_yticks(())
ax[0].set_xlabel("Feature magnitude")
ax[0].set_ylabel("Frequency")

```

```
ax[0].legend(["Rock", "Mine"], loc="best")
fig.tight_layout()
```







Εικόνα 15. Σχέση ισχύς σήματος και συχνότητας μεταξύ μεταλλικής επιφάνειας και βράχου σε κάθε χαρακτηριστικό (feature)

Από την παραπάνω εικόνα, διακρίνεται ότι οι τιμές της ισχύς των σημάτων της μεταλλικής επιφάνειας και αυτές των βράχων για κάθε χαρακτηριστικό ,άρα και για κάθε συγκεκριμένο εύρος συχνοτήτων, αλληλεπικαλύπτονται. Επομένως, εξάγεται το συμπέρασμα ότι δεν υπάρχει σαφής διάκριση μεταξύ των σημάτων που να μπορεί να προβλεφθεί γραμμικά από έναν αλγόριθμο καθώς και ότι η σχέση των σημάτων της μεταλλικής επιφάνειας και του βράχου είναι μη γραμμική.

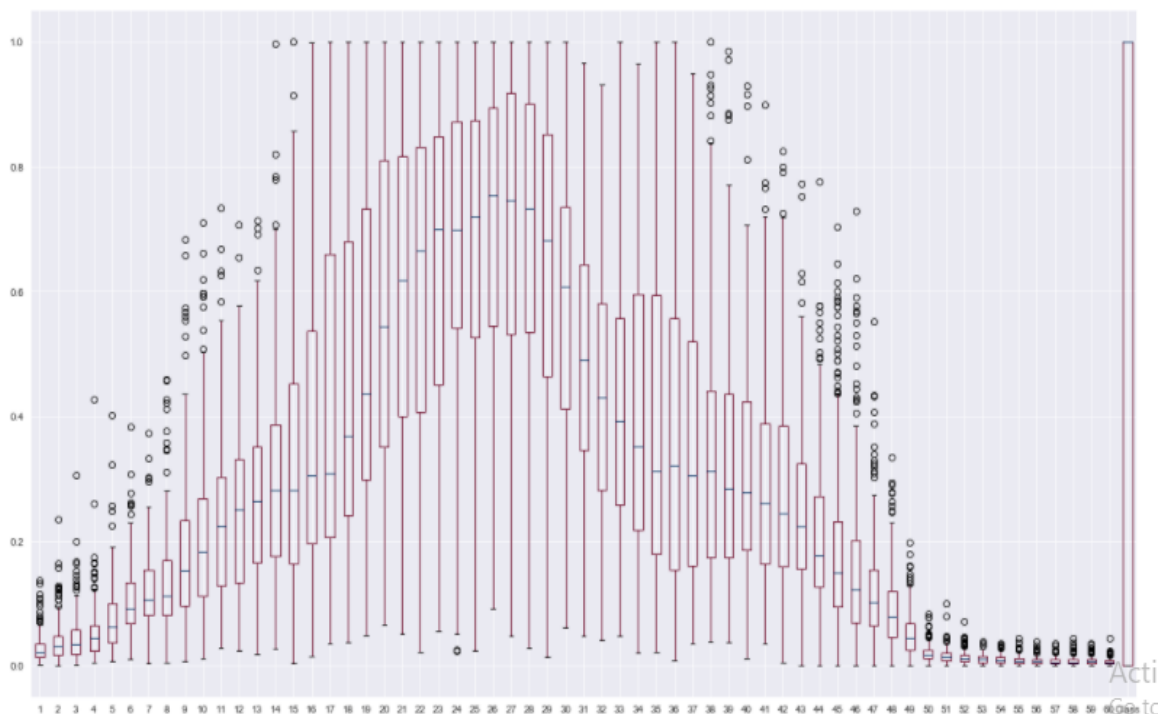
in:

```
# box plots
```

```
sonar_dataset.plot(kind='box', layout=(8,8), sharex=False, sharey=False,
fontsize=10,figsize=(20,12),use_index=True,colormap='RdBu')
```

Στην παρακάτω **Εικόνα 16**, παρατηρείται ότι τα σήματα έχουν σχετικά διαφορετικές διακυμάνσεις στις τιμές τους, δεδομένου ότι έχουν διαμορφωθεί στην κλίμακα μεταξύ 0-1. Παρόλα αυτά η τεχνική «κανονικοποίησης» των τιμών (standardization) ίσως βοηθήσει στην καλύτερη εφαρμογή-πρόβλεψη των μοντέλων. Σε αυτή την περίπτωση η συνάρτηση Standard scaler(), μέσω της βιβλιοθήκης Sklearn εξασφαλίζει ότι για κάθε χαρακτηριστικό το μέσο είναι 0 και η διακύμανση


είναι 1, τυποποιώντας όλα τα χαρακτηριστικά στο ίδιο μέγεθος. Επιπλέον, εναλλακτική τεχνική είναι ο Robust scaler(), ο οποίος χρησιμοποιεί τα μέτρα θέσης διάμεσο και τα τεταρτημόρια, αντί για το μέσο όρο και τη διακύμανση. Η συνάρτηση αυτή αγνοεί τα σημεία δεδομένων που είναι πολύ διαφορετικά από τα υπόλοιπα, όπως μπορεί να είναι λάθη μέτρησης ή outliers.



Εικόνα 16. Διακυμάνσεις των σημάτων σε κάθε χαρακτηριστικό (feature)

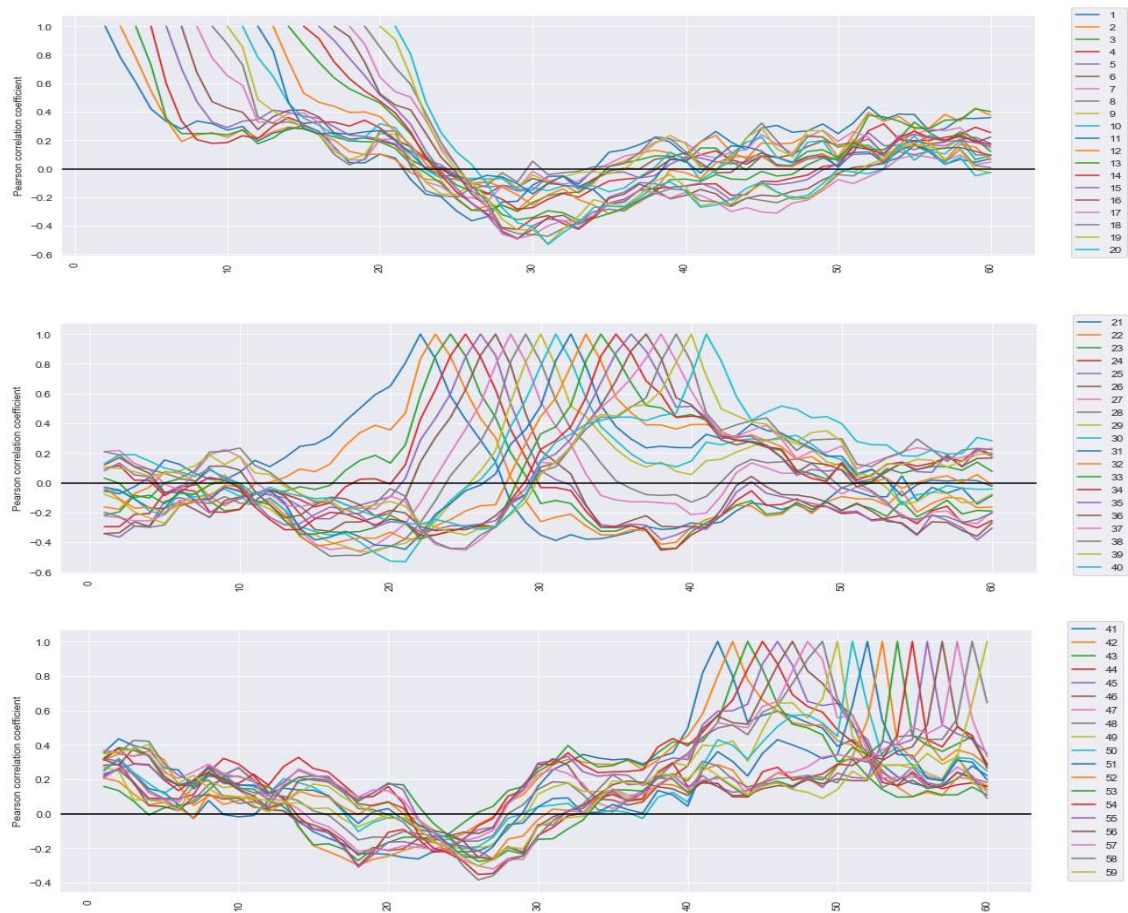
Στο παρακάτω διάγραμμα **Εικόνα 17**, διακρίνεται ένα μοτίβο (pattern), το οποίο αποτυπώνεται με χρωματικά χαρακτηρισμένες συσχετίσεις, μεταξύ των επιμέρους μεταβλητών. Συγκεκριμένα, το πορτοκαλί γύρω από τη διαγώνια γραμμή υποδηλώνει ότι οι μεταβλητές που βρίσκονται η μια δίπλα στην άλλη έχουν την μεγαλύτερη συσχέτιση. Οι σκούρο μωβ και μαύρο περιοχές, παρουσιάζουν αρνητική συσχέτιση μεταξύ των μεταβλητών, οι οποίες είναι μακριά μεταξύ τους κατά τη σειρά των χαρακτηριστικών, έτσι όπως είναι οργανωμένες στο σετ δεδομένων. Η παραπάνω διαπίστωση επιβεβαιώνεται και από την **Εικόνα 18**, η οποία παρουσιάζει την πορεία των συσχετίσεων της κάθε επιμέρους μεταβλητής με τις υπόλοιπες. Αξίζει να σημειωθεί ότι από το μοτίβο αυτό εξάγεται το συμπέρασμα ότι η σειρά των χαρακτηριστικών (features) πιθανόν να αποτυπώνει και τη σειρά του εύρους γωνιών των ηχητικών σημάτων.

- **in:**
`plt.figure(figsize=(8,5))`
`sns.heatmap(sonar_dataset.corr(),cmap='rocket')`



Εικόνα 17. Πίνακας συσχετίσεων μεταβλητών (correlation heatmap)

- **in:**
`num_cols = sonar_dataset.shape[1]`
`data_corr = class_drop.corr(method = 'pearson')`
`fig,axes = plt.subplots(figsize=(15,5))`
for i in range (1,21):
 `plt.plot(data_corr.iloc[i:num_cols,i], label=str(i))`
`plt.xticks(rotation='vertical')`
`plt.legend(bbox_to_anchor=(1.1, 1.05))`
`plt.axhline(y=0,color='k')`
`plt.ylabel("Pearson correlation coefficient")`

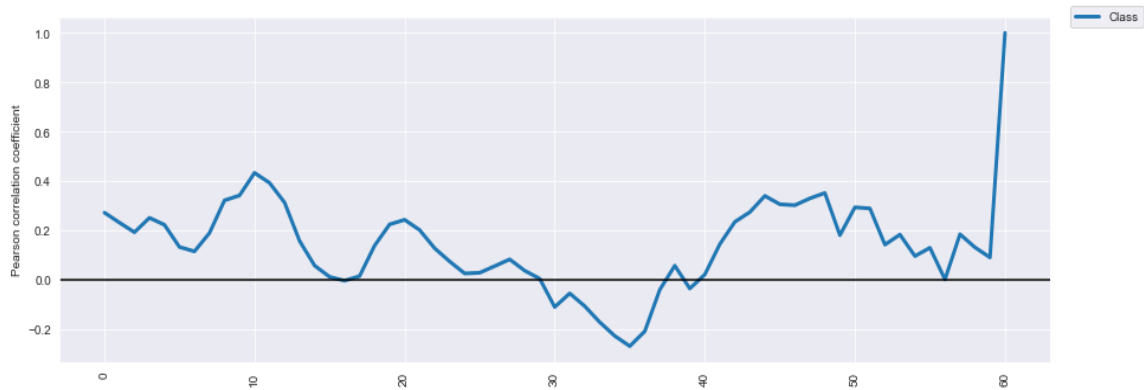


Εικόνα 18. Πορεία συσχέτισης κάθε μεταβλητής με τις υπόλοιπες

Στην παρακάτω **Εικόνα 19**, παρουσιάζεται η συσχέτιση μεταξύ της κλάσης-στόχος και των επιμέρους μεταβλητών. Παρατηρούμε ότι η συσχέτιση αυτή συνολικά δεν ξεπερνάει τις 0,5 μονάδες

- **in:**

```
fig.axes = plt.subplots(figsize=(15,5))
plt.plot(sonar_dataset.corr().loc['Class'].values,label='Class', lw=3)
plt.xticks(rotation='vertical')
plt.legend(bbox_to_anchor=(1.1, 1.05))
plt.axhline(y=0,color='k')
plt.ylabel("Pearson correlation coefficient")
plt.show()
```



Εικόνα 19. Συσχέτιση των μεταβλητών με την κλάση-στόχο

Παραπάνω, στην **Εικόνα 14** αναφέρθηκε στην απαίτηση για μετασχηματισμού των δεδομένων ώστε να προσεγγίζουν όσο το δυνατόν περισσότερο την κανονική κατανομή. (Sharma, 2019) Για την επιλογή του ιδανικότερου μετασχηματισμού δοκιμάστηκαν ορισμένες βασικές τεχνικές όπως ο εκθετικός μετασχηματισμός, ο λογαριθμικός και ο μετασχηματισμός Yeo-Johnson που αφορά την υποκατηγορία του δυναμικού μετασχηματισμού (power transformation), οι οποίες παρουσιάζονται στη παρακάτω **Εικόνα 20**. Με βάση τα παρακάτω διαγράμματα φαίνεται ότι η τεχνική Yeo-Johnson είναι η καλύτερη επιλογή όσον αφορά το εύρος της διακύμανση των δεδομένων καθώς και της βελτίωσης των κατανομών των επιμέρους μεταβλητών, ώστε να προσεγγίζουν περισσότερο την κανονική κατανομή έτσι όπως αναδεικνύεται στην **Εικόνα 21**.

- **in:**

```
transf = [ ]
```

```
transf_sqrt = [ ]
```

```
transf_yj = [ ]
```

```
transf_log = [ ]
```

```
#square transform
```

```
data_sqrt = sonar_without_target.apply(np.sqrt)
```

```
# Yeo-Johnson transform
```

```
temp = power_transform(sonar_without_target.iloc[:, :-1], method = "yeo-johnson")
```

```
data_yj = pd.DataFrame(temp, columns=sonar_without_target.iloc[:, :-1].columns.tolist())
```

```
1].columns.tolist())
```

```
#log transform
```

```

data_log = sonar_without_target.apply(np.log)
for att in sonar_without_target.iloc[:, :-1].columns:
    transf.append(sonar_without_target[att].skew())
for att in data_sqrt.iloc[:, :-1].columns:
    transf_sqrt.append(data_sqrt[att].skew())
for att in data_yj.iloc[:, :-1].columns:
    transf_yj.append(data_yj[att].skew())
for att in data_log.iloc[:, :-1].columns:
    transf_log.append(data_log[att].skew())
fig, axes = plt.subplots(4, 1, figsize=(30, 6), sharex=True)
bins = 40
fontsize = 15
axes[0].hist(transf, bins=bins)
axes[1].hist(transf_sqrt, bins=bins, color='green')
axes[2].hist(transf_yj, bins=bins, color='purple')
axes[3].hist(transf_log, bins=bins, color='red')
axes[0].text(3, 2.5, "no transform", fontsize = fontsize)
axes[1].text(3, 2.5, "sqrt", fontsize = fontsize)
axes[2].text(3, 2.5, "yeo-johnson", fontsize = fontsize)
axes[3].text(3, 2.5, "log", fontsize = fontsize)
fig.subplots_adjust(hspace=0)
for ax in axes:
    ax.label_outer()
    ax.axvline(x=0, color='r')
fig.tight_layout()

```

- **in:**

```

fig, ax = plt.subplots(figsize=(10, 6))
plt.plot(transf, label = "No transformation")
plt.plot(transf_sqrt, color='r', label = "Sqrt transformation")
plt.plot(transf_yj, color='g', label = "Yeo-Johnson transformation")
#plt.plot(transf_log, color='b', label = "Log transformation")
plt.axhline(y=0, color='k')
plt.xlabel("Variable/Column")
plt.ylabel("Skewness")
plt.legend(loc="best")
plt.show()

```

- **in:**

```

data_yj.plot(kind='box', layout=(8, 8), sharex=False, sharey=False,
fontsize=10, figsize=(20, 12), use_index=True, colormap='RdBu')

```

- **in:**

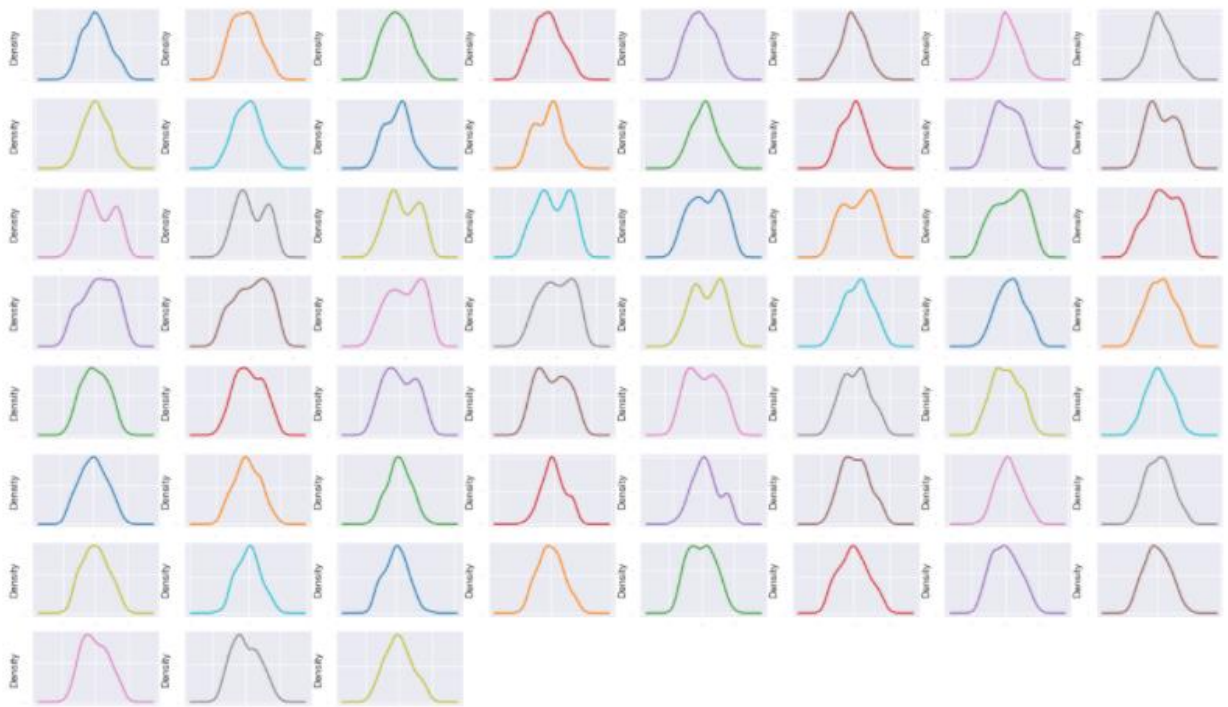
```

data_yj.hist(xlabelsize = 0, figsize=(20, 12))
plt.show()

```



Εικόνα 20. Μετασχηματισμοί δεδομένων με την τεχνική Yeo-Johnson



Εικόνα 21. Διαμόρφωση των κατανομών των μεταβλητών μετά από μετασχηματισμό Yeo-Johnson

3. Διαχωρισμός δεδομένων (Splitting dataset)

Ένα σύνολο δεδομένων που χρησιμοποιείται για τη μηχανική μάθηση, ενδείκνυται να χωριστεί σε τρία υποσύνολα - σετ εκπαίδευσης (training), δοκιμών (test) και επικύρωσης (validation). Τα δεδομένα εκπαίδευσης αξιοποιούνται για την εκπαίδευση του μοντέλου συμβάλλοντας στον καθορισμό των βέλτιστων παραμέτρων του με σκοπό τη μάθηση από τα δεδομένα. Τα δεδομένα δοκιμών απαιτούνται για την αξιολόγηση του εκπαιδευμένου μοντέλου και την ικανότητά του για γενίκευση. Το τελευταίο σημαίνει την ικανότητα ενός μοντέλου να αναγνωρίζει μοτίβα σε νέα άγνωστα σε αυτό δεδομένα, έχοντας εκπαιδευτεί αποκλειστικά πάνω σε δεδομένα εκπαίδευσης. Είναι ζωτικής σημασίας η αξιοποίηση διαφορετικών υποσυνόλων για εκπαίδευση και δοκιμή, ώστε να αποφευχθεί η υπερβολική μάθηση του μοντέλου (overfitting), η οποία προκαλεί ανικανότητα γενίκευσης του μοντέλου. Τα δεδομένα επικύρωσης παρουσιάζουν καταλυτικό ρόλο στην ρύθμιση και επιλογή του κατάλληλου μοντέλου βάσει των δεδομένων που διαθέτουμε και του προβλήματος που καλούμαστε να επιλύσουμε. Ο σκοπός μέσω ενός συνόλου δεδομένων επικύρωσης είναι η πραγματοποίηση τροποποιήσεων στις

υπερπαραμέτρους (hyperparameters) ενός μοντέλου, οι οποίες αφορούν δομικές και ρυθμίσεις υψηλότερου επιπέδου που δεν μπορούν να μάθουν άμεσα από τα δεδομένα. Αυτές οι ρυθμίσεις μπορούν να εκφράσουν, για παράδειγμα, πόσο περίπλοκο είναι ένα μοντέλο και πόσο γρήγορα εντοπίζει μοτίβα στα δεδομένα. Έτσι τα αποτελέσματα ενός μοντέλου πάνω στα δεδομένα επικύρωσης μας δίνουν μια πρώτη εκτίμηση για την απόδοση του μοντέλου. Βέβαια, η τελική απόδοση πρόβλεψης του μοντέλου διαπιστώνεται με τα δεδομένα δοκιμών. Στην παρούσα εργασία η ποσόστωση διαχωρισμού του συνόλου των δεδομένων έγινε με ποσοστό εκπαίδευσης 80% και ποσοστό δοκιμών 20% (βλ. **Εικόνα 21**), ενώ όσον αφορά τα δεδομένα επικύρωσης χρησιμοποιήθηκε μια διαφορετική προσέγγιση η οποία θα αναλυθεί παρακάτω και ονομάζεται διασταυρωμένη επικύρωση (cross validation). Αντίθετα, όσον αφορά την εκπαίδευση του νευρωνικού δικτύου, το ποσοστό εκπαίδευσης αφορούσε το 80% των δεδομένων, το ποσοστό δοκιμών το 10% και το ποσοστό επικύρωσης το άλλο 10%.

Τέλος, είναι χαρακτηριστικό ότι όσο περισσότερα δεδομένα εκπαίδευσης χρησιμοποιούνται στην εκπαίδευση, τόσο καλύτερη θα είναι η δυναμική και η απόδοση του μοντέλου. Κατά συνέπεια, περισσότερα αποτελέσματα δεδομένων δοκιμών οδηγούν σε καλύτερη απόδοση μοντέλου και δυνατότητα γενίκευσης.

Train/test split data

```
In [35]: y=sonar_dataset['Class']
```

```
In [36]: X_train,X_test,y_train,y_test= train_test_split(sonar_without_target,y,test_size=0.20,random_state=52,stratify=y )
```

```
In [37]: X_train_yj,X_test_yj,y_train_yj,y_test_yj= train_test_split(data_yj,y,test_size=0.20,random_state=52,stratify=y )
```

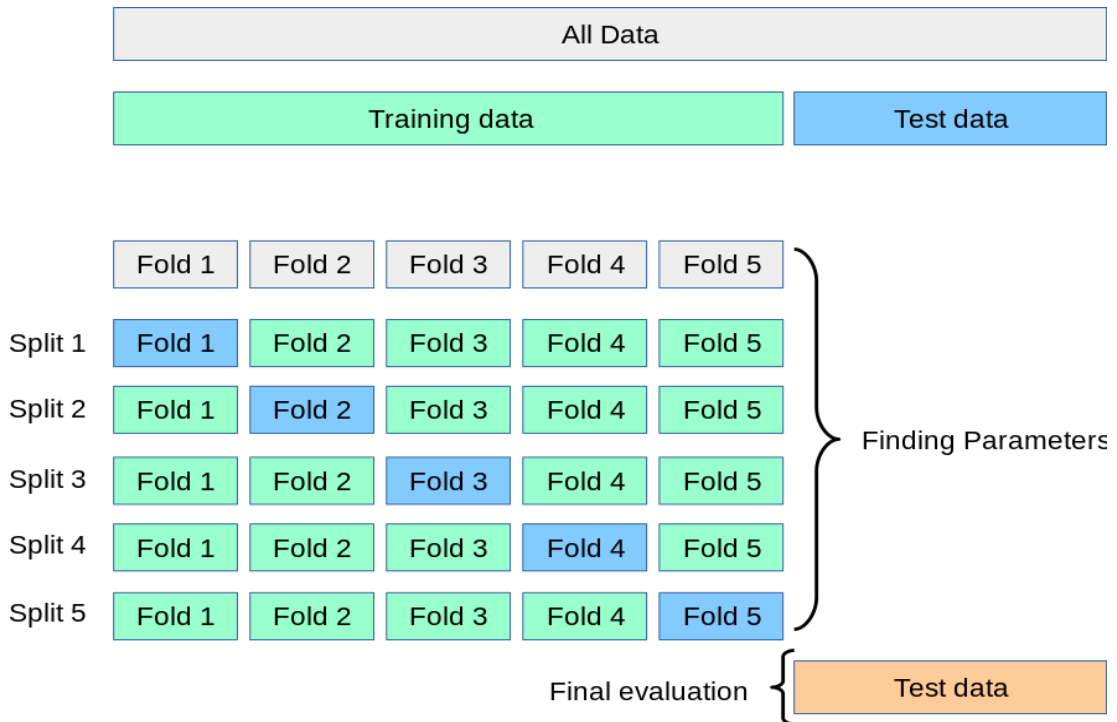
Εικόνα 22. Μέθοδος διαχωρισμού δεδομένων

4. Διερεύνηση του μοντέλου που είναι καλύτερο για τον τύπο δεδομένων. (Modelling)

Κατά τη διάρκεια αυτού του σταδίου, εκπαιδεύτηκαν τα μοντέλα μηχανικής εκμάθησης έτσι όπως παρουσιάστηκαν στο κεφάλαιο 2.4, για να καθοριστεί ποιο από αυτά παρέχει τις πιο ακριβείς προβλέψεις με βάση το ζήτημα της ταξινόμησης ηχητικών σημάτων sonar. Μετά την ολοκλήρωση του σταδίου συλλογής, προεπεξεργασίας και διαχωρισμού των δεδομένων, το επόμενο στάδιο αφορά στην εκπαίδευση των μοντέλων. Αυτή η διαδικασία συνεπάγεται «τροφοδοσία» του αλγορίθμου με δεδομένα εκπαίδευσης. Ένας αλγόριθμος θα επεξεργάζεται δεδομένα και θα εξάγει ένα μοντέλο που μπορεί να βρει μια τιμή-στόχο (target label) σε νέα δεδομένα. Ο σκοπός της εκπαίδευσης των αλγορίθμων είναι η ανάπτυξη ενός μοντέλου πρόβλεψης νέων άγνωστων δεδομένων, παρόμοιων με αυτά που εκπαιδεύτηκε ο αλγόριθμος. Στην παρούσα μελέτη αξιοποιήθηκαν αλγόριθμοι εποπτευόμενης μάθησης, κατάλληλοι για ταξινόμηση προβλημάτων (classification problems). (βλ. *Σχήμα II*) Τελική φάση του σταδίου αυτού είναι η αξιολόγηση των μοντέλων (evaluation). Στη φάση αυτή πραγματοποιείται περαιτέρω ρύθμιση των παραμέτρων των καλύτερων μοντέλων τα οποία έδωσαν τα μεγαλύτερα ποσοστά πρόβλεψης σε σχέση με τα υπόλοιπα και τα οποία αξιολογήθηκαν, είτε με τα δεδομένα επικύρωσης, είτε με διασταυρωμένη επικύρωση.

Η διασταυρωμένη επικύρωση είναι η πιο συχνά χρησιμοποιούμενη μέθοδος παραμετροποίησης, ειδικά όταν το μέγεθος των δεδομένων που διαθέτουμε θεωρείται σχετικά μικρό. Η διαδικασία αυτή συνεπάγεται τη διάσπαση ενός συνόλου δεδομένων εκπαίδευσης συνήθως σε 3 ή 5 ή 10 ίσα μέρη (πτυχές). Το μοντέλο στην περίπτωση των 10 πτυχών, εκπαιδεύεται μόνο σε εννέα πτυχές και στη συνέχεια δοκιμάζεται στη δέκατη (αυτή που είχε προηγουμένως παραλειφθεί). Η εκπαίδευση συνεχίζεται έως ότου κάθε πτυχή παραμείνει στην άκρη και χρησιμοποιηθεί για δοκιμές. Αποτέλεσμα της διαδικασίας αυτής αποτελεί μια τιμή (score) η οποία αφορά τη μέση τιμή όλων των επιμέρους τιμών που προέκυψαν από τις 10 διαφορετικές δοκιμές αξιολόγησης που έγιναν με την παραπάνω διαδικασία και μετρά την απόδοση του μοντέλου με βάση τις συγκεκριμένες παραμέτρους που τέθηκαν. Όσον αφορά την παρούσα μελέτη, το σύνολο των αλγορίθμων που χρησιμοποιήθηκαν, αξιολογήθηκε σε πρώτο στάδιο με διασταυρωμένη επικύρωση 10 ίσων πτυχών (10-Fold cross validation) και ως μέτρο αξιολόγησης τέθηκε το μέτρο της ακρίβειας (accuracy). Έπειτα με βάση τα αποτελέσματα της απόδοσης

τους, επιλέχθηκαν οι αλγόριθμοι με την καλύτερη απόδοση για περαιτέρω επεξεργασία. Στην παρακάτω **Εικόνα 23** παρουσιάζεται η διαδικασία της διασταυρωμένης επικύρωσης.



Εικόνα 23. Διασταυρωμένη επικύρωση 5 πτυχών (Scikit learn, 2020)

Μια επιπλέον τεχνική η οποία μπορεί να εφαρμοστεί κατάλληλα σε συνδυασμό με τη διασταυρωμένη επικύρωση και η οποία αξιοποιήθηκε στη παρούσα μελέτη, είναι η τεχνική αναζήτησης πλέγματος (grid search). Με την τεχνική αυτή εκπαιδεύτηκαν μοντέλα με διαφορετικά σύνολα υπερπαραμέτρων και σε συνδυασμό με την διασταυρωμένη επικύρωση, καθορίστηκε ποιο μοντέλο είχε την υψηλότερη ακρίβεια πρόβλεψης. Η διασταυρούμενη βαθμολογία αναδεικνύει τη μέση απόδοση του μοντέλου με βάση των αριθμό πτυχών που έχουν επιλεγεί για κάθε παράμετρο που έχει τεθεί ξεχωριστά. Έτσι, στους αλγόριθμους με την καλύτερη απόδοση από το προηγούμενο στάδιο εφαρμόστηκε η τεχνική «grid search», με την οποία δοκιμάστηκε ένα επαρκές εύρος τιμών για την παραμετροποίηση των επιμέρους μεταβλητών τους, με στόχο τη βελτίωση της απόδοσης τους.

ΑΛΓΟΡΙΘΜΟΙ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ	
1. LR	Logistic Regression
2. LDA	Linear Discriminant Analysis
3. KNN	K Neighbors Classifier
4. DTC	Decision Tree Classifier
5. NB	Gaussian NB
6. SVC	Support Vector Classifier
7. QDA	Quadratic Discriminant Analysis
8. ABC	Ada Boost Classifier
9. RFC	Random Forest Classifier
10. GPC	Gaussian Process Classifier
11. LINSVC	Linear SVC
12. GBooSTC	Gradient Boosting Classifier
13. ET	Extra Trees Classifier
14. XGBC	XG Boost Classifier

Σχήμα 11. Αλγόριθμοι Μηχανικής Μάθησης

5. Δοκιμή (Testing) – Εφαρμογή του καλύτερου μοντέλου σε άγνωστα δεδομένα

Στο τελικό αυτό στάδιο το καλύτερο σε ποσοστά πρόβλεψης μοντέλο που απορρέει από την προηγούμενη διαδικασία, δοκιμάζεται σε νέα άγνωστα δεδομένα. Σε αυτό το στάδιο, διαφαίνεται η πραγματική απόδοση του μοντέλου σχετικά με την γενικευσιμότητα του και την ουσιαστική του λειτουργία όσον αφορά την επίλυση του προβλήματος για το οποίο αναπτύχθηκε. (‘Machine Learning Project Structure’, 2020; Pant, 2019)

Μέτρα Αξιολόγησης (Evaluation Metrics)

Ένα από τα πιο γνωστά μέτρα αξιολόγησης, όσον αφορά την ταξινόμηση των δεδομένων αποτελεί το μέτρο της ακρίβειας (accuracy). Το μέτρο αυτό είναι ο λόγος των ορθά ταξινομημένων δεδομένων τα οποία προέβλεψε ο αλγόριθμος προς τον συνολικό αριθμό των δεδομένων και συχνά αναπαριστάται σε ποσοστό επί της %.

Ένα άλλο ενδιαφέρον μέτρο το οποίο παρέχει ακριβέστερη πληροφόρηση για το βαθμό απόδοσης-πρόβλεψης ενός αλγόριθμου αφορά στον πίνακα σύγχυσης (confusion matrix). Ο πίνακας σύγχυσης παρέχει σαφέστερα και περισσότερο αξιόπιστα αποτελέσματα από το μέτρο ακρίβειας, ειδικότερα σε ανισομερώς ταξινομημένα δεδομένα. Στο παρακάτω **Σχήμα 12** απεικονίζεται ο πίνακας σύγχυσης καθώς και τα επιμέρους μέτρα αξιολόγησης που απορρέουν από αυτόν.

		Predicted Class		
		Positive	Negative	
Actual Class	Positive	True Positive (TP)	False Negative (FN) Type II Error	Sensitivity $\frac{TP}{(TP + FN)}$
	Negative	False Positive (FP) Type I Error	True Negative (TN)	Specificity $\frac{TN}{(TN + FP)}$
		Precision $\frac{TP}{(TP + FP)}$	Negative Predictive Value $\frac{TN}{(TN + FN)}$	Accuracy $\frac{TP + TN}{(TP + TN + FP + FN)}$

Σχήμα 12. Confusion matrix (Science, 2019)

1. True Positive (TP) είναι ο αριθμός των σωστών προβλέψεων της θετικής κλάσης, δηλαδή ότι ένα παράδειγμα είναι θετικό και αναγνωρίζεται σωστά στη θετική κλάση.

2. False Negative (FN) είναι ο αριθμός λανθασμένων προβλέψεων ότι ένα παράδειγμα είναι αρνητικό, ενώ ανήκει στη θετική κλάση και εσφαλμένα αναγνωρίζεται ως αρνητικό.

3. False positive (FP) είναι ο αριθμός λανθασμένων προβλέψεων ότι ένα παράδειγμα είναι θετικό ενώ ανήκει στην αρνητική κλάση το οποίο εσφαλμένα αναγνωρίζεται ως θετικό.

4. True Negative (TN) είναι ο αριθμός των σωστών προβλέψεων της αρνητικής κλάσης, δηλαδή ότι ένα παράδειγμα είναι αρνητικό και αναγνωρίζεται σωστά ως αρνητική κλάση.

Τα επιμέρους μέτρα αξιολόγησης παρέχουν σημαντικές πληροφορίες, σχετικές με την απόδοση των μοντέλων και μπορούν να διαφωτίσουν ακόμα περισσότερο το ζήτημα της καλύτερης επιλογής αλγόριθμου, στην περίπτωση που το μέτρο της ακρίβειας δίνει σχεδόν παρόμοια αποτελέσματα για έναν αριθμό αλγόριθμων περισσότερων του ενός. Επιπλέον, ανάλογα με τη φύση του προβλήματος, κάποιες φορές χρειάζεται να δοθεί περισσότερη έμφαση σχετικά με τον βαθμό πρόβλεψης του αλγόριθμου σε μόνο μια εκ των δύο κλάσεων, όσον αφορά ζητήματα διωνυμικής ταξινόμησης όπως συμβαίνει και στην παρούσα μελέτη. Για παράδειγμα εάν επιθυμούμε ο αλγόριθμος να προβλέπει καλύτερα την κλάση δεδομένων της μεταλλικής επιφάνειας έναντι των βράχων και έστω ότι η κλάση της μεταλλικής επιφάνειας αφορά την θετική κλάση (positive class) του **Σχήματος 12** τότε θα πρέπει να περιορίσουμε στο ελάχιστο ή και να μηδενίσουμε το σφάλμα τύπου II (FN-False Negative), δηλαδή τα δεδομένα εκείνα τα οποία ανήκαν στην κλάση των μεταλλικών αντικείμενων (positive class) και ταξινομήθηκαν με βάση τον αλγόριθμο στην κλάση των βράχων (negative class).

Ιδιαίτερο ενδιαφέρον για την σωστή επιλογή αλγόριθμου αποτελεί και η αναφορά ταξινόμησης (classification report), έτσι όπως αποτυπώνεται στο παρακάτω **Σχήμα 13**.

	precision	recall	f1-score	support
0	0.77	0.86	0.81	37584
1	0.84	0.75	0.79	37577
accuracy			0.80	75161
macro avg	0.81	0.80	0.80	75161
weighted avg	0.81	0.80	0.80	75161

Σχήμα 13 Αναφορά ταξινόμησης

Όπως και στον πίνακα σύγχυσης, έτσι και στην αναφορά ταξινόμησης περιέχονται επιμέρους μέτρα, τα οποία αποτελούν μια πιο αναλυτική προσέγγιση της απόδοσης ενός αλγόριθμου.

Precision: Το μέτρο αυτό χρησιμοποιείται όταν ο σκοπός, με βάση το πρόβλημα που πραγματευόμαστε είναι ο περιορισμός των false positives, δηλαδή των δεδομένων εκείνων που ταξινομήθηκαν ως θετικά από τον αλγόριθμο αλλά στην πραγματικότητα ανήκαν στην αρνητική κλάση. (βλ. *Σχήμα 14*) (Muller & Guido, 2016)

$$\text{Precision} = \frac{TP}{TP+FP}$$

Σχήμα 14. Precision

Recall (Sensitivity): Από την άλλη πλευρά, το μέτρο αυτό υπολογίζει πόσα από τα θετικά δείγματα καλύπτονται από τις θετικές προβλέψεις του αλγόριθμου. Το μέτρο αυτό χρησιμοποιείται ως μέτρηση απόδοσης όταν πρέπει να αναγνωρίσουμε όλα τα θετικά δείγματα δηλαδή, όταν είναι σημαντικό να αποφεύγονται τα False negatives. (βλ. *Σχήμα 15*)

$$\text{Recall} = \frac{TP}{TP+FN}$$

Σχήμα 15. Recall


f1-score: είναι ο σταθμισμένος μέσος όρος της ανάκλησης (Recall) και της ακρίβειας (Precision). Το μέτρο αυτό μπορεί να θεωρηθεί καλή επιλογή, όταν απαιτείται ισορροπία μεταξύ Precision και Recall. (βλ. *Σχήμα 16*)

$$F = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}}$$

Σχήμα 16. f1-score

Τέλος, άλλο ένα χρήσιμο μέρος πληροφορίας, συναφές με την ορθότητα των προβλέψεων ενός μοντέλου, το οποίο δεν έχει συζητηθεί ακόμη είναι η ικανότητα των ταξινομητών να παρέχουν εκτιμήσεις αβεβαιότητας των προβλέψεων. Συχνά, το ενδιαφέρον δεν στρέφεται αποκλειστικά στην κλάση που ο ταξινομητής προβλέπει για ένα συγκεκριμένο σύνολο δεδομένων δοκιμών (test data), αλλά και στο βαθμό βεβαιότητας της πρόβλεψης. Με βάση αυτό το χαρακτηριστικό, υπάρχουν δύο διαφορετικές λειτουργίες στην βιβλιοθήκη scikit-learn που μπορούν να χρησιμοποιηθούν για την εκτίμηση της αβεβαιότητας πρόβλεψης ενός μοντέλου ταξινόμησης. Η «decision_function» και η «predict_proba» είναι οι δύο λειτουργίες οι οποίες υπολογίζουν την αβεβαιότητα κάθε επιμέρους πρόβλεψης ενός αλγόριθμου, για ένα συγκεκριμένο σύνολο δεδομένων. Η τιμές της «decision_function» υποδηλώνουν το πόσο ισχυρά το μοντέλο πιστεύει ότι ένα σημείο δεδομένων ανήκει σε μια από τις δύο κλάσεις και όσο μεγαλύτερη είναι αυτή η τιμή τόσο μεγαλύτερος είναι και ο βαθμός εμπιστοσύνης του μοντέλου με βάση τη συγκεκριμένη πρόβλεψη. Από την άλλη, οι τιμές της «predict_proba» είναι δύο και υποδηλώνουν την πιθανότητα πρόβλεψης της κάθε κλάσης για ένα σύνολο δεδομένων. Το εύρος των τιμών της κυμαίνεται μεταξύ 0-1. Η πρώτη τιμή της «predict_proba» αφορά την πιθανότητα της μιας κλάσης ενώ η δεύτερη, την πιθανότητα πρόβλεψης της άλλης κλάσης. Το άθροισμα των δύο αυτών τιμών δίνει

τιμή 1, δηλαδή πιθανότητα 100% και το κατώφλι επιλογής (threshold) μιας εκ των δύο κλάσεων είναι το 0.5 δηλαδή το 50%. Για την «decision_function» το κατώφλι επιλογής είναι το 0. Επιπλέον, υπάρχει η δυνατότητα αλλαγής του ορίου επιλογής (threshold) στις παραπάνω συναρτήσεις, στην περίπτωση που απαιτηθεί ένας ισχυρότερος βαθμός πρόβλεψης που αφορά μια συγκεκριμένη κλάση. Για την επίτευξη αυτού του σκοπού, η μέθοδος που προτείνεται αφορά στην καμπύλη Precision-Recall και στην καμπύλη ROC. Η πρώτη καμπύλη παρουσιάζει την σχέση των μετρικών Precision και Recall που απορρέουν από την αναφορά ταξινόμησης (Classification report). Η καμπύλη διευκολύνει ένα πρόβλημα ταξινόμησης να κατανοηθεί καλύτερα, εξετάζοντας όλα τα πιθανά κατώτατα όρια επιλογών (thresholds) ή όλες τις πιθανές σχέσεις των μετρικών Precision και Recall. Σημαντική πληροφορία που μας παρέχει αυτή η καμπύλη είναι η εύρεση της καλύτερης δυνατής σχέσης μεταξύ των δύο αυτών μετρικών με βάση ένα συγκεκριμένο threshold, δηλαδή αναζητείται εκείνο το threshold στο οποίο τα μετρικά Precision και Recall θα κατέχουν τις υψηλότερες τιμές. (βλ. Παράδειγμα 1)(Muller & Guido, 2016)

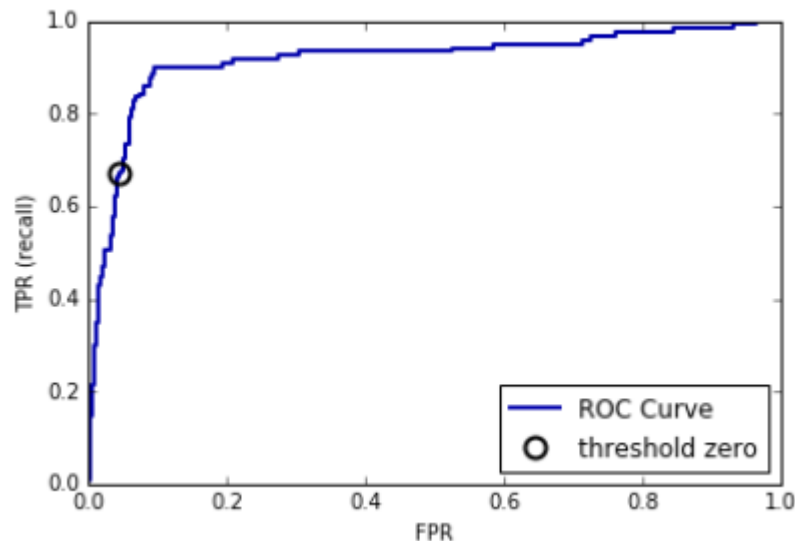


Παράδειγμα 1 Καμπύλη Precision-Recall (Muller & Guido, 2016)

Όσον αφορά την καμπύλη ROC, αφορά ένα εναλλακτικό εργαλείο που χρησιμοποιείται για την ανάλυση της συμπεριφοράς των ταξινομητών σε διαφορετικά thresholds, αλλά αντί να αξιοποιεί τα μετρικά Precision και Recall ,

χρησιμοποιεί το ψευδώς θετικό ποσοστό (FPR) έναντι του αληθινού θετικού ρυθμού (TPR). Το ποσοστό TPR είναι απλά ένα άλλος όρος για το Recall, ενώ το ψευδώς θετικό ποσοστό είναι ο λόγος του ψευδώς θετικού ρυθμού προς όλα τα αρνητικά δείγματα (βλ. *Παράδειγμα 2*):

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}}$$



Παράδειγμα 2 Καμπύλη ROC (Muller & Guido, 2016)

3.3.2.1 Στάδια ανάπτυξης νευρωνικού δικτύου

Η ανάπτυξη του νευρωνικού δικτύου σχετικά με την παρούσα μελέτη υλοποιήθηκε με τη βιβλιοθήκη Keras. Το Keras είναι μια ισχυρή και εύχρηστη βιβλιοθήκη ανοιχτού κώδικα Python για την ανάπτυξη και αξιολόγηση μοντέλων βαθιάς μάθησης. Συνεργάζεται με τις αριθμητικές βιβλιοθήκες υπολογισμού Theano και TensorFlow και επιτρέπει να οριστούν και να εκπαιδευτούν μοντέλα νευρωνικών δικτύων. Η ανάπτυξη του νευρωνικού μοντέλου της παρούσας εργασίας εκτελέστηκε σε 4 στάδια.

Στο πρώτο στάδιο, εισήχθησαν τα δεδομένα ηχητικών σημάτων, εκτελέστηκε ο διαχωρισμός των δεδομένων σε δεδομένα εκπαίδευσης (80%), σε δεδομένα επικύρωσης (10%) και δεδομένα δοκιμών (10%) και πραγματοποιήθηκε κανονικοποίηση (standardization) στα δεδομένα με τον αλγόριθμο StandardScaler() της βιβλιοθήκης Sklearn.

```
#loading the sonar dataset
sonar_dataframe= pd.read_csv("E:\Μεταπτυχιακά\Νέες τεχνολογίες & Αυτοματισμοί στη Ναυτιλία\Διπλωματική\dataset_40_sonar.csv")
#sonar_dataset= sonar_dataframe.values

sonar_dataframe
sonar_dataframe['Class']=sonar_dataframe['Class'].map({'Mine':1, 'Rock':0})
sonar_dataset= sonar_dataframe.values

#split to input and output arrays
X= sonar_dataset[:, :60].astype(float)
y=sonar_dataset[:, 60]
print(X.shape,y.shape)

#train/test split
X_trainval, X_test, y_trainval, y_test =train_test_split(X,y,test_size=0.10,
                                                         random_state=seed, stratify=y)

scaler= StandardScaler()
x_scaled=scaler.fit_transform(X_trainval)
xval_scaled=scaler.transform(X_test)
```

Εικόνα 24 Κώδικας πρώτου σταδίου ανάπτυξης

Στο δεύτερο στάδιο ορίστηκε το μοντέλο του νευρωνικού δικτύου. Στο στάδιο αυτό ορίστηκε η αρχιτεκτονική του δικτύου, δηλαδή ο αριθμός των εισόδων (input layer), των ενδιάμεσων επιπέδων (hidden layers) και των εξόδων (output layer). Επιπλέον, ορίστηκε η συνάρτηση ενεργοποίησης του νευρώνα (activation), η συνάρτηση υπολογισμού σφάλματος (loss function), η συνάρτηση βελτίωσης των βαρών του δικτύου (optimization) καθώς και το μετρικό αξιολόγησης. (βλ. Εικόνα 25


```
def create_model():
    #creating the model
    model = Sequential()
    model.add(Dropout(0.2, input_shape=(60,)))
    model.add(Dense(55, input_dim=60, activation='relu', kernel_constraint=maxnorm(2)))
    #model.add(Dropout(0.2))
    model.add(Dense(23, kernel_initializer='uniform', activation='relu', kernel_constraint=maxnorm(2)))
    #model.add(Dense(30, kernel_initializer='normal', activation='relu', kernel_constraint=maxnorm(3)))
    #model.add(Dropout(0.2))
    #model.add(Dense(18, kernel_initializer='normal', activation='relu', kernel_constraint=maxnorm(2)))
    model.add(Dense(1, activation="sigmoid"))
    #compile the model
    sgd = SGD(lr=0.01, momentum=0.7, decay=0.0, nesterov=False)
    model.compile(loss='binary_crossentropy', optimizer="adam", metrics=['accuracy'])
    return model
```

Εικόνα 25 Ορισμός νευρωνικού δικτύου

Στο τρίτο στάδιο, εκτελέστηκε το νευρωνικό δίκτυο στα δεδομένα εκπαίδευσης μέσω της μεθόδου fit() στο μοντέλο. Χαρακτηριστικό της εκπαίδευσης του δικτύου αποτελούν οι παράμετροι «εποχές» (epochs) ενώ κάθε εποχή χωρίζεται σε «παρτίδες» (batches).

Epoch: Μια περίοδος οπού το μοντέλο επεξεργάζεται το σύνολο δεδομένων εκπαίδευσης.

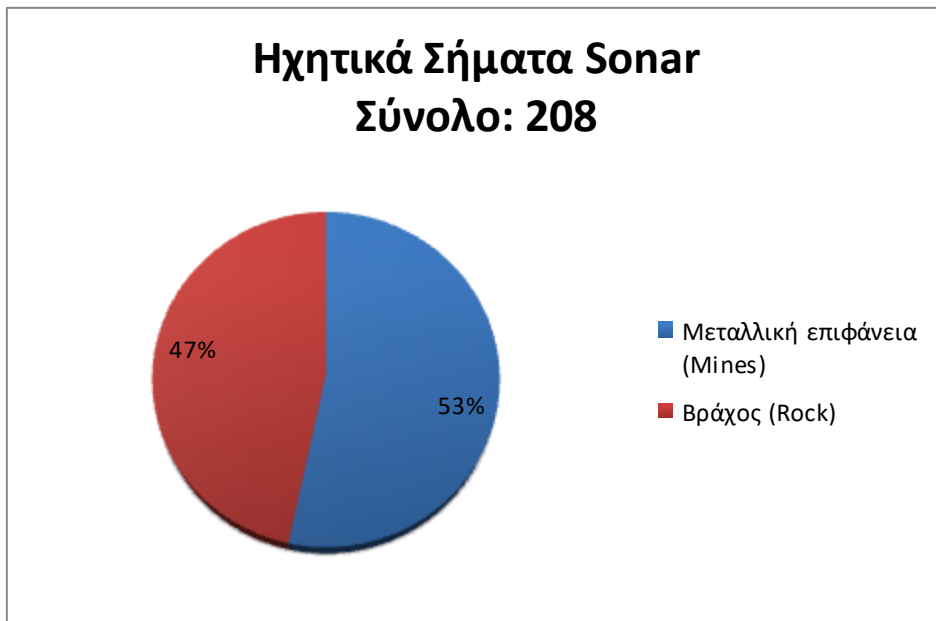
Batch: Ένα ή περισσότερα πακέτα δειγμάτων που εξετάστηκαν από το μοντέλο σε μια εποχή πριν από την ενημέρωση των βαρών του.

```
model=create_model()
history=model.fit(x_scaled, y_trainval, validation_split=0.10,epochs=75,batch_size=20)
```

Στο τέταρτο στάδιο πραγματοποιήθηκε η αξιολόγηση του μοντέλου. Η απόδοση του μοντέλου, αξιολογήθηκε με την μέθοδο έρευνας πλέγματος σε συνδυασμό με τη διασταυρούμενη επικύρωση (grid search with cross validation) λόγω του περιορισμένου αριθμού δεδομένων (208 ηχητικές επιστροφές). Έπειτα, το μοντέλο με τις καλύτερες παραμέτρους αξιολογήθηκε σε άγνωστα δεδομένα δοκιμών (test data). Είναι χαρακτηριστικό ότι, η παραμετροποίηση του νευρωνικού δικτύου αποτελεί ένα δύσκολο εγχείρημα διότι δεν βασίζεται σε μια συγκεκριμένη μέθοδο αλλά στην έρευνα και στις δοκιμές σε συνδυασμό με το μεγάλο αριθμό παραμέτρων. Η διαδικασία της έρευνας πλέγματος με διασταυρούμενη επικύρωση, η οποία εκτελείται με σκοπό την διερεύνηση ενός ικανοποιητικού εύρους τιμών για κάθε παράμετρο συνεπάγεται μεγάλο χρόνο επεξεργασίας.

4. Αποτελέσματα-Ευρήματα

Στο παρόν κεφάλαιο παρουσιάζονται τα αποτελέσματα της μελέτης, η οποία βασίστηκε στην ταξινόμηση επιστροφών σημάτων σόναρ που συλλέχθηκαν από ένα μεταλλικό κύλινδρο και ένα κυλινδρικό σχήμα βράχου. Ένα σύνολο από 208 επιστροφές και συγκεκριμένα 111 επιστροφές από μεταλλικό κύλινδρο και 97 επιστροφές από βράχο, επιλέχθηκαν με βάση την ένταση της κατοπτρικής επιστροφής, έτσι όπως αποτυπώνονται και στην πρωταρχική μελέτη των Gorman & Sejnowski (1988). (βλ. *Σχήμα 17*)



Σχήμα 17. Ηχητικά σήματα Sonar


4.1 Ευρήματα με βάση τα ερευνητικά ερωτήματα

Παρακάτω παρουσιάζονται τα ευρήματα όσον αφορά τα ερωτήματα που τέθηκαν και σχετίζονται με την παρούσα μελέτη.

4.1.1 Ερευνητικό ερώτημα No1

Ποιός αλγόριθμος πέτυχε την καλύτερη απόδοση στην ταξινόμηση και αναγνώριση στόχων με βάση τα προς μελέτη δεδομένα;

Με βάση το πρώτο ερευνητικό ερώτημα, ο καθορισμός της καλύτερης απόδοσης όσον αφορά την ταξινόμηση και αναγνώριση στόχων από τη μελέτη ηχητικών επιστροφών σημάτων Sonar, βασίστηκε στην αξιοποίηση 14 αλγόριθμων μηχανικής εκμάθησης κατάλληλων για προβλήματα ταξινόμησης εποπτευόμενης μάθησης. Το σύνολο των αλγόριθμων που χρησιμοποιήθηκαν αξιολογήθηκε σε πρώτο στάδιο με διασταυρωμένη επικύρωση 10 ίσων πτυχών (10-Fold cross validation) και ως μέτρο αξιολόγησης τέθηκε το μέτρο της ακρίβειας (accuracy).



Σχήμα 18. Απόδοση αλγόριθμων

Στο παραπάνω ραβδόγραμμα, παρουσιάζεται ο βαθμός ακρίβειας (accuracy) των αλγόριθμων μηχανικής εκμάθησης με βάση το ποσοστό πρόβλεψης έπειτα από


το διαχωρισμό του συνόλου των δεδομένων (80% δεδομένα εκπαίδευσης, 20% δεδομένα δοκιμής) και εφαρμογής της τεχνικής της διασταυρούμενης επικύρωσης (cross validation). Από τους παραπάνω αλγόριθμους, ενδιαφέρον για περαιτέρω διερεύνηση, παρουσίασαν αυτοί που σημείωσαν τα μεγαλύτερα ποσοστά και είναι οι εξής: Gradient Boosting Classifier : 84.4% με 0.08 std (τυπική απόκλιση), Support Vector Classifier: 85.5% με 0.08 std, XG Boost Classifier: 88% και Gaussian Process Classifier: 88% με 0.09 std. Στους παραπάνω τέσσερις αλγόριθμους εφαρμόστηκε η τεχνική «grid search» σε συνδυασμό με την τεχνική «cross validation», με τις οποίες δοκιμάστηκε ένα επαρκές εύρος τιμών για την παραμετροποίηση των επιμέρους μεταβλητών τους με στόχο τη βελτίωση της απόδοσης τους. Παρακάτω, αναπτύσσεται αναλυτικά η διαδικασία διερεύνησης παραμετροποίησης για κάθε αλγόριθμο ξεχωριστά καθώς και τα τελικά τους αποτελέσματα.

Gradient Boosting Classifier

Οι βασικές παράμετροι του αλγόριθμου Gradient Boosting Classifier, ο οποίος ανήκει στην ευρύτερη κατηγορία μεθόδων συνόλου (ensemble methods) και των δέντρων αποφάσεων, είναι ο αριθμός των δέντρων που θα αναπτυχθούν (number of trees), ο αριθμός των χαρακτηριστικών (features) που θα ληφθούν υπόψη σε κάθε δέντρο απόφασης (n_estimators), το μέγιστο βάθος ανάπτυξης του δέντρου (max_depth), ο ρυθμός μάθησης (learning rate), ο οποίος ελέγχει τον βαθμό στον οποίο κάθε δέντρο επιτρέπεται να διορθώνει τα λάθη των προηγούμενων δέντρων και η συνάρτηση υπολογισμού σφάλματος (loss function) με την οποία επιλέγεται ποια συνάρτηση θα συμβάλει στον υπολογισμό σφάλματος του μοντέλου. (Muller & Guido, 2016; sklearn.ensemble.GradientBoostingClassifier, 2020) Τα αποτελέσματα ανέδειξαν ποσοστό ακρίβειας 86.2%, 2% περίπου μεγαλύτερο ποσοστό σε σχέση με πριν (84.4%) με τις εξής παραμέτρους:

```
Best: 0.862500 using {'learning_rate': 0.1, 'loss': 'deviance', 'max_depth': 3, 'n_estimators': 200}
```

Όσον αφορά την συμπεριφορά του αλγόριθμου στα δεδομένα δοκιμής (test data), το ποσοστό πρόβλεψης μειώθηκε στο 85.71% . Παρακάτω παρουσιάζεται ο πίνακας σύγκυσης (confusion matrix) (βλ. **Εικόνα 26**) καθώς και η αναφορά ταξινόμησης (classification report) στον **Πίνακα 2**.



Εικόνα 26. GBC Confusion matrix

	precision	recall	f1-score	support
Rock	0.94	0.75	0.83	20
Mine	0.81	0.95	0.88	22
accuracy			0.86	42
macro avg	0.87	0.85	0.85	42
weighted avg	0.87	0.86	0.86	42

Πίνακας 2 GBC Classification report

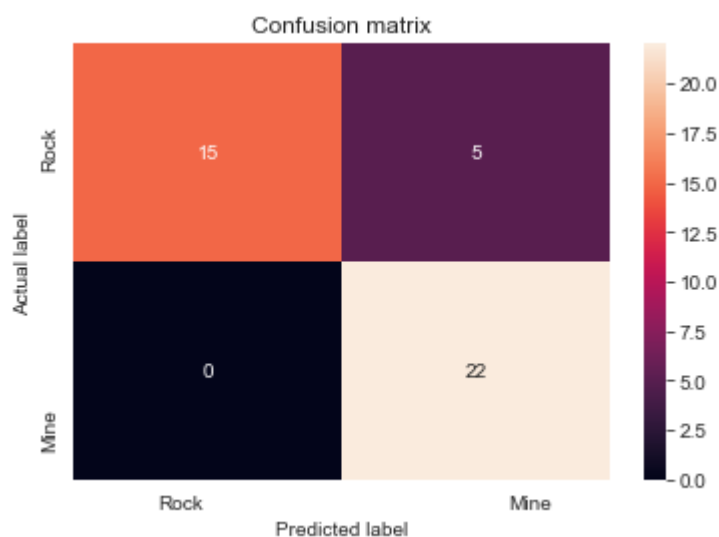
Support Vector Classifier

Οι παράμετροι που τέθηκαν υπό διερεύνηση για τον αλγόριθμο Support Vector Classifier αφορούν την παράμετρο C, η οποία είναι μια παράμετρος κανονικοποίησης (regularization), παρόμοια με αυτήν που χρησιμοποιείται στα γραμμικά μοντέλα και περιορίζει τη σημασία κάθε σημείου (L2 penalty). Επιπλέον, η παράμετρος Kernel, η οποία καθορίζει τον τύπο του πυρήνα που θα

χρησιμοποιηθεί στον αλγόριθμο και επιλέγεται μια από τις ενδείξεις "linear", "poly", "rbf", "sigmoid", "precomputed" . Η τελευταία παράμετρος αποτελεί το ιδιαίτερο χαρακτηριστικό του μοντέλου αυτού, η οποία επιτρέπει στο μοντέλο ταξινόμησης να μαθαίνει από τα δεδομένα σε μια υψηλότερη διάσταση-χώρο χωρίς να υπολογίζει στην πράξη τη νέα, πιθανώς πολύ μεγάλη αναπαράσταση. Αυτό είναι γνωστό ως τεχνική πυρήνα (kernel trick) και λειτουργεί υπολογίζοντας απευθείας την απόσταση των σημείων των δεδομένων για την εκτεταμένη αναπαράσταση των χαρακτηριστικών, χωρίς να υπολογίζει ποτέ την επέκταση. Ο αλγόριθμος απέδωσε ποσοστό 91% με 0.08 std με τις εξής τιμές παραμέτρων:

Best: 0.910662 using {'C': 10, 'kernel': 'rbf'}

Η απόδοση του αλγόριθμου στα άγνωστα δεδομένα δοκιμής (test data), συγκέντρωσε ποσοστό πρόβλεψης 88%. Παρακάτω παρουσιάζεται ο πίνακας σύγχυσης (confusion matrix) του μοντέλου (βλ. **Εικόνα 27**) καθώς και η αναφορά ταξινόμησης (classification report) στον Πίνακα 3.



Εικόνα 27 SVC Confusion matrix

	precision	recall	f1-score	support
Rock	1.00	0.75	0.86	20
Mine	0.81	1.00	0.90	22
accuracy			0.88	42
macro avg	0.91	0.88	0.88	42
weighted avg	0.90	0.88	0.88	42

Πίνακας 3 SVC Classification report


XG Boost Classifier

Οι παράμετροι του XG Boost Classifier είναι ο αριθμός των δέντρων που θα αναπτυχθούν (number of trees), ο αριθμός των χαρακτηριστικών (features) που θα ληφθούν υπόψη σε κάθε δέντρο απόφασης (n_estimators), το μέγιστο βάθος ανάπτυξης του δέντρου (max_depth), ο ρυθμός μάθησης (learning rate) ο οποίος ελέγχει τον βαθμό στον οποίο κάθε δέντρο επιτρέπεται να διορθώνει τα λάθη των προηγούμενων δέντρων, min_child_weight το οποίο σταματά τον διαχωρισμό σε ένα κόμβο όταν το μέγεθος του δείγματος φτάσει κάτω από ένα καθορισμένο όριο και το colsample_by_tree το οποίο είναι παρόμοιο με την παράμετρο max_features. Δηλώνει το κλάσμα των στηλών να είναι τυχαία δείγματα για κάθε δέντρο. Ανήκει και αυτός στην κατηγορία των μεθόδων συνόλου (ensemble methods) και των δέντρων αποφάσεων (decision trees). Τα αποτελέσματα του αλγόριθμου με βάση την καλύτερη απόδοση μετά από την έρευνα πλέγματος (grid search with cross validation) σημείωσαν ποσοστό ακρίβειας πρόβλεψης 88.5% με τις εξής παραμέτρους:

Best: 0.885662 using {'colsample_bytree': 0.3, 'learning_rate': 0.1, 'max_depth': 4, 'min_child_weight': 1, 'n_estimators': 100}

Επιπλέον, η απόδοση του αλγόριθμου στα άγνωστα δεδομένα δοκιμής (test data), συγκέντρωσε ποσοστό πρόβλεψης 83.3% , απόδοση μικρότερη από αυτή της επικύρωσης. Παρακάτω παρουσιάζεται ο πίνακας σύγχυσης (confusion matrix) του

μοντέλου (βλ. **Εικόνα 28**) καθώς και η αναφορά ταξινόμησης (classification report) στον **Πίνακα 4**.



Εικόνα 28 XG Boost Confusion matrix

	precision	recall	f1-score	support
Rock	0.93	0.70	0.80	20
Mine	0.78	0.95	0.86	22
accuracy			0.83	42
macro avg	0.86	0.83	0.83	42
weighted avg	0.85	0.83	0.83	42

Πίνακας 4 XG Boost Classification report


Gaussian Process Classifier

Ο αλγόριθμος αυτός είναι μια γενίκευση της κατανομής πιθανοτήτων του Gauss και μπορεί να χρησιμοποιηθεί ως βάση για εξελιγμένους, μη παραμετρικούς αλγόριθμους μηχανικής μάθησης για ταξινόμηση. Οι βασικές παράμετροι που χρησιμοποιήθηκαν για διερεύνηση είναι: `max_iter_predict`, `optimizer`, `n_restarts_optimizer`, `kernel`. Η παράμετρος η οποία επηρέασε την απόδοση του αλγόριθμου ήταν η `kernel`. Με την παράμετρο αυτή υπολογίζεται η συνδιακύμανση

του μοντέλου μεταξύ των σημείων των δεδομένων.(Analytics Vidhya, 2016) Το παραπάνω μοντέλο απέδωσε 88% με τις εξής τιμές παραμέτρων:

Best: 0.879412 using {'kernel': 1**2 * RBF(length_scale=1), 'max_iter_predict': 50, 'n_restarts_optimizer': 0, 'optimizer': None}

Η απόδοση του αλγόριθμου στα άγνωστα δεδομένα δοκιμής (test data), συγκέντρωσε ποσοστό πρόβλεψης 81%, απόδοση μικρότερη από αυτή της επικύρωσης. Παρακάτω, παρουσιάζεται ο πίνακας σύγχυσης (confusion matrix) του μοντέλου (βλ. **Εικόνα 29**) καθώς και η αναφορά ταξινόμησης (classification report) στον **Πίνακα 5**.




Εικόνα 29. GPC Confusion matrix

	precision	recall	f1-score	support
Rock	0.88	0.70	0.78	20
Mine	0.77	0.91	0.83	22
accuracy			0.81	42
macro avg	0.82	0.80	0.81	42
weighted avg	0.82	0.81	0.81	42

Πίνακας 5. GPC Classification report

Συνοψίζοντας, λαμβάνοντας υπόψη όλη την παραπάνω διαδικασία βελτίωσης της απόδοσης των αλγόριθμων, παρατηρείται ότι ο “Support vector Classifier” έδωσε τα καλύτερα αποτελέσματα με ποσοστό πρόβλεψης 88% στα άγνωστα δεδομένα δοκιμής (test data) έναντι των υπόλοιπων μοντέλων, τα οποία σημείωσαν 83% (XG Boost Classifier), 85% (Gradient Boosting Classifier) και 81%(Gaussian Process Classifier) έτσι όπως φαίνεται στο παρακάτω διάγραμμα. (βλ. *Σχήμα 19*)



Σχήμα 19. Συνολική επίδοση τελικών μοντέλων

4.1.2 Ερευνητικό ερώτημα No2

Ποιες τεχνικές προεπεξεργασίας (preprocessing) συμβάλουν στην επιδίωξη αυτή;

Το παρόν ερευνητικό ερώτημα αποτελεί υποκατηγορία του προηγούμενου ερωτήματος διότι συμπεριλήφθηκε στην διαδικασία επιλογής του μοντέλου εκείνου με την καλύτερη απόδοση σχετικά με την διαμόρφωση της ταξινόμησης των ηχητικών σημάτων sonar που αφορούν αντικείμενο της παρούσας μελέτης. Επιπλέον, μεγάλο μέρος της διαδικασίας προεπεξεργασίας των δεδομένων αναφέρεται αναλυτικά στο κεφάλαιο 3.3.2 κατά την φάση ανάπτυξης του δεύτερου σταδίου της συλλογής και ανάλυσης δεδομένων. Παρόλα αυτά κρίθηκε σκόπιμο να παρουσιαστούν τα αποτελέσματα που φανερώνουν την βελτίωση της απόδοσης των

μοντέλων και απορρέουν από την κατάλληλη επιλογή τεχνικών προεπεξεργασίας (preprocessing) και μετασχηματισμού (data transformation) των δεδομένων σε ένα ξεχωριστό ερευνητικό ερώτημα.

Στο σύνολο τους η απόδοση των αλγόριθμων δοκιμάστηκε με 3 διαφορετικούς μετασχηματισμούς δεδομένων. Αρχικά αξιοποιήθηκε η γνήσια μορφή τους, έπειτα χρησιμοποιήθηκε η τεχνική κανονικοποίησης (Standard Scaler), η τεχνική μετασχηματισμού Yeo-Johnson και τέλος ο συνδυασμός των δύο τελευταίων. Τα αποτελέσματα απόδοσης των αλγόριθμων με βάση τον βαθμό ακρίβειας (accuracy) παρουσιάζονται στον παρακάτω πίνακα:

Out [53]:

	original	Standard scaler	yeo-johnson	Std scaler & yj
LR	0.771691	0.802574	0.796324	0.802574
LDA	0.754044	0.784191	0.784191	0.784191
KNN	0.771691	0.795588	0.789338	0.795588
DTC	0.748162	0.669485	0.716912	0.699632
NB	0.717647	0.754044	0.754044	0.754044
SVC	0.559559	0.855147	0.855147	0.855147
QDA	0.694118	0.699265	0.693750	0.699265
ABC	0.826838	0.826838	0.826838	0.826838
RFC	0.802574	0.825735	0.813971	0.843750
GPC	0.807353	0.885294	0.885294	0.885294
LINSVC	0.766544	0.778309	0.784191	0.778309
GBooSTC	0.844853	0.868015	0.844485	0.856618
ET	0.873529	0.802206	0.814706	0.843750

Πίνακας 6 Αποτελέσματα με βάση τον μετασχηματισμό των δεδομένων

Παρατηρώντας τον **Πίνακα 6**, διακρίνουμε βελτιώσεις στις αποδόσεις των αλγόριθμων με βάση τον μετασχηματισμό των δεδομένων συγκρινόμενα με τις αποδόσεις τους πριν το μετασχηματισμό. Τα ποσοστά των αλγόριθμων στην πλειοψηφία τους έχουν αυξηθεί κατά 3% πλην του Support Vector Classifier ο οποίος βελτιώθηκε κατά 30%. Αξίζει να σημειωθεί ότι σε ορισμένους αλγόριθμους όπως ο SVC, τα γραμμικά μοντέλα ή τα νευρωνικά δίκτυα, στους οποίους ο

υπολογισμός βασίζεται σε ευκλείδειες αποστάσεις, η απαίτηση για κανονικοποίηση (standardization) είναι καθοριστικής σημασίας, διότι υπάρχει ομαλοποίηση των τιμών των δεδομένων. Από την άλλη πλευρά, άλλες κατηγορίες αλγόριθμων όπως στα δέντρα αποφάσεων δεν υπάρχει αυτή η απαίτηση. Άλλοτε ένας μετασχηματισμός στα δεδομένα ωφελεί και άλλοτε όχι. Σημαντικός παράγοντας σε αυτή την περίπτωση αποτελεί η μέθοδος «δοκιμή και σφάλμα» (trial and error). Επιπλέον, στο παραπάνω διάγραμμα, οι αποδόσεις μεταξύ των διαφορετικών μετασχηματισμών δεν διαφέρουν κατά πολύ μεταξύ τους. Στην ερευνητική διαδικασία βελτίωσης των μοντέλων επιλέχθηκε η τεχνική Yeο-Johnson, διότι παρουσίασε καλύτερη διακύμανση στα δεδομένα σύμφωνα με την **Εικόνα 20 (κεφ. 3.3.1)**, μείωσε τη λοξότητα των κατανομών των επιμέρους χαρακτηριστικών των δεδομένων προσεγγίζοντας περισσότερο την κανονική κατανομή του Gauss (βλ. **Εικόνα 21**) και έδωσαν καλύτερα αποτελέσματα στην μετέπειτα επεξεργασία των αλγόριθμων με βάση την απόδοση σε σχέση με τις υπόλοιπες τεχνικές του **Πίνακα 6** με τη μέθοδο «δοκιμή και σφάλμα».

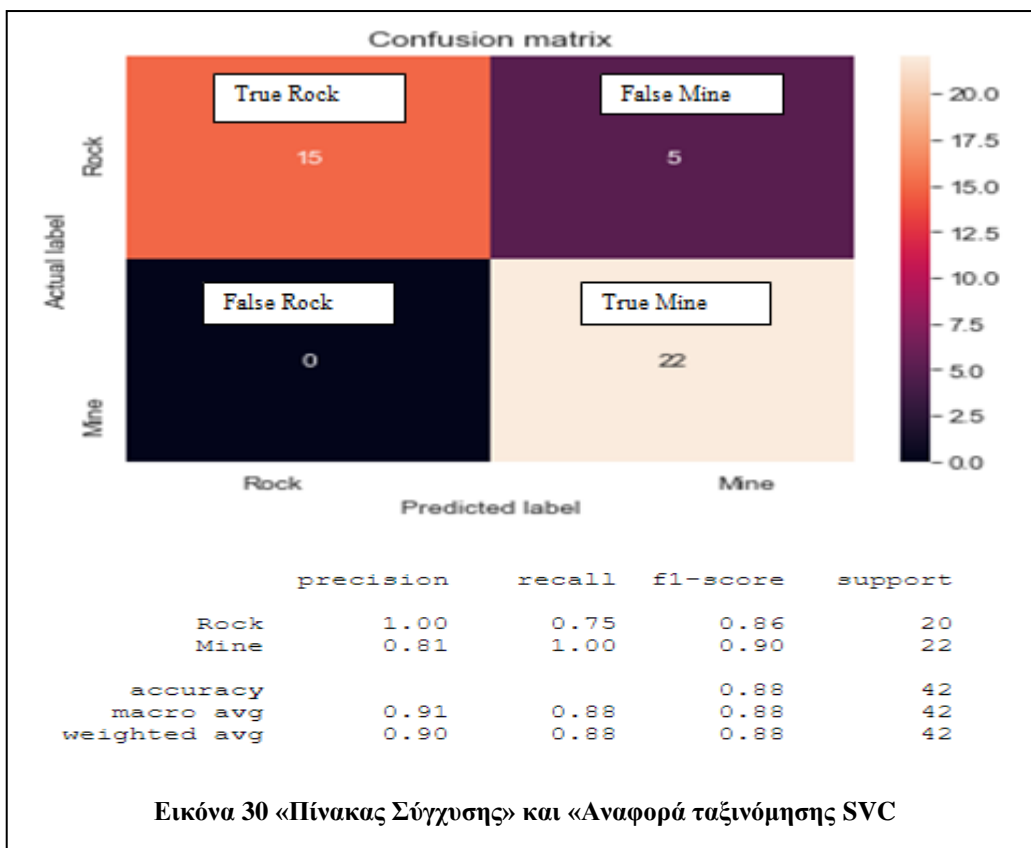
4.1.3 Ερευνητικό ερώτημα No3

Πώς μπορεί να βελτιωθεί ο παραπάνω αλγόριθμος ώστε να προβλέπει τις μεταλλικές επιφάνειες έναντι των βράχων;

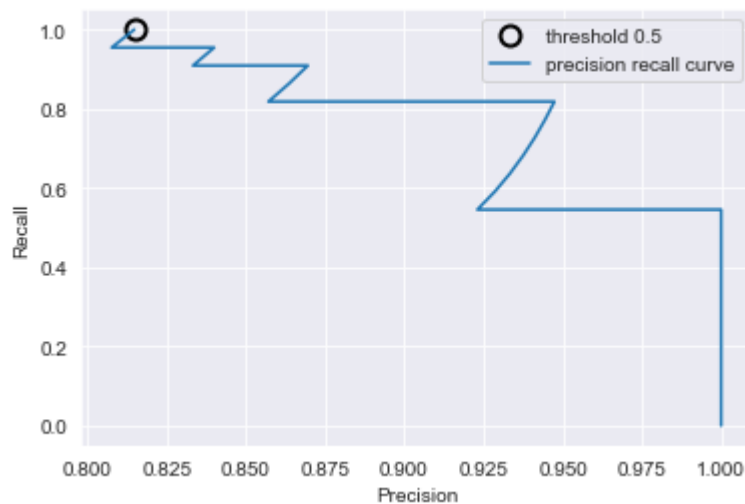
Σύμφωνα με τα δύο παραπάνω ερευνητικά ερωτήματα, την καλύτερη απόδοση σε ποσοστό ακρίβειας πρόβλεψης σημείωσε ο αλγόριθμος Support Vector Machine. Για τη διάγνωση του μοντέλου αυτού ώστε να προβλέπει κυρίως τις μεταλλικές επιφάνειες έναντι των βράχων, απαιτείται ένα αναλυτικότερο μέτρο αξιολόγησης από αυτό της ακρίβειας (accuracy). Το μέτρο του «πίνακα σύγχυσης» (confusion matrix) παρέχει μια σαφέστερη εικόνα όσον αφορά τις σωστές και τις λανθασμένες προβλέψεις του μοντέλου σε σχέση με τις δύο κλάσεις των δεδομένων, δηλαδή αυτή της μεταλλικής επιφάνειας και αυτή του βράχου. Στην **Εικόνα 30** αποτυπώνεται ο «πίνακας σύγχυσης» του αλγόριθμου SVC, στον οποίο παρουσιάζονται τα αποτελέσματα πρόβλεψης. Παρατηρείται λοιπόν ότι ο αλγόριθμος προέβλεψε σωστά 15 τιμές της κλάσης «Βράχος», ενώ 5 τιμές

ταξινομήθηκαν λάθος στην κλάση «Μεταλλική επιφάνεια» (Mine), ενώ όσον αφορά τη κλάση «Μεταλλική επιφάνεια» προέβλεψε σωστά και τις 22 τιμές που ανήκαν στην κλάση αυτή. Η παραπάνω διαπίστωση επιβεβαιώνεται και από την αναφορά ταξινόμησης (classification report). Με βάση αυτή, διαφαίνεται ότι για την κλάση «Μεταλλική επιφάνεια» (Mine) το επιμέρους μέτρο «recall», το οποίο μετράει πόσα από τα δείγματα της «Μεταλλικής επιφάνειας» καλύπτονται από τις προβλέψεις του μοντέλου σύμφωνα με την κλάση αυτή, έχει τιμή 1.00. Αυτό σημαίνει ότι η κλάση αυτή καλύπτεται από τις προβλέψεις του αλγόριθμου και ότι ο αλγόριθμος έχει την τάση να προβλέπει αρκετά σωστά στόχους και επιστροφές σημάτων που προέρχονται από μεταλλικές επιφάνειες έναντι των βράχων. Επιπλέον, η παραπάνω διαπίστωση αποδεικνύεται και από το μέτρο «precision», το οποίο σκοπός του είναι να περιοριστεί ο αριθμός των False Rock, ο οποίος είναι 0 σύμφωνα με την **Εικόνα 30** και για αυτό το λόγο η τιμή precision για την κλάση βράχο» είναι 1.00 .

Ο πίνακας σύγχυσης και η αναφορά ταξινόμησης παρέχουν μια πολύ λεπτομερή ανάλυση για ένα συγκεκριμένο σύνολο προβλέψεων. Ωστόσο, οι ίδιες οι προβλέψεις αδυνατούν να αναδείξουν αρκετές πληροφορίες που περιέχονται στο μοντέλο και καθορίζουν τον τρόπο με τον οποίο προβλέπει και στην συγκεκριμένη




περίπτωση τον τρόπο πρόβλεψης μεταξύ δύο κλάσεων.(Muller & Guido, 2016) Στο κεφάλαιο 3.3.2, στο κομμάτι των μέτρων αξιολόγησης αναφέρεται ένα ενδιαφέρον εργαλείο το οποίο αξιολογεί την ικανότητα των ταξινομητών να παρέχουν εκτιμήσεις αβεβαιότητας των προβλέψεων. Η πληροφορία αυτή παρέχεται ευκολότερα με την αναπαράσταση της καμπύλης Precision- Recall και την καμπύλη ROC. Στα παρακάτω διαγράμματα παρουσιάζονται οι καμπύλες αυτές καθώς και τα και τα κατώτερα όρια επιλογής (thresholds) του αλγόριθμου SVC.(βλ. *Σχήμα 20, 21*)



Σχήμα 20 Precision-Recall curve

Στην παραπάνω καμπύλη *Σχήμα 20*, αποτυπώνονται όλα τα πιθανά κατώτατα όρια (thresholds) ή όλες οι πιθανές σχέσεις Precision-Recall σε μια γραμμή (μπλε). Παρατηρείται ότι το κατώφλι του SVC αλγόριθμου βρίσκεται πάνω αριστερά της καμπύλης, δηλαδή στο σημείο όπου το Recall= 1.0 και το Precision= 0.81 έτσι όπως επιβεβαιώνεται και από την αναφορά ταξινόμησης της *Εικόνας 30*. Όσο πιο κοντά παραμένει μια καμπύλη στην επάνω δεξιά γωνία, τόσο καλύτερη είναι η ταξινόμηση. Ένα σημείο στην πάνω δεξιά γωνία σημαίνει υψηλό Precision και υψηλό Recall για το ίδιο κατώφλι. Η καμπύλη ξεκινά στην επάνω αριστερή γωνία, που αντιστοιχεί σε ένα πολύ χαμηλό κατώφλι, ταξινομώντας τα πάντα ως κλάση «μεταλλική επιφάνεια» (αρνητική κλάση). Η αύξηση του κατωφλίου μετακινεί την καμπύλη προς τιμές υψηλότερου Precision, αλλά και σε τιμές χαμηλότερου Recall. Αυξάνοντας το κατώφλι όλο και περισσότερο, φτάνουμε σε μια κατάσταση όπου τα περισσότερα από τα σημεία που χαρακτηρίζονται ως αρνητικά

είναι αληθή αρνητικά, οδηγώντας σε πολύ υψηλό Precision αλλά χαμηλότερο Recall. Όσο περισσότερο το μοντέλο έχει υψηλό Precision και το Recall ανεβαίνει, τόσο το καλύτερο. Στο παρόν διάγραμμα παρατηρείται ότι το προεπιλεγμένο κατώφλι του μοντέλου βρίσκεται σε αρκετά υψηλό recall και σε χαμηλότερο precision όσον αφορά την κλάση της μεταλλικής επιφάνειας (αρνητική κλάση). Αυτό συνεπάγεται ότι ο αλγόριθμος προεβλέψε όλα τα δείγματα που αφορούσαν την κλάση μεταλλική επιφάνεια σωστά. Βέβαια παρατηρείται επίσης ότι και το precision του SVC αλγόριθμου έχει τιμή 0.81, που σημαίνει ότι για την κλάση της μεταλλικής επιφάνειας το 81% του ποσοστού των δειγμάτων που προβλέφθηκαν για την κλάση αυτή από τον αλγόριθμο είναι και τα σωστά, διότι υπήρχαν 5 δείγματα που προβλέφθηκαν λάθος και ανήκουν στην κλάση του «βράχου» (θετική κλάση). (βλ. **Εικόνα 30**) Αυτή η διαπίστωση επιβεβαιώνεται και από το παρακάτω διάγραμμα στο οποίο φαίνεται ότι εκτός από υψηλό Recall έχουμε και υψηλό False negative rate.




Σχήμα 21 ROC curve

Συνοψίζοντας, για την καλύτερη συνολική απόδοση του αλγόριθμου θα πρέπει να επιλεγεί ένα κατώτερο όριο επιλογής (threshold), το οποίο να αντικατοπτρίζει την καλύτερη δυνατή σχέση τιμών Precision-Recall με βάση το προς μελέτη διάγραμμα. Αξίζει να σημειωθεί ότι η ρύθμιση του ορίου αυτού δεν θα πρέπει να εκτελεστεί στα δεδομένα δοκιμών (test data) αλλά στα δεδομένα επικύρωσης (validation data).

4.1.4 Ερευνητικό ερώτημα No4

Πώς μπορεί να βελτιωθεί η ταξινόμηση και η αναγνώριση των στόχων με τη χρήση νευρωνικών δικτύων στα προς μελέτη δεδομένα;

Το νευρωνικό δίκτυο, το οποίο λειτούργησε αποδοτικότερα όσον αφορά το σύνολο των δεδομένων της παρούσας μελέτης κατόπιν διερεύνησης και δοκιμών διαφορετικών επιπέδων εισόδων, ενδιάμεσων επιπέδων και εξόδων έχει την παρακάτω μορφή. (βλ. *Εικόνα 31*)



Εικόνα 31 Αρχιτεκτονική νευρωνικού δικτύου

Οι τιμές των παραμέτρων του νευρωνικού δικτύου που αξιοποιήθηκαν στην έρευνα πλέγματος (grid search) και συνέβαλαν στην καλύτερη απόδοση του είναι οι εξής :

- batch_size= 75
- epochs= 20

- kernel_initializer= 'uniform'
- optimizer= 'adam'
- kernel_constraint= maxnorm(2)
- dropout_rate= 0.2
- activation (output layer)= 'sigmoid'
- activation (input, hidden layer)= 'relu'
- loss= 'cross entropy'
- metrics= 'accuracy'

Η απόδοση του νευρωνικού δικτύου σε ποσοστά πρόβλεψης σημείωσε ακρίβεια 98.4% στο σετ επικύρωσης (validation test- 10%) και 95.2 % στο σετ δοκιμών (test data- 10%) (βλ. Εικόνα 32)

```
Epoch 73/75
168/168 [=====] - 0s
161us/step - loss: 0.0227 - accuracy: 0.9940 -
val_loss: 0.6524 - val_accuracy: 0.8947
Epoch 74/75
168/168 [=====] - 0s
226us/step - loss: 0.0286 - accuracy: 0.9881 -
val_loss: 0.7306 - val_accuracy: 0.8421
Epoch 75/75
168/168 [=====] - 0s
101us/step - loss: 0.0262 - accuracy: 0.9881 -
val_loss: 0.7884 - val_accuracy: 0.8421
Train acc: 0.984, Test acc: 0.952
```

Εικόνα 32 Αποτελέσματα τελικού νευρωνικού δικτύου

Όσον αφορά την επιλογή των μονάδων εισόδου, των ενδιάμεσων επιπέδων-μονάδων και των μονάδων εξόδου, πραγματοποιήθηκε πληθώρα δοκιμών και συνδυασμών στοχεύοντας στον συνδυασμό εκείνο με την καλύτερη μέση απόδοση μέσω των αποτελεσμάτων ακρίβειας της διασταυρούμενης επικύρωσης. Στον παρακάτω **Πίνακα 7** παρουσιάζονται ορισμένα πρωταρχικά παραδείγματα διερεύνησης διάφορων επιπέδων νευρωνικού δικτύου.

Αριθμός μονάδων εισόδου	Αριθμός μονάδων ενδιάμεσων επιπέδων	Μέση απόδοση στο σετ επικύρωσης (%)	Τυπική απόκλιση στο σετ επικύρωσης (%)	Παράμετροι Epochs Batches
60	23	89%	5.9%	150 5
60	18	89%	8.03%	200 5
55	1 ^ο layer: 23 2 ^ο layer: 18	90.1%	7%	100 2
55	1 ^ο layer: 23 2 ^ο layer: 18 3 ^ο layer: 20	90.2	8.7%	100 2

Πίνακας 7 Διερεύνηση επιπέδων νευρωνικού δικτύου

Έπειτα πραγματοποιήθηκε έρευνα πλέγματος με διασταυρούμενη επικύρωση, δοκιμάζοντας κάθε φορά ένα επαρκές εύρος τιμών σε συγκεκριμένες παραμέτρους. Στο πρώτο στάδιο διερεύνησης επιλέχθηκαν οι παράμετροι epochs και batch_size. Ενδεικτικά παρουσιάζονται τα καλύτερα αποτελέσματα και επιμέρους συνδυασμοί των παραμέτρων

Epochs: 300,250,200,180 ,150,120,100,80,70	Batch size: 1,2,5,7,9,15,20,25,30,50,	Μέση απόδοση στο σετ επικύρωσης (%)	Τυπική απόκλιση στο σετ επικύρωσης (%)
300	30	90,2%	7%
250	1	91%	9%
200	20	89.6%	9%
120	20	90.2%	8%

Στο δεύτερο στάδιο διερεύνησης επιλέχθηκαν οι τιμές με την καλύτερη απόδοση από το πρώτο στάδιο για της παραμέτρους epochs και batch_size και προστέθηκε η παράμετρος optimizers.

Epochs: 300,250,200,180 ,150,120,100,80,70	Batch size: 1,2,5,7,9,15,20 ,25,30,50,	Optimizers: Adadelta, Rmsprop, Adam, SGD, Adagrad, Adamax, Nadam	Μέση απόδοση στο σετ επικύρωσης (%)	Τυπική απόκλιση στο σετ επικύρωσης (%)
80	5	Adadelta	92%	10%
70	1	Nadam	90%	10%
250	1	Adadelta	90.8%	9%
80	1	Adam	90.2%	11%

Τέλος, στο τρίτο στάδιο επιλέχθηκαν οι παράμετροι activation, kernel_initializer, dropout_rate, kernel_constraint. Η καλύτερη απόδοση του νευρωνικού δικτύου σημειώθηκε σε ποσοστό 92.7% με τυπική απόκλιση 9% με τις εξής παραμέτρους:

Best: 0.927206 using {'mlperceptron__activation': 'sigmoid',
'mlperceptron__batch_size': 5, 'mlperceptron__dropout_rate': 0.2,
'mlperceptron__epochs': 80, 'mlperceptron__kernel_initializer': 'normal',
'mlperceptron__optimizer': 'rmsprop', 'mlperceptron__weight_constraint': 2}

4.2 Κριτική ανάλυση αποτελεσμάτων – Σύνοψη

Στην παρούσα ενότητα παρουσιάζεται η σύνοψη των ευρημάτων της έρευνας, έτσι όπως πρόεκυψαν από την μελέτη της απόδοσης μοντέλων μηχανικής εκμάθησης και νευρωνικών δικτύων, όσον αφορά την επεξεργασία, αναγνώριση και ταξινόμηση στόχων που προέρχονται από υπερηχητικά σήματα Sonar.. Σκοπός της ενότητας αυτής, αφορά την κριτική θεώρηση των αποτελεσμάτων τα οποία αποτέλεσαν πηγή δεδομένων για τη συστηματική τεκμηρίωση των απαντήσεων των ερευνητικών ερωτημάτων.

Όσον αφορά τη σημασία των αποτελεσμάτων αξίζει να σημειωθούν οι βασικοί άξονες του θεωρητικού πλαισίου από τους οποίους καθοδηγήθηκε η έρευνα:

- Ανάπτυξη αλγόριθμων μηχανικής εκμάθησης ως εργαλείο βελτίωσης εφαρμογών με στόχο την επίλυση συγκεκριμένου προβλήματος. Σκοπός της μηχανικής μάθησης, η οποία συγκαταλέγεται στην τεχνητή νοημοσύνη, είναι ο σχεδιασμός και η ανάπτυξη αλγορίθμων που επιτρέπουν στους υπολογιστές να αναπτύξουν συμπεριφορές με βάση εμπειρικά δεδομένα». (Fossaceca & Young, 2018)
- Αξιοποίηση και επεξεργασία υπερηχητικών σημάτων Sonar. Οι εφαρμογές του εκτείνονται σε ένα μεγάλο υδάτινων κυρίως δραστηριοτήτων. Το σύστημα αυτό αξιοποιεί τη διάδοση ήχου για τη μεταφορά σημάτων και ως μέσο το νερό για πλοήγηση, επικοινωνία ή ανίχνευση αντικειμένων πάνω ή κάτω από την επιφάνεια του νερού.
- Ανάπτυξη νευρωνικού δικτύου ως εναλλακτικό εργαλείο επίλυσης εφαρμογών σε ζητήματα όπως η λήψη αποφάσεων, την ταχύτητα επεξεργασίας και τον ανθρώπινο παράγοντα (human factor). Τα νευρωνικά δίκτυα έχουν δημιουργηθεί με τρόπο τέτοιο ώστε να μιμούνται την λειτουργία του ανθρώπινου εγκεφάλου. Η λειτουργία αυτή, προσεγγίζει τα διάφορα προβλήματα χρησιμοποιώντας επίπεδα αλληλοσυνδεδεμένων μονάδων, μαθαίνοντας και συνάγοντας σχέσεις με βάση τα παρατηρούμενα δεδομένα.

Λαμβάνοντας υπόψη τα ευρήματα της έρευνας τα οποία εξήχθησαν με βάση τα τέσσερα ερευνητικά ερωτήματα που τέθηκαν, παρατηρείται ότι για το πρώτο ερώτημα το οποίο εστιάζει στην επίλυση του αλγόριθμου μηχανικής εκμάθησης με την καλύτερη απόδοση, όσον αφορά την ταξινόμηση και αναγνώριση στόχων με βάση τις επιστροφές υπερηχητικών σημάτων sonar, ο αλγόριθμος Support Vector Classifier σημείωσε ποσοστό 85.5% στο αρχικό στάδιο εφαρμογής του. Έπειτα από

κατάλληλη επεξεργασία και διαδικασία παραμετροποίησης, το ποσοστό βελτιώθηκε σε ποσοστό ακρίβειας 91% με τη μέθοδο «grid search with cross validation» ενώ η απόδοση του μοντέλου σε άγνωστα δεδομένα δοκιμών (test data), κατέλαβε ποσοστό ακρίβειας 88%. Το ποσοστό αυτό επιβεβαιώνεται και από τα μετρικά αξιολόγησης «confusion matrix» και «classification report», τα οποία παρουσίασαν ότι από το σύνολο των 42 δειγμάτων (20% του συνολικού δείγματος) των δεδομένων δοκιμής (test data), μόνο 5 δείγματα ταξινομήθηκαν σε λάθος κλάση (ανήκαν στη κλάση του «Βράχος» και ταξινομήθηκαν στην κλάση της «Μεταλλικής επιφάνειας» -False Negative- σφάλμα τύπου No II). Επιπλέον, το επιμέρους μετρικό Recall, το οποίο μετρά πόσα από τα θετικά δείγματα συλλαμβάνονται από τις θετικές προβλέψεις, όσον αφορά την κλάση «Βράχος», η οποία στην προκείμενη μελέτη αντιπροσωπεύει την θετική κλάση του «πίνακα σύγκρισης», σημείωσε ποσοστό 85% το οποίο επιβεβαιώνει την λανθασμένη πρόβλεψη του SVC μοντέλου των 5 δειγμάτων.

Όσον αφορά το ερευνητικό ερώτημα 2 σχετικά με το ποιες τεχνικές προεπεξεργασίας (preprocessing) συμβάλουν στην επιδίωξη του μοντέλου με την καλύτερη απόδοση, σημαντικό στοιχείο στην ερευνητική διαδικασία βελτίωσης των μοντέλων ήταν η τεχνική μετασχηματισμού Yeo-Johnson, διότι παρουσίασε μικρότερη διακύμανση στα δεδομένα σύμφωνα με την *Εικόνα 20*, μείωσε τη λοξότητα των κατανομών των επιμέρους χαρακτηριστικών (features) των δεδομένων προσεγγίζοντας περισσότερο την κανονική κατανομή του Gauss (βλ. *Εικόνα 21*) και έδωσε καλύτερα αποτελέσματα στην μετέπειτα επεξεργασία των αλγόριθμων με βάση την απόδοση σε σχέση με τις υπόλοιπες τεχνικές του *Πίνακα 6* με τη μέθοδο «δοκιμή και σφάλμα». Η διακύμανση είναι η μεταβλητότητα της πρόβλεψης ενός μοντέλου για ένα δεδομένο σημείο δεδομένων ή μια τιμή που μας λέει την εξάπλωση των δεδομένων μας. Το μοντέλο με μεγάλη διακύμανση, δίνει μεγάλη προσοχή στα δεδομένα εκπαίδευσης και δεν γενικεύει τα δεδομένα που δεν έχει ξαναδεί. Ως αποτέλεσμα, τέτοια μοντέλα αποδίδουν πολύ καλά στα δεδομένα εκπαίδευσης αλλά έχουν υψηλά ποσοστά σφάλματος (error) στα δεδομένα δοκιμών.(Singh, 2018) Η επιδίωξη στην παρούσα μελέτη, ήταν αφενός ο υψηλός βαθμός γενικευσιμότητας αναλογιζόμενος πάντα με το μικρότερο βαθμό σφάλματος πρόβλεψης των μοντέλων (bias).

Επιπλέον είναι χαρακτηριστικό ότι πολλοί αλγόριθμοι μηχανικής μάθησης αποδίδουν καλύτερα όταν η κατανομή των μεταβλητών είναι γκαουσιανή (Gaussian). Ορισμένοι αλγόριθμοι, όπως η γραμμική παλινδρόμηση και η λογιστική παλινδρόμηση προϋποθέτουν ρητά ότι οι μεταβλητές πρέπει να ακολουθούν την κατανομή Gauss. Άλλοι μη γραμμικοί αλγόριθμοι ενδέχεται να μην προαπαιτούν αυτήν την υπόθεση, αλλά συχνά αποδίδουν καλύτερα όταν οι μεταβλητές έχουν αυτή την κατανομή.(Brownlee, 2020a)

Ως προς την ερμηνεία του τρίτου ερευνητικού ερωτήματος, η οποία διερευνά πώς μπορεί να βελτιωθεί ο παραπάνω αλγόριθμος ώστε να προβλέπει τις μεταλλικές επιφάνειες έναντι των βράχων, παρατηρήθηκε ότι τα αποτελέσματα του SVC αλγόριθμου όσον αφορά τα δεδομένα δοκιμής (test data) με βάση την **Εικόνα 30 «Πίνακας Σύγκρισης» και «Αναφορά ταξινόμησης SVC»** και την ανάλυση που αναπτύχθηκε στο κεφάλαιο 4.1.3, απαντούν επαρκώς το παραπάνω ερώτημα αλλά απαιτείται να υπογραμμιστούν ορισμένα σημαντικά σημεία. Το συνολικό δείγμα των υπερηχητικών σημάτων sonar, αποτελεί ένα μικρό δείγμα και αυτός ο παράγοντας πιθανόν να αποτελεί μειονέκτημα όσον αφορά την αντικειμενικότητα των αποτελεσμάτων. Επιπλέον, το δείγμα δοκιμής (test data) το οποίο ξεχωρίζει από τα υπόλοιπα δεδομένα εκπαίδευσης είναι ακόμα μικρότερο (42 δείγματα), γεγονός το οποίο υποδηλώνει ότι με μεγαλύτερο αριθμό δεδομένων δοκιμής το αποτέλεσμα ταξινόμησης θα ήταν διαφορετικό. Παρόλα αυτά, λήφθηκαν υπόψη ορισμένοι τεχνικοί παράγοντες όσο το δυνατόν αντικειμενικότερης εφαρμογής τυχαιότητας επιλογής και διαχωρισμού του συνόλου των δεδομένων ώστε τα αποτελέσματα απόδοσης των μοντέλων να παρέχουν κάποιο βαθμό αξιοπιστίας. Ο διαχωρισμός των δεδομένων και ειδικότερα των δεδομένων δοκιμής (test data) πραγματοποιήθηκε με ένα συγκεκριμένο αλγόριθμο τυχαιότητας (random state:52) και στρωματοποίησης (βλ. **Εικόνα 34**), δηλαδή για κάθε κατηγορία (train, validation, test data), το σύνολο των δεδομένων διαχωρίστηκε αναλογικά με το ποσοστό που είναι ταξινομημένα στις δύο κλάσεις («Βράχος», «Μεταλλική επιφάνεια») ώστε να υπάρχει αντιπροσωπευτικός αριθμός για κάθε κλάση, αφενός στην εκπαίδευση του μοντέλου και αφετέρου στην αξιολόγηση του σε άγνωστα δεδομένα.

Train/test split data

```
: y=sonar_dataset['Class']  
: X_train,X_test,y_train,y_test= train_test_split(sonar_without_target,y,test_size=0.20,random_state=52,stratify=y )  
: X_train_yj,X_test_yj,y_train_yj,y_test_yj= train_test_split(data_yj,y,test_size=0.20,random_state=52,stratify=y )
```

Εικόνα 33. Στρωματοποιημένος διαχωρισμός των δεδομένων

Τέλος με το τέταρτο ερευνητικό ερώτημα, αξιοποιήθηκε η χρήση των νευρωνικών δικτύων στην επίλυση ταξινόμησης των υπερηχητικών σημάτων sonar. Η απόδοση του νευρωνικού δικτύου σε ποσοστά πρόβλεψης σημείωσε ακρίβεια 98.4% στο σετ επικύρωσης (validation test- 10%) και 95.2 % στο σετ δοκιμών. (test data- 10%) (βλ. **Εικόνα 32**) Τα συγκεκριμένα αποτελέσματα αναδεικνύουν τη χρησιμότητα των νευρωνικών δικτύων στην αντιμετώπιση ζητημάτων ταξινόμησης, καθώς παρατηρείται ότι σημείωσαν την καλύτερη απόδοση στην παρούσα μελέτη σε σύγκριση με τους αλγόριθμους μηχανικής μάθησης και συγκεκριμένα του SVC ο οποίος σημείωσε απόδοση 88% στο σετ δοκιμής (test data).

5. Συμπεράσματα

Το κύριο ενδιαφέρον για την εκπόνηση της παρούσας διπλωματικής βασίστηκε στη προσπάθεια βελτίωσης της ακρίβειας όσον αφορά την επεξεργασία, αναγνώριση και ταξινόμηση στόχων που προέρχονται από υπερηχητικά σήματα Sonar. Η παρούσα έρευνα βασίστηκε πάνω στα δεδομένα από πρωταρχική έρευνα των Gorman & Sejnowski, (1988), οι οποίοι για πρώτη φορά μελέτησαν το συγκεκριμένο σετ δεδομένων και η οποία αφορούσε την ταξινόμηση επιστροφών Sonar από δύο διαφορετικά υποθαλάσσια αντικείμενα, ένα μεταλλικό με την ετικέτα “Mine” και ένα βράχο με την ετικέτα “Rock” χρησιμοποιώντας νευρωνικά δίκτυα. Έκτοτε, πληθώρα ερευνητών αξιοποίησε στη μελέτη τους τα παραπάνω δεδομένα, υπογραμμίζοντας ότι η αναγνώριση ηχητικών σημάτων σόναρ με αποτελεσματική ακρίβεια αποτελεί μια δύσκολη διαδικασία. (Venugopal κ.ά., 1991)

Από την μελέτη και ανάλυση του συνόλου των δεδομένων των ηχητικών επιστροφών Sonar αναδεικνύεται η ικανότητα των μοντέλων μηχανικής μάθησης καθώς και των νευρωνικών δικτύων στην επίλυση ζητημάτων ταξινόμησης προέκυψαν ορισμένα ενδιαφέροντα αποτελέσματα. Συγκεκριμένα την μεγαλύτερη απόδοση όσον αφορά τους αλγόριθμους μηχανικής μάθησης κατείχε ο Support Vector Classifier με ποσοστό 91%, εκπαιδευόμενος σε 169 δείγματα και ποσοστό 88%, ταξινομώντας ορθά 37 από τα 42 άγνωστα δείγματα του σετ δοκιμής. Όσον αφορά τη διαδικασία προεπεξεργασίας των αλγόριθμων, επιλέχθηκε η μέθοδος μετασχηματισμού των δεδομένων Yeo-Johnson με την οποία διορθώθηκε κατά ένα μεγάλο ποσοστό το συνολικό σετ των ηχητικών επιστροφών, παρουσιάζοντας μικρότερη διακύμανση στα δεδομένα σύμφωνα με την **Εικόνα 20** , μειώνοντας τη λοξότητα των κατανομών των επιμέρους χαρακτηριστικών (features) των δεδομένων προσεγγίζοντας περισσότερο την κανονική κατανομή του Gauss (βλ. **Εικόνα 21**) και έδωσε καλύτερα αποτελέσματα στην μετέπειτα επεξεργασία των αλγόριθμων με βάση την απόδοση σε σχέση με τις υπόλοιπες τεχνικές του **Πίνακα 6** . Από την άλλη πλευρά, η αξιοποίηση της αρχιτεκτονικής νευρωνικών δικτύων με 55 μονάδες στο επίπεδο εισόδου, 12 μονάδες στο ενδιάμεσο επίπεδο και μια μονάδα στο επίπεδο εξόδου καθώς και η παραμετροποίηση τους, όπως αναφέρεται στο κεφάλαιο 4.1.4, συνέβαλε επιτυχώς στην ταξινόμηση των υπερηχητικών επιστροφών του ηχοβολιστικού συγκεντρώνοντας ποσοστό 98.4% ,εκπαιδευόμενα σε 169 δείγματα (80% των συνολικών δεδομένων), αξιολογήθηκαν στο σετ επικύρωσης (validation test) σε 21 δείγματα και δοκιμάστηκαν στο άγνωστο σετ δοκιμής (test data) 21 δειγμάτων, συγκεντρώνοντας ποσοστό 95.2 %.

Τέλος, στην περίπτωση στρατιωτικών επιχειρήσεων ανθυποβρυχιακού εντοπισμού, οι εφαρμογές μηχανικής μάθησης καθώς και οι αλγόριθμοι που αξιοποιούνται για την επίλυση τέτοιων ζητημάτων με δεδομένα κατάλληλα όπως αυτά της παρούσας μελέτης, θα πρέπει να εκπαιδεύονται και να παραμετροποιούνται με τέτοιο τρόπο ώστε να προβλέπουν κυρίως ηχητικές επιστροφές sonar προερχόμενες από μεταλλικές επιφάνειες έναντι των βράχων. Με βάση την επιδίωξη αυτή ο αλγόριθμος Support Vector Classifier σημείωσε ικανοποιητικά αποτελέσματα με υψηλό Recall όσον αφορά την κλάση της μεταλλικής επιφάνειας (Mine). Βέβαια,

για τη μεγαλύτερη αξιοπιστία των παραπάνω αποτελεσμάτων απαιτείται μεγαλύτερος αριθμός δειγμάτων, πολλαπλές δοκιμές με διαφορετικό διαχωρισμό των δεδομένων σχετικά με τα δείγματα εκπαίδευσης, επικύρωσης και δοκιμής και περισσότερες δοκιμές σχετικές με την προεπεξεργασία (preprocessing), μετασχηματισμό (transformation), επιλογή και εξαγωγή χαρακτηριστικών (feature selection & extraction) των δεδομένων. Με βάση την παραπάνω διατύπωση επαληθεύεται ο πολύπλοκος και πολυσύνθετος ρόλος της επιστήμης δεδομένων και του ερευνητή ως διαμεσολαβητή σε ένα τέτοιου είδους πλαίσιο.

6. Περιορισμοί και προτάσεις

Στην ενότητα αυτή, παρουσιάζονται ορισμένοι περιορισμοί στην παρούσα μεταπτυχιακή έρευνα, οι οποίοι αξίζει να αναφερθούν. Το δείγμα της έρευνας, η οποία αποτελεί μια μελέτη περίπτωσης (case study), επιλέχθηκε με βάση την διαδικασία της μη πιθανοτικής δειγματοληψίας (δείγμα ευκολίας). Συνεπώς, δεν δόθηκε ιδιαίτερη σημασία όσον αφορά την αντιπροσωπευτικότητα του δείγματος. Η προσοχή επικεντρώθηκε κυρίως στην ουσιαστικότερη κατανόηση της προοπτικής επιλεγμένου δείγματος 208 ηχητικών σημάτων Sonar ως μια μελέτη περίπτωσης.

Όσον αφορά την αξιοπιστία των αποτελεσμάτων και τον παράγοντα της γενικευσιμότητας σε άγνωστα δεδομένα, ο περιορισμός επικεντρώνεται στο μικρό αριθμό δειγμάτων του συνόλου των δεδομένων, γεγονός το οποίο επηρεάζει την αποτελεσματικότητα των αλγόριθμων μηχανικής εκμάθησης, αλλά ακόμα περισσότερο την απόδοση των νευρωνικών δικτύων, τα οποία αποδίδουν ικανοποιητικά σε αρκετά μεγάλο αριθμό δειγμάτων σε συνάρτηση με τις πολλές παραμέτρους που απαιτούνται, για την βελτίωση του βαθμού πρόβλεψής τους. Επιπλέον, άλλος ένας σημαντικός παράγοντας είναι αυτός της πολυπλοκότητας ενός μοντέλου (complexity) σε σχέση με το μέγεθος του σετ δεδομένων για την αποφυγή «overfitting». Είναι χαρακτηριστικό ότι όσο μεγαλύτερη ποικιλία τιμών περιέχεται στα δεδομένα, τόσο η πολυπλοκότητα ενός μοντέλου μπορεί να αποδώσει ικανοποιητικά αποτελέσματα χωρίς την παρουσία «overfitting». Η λύση στο

πρόβλημα αυτό είναι η αξιοποίηση μεγαλύτερου αριθμού δεδομένων (δηλαδή μεγαλύτερη ποικιλία τιμών). Στην παρούσα μελέτη, η ταξινόμηση των δεδομένων απαιτούσε τη χρήση πιο πολύπλοκων μοντέλων σε συνδυασμό όμως με μικρό αριθμό δεδομένων εκπαίδευσης και δοκιμής, με αποτέλεσμα το ενδεχόμενο του «overfitting» να υφίσταται. Παρόλα αυτά τα ικανοποιητικά αποτελέσματα όσον αφορά την απόδοση των μοντέλων στο άγνωστο σετ δοκιμής (test set) δεν φαίνεται να ενισχύουν αυτή την διαπίστωση.

Μελλοντικές προτάσεις που αποσκοπούν σε μια περισσότερο ολοκληρωμένη εικόνα απόδοσης των μοντέλων μηχανικής μάθησης και των νευρωνικών δικτύων, αφορούν την μελέτη που εστιάζει στη διερεύνηση μιας μεγαλύτερης απξέντας αλγόριθμων και τεχνικών προεπεξεργασίας καθώς και εμπλουτισμού των δεδομένων με νέα, γεγονός το οποίο θα προσδώσει μεγαλύτερη αξιοπιστία αποτελεσμάτων σχετικά με τις εκτιμήσεις πρόβλεψης των υπό εξέταση αλγόριθμων και νευρωνικών δικτύων.

7. Βιβλιογραφία

- Παπακωνσταντίνου, Ευαγ. Θ., & Καϊτσα, Γεωρ. Ν. (1997). *Στατιστική*. Ίδρυμα Ευγενίδου.
- Πετρίδης, Δ. (2015). *Ανάλυση Πολυμεταβλητων Τεχνικών, Εφαρμογές Περιπτώσεων*. Αποθετήριο Κάλλιπος. <https://repository.kallipos.gr/>
- Τεχνητή νοημοσύνη. (2020). Στο *Βικιπαίδεια*.
https://el.wikipedia.org/w/index.php?title=%CE%A4%CE%B5%CF%87%CE%BD%CE%B7%CF%84%CE%AE_%CE%BD%CE%BF%CE%B7%CE%BC%CE%BF%CF%83%CF%8D%CE%BD%CE%B7&oldid=8343471
- Alexandridis, M. G., Entin, E. E., Wohl, J. G., & Deckert, J. C. (1984). *Cognitive Simulation of an Anti-Submarine Warfare Commander's Tactical Decision Process*.
- Alzubi, J., Nayyar, A., & Kumar, A. (2018). Machine Learning from Theory to Algorithms: An Overview. *Journal of Physics: Conference Series*, 1142, 012012. <https://doi.org/10.1088/1742-6596/1142/1/012012>

- Analytics Vidhya. (2016, Μάρτιος 1). XGBoost Parameters | XGBoost Parameter Tuning. *Analytics Vidhya*.
<https://www.analyticsvidhya.com/blog/2016/03/complete-guide-parameter-tuning-xgboost-with-codes-python/>
- Anitha, U., & Malarkkan, S. (2018). Underwater object identification and recognition with sonar images using soft computing techniques. *INDIAN J. MAR. SCI.*, 47(03), 9.
- Asakawa, K., J. Kojima, Y. Ito, S. Takagi, Y. Shirasaki, and N. Kato. “Autonomous Underwater Vehicle AQUA EXPLORER 1000 for Inspection of Underwater Cables.” *Proceedings, Oceans 1996*: 10-17.
- Atallah, L. N. (2005). *Learning from sonar data for the classification of underwater seabeds*. <https://ora.ox.ac.uk/objects/uuid:11a17b77-6e17-409e-9a6e-d19c13b86709>
- Baran, R. H., & Coughlin, J. P. (1991). A neural network for target classification using passive sonar. *Proceedings of the Conference on Analysis of Neural Network Applications - ANNA '91*, 188–198.
<https://doi.org/10.1145/106965.106969>
- Brownlee, J. (2013, Νοέμβριος 16). What is Machine Learning? *Machine Learning Mastery*. <https://machinelearningmastery.com/what-is-machine-learning/>
- Brownlee, J. (2020a, Μάιος 17). How to Use Power Transforms for Machine Learning. *Machine Learning Mastery*.
<https://machinelearningmastery.com/power-transforms-with-scikit-learn/>
- Brownlee, J. (2020b, Σεπτέμβριος 27). Linear Discriminant Analysis With Python. *Machine Learning Mastery*. <https://machinelearningmastery.com/linear-discriminant-analysis-with-python/>
- Brownlee, J. (2020c, Οκτώβριος 1). Gaussian Processes for Classification With Python. *Machine Learning Mastery*.
<https://machinelearningmastery.com/gaussian-processes-for-classification-with-python/>
- Carbonell, J. G., Michalski, R. S., & Mitchell, T. M. (1983). An Overview Of Machine Learning. Στο R. S. Michalski, J. G. Carbonell, & T. M. Mitchell

- (Επιμ.), *Machine Learning* (σσ. 3–23). Morgan Kaufmann.
<https://doi.org/10.1016/B978-0-08-051054-5.50005-4>
- Casselmann, F. L., D. F. Freeman, D. Kerrigan, S. Lane, N. Millstrom, and W. Nichols Jr. “A Neural Network-Based Passive Sonar Detection and Classification Design With a Low False Alarm Rate”. *Proceedings: Oceans 1991*: 1701-1706.
- Chin-Hsing, C., Jiann-Der, L., & Ming-Chi, L. (1998). Classification of underwater signals using wavelet transforms and neural networks. *Mathematical and Computer Modelling*, 27(2), 47–60. [https://doi.org/10.1016/S0895-7177\(97\)00259-8](https://doi.org/10.1016/S0895-7177(97)00259-8)
- Cottle, D., and D. Hamilton. “All Neural Network Sonar Discrimination System”. *Proceedings, IEEE Conference on Neural Networks for Ocean Engineering*, (1991): 13-19.
- Dey, A. (2016). *Machine Learning Algorithms: A Review*. 7, 6.
- Einsidler, D., Dhanak, M., & Beaujean, P.-P. (2018). A Deep Learning Approach to Target Recognition in Side-Scan Sonar Imagery. *OCEANS 2018 MTS/IEEE Charleston*, 1–4. <https://doi.org/10.1109/OCEANS.2018.8604879>
- Erkmen, B., & Yildirim, T. (2006). *Conic Section Function Neural Networks for Sonar Target Classification and Performance Evaluation Using ROC Analysis*. 6.
- Finlay, B., Loehrke, B., & King, C. (2019). *The Militarization of Artificial Intelligence*. 32.
- Fong, S., Deb, S., & Thampi, S. (2014). Classifying Sonar Signals Using an Incremental Data Stream Mining Methodology with Conflict Analysis. Στο S. M. Thampi, A. Gelbukh, & J. Mukhopadhyay (Επιμ.), *Advances in Signal Processing and Intelligent Recognition Systems* (τ. 264, σσ. 171–182). Springer International Publishing. https://doi.org/10.1007/978-3-319-04960-1_15
- Fong, S., Deb, S., Wong, R., & Sun, G. (2014). Underwater Sonar Signals Recognition by Incremental Data Stream Mining with Conflict Analysis. *International Journal of Distributed Sensor Networks*, 10(5), 635834. <https://doi.org/10.1155/2014/635834>

- Fossaceca, J. M., & Young, S. H. (2018). Artificial intelligence and machine learning for future army applications. Στο T. Pham, M. A. Kolodny, & D. M. Wiegmann (Επιμ.), *Ground/Air Multisensor Interoperability, Integration, and Networking for Persistent ISR IX* (σ. 6). SPIE.
<https://doi.org/10.1117/12.2307753>
- Gendron, M. L., & Lohrenz, M. C. (2007). The Automated Change Detection and Classification Real-time (ACDC-RT) System. *OCEANS 2007 - Europe*, 1–4.
<https://doi.org/10.1109/OCEANSE.2007.4302387>
- Giddings TE, Shirron JJ. A model for sonar interrogation of complex bottom and surface targets in shallow-water waveguides. *J Acoust Soc Am*. 2008 Apr;123(4):2024-34. doi: 10.1121/1.2839002. PMID: 18397010.
- Glette, K., Torresen, J., & Yasunaga, M. (2007). An Online EHW Pattern Recognition System Applied to Sonar Spectrum Classification. Στο L. Kang, Y. Liu, & S. Zeng (Επιμ.), *Evolvable Systems: From Biology to Hardware* (τ. 4684, σσ. 1–12). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-74626-3_1
- Gorman, R.P. (1991). Neural networks and the classification of complex sonar signals. *[1991 Proceedings] IEEE Conference on Neural Networks for Ocean Engineering*, 283–290. <https://doi.org/10.1109/ICNN.1991.163363>
- Gorman, R.P., & Sejnowski, T. J. (1988). Learned classification of sonar targets using a massively parallel network. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 36(7), 1135–1140. <https://doi.org/10.1109/29.1640>
- Gorman, R.Paul, & Sejnowski, T. J. (1988). Analysis of hidden units in a layered network trained to classify sonar targets. *Neural Networks*, 1(1), 75–89.
[https://doi.org/10.1016/0893-6080\(88\)90023-8](https://doi.org/10.1016/0893-6080(88)90023-8)
- Guicking, D., Goerk, K., & Peine, H. (1992). *Recent advances in sonar target classification* (F. A. Sadjadi, Επιμ.; σσ. 2–15).
<https://doi.org/10.1117/12.138258>
- Hastie, T., Tibshirani, R., & Friedman, J. (2016). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition* (2nd edition). Springer.

- Hayashi, Chikio (1998-01-01). "What is Data Science? Fundamental Concepts and a Heuristic Example". *Data Science, Classification, and Related Methods. Studies in Classification, Data Analysis, and Knowledge Organization*. Springer Japan. pp. 40–51. doi:10.1007/978-4-431-65950-1_3. ISBN 9784431702085
- Herbrich, R., & Graepel, T. (2015). *Machine Learning. An Algorithm Perspective*. 452.
- Hjelmervik, K. T., Berg, H., & Sastad, T. S. (2020). Predicting False Alarm Rates for High-Resolution Antisubmarine Warfare Sonars in a Cluttering Environment Prone to False Alarm Rate Inflation. *IEEE Journal of Oceanic Engineering*, 45(4), 1527–1537. <https://doi.org/10.1109/JOE.2019.2936642>
- Howell, B. P. (2004). *Evaluation of Neural Networks for Data Classification, Recognition, and Navigation in the Marine Environment*. 188.
- Hurwitz, J. (2018). *Machine Learning For Dummies®*, IBM Limited Edition. 75.
- Instance-based learning. (2020). Στο *Wikipedia*.
https://en.wikipedia.org/w/index.php?title=Instance-based_learning&oldid=962636761
- Jade, R. K., Verma, L. K., & Verma, K. (2013). Classification using Neural Network & Support Vector Machine for Sonar dataset. *International Journal of Computer Trends and Technology*, 4.
- Khishe, M., & Safari, A. (2019). Classification of Sonar Targets Using an MLP Neural Network Trained by Dragonfly Algorithm. *Wireless Personal Communications*, 108(4), 2241–2260. <https://doi.org/10.1007/s11277-019-06520-w>
- Kim, T., Kim, J., & Byun, S.-W. (2018). A Comparison of Nonlinear Filter Algorithms for Terrain-referenced Underwater Navigation. *International Journal of Control, Automation and Systems*, 16(6), 2977–2989.
<https://doi.org/10.1007/s12555-017-0504-5>
- Long, S., & Dhillon, B. S. (Επιμ.). (2020). *Man-Machine-Environment System Engineering: Proceedings of the 20th International Conference on MMESE* (τ. 645). Springer Singapore. <https://doi.org/10.1007/978-981-15-6978-4>
- Lück, N. (2019). *Machine-learning-powered artificial intelligence in arms control*.

- Machine Learning Decision Tree Classification Algorithm—Javatpoint.* (2020).
 Www.Javatpoint.Com. <https://www.javatpoint.com/machine-learning-decision-tree-classification-algorithm>
- Machine Learning Project Structure: Stages, Roles, and Tools. (χ.χ.). *AltexSoft*.
 Ανακτήθηκε 13 Δεκέμβριος 2020, από
<https://www.altexsoft.com/blog/datascience/machine-learning-project-structure-stages-roles-and-tools/>
- Masuhr, N. (2019). *AI in Military Enabling Applications* [Application/pdf]. 4 p.
<https://doi.org/10.3929/ETHZ-B-000367663>
- Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
- Mosavi, M R, Kaveh, M., & Khishe, M. (2016). *Sonar Data Set Classification using MLP Neural Network Trained by Non-linear Migration Rates BBO*. 6.
- Mosavi, Mohammad Reza, Khishe, M., & Ebrahimi, E. (2016). *Classification of Sonar Targets Using OMKC, Genetic Algorithms and Statistical Moments*. 7(1), 14.
- Mosavi, Mohammad Reza, Khishe, M., & Ghamgosar, A. (2016).
 CLASSIFICATION OF SONAR DATA SET USING NEURAL NETWORK
 TRAINED BY GRAY WOLF OPTIMIZATION. *Neural Network World*,
 26(4), 393–415. <https://doi.org/10.14311/NNW.2016.26.023>
- Muller, A. C., & Guido, S. (2016). *Introduction to Machine Learning with Python*. 392.
- N. dhage, S., & Raina, C. K. (2016). A review on Machine Learning Techniques.
International Journal on Recent and Innovation Trends in Computing and Communication (IJRITCC), Volume 4(Issue 3), 395 – 399.
- Novakovic, J. (2009). Using Information Gain Attribute Evaluation to Classify Sonar Targets. *17th Telecommunications Forum TELFOR 2009*, 4.
- Pant, A. (2019, Ιανουάριος 23). *Workflow of a Machine Learning Project*. Medium.
<https://towardsdatascience.com/workflow-of-a-machine-learning-project-ec1dba419b94>
- Pelliccia, D. (2018, Δεκέμβριος 3). Classification of NIR spectra by Linear Discriminant Analysis in Python. *NIRPY Research*.

<https://nirpyresearch.com/classification-nir-spectra-linear-discriminant-analysis-python/>

- Porto, V. W. “A Short Overview of Neural Networks and Information Processing Trends in Oceans Technology”. URL:
<http://www.ieee.org/organizations/society/oes/html/spring00/overview.htm>.
April 8, 2020
- Pruim, R. H. R., Van Opbroek, A., Kruithof, M., Den Hollander, R. J. M., Baan, J., Van den Broek, S. P., Van der Stap, N., & Dijk, J. (2019). Spatiotemporal detection of maritime targets using neural networks. Στο J. Dijk (Επιμ.), *Artificial Intelligence and Machine Learning in Defense Applications* (σ. 4). SPIE. <https://doi.org/10.1117/12.2532323>
- Royal Society (Great Britain). (2017). *Machine learning: The power and promise of computers that learn by example*.
- Science, D. (2019, Απρίλιος 29). Data Science and Machine Learning: Confusion Matrix. *Data Science and Machine Learning*. <https://manisha-sirsat.blogspot.com/2019/04/confusion-matrix.html>
- Seo, I., Kim, S., Ryu, Y., Park, J., & Han, D. S. (2019). Underwater Moving Target Classification Using Multilayer Processing of Active Sonar System. *Applied Sciences*, 9(21), 4617. <https://doi.org/10.3390/app9214617>
- Sharma, R. (2019, Ιούνιος 13). *Gaussian distribution: Why is it important in data science and machine learning?* Medium. <https://medium.com/ai-techsystems/gaussian-distribution-why-is-it-important-in-data-science-and-machine-learning-9adbe0e5f8ac>
- Singh, S. (2018, Οκτώβριος 9). *Understanding the Bias-Variance Tradeoff*. Medium. <https://towardsdatascience.com/understanding-the-bias-variance-tradeoff-165e6942b229>
- `sklearn.ensemble.GradientBoostingClassifier`. (2020). 3.2.4.3.5. *Sklearn.ensemble.GradientBoostingClassifier—Scikit-learn 0.23.2 documentation*. <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.GradientBoostingClassifier.html>

- Solinsky, J., and E. Nash. "Neural Network Performance Assessment in Sonar Applications". Proceedings, IEEE Conference on Neural Networks for Ocean Engineering, (1991): 1-12.
- Support Vector Machine (SVM) Algorithm*. (2020). Wwww.Javatpoint.Com.
<https://www.javatpoint.com/machine-learning-support-vector-machine-algorithm>
- Thampi, S. M., Gelbukh, A., & Mukhopadhyay, J. (Επιμ.). (2014). *Advances in Signal Processing and Intelligent Recognition Systems* (τ. 264). Springer International Publishing. <https://doi.org/10.1007/978-3-319-04960-1>
- UCI Machine Learning Repository. (2020). *UCI Machine Learning Repository: Connectionist Bench (Sonar, Mines vs. Rocks) Data Set*.
[https://archive.ics.uci.edu/ml/datasets/Connectionist+Bench+\(Sonar,+Mines+vs.+Rocks\)](https://archive.ics.uci.edu/ml/datasets/Connectionist+Bench+(Sonar,+Mines+vs.+Rocks))
- Venugopal, K. P., Pandya, A. S., & Sudhakar, R. (1991). *Continuous recognition of sonar targets using neural networks* (F. A. Sadjadi, Επιμ.; σσ. 44–53).
<https://doi.org/10.1117/12.44865>
- Waltzman, R., Ablon, L., Curriden, C., Hartnett, G. S., Holliday, M. A., Ma, L., Nichiporuk, B., Scobell, A., & Tarraf, D. C. (2020). *Maintaining the Competitive Advantage in Artificial Intelligence and Machine Learning*. RAND Corporation Santa Monica United States.
<https://apps.dtic.mil/sti/citations/AD1106128>
- wikipedia. (2020). Linear discriminant analysis. Στο *Wikipedia*.
https://en.wikipedia.org/w/index.php?title=Linear_discriminant_analysis&oldid=989019705
- Wikipedia, Short-time Fourier transform. (2020). Short-time Fourier transform. Στο *Wikipedia*. https://en.wikipedia.org/w/index.php?title=Short-time_Fourier_transform&oldid=992533854
- Yang, H., Lee, K., Choo, Y., & Kim, K. (2020). Underwater Acoustic Research Trends with Machine Learning: Passive SONAR Applications. *Journal of Ocean Engineering and Technology*, 34(3), 227–236.
<https://doi.org/10.26748/KSOE.2020.017>

8. Παραρτήματα

8.1 Παράρτημα 1: [PAPER ENGLISH]

Summary

In the present thesis, an attempt has been made to improve the accuracy of the processing, recognition and classification of targets derived from sonar ultrasonic signals. The work is part of the wider area of Artificial Intelligence and mostly of Machine Learning as a tool for improving applications related to signal processing. It is worth noting that the present study was based on the sonar dataset from a previous study by Gorman & Sejnowski, (1988), who for the first time studied this dataset which concerned the classification of Sonar returns from two different underwater objects, a metal with labeled "Mine" and a rock labeled "Rock" using neural networks.

The theoretical framework applied focuses mainly on machine learning and the utilization of a series of algorithms suitable for classification problems that aim to develop models capable of locating marine objectives taking into account their key characteristics.

From the analysis of the total sample of 208 sonar ultrasonic signals and the selection of the most suitable model which provides the highest percentage of prediction in this dataset, interesting results were obtained which satisfactorily showed the ability of machine learning models as well as neural networks to solve classification issues. Specifically, the highest performance of the machine learning algorithms was held by the Support Vector Classifier with a percentage of 91%. trained in 169 samples and a percentage of 88%, correctly classifying 37 of the 42 unknown samples of the test set. The utilization of neural network architecture

successfully contributed to the classification of sonar ultrasonic returns with a rate of 98.4% trained in 169 samples (80% of the total data), evaluated in the validation set in 21 samples and in the unknown test set (test data) 21 samples at a rate of 95.2%.

Area: Machine Learning

Keywords: Artificial Intelligence, Machine Learning, supervised learning, classification, signal processing, sonar