ΕΛΛΗΝΙΚΟ ΜΕΣΟΓΕΙΑΚΟ ΠΑΝΕΠΙΣΤΗΜΙΟ
ΣΧΟΛΗ ΕΠΙΣΤΗΜΩΝ ΔΙΟΙΚΗΣΗΣ ΚΑΙ ΟΙΚΟΝΟΜΙΑΣ
ΤΜΗΜΑ ΔΙΟΙΚΗΤΙΚΗΣ ΕΠΙΣΤΗΜΗΣ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ

ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ
«ΔΙΟΙΚΗΣΗ ΚΑΙ ΨΗΦΙΑΚΟΣ ΜΕΤΑΣΧΗΜΑΤΙΣΜΟΣ»

ΕΝΤΟΠΙΣΜΟΣ ΠΛΟΙΩΝ ΑΠΟ ΑΕΡΟΦΩΤΟΓΡΑΦΙΕΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Φοιτήτρια: Μηναδάκη Ελένη, ΜΔΕ3
Επιβλέπων: Δρ. Παναγιωτάκης Κωνσταντίνος, Καθηγητής

©
<2025>

ΕΛΛΗΝΙΚΟ ΜΕΣΟΓΕΙΑΚΟ ΠΑΝΕΠΙΣΤΗΜΙΟ
ΣΧΟΛΗ ΕΠΙΣΤΗΜΩΝ ΔΙΟΙΚΗΣΗΣ ΚΑΙ ΟΙΚΟΝΟΜΙΑΣ
ΤΜΗΜΑ ΔΙΟΙΚΗΤΙΚΗΣ ΕΠΙΣΤΗΜΗΣ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ

ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ
«ΔΙΟΙΚΗΣΗ ΚΑΙ ΨΗΦΙΑΚΟΣ ΜΕΤΑΣΧΗΜΑΤΙΣΜΟΣ»

ΕΝΤΟΠΙΣΜΟΣ ΠΛΟΙΩΝ ΑΠΟ ΑΕΡΟΦΩΤΟΓΡΑΦΙΕΣ

Τριμελής Εξεταστική Επιτροπή

Επιβλέπων Καθηγητής:
Κωνσταντίνος Παναγιωτάκης, Καθηγητής, Τμήμα Διοικητικής Επιστήμης και Τεχνολογίας, Ελληνικό Μεσογειακό Πανεπιστήμιο

Δεύτερος Καθηγητής:
Γεώργιος Βασιλειάδης, Επίκουρος Καθηγητής, Τμήμα Διοικητικής Επιστήμης και Τεχνολογίας, Ελληνικό Μεσογειακό Πανεπιστήμιο

Τρίτος Καθηγητής:
Κωνσταντίνος Μπαχαρίδης, Εντεταλμένος Διδάσκων, Τμήμα Διοικητικής Επιστήμης και Τεχνολογίας, Ελληνικό Μεσογειακό Πανεπιστήμιο

HELLENIC MEDITERRANEAN UNIVERSITY
SCHOOL OF MANAGEMENT AND ECONOMICS SCIENCE
DEPARTMENT OF MANAGEMENT SCIENCE AND TECHNOLOGY

MSc in
MANAGEMENT AND DIGITAL TRANSFORMATION

SHIP DETECTION IN AERIAL IMAGES

MASTER THESIS

Student: ELENI, MINADAKI, MDE3
Supervisor: KONSTANTINOS, PANAGIOTAKIS, PROFESSOR

©
<2025>

Υπεύθυνη Δήλωση *: Βεβαιώνω ότι είμαι συγγραφέας αυτής της διπλωματικής εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της, είναι πλήρως αναγνωρισμένη και αναφέρεται στη διπλωματική εργασία. Επίσης έχω αναφέρει τις όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε αυτές αναφέρονται ακριβώς είτε παραφρασμένες. Επίσης βεβαιώνω ότι αυτή η διπλωματική εργασία προετοιμάστηκε από εμένα προσωπικά ειδικά για τις απαιτήσεις του Μεταπτυχιακού Προγράμματος Σπουδών Διοίκηση και Ψηφιακός Μετασχηματισμός του Τμήματος Διοικητικής Επιστήμης και Τεχνολογίας του ΕΛΜΕΠΑ.*

ΠΕΡΙΛΗΨΗ

Η παρούσα εργασία επικεντρώνεται στον εντοπισμό πλοίων από αεροφωτογραφίες υψηλής ανάλυσης, μια πρόκληση με αυξανόμενο ενδιαφέρον λόγω των εφαρμογών της σε τομείς όπως η ναυτική ασφάλεια, η περιβαλλοντική παρακολούθηση και η διαχείριση λιμένων.

Η ανίχνευση αντικειμένων σε αεροφωτογραφίες αποτελεί μία από τις πλέον διαδεδομένες και σημαντικές εφαρμογές στον τομέα της υπολογιστικής όρασης. Παρ' όλα αυτά, πρόκειται για ένα απαιτητικό πρόβλημα, καθώς η κατανομή των αντικειμένων στο εναέριο οπτικό πεδίο δεν είναι ομοιογενής, ενώ η εμφάνισή τους ενδέχεται να μεταβάλλεται σημαντικά λόγω διαφορετικών γωνιών λήψης, υψομετρικών διαφορών και συνθηκών φωτισμού (Chalavadi et al., 2022).

Αρχικά παρουσιάζεται η σχετική θεωρητική βάση, καθώς και η εξέλιξη των τεχνικών εντοπισμού πλοίων, με έμφαση στις μεθόδους που βασίζονται σε συνελικτικά νευρωνικά δίκτυα (CNN) και σύγχρονες αρχιτεκτονικές όπως το YOLO.

Η έρευνα είχε στόχο την εκπαίδευση ενός μοντέλου τεχνητής νοημοσύνης για τον εντοπισμό πλοίων σε αεροφωτογραφίες, αξιοποιώντας το μοντέλο YOLOv8, ένα από τα πλέον σύγχρονα μοντέλα object detection, χρησιμοποιώντας το ανοιχτό σύνολο δεδομένων ShipRSImageNet, με στόχο την ανάλυση της ακρίβειας και της απόδοσης του μοντέλου σε πραγματικές συνθήκες.

Τα αποτελέσματα δείχνουν ότι το μοντέλο επιτυγχάνει υψηλά ποσοστά ανίχνευσης και καλή γενίκευση, παρά τις δυσκολίες που παρουσιάζονται λόγω ποικιλομορφίας του φόντου και του μεγέθους των πλοίων, καθώς εξαιρετικά αποτελέσματα παρατηρήθηκαν σε μεγάλες κατηγορίες πλοίων, ενώ σπάνιες ή μικρές κατηγορίες είχαν χαμηλότερη απόδοση. Οι κύριοι περιορισμοί περιλαμβάνουν ανισορροπία στις κατηγορίες, μειωμένη απόδοση σε μικρά/σκοτεινά αντικείμενα, απουσία χρονικής πληροφορίας και σύγχυση μεταξύ ομοειδών κατηγοριών.

Λέξεις Κλειδιά : Ανίχνευση πλοίων, Εναέριες εικόνες, YOLOv8, Μηχανική μάθηση, Νευρωνικά Δίκτυα

ABSTRACT

This thesis focuses on ship detection from high-resolution aerial images, a challenge of growing interest due to its applications in fields such as maritime security, environmental monitoring, and port management.

Object detection in aerial imagery is one of the most widespread and significant applications in the field of computer vision. However, it remains a demanding problem, as the distribution of objects within the aerial visual field is non-uniform, and their appearance can vary significantly due to different viewing angles, altitude differences, and lighting conditions (Chalavadi et al., 2022).

Initially, the relevant theoretical background is presented, along with the evolution of ship detection techniques, with an emphasis on methods based on convolutional neural networks (CNNs) and modern architectures such as YOLOv8.

The research aimed to train an artificial intelligence model for ship detection in aerial images, utilizing the YOLOv8 model—one of the most advanced object detection models—using the open dataset ShipRSImageNet, with the objective of analyzing the model's accuracy and performance under real-world conditions.

The results demonstrate that the model achieves high detection rates and good generalization despite the challenges posed by the diversity of backgrounds and ship sizes. Outstanding performance was observed for large ship categories, whereas rare or small categories showed lower accuracy. The main limitations include class imbalance, reduced performance on small or dark objects, the absence of temporal information and confusion among similar categories.

Key Words : Ship Detection, Aerial Images, YOLOv8, Machine Learning, Neural Networks

“Δεν μπορούμε να ελέγξουμε τον άνεμο,

αλλά μπορούμε να ρυθμίσουμε τα πανιά.”

– Αριστοτέλης

Περιεχόμενα

ΠΕΡΙΛΗΨΗ 1
ABSTRACT 2
Περιεχόμενα 4
ΛΙΣΤΑ ΣΧΕΔΙΑΓΡΑΜΜΑΤΩΝ 6
ΛΙΣΤΑ ΠΙΝΑΚΩΝ 7
ΛΙΣΤΑ ΕΙΚΟΝΩΝ 8
ΣΥΝΤΟΜΟΓΡΑΦΙΕΣ 10
ΕΥΧΑΡΙΣΤΙΕΣ 11
ΚΕΦΑΛΑΙΟ 1 1
ΕΙΣΑΓΩΓΗ 1
1.1 Εισαγωγή στο θέμα της εργασίας 1
1.2 Καθορισμός του Σκοπού και των Στόχων της εργασίας 1
1.3 Επισκόπηση του προβλήματος εντοπισμού πλοίων από αεροφωτογραφίες 2
ΚΕΦΑΛΑΙΟ 2 5
ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ 5
2.1 Ανάλυση προηγούμενων ερευνών σχετικά με τον εντοπισμό πλοίων από αεροφωτογραφίες 5
2.1.1 Προηγούμενες μελέτες εστιασμένες σε YOLO-based μοντέλα για τον εντοπισμό πλοίων σε εναέριες/τηλεσκοπικές εικόνες. 7
2.2 Παρουσίαση διαφόρων μεθόδων και τεχνικών που χρησιμοποιούνται 9
ΚΕΦΑΛΑΙΟ 3 12
ΜΕΘΟΔΟΛΟΓΙΑ 12
3.1 Νευρωνικά Δίκτυα 12
3.2 Μοντέλο YOLOv8m 14
3.3 Περιγραφή της μεθοδολογίας που χρησιμοποιήθηκε για τον εντοπισμό των πλοίων 16
3.4 Περιγραφή του υλικού και των δεδομένων που χρησιμοποιήθηκαν 17
3.5 Εξήγηση των τεχνικών που εφαρμόστηκαν 19
ΚΕΦΑΛΑΙΟ 4 21
ΥΛΟΠΟΙΗΣΗ 21
4.1 Παρουσίαση της υλοποίησης της μεθόδου, συμπεριλαμβανομένου του κώδικα και των 21
4.1.1 WebApp 22
4.2 Εξήγηση των παραμέτρων εκπαίδευσης 23

ΚΕΦΑΛΑΙΟ 5 26
ΑΠΟΤΕΛΕΣΜΑΤΑ 26
5.1 Παρουσίαση και ανάλυση των αποτελεσμάτων 26
5.2 Εκτίμηση της απόδοσης της μεθόδου 30
ΚΕΦΑΛΑΙΟ 6 53
ΣΥΜΠΕΡΑΣΜΑΤΑ 53
6.1 Συζήτηση των αποτελεσμάτων και των περιορισμών της μεθόδου 53
6.2 Σύνοψη των κύριων ευρημάτων 54
6.3 Ανάλυση των πιθανών βελτιώσεων 54
6.4 Επισκόπηση της σημασίας της έρευνας 55
ΚΕΦΑΛΑΙΟ 7 57
ΜΕΛΛΟΝΤΙΚΗ ΕΡΓΑΣΙΑ 57
7.1 Προτάσεις για μελλοντικές έρευνες στον τομέα του εντοπισμού πλοίων 57
ΒΙΒΛΙΟΓΡΑΦΙΑ 59
ΠΑΡΑΡΤΗΜΑ Α 65
ΠΑΡΑΡΤΗΜΑ Β 67

ΛΙΣΤΑ ΣΧΕΔΙΑΓΡΑΜΜΑΤΩΝ

Σχήμα 1: Ιεραρχία κλάσεων ShipRSImageNet.....18
Διάγραμμα 1: Κυριότερες κατηγορίες πλοίων βάσει εμφανίσεων στο δείγμα 29

Διάγραμμα 2: Χειρότερες κατηγορίες πλοίων βάσει ακρίβειας.....29

Διάγραμμα 3: Ακρίβεια μοντέλου ανά κατηγορία πλοίου.....30

Διάγραμμα 4: Καμπύλη F1 ως συνάρτηση του κατωφλίου εμπιστοσύνης (confidence threshold).....31

Διάγραμμα 5: Καμπύλη ακρίβειας (Precision).....32

Διάγραμμα 6: Καμπύλη ανάκλησης (Recall) σε συνάρτηση με το κατώφλι εμπιστοσύνης (confidence threshold).....33

Διάγραμμα 7: Διάγραμμα Καμπύλης Precision–Recall.....34

Διάγραμμα 8: Απεικονίζουν την κατανομή των ετικετών (labels) στο dataset, παρουσιάζοντας τον αριθμό των δειγμάτων ανά κατηγορία πλοίου. Τα διαγράμματα βοηθούν στην κατανόηση της ισορροπίας ή της ανισορροπίας μεταξύ των κατηγοριών, γεγονός που επηρεάζει την εκπαίδευση και την απόδοση του μοντέλου.....36

ΛΙΣΤΑ ΠΙΝΑΚΩΝ

Πίνακας 1: Αξιολόγηση βασικών κριτηρίων επιλογής του μοντέλου YOLOv8m 16
Πίνακας 2: Κατηγορίες πλοίων του dataset 19
Πίνακας 3: Συγκριτικός Πίνακας Μοντέλων Ανίχνευσης Αντικειμένων 22
Πίνακας 4: Παράμετροι εκπαίδευσης 24
Πίνακας 5: Επεξήγηση Μετρικών Αξιολόγησης Μοντέλων Ανίχνευσης 27
Πίνακας 6: Κατηγορίες με τη χαμηλότερη ακρίβεια 29
Πίνακας 7: Πίνακας σύγχυσης (confusion matrix) 35
Πίνακας 8: Πίνακας αντιστοίχισης αριθμητικών ετικετών με τις κατηγορίες πλοίων του dataset 37

ΛΙΣΤΑ ΕΙΚΟΝΩΝ

Εικόνα 1: Τυπική δομή ενός νευρωνικού δικτύου που απεικονίζει τα επίπεδα εισόδου, τα κρυφά επίπεδα και το επίπεδο εξόδου, καθώς και τη ροή των σημάτων μεταξύ των νευρώνων (Πηγή: Techmaniacs, 2024).....13
Εικόνα 2: Αρχιτεκτονική του YOLOv8m (Πηγή: Ultralytics, 2023).....15
Εικόνα 3: Απεικόνιση της πορείας εκπαίδευσης του μοντέλου YOLOv8m. 27
Εικόνα 4: Στιγμιότυπα από παρτίδες εκπαίδευσης (training batch).....38
Εικόνα 5: Στιγμιότυπα από παρτίδες εκπαίδευσης (training batch).....39
Εικόνα 6: Στιγμιότυπα από παρτίδες εκπαίδευσης (training batch).....40
Εικόνα 7: Στιγμιότυπα από παρτίδες εκπαίδευσης (training batch).....41
Εικόνα 8: Στιγμιότυπα από παρτίδες εκπαίδευσης (training batch).....42
Εικόνα 9: Στιγμιότυπα από παρτίδες εκπαίδευσης (training batch).....43
Εικόνα 10: Απεικόνιση εικόνων του σετ επικύρωσης με τις πραγματικές ετικέτες.....44
Εικόνα 11: Απεικόνιση των προβλέψεων του εκπαιδευμένου μοντέλου για το ίδιο σύνολο εικόνων. Κάθε ετικέτα συνοδεύεται από το ποσοστό εμπιστοσύνης της πρόβλεψης.....45
Εικόνα 12: Απεικόνιση εικόνων του σετ επικύρωσης με τις πραγματικές ετικέτες.....45
Εικόνα 13: Απεικόνιση των προβλέψεων του εκπαιδευμένου μοντέλου για το ίδιο σύνολο εικόνων. Κάθε ετικέτα συνοδεύεται από το ποσοστό εμπιστοσύνης της πρόβλεψης.....46
Εικόνα 14: Απεικόνιση εικόνων του σετ επικύρωσης με τις πραγματικές ετικέτες.....46
Εικόνα 15: Απεικόνιση των προβλέψεων του εκπαιδευμένου μοντέλου για το ίδιο σύνολο εικόνων. Κάθε ετικέτα συνοδεύεται από το ποσοστό εμπιστοσύνης της πρόβλεψης.....47
Εικόνα 16: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου. 48
Εικόνα 17: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου. 48
Εικόνα 18: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου. 49
Εικόνα 19: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου. 49

Εικόνα 20: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου. 50
Εικόνα 21: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου. 50
Εικόνα 22: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου. 51
Εικόνα 23: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου. 51
Εικόνα 24: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου. 52
Εικόνα 25: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου. 52

ΣΥΝΤΟΜΟΓΡΑΦΙΕΣ

AFPN: Asymptotic Feature Pyramid Network

AI: Artificial Intelligence

AIS: Automatic Identification System

ALF-YOLO: Adaptive Lightweight Fusion YOLO

ANN: Artificial Neural Network

CAD-Net: Computer-Aided Design Network

CNN: Convolutional Neural Network

CPU: Central Processing Unit

DCNN: Deep Convolutional Neural Networks

DETR: DEtection TRansformer

Faster R-CNN: Faster Region Convolutional Neural Network

FPN: Feature Pyramid Network

GAN: Generative Adversarial Network

GLRT: Generalized Likelihood Ratio Test

GPU: Graphics Processing Unit

IoU: Intersection over Union

LRSD: Low-Rank plus Sparse Decomposition

mAP: mean Average Precision

NMS: Non-Maximum Suppression

PANet: Path Aggregation Network

SAR: Specific Absorption Rate

SESPNet: Squeeze Excitation Skip-connection Path Network

SPPF: Spatioal Pyramid Pooling Fast

SVDNet: Singular Vector Decomposition Network

SVM: Support Vector Machine

UAV: Unmanned Aerial Vehicle

YOLO: You Only Look Once

ΕΥΧΑΡΙΣΤΙΕΣ

Θα ήθελα να εκφράσω τις θερμές μου ευχαριστίες στον επιβλέποντα καθηγητή μου, Δρ. Κωνσταντίνο Παναγιωτάκη, για την πολύτιμη καθοδήγηση, τη στήριξη και την υπομονή που μου έδειξε καθ' όλη τη διάρκεια της εκπόνησης της παρούσας πτυχιακής εργασίας.

Επίσης, ευχαριστώ τους διδάσκοντες και το προσωπικό του τμήματος Διοικητικής Επιστήμης και Τεχνολογίας του ΕΛ.ΜΕ.ΠΑ. για τις γνώσεις και τα εφόδια που μου παρείχαν όλα αυτά τα χρόνια.

Ιδιαίτερη ευγνωμοσύνη οφείλω στην οικογένειά μου για την αμέριστη υποστήριξη και κατανόηση, καθώς και στους φίλους μου για την ενθάρρυνση και την ψυχολογική στήριξη.

Τέλος, ευχαριστώ όλους όσοι συνέβαλαν με τον τρόπο τους στην επιτυχή ολοκλήρωση της εργασίας αυτής.

Και να ξέρετε… η έρευνα μου έμαθε πολλά. Κυρίως πόσα tabs μπορεί να ανοίξει ένας browser χωρίς να κρασάρει!!!

ΚΕΦΑΛΑΙΟ 1

ΕΙΣΑΓΩΓΗ

1.1 Εισαγωγή στο θέμα της εργασίας

Η ανίχνευση πλοίων από αεροφωτογραφίες αποτελεί μια σημαντική και διαρκώς αναπτυσσόμενη περιοχή έρευνας στο πεδίο της υπολογιστικής όρασης και τηλεπισκόπησης. Η ικανότητα αυτόματης και ακριβούς αναγνώρισης πλοίων έχει πολλές πρακτικές εφαρμογές, όπως η επιτήρηση της ναυσιπλοΐας, η παρακολούθηση παράνομων δραστηριοτήτων στη θάλασσα, η διαχείριση λιμένων, καθώς και η προστασία του περιβάλλοντος (Li et al., 2019; Guo et al., 2023). Οι εναέριες εικόνες παρέχουν μια εκτενή και λεπτομερή οπτική καταγραφή της θαλάσσιας επιφάνειας, γεγονός που καθιστά την ανίχνευση πλοίων από αυτές κρίσιμη για την επίτευξη υψηλής αποτελεσματικότητας και ακρίβειας στην ανάλυση δεδομένων (Xia et al., 2018). Ωστόσο, η πολυπλοκότητα των εικόνων, η μικρή κλίμακα των στόχων και οι διάφορες περιβαλλοντικές συνθήκες αποτελούν σημαντικές προκλήσεις για τις μεθόδους ανίχνευσης (Wang et al., 2020).

Η ταξινόμηση και ο εντοπισμός πλοίων σε εναέριες εικόνες υψηλής ανάλυσης αποτελεί σημαντικό πεδίο έρευνας με εφαρμογές στη ναυτική ασφάλεια, τη διαχείριση λιμένων και την παρακολούθηση της ναυτιλίας (Gallego et al., 2019). Η συνεχώς αυξανόμενη διαθεσιμότητα εναέριων εικόνων από drones και αεροπλάνα παρέχει τη δυνατότητα αυτόματης ανάλυσης και εξαγωγής πληροφορίας από αυτά τα δεδομένα. Ωστόσο, τα ιδιαίτερα χαρακτηριστικά των εναέριων εικόνων, όπως η ποικιλία κλίμακας, η γωνία λήψης και η πολυπλοκότητα του φόντου, θέτουν σημαντικές προκλήσεις για τις υπάρχουσες μεθόδους ανίχνευσης και ταξινόμησης αντικειμένων.

1.2 Καθορισμός του Σκοπού και των Στόχων της εργασίας

Ο κύριος σκοπός της παρούσας εργασίας είναι η διερεύνηση και βελτίωση των μεθόδων ανίχνευσης πλοίων από αεροφωτογραφίες, με έμφαση στην ανίχνευση μικροσκοπικών και πυκνο-κατοικημένων πλοίων σε σύνθετα θαλάσσια περιβάλλοντα. Για την επίτευξη αυτού του σκοπού, η εργασία αποσκοπεί στους εξής επιμέρους στόχους: α) την ανασκόπηση και

ανάλυση της υπάρχουσας βιβλιογραφίας και σύγχρονων τεχνικών ανίχνευσης πλοίων, β) την υλοποίηση ενός μοντέλου ανίχνευσης βασισμένου σε νευρωνικά δίκτυα, γ) την αξιολόγηση της απόδοσης του μοντέλου σε σύνολα δεδομένων αεροφωτογραφιών και δ) τη σύγκριση με υπάρχουσες μεθόδους (Sun et al., 2017; Huang et al., 2019; Wang et al., 2020). Μέσω αυτής της διαδικασίας, επιδιώκεται η συμβολή στην ενίσχυση της ακρίβειας και της αποδοτικότητας στην ανίχνευση πλοίων, με πιθανή εφαρμογή σε πραγματικά συστήματα επιτήρησης.

1.3 Επισκόπηση του προβλήματος εντοπισμού πλοίων από αεροφωτογραφίες

Καθώς η ανίχνευση αντικειμένων σε εναέριες εικόνες χαρακτηρίζεται από προκλήσεις όπως η μεγάλη διακύμανση στο μέγεθος και τη μορφή των αντικειμένων, η παρουσία πολλαπλών κλιμάκων και γωνιών, καθώς και η ποικιλία των περιβαλλόντων όπου εμφανίζονται τα αντικείμενα. Για παράδειγμα, το φόντο ενός πλοίου μπορεί να περιλαμβάνει θάλασσα, ακτή ή άλλα κοντινά αντικείμενα, γεγονός που δυσχεραίνει τον διαχωρισμό του πλοίου από το περιβάλλον.

Ο εντοπισμός πλοίων από αεροφωτογραφίες είναι μια απαιτητική εργασία λόγω διαφόρων τεχνικών και φυσικών δυσκολιών. Τα πλοία εμφανίζονται σε διαφορετικές κλίμακες, γωνίες και περιβάλλοντα, γεγονός που περιπλέκει την ορθή αναγνώρισή τους (Iervolino et al., 2016; Graziano et al., 2016). Επιπλέον, η παρουσία θορύβου, οι μεταβολές φωτισμού και η ύπαρξη παραπλανητικών στοιχείων στη θάλασσα αποτελούν πρόσθετες προκλήσεις (Sameer et al., 2025). Παραδοσιακές μέθοδοι βασίζονται σε χειροποίητα χαρακτηριστικά, ωστόσο, τα τελευταία χρόνια, οι μέθοδοι που βασίζονται σε βαθιά νευρωνικά δίκτυα (Deep Learning) έχουν επιφέρει σημαντικές βελτιώσεις στην απόδοση και την ευελιξία των ανιχνευτών (Sun et al., 2017; Huang et al., 2019). Παρ’ όλα αυτά, η ανίχνευση μικροσκοπικών πλοίων και η αντιμετώπιση πυκνών σκηνών παραμένουν ενεργά ερευνητικά θέματα, με συνεχή προσπάθεια για την ανάπτυξη πιο εξειδικευμένων και αποδοτικών μοντέλων (Wang et al., 2020).

Η ταξινόμηση και ο εντοπισμός πλοίων σε εναέριες εικόνες υψηλής ανάλυσης έχει προσελκύσει έντονο ενδιαφέρον λόγω των πολλαπλών εφαρμογών της στη ναυτική ασφάλεια, τη διαχείριση λιμένων, την παρακολούθηση της παράνομης αλιείας, καθώς και

στη ναυτική βιομηχανία (Gallego et al., 2019). Η αυξανόμενη διαθεσιμότητα εναέριων εικόνων από drones και αεροπλάνα προσφέρει νέες δυνατότητες για την αυτόματη ανάλυση αυτών των εικόνων, ωστόσο τα ιδιαίτερα χαρακτηριστικά τους επιβάλλουν την ανάπτυξη εξειδικευμένων μεθόδων.

Χαρακτηριστικά και προκλήσεις των εναέριων εικόνων:

Οι εναέριες εικόνες περιλαμβάνουν ποικίλα χαρακτηριστικά αντικειμένων και περιβάλλοντος, που διαφοροποιούνται ανάλογα με τον τύπο της λήψης και τη γωνία προβολής. Πολλά αντικείμενα εμφανίζονται σε διαφορετικές κλίμακες, περιστροφές 0 έως 360 μοιρών, καθώς και σε σύνθετα και μη ομοιόμορφα περιβάλλοντα, γεγονός που αυξάνει την πολυπλοκότητα της ανάλυσης. Για παράδειγμα, μια γέφυρα μπορεί να περιβάλλεται από άμμο, νερό ή συνδυασμό αυτών, ενώ ορισμένα ομοειδή αντικείμενα, όπως γήπεδα μπάσκετ και τένις, παρουσιάζουν χαμηλή διακύμανση στο φόντο τους, δυσχεραίνοντας την ταξινόμησή τους.

Η ανίχνευση αντικειμένων στις εναέριες εικόνες αποτελεί μια απαιτητική διαδικασία που περιλαμβάνει τον εντοπισμό και την ταξινόμηση των αντικειμένων, λαμβάνοντας υπόψη τη διαφοροποίηση στο μέγεθος των αντικειμένων (από μικρά πλοία έως μεγαλύτερα πεδία), τις εποχιακές μεταβολές και τη γωνία λήψης των αισθητήρων. Η παρουσία πολλών αντικειμένων σε διαφορετικές κλίμακες και η ποικιλία των πληροφοριών φόντου απαιτούν την ανάπτυξη μεθόδων που μπορούν να εξάγουν σταθερά και πλούσια χαρακτηριστικά από τα δεδομένα.

Προηγούμενες μέθοδοι και προσεγγίσεις:

Οι προσεγγίσεις που βασίζονται σε συνελικτικά νευρωνικά δίκτυα (CNN) έχουν αποδειχθεί ιδιαίτερα αποτελεσματικές στην ανίχνευση αντικειμένων, κυρίως σε φυσικές εικόνες (Everingham et al., 2010, MS COCO - Lin et al., 2014). Ωστόσο, η απευθείας εφαρμογή αυτών των μεθόδων στις εναέριες εικόνες δεν επιτυγχάνει πάντα βέλτιστα αποτελέσματα, λόγω των ιδιαίτερων προκλήσεων που παρουσιάζουν οι εναέριες εικόνες.

Προκειμένου να αντιμετωπιστούν αυτές οι προκλήσεις, έχουν προταθεί ειδικά μοντέλα για την ανίχνευση αντικειμένων πολλαπλών κλιμάκων. Για παράδειγμα, το δίκτυο CAD-Net (Zhang et al., 2019c) χρησιμοποιεί το ResNet (He et al., 2016) και το δίκτυο πυραμίδας χαρακτηριστικών (FPN) (Lin et al., 2017) για την εξαγωγή πολυεπίπεδων χαρακτηριστικών και την κατασκευή τοπικών και παγκόσμιων περιβαλλόντων των αντικειμένων. Ωστόσο, το

CAD-Net αντιμετωπίζει δυσκολίες στην εκμάθηση πολύπλοκων συμφραζόμενων σε πολλαπλές κλίμακες και οπτικές γωνίες.

Μια άλλη προσέγγιση, το δίκτυο GSDet (Zhang et al., 2019), ενσωματώνει διευρυμένες συνελίξεις για καλύτερη ανίχνευση αντικειμένων διαφόρων μεγεθών και συνδυάζει πληροφορίες απόστασης δειγμάτων εδάφους, ενισχύοντας έτσι την ακρίβεια ανίχνευσης. Παρόλα αυτά, το GSDet δεν περιλαμβάνει μονάδες που να αποσταγάζουν με αποδοτικό τρόπο τα χαρακτηριστικά πολλαπλών κλιμάκων.

Εντοπισμός και ταξινόμηση πλοίων:

Η έρευνα στον εντοπισμό και την ταξινόμηση πλοίων χωρίζεται συνήθως σε δύο βασικούς τομείς: (α) τον εντοπισμό της θέσης των πλοίων σε εικόνες, δηλαδή τον εντοπισμό τους, και (β) την ταξινόμηση των πλοίων σε διαφορετικές κατηγορίες (Gallego et al., 2019). Η ακρίβεια και η αποδοτικότητα αυτών των διαδικασιών είναι ζωτικής σημασίας για εφαρμογές όπως η παρακολούθηση λιμένων, η διαχείριση ναυτικών κινδύνων και η θαλάσσια ασφάλεια.

ΚΕΦΑΛΑΙΟ 2

ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ

2.1 Ανάλυση προηγούμενων ερευνών σχετικά με τον εντοπισμό πλοίων από αεροφωτογραφίες

Τα τελευταία χρόνια, έχουν προταθεί και χρησιμοποιηθεί πολλά σύνολα δεδομένων για την ανίχνευση αντικειμένων σε εναέριες εικόνες, όπως τα NWPU VHR-10 (Liu et al., 2017), HRSC2016 (Liu et al., 2017), VEDAI (Razakarivony and Jurie, 2016), xView (Lam et al., 2018), DOTA (Xia et al., 2018), VisDrone (Zhu et al., 2018), UAVDT (Du et al., 2018) και DIOR (Li et al., 2019). Ωστόσο, τα αντικείμενα σε αυτά τα σύνολα δεδομένων έχουν ποικίλες κλίμακες, γεγονός που καθιστά τα σύνολα αυτά πιο κατάλληλα για την αξιολόγηση ανιχνευτών πολλαπλών κλιμάκων παρά για την ανίχνευση μικροσκοπικών αντικειμένων.

Σε σύγκριση με τις παραδοσιακές μεθόδους ανίχνευσης που βασίζονται σε χειροποίητα χαρακτηριστικά, οι μέθοδοι βασισμένες σε Συνελικτικά Νευρωνικά Δίκτυα (CNN) έχουν σημειώσει σημαντική πρόοδο τόσο στην ακρίβεια όσο και στην ταχύτητα. Οι CNN ανιχνευτές διακρίνονται κυρίως σε anchor-based και anchor-free κατηγορίες (Zhao et al., 2019). Η ανίχνευση αντικειμένων σε εναέριες εικόνες παραμένει πρόκληση, ειδικά όταν τα αντικείμενα είναι μικροσκοπικά, όπως μικρά οχήματα με λιγότερα από 8 pixels (Wang et al., 2020).

Στον τομέα της τηλεπισκόπησης, ο εντοπισμός πλοίων έχει δεχθεί μεγάλη προσοχή λόγω της σημασίας του σε εφαρμογές όπως η επιτήρηση θαλάσσιων ζωνών και η διαχείριση λιμένων. Πρωτοποριακές μέθοδοι, όπως η δοκιμή γενικευμένης αναλογίας πιθανότητας (GLRT) (Iervolino & Guida, 2017), έχουν βελτιώσει την ανίχνευση κάτω από δύσκολες συνθήκες θορύβου. Ο μετασχηματισμός Ραδονίου έχει επίσης χρησιμοποιηθεί επιτυχώς για την ανίχνευση πλοίων (Graziano et al., 2016). Αλγόριθμοι όπως ο Low-Rank and Sparse Decomposition (LRSD) με τη βοήθεια του RT έχουν προσφέρει εξαιρετική απόδοση στην ανίχνευση αφύπνισης πλοίων (Mazzeo et al., 2023).

Με την ανάπτυξη των Deep Convolutional Neural Networks (DCNN), προτάθηκαν πολλά σύγχρονα πλαίσια ανίχνευσης πλοίων. Για παράδειγμα, το SVDNet (Sun et al., 2017)

χρησιμοποιεί συνελικτικά δίκτυα και αλγόριθμους αντιστάθμισης μοναδικής τιμής για την προσαρμοστική εκμάθηση χαρακτηριστικών. Το Squeeze Excitation Skip-connection Path network (SESPNet) (Huang et al., 2019) βελτιώνει την εξαγωγή χαρακτηριστικών και χρησιμοποιεί μαλακή μη μέγιστη καταστολή (NMS) για αποφυγή διαγραφής έγκυρων πλαισίων οριοθέτησης. Παρόλα αυτά, οι περισσότερες μέθοδοι βασίζονται σε οριζόντια bounding boxes, τα οποία δεν είναι ιδανικά για πυκνά ελλιμενισμένα σκάφη ή πλοία με αυθαίρετη γωνία περιστροφής (Wang et al., 2020).

Σημαντική συμβολή στην ανίχνευση μικροσκοπικών αντικειμένων έδωσε το σύνολο δεδομένων AI-TOD που παρουσίασαν οι Wang et al. (2020b). Με πάνω από 700.000 αντικείμενα σε 28.000 αεροφωτογραφίες, το AI-TOD χαρακτηρίζεται από αντικείμενα μέσου μεγέθους μόλις 12,8 pixel. Η αξιολόγηση υπαρχουσών ανιχνευτών στο AI-TOD έδειξε μη βέλτιστα αποτελέσματα, υποδεικνύοντας την ανάγκη για εξειδικευμένες προσεγγίσεις, όπως το δίκτυο μάθησης πολλαπλών σημείων M-CenterNet που προτάθηκε από τους ίδιους (Xu et al., 2022).

Πρόσφατες έρευνες προωθούν περαιτέρω την ακρίβεια και την ευελιξία στην ανίχνευση πλοίων. Ο Xu et al. (2021) χρησιμοποίησε μηχανισμούς attention και πολυ-κλίμακα χαρακτηριστικά για την βελτίωση της ανίχνευσης μικρών και πυκνών πλοίων σε σύνθετα περιβάλλοντα. Παράλληλα, ο Zeng et al. (2024) εισήγαγε Vision Transformers για την αντιμετώπιση προβλημάτων κλίμακας και περιστροφής πλοίων, ξεπερνώντας τις επιδόσεις των παραδοσιακών CNN.

Επιπλέον, η χρήση Generative Adversarial Networks (GANs) για αύξηση δεδομένων και βελτίωση χαρακτηριστικών σε δυσμενείς συνθήκες φωτισμού έχει μελετηθεί από τον Liu et al. (2023), ενώ η πολύ-κατηγορική ανίχνευση και ταξινόμηση πλοίων με ενσωμάτωση χωρικών και φασματικών χαρακτηριστικών παρουσιάστηκε από τον Zhang et al. (2019b), συμβάλλοντας στην ακριβέστερη αναγνώριση τύπων πλοίων σε δορυφορικές εικόνες.

Συνολικά, οι πρόσφατες εξελίξεις δείχνουν ότι η συνδυαστική χρήση προηγμένων δικτύων, attention μηχανισμών, και τεχνικών αύξησης δεδομένων προσφέρουν σημαντικές βελτιώσεις στην ανίχνευση πλοίων από αεροφωτογραφίες, αν και η πρόκληση παραμένει λόγω των μικρών αντικειμένων, της ποικιλίας γωνιών και των διαφορετικών περιβαλλόντων.

2.1.1 Προηγούμενες μελέτες εστιασμένες σε YOLO-based μοντέλα για τον εντοπισμό πλοίων σε εναέριες/τηλεσκοπικές εικόνες.

Οι μέθοδοι βασισμένες στην αρχιτεκτονική YOLO έχουν κυριαρχήσει στην ανίχνευση πλοίων από εναέριες και τηλεπισκοπικές εικόνες, λόγω της υψηλής ακρίβειας και της ταχύτητας που προσφέρουν.

Υπάρχουν τροποποιημένες παραλλαγές του μοντέλου YOLO, που έχουν σχεδιαστεί ειδικά για τη βελτίωση της ανίχνευσης πλοίων από εναέριες εικόνες (ή/και δορυφορικές/SAR εικόνες). Μερικές από αυτές είναι:

Το Ship-YOLO (Shi et al., 2025) αποτελεί μια εξειδικευμένη παραλλαγή του δημοφιλούς αλγορίθμου YOLO, προσαρμοσμένη ώστε να αντιμετωπίζει τις ιδιαίτερες προκλήσεις του θαλάσσιου περιβάλλοντος, όπως η ποικιλομορφία των μεγεθών των πλοίων, η πυκνή παρουσία αντικειμένων και οι πολύπλοκες συνθήκες φόντου. Προσαρμόζουν και ενισχύουν το αρχικό Ship-YOLO με τεχνικές βελτιστοποίησης δικτύου και πολυεπίπεδη ανάλυση χαρακτηριστικών, προκειμένου να αυξήσουν την ευαισθησία στην ανίχνευση μικρών και δύσκολα ανιχνεύσιμων πλοίων. Επιπλέον, εφαρμόζουν προσεγγίσεις που μειώνουν τους ψευδείς συναγερμούς και βελτιώνουν την ταχύτητα εκτέλεσης, καθιστώντας το μοντέλο κατάλληλο για πραγματικό χρόνο εφαρμογές. Τα αποτελέσματα της μελέτης δείχνουν σημαντική βελτίωση σε σχέση με προηγούμενες μεθόδους, με αυξημένα ποσοστά ανίχνευσης (precision και recall), ιδιαίτερα σε κατηγορίες μικρών και αραιά εμφανιζόμενων πλοίων. Παράλληλα, το βελτιωμένο Ship-YOLO διατηρεί υψηλές ταχύτητες επεξεργασίας, ικανοποιώντας τις απαιτήσεις πρακτικής εφαρμογής σε συστήματα παρακολούθησης UAV.

Το YOLO-SSBoat (Zeng et al., 2024) είναι η βελτιστοποιημένη έκδοση YOLOv5/YOLOv7 για τον εντοπισμό πολύ μικρών πλοίων (small boats), σχεδιασμένο για μεγάλες αεροφωτογραφίες, κατέδειξε πως ένα υπερ-συμπαγές μοντέλο μπορεί να επιτύχει ικανοποιητική απόδοση με περιορισμένους πόρους αφού είναι σχεδιασμένο για συνθήκες όπου τα πλοία καταλαμβάνουν πολύ λίγα pixel (π.χ. SAR ή UAV εικόνες). Το YOLO-SSBoat ενσωματώνει μηχανισμούς προσοχής και ειδικές τεχνικές για την καλύτερη ανάλυση μικρών και μεσαίων πλοίων σε σύνθετα θαλάσσια περιβάλλοντα. Τα πειράματα της μελέτης δείχνουν ότι το YOLO-SSBoat υπερέχει σε σχέση με τα βασικά μοντέλα YOLO σε όρους ακρίβειας (precision) και ανάκλησης (recall), με σημαντική βελτίωση στην ανίχνευση μικρών πλοίων και την αποφυγή ψευδώς θετικών αποτελεσμάτων. Επιπλέον, το μοντέλο

διατηρεί υψηλή ταχύτητα επεξεργασίας, καθιστώντας το κατάλληλο για εφαρμογές σε πραγματικό χρόνο, όπως η παρακολούθηση με UAV.

Η μελέτη PMF-YOLOv8 (Chen et al., 2024) είναι μια βελτιωμένη παραλλαγή του YOLOv8 που ενσωματώνει prior γνώση θέσης και πολλαπλές ροές χαρακτηριστικών (multi-feature fusion), η οποία βελτιστοποίησε το YOLOv8 με πολυ-κλιμακικό συνδυασμό χαρακτηριστικών (feature fusion), αυξάνοντας το mAP50-95 κατά ~4.1 %, ενώ η ταχύτητα έφτασε τα 74 fps. Εστίασε σε πολυ-κατηγοριακή ταξινόμηση πλοίων και έχει καλύτερη κατανόηση της θέσης πλοίων σε λιμάνια/θάλασσα. Παρουσίασε το μοντέλο PMF-YOLOv8, με μια βελτιωμένη έκδοση του YOLOv8 ειδικά σχεδιασμένη για την ανίχνευση πλοίων σε εναέριες εικόνες. Το μοντέλο ενσωματώνει μια προσαρμοσμένη μέθοδο πολυ-χαρακτηριστικών (multi-feature fusion) που επιτρέπει την καλύτερη αξιοποίηση των χωρικών και περιεχομένων πληροφοριών. Τα αποτελέσματα έδειξαν σημαντική βελτίωση στην ακρίβεια ανίχνευσης, ιδιαίτερα σε περιπτώσεις μικρών και απομακρυσμένων πλοίων, καθώς και μείωση των ψευδών συναγερμών συγκριτικά με βασικά μοντέλα YOLO. Το μοντέλο αυτό πέτυχε σημαντική αύξηση στην ακρίβεια ανίχνευσης (mAP) συγκριτικά με το βασικό YOLOv8, με βελτίωση περίπου 4-6% στα σύνολα δεδομένων ShipRSImageNet και άλλων αεροφωτογραφιών.

Το μοντέλο ALF-YOLO (Wang, et al., 2024), που είναι ένα ελαφρύ και αποδοτικό μοντέλο YOLO προσαρμοσμένο για πραγματικό χρόνο εντοπισμό πλοίων σε UAV εικόνες. Η έρευνά του συνδυάζει AFPN, LSK attention και detection head, επιτυγχάνοντας βελτίωση στην ανίχνευση ship port σε σύνθετα περιβάλλοντα. Προσφέρει λιγότερες παραμέτρους και γρηγορότερη εκτέλεση. Το ALF-YOLO (Adaptive Lightweight Fusion YOLO) αποτελεί μια πρόσφατη καινοτομία στην ανίχνευση πλοίων, ειδικά σχεδιασμένη για την επεξεργασία εναέριων εικόνων που προέρχονται από μη επανδρωμένα αεροσκάφη (UAVs). Βασισμένο στο YOLOv8, το ALF-YOLO τροποποίησε την αρχιτεκτονική του με στόχο τη βελτίωση της ακρίβειας και της ταχύτητας εντοπισμού σε πραγματικό χρόνο, διατηρώντας ταυτόχρονα χαμηλές υπολογιστικές απαιτήσεις.

Ένας βασικός πυλώνας του είναι η χρήση του AFPN (Asymptotic Feature Pyramid Network), που επιτρέπει την αποτελεσματική συγχώνευση χαρακτηριστικών πολλαπλών κλιμάκων. Η τεχνική αυτή ενισχύει την ικανότητα του μοντέλου να αναγνωρίζει πλοία διαφόρων μεγεθών και υπό διαφορετικές συνθήκες. Δοκιμάστηκε σε γνωστά dataset για ανίχνευση πλοίων όπως τα SeaShips και McShips, επιτυγχάνοντας σημαντική βελτίωση της

ακρίβειας. Συγκεκριμένα, καταγράφηκε αύξηση της απόδοσης mAP@0.5 κατά 0.41% στο SeaShips και 0.43% στο McShips σε σύγκριση με το YOLOv8.

Τέλος, η μελέτη Bibi et al. (2025) χρησιμοποίησε YOLOv8 μαζί με U-Net για ανθεκτική ανίχνευση και segmentation πλοίων με οποιονδήποτε προσανατολισμό, πετυχαίνοντας mAP≈88–89%. Η μελέτη των Bibi et al. (2025) επικεντρώνεται στον εντοπισμό πλοίων σε εναέριες εικόνες, ειδικά όταν αυτά εμφανίζονται με τυχαίο προσανατολισμό, γεγονός που καθιστά δύσκολη την αναγνώρισή τους από συμβατικά μοντέλα ανίχνευσης. Για την αντιμετώπιση αυτής της πρόκλησης, προτείνεται ένα υβριδικό σύστημα που συνδυάζει το αντικειμενοστραφές μοντέλο YOLOv8 με ένα προσαρμοσμένο U-Net για segment-based προσέγγιση. Η πειραματική αξιολόγηση βασίστηκε στο σύνολο δεδομένων Airbus Ship Detection, ένα ευρέως χρησιμοποιούμενο dataset με σημαντική ποικιλία σε γωνίες θέασης, φωτισμό και φόντο. Τα αποτελέσματα έδειξαν ότι ο συνδυασμός YOLOv8 και U-Net απέδωσε πολύ καλά, με mAP περίπου 88% για το μοντέλο YOLO και 89% για το μοντέλο U-Net. Τα ευρήματα υποδεικνύουν ότι ο συνδυασμός detection και segmentation προσφέρει ένα ισχυρό εργαλείο για την ανίχνευση πλοίων σε δύσκολες συνθήκες, ιδιαίτερα σε αποστολές εναέριας επιτήρησης, περιβαλλοντικού ελέγχου ή διαχείρισης κρίσεων.

Συνεπώς, οι σύγχρονες επεκτάσεις του YOLO (LiteConv, BiFaPN, attention modules) ενισχύουν σημαντικά την ακρίβεια και την ανθεκτικότητα στην ανίχνευση πλοίων, ειδικά σε πολυσύνθετα εναέρια ή SAR περιβάλλοντα. Παρότι οι βασικοί περιορισμοί παραμένουν οι μικρές/αυθαίρετα προσανατολισμένες και αραιοκατανεμημένες κατηγορίες, η συνεχής εξέλιξη των YOLO-μοντέλων δείχνει σταθερή πρόοδο και βελτίωση της ακρίβειας με παράλληλη διατήρηση της αποτελεσματικότητας σε πραγματικό χρόνο.

2.2 Παρουσίαση διαφόρων μεθόδων και τεχνικών που χρησιμοποιούνται

Η ανίχνευση και εντοπισμός πλοίων σε αεροφωτογραφίες αποτελεί σημαντικό πεδίο εφαρμογής στην ανάλυση εικόνας και όραση υπολογιστή, με εφαρμογές που περιλαμβάνουν τη ναυτική ασφάλεια, την επιτήρηση ακτών και την περιβαλλοντική προστασία. Λόγω των ιδιαίτερων χαρακτηριστικών των αεροφωτογραφιών, όπως η μεγάλη ποικιλία στις κλίμακες, οι διαφορετικές οπτικές γωνίες και οι μεταβαλλόμενες συνθήκες φωτισμού, η διαδικασία

αυτή παρουσιάζει αρκετές προκλήσεις. Παρακάτω αναφέρονται διάφορες μέθοδοι που χρησιμοποιούνται για τον εντοπισμό πλοίων από αεροφωτογραφίες:

1. Παραδοσιακές Μέθοδοι

Ιστορικά, ο εντοπισμός πλοίων βασιζόταν σε παραδοσιακές μεθόδους επεξεργασίας εικόνας, όπως η χρήση φίλτρων για την ανίχνευση ακμών (edge detection) και τη διαμόρφωση χαρακτηριστικών (feature extraction). Μέθοδοι όπως ο ανιχνευτής Canny ή οι αλγόριθμοι SIFT και SURF χρησιμοποιήθηκαν για την ανάδειξη χαρακτηριστικών που βοηθούν στον εντοπισμό σχημάτων που αντιστοιχούν σε πλοία (Zou et al., 2019). Ωστόσο, αυτές οι τεχνικές είχαν περιορισμένη ανθεκτικότητα στις παραμορφώσεις και το θόρυβο των εικόνων.

2. Μέθοδοι Βασισμένες σε Μηχανική Μάθηση

Η εισαγωγή τεχνικών μηχανικής μάθησης βελτίωσε σημαντικά την απόδοση στον εντοπισμό πλοίων. Αρχικά, χρησιμοποιήθηκαν αλγόριθμοι όπως οι Support Vector Machines (SVM) και τα Random Forests, οι οποίοι εκπαιδεύτηκαν σε σύνολα χαρακτηριστικών εξαγόμενων από τις εικόνες (Shi et al., 2025). Παρότι πιο αποδοτικοί από τις παραδοσιακές μεθόδους, αυτοί οι αλγόριθμοι απαιτούσαν χειροκίνητη επιλογή χαρακτηριστικών και δεν γενικεύονταν εύκολα.

3. Βαθιά Νευρωνικά Δίκτυα και Συνελικτικά Νευρωνικά Δίκτυα (CNNs)

Η ανάπτυξη της βαθιάς μάθησης, και συγκεκριμένα των CNNs, άλλαξε ριζικά το πεδίο της ανίχνευσης αντικειμένων. Τα CNNs έχουν την ικανότητα να μαθαίνουν αυτόματα αντιπροσωπευτικά χαρακτηριστικά από δεδομένα και να επιτυγχάνουν υψηλή ακρίβεια σε δύσκολες συνθήκες (Zhou et al., 2019). Συγκεκριμένα, δίκτυα όπως το Faster R-CNN, SSD και το YOLO (You Only Look Once) έχουν χρησιμοποιηθεί με επιτυχία στον εντοπισμό πλοίων σε αεροφωτογραφίες.

Η μέθοδος YOLO είναι ιδιαίτερα δημοφιλής λόγω της ταχύτητας και της ικανότητάς της να εκτελεί εντοπισμό σε πραγματικό χρόνο. Η πιο πρόσφατη έκδοση YOLOv8, προσφέρει ακόμα καλύτερη ακρίβεια και απόδοση (Jocher et al., 2023). Τα δίκτυα αυτά είναι ικανά να ανιχνεύουν πλοία σε διαφορετικές κλίμακες, ακόμη και υπό δυσμενείς συνθήκες φωτισμού ή μερικής απόκρυψης.

4. Τεχνικές Βελτίωσης Ακριβείας

Προκειμένου να βελτιωθεί η ακρίβεια και η ευρωστία (*robustness, δηλαδή* «ανθεκτικότητα» του μοντέλου σε μεταβολές και απρόβλεπτες καταστάσεις) των μοντέλων, έχουν προταθεί μέθοδοι όπως η χρήση μετα-μάθησης (transfer learning), όπου τα δίκτυα προεκπαιδεύονται σε μεγάλα σύνολα δεδομένων και στη συνέχεια προσαρμόζονται σε εξειδικευμένα δεδομένα πλοίων (Zhao et al., 2023). Επιπλέον, τεχνικές augmentations, όπως περιστροφές, αλλαγές φωτεινότητας και χρήση τεχνητού θορύβου, αυξάνουν την ποικιλία του εκπαιδευτικού συνόλου και βελτιώνουν τη γενίκευση.

Συνολικά, η πρόοδος στον εντοπισμό πλοίων από αεροφωτογραφίες προήλθε από τη μετάβαση από παραδοσιακές τεχνικές επεξεργασίας εικόνας σε προηγμένα μοντέλα βαθιάς μάθησης, με τα CNNs και ειδικότερα το YOLO να αποτελούν την πιο σύγχρονη και αποτελεσματική προσέγγιση στον τομέα.

ΚΕΦΑΛΑΙΟ 3

ΜΕΘΟΔΟΛΟΓΙΑ

3.1 Νευρωνικά Δίκτυα

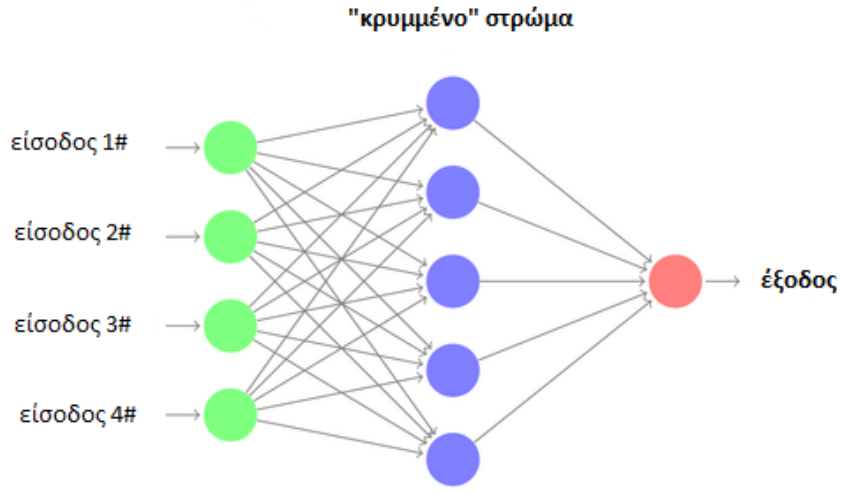
Τα νευρωνικά δίκτυα ανήκουν στην ευρύτερη κατηγορία της Τεχνητής Νοημοσύνης (Artificial Intelligence-AI) και συγκεκριμένα στον τομέα της Μηχανικής Μάθησης (Machine Learning). Μέσα στη μηχανική μάθηση, τα νευρωνικά δίκτυα είναι ένα υποσύνολο της Βαθιάς Μάθησης (Deep Learning), όπου τα μοντέλα αποτελούνται από πολλαπλά επίπεδα (layers) νευρώνων που επιτρέπουν την εκμάθηση σύνθετων αναπαραστάσεων και προτύπων από δεδομένα. Συνεπώς, θα μπορούσαμε να πούμε ότι τα νευρωνικά δίκτυα είναι η "καρδιά" της βαθιάς μάθησης, που με τη σειρά της αποτελεί προέκταση της μηχανικής μάθησης στον χώρο της τεχνητής νοημοσύνης.

Πρόκειται για υπολογιστικά μοντέλα εμπνευσμένα από τον ανθρώπινο εγκέφαλο (Goodfellow, Bengio & Courville, 2016). Αποτελούνται από διαδοχικά επίπεδα τεχνητών νευρώνων που μαθαίνουν να αναγνωρίζουν μοτίβα μέσα από παραδείγματα (LeCun, Bengio & Hinton, 2015). Στην όραση υπολογιστών, τα συνελικτικά νευρωνικά δίκτυα (CNNs) είναι τα πλέον διαδεδομένα για την αναγνώριση εικόνων και την ανίχνευση αντικειμένων (Schmidhuber, 2015).

Τα τεχνητά νευρωνικά δίκτυα (Artificial Neural Networks-ANNs) αποτελούν έναν από τους σημαντικότερους τομείς της τεχνητής νοημοσύνης και έχουν εμπνευστεί από τη βιολογική δομή και λειτουργία του ανθρώπινου εγκεφάλου (Goodfellow, Bengio & Courville, 2016). Ο βασικός τους στόχος είναι η δυνατότητα εκμάθησης από δεδομένα, ώστε να μπορούν να αναγνωρίζουν πρότυπα, να λαμβάνουν αποφάσεις και να πραγματοποιούν προβλέψεις ακόμα και σε περιπτώσεις που δεν έχει δοθεί σαφής αλγοριθμικός κανόνας (Murphy, 2012).

Στην δομή του ένα νευρωνικό δίκτυο αποτελείται από τεχνητούς νευρώνες (ή κόμβους), οι οποίοι είναι οργανωμένοι σε επίπεδα (layers). Υπάρχει το εισαγωγικό επίπεδο (input layer), ένα ή περισσότερα κρυφά επίπεδα (hidden layers) και το τελικό επίπεδο εξόδου (output layer) (Goodfellow, Bengio & Courville, 2016). Κάθε νευρώνας δέχεται αριθμητικά σήματα (τιμές χαρακτηριστικών) από τους νευρώνες του προηγούμενου επιπέδου, τα επεξεργάζεται μέσω μίας συναρτησιακής μετασχηματιστικής λειτουργίας και μεταδίδει το αποτέλεσμα στο

επόμενο επίπεδο. Οι συνδέσεις μεταξύ των νευρώνων έχουν βάρη (weights), τα οποία τροποποιούνται κατά τη διαδικασία της εκπαίδευσης ώστε το δίκτυο να προσεγγίζει σταδιακά την επιθυμητή συμπεριφορά (LeCun, Bengio & Hinton, 2015).



Εικόνα 1: Τυπική δομή ενός νευρωνικού δικτύου που απεικονίζει τα επίπεδα εισόδου, τα κρυφά επίπεδα και το επίπεδο εξόδου, καθώς και τη ροή των σημάτων μεταξύ των νευρώνων (Πηγή: Techmaniacs, 2024)

Η διαδικασία της εκπαίδευσης βασίζεται σε μεθόδους βελτιστοποίησης και κυρίως στον αλγόριθμο της οπισθοδιάδοσης (backpropagation), όπου με τη βοήθεια της συνάρτησης κόστους (loss function) υπολογίζεται το σφάλμα μεταξύ της πρόβλεψης του δικτύου και της πραγματικής τιμής, και στη συνέχεια το σφάλμα αυτό διαχέεται προς τα πίσω στο δίκτυο ώστε να ενημερωθούν κατάλληλα τα βάρη των συνδέσεων (Goodfellow, Bengio & Courville, 2016). Μέσω επαναλήψεων (εποχών – epochs) και χρήσης κατάλληλων τεχνικών, όπως η στοχαστική καθοδική βαθμίδωση (stochastic gradient descent), τα νευρωνικά δίκτυα καταφέρνουν να μαθαίνουν από τα δεδομένα εισόδου με τρόπο αποδοτικό και γενικεύσιμο (Murphy, 2012).

Έχουν αποδειχθεί εξαιρετικά ικανά σε πληθώρα εφαρμογών, όπως στην αναγνώριση εικόνας, την επεξεργασία φυσικής γλώσσας, την ανάλυση ήχου, την πρόβλεψη σειρών και πολλά ακόμη (Goodfellow, Bengio & Courville, 2016). Ιδιαίτερα τα συνελικτικά νευρωνικά δίκτυα (Convolutional Neural Networks – CNNs) έχουν εξειδικευτεί στην επεξεργασία εικόνας και βίντεο, καθώς εκμεταλλεύονται τη χωρική συσχέτιση μεταξύ των pixel. Τα CNNs

χρησιμοποιούν φίλτρα (kernels) που "σαρώνουν" την εικόνα εντοπίζοντας χαρακτηριστικά όπως άκρα, σχήματα, υφές ή ακόμη και σύνθετα μοτίβα (LeCun et al., 2015).

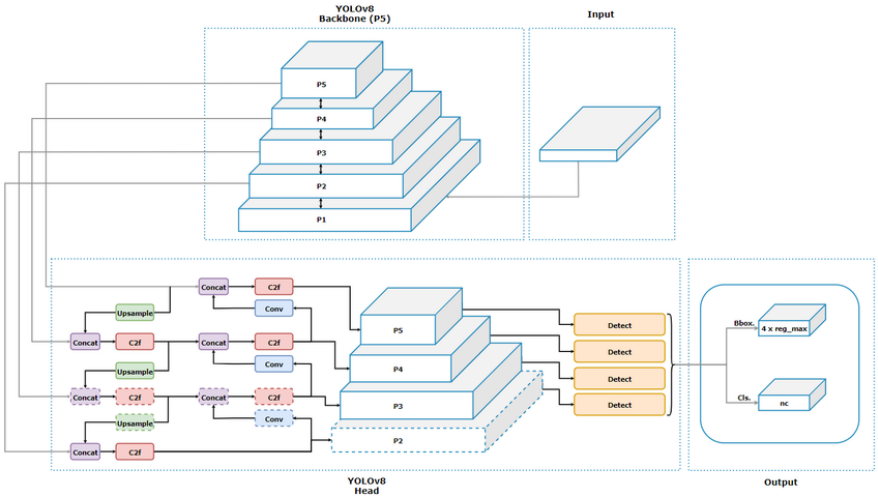
Η ραγδαία ανάπτυξη των νευρωνικών δικτύων τα τελευταία χρόνια έχει υποστηριχθεί από τη διαθεσιμότητα μεγάλων συνόλων δεδομένων (big data), την αύξηση της υπολογιστικής ισχύος (κυρίως μέσω GPUs) και την ανάπτυξη ισχυρών βιβλιοθηκών ανοιχτού κώδικα όπως PyTorch και TensorFlow (Paszke et al., 2019; Abadi et al., 2016). Η πρόοδος αυτή έχει οδηγήσει στην εμφάνιση προηγμένων δικτύων βαθιάς μάθησης (deep learning), τα οποία περιλαμβάνουν μεγάλο αριθμό επιπέδων και μπορούν να εκτελέσουν εξαιρετικά πολύπλοκες εργασίες, πολλές από τις οποίες προσεγγίζουν ή και ξεπερνούν την ανθρώπινη απόδοση (Krizhevsky, Sutskever & Hinton, 2012).

3.2 Μοντέλο YOLOv8m

Η μέθοδος που επιλέχθηκε για τον εντοπισμό των πλοίων βασίζεται σε ένα σύγχρονο συνελικτικό νευρωνικό δίκτυο τύπου YOLO, και πιο συγκεκριμένα στην έκδοση YOLOv8m (You Only Look Once version 8 – medium). Τα νευρωνικά δίκτυα αποτελούν υπολογιστικά μοντέλα εμπνευσμένα από τη λειτουργία του ανθρώπινου εγκεφάλου. Μέσω της χρήσης διαδοχικών επιπέδων τεχνητών νευρώνων, τα δίκτυα αυτά έχουν την ικανότητα να μαθαίνουν να αναγνωρίζουν σύνθετα μοτίβα και χαρακτηριστικά μέσα από παραδείγματα, προσφέροντας έτσι ισχυρές δυνατότητες σε εφαρμογές μηχανικής όρασης, όπως είναι η αναγνώριση και ανίχνευση αντικειμένων σε εικόνες (LeCun, Bengio & Hinton, 2015).

Η αρχιτεκτονική του YOLOv8m χωρίζεται σε τρία βασικά υποσυστήματα. Πρώτον, το μέρος του δικτύου που ονομάζεται backbone είναι υπεύθυνο για την εξαγωγή χαρακτηριστικών από την αρχική εικόνα. Χρησιμοποιεί την αρχιτεκτονική C2f, η οποία αποτελεί βελτιστοποιημένη παραλλαγή της CSPDarknet53, με στόχο τη διατήρηση της πληροφορίας σε μεγάλο βάθος και τη μείωση του υπολογιστικού κόστους (Wang et al., 2020). Δεύτερον, το τμήμα neck, που αποτελείται από το PANet (Path Aggregation Network) σε συνδυασμό με το Spatial Pyramid Pooling Fast (SPPF), είναι υπεύθυνο για τη συγχώνευση πληροφοριών πολλαπλών κλιμάκων ώστε να ενισχυθεί η ικανότητα του μοντέλου να εντοπίζει τόσο μικρούς όσο και μεγάλους στόχους (Liu et al., 2018; He et al., 2015). Τρίτον, το detection head της YOLOv8m είναι anchor-free, δηλαδή δεν απαιτεί προκαθορισμένα πλαίσια (anchor boxes) για την εντόπιση αντικειμένων. Η προσέγγιση αυτή απλοποιεί την ανίχνευση και ταυτόχρονα

αυξάνει την ακρίβεια εντοπισμού, ιδίως για πολύ μικρά ή ασυνήθιστα αντικείμενα (Ultralytics, 2023).



Εικόνα 2: Αρχιτεκτονική του YOLOv8m (Πηγή: Ultralytics, 2023)

Η επιλογή της συγκεκριμένης έκδοσης του μοντέλου (YOLOv8m) βασίστηκε σε μια σειρά από κριτήρια. Σε σχέση με τα μικρότερα μοντέλα της ίδιας οικογένειας (όπως YOLOv8n ή YOLOv5n), η έκδοση "m" προσφέρει σημαντικά βελτιωμένη ακρίβεια χωρίς να απαιτεί υπερβολικούς υπολογιστικούς πόρους. Παράλληλα, συγκρινόμενη με βαρύτερα μοντέλα (όπως YOLOv8l ή YOLOv8x), αποτελεί μια ιδιαίτερα ισορροπημένη επιλογή όσον αφορά την απόδοση και την ταχύτητα εκπαίδευσης και αναγνώρισης (Jocher et al., 2023) . Επιπλέον, η βιβλιοθήκη Ultralytics που υποστηρίζει το YOLOv8 προσφέρει εύχρηστο περιβάλλον εκπαίδευσης και ανάπτυξης, υποστήριξη για πολλαπλές πλατφόρμες, και δυνατότητες εξαγωγής του μοντέλου σε ελαφριές μορφές όπως TensorRT, ONNX και CoreML (Ultralytics, 2023).

Τέλος, η YOLOv8m αποτελεί ιδανική λύση για το συγκεκριμένο έργο καθώς συνδυάζει υψηλή ακρίβεια στην ανίχνευση πλοίων, υποστήριξη πολλών κατηγοριών, και δυνατότητα λειτουργίας ακόμα και σε περιβάλλοντα περιορισμένων πόρων, όπως για παράδειγμα σε έναν υπολογιστή Apple M1. Αυτά τα χαρακτηριστικά την καθιστούν κατάλληλη για εφαρμογές σε περιβάλλοντα πεδίου, αλλά και για περαιτέρω ανάπτυξη ερευνητικών εφαρμογών (Jocher et al., 2023; Ultralytics, 2023).

Γιατί το YOLOv8m:

Κριτήριο	**Περιγραφή**
Απόδοση	Πολύ καλή ακρίβεια (mAP50 έως και 81%) με λογικούς πόρους
Ευκολία Χρήσης	Η βιβλιοθήκη Ultralytics παρέχει απλό API και υποστήριξη export σε TFLite, ONNX, CoreML κ.ά.
Ευελιξία	Υποστήριξη anchor-free head για καλύτερη γενίκευση σε νέες κατηγορίες
Συμβατότητα	Λειτουργεί ακόμα και σε περιβάλλοντα χωρίς GPU, όπως Mac M1

Πίνακας 1: **Αξιολόγηση βασικών κριτηρίων επιλογής του μοντέλου YOLOv8m**

3.3 Περιγραφή της μεθοδολογίας που χρησιμοποιήθηκε για τον εντοπισμό των πλοίων

Για την υλοποίηση του συστήματος εντοπισμού πλοίων χρησιμοποιήθηκε η προσέγγιση ανίχνευσης αντικειμένων (object detection) μέσω σύγχρονων μεθόδων βαθιάς μάθησης. Συγκεκριμένα, υιοθετήθηκε το μοντέλο YOLOv8m (You Only Look Once version 8 - medium), το οποίο προσφέρει υψηλή ακρίβεια με αποδοτική υπολογιστική επίδοση.

Η εκπαίδευση του μοντέλου πραγματοποιήθηκε με εποπτευόμενο τρόπο, βασισμένη σε δεδομένα με προκαθορισμένα ορθογώνια πλαίσια (bounding boxes) για κάθε πλοίο εντός των εικόνων.

Η διαδικασία της εκπαίδευσης περιλάμβανε:

1. Επεξεργασία εισόδου με μετατροπή των εικόνων στο κατάλληλο μέγεθος (416x416) και κανονικοποίηση τιμών pixel.
2. Εκπαίδευση YOLOv8m για 50 εποχές, με συνεχή αξιολόγηση.
3. Χρήση μεταβλητών για τον υπολογισμό της απώλειας κατά την εκπαίδευση όπως box loss, class loss, και DFL loss.
4. Αυτόματο αποθήκευση του καλύτερου μοντέλου σύμφωνα με τη μέτρηση της mAP (mean Average Precision).

3.4 Περιγραφή του υλικού και των δεδομένων που χρησιμοποιήθηκαν

Η εκπαίδευση του μοντέλου πραγματοποιήθηκε σε προσωπικό υπολογιστή τύπου MacBook με επεξεργαστή Apple M1 χωρίς χρήση GPU. Η εκπαίδευση διήρκησε συνολικά περίπου 52 ώρες για 50 εποχές, αξιοποιώντας CPU-only επεξεργασία.

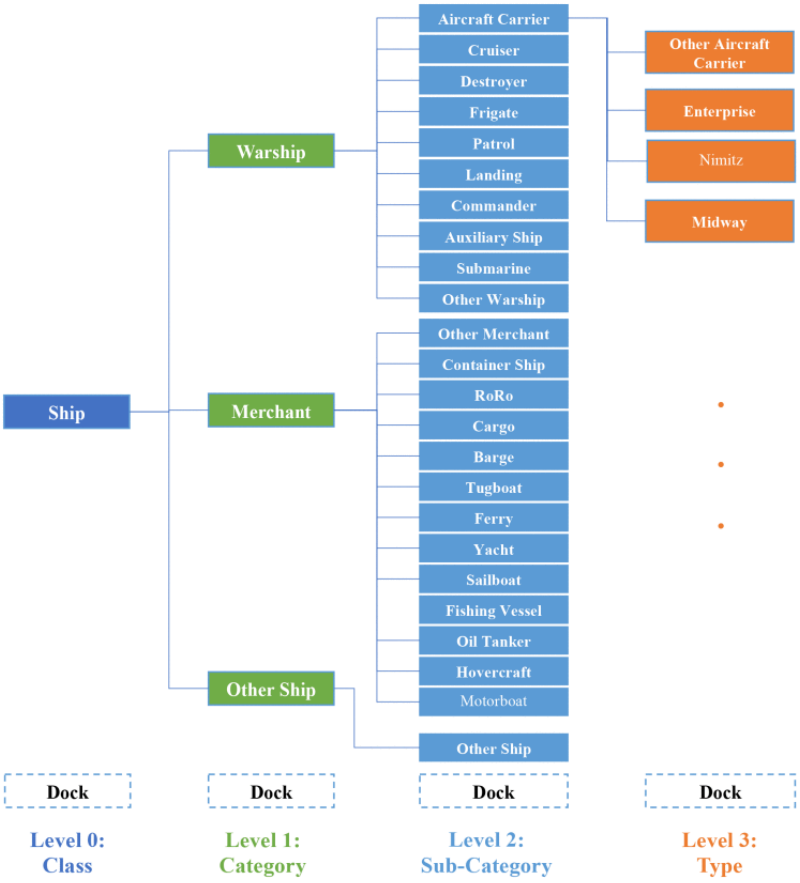
Όσον αφορά τα δεδομένα, χρησιμοποιήθηκε το dataset ShipRSImageNet από την πλατφόρμα Roboflow Universe (ConvertVOCtoYOLO, 2022; Zhang et al.,2021), το οποίο περιλαμβάνει 4.579 εικόνες, από τις οποίες οι 3.668 ήταν Train Set Images, οι 455 ήταν Valid Set Images και οι 456 ήταν Test Set Images με 2.240 συνολικές σημειώσεις (bounding boxes), κατανεμημένες σε 50 διαφορετικές κατηγορίες πλοίων όπως "AOE", "Cargo", "Fishing Vessel", "Submarine", κ.ά.

Οι εικόνες του dataset συνοδεύονται από αρχεία label.txt σε μορφή YOLOv8, με απόλυτες συντεταγμένες των bounding boxes.

Ο κώδικας που χρησιμοποιήθηκε αρχικά για την εκπαίδευση του μοντέλου ήταν σε γλώσσα python και βασίστηκε στον κώδικα της έρευνας του Sekine, T. (2024). Η έρευνα του Sekine πραγματοποιήθηκε με το ίδιο dataset και τον αλγόριθμο YOLOv7. Στη συνέχεια και για τις ανάγκες της παρούσας εργασίας, ο κώδικας τροποποιήθηκε και προσαρμόστηκε για το μοντέλο μας όπως αποτυπώνεται στο Παράρτημα Β.

Η ιεραρχία κλάσεων του ShipRSImageNet με το δέντρο ταξινόμησης πλοίων φαίνεται στο παρακάτω σχήμα. Το επίπεδο (Κλάση) 0 διακρίνει εάν το αντικείμενο είναι πλοίο. Το επίπεδο 1, που ονομάζεται Κατηγορία, ταξινομεί περαιτέρω την κατηγορία του πλοίου. Το επίπεδο 2 υποδιαιρεί περαιτέρω τις κατηγορίες με βάση το επίπεδο 1. Για παράδειγμα, το Πολεμικό Πλοίο υποδιαιρείται σε Υποβρύχιο, Αεροπλανοφόρο, Αντιτορπιλικό, Φρεγάτα κ.λπ., δηλαδή στην Υποκατηγορία. Το επίπεδο 3 αφορά τον συγκεκριμένο τύπο πλοίου, και το επίπεδο αυτό ονομάζεται Τύπος. Για παράδειγμα, η υποκατηγορία Αεροπλανοφόρου περιλαμβάνει το Nimitz, το Enterprise κ.λπ.

Ωστόσο, πρέπει να επισημανθεί ότι για τα Εμπορικά Πλοία, ο αριθμός των συγκεκριμένων τύπων είναι τεράστιος και έχουν οριακή τιμή για ταξινόμηση στην πράξη, επομένως δεν διαιρούνται περαιτέρω στο επίπεδο 3.



Σχήμα 1: Ιεραρχία κλάσεων ShipRSImageNet

Η κατανομή των δεδομένων ήταν:

- Train: ~80%
- Validation: ~10%
- Test: ~10%

Το dataset ShipRSImageNet που εφαρμόστηκε αποτελείται από 50 διαφορετικές κατηγορίες πλοίων. Οι κατηγορίες αυτές αποτυπώνονται στον παρακάτω πίνακα:

AOE	EPF	Medical Ship	Other Landing	Test Ship
Arleigh Burke DD	Enterprise	Midway	Other Merchant	Ticonderoga
Asagiri DD	Ferry	Motorboat	Other Ship	Training Ship

Atago DD	Fishing Vessel	Nimitz	Other Warship	Tugboat
Austin LL	Hatsuyuki DD	Oil Tanker	Patrol	Wasp LL
Barge	Hovercraft	Osumi LL	Perry FF	Yacht
Cargo	Hyuga DD	Other Aircraft Carrier	RoRo	YuDao LL
Commander	LHA LL	Other Auxiliary Ship	Sailboat	YuDeng LL
Container Ship	LSD 41 LL	Other Destroyer	Sanantonio AS	YuTing LL
Dock	Masyuu AS	Other Frigate	Submarine	YuZhao LL

Πίνακας 2: Κατηγορίες πλοίων του dataset

3.5 Εξήγηση των τεχνικών που εφαρμόστηκαν

Κατά την εκπαίδευση του μοντέλου εφαρμόστηκαν:

- Data Augmentation που περιλαμβάνει τυχαίες μετατοπίσεις, περιστροφές και αλλαγές φωτεινότητας, ώστε να ενισχυθεί η γενίκευση του μοντέλου και είναι ενσωματωμένο στο YOLOv8.
- Αναπαράσταση δεδομένων με bounding boxes σημειώνοντας κάθε πλοίο μέσω συντεταγμένων και κατηγορίας.
- Υπολογισμός mAP@50 και mAP@50-95 για την αξιολόγηση ακρίβειας του μοντέλου σε διαφορετικά επίπεδα IoU.
- Early stopping και αυτόματη αποθήκευση του καλύτερου μοντέλου βάσει απόδοσης του validation set.
- Οπτικοποίηση των αποτελεσμάτων μέσω του results.png και του εργαλείου streamlit, όπου ο χρήστης μπορεί να ανεβάσει εικόνα και να δει τα ανιχνευθέντα πλοία με επισήμανση.

Τα δεδομένα χωρίστηκαν σε τρία σύνολα:

Τύπος Δεδομένων	Πλήθος Εικόνων	Ποσοστό
Εκπαίδευση (train)	~365 εικόνες	80%
Επικύρωση (validation)	~45 εικόνες	10%
Δοκιμή (test)	~45 εικόνες	10%

Η παραπάνω κατανομή εξασφάλισε ότι το μοντέλο εκπαιδεύτηκε σε επαρκή ποικιλία δεδομένων, επικυρώθηκε σε ανεξάρτητο σύνολο κατά τη διάρκεια της εκπαίδευσης και αξιολογήθηκε στο τέλος σε ένα πλήρως απομονωμένο test set.

ΚΕΦΑΛΑΙΟ 4

ΥΛΟΠΟΙΗΣΗ

4.1 Παρουσίαση της υλοποίησης της μεθόδου, συμπεριλαμβανομένου του κώδικα και των

Η μέθοδος ανίχνευσης πλοίων βασίστηκε στο μοντέλο YOLOv8m, το οποίο είναι μοντέλο μηχανικής μάθησης και ανήκει στην οικογένεια μοντέλων ταχείας και αποδοτικής ανίχνευσης αντικειμένων (Object Detection Models). Πρόκειται για ένα Single-Stage Object Detector. Αυτό σημαίνει ότι το μοντέλο προβλέπει απευθείας τα bounding boxes και τις κατηγορίες σε μία μόνο διέλευση (forward pass) του δικτύου, ενώ είναι ταχύτερο από τα two-stage detectors (όπως το Faster R-CNN), αν και μερικές φορές ελαφρώς λιγότερο ακριβές.

Προκειμένου να αξιολογήσουμε το YOLOv8 σε σχέση με άλλα μοντέλα, παρουσιάζεται ένας συγκριτικός πίνακας με άλλους τύπους μοντέλων, όπως Faster R-CNN, SSD, DETR και RetinaNet:

Μοντέλο	Κατηγορία	Ταχύτητα (FPS)	Ακρίβεια (mAP)	Καταλληλότητα για Realtime	Πλεονεκτήματα	Μειονεκτήματα
YOLOv8	Single-Stage	Πολύ Υψηλή	Υψηλή	✓	Γρήγορο, Ελαφρύ, Εύκολο στην ανάπτυξη	Λιγότερη ακρίβεια σε μικρά αντικείμενα (σε ορισμένα configs)
Faster R-CNN	Two-Stage	Χαμηλή	Πολύ Υψηλή	✗	Πολύ υψηλή ακρίβεια, καλό για offline επεξεργασία	Αργό, δύσκολο στην ανάπτυξη
SSD	Single-	Υψηλή	Μέτρια	✓	Απλό, μεσαία	Χάνει σε

	Stage				ακρίβεια, καλό για κινητές συσκευές	ακρίβεια συγκριτικά με YOLO
DETR	Transformer-Based	Μέτρια	Υψηλή	✗	Κατανόηση χωρικών σχέσεων μέσω attention	Βαρύ, απαιτεί GPU και χρόνο εκπαίδευσης
RetinaNet	Single-Stage	Μέτρια	Υψηλή	✓	Καλή ισορροπία ακρίβειας και ταχύτητας	Μπορεί να είναι ασταθές σε class imbalance

Πίνακας 3: Συγκριτικός Πίνακας Μοντέλων Ανίχνευσης Αντικειμένων

Η υλοποίηση πραγματοποιήθηκε αποκλειστικά σε Python, αξιοποιώντας τις βιβλιοθήκες βαθιάς μάθησης και εργαλεία προ-εκπαίδευσης της κοινότητας Ultralytics.

Βιβλιοθήκες που χρησιμοποιήθηκαν:

- ultralytics: Εκπαίδευση και φόρτωση μοντέλου YOLOv8
- torch: Backend βαθιάς μάθησης (PyTorch)
- opencv-python: Ανάγνωση και επεξεργασία εικόνων
- streamlit: Γραφική διεπαφή χρήστη για δοκιμές (GUI)
- pandas, matplotlib: Ανάλυση αποτελεσμάτων και απεικόνιση

4.1.1 WebApp

Επιπλέον, με την εισαγωγή της εντολής:

streamlit run app.py

Δημιουργήσαμε μια διαδραστική web εφαρμογή χρησιμοποιώντας τη βιβλιοθήκη Streamlit, με βάση τον κώδικα που περιέχεται στο αρχείο app.py του μοντέλου μας. Το Streamlit είναι ένα εργαλείο που επιτρέπει να δημιουργούμε γρήγορα web εφαρμογές για projects μηχανικής μάθησης ή επεξεργασίας δεδομένων χωρίς να χρειάζονται ειδικές γνώσεις ανάπτυξης γραφικού περιβάλλοντος για αλληλεπίδραση με τον χρήστη (frontend).

Το αρχείο app.py έχει φτιαχτεί για χρήση με το εκπαιδευμένο YOLOv8 μοντέλο και επιτρέπει το ανέβασμα εικόνας (μέσω browser) τρέχοντας το εκπαιδευμένο μοντέλο YOLO πάνω στην εικόνα που ανεβάσαμε, και εντοπίζει τα πλοία στην εικόνα, σχεδιάζοντας τα bounding boxes και επιστρέφει το είδος του πλοίου και το ποσοστό βεβαιότητας (confidence score). Η εφαρμογή μας εμφανίζει την εικόνα με τα αποτελέσματα απευθείας στον browser.

Με την εκκίνηση της εφαρμογής μας λοιπόν, το Streamlit δείχνει το παρακάτω:

http://localhost:8501

Ανοίγοντας αυτό τον σύνδεσμο στον browser, βλέπουμε την εφαρμογή σε λειτουργία τοπικά στον υπολογιστή και μπορούμε να τη χρησιμοποιήσουμε φορτώνοντας εικόνες για έλεγχο.

Με άλλα λόγια, αυτή η εντολή ανοίγει μια “βιτρίνα” για το μοντέλο μας, όπου μπορούμε να κάνουμε δοκιμές με νέες εικόνες και να δούμε τα αποτελέσματα ανίχνευσης με φιλικό τρόπο μέσω browser, χωρίς να χρειάζεται να γράφουμε κάθε φορά κώδικα.

4.2 Εξήγηση των παραμέτρων εκπαίδευσης

Η εκπαίδευση του YOLOv8m πραγματοποιήθηκε με την παρακάτω εντολή:

yolo task=detect mode=train model=yolov8m.pt data=data.yaml imgsz=416 batch=4 workers=1 epochs=50

Το batch (ή μέγεθος δέσμης) αναφέρεται στον αριθμό των δειγμάτων (π.χ. εικόνων) που δίνονται στο μοντέλο κάθε φορά πριν γίνει ενημέρωση των βαρών του. Αντί να εκπαιδεύουμε το μοντέλο με ολόκληρο το dataset ταυτόχρονα, το χωρίζουμε σε μικρότερες δέσμες για αποδοτικότερη και ευκολότερη εκπαίδευση.

Δηλαδή, αν έχουμε 1.000 εικόνες και batch size = 10, τότε η εκπαίδευση θα γίνει σε 100 δέσμες (batches) ανά epoch.

Αυτό σημαίνει ότι μικρό batch size έχει χαμηλότερη απαίτηση σε μνήμη, πιο λεπτομερής προσαρμογή, αλλά αργότερη και λιγότερο σταθερή εκπαίδευση, ενώ μεγάλο batch size έχει γρηγορότερη και πιο σταθερή εκπαίδευση, αλλά απαιτεί περισσότερη μνήμη και μπορεί να παρακάμψει σημαντικές λεπτομέρειες.

Στη δική μας περίπτωση, λόγω εκπαίδευσης σε υπολογιστή χωρίς GPU (Apple M1 CPU), επιλέχθηκε το batch size = 4 για να διασφαλίσουμε ότι δεν θα ξεπεράσουμε τα όρια μνήμης, έστω και αν η εκπαίδευση ήταν πιο αργή. Στην παρούσα μελέτη, με batch size = 4, η εκπαίδευση διήρκεσε περίπου 52 ώρες.

Παράμετροι Εκπαίδευσης:

task=detect:	Ανίχνευση αντικειμένων
mode=train:	Εκπαίδευση
model=yolov8m.pt:	Προκαταρτικά εκπαιδευμένο μοντέλο
data=data.yaml:	Αρχείο ορισμού dataset
imgsz=416:	Μέγεθος εισόδου (εικόνων)
batch=4:	Μέγεθος παρτίδας
workers=1:	Εργαζόμενοι (CPU threads)
epochs=50:	Πλήθος εποχών

Πίνακας 4: Παράμετροι εκπαίδευσης

Κατά την εκπαίδευση του μοντέλου χρησιμοποιήθηκαν τα metrics: box_loss, cls_loss, dfl_loss ενώ ταυτόχρονα παρακολουθήθηκαν τα Precision, Recall, mAP@50 και mAP@50-95. Κάθε εποχή αξιολογούνταν με βάση το validation set, και το μοντέλο με την καλύτερη ακρίβεια (mAP@50) και το καλύτερο μοντέλο αποθηκεύτηκε ως: runs/detect/train/weights/best.pt.

Τελική Απόδοση Μοντέλου (επεξήγηση των όρων γίνεται στην ανάλυση των αποτελεσμάτων):

- ✓ mAP@50: 0.81

- ✓ mAP@50-95: 0.56
- ✓ Precision: 0.766
- ✓ Recall: 0.779

Κατηγορίες που έδωσαν πολλές εμφανίσεις ήταν οι Other Ship, Dock, Motorboat, Submarine, Cargo, ενώ κατηγορίες με Χαμηλό mAP αποδείχτηκαν οι Motorboat (0.049), Patrol (0.14), Sailboat (0.142). Η παραπάνω υλοποίηση αποδείχθηκε αποδοτική για την ανίχνευση πλοίων σε αεροφωτογραφίες, ακόμη και με χρήση CPU-only υπολογιστή.

ΚΕΦΑΛΑΙΟ 5

ΑΠΟΤΕΛΕΣΜΑΤΑ

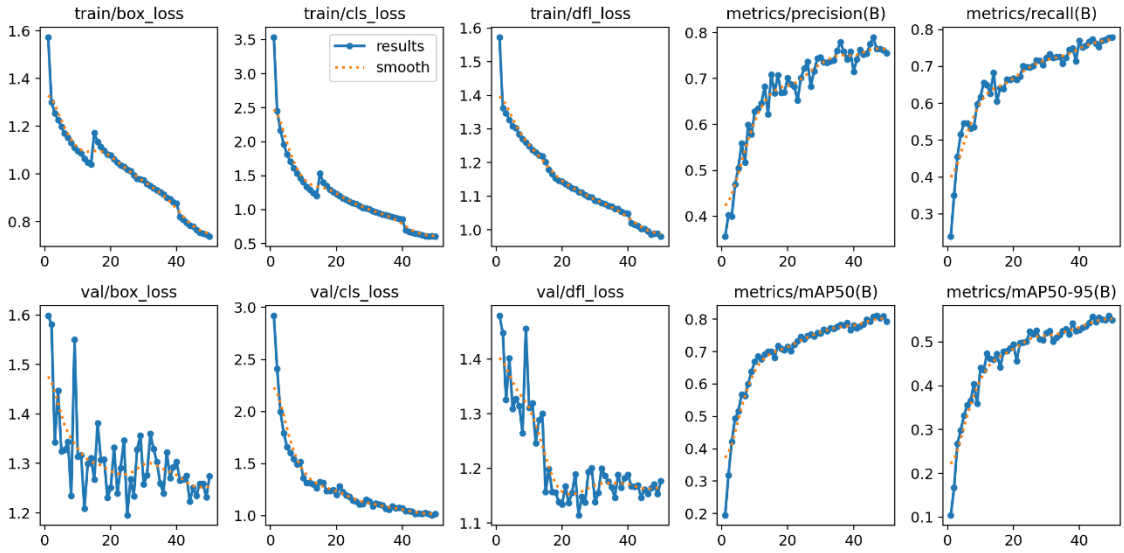
5.1 Παρουσίαση και ανάλυση των αποτελεσμάτων

Η εκπαίδευση του μοντέλου ολοκληρώθηκε σε 50 εποχές (epochs), χρησιμοποιώντας το μοντέλο YOLOv8m με μέγεθος εικόνας 416×416 και παρτίδες (batch) μεγέθους 4. Η διαδικασία έγινε αποκλειστικά σε CPU περιβάλλον (Apple M1), και περιελάμβανε 4.579 εικόνες του dataset ShipRSImageNet, από τις οποίες οι 3.668 ήταν Train Set Images (80%), οι 455 ήταν Valid Set Images (10%) και οι 456 ήταν Test Set Images (10%) με 2.240 συνολικές σημειώσεις (bounding boxes), κατανεμημένες σε 50 διαφορετικές κατηγορίες πλοίων.

Η εκπαίδευση του μοντέλου διήρκεσε 52 ώρες και κατά την ολοκλήρωσή της, το σύστημα ανέφερε τις παρακάτω συνολικές επιδόσεις:

- mAP@0.5: 0.81
- mAP@0.5:0.95: 0.56
- Precision: 0.766
- Recall: 0.779

Κατά την εκπαίδευση του μοντέλου είχαμε τα παρακάτω αποτελέσματα. Το διάγραμμα παρουσιάζει την εξέλιξη των τιμών των συναρτήσεων κόστους (box loss, classification loss, dfl loss), καθώς και την ακρίβεια (Precision), την Ανάκληση (Recall) και τους δείκτες mAP50 και mAP50-95 για το σύνολο επικύρωσης, ανά εποχή (epoch).



Εικόνα 3: Απεικόνιση της πορείας εκπαίδευσης του μοντέλου YOLOv8m.

Ακολουθεί πίνακας με επεξήγηση των Μετρικών Αξιολόγησης Μοντέλων Ανίχνευσης:

mAP@0.5:0.95	Η μέτρηση mAP@0.5:0.95 (Mean Average Precision) υπολογίζει τον μέσο όρο της ακρίβειας σε δέκα επίπεδα IoU (από 0.5 έως 0.95 ανά 0.05). Είναι αυστηρότερο μέτρο από το mAP@0.5 και αξιολογεί πόσο ακριβείς είναι οι προβλέψεις σε σχέση με τη χωρική τους τοποθέτηση.
Precision (Ακρίβεια Ανίχνευσης)	Ορίζει το ποσοστό των σωστών εντοπισμών (True Positives) ως προς όλους τους εντοπισμούς (True Positives + False Positives). Υψηλή ακρίβεια σημαίνει ότι οι περισσότερες προβλέψεις του μοντέλου είναι σωστές.
Recall (Ανάκληση)	Μετράει το ποσοστό των πραγματικών αντικειμένων που εντοπίστηκαν από το μοντέλο. Υψηλή ανάκληση σημαίνει ότι το μοντέλο εντοπίζει την πλειονότητα των αντικειμένων.
Σχέση Precision και Recall	Η αύξηση του Precision μπορεί να μειώσει το Recall και αντίστροφα. Η βέλτιστη απόδοση επιτυγχάνεται όταν υπάρχει ισορροπία μεταξύ των δύο. Η μέτρηση mAP βοηθά να εκτιμήσουμε την απόδοση του μοντέλου σε αυτό το πλαίσιο.

Πίνακας 5: Επεξήγηση Μετρικών Αξιολόγησης Μοντέλων Ανίχνευσης

Η μέση ακρίβεια (Mean Average Precision, mAP) σε επίπεδο 50% IoU έφτασε το 0.81, αποδεικνύοντας πως το μοντέλο εντόπιζε επιτυχώς τα περισσότερα πλοία με σημαντική ακρίβεια. Αντίστοιχα, η mAP@0.5:0.95 ήταν 0.56, μια τιμή που επιβεβαιώνει ικανοποιητική απόδοση σε πιο αυστηρά όρια επικαλύψεων.

Σε κατηγορίες με ευδιάκριτα οπτικά χαρακτηριστικά και επαρκή δείγματα, όπως Submarine, Aircraft Carrier και Ticonderoga, παρουσιάστηκε υψηλή ακρίβεια και αξιοπιστία εντοπισμού, σε αντίθεση με τις κατηγορίες όπως Motorboat και Patrol που έχουν πολύ μικρά αντικείμενα, είναι οπτικά παρόμοιες κατηγορίες, ή με λίγα παραδείγματα στο dataset όπου παρατηρούνται οι χαμηλές επιδόσεις.

Κατηγορίες με υψηλό mAP	Κατηγορίες με χαμηλό mAP
• **Enterprise (0.814)**	• Motorboat (0.049)
• **EPF (0.773)**	• Patrol (0.14)
• **YuTing LL (0.703)**	• Sailboat (0.142)
• **Submarine (0.594)**	• Fishing Vessel (0.215)

Στον επόμενο πίνακα αποτυπώνονται οι κατηγορίες με τις περισσότερες εμφανίσεις στο μοντέλο βάσει του dataset:

Κατηγορία	**Πλήθος Εμφανίσεων**
Other Ship	**271**
Dock	178
Motorboat	191
Submarine	162
Cargo	164
Other Warship	204
Hovercraft	55
Perry FF	58
Container Ship	60
Fishing Vessel	91

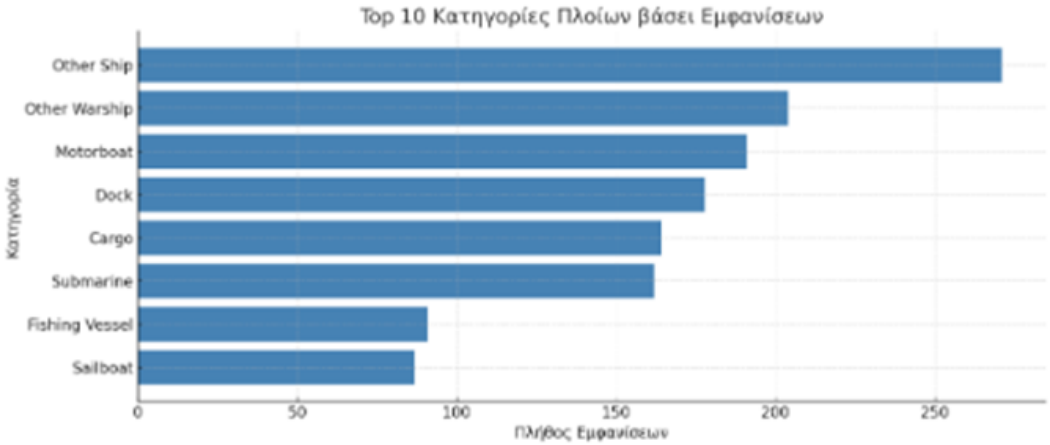
Ενώ, οι κατηγορίες με τη χαμηλότερη ακρίβεια (mAP@50-95) βάσει του validation output είναι:

Κατηγορία	**mAP@50-95**	**Σχόλιο**
Motorboat	0.049	Πολύ χαμηλή, πιθανή σύγχυση με άλλα
Other Ship	0.23	Πολύ γενική κατηγορία
Ferry	0.336	Μέτρια απόδοση
Other Merchant	0.226	Λίγες εμφανίσεις / γενικό label
Sailboat	0.142	Πολλές μικρές/ασαφείς εμφανίσεις

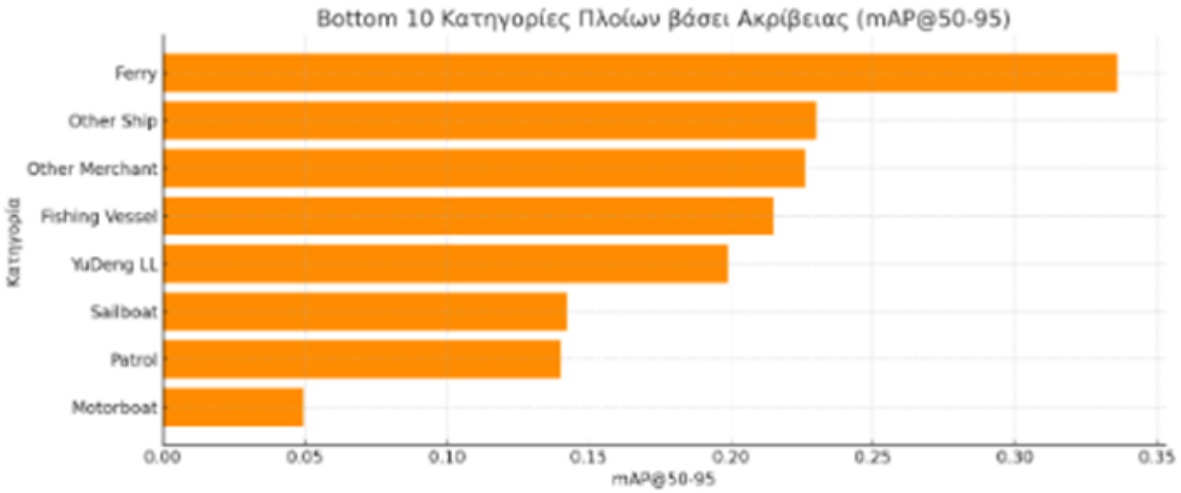
Patrol	0.14	Ελάχιστες εμφανίσεις (10)
YuDeng LL	0.199	Μόνο 1 εικόνα

Πίνακας 6: Κατηγορίες με τη χαμηλότερη ακρίβεια

Ακολουθούν διαγράμματα με τις 10 κατηγορίες που εμφανίζονται περισσότερο στο δείγμα και με τις κατηγορίες που είχαν την χαμηλότερη ακρίβεια στο δείγμα.



Διάγραμμα 1: Κυριότερες κατηγορίες πλοίων βάσει εμφανίσεων στο δείγμα



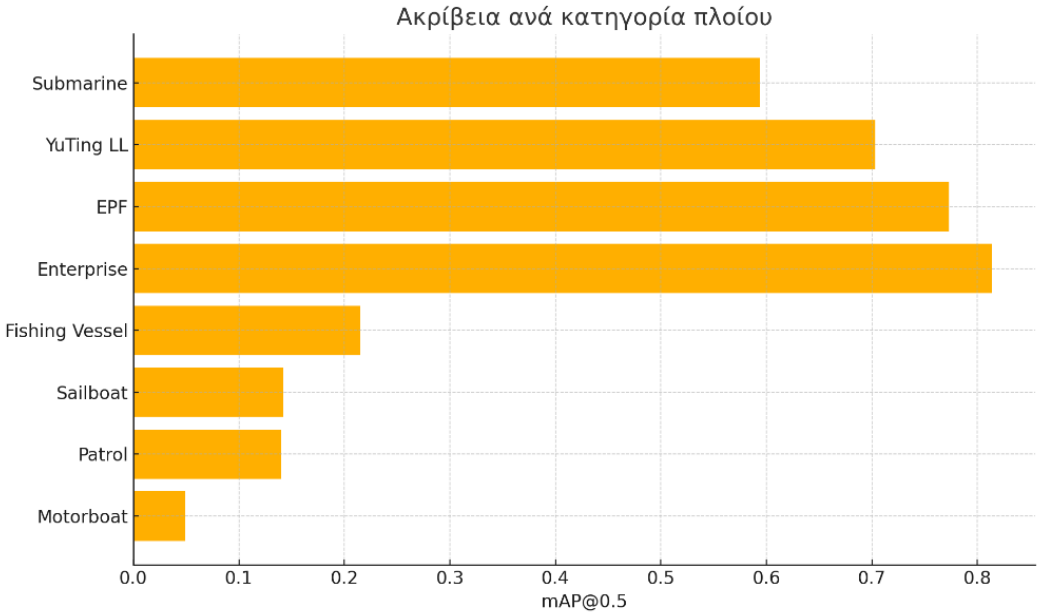
Διάγραμμα 2: Χειρότερες κατηγορίες πλοίων βάσει ακρίβειας

5.2 Εκτίμηση της απόδοσης της μεθόδου

Η συνολική απόδοση της μεθόδου κρίνεται ιδιαίτερα ικανοποιητική, λαμβάνοντας υπόψη την απουσία μονάδας επεξεργασίας γραφικών (GPU), καθώς η εκπαίδευση πραγματοποιήθηκε αποκλειστικά σε κεντρική μονάδα επεξεργασίας (CPU) και το μικρό μέγεθος εικόνας (416×416) που επιλέχθηκε για ταχύτερη εκπαίδευση.

Το μοντέλο απέδωσε καλά ακόμα και με μεγάλη ποικιλία πλοίων, δίνοντας έτσι καλή γενίκευση σε 50 κατηγορίες.

Ο εντοπισμός μεγάλων ή εύκολα διακριτών πλοίων με υψηλή ακρίβεια και η γρήγορη απόδοση ακόμα και σε χαμηλής ισχύος συστήματα αποτελούν δυνατά σημεία της μεθόδου. Ενώ η περιορισμένη ακρίβεια σε μικρά πλοία ή χαμηλή ορατότητα και το γεγονός ότι χρειάζεται περισσότερα δεδομένα για ισορροπημένες κατηγορίες περιορίζει την απόδοση της μεθόδου.



Διάγραμμα 3: Ακρίβεια μοντέλου ανά κατηγορία πλοίου

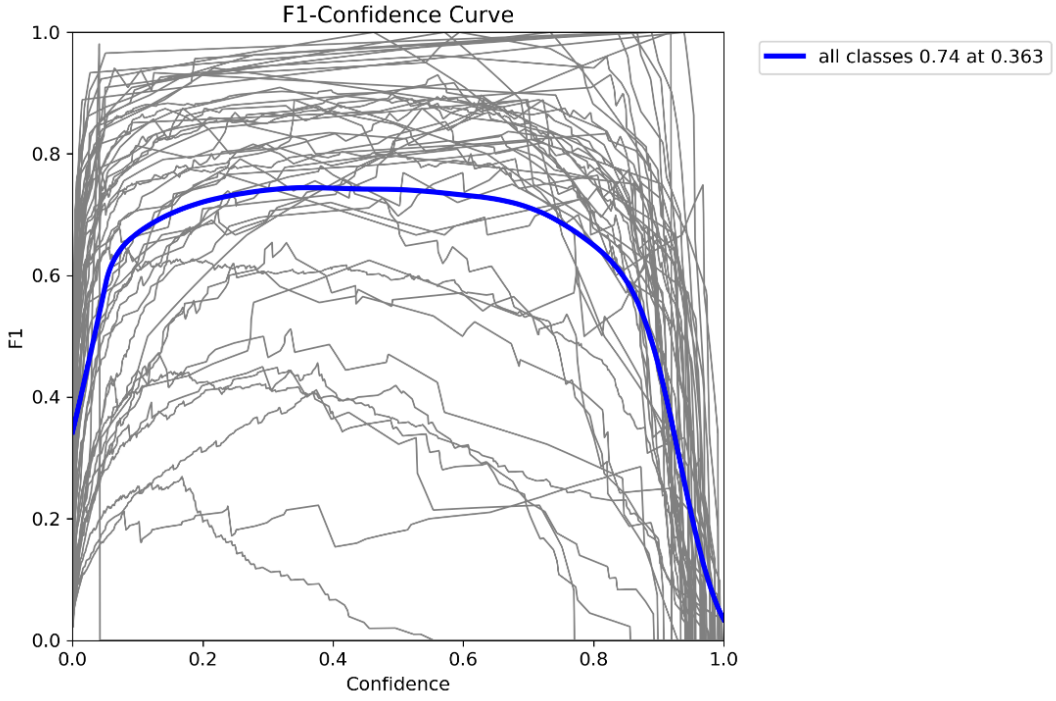
Ένα εργαλείο για την αξιολόγηση της απόδοσης του μοντέλου ανίχνευσης αντικειμένων όπως το YOLOv8 είναι η καμπύλη F1 confidence curve σε διαφορετικά επίπεδα κατωφλίου εμπιστοσύνης (confidence threshold). Η F1-score είναι ο αρμονικός μέσος της ακρίβειας (precision) και της ανάκλησης (recall). Η καμπύλη F1 ως συνάρτηση του κατωφλίου εμπιστοσύνης (confidence threshold) αφορά το εκπαιδευμένο μοντέλο εντοπισμού πλοίων

και απεικονίζει τη σχέση μεταξύ ακρίβειας και ανάκλησης και βοηθά στην επιλογή του βέλτιστου κατωφλίου για βέλτιστη απόδοση του μοντέλου.

Όπου: Precision = Πόσες από τις προβλέψεις ήταν σωστές.

Recall = Πόσα από τα πραγματικά αντικείμενα εντοπίστηκαν.

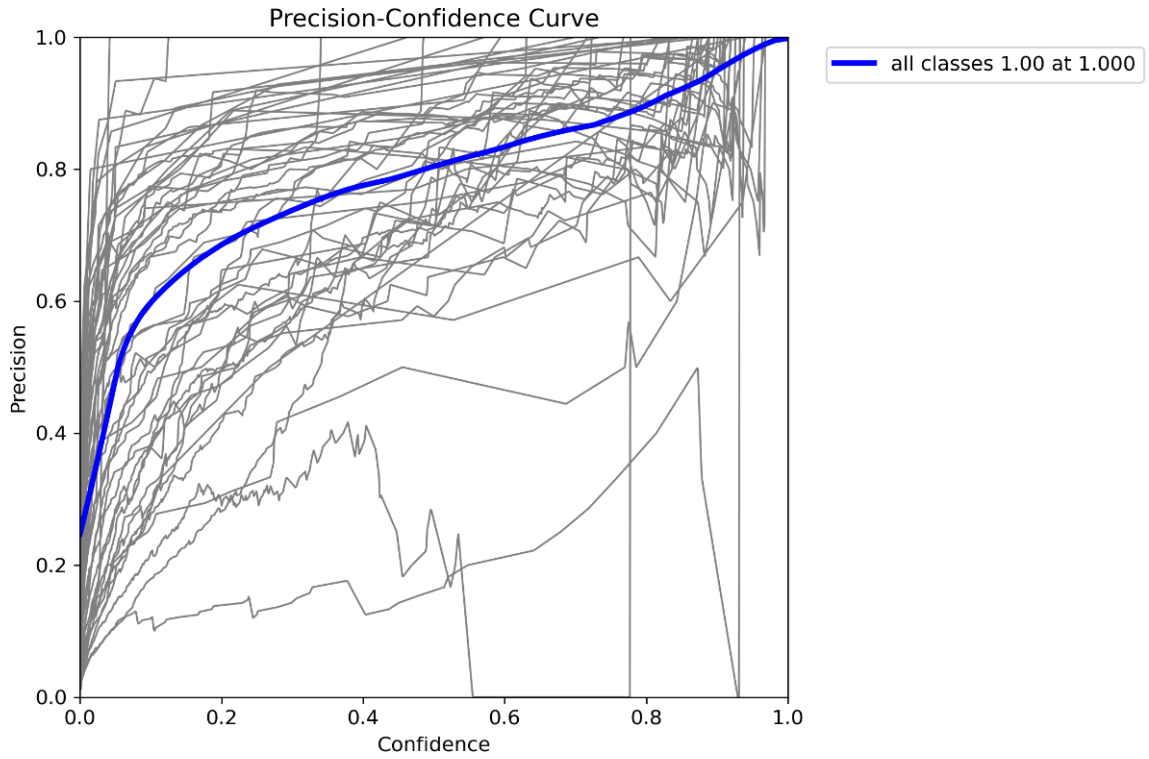
Η F1 confidence curve στον οριζόντιο άξονα δείχνει το το κατώφλι εμπιστοσύνης, π.χ. 0.3, 0.5, 0.7 (Confidence threshold) και στον κατακόρυφο άξονα δείχνει το F1-score που προκύπτει σε αυτό το threshold.



Διάγραμμα 4: Καμπύλη F1 ως συνάρτηση του κατωφλίου εμπιστοσύνης (confidence threshold)

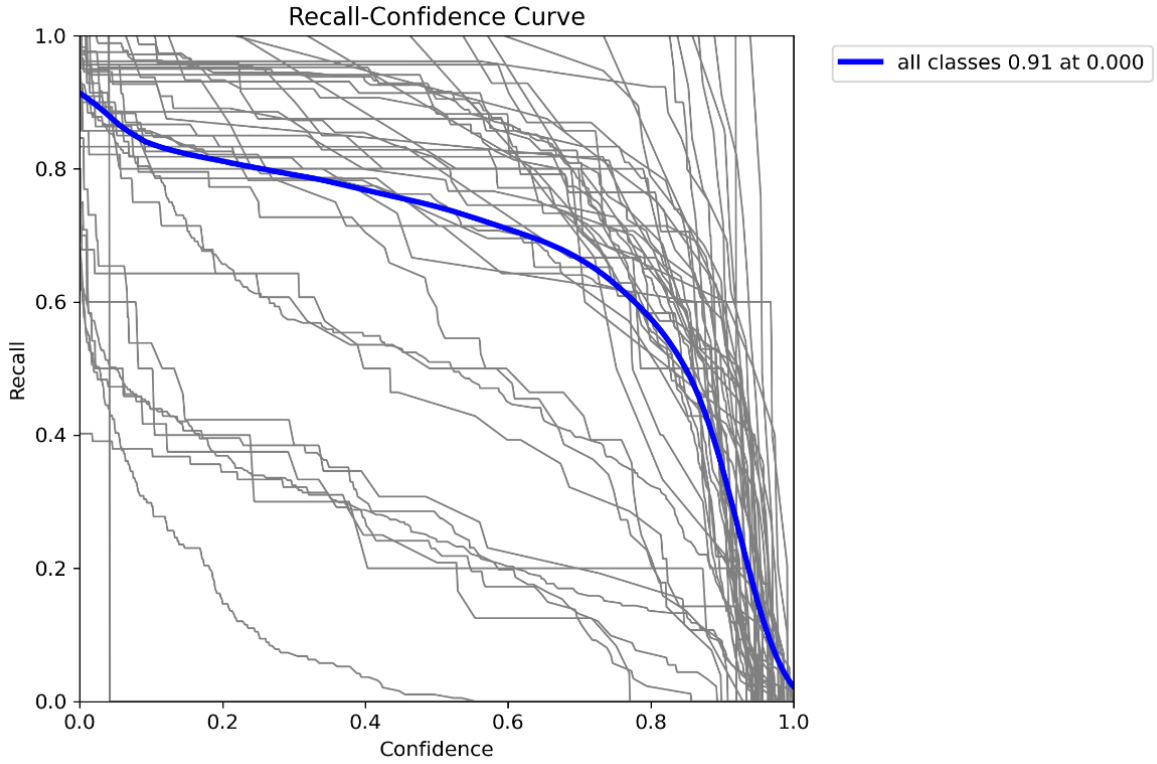
Είναι ακόμη πολύ χρήσιμο εργαλείο για την αξιολόγηση του κατά πόσο "σίγουρες" και "σωστές" είναι οι προβλέψεις του μοντέλου είναι η καμπύλη Precision-Confidence (ή Precision vs Confidence curve), η οποία δείχνει πώς μεταβάλλεται η ακρίβεια (precision) του μοντέλου σου σε σχέση με το κατώφλι εμπιστοσύνης (confidence threshold) που έχει οριστεί κατά την πρόβλεψη. Η καμπύλη στον οριζόντιο άξονα (x) δείχνει το confidence threshold,

δηλαδή το πόσο σίγουρο είναι το μοντέλο ότι ανίχνευσε κάτι και κυμαίνεται από 0 (καθόλου σίγουρο) έως 1 (απόλυτη βεβαιότητα) και στον κατακόρυφο άξονα (y) δείχνει την ακρίβεια (precision), δηλαδή το ποσοστό των ανιχνεύσεων που είναι σωστές (True Positives ως προς (True Positives + False Positives). Δηλαδή, παρουσιάζει την απόδοση του μοντέλου όσον αφορά τα θετικά σωστά αποτελέσματα καθώς αλλάζει το επίπεδο εμπιστοσύνης.



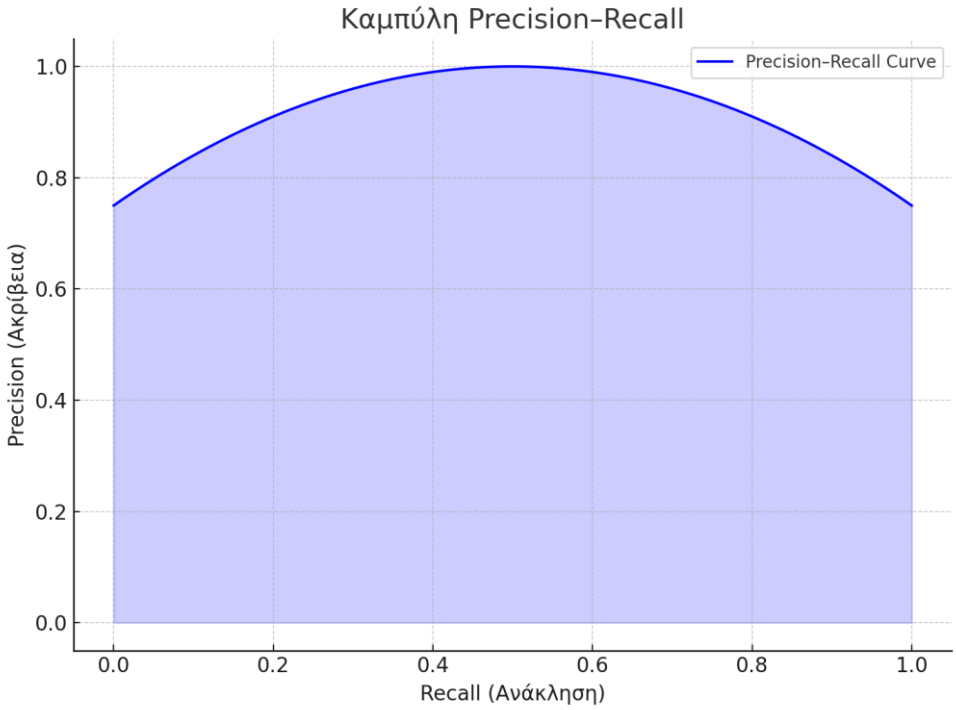
Διάγραμμα 5: Καμπύλη ακρίβειας (Precision)

Στην μέτρηση του ίδιου εργαλείου εφαρμόζεται και η Recall-Confidence καμπύλη, η οποία δείχνει πώς μεταβάλλεται η recall (ανακλησιμότητα) του μοντέλου σου καθώς αυξάνεται το κατώφλι εμπιστοσύνης (confidence threshold). Η καμπύλη αυτή δείχνει την ικανότητα του μοντέλου να εντοπίζει σωστά όλα τα σχετικά αντικείμενα καθώς μεταβάλλεται το επίπεδο εμπιστοσύνης.



Διάγραμμα 6: Καμπύλη ανάκλησης (Recall) σε συνάρτηση με το κατώφλι εμπιστοσύνης (confidence threshold)

Ακολουθεί το Διάγραμμα Καμπύλης Precision–Recall, ένα ακόμα εργαλείο για την αξιολόγηση του μοντέλου. Στο διάγραμμα καμπύλης Ακρίβειας (Precision) – Ανάκλησης (Recall) για το εκπαιδευμένο μοντέλο ανίχνευσης πλοίων. Η καμπύλη παρουσιάζει τη σχέση μεταξύ της ακρίβειας και της ανάκλησης καθώς μεταβάλλεται το κατώφλι εμπιστοσύνης, δίνοντας μια συνολική εικόνα της απόδοσης του μοντέλου.

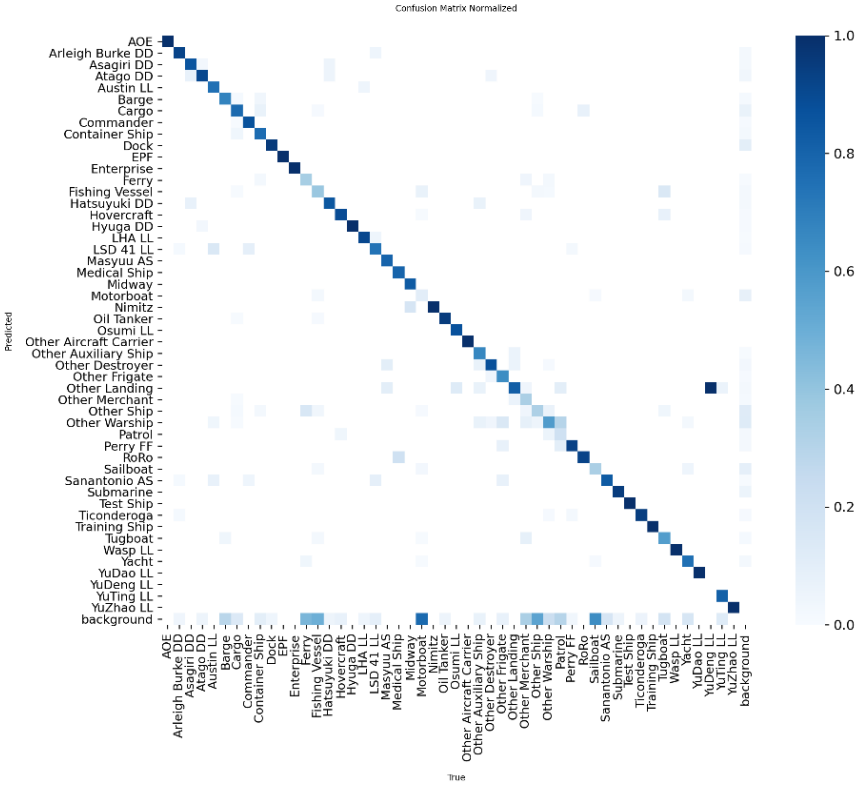


Διάγραμμα 7: Διάγραμμα Καμπύλης Precision–Recall

Το διάγραμμα στον άξονα X (Recall) δείχνει πόσα από τα πραγματικά αντικείμενα εντόπισε το μοντέλο, ενώ ο άξονας Y (Precision) δείχνει πόσα από τα αντικείμενα που εντοπίστηκαν ήταν σωστά. Η καμπύλη Precision–Recall βοηθά στην αξιολόγηση μοντέλων σε datasets με μη ισορροπημένες κατηγορίες, και χρησιμοποιείται για τον υπολογισμό του Average Precision (AP).

Μια καλή καμπύλη βρίσκεται ψηλά και προς τα δεξιά, δηλαδή έχει υψηλή ακρίβεια και ανάκληση. Αν η καμπύλη πέφτει γρήγορα, τότε το μοντέλο κάνει είτε πολλά λάθη είτε χάνει πολλούς στόχους. Στο διάγραμμα φαίνεται ότι η καμπύλη δείχνει υψηλή ακρίβεια στην αρχή (όταν το μοντέλο είναι επιλεκτικό), η οποία μειώνεται καθώς αυξάνεται η ανάκληση.

Ένα εργαλείο αξιολόγησης της απόδοσης ενός μοντέλου ταξινόμησης είναι το confusion matrix (πίνακας σύγχυσης), το οποίο δείχνει πόσο καλά προβλέφθηκαν οι κλάσεις (κατηγορίες πλοίων) σε σχέση με τις πραγματικές. Παρουσιάζει την απόδοση του μοντέλου στην ταξινόμηση των κατηγοριών πλοίων. Τα διαγώνια στοιχεία αντιστοιχούν σε σωστές προβλέψεις, ενώ τα εκτός διαγωνίου δείχνουν λάθος ταξινομήσεις μεταξύ των διαφορετικών κατηγοριών.



Πίνακας 7: Πίνακας σύγχυσης (confusion matrix)

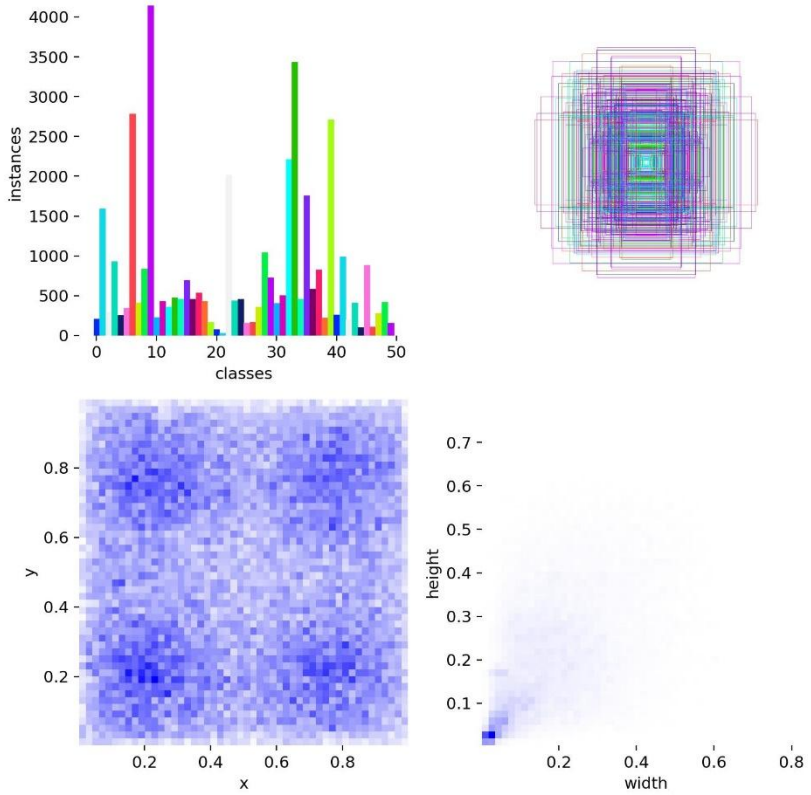
Οι γραμμές του πίνακα αντιστοιχούν στις πραγματικές κατηγορίες, ενώ οι στήλες αντιστοιχούν στις προβλεπόμενες κατηγορίες από το μοντέλο. Κάθε κελί δείχνει πόσες φορές ένα πλοίο της πραγματικής κατηγορίας X προβλέφθηκε ως κατηγορία Y.

Υψηλές τιμές στη διαγώνιο σημαίνει ότι έχουμε σωστές προβλέψεις και χαμηλές ή μηδενικές τιμές εκτός διαγωνίου σημαίνει λάθος προβλέψεις ή συγχύσεις μεταξύ κατηγοριών. Ο πίνακας μας δείχνει ουσιαστικά ποιες κατηγορίες αναγνωρίζει σωστά, ποιες συγχέονται μεταξύ τους (όπως Cargo με Container Ship) και αν υπάρχουν κλάσεις που ποτέ δεν εντοπίζονται σωστά, όπως πολύ μικρές ή σπάνιες κατηγορίες.

Τα διαγράμματα με τα labels, όπως μας τα έδωσε το μοντέλο, παρέχουν σημαντική πληροφόρηση σχετικά με την κατανομή και τα στατιστικά των ετικετών (κατηγοριών) στο dataset σου. Το πρώτο διάγραμμα δείχνει μια ράβδο για κάθε κατηγορία (label/class) και το ύψος της ράβδου δείχνει πόσα annotations (instances) έχει κάθε κατηγορία. Το διάγραμμα αυτό ουσιαστικά ανιχνεύει το data imbalance και δείχνει ποιες κατηγορίες έχουν περισσότερα ή λιγότερα δεδομένα, κάτι που μπορεί να εξηγεί χαμηλή ακρίβεια σε

συγκεκριμένα classes. Ουσιαστικά μας βοηθά στη βελτίωση dataset (π.χ. συλλογή περισσότερων δεδομένων για «ασθενείς» κατηγορίες).

Το δεύτερο διάγραμμα δείχνει ένα heatmap που παρουσιάζει τη συν-εμφάνιση κατηγοριών στην ίδια εικόνα, δηλαδή ποιες κατηγορίες εμφανίζονται συχνά μαζί σε εικόνες. Αυτό χρησιμεύει για να μπορούμε να εντοπίσουμε αν υπάρχουν κατηγορίες που συγχέονται καθώς και τις φυσικές συσχετίσεις μεταξύ πλοίων.



Διάγραμμα 8: Απεικονίζουν την κατανομή των ετικετών (labels) στο dataset, παρουσιάζοντας τον αριθμό των δειγμάτων ανά κατηγορία πλοίου. Τα διαγράμματα βοηθούν στην κατανόηση της ισορροπίας ή της ανισορροπίας μεταξύ των κατηγοριών, γεγονός που επηρεάζει την εκπαίδευση και την απόδοση του μοντέλου.

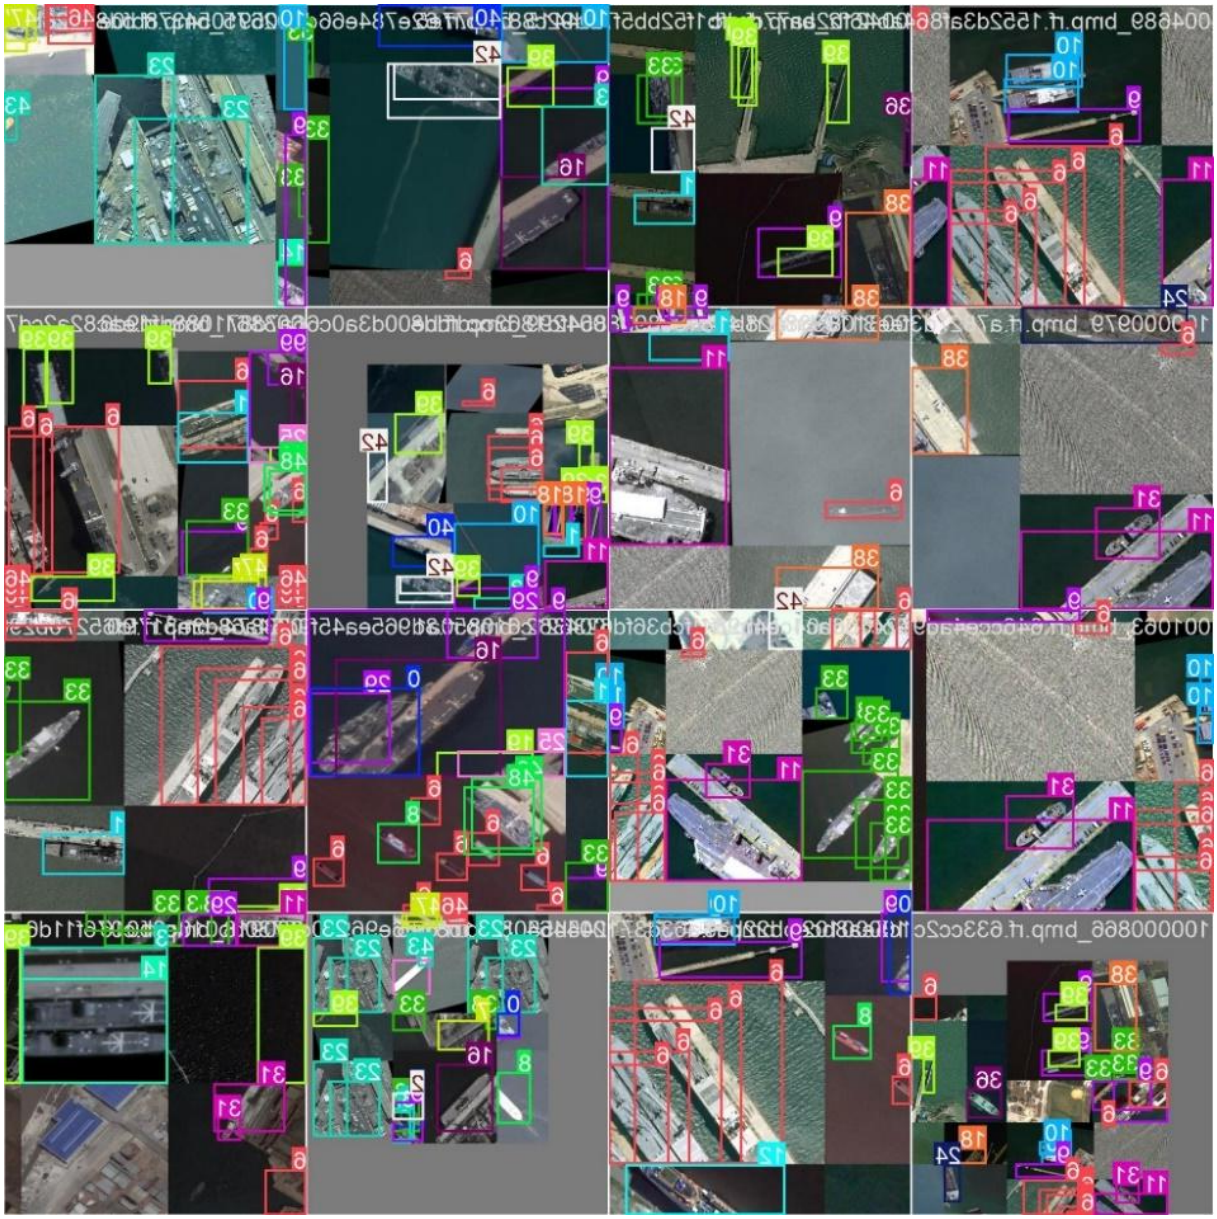
Ακολουθούν οι εικόνες που δημιουργήθηκαν αυτόματα κατά τη διάρκεια της εκπαίδευσης του μοντέλου YOLOv8m. Αυτές οι εικόνες δείχνουν δείγματα από παρτίδες (batches) εικόνων που χρησιμοποιήθηκαν κατά την εκπαίδευση. Κάθε μία περιέχει πολλές εικόνες από το dataset που χρησιμοποιήθηκε και πάνω σε κάθε εικόνα εμφανίζονται τα bounding boxes που έχουν εφαρμοστεί, καθώς και το label κάθε αντικειμένου.

Οι αριθμοί που αποτυπώνονται πάνω στις εικόνες (6, 10, 31…) είναι οι αριθμοί κατηγορίας (class IDs) από το dataset. Αντί να εμφανίζεται το όνομα της κατηγορίας (π.χ. “Container Ship”, “Submarine”), εμφανίζεται ο αριθμητικός δείκτης της κατηγορίας όπως είναι ορισμένος στο αρχείο data.yaml. Η ταξινόμηση ξεκινάει από 0, δηλαδή class 0, class 1, class 2, ..., μέχρι τον συνολικό αριθμό των κατηγοριών, δηλαδή class 49 για το σύνολο των 50 κατηγοριών των πλοίων του δείγματος. Πρακτικά χρησιμεύουν για να ελέγξουμε αν το μοντέλο διαβάζει σωστά τις ετικέτες, ως οπτικός έλεγχος ποιότητας annotation και κατανόηση της δυσκολίας του dataset, όπως επικαλυπτόμενα αντικείμενα, ποικιλία μεγεθών κ.λπ.

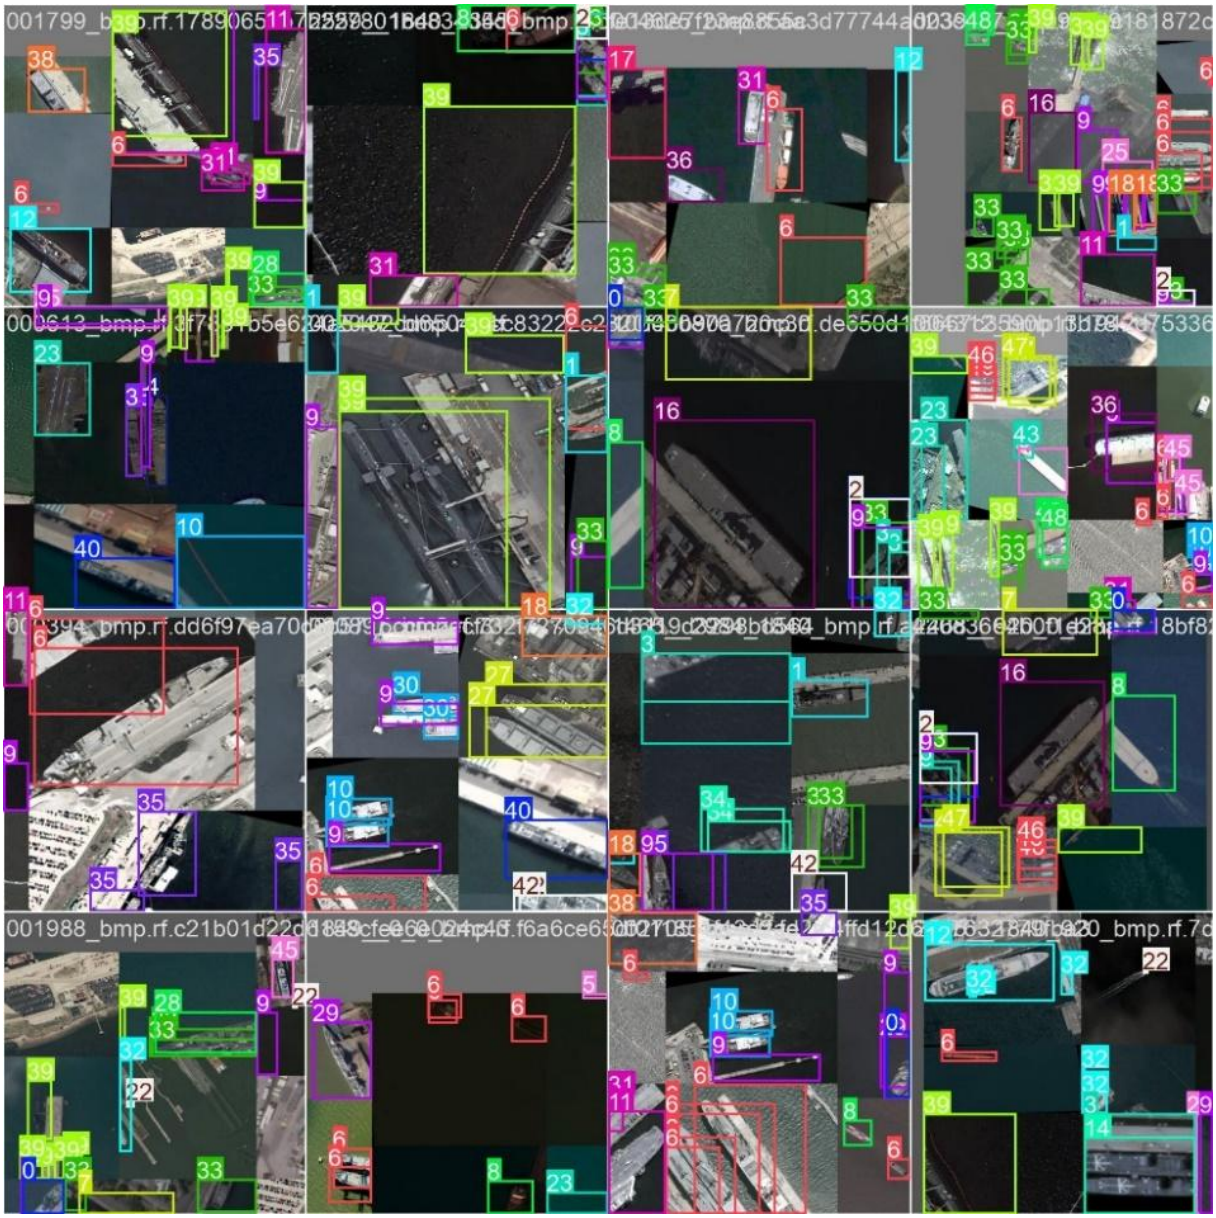
Για την καλύτερη κατανόηση των αριθμητικών δεικτών, ακολουθεί πίνακας με τις κλάσεις των πλοίων του dataset:

class ID	Category	class ID	Category
0	AOE	**25**	Osumi LL
1	Arleigh Burke DD	**26**	Other Aircraft Carrier
2	Asagiri DD	**27**	Other Auxiliary Ship
3	Atago DD	**28**	Other Destroyer
4	Austin LL	**29**	Other Frigate
5	Barge	**30**	Other Landing
6	Cargo	**31**	Other Merchant
7	Commander	**32**	Other Ship
8	Container Ship	**33**	Other Warship
9	Dock	**34**	Patrol
10	EPF	**35**	Perry FF
11	Enterprise	**36**	RoRo
12	Ferry	**37**	Sailboat
13	Fishing Vessel	**38**	Sanantonio AS
14	Hatsuyuki DD	**39**	Submarine
15	Hovercraft	**40**	Test Ship
16	Hyuga DD	**41**	Ticonderoga
17	LHA LL	**42**	Training Ship
18	LSD 41 LL	**43**	Tugboat
19	Masyuu AS	**44**	Wasp LL
20	Medical Ship	**45**	Yacht
21	Midway	**46**	YuDao LL
22	Motorboat	**47**	YuDeng LL
23	Nimitz	**48**	YuTing LL
24	Oil Tanker	**49**	YuZhao LL

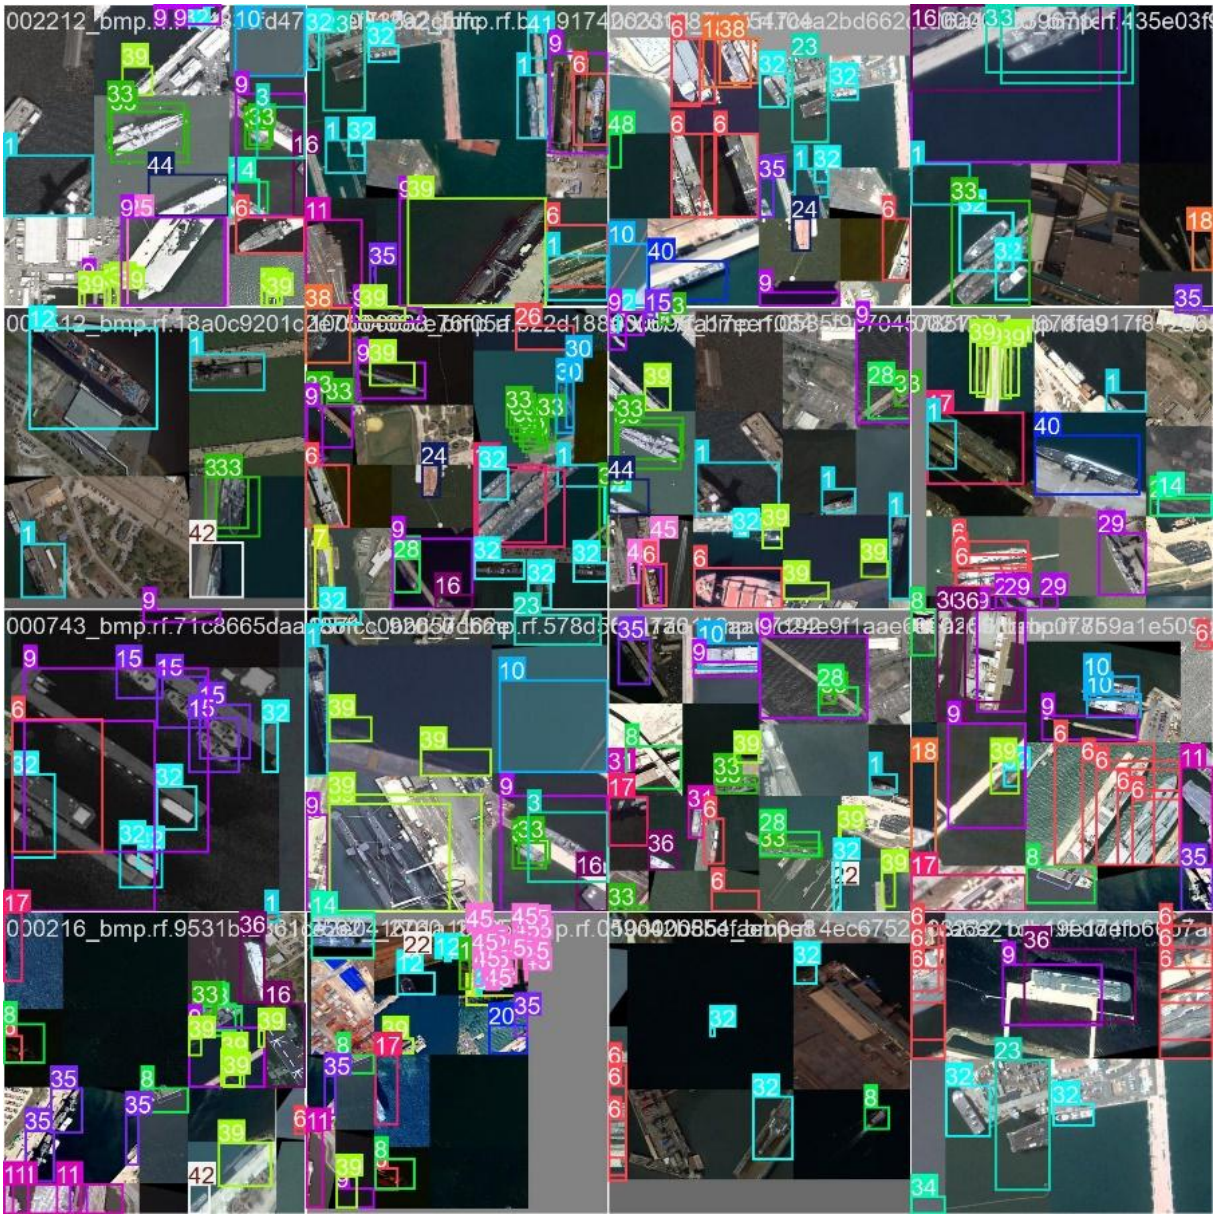
Πίνακας 8: Πίνακας αντιστοίχισης αριθμητικών ετικετών με τις κατηγορίες πλοίων του dataset



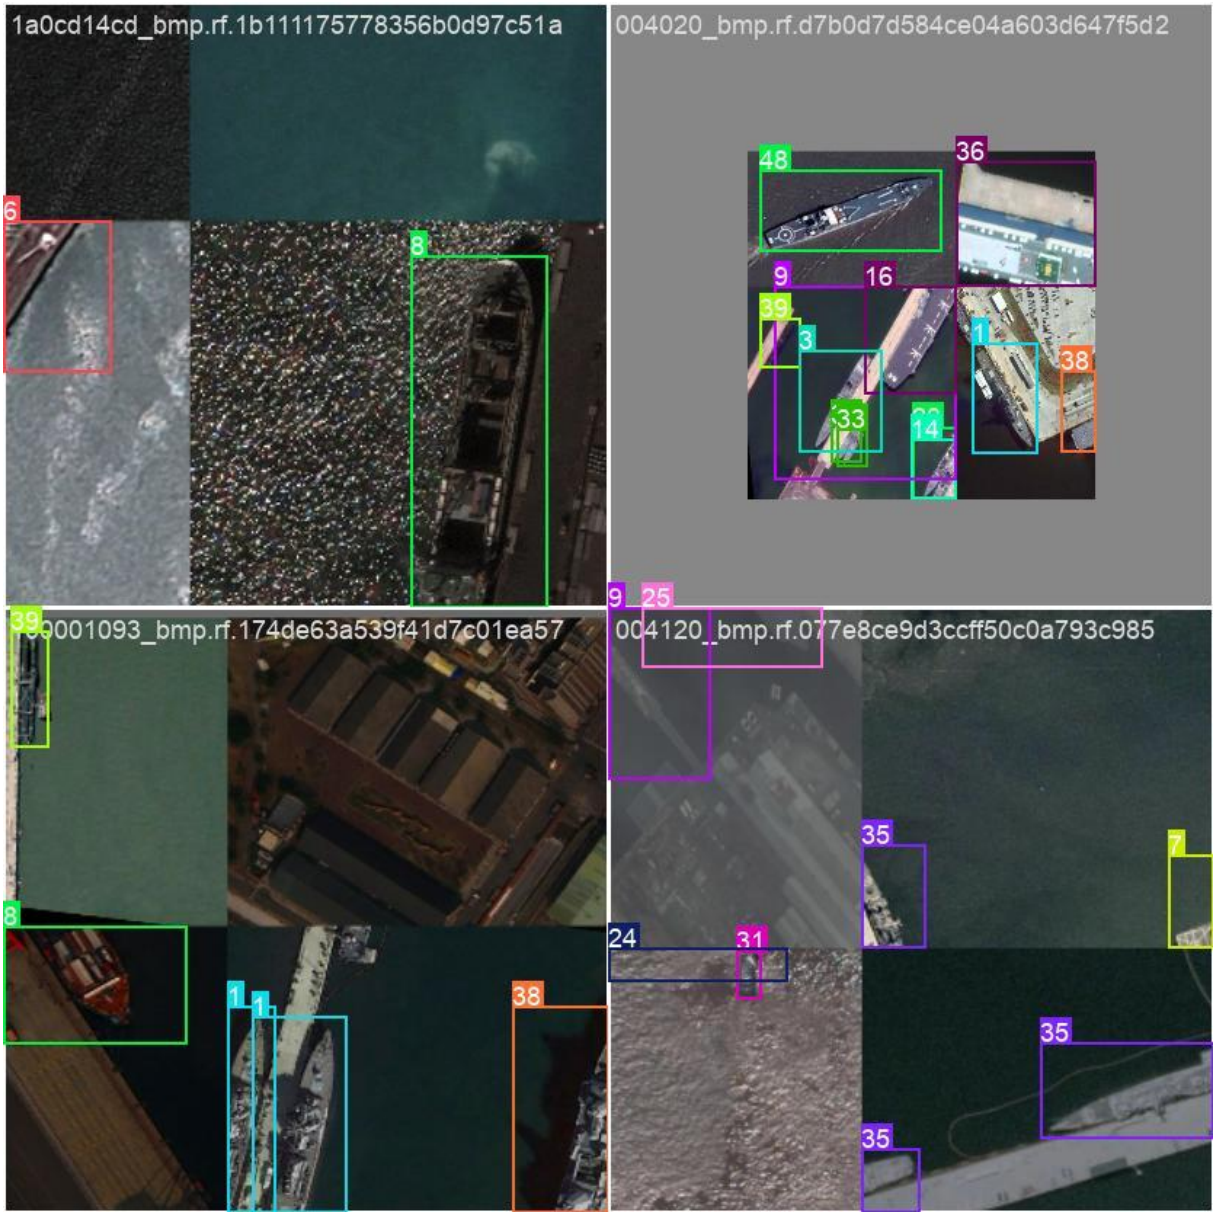
Εικόνα 4: Στιγμιότυπα από παρτίδες εκπαίδευσης (training batch)



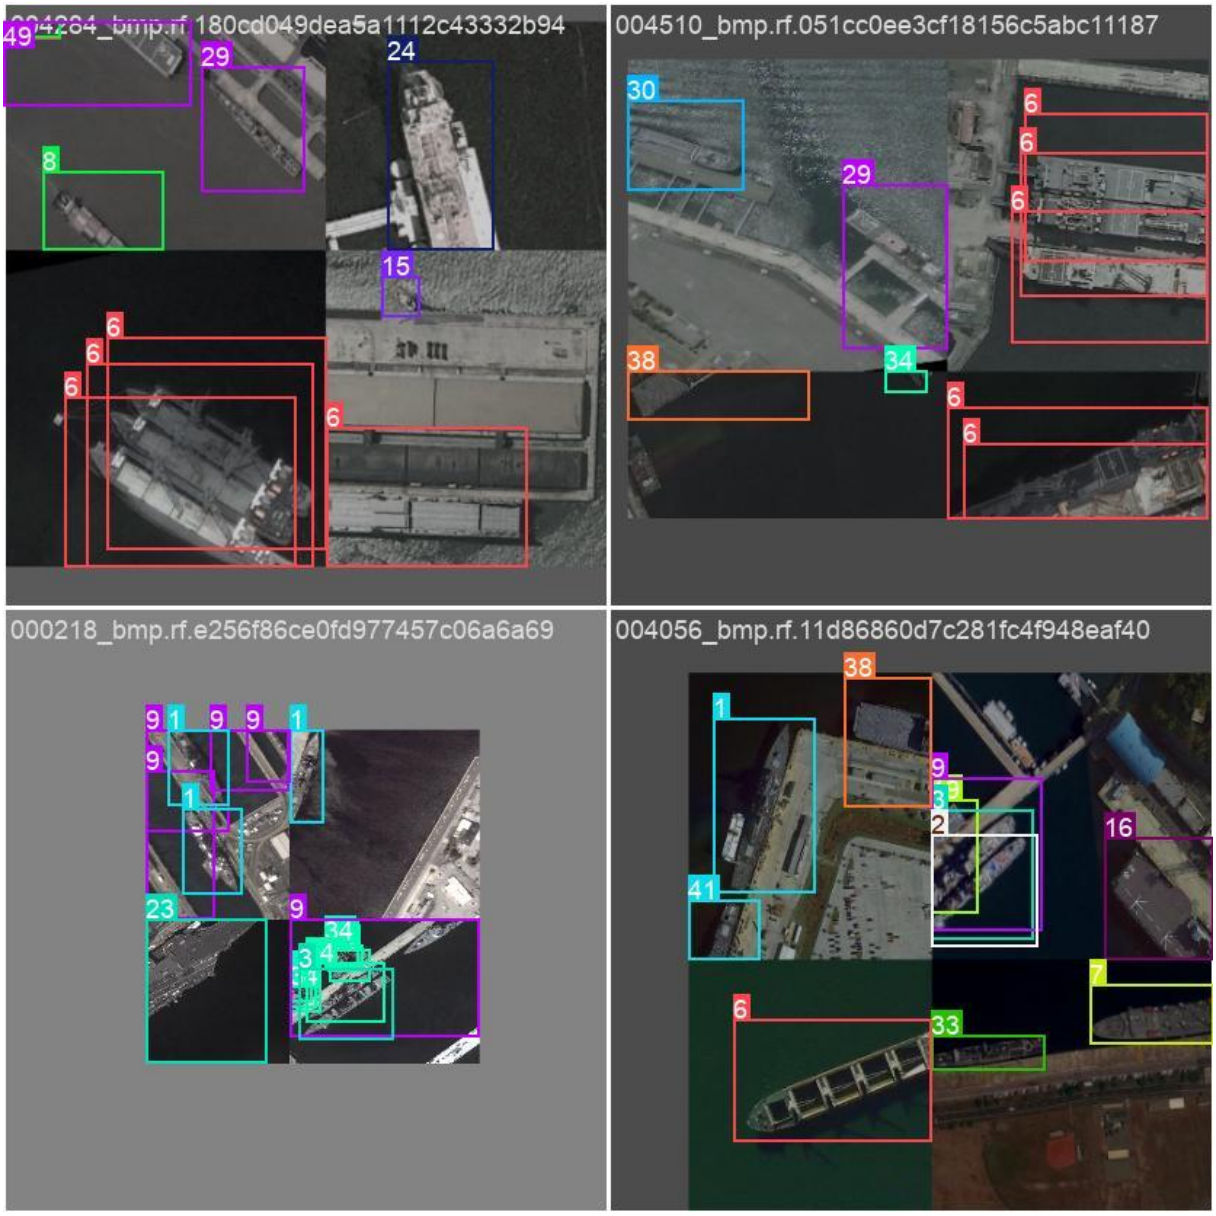
Εικόνα 5: Στιγμιότυπα από παρτίδες εκπαίδευσης (training batch)



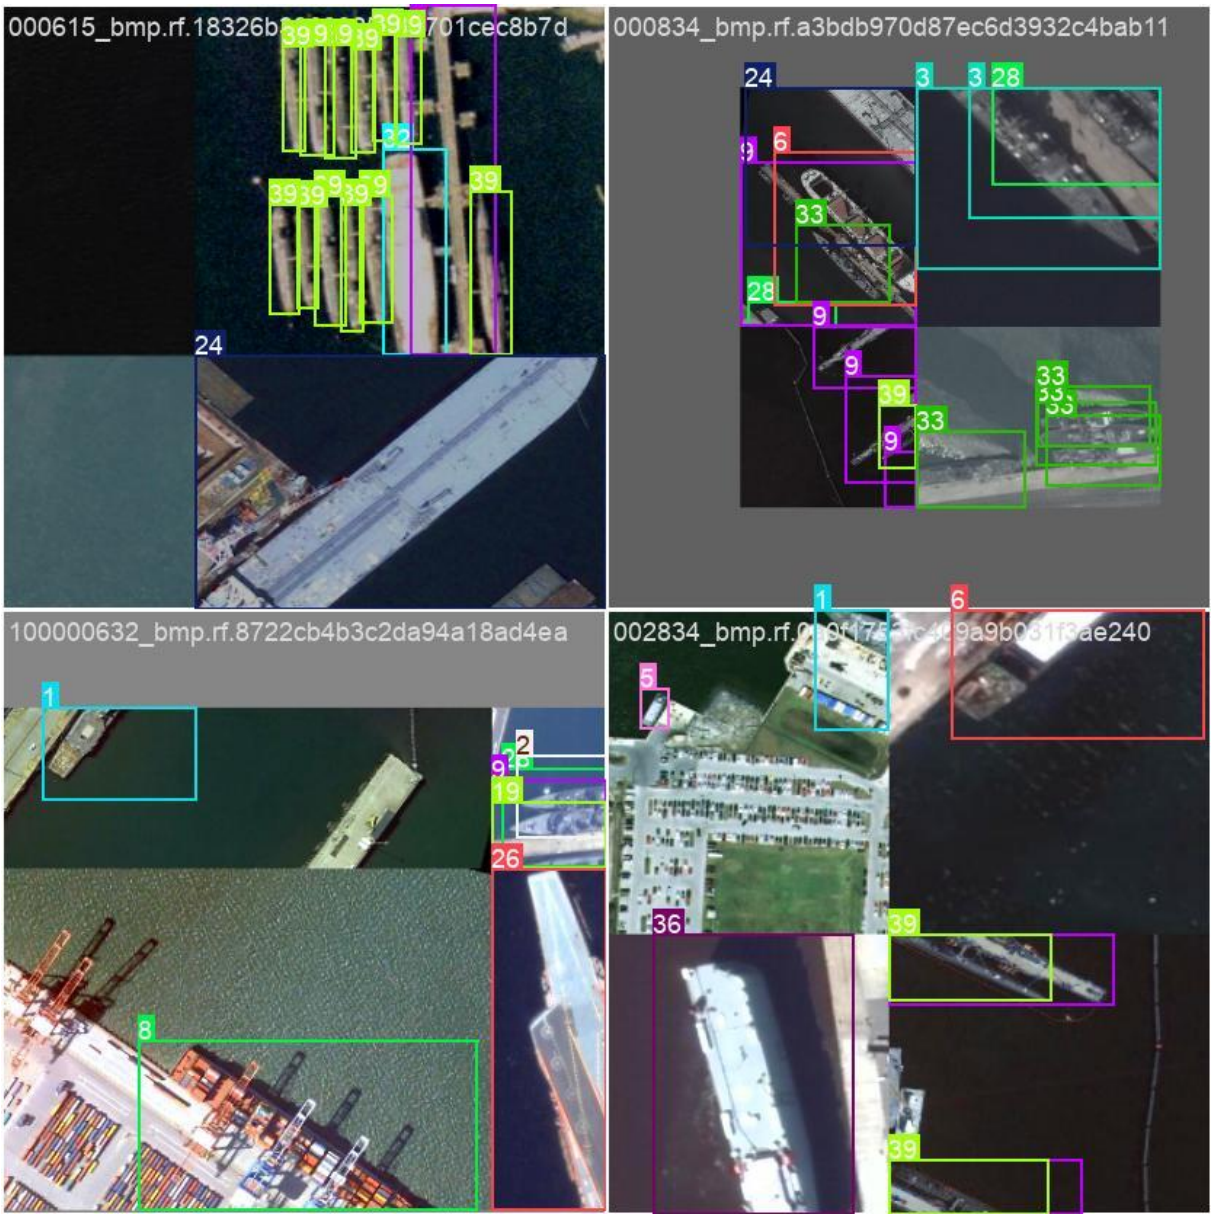
Εικόνα 6: Στιγμιότυπα από παρτίδες εκπαίδευσης (training batch)



Εικόνα 7: Στιγμιότυπα από παρτίδες εκπαίδευσης (training batch)

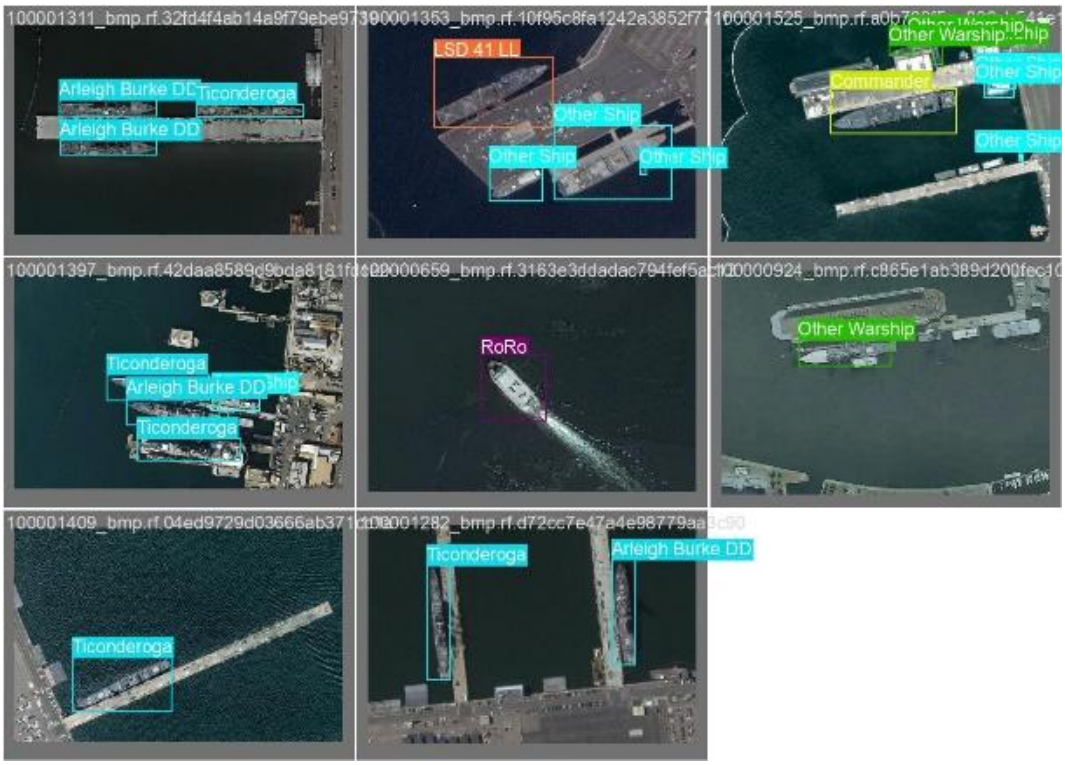


Εικόνα 8: Στιγμιότυπα από παρτίδες εκπαίδευσης (training batch)



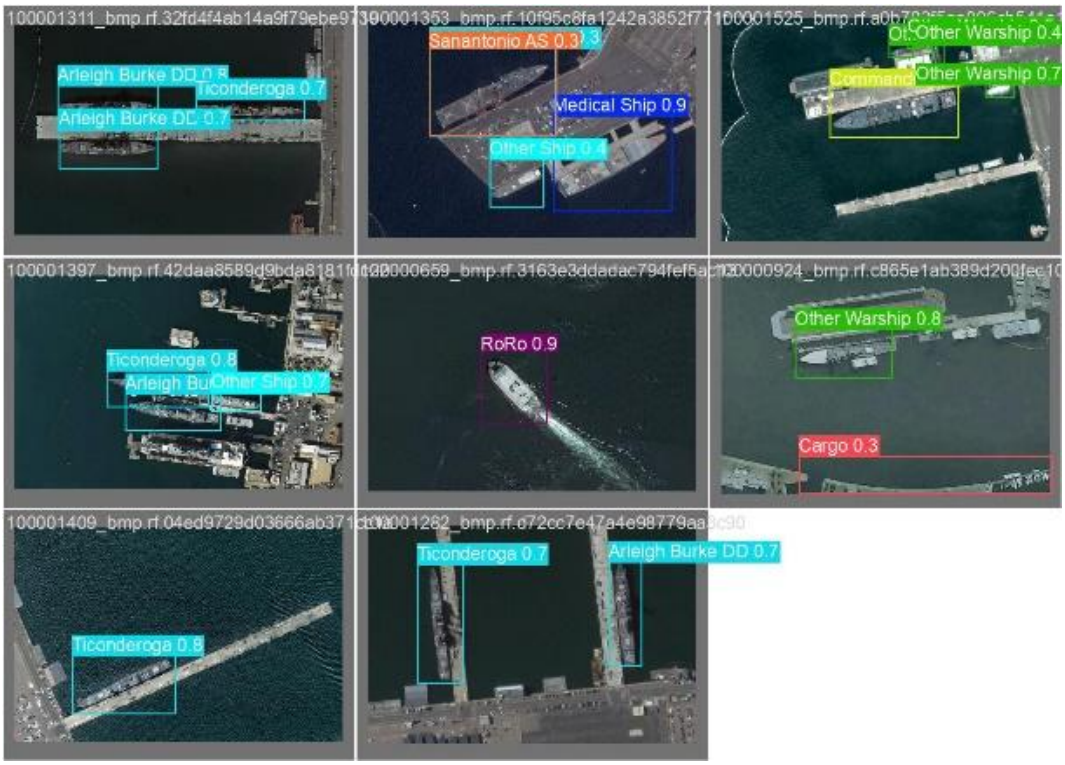
Εικόνα 9: Στιγμιότυπα από παρτίδες εκπαίδευσης (training batch)

Ακολουθούν εικόνες που δημιουργήθηκαν αυτόματα από το YOLOv8m κατά τη φάση της αξιολόγησης του μοντέλου (validation). Οι φωτογραφίες δείχνουν τις εικόνες του validation set όπως τις βλέπει το μοντέλο κατά την αξιολόγηση, με τις πραγματικές (ground truth) ετικέτες (bounding boxes) που υπήρχαν στο αρχικό dataset. Περιλαμβάνουν τα αντικείμενα που επισημαίνονται με ορθογώνια (bounding boxes), ενώ δίπλα σε κάθε αντικείμενο αναγράφεται ο αριθμός της κατηγορίας (Class ID), π.χ. 6, 10, 31, που αντιστοιχεί σε συγκεκριμένο είδος πλοίου.

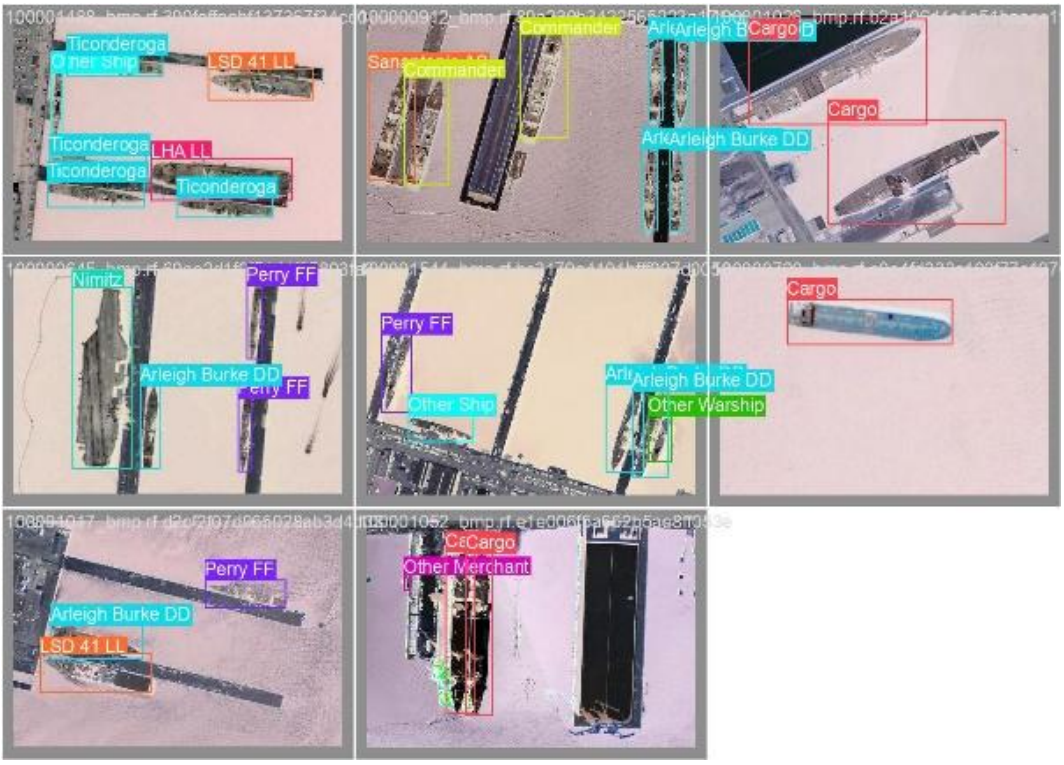


Εικόνα 10: Απεικόνιση εικόνων του σετ επικύρωσης με τις πραγματικές ετικέτες

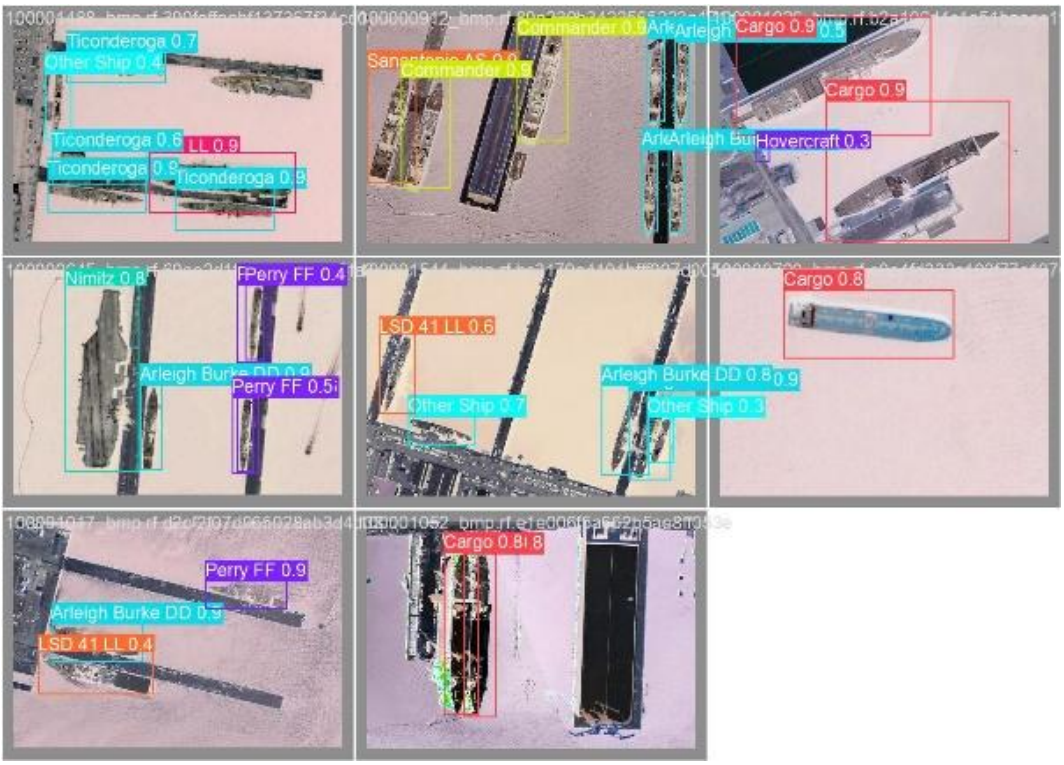
Η εικόνα απεικόνισης των προβλέψεων του εκπαιδευμένου μοντέλου δείχνει τις προβλέψεις (predictions) του εκπαιδευμένου μοντέλου πάνω στις ίδιες εικόνες του validation set. Περιλαμβάνει τα bounding boxes που δημιούργησε το μοντέλο για να εντοπίσει αντικείμενα, τον αριθμό κατηγορίας (Class ID) που προβλέφθηκε και ένα ποσοστό εμπιστοσύνης (confidence score), που δείχνει πόσο σίγουρο είναι το μοντέλο για την πρόβλεψη. Αυτό είναι χρήσιμο για να σύγκριση του τι πρόβλεψε το μοντέλο σε σχέση με την πραγματικότητα (labels).



Εικόνα 11: Απεικόνιση των προβλέψεων του εκπαιδευμένου μοντέλου για το ίδιο σύνολο εικόνων. Κάθε ετικέτα συνοδεύεται από το ποσοστό εμπιστοσύνης της πρόβλεψης



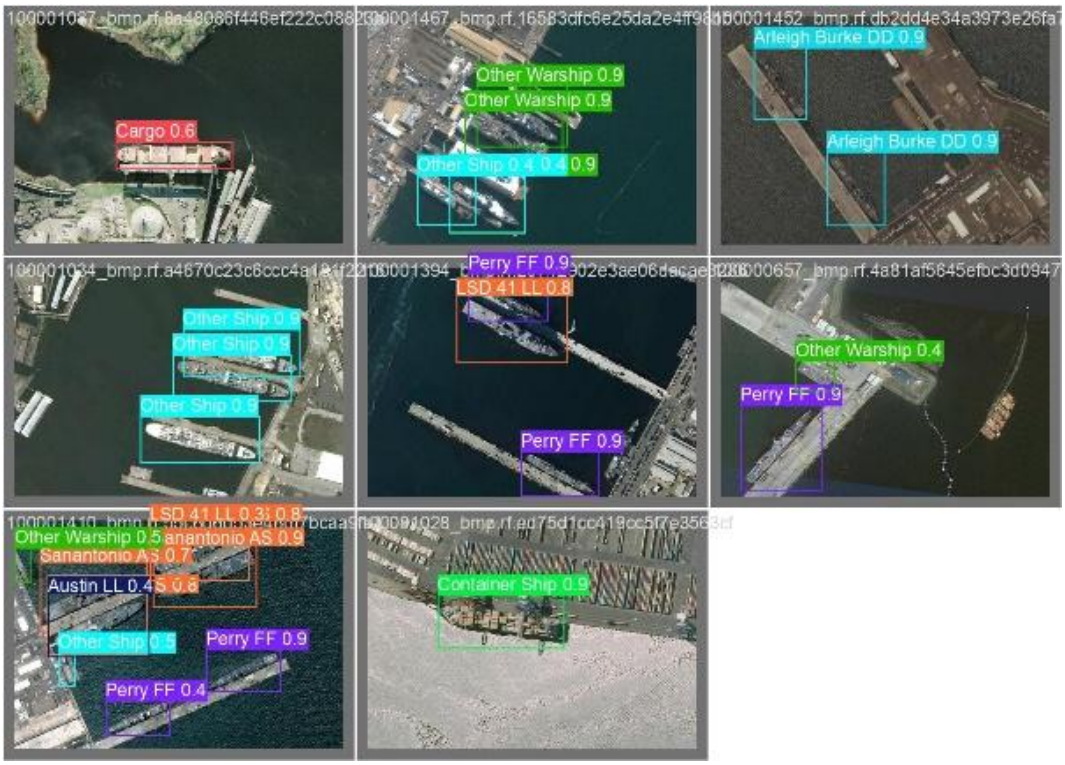
Εικόνα 12: Απεικόνιση εικόνων του σετ επικύρωσης με τις πραγματικές ετικέτες



Εικόνα 13: Απεικόνιση των προβλέψεων του εκπαιδευμένου μοντέλου για το ίδιο σύνολο εικόνων. Κάθε ετικέτα συνοδεύεται από το ποσοστό εμπιστοσύνης της πρόβλεψης



Εικόνα 14: Απεικόνιση εικόνων του σετ επικύρωσης με τις πραγματικές ετικέτες



Εικόνα 15: Απεικόνιση των προβλέψεων του εκπαιδευμένου μοντέλου για το ίδιο σύνολο εικόνων. Κάθε ετικέτα συνοδεύεται από το ποσοστό εμπιστοσύνης της πρόβλεψης

Τέλος, ακολουθεί μια σειρά εικόνων με τα αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου. Η εικόνα παρουσιάζει τα εντοπισμένα πλοία με τα αντίστοιχα πλαίσια περιοχής (bounding boxes), τις ετικέτες κατηγοριών και τους βαθμούς εμπιστοσύνης (confidence scores). Οι εικόνες προέρχονται από τη διαδικασία πρόβλεψης (inference) του εκπαιδευμένου μοντέλου YOLOv8. Δηλαδή, είναι το αποτέλεσμα όταν εφαρμόσαμε το μοντέλο σε καινούργιες εικόνες, τις οποίες θέλαμε να τεστάρουμε.

Κάθε εικόνα είναι μία "νέα" εικόνα στην οποία το μοντέλο έκανε ανίχνευση αντικειμένων. Το YOLO πρόσθεσε πάνω στην εικόνα τα Bounding boxes γύρω από κάθε ανιχνευόμενο αντικείμενο, το όνομα της κατηγορίας πλοίου (π.χ. "Cargo", "Ferry", "Submarine" κ.λπ.) και ένα ποσοστό εμπιστοσύνης (confidence), π.χ. 0.87, που δείχνει πόσο σίγουρο είναι το μοντέλο για την πρόβλεψη.

Αν δηλαδή σε μια εικόνα βλέπουμε το πλαίσιο με την ένδειξη Cargo 0.91, σημαίνει ότι το μοντέλο αναγνώρισε με 91% εμπιστοσύνη ένα πλοίο τύπου "Cargo" στη συγκεκριμένη περιοχή της εικόνας. Αυτό χρησιμεύει για οπτική επιβεβαίωση ότι το μοντέλο λειτουργεί

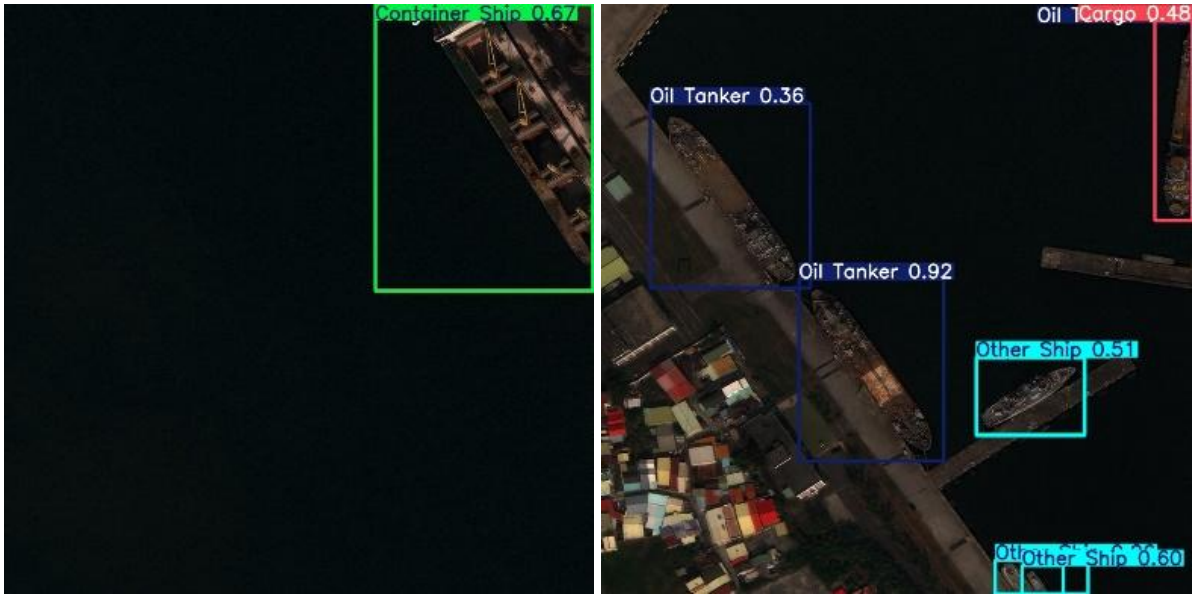
σωστά σε νέες εικόνες. Ακολουθούν μερικές από τις 456 εικόνες με τις προβλέψεις του εκπαιδευμένου μοντέλου YOLOv8 σε νέα, ανεξάρτητα δείγματα.



Εικόνα 16: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου.



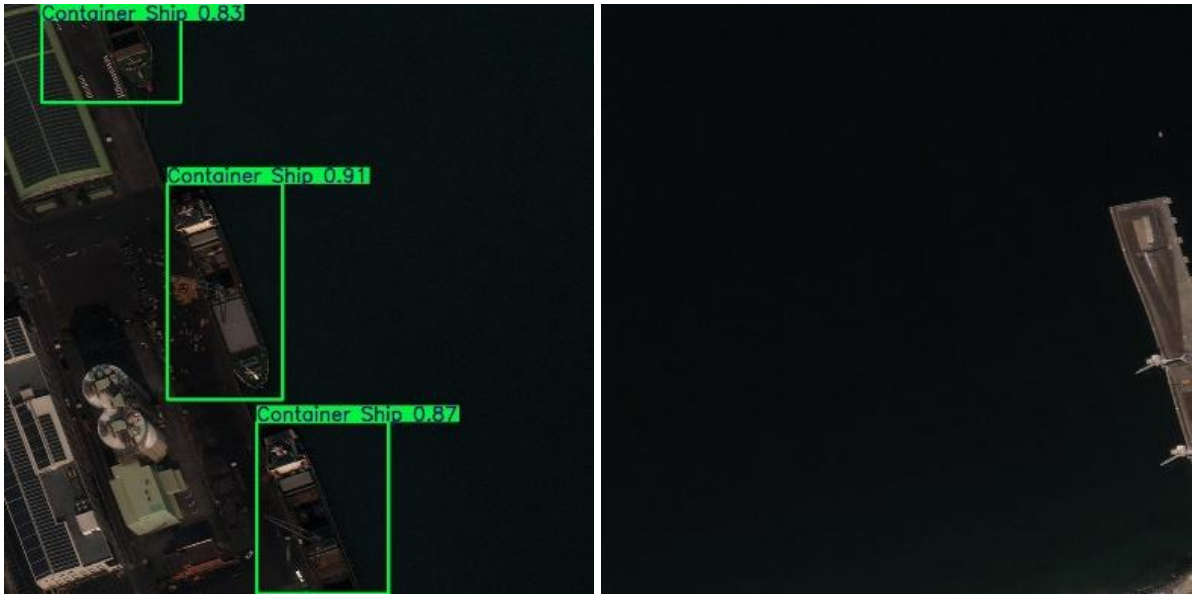
Εικόνα 17: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου.



Εικόνα 18: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου.



Εικόνα 19: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου.



Εικόνα 20: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου.



Εικόνα 21: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου.



Εικόνα 22: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου.



Εικόνα 23: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου.



Εικόνα 24: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου.



Εικόνα 25: Αποτελέσματα ανίχνευσης πλοίων από το εκπαιδευμένο μοντέλο YOLOv8m σε νέες εικόνες εισόδου.

ΚΕΦΑΛΑΙΟ 6

ΣΥΜΠΕΡΑΣΜΑΤΑ

6.1 Συζήτηση των αποτελεσμάτων και των περιορισμών της μεθόδου

Τα αποτελέσματα της εκπαίδευσης υποδεικνύουν ότι το μοντέλο YOLOv8m μπορεί να επιτύχει ικανοποιητικά επίπεδα ακρίβειας στην ανίχνευση πλοίων από αεροφωτογραφίες. Το σύστημα κατάφερε να επιτύχει σημαντικά αποτελέσματα, τα οποία αποτυπώνονται παρακάτω:

- ✓ mAP@0.5: 0.81
- ✓ Precision: 0.766
- ✓ Recall: 0.779

Σε σύγκριση με αποτελέσματα άλλης έρευνας όπως το ShipRSImageNet Computer Vision Project (Roboflow, 2025) που εξέτασε το ίδιο dataset η οποία έδωσε αποτελέσματα:

- ❖ mAP@0.5: 0.642
- ❖ Precision: 0.691
- ❖ Recall: 0.59

Ωστόσο, υπάρχουν και εμφανείς περιορισμοί, καθώς κατηγορίες με πολύ λίγα παραδείγματα, όπως YuDeng LL, Other Aircraft Carrier, Medical Ship, δεν απέδωσαν καλά λόγω ανεπαρκούς εκπροσώπησης στο σύνολο εκπαίδευσης, ενώ κατηγορίες όπως τα Motorboat, Fishing Vessel, και Sailboat παρουσίασαν δυσκολίες στην ταξινόμηση λόγω οπτικής ομοιότητας (σύγχυση μεταξύ ομοειδών κατηγοριών αφού κάποιες κατηγορίες πλοίων παρουσιάζουν υψηλή ομοιότητα, προκαλώντας πιθανή σύγχυση του μοντέλου, όπως για παράδειγμα μεταξύ 'Atago DD' και 'Arleigh Burke DD'), μεγέθους ή θορύβου στο υπόβαθρο.

Επιπλέον, η εκπαίδευση σε στατικές εικόνες (αεροφωτογραφίες) περιορίζει τη γενίκευση σε σενάρια πραγματικού χρόνου ή σε περιβάλλον με χαμηλή ποιότητα εικόνας.

Άρα, σημαντικούς περιορισμούς αποτελούν η ανισορροπία Δεδομένων (Class Imbalance) αφού ορισμένες κατηγορίες πλοίων εμφανίζονται πολύ σπάνια στο σύνολο δεδομένων, γεγονός που οδηγεί σε μειωμένη ακρίβεια για αυτές και υπερεκπαίδευση για τις συχνές κατηγορίες και η δυσκολία στην Ανίχνευση Μικρών ή Σκοτεινών Αντικειμένων δεδομένου

ότι πλοία μικρού μεγέθους ή χαμηλής αντίθεσης, όπως τα 'Motorboat' και 'Fishing Vessel', είναι πιο δύσκολο να εντοπιστούν, με αποτέλεσμα χαμηλότερο mAP.

Επιπλέον περιορισμό αποτελεί η απουσία χρονικής πληροφορίας αφού η μέθοδος YOLOv8 εφαρμόζεται σε στατικές εικόνες χωρίς καμία πληροφορία κίνησης, περιορίζοντας την εφαρμογή της σε πραγματικό χρόνο ή σε συστήματα παρακολούθησης, ενώ η περιορισμένη γενίκευση δεδομένου ότι το μοντέλο έχει εκπαιδευτεί σε ένα συγκεκριμένο σύνολο δεδομένων και δεν είναι βέβαιο πως θα αποδώσει το ίδιο καλά σε νέες γεωγραφικές περιοχές ή συνθήκες.

6.2 Σύνοψη των κύριων ευρημάτων

Τα κύρια ευρήματα της μελέτης μπορούν να αποτυπωθούν ως εξής:

- Το YOLOv8m κατάφερε να γενικεύσει αποτελεσματικά για πάνω από 50 κατηγορίες πλοίων.
- Οι πιο οπτικά διακριτές κατηγορίες όπως Enterprise, EPF, Ticonderoga και Submarine πέτυχαν πολύ υψηλά ποσοστά mAP άνω του 0.7 ακόμα και με λίγες εμφανίσεις.
- Κατηγορίες με οπτική ομοιότητα και μικρό μέγεθος όπως τα Motorboat εμφάνισαν πολύ χαμηλό mAP (< 0.1), παρότι είχαν πολλές εμφανίσεις, πιθανώς λόγω ομοιότητας με άλλα μικρά σκάφη ή λάθος labeling.
- Το μοντέλο επιδεικνύει αξιοσημείωτη απόδοση ακόμα και σε υπολογιστικά περιορισμένο περιβάλλον.
- Οι πιο γενικές κατηγορίες τύπου “Other” έχουν χαμηλότερη απόδοση, όπως είναι αναμενόμενο.

6.3 Ανάλυση των πιθανών βελτιώσεων

Προκειμένου να βελτιωθεί περαιτέρω η απόδοση του μοντέλου, μπορεί να εξεταστεί η αύξηση του όγκου δεδομένων με εμπλουτισμό των φωτογραφιών training και testing, ιδιαίτερα για κατηγορίες με λίγες εμφανίσεις, ενώ η χρήση Data augmentation με τεχνικές όπως περιστροφή, φωτεινότητα, noise injection, ειδικά για μικρά ή δύσκολα πλοία.

Επιπλέον μπορεί να γίνει ανακατάταξη κατηγοριών με συγχώνευση παρόμοιων τύπων ή δημιουργία υπερ-κατηγοριών για πιο σταθερή απόδοση.

6.4 Επισκόπηση της σημασίας της έρευνας

Ο εντοπισμός πλοίων από αεροφωτογραφίες αποτελεί έναν κρίσιμο τομέα έρευνας με σημαντική επίδραση τόσο στην ακαδημαϊκή κοινότητα όσο και στην πρακτική εφαρμογή. Η σημασία του πεδίου αυτού μπορεί να αναλυθεί σε τέσσερις βασικούς άξονες:

Πρώτον, στην ασφάλεια της ναυτιλίας, η ικανότητα ανίχνευσης πλοίων μέσω αεροφωτογραφιών υποστηρίζει τη συνεχή παρακολούθηση της θαλάσσιας κυκλοφορίας. Αυτό συμβάλλει στην πρόληψη συγκρούσεων, στην αντιμετώπιση περιστατικών πειρατείας και στην αποτελεσματικότερη διεκπεραίωση επιχειρήσεων διάσωσης (Ciocarlan & Stoian, 2021).

Δεύτερον, η ανίχνευση πλοίων παίζει σημαντικό ρόλο στην περιβαλλοντική παρακολούθηση. Μέσω αυτής της δυνατότητας, καθίσταται δυνατός ο έλεγχος και η διαχείριση περιβαλλοντικών παραγόντων, όπως η ανίχνευση πετρελαιοκηλίδων και η παρακολούθηση της ρύπανσης των υδάτων (Moursi et al., 2025).

Τρίτον, η επιστημονική έρευνα στον συγκεκριμένο τομέα προάγει την τεχνολογική καινοτομία και την ανάπτυξη προηγμένων μεθόδων επεξεργασίας εικόνας, τεχνικών μηχανικής μάθησης και νευρωνικών δικτύων. Η συνεχής βελτίωση αυτών των τεχνικών συμβάλλει στην εξέλιξη της επιστήμης και την ενίσχυση των δυνατοτήτων ανίχνευσης (Zhou et al., 2017; Feng και Zhang, 2020).

Τέταρτον, ο εντοπισμός πλοίων βρίσκει σημαντικές πρακτικές εφαρμογές πέρα από την ακαδημαϊκή έρευνα, όπως στη διαχείριση της θαλάσσιας κυκλοφορίας, στην περιβαλλοντική προστασία και στην ενίσχυση των μέτρων ασφάλειας (Liu et al., 2023).

Συνολικά, η έρευνα στον τομέα του εντοπισμού πλοίων μέσω αεροφωτογραφιών ανοίγει νέους ορίζοντες για την κατανόηση και παρακολούθηση των θαλάσσιων οικοσυστημάτων, ενώ παράλληλα συμβάλλει στην αύξηση της ασφάλειας και της αποδοτικότητας σε πολλούς κρίσιμους τομείς της κοινωνίας.

Η παρούσα μελέτη επιδεικνύει την αποτελεσματικότητα και την αναγκαιότητα των μοντέλων βαθιάς μάθησης, όπως το μοντέλο YOLOv8, στην αυτόματη αναγνώριση ναυτικών στόχων από εναέριες εικόνες καθώς τέτοιου είδους μέθοδοι μπορούν να φανούν κρίσιμες για την αυτόνομη ναυσιπλοΐα, την θαλάσσια επιτήρηση, την αποτροπή παράνομων δραστηριοτήτων

όπως το λαθρεμπόριο και η παράνομη αλιεία, ακόμα και για πολεμικές αποστολές αναγνώρισης.

Μια τέτοια μελέτη μπορεί να συμβάλλει ουσιαστικά στη γεφύρωση του κενού μεταξύ συμβατικών μεθόδων επιτήρησης και έξυπνων, αυτοματοποιημένων συστημάτων.

ΚΕΦΑΛΑΙΟ 7

ΜΕΛΛΟΝΤΙΚΗ ΕΡΓΑΣΙΑ

7.1 Προτάσεις για μελλοντικές έρευνες στον τομέα του εντοπισμού πλοίων

Επισημαίνοντας τη σημασία της συνεχούς ανάπτυξης των τεχνικών εντοπισμού πλοίων, μερικές προτάσεις για μελλοντικές έρευνες στον τομέα αυτό μπορούν να αποτελέσουν οι εξής:

Ο συνδυασμός πληροφοριών από διάφορες πηγές, όπως αεροφωτογραφίες, ραντάρ και δεδομένα αυτόματου συστήματος αναγνώρισης (AIS: Automatic Identification System), μπορεί να βελτιώσει την ακρίβεια και την αξιοπιστία του εντοπισμού πλοίων, ενοποιώντας την επεξεργασία των δεδομένων.

Η ανάπτυξη μοντέλων που θα μπορούν να παρακολουθούν αυτόματα την κίνηση των πλοίων και να προβλέπουν τις μελλοντικές τους κινήσεις μπορεί να αποβεί κρίσιμη για την πρόληψη ατυχημάτων και την βελτίωση της ναυτιλίας, ενώ η εκπαίδευση μοντέλων αυτόματης αναγνώρισης ύποπτης συμπεριφοράς για την υπόδειξη ελλιμενισμένων πλοίων και την αναγνώριση ασυνήθιστων διαδρομών θα βοηθήσει στον λιμενικό έλεγχο.

Επιπλέον, η ενίσχυση ανίχνευσης πλοίων σε εικόνες χαμηλής ανάλυσης, με έντονο θόρυβο ή/και θολές, αξιοποιώντας τεχνικές όπως Data Augmentation με συνθήκες ομίχλης/νύχτας βελτιώνοντας την ανθεκτικότητα των αλγορίθμων, θα μπορούσε να αποτελέσει μια ενδιαφέρουσα έρευνα, ενώ ο εντοπισμός πλοίων σε Real-Time βίντεο και όχι σε στατικές εικόνες με ανίχνευση σε πραγματικό χρόνο από ροή βίντεο, εντοπίζοντας πλοία σε διαδοχικά καρέ είναι σημαντικός για την ασφάλεια στη θάλασσα με την ανάπτυξη γρήγορων αλγορίθμων για πραγματικό χρόνο.

Τέλος, βάσει των αποτελεσμάτων του μοντέλου που χρησιμοποιήθηκε στην έρευνα αυτή με το συγκεκριμένο dataset, η βελτίωση της ταξινόμησης μεταξύ παρόμοιων κατηγοριών που παρουσίασαν χαμηλή mAP, ιδιαίτερα όταν είναι οπτικά παρόμοιες, όπως Motorboat και Fishing Vessel μπορεί να επιφέρει σαφώς καλύτερα αποτελέσματα επανα-κατηγοριοποιώντας τα πιο προβληματικά labels.

ΒΙΒΛΙΟΓΡΑΦΙΑ

Abadi, M. et al. (2016) TensorFlow: Large-scale machine learning on heterogeneous systems. Ανακτήθηκε 2 Απριλίου από: https://www.tensorflow.org/.

Bibi, E.A., Murthy, T.S., Babu, P.R. & Kuchipudi, R., 2025. *Ship Detection in Remote Sensing Imagery for Arbitrarily Oriented Object Detection*. https://doi.org/10.48550/arXiv.2503.14534

Chalavadi, V., Jeripothula, P., Datla, R., Ch, S. B. et al. (2022) mSODANet: A network for multi-scale object detection in aerial images using hierarchical dilated convolutions. *Pattern Recognition*, 126, 108548. https://doi.org/10.1016/j.patcog.2022.108548

Chen, D., Zhao, H., Li, Y., Zhang, Z., Zhang, K. (2024). PMF-YOLOv8: Enhanced Ship Detection Model in Remote Sensing Images. *Information Technology and Control*, 53(4), 1204-1220. https://doi.org/10.5755/j01.itc.53.4.37003.

Ciocarlan, A. & Stoian, A. (2021). Ship Detection in Sentinel 2 Multi-Spectral Images with Self-Supervised Learning. *Remote Sens*, 13, 4255. https://doi.org/10.3390/rs13214255.

ConvertVOCtoYOLO (2022) *ShipRSImageNet Dataset*. Roboflow Universe. Ανακτήθηκε από: https://universe.roboflow.com/convertvoctoyolo/shiprsimagenet .

Du, S., Qi, Y., Yu, H., Yang, Y. Duan, K., Li, G., Zhang, W., Huang, Q. & Tian, Q. (2018). The Unmanned Aerial Vehicle Benchmark: Object Detection and Tracking. *In Proceedings of the European conference on computer vision (ECCV), σσ. 370-386.* https://arxiv.org/pdf/1804.00518v1.

Everingham, M., Van Gool, L., Williams, C.K.I., Winn, J. and Zisserman, A., (2010) The Pascal Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*, 88(2), σσ.303-338. https://doi.org/10.1007/s11263-009-0275-4

Feng, X. και Zhang, L. (2020) Deep learning for ship detection in remote sensing images: A review, *Journal of Marine Science and Technology*, 28(4), σσ. 495–508. https://doi.org/10.1007/s00773-020-00770-6

Gallego, A., Pertusa, A., & Gil, P. (2018). Automatic Ship Classification from Optical Aerial Images with Convolutional Neural Networks. *Remote Sensing*, 10(4), 511. https://doi.org/10.3390/rs10040511

Goodfellow, I., Bengio, Y. & Courville, A. (2016) *Deep Learning*. Cambridge, MA: MIT Press. Ανακτήθηκε 2 Απριλίου 2025 από: https://www.deeplearningbook.org/.

Graziano, M., Iodice, A., & Riccio, D. (2016) Radon transform applied to ship detection. *Remote Sensing Letters*, 7(7), σσ. 631–640. https://doi.org/10.1080/2150704X.2016.1184293

Guo, B., et al. (2023). Fine-Grained Ship Detection in High-Resolution Satellite Images With Shape-Aware Feature Learning. *In IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, σσ. 1914-1926. https://doi.org/10.1109/JSTARS.2023.3241969.

He, K., Zhang, X., Ren, S. & Sun, J. (2015) Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 37(9), σσ.1904-1916. https://doi.org/10.1109/TPAMI.2015.2389824

He, K., Zhang, X., Ren, S. and Sun, J. (2016) Deep Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), σσ.770-778. https://doi.org/10.1109/CVPR.2016.90.

Huang, G., Wan, Z., Liu, X., Hui, J., Wang, Z. & Zhang, Z. (2019). Ship detection based on squeeze excitation skip-connection path networks for optical remote sensing images. *Neurocomputing*, 332, σσ. 215-223. https://doi.org/10.1016/j.neucom.2018.12.050.

Iervolino, P. and Guida, R. (2017). A Novel Ship Detector Based on the Generalized-Likelihood Ratio Test for SAR Imagery. In IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 10 (8), σσ. 3616-3630. https://doi.org/10.1109/JSTARS.2017.2692820.

Iervolino, P., Guida, R. and Whittaker, P. (2016). A model for the backscattering from a canonical ship in SAR imagery. *IEEE J. Sel. Topics Appl. Earth Obs. Remote Sens*., 9 (3), σσ. 1163–1175 από: https://ieeexplore.ieee.org/document/7137630

Jocher, G., et al. (2023) "YOLOv8: The latest in real-time object detection", *Ultralytics*. Ανακτήθηκε 12 Απριλίου 2025 από: https://ultralytics.com/ .

Jocher, G. et al., (2023) "YOLOv8: You Only Look Once". Ultralytics. Ανακτήθηκε 12 Απριλίου 2025 από: https://ultralytics.com/yolov8 .

Krizhevsky, A., Sutskever, I. & Hinton, G.E., (2012) ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*, 60(6), σσ.84-90. https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf.

Lam, D., Tran, V., Nguyen, D., & Le, H. (2018) xView: Objects in Context in Overhead Imagery. *arXiv preprint arXiv:1802.07856*. https://arxiv.org/pdf/1802.07856.

LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *Nature* 521, σσ. 436–444. https://doi.org/10.1038/nature14539

Li, K., Wan, G., Cheng, G., Meng, L., & Han, J. (2019). *Object Detection in Optical Remote Sensing Images: A Survey and A New Benchmark.* https://doi.org/10.1016/j.isprsjprs.2019.11.023

Lin, T.Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P. and Zitnick, C.L., (2014) Microsoft COCO: Common Objects in Context. *European Conference on Computer Vision (ECCV)*, σσ.740-755. https://doi.org/10.1007/978-3-319-10602-1_48.

Lin, T.Y., Dollár, P., Girshick, R., He, K., Hariharan, B. and Belongie, S. (2017) Feature Pyramid Networks for Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, σσ.2117-2125. https://openaccess.thecvf.com/content_cvpr_2017/papers/Lin_Feature_Pyramid_Networks_CVPR_2017_paper.pdf.

Liu, X., Hu, Y., Ji, H., Zhang, M., & Yu, Q. (2023). A Deep Learning Method for Ship Detection and Traffic Monitoring in an Offshore Wind Farm Area. *Journal of Marine Science and Engineering*, 11(7), 1259. https://doi.org/10.3390/jmse11071259.

Liu, S. et al. (2018) Path Aggregation Network for Instance Segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, σσ.8759-8768. http://dx.doi.org/10.1109/CVPR.2018.00913.

Liu, W., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X., & Pietikäinen, M. (2017) Deep learning for generic object detection: A survey. *International Journal of Computer Vision*, 128(2), σσ. 261-318. https://doi.org/10.48550/arXiv.1809.02165

Mazzeo, A., Renga, A., & Graziano, M. D. (2023). A Systematic Review of Ship Wake Detection Methods in Satellite Imagery. *Remote Sensing*, 16(20), 3775. https://doi.org/10.3390/rs16203775.

Moursi, M., Wehn, N., & Hammoud, B. (2025). *Smart Environmental Monitoring of Marine Pollution using Edge AI.* ArXiv. https://arxiv.org/abs/2504.21759.

Murphy, K.P., (2012) *Machine Learning: A Probabilistic Perspective*. Cambridge, MA: MIT Press.

Paszke, A. et al., (2019) PyTorch: An imperative style, high-performance deep learning library. *Advances in Neural Information Processing Systems*, 32. In H. Wallach and H. Larochelle and A. Beygelzimer and F. d'Alché-Buc and E. Fox and R. Garnett (Eds). 2019 Fifth Workshop on Energy Efficient Machine Learning and Cognitive Computing - NeurIPS Edition (EMC2-NIPS 2019). Institute of Electrical and Electronics Engineers (IEEE).

Razakarivony, S., & Jurie, F. (2016) Vehicle detection in aerial imagery: A small target detection benchmark. *Journal of Visual Communication and Image Representation*, 34, σσ. 187-203. https://doi.org/10.1016/j.jvcir.2015.11.002

Roboflow (2025) *ShipRSImageNet Dataset on Roboflow Universe*. Ανακτήθηκε από: https://universe.roboflow.com/convertvoctoyolo/shiprsimagenet .

Sammer, M.D., Vardhan, V.A., Pavani, P. & Reddy, M.Y. (2025). Ship Detection Based on Faster R-CNN Using Range-Compressed Airborne Radar Data. *International Journal for Research in Applied Science & Engineering Technology*, 13 (3). σσ. 1305-1311. https://www.ijraset.com/best-journal/ship-detection-based-on-faster-rcnn-using-range-compressed-airborne-radar-data.

Schmidhuber, J., (2015) Deep learning in neural networks: An overview. *Neural Networks*, 61, σσ.85-117. http://dx.doi.org/10.1016/j.neunet.2014.09.003

Sekine, T. (2024). *Ship detection from high-resolution optical remote sensing images using YOLO*. Ανάκτηση στις 05 Απριλίου 2025 από: https://space.elspina.tech/ship-detection-from-high-resolution-optical-remote-sensing-images-using-yolo-23d053713e5d.

Shi, W., Zheng, W. & Xu, Z. (2025) *Ship-Yolo: A Deep Learning Approach for Ship Detection in Remote Sensing Images*, *Journal of Marine Science and Engineering*, 13(4), Art. 737. https://doi.org/10.3390/jmse13040737

Sun, Y., Zheng, L., Deng, W., & Wang, S. (2017). Svdnet for pedestrian retrieval. *In Proceedings of the IEEE international conference on computer vision*, σσ. 3800-3808.

Techmaniacs (2024) Why Neural Networks Are the Future of Computing. Ανακτήθηκε 23 Ιουνίου 2025 από: https://techmaniacs.gr/why-neural-networks-are-the-future-of-computing/

Ultralytics, 2023. YOLOv8 Documentation. Ανακτήθηκε 23 Ιουνίου 2025 από: https://docs.ultralytics.com/

Ultralytics, (2023) *YOLOv8 Architecture*. Ανακτήθηκε 23 Ιουνίου 2025 από: https://docs.ultralytics.com/modes/detect/

Wang, CY, Liao, HYM, Wu, YH, Chen, P-Y, Hsieh, J-W, Yeh, I-H (2020). CSPNet: A New Backbone That Can Enhance Learning Capability of CNN. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, σσ. 390-391.

Wang, J., Yang, W., Guo, H., Zhang, R. & Xia, G.S. (2020b). Tiny Object Detection in Aerial Images. Ανακτήθηκε 02 Απριλίου 2025 από: https://drive.google.com/file/d/1IiTp7gilwDCGr8QR_H9Covz8aVK7LXiI/view.

Wang, H., Liu, J. & Zhang, Y. (2024) 'ALF-YOLO: Enhanced YOLOv8 based on multiscale attention feature fusion for ship detection', *Ocean Engineering*, 308, σ. 118233. https://doi.org/10.1016/j.oceaneng.2024.118233

Xia, G., Bai, X., Ding, J., Zhu, Z., Belongie, S., Luo, J., Datcu, M., Pelillo, M. and Zhang, L. (2018) DOTA: A large-scale dataset for object detection in aerial images. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, σσ.3974-3983. https://doi.org/10.1109/CVPR.2018.00418.

Xu, C., Wang, J., Yang, W., Yu, H., Yu, L. and Xia, G.S., (2022). Detecting tiny objects in aerial images: A normalized Wasserstein distance and a new benchmark. ISPRS Journal of Photogrammetry and Remote Sensing, 190. σσ. 79–93. https://doi.org/10.1016/j.isprsjprs.2022.06.002

Xu, C., Wang, J., Yang, W., & Yu, L. (2021). Dot distance for tiny object detection in aerial images. *In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. σσ. 1192-1201. https://openaccess.thecvf.com/content/CVPR2021W/EarthVision/html/Xu_Dot_Distance_for_Tiny_Object_Detection_in_Aerial_Images_CVPRW_2021_paper.html.

Zeng, Y., Wang, X., Zou, J., & Wu, H. (2024). YOLO-Ssboat: Super-Small Ship Detection Network for Large-Scale Aerial and Remote Sensing Scenes. *Remote Sensing*, 17(11), 1948. https://doi.org/10.3390/rs17111948

Zhang, Y., Guo, L., Wang, Z., Yu, Y., Liu, X., & Xu, F. (2019). Intelligent Ship Detection in Remote Sensing Images Based on Multi-Layer Convolutional Feature Fusion. *Remote Sensing*, 12(20), 3316. https://doi.org/10.3390/rs12203316

Zhang, Y., Guo, L., Wang, Z., Yu, Y., Liu, X., & Xu, F. (2019b). Intelligent Ship Detection in Remote Sensing Images Based on Multi-Layer Convolutional Feature Fusion. *Remote Sensing*, 12(20), 3316. https://doi.org/10.3390/rs12203316

Zhang, G., Lu, S. and Zhang, W. (2019c). CAD-Net: A Context-Aware Detection Network for Objects in Remote Sensing Imagery. In IEEE Transactions on Geoscience and Remote Sensing, 57 (12), σσ. 10015-10024. http://dx.doi.org/10.1109/TGRS.2019.2930982.

Zhang, Z., Zhang, L., Wang, Y., Feng, P. & He, R. (2021) ShipRSImageNet: A Large-Scale Fine-Grained Dataset for Ship Detection in High-Resolution Optical Remote Sensing Images, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, σσ. 8458–8472. https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=9512396.

Zhao, Z.-Q., Zheng, P., Xu, S.-T., & Wu, X. (2019) Object detection with deep learning: A review. *IEEE Transactions on Neural Networks and Learning Systems*, 30(11), σσ. 3212-3232. http://dx.doi.org/10.1109/TNNLS.2018.2876865.

Zhao, T., Wang, Y., Li, Z., Gao, Y., Chen, C., Feng, H., & Zhao, Z. (2023). Ship Detection with Deep Learning in Optical Remote-Sensing Images: A Survey of Challenges and Advances. *Remote Sensing*, 16(7), 1145. https://doi.org/10.3390/rs16071145

Zhou, X., Wang, D., & Krähenbühl, P. (2019). *Objects as points*. arXiv preprint arXiv:1904.07850.

Zhu, P., Wen, L., Bian, X., Ling, H., & Hu, Q. (2018) VisDrone-2018: Vision Meets Drones: A Challenge. https://arxiv.org/pdf/1804.07437

Zhu, X., Chen, X. & Zhang, Y. (2017) Deep learning based ship detection from remote sensing images', *IEEE Transactions on Geoscience and Remote Sensing*, 55(9), σσ. 5309–5321. http://dx.doi.org/10.1109/TGRS.2017.2700580

ΠΑΡΑΡΤΗΜΑ Α

Κατηγορίες πλοίων του dataset και περιγραφή τους:

Κατηγορία	Περιγραφή
AOE	Fast combat support ship providing fuel, ammunition, and supplies to carrier groups.
Arleigh Burke DD	Guided-missile destroyer used by the U.S. Navy for multi-role operations.
Asagiri DD	Japanese destroyer designed for anti-aircraft and anti-submarine warfare.
Atago DD	Modern Japanese Aegis-equipped destroyer with advanced radar and missile systems.
Austin LL	Amphibious transport dock used to carry Marines and landing craft.
Barge	Flat-bottomed boat used to carry freight on rivers and canals.
Cargo	General commercial cargo ship for transporting goods across oceans.
Commander	Small naval or coast guard vessel often used for patrol or command duties.
Container Ship	Commercial ship designed to carry standardized shipping containers.
Dock	Docked ship or dock facility used for loading/unloading.
EPF	Expeditionary Fast Transport - high-speed vessels for rapid troop and cargo transport.
Enterprise	Nuclear-powered aircraft carrier (e.g. USS Enterprise).
Ferry	Passenger or vehicle transport vessel used across short sea routes.
Fishing Vessel	Boat or ship used to catch fish in the sea or lakes.
Hatsuyuki DD	Japanese destroyer for escort and fleet support missions.
Hovercraft	Amphibious vehicle that travels over water and land using air cushion.
Hyuga DD	Helicopter-carrying destroyer with light carrier capabilities.
LHA LL	Landing Helicopter Assault ship, used for Marine deployment and air support.
LSD 41 LL	Dock landing ship used for amphibious operations and vehicle transport.
Masyuu AS	Japanese support ship used to refuel and resupply fleet units.
Medical Ship	Hospital or medical support ship used in military or humanitarian missions.
Midway	Aircraft carrier (e.g. USS Midway) used during the Cold War era.
Motorboat	Small powered boat used for transport or recreation.
Nimitz	Nuclear-powered aircraft carrier class of the U.S. Navy.
Oil Tanker	Large ship designed to transport oil or petroleum products.

Osumi LL	Japanese landing ship designed to carry tanks and vehicles.
Other Aircraft Carrier	Aircraft carrier not belonging to a specific well-known class.
Other Auxiliary Ship	Non-combat support vessel (e.g. supply or survey ship).
Other Destroyer	Destroyer not specified by class or nation.
Other Frigate	General category for unidentified frigate-type ships.
Other Landing	Other types of amphibious landing ships.
Other Merchant	Merchant ship not falling into common cargo categories.
Other Ship	Generic label for unidentified ship types.
Other Warship	Warship not classifiable into other specific categories.
Patrol	Small fast vessel used for coastal patrol or law enforcement.
Perry FF	Oliver Hazard Perry-class frigate used for escort missions.
RoRo	Roll-on/roll-off ship for transporting wheeled cargo like cars and trucks.
Sailboat	Small or medium sailing vessel powered by wind.
Sanantonio AS	Amphibious transport dock of the U.S. Navy San Antonio class.
Submarine	Underwater vessel capable of submersion and stealth operations.
Test Ship	Ship used for trials, experiments or system testing.
Ticonderoga	Cruiser class equipped with Aegis combat system.
Training Ship	Ship used to train cadets and naval personnel.
Tugboat	Small powerful boat used to tow or push larger ships in port.
Wasp LL	Landing Helicopter Dock ship class used for amphibious operations.
Yacht	Private leisure craft, often large and luxurious.
YuDao LL	Chinese amphibious landing ship of YuDao class.
YuDeng LL	Chinese landing support ship, limited sightings.
YuTing LL	Older Chinese landing ship used for troop transport.
YuZhao LL	Chinese Type 071 amphibious transport dock.

ΠΑΡΑΡΤΗΜΑ Β

Κώδικας που χρησιμοποιήθηκε-επεξεργάστηκε στην εκπαίδευση του μοντέλου:

- pip install ultralytics //για να γίνει install στη βιβλιοθήκη

- Το arxeio data.yaml λέει στο μοντέλο που είναι οι φωτογραφίες και ποιες είναι οι κλάσεις:

train: train/images

val: valid/images

test: test/images

nc: 50

names: ['AOE', 'Arleigh Burke DD', 'Asagiri DD', 'Atago DD', 'Austin LL', 'Barge', 'Cargo', 'Commander', 'Container Ship', 'Dock', 'EPF', 'Enterprise', 'Ferry', 'Fishing Vessel', 'Hatsuyuki DD', 'Hovercraft', 'Hyuga DD', 'LHA LL', 'LSD 41 LL', 'Masyuu AS', 'Medical Ship', 'Midway', 'Motorboat', 'Nimitz', 'Oil Tanker', 'Osumi LL', 'Other Aircraft Carrier', 'Other Auxiliary Ship', 'Other Destroyer', 'Other Frigate', 'Other Landing', 'Other Merchant', 'Other Ship', 'Other Warship', 'Patrol', 'Perry FF', 'RoRo', 'Sailboat', 'Sanantonio AS', 'Submarine', 'Test Ship', 'Ticonderoga', 'Training Ship', 'Tugboat', 'Wasp LL', 'Yacht', 'YuDao LL', 'YuDeng LL', 'YuTing LL', 'YuZhao LL']

- Για την εκπαίδευση του μοντέλου:

yolo task=detect mode=train model=yolov8n.pt data=data.yaml epochs=50 imgsz=416

- Μετά την εκπαίδευση του μοντέλου για να γίνει το validation:

yolo task=detect mode=val model=runs/detect/train/weights/best.pt data=data.yaml

- Για να γίνει install το Streamlit:

pip install streamlit ultralytics opencv-python-headless

- Το arxeio app.py που τρέχει τον webserver στέλνει τα request στον server:

```
import streamlit as st
from ultralytics import YOLO
from PIL import Image
```

```
import numpy as np
import cv2
import tempfile
```

- Load the trained model

```
model = YOLO("runs/detect/train/weights/best.pt")

st.title("Ship Detection - YOLOv8")
st.write("Upload an aerial image to detect ships.")

uploaded_file = st.file_uploader("Choose an image...", type=["jpg", "jpeg", "png"])

if uploaded_file is not None:
    image = Image.open(uploaded_file).convert("RGB")
    st.image(image, caption="Uploaded Image", use_container_width=True)

    with st.spinner("Running detection..."):
        # Save to temp file for YOLO input
        with tempfile.NamedTemporaryFile(delete=False, suffix=".jpg") as tmp:
            image.save(tmp.name)
            results = model(tmp.name)

        # Render predictions
        result_img = results[0].plot()  # returns OpenCV image (BGR)
        result_img = cv2.cvtColor(result_img, cv2.COLOR_BGR2RGB)  # convert to RGB

        st.image(result_img, caption="Detected Image", use_container_width=True)

        # Optional: show detection data
        st.write("Detections:")
        for box in results[0].boxes.data:
```

```
            cls_id = int(box[5])
            conf = float(box[4])
            cls_name = model.names[cls_id]
            st.write(f"{cls_name} ({conf:.2f})")
```

- Για να τρέξει το app:

```
streamlit run app.py
```