



Καινοτόμες λύσεις για τη βιώσιμη και περιβαλλοντικά φιλική φυτοπροστασία των οπωροκηπευτικών της Ελλάδας, στην Ευρώπη του μέλλοντος

Παραδοτέο Π.1.4.1: Μοντέλα αυτοματοποιημένης αναγνώρισης ζιζανίων για χρήση από drone για την υποστήριξη συστήματος δημιουργίας ζωνών διαφοροποιημένης εφαρμογής ζιζανιοκτόνων

Πληροφορίες για το έγγραφο

Αριθμός παραδοτέου: **Π1.4.1**

Ενότητα εργασίας: **ΕΕ1**

Επικεφαλής δικαιούχος: **ΕΛΓΟ-ΔΗΜΗΤΡΑ**

Συγγραφείς: **Χρυσή Κόπακα, Κωνσταντίνος Φερεντίνος, Γεράσιμος Πετεινάτος, Δημοσθένης Χάχαλης**

Έκδοση: **1.0**

Είδος Παραδοτέου: **Έκθεση**

Ημερομηνία παράδοσης: **31 Οκτωβρίου 2025**

Στοιχεία Πράξης

Τίτλος: Καινοτόμες λύσεις για τη βιώσιμη και περιβαλλοντικά φιλική φυτοπροστασία των οπωροκηπευτικών της Ελλάδας, στην Ευρώπη του μέλλοντος

Τίτλος (EN): InnoPP-Innovations in Plant Protection for sustainable and environmentally friendly pest control

Κωδικός πράξης: TAEDR-0535675

Ακρωνύμιο έργου: InnoPP

Ημερομηνία έναρξης: 15 Μαΐου 2023

Διάρκεια: 28 Μήνες

Συντονιστής Φορέας: Γεωπονικό Πανεπιστήμιο Αθηνών

Συντονιστής/ Επιστημονικός Υπεύθυνος: Ιωάννης Βόντας

Πίνακας Περιεχομένων

1	ΕΙΣΑΓΩΓΗ ΚΑΙ ΣΤΟΧΟΙ	5
2	ΠΕΡΙΓΡΑΦΗ ΤΩΝ ΕΡΓΑΣΙΩΝ	7
2.1	ΣΥΝΤΟΜΗ ΒΙΒΛΙΟΓΡΑΦΙΚΉ ΑΝΑΣΚΟΠΗΣΗ	7
2.1.1	Χρήση μοντέλων βαθιάς μάθησης για τον αυτόματο εντοπισμό ζιζανίων	7
2.1.2	Μέθοδοι προ-επεξεργασίας εικόνων για την εκπαίδευση μοντέλων	10
2.2	ΒΑΣΗ ΔΕΔΟΜΕΝΩΝ ΑΝΑΠΤΥΞΗΣ ΜΟΝΤΕΛΩΝ	11
2.2.1	Συλλογή δεδομένων	11
2.2.2	Καλλιέργεια και είδη ζιζανίων ενδιαφέροντος	12
2.2.3	Δημιουργία βάσης δεδομένων	14
2.2.3.1	Πρώτη βάση δεδομένων	14
2.2.3.2	Δεύτερη βάση δεδομένων	19
2.3	ΕΚΠΑΙΔΕΥΣΗ ΜΟΝΤΕΛΩΝ	20
2.3.1	Πρώτη εκπαίδευση μοντέλων - Ολόκληρες εικόνες εισόδου	21
2.3.2	Δεύτερη εκπαίδευση μοντέλων - Τμηματοποιημένες εικόνες εισόδου	24
2.3.2.1	Ανάπτυξη μοντέλων Faster R-CNN	24
2.3.2.2	Ανάπτυξη μοντέλων Vision Transformer	25
2.3.2.3	Ανάπτυξη μοντέλου YOLO11	26
2.4	ΑΞΙΟΛΟΓΗΣΗ ΤΕΛΙΚΉΝ ΜΟΝΤΕΛΩΝ	26
2.4.1	YOLO11 με ολόκληρες εικόνες εισόδου	27
2.4.2	YOLO11 με τμηματοποιημένες εικόνες εισόδου (tiling)	38
2.5	ΔΗΜΙΟΥΡΓΙΑ ΧΑΡΤΩΝ ΖΙΖΑΝΙΩΝ	46
2.5.1	Σύντομη βιβλιογραφική ανασκόπηση	46
2.5.2	Μεθοδολογία δημιουργίας χαρτών ζιζανίων από βίντεο ΣμηΕΑ	47
2.5.2.1	Χάρτες επικρατέστερου (κυρίαρχου) ζιζανίου	48
2.5.2.2	Χάρτες σχετικής πυκνότητας ζιζανίων	49
2.5.2.3	Χάρτες απόλυτης πυκνότητας ζιζανίων	53
2.5.3	Επαλήθευση δημιουργίας χαρτών ζιζανίων σε νέα δεδομένα	57
2.5.3.1	Χάρτες επικρατέστερου (κυρίαρχου) ζιζανίου	58
2.5.3.2	Χάρτες σχετικής πυκνότητας ζιζανίων	60
2.5.3.3	Χάρτες απόλυτης πυκνότητας ζιζανίων	64
2.6	ΣΥΖΗΤΗΣΗ	70
3	ΣΥΝΟΨΗ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ	75
4	ΠΑΡΑΡΤΗΜΑ Ι	76
5	ΠΑΡΑΡΤΗΜΑ ΙΙ	83

Περίληψη του Έργου

Το έργο «Καινοτόμες λύσεις για τη βιώσιμη και περιβαλλοντικά φιλική φυτοπροστασία των οπωροκηπευτικών της Ελλάδας, στην Ευρώπη του μέλλοντος» στοχεύει στην ανάπτυξη σύγχρονων και καινοτόμων μεθόδων για την προστασία των καλλιεργειών όπως τα κηπευτικά, τα εσπεριδοειδή και το επιτραπέζιο σταφύλι. Περιλαμβάνει τη δημιουργία προηγμένων διαγνωστικών εργαλείων για την ανίχνευση εχθρών και παθογόνων με τεχνολογίες αιχμής, όπως ηλεκτρονικές παγίδες και βιοαισθητήρες, καθώς και πλατφόρμες αλληλούχησης για τον πλήρη προσδιορισμό των ιωμάτων. Επιπλέον, θα αναπτυχθούν μοντέλα πρόβλεψης επιδημιών και καινοτόμα βιοφυτοπροστατευτικά προϊόντα, τα οποία θα αξιολογηθούν για την ασφάλεια τους σε μη στόχους οργανισμούς. Τέλος, οι νέες τεχνολογίες θα ενσωματωθούν σε συστήματα ολοκληρωμένης διαχείρισης φυτοπροστασίας και θα δοκιμαστούν σε πραγματικές συνθήκες, ενώ θα αξιολογηθούν οι κοινωνικοοικονομικές και περιβαλλοντικές επιπτώσεις τους.

Σύνοψη της ΕΕ1

Σκοπός της ΕΕ1 του έργου είναι η ανάπτυξη διαγνωστικών εργαλείων και μεθόδων για την ανίχνευση, ταυτοποίηση και παρακολούθηση των εχθρών, των παθογόνων και των χαρακτηριστικών τους. Το αντικείμενο της υποενότητας εργασίας 1.4 («Τεχνητή νοημοσύνη για αναγνώριση ζιζανίων και ζώνες διαφοροποιημένης εφαρμογής ζιζανιοκτόνων») στην οποία ανήκει το παρόν παραδοτέο, αφορά την ανάπτυξη και αξιολόγηση διαφορετικών μοντέλων τεχνητής νοημοσύνης (συγκεκριμένα, βαθιάς μάθησης) για τον εντοπισμό ζιζανίων σε πραγματικές συνθήκες καλλιέργειας, με σκοπό τη δυνατότητα διαφοροποιημένης εφαρμογής ζιζανιοκτόνων στον αγρό. Το προτεινόμενο σύστημα αποτελεί ένα σύστημα αυτοματοποιημένης αναγνώρισης ζιζανίων με σκοπό την εφαρμογή εξειδικευμένης δόσης (Variable Rate Application) ζιζανιοκτόνου στα εντοπισμένα ζιζάνια, μέσω της δημιουργίας χαρτών ζιζανίων. Οι χάρτες αυτοί μπορούν να συμβάλλουν σημαντικά στην αποδοτικότερη λήψη αποφάσεων ως προς την εκλεκτικότητα και τη ποσότητα των ζιζανιοκτόνων που πρόκειται να χρησιμοποιηθούν σε μία καλλιέργεια.

Συνοπτική παρουσίαση του παραδοτέου Π1.4.1

Στο παρόν παραδοτέο προσδιορίζονται οι βασικές απαιτήσεις και προδιαγραφές ενός αυτοματοποιημένου συστήματος αναγνώρισης ζιζανίων με χρήση Συστημάτων μη Επανδρωμένων Αεροσκαφών (ΣμηΕΑ) σε πραγματικές συνθήκες καλλιέργειας, μέσω της ανάπτυξης ενός τέτοιου μοντέλου αναγνώρισης ζιζανίων βασισμένου σε σύγχρονες μεθόδους τεχνητής νοημοσύνης. Αφού αναλυθούν τα τεχνικά χαρακτηριστικά του και αξιολογηθεί σε πραγματικές συνθήκες καλλιέργειας,, χρησιμοποιείται για τη δημιουργία χαρτών ζιζανίων σε επιλεγμένους αγρούς, ώστε να αξιολογηθεί η δυνατότητα χρήσης του στη δημιουργία συστημάτων διαφοροποιημένης εφαρμογής ζιζανιοκτόνων στον αγρό.

Αρχικά γίνεται μία σύντομη βιβλιογραφική ανασκόπηση των υπαρχόντων σχετικών συστημάτων αυτοματοποιημένης αναγνώρισης ζιζανίων, με έμφαση σε αυτά που χρησιμοποιούν τεχνικές βαθιάς μάθησης, καθώς και αναφορά στα κυριότερα προβλήματα της αυτοματοποιημένης αναγνώρισης ζιζανίων μέσω μοντέλων βαθιάς μάθησης και στα προβλήματα σχετικά με την απαραίτητη επεξεργασία της εικόνας για την εκπαίδευση τέτοιου τύπου μοντέλων. Στη συνέχεια, παρουσιάζεται η ανάπτυξη της βάσης δεδομένων για την ανάπτυξη του μοντέλου αναγνώρισης ζιζανίων, ο τρόπος συλλογής των δεδομένων, οι τοποθεσίες συλλογής τους, η καλλιέργεια και τα ζιζάνια ενδιαφέροντος. Στη συνέχεια παρουσιάζεται ο τρόπος εκπαίδευσης των μοντέλων και τα αποτελέσματα που δόθηκαν από τα επιλεγμένα metrics (Precision, Recall, F1-score) για το κάθε είδος ζιζανίου, ενώ ακολουθεί η δοκιμή των μοντέλων και η επιλογή του μοντέλου με την υψηλότερη απόδοση, καθώς και η σύγκριση δύο επιλεγμένων μοντέλων με σκοπό τον ορισμό ακρίβειας του μοντέλου σε συνθήκες πραγματικού αγρού. Τέλος, παρουσιάζεται η μεθοδολογία δημιουργίας χαρτών ζιζανίων από τις εικόνες που λήφθηκαν μέσω ΣμηΕΑ και τις αντίστοιχες αναγνωρίσεις του τελικού μοντέλου, με τελικό σκοπό την εφαρμογή τους για πραγματοποίηση ψεκασμών με ακριβείς ποσότητες ζιζανιοκτόνου.

1 ΕΙΣΑΓΩΓΗ ΚΑΙ ΣΤΟΧΟΙ

Στόχος της συγκεκριμένης έρευνας είναι η ανάπτυξη, η αξιολόγηση και η λειτουργία πολλαπλών μοντέλων συνελικτικών νευρωνικών δικτύων (CNNs), κατά τα οποία θα επιλεγθεί το τελικό μοντέλο που έδωσε τα υψηλότερα ποσοστά αναγνώρισης. Έτσι, το επιλεγόμενο μοντέλο θα δημιουργεί μία ακριβή (ως προς την απόδοση εντοπισμού) και ταυτόχρονα επαρκή (ως προς την ποσότητα και ποιότητα της παρεχόμενης πληροφορίας) εικόνα ζιζανιοκάλυψης στον αγρό. Η χαρτογράφηση ζιζανίων μέσω επιλεγμένων μοντέλων θα μπορέσει να αποδώσει μία αντιπροσωπευτική κατάσταση ζιζανιοκάλυψης που επικρατεί ανά αγρό μέσω επιλεγμένων κατηγοριών χαρτών («κυριαρχίας», «σχετικής πυκνότητας» και «απόλυτης πυκνότητας»).

Ο σκοπός του παρόντος εγγράφου είναι ο προσδιορισμός των βασικών απαιτήσεων και προδιαγραφών ενός αυτοματοποιημένου συστήματος αναγνώρισης ζιζανίων με χρήση Συστημάτων μη Επανδρωμένων Αεροσκαφών (ΣμηΕΑ) σε πραγματικές συνθήκες καλλιέργειας, η ανάπτυξη ενός τέτοιου μοντέλου βασισμένου σε σύγχρονες μεθόδους τεχνητής νοημοσύνης, η ανάλυση των τεχνικών χαρακτηριστικών του και η αξιολόγησή του, και τέλος, η χρήση του για τη δημιουργία χαρτών ζιζανίων σε επιλεγμένους αγρούς, ώστε να αξιολογηθεί η δυνατότητα χρήσης του στη δημιουργία συστημάτων διαφοροποιημένης εφαρμογής ζιζανιοκτόνων στον αγρό.

Μεταξύ των δύο πιθανών καλλιεργειών που είχαν αρχικά προβλεφθεί (κηπευτικά ή εσπεριδοειδή) επιλέχθηκαν τα κηπευτικά και συγκεκριμένα η καλλιέργεια τομάτας. Από τους δύο τύπους ζιζανίων που είχαν αρχικά προβλεφθεί (ενός ωφέλιμου και ενός ανταγωνιστικού), συμπεριλήφθηκε μόνο ο δεύτερος (του ανταγωνιστικού) με τη συμπερίληψη τεσσάρων ειδών (όπως περιγράφεται αναλυτικά σε επόμενη ενότητα), αφού δεν εντοπίστηκε κάποιο είδος της πρώτης κατηγορίας στο φωτογραφικό υλικό που συλλέχθηκε. Τέλος, ως προς τον τύπο των εικόνων που λήφθηκαν για την ανάπτυξη και λειτουργία των μοντέλων αυτοματοποιημένης αναγνώρισης των ζιζανίων, χρησιμοποιήθηκαν κάμερες RGB τόσο στην περίπτωση της λήψης με στατική κάμερα όσο και σε αυτή της λήψης με ΣμηΕΑ (drone), που είναι και ο βασικός τρόπος χρήσης του προτεινόμενου συστήματος.

Το παραδοτέο εστιάζεται στη χρήση διαφορετικών τύπων μοντέλων βαθιάς μάθησης (Faster R-CNN, YOLOv8, YOLO11, Vision Transformer) για την αυτοματοποιημένη αναγνώριση ζιζανίων, εξετάζοντας τη χρήση διαφορετικών μεγεθών εικόνας (image size input), με σκοπό την εύρεση της καταλληλότερης μεθόδου που θα δώσει τα υψηλότερα αποτελέσματα αναγνώρισης. Ως προς τις εικόνες εισόδου των μοντέλων, μελετήθηκαν δύο τεχνικές: η πρώτη με τη διατήρηση της αρχικής ανάλυσης των εικόνων μέσω της προσθήκης πλαισίου (padding) όπου ήταν απαραίτητο, και η δεύτερη με την τμηματοποίηση των αρχικών εικόνων σε εικόνες μικρότερου μεγέθους (image-tiling).

Το παρόν έγγραφο **ακολουθεί την παρακάτω δομή:**

1. Εισαγωγή και Στόχοι: Παρουσιάζεται το πλαίσιο της έρευνας και οι στόχοι του εγγράφου.

2. Περιγραφή των Εργασιών: 2.1. Σύνομη βιβλιογραφική ανασκόπηση, 2.2. Βάση δεδομένων ανάπτυξης μοντέλων, 2.3. Εκπαίδευση μοντέλων, 2.4. Αξιολόγηση τελικών μοντέλων, 2.5. Δημιουργία χαρτών ζιζανίων, 2.6. Συζήτηση.

3. Σύνοψη και Συμπεράσματα: Βασικά ευρήματα της έρευνας και σχετικά συμπεράσματα.

4. Παράρτημα I: Βιβλιογραφικές αναφορές.

5. Παράρτημα II: Κώδικας βασικών προγραμμάτων.

2 ΠΕΡΙΓΡΑΦΗ ΤΩΝ ΕΡΓΑΣΙΩΝ

2.1 Σύντομη βιβλιογραφική ανασκόπηση

2.1.1 Χρήση μοντέλων βαθιάς μάθησης για τον αυτόματο εντοπισμό ζιζανίων

Η λήψη εικόνων ζιζανίων μπορεί να γίνει με διαφορετικά είδη καμερών και αισθητήρων, όπως είναι οι κάμερες RGB (Lameski et al., 2017; Barrero & Perdomo, 2018; Islam et al., 2020), οι πολυφασματικές (Kim et al., 2019; Osorio et al., 2020) και οι υπερφασματικές (Okamoto et al., 2004; Okamoto et al., 2007). Η λήψη των εικόνων μπορεί να γίνει με διαφορετικούς τρόπους, όπως είναι τα Συστήματα Μη-Επανδρωμένων Αεροσκαφών / ΣΜηΕΑ (Guo et al., 2020; Diez et al., 2021), αυτόνομα ρομπότ (Fawakherji et al., 2019), ψηφιακές κάμερες (Gao et al., 2020), κάμερες κινητών τηλεφώνων (Hennessy et al., 2022) και μικρά εναέρια οχήματα (Sa et al., 2017).

Η αυτοματοποιημένη ταξινόμηση ζιζανίων μπορεί να γίνει με χρήση μεθόδων μηχανικής μάθησης (machine learning - ML), και συγκεκριμένα με μοντέλα και τεχνικές βαθιάς μάθησης (deep learning - DL). Στον πιο γενικό τομέα της μηχανικής μάθησης, οι πιο διαδεδομένοι αλγόριθμοι που έχουν χρησιμοποιηθεί για την αναγνώριση ζιζανίων είναι το Random Forest/RF (π.χ., Fletcher, 2016; Alam et al., 2020), το Support Vector Machine/SVM (π.χ., Saha et al., 2016; Kiala et al., 2019), το Decision Tree Forward (π.χ., Kiala et al., 2019), το SVM-RBF (Radial Basis Function) (π.χ., Gée & Denimal, 2020), το K-Nearest Neighbors/KNN (π.χ., Khurana et al., 2019), και το Extremely Randomized Trees/ERT (π.χ., Lameski et al., 2017). Στον υποτομέα της βαθιάς μάθησης χρησιμοποιούνται κυρίως τα Συνελκτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks - CNNs), όπως είναι το AlexNet (Beeharry & Bassoo, 2020), το Inception-v3 (Teimouri et al., 2018), το DetectNet (Yu et al., 2019a), το VGGNet (Yu et al., 2019b), το Faster RCNN (Saleem et al., 2022), και το YOLO (Chen et al., 2022). Η βαθιά μάθηση αποτελεί σημαντικό κλάδο της μηχανικής μάθησης. Για τη ταξινόμηση εικόνων, εντοπισμού αντικειμένου και αναγνώρισης, οι DL αλγόριθμοι έχουν πολλά πλεονεκτήματα σε σχέση με τους ML (Hasan et al., 2021).

Η μεγαλύτερη πρόκληση για τη ταξινόμηση των φυτών είναι το πρόβλημα του “Fine grained visual classification” (FGVC), όπου ο σκοπός είναι η αναγνώριση υποκατηγοριών, όπως είναι οι κατηγορίες ζώων ή τα μοντέλα αυτοκινήτων. Η αναγνώριση του είδους των φυτών είναι μία αρκετά δύσκολη διαδικασία, γιατί έχουν σχετικά μικρές διαφορές μεταξύ τους (Di Cicco et al., 2017).

Η ικανοποιητική απόδοση των μοντέλων βαθιάς μάθησης, στην οποία συμπεριλαμβάνονται η ακριβής αναγνώριση αλλά και η ταχύτητα αναγνώρισης, είναι κρίσιμες παράμετροι για τη δυναμική τους χρήση σε πραγματικό χρόνο (real-time), αλλά και την αξιοπιστία του συστήματος για τη διάκριση φυτών με ζιζάνια, για την απομόνωση των ζιζανίων σε πληθυσμούς αλλά και στην ταξινόμησή τους (Su et al., 2021). Οι περισσότερες από τις ήδη υπάρχουσες μελέτες αφορούν είτε τη βελτίωση της απόδοσης αναγνώρισης είτε τη βελτιστοποίηση της ταχύτητας αναγνώρισης, με πολύ λιγότερες έρευνες να επικεντρώνονται και στα δύο προβλήματα ταυτόχρονα (Qu & Su, 2024).

Τα CNNs έχουν χρησιμοποιηθεί και για τον εντοπισμό ζιζανίων σε καλλιέργεια υπαίθριας τομάτας, πού όπως θα αναφερθεί αναλυτικά στη συνέχεια, αποτελεί την καλλιέργεια

στόχο της παρούσας εργασίας. Οι López-Correa et al. (2022), χρησιμοποίησαν το μοντέλο RetinaNet για τον αυτόματο εντοπισμό ζιζανίων σε καλλιέργεια τομάτας. Έπειτα από σύγκριση με άλλους τύπου μοντέλων, όπως είναι το YOLOv7 και το Faster-RCNN με εικόνες RGB μονοκοτυλήδων (*Cyperus rotundus* L., *Echinochloa crus galli* L., *Setaria verticillate* L.) και δικοτυλήδων (*Portulaca oleracea* L., *Solanum nigrum* L.) ζιζανίων, το μοντέλο έδωσε υψηλές αποδόσεις αναγνώρισης ζιζανίων, με Average Precision (AP) από 0.90 έως 0.97, ανάλογα με το είδος ζιζανίου. Η έρευνα των Kanvarriya et al. (2023) ασχολήθηκε με τη διερεύνηση δύο εκδοχών του αλγορίθμου YOLO (v5 και v7) για την αυτόματη αναγνώριση φυτών τομάτας και ζιζανίων. Το σύνολο δεδομένων που χρησιμοποίησαν περιείχε 200 εικόνες από τομάτες και 130 από ζιζάνια, οι οποίες, μετά από επεξεργασία, έδωσαν ένα σύνολο 736 εικόνων. Τα αποτελέσματα έδωσαν F1-score 98.89% για το YOLOv5 και 96.41% για το YOLOv7. Οι συγγραφείς επεσήμαναν ότι το YOLOv7 χρειάστηκε 10 φορές περισσότερο χρόνο για την ίδια αναγνώριση που πραγματοποίησε το YOLOv5¹. Οι Almalky & Ahmed (2023) χρησιμοποίησαν εικόνες από ΣμηΕΑ για να εντοπίσουν τα στάδια ανάπτυξης ενός είδους κονσολίδας (*Consolida regalis*) σε σύγκριση με τα μοντέλα YOLOv5, RetinaNet (Resnet-101-FPN και Resnet-50-FPN backbones) και Faster R-CNN (με Resnet-101-DC5, Resnet-101-FPN και Resnet-50-FPN backbones). Τα αποτελέσματα έδειξαν ότι το YOLOv5-small έδωσε το καλύτερο recall (0.794), το YOLOv5-large το καλύτερο precision αλλά μη εντοπίζοντας αρκετά ζιζάνια, το Resnet (Resnet-101-FPN) είχε το πιο υψηλό και ακριβές Precision (0.874), ενώ το Faster-RCNN (Resnet-101) σημείωσε precision 0.867.

Η αρχιτεκτονική μοντέλων YOLO έχει χρησιμοποιηθεί αρκετά για τη δημιουργία συστημάτων αυτοματοποιημένης αναγνώρισης ζιζανίων (Chen et al., 2022; Wang et al., 2022; Dang et al., 2023; Hu R. et al., 2024; Deng et al., 2025). Σύμφωνα και με την έρευνα των García-Navarrete et al. (2024), το YOLO είναι το πιο ευρέως χρησιμοποιούμενο μοντέλο για την αναγνώριση και ταξινόμηση ζιζανίων, από τα υπόλοιπα μοντέλα (VGG, ResNet, Faster R-CNN, AlexNet και MobileNet). Για παράδειγμα, οι Zhang et al. (2022) πρότειναν ένα μοντέλο μορφής YOLOv5x για την αναγνώριση ζιζανίων σε μαρούλι, με ακρίβεια αναγνώρισης 97.6%. Οι Chen et al. (2022) εφάρμοσαν ένα μοντέλο YOLO για τον εντοπισμό ζιζανίων σε καλλιέργεια σουσαμιού, με F1-score για το σουσάμι να είναι 0.91 και για τα ζιζάνια 0.92. Οι Wang et al. (2022) πρότειναν ένα αναβαθμισμένο μοντέλο YOLO_CBAM για την σε πραγματικό χρόνο αναγνώριση ενός είδους ζιζανίου (*Solanum rostratum*) με precision και recall 0.9465 και 0.9017, αντίστοιχα.

Το μοντέλο YOLOv8 έχει χρησιμοποιηθεί εκτενώς για την αυτοματοποιημένη αναγνώριση ζιζανίων σε βαμβάκι (Hu J. et al, 2024; Zheng et al., 2024), σε καλαμπόκι (Jia et al., 2024), σε μαρούλι (Chang-Tao et al., 2024), σε πατάτα (Goyal et al., 2025) και σε λάχανο (Sun et al., 2024). Έχει χρησιμοποιηθεί και σε καλλιέργεια τομάτας για τον εντοπισμό των σταδίων ωρίμανσης (Wang et al., 2024), για τη μέτρηση τομάτων σε συνθήκες θερμοκηπίου (Tian et al., 2024) και για τη τμηματοποίηση κάλυψης σε τομάτες μέσω θερμικής ανάπτυξης ("Thermal canopy segmentation", Hemamalini et al., 2025). Αντιθέτως, το YOLO11 έχει χρησιμοποιηθεί μέχρι στιγμής σε μία μόνο έρευνα για τον αυτόματο εντοπισμό 5 ζιζανίων (αγριομελιτζάνα "*Xanthium strumarium*", πικραλίδα "*Taraxacum officinale*", λουβουδιά "*Chenopodium album*", τραχύ βλήτο "*Amaranthus palmeri*" και ακόμα ένα είδος βλήτου, "*Amaranthus rudis*") από τους Sharma et al. (2024), οι οποίοι συγκρίναν την απόδοση σε 4 μορφές του YOLO (v8, v9, v10 και 11). Τα αποτελέσματα έδειξαν ότι το YOLO11 έδωσε τα πιο γρήγορα αποτελέσματα (13.5 ms), ενώ το YOLOv9 ήταν το πιο ακριβές στην αναγνώριση, με

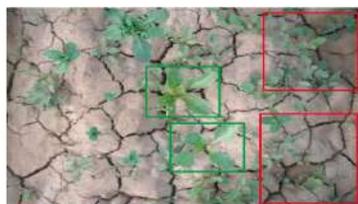
¹ Οι ακριβείς ορισμοί των διαφόρων δεικτών απόδοσης (metrics) δίνονται στην υποενότητα 2.3.

mAP50 στο 0.935.

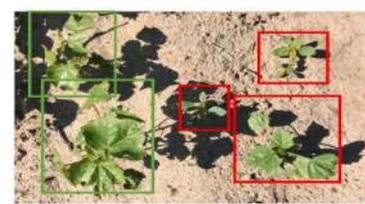
Για τον σχεδιασμό ενός αυτοματοποιημένου συστήματος αναγνώρισης ζιζανίων, είναι πολύ σημαντικό το σύστημα να εντοπίζει και να αναγνωρίζει τα ζιζάνια σωστά (Liu & Bruch, 2020). Ο εντοπισμός ζιζανίων είναι αρκετά απαιτητική διαδικασία, καθώς τα φυτά με τα ζιζάνια έχουν συχνά παρόμοια χρώματα, υφές και σχήματα (Hasan et al., 2021). Οι πιο σημαντικές προκλήσεις στην επιτυχή αναγνώριση ζιζανίων, όπως φαίνεται και παρακάτω (Εικόνα 1.4.1-1), περιλαμβάνουν την αλληλοεπικάλυψη ζιζανίου-φυτού (a), την ομοιότητα σε χρώματα και υφές λόγω συνθηκών φωτισμού (b), τις σκιές σε φυσικό φωτισμό (c), την ποικιλότητα χρωμάτων και υφών εξαιτίας συνθηκών φωτισμού και αντικατοπτρισμού (d), την ομοιότητα διαφορετικών ειδών ζιζανίων (e), τις ανομοιομορφίες ζιζανίων σε διαφορετικά στάδια ανάπτυξης (f), τον θόρυβο (noise) ή τις θολές εικόνες λήψης (g), αλλά και τον διαφορετικό βαθμό ανάπτυξης των ίδιων ζιζανίων ανά περιοχές (h). Όλα αυτά τα προβλήματα δυσκολεύουν την αυτοματοποιημένη αναγνώριση ζιζανίων.



(a) Occlusion of crop and weed (Haug & Ostermann, 2014)



(b) Colour and texture similarities between crop and weed plants (Bakhshipour & Jafari, 2018)



(c) Shadow effects in natural weed image (PyTorch, 2020)



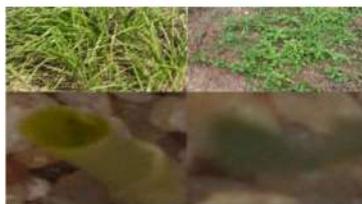
(d) Effects of illumination conditions (Di Cicco et al., 2017)



(e) Four different species of weeds that share similarities (inter-class similarity) (Olsen et al., 2019)



(f) Sugar beet crop at different growth stages (intra-class variations) (Giselsson et al., 2017)



(g) Effects of motion blur and noise (Ahmad et al., 2018; Giselsson et al., 2017)



(h) Weeds can vary at different geographic/weather locations: weed in carrot crop collected from Germany (left) (Haug & Ostermann, 2014) and Macedonia (Right) (Lameski et al., 2017)

Εικόνα 1.4.1-1: Διαφορετικές περιπτώσεις επισήμανσης ζιζανίων, στις οποίες διακρίνονται χαρακτηριστικά τα εξής προβλήματα: (a) Αλληλοεπικάλυψη ζιζανίου-φυτού (Haug & Ostermann, 2014), (b) Ομοιότητες χρώματος και υφής σε ζιζάνιο-φυτό (Bakhshipour & Jafari, 2018), (c) Σκιάσεις (PyTorch, 2020), (d) Διαφορετική φωτεινότητα (Di Cicco et al., 2017), (e) Ομοιότητες μεταξύ διαφορετικών ζιζανίων (Olsen et al., 2019), (f) Ποικιλομορφία στα στάδια ωρίμανσης (Giselsson et al., 2017), (g) Αδυναμία ευκρίνειας (Giselsson et al., 2017; Ahmad et al., 2018), (h) Διαφορετική ανάπτυξη ζιζανίων ανάλογα με τη περιοχή ωρίμανσης (Haug & Ostermann, 2014; Lameski et al., 2017). (Πηγή: Hasan et al., 2021).

Μία σχετικά καινούργια προσέγγιση για τον αυτοματοποιημένο εντοπισμό ζιζανίων είναι τα μοντέλα τύπου transformer, τα οποία έχουν χρησιμοποιηθεί με επιτυχία, προσφέροντας σημαντικά πλεονεκτήματα σε σύγκριση με τις παραδοσιακές τεχνικές βαθιάς μάθησης. Τα μοντέλα τύπου Vision Transformer (ViT), SegFormer και DETR μπορούν να αναγνωρίσουν και να ταξινομήσουν ζιζάνια κάτω από δύσκολες συνθήκες πεδίου με σύνθετο υπόβαθρο. Οι τεχνικές αυτές έχουν δείξει ικανοποιητική ακρίβεια, τόσο στην ταξινόμηση όσο και στον εντοπισμό ζιζανίων, ενισχύοντας την αποτελεσματικότητα των συστημάτων ευφυούς γεωργίας (Jiang et al., 2022; Alaoui & Mousannif, 2025; Saleh et al., 2025). Επιπλέον, τα transformer τύπου DETR (π.χ. εκδοχές V2, PHRF) και SWIN έχουν επιτύχει αρκετά υψηλά αποτελέσματα (Jiang et al., 2022; Gómez et al., 2025; Jin et al., 2025).

2.1.2 Μέθοδοι προ-επεξεργασίας εικόνων για την εκπαίδευση μοντέλων

Σύμφωνα με τους Hou et al. (2016), η εκπαίδευση ενός μοντέλου CNN με εικόνες υψηλής ανάλυσης είναι υπολογιστικά χρονοβόρα και ακριβή. Επιπλέον, η έρευνα των Hasan et al. (2023) επισήμανε ως πρόβλημα για την εκπαίδευση των μοντέλων βαθιάς μάθησης την ανεπαρκεία διαθεσιμότητας μεγάλων βάσεων δεδομένων, αλλά και την ανισορροπία κλάσεων, είτε υψηλής ανομοιότητας (intra-class dissimilarity), είτε υψηλής ομοιότητας (inter-class similarity). Η έρευνα των Gée & Denimal (2020) χρησιμοποίησε το SVM με RBF για τη ταξινόμηση πλατύφυλλων ζιζανίων από εικόνες ΣμηΕΑ με ακρίβεια 93% αλλά επισήμαναν ως περιορισμό το ανομοιομορφοποιημένο σύνολο δεδομένων που χρησιμοποίησαν. Οι Jonak et al. (2024) επισήμαναν το πρόβλημα του θορύβου (noise) στις περιπτώσεις που υπάρχει ανομοιομορφία στις εμφανίσεις των ζιζανίων για την εκπαίδευση μοντέλων βαθιάς μάθησης.

Επομένως είναι απαραίτητη η επιλογή μεθόδων για την προ-επεξεργασία των εικόνων στην εκπαίδευση των μοντέλων, έτσι ώστε να μην δημιουργούνται προβλήματα μνήμης ή και υπολογιστικού κόστους. Μάλιστα, η πλειοψηφία των ερευνών σχετικά με τη χρήση των μοντέλων βαθιάς μάθησης για τον αυτοματοποιημένο εντοπισμό ζιζανίων χρησιμοποιεί κάποιου είδους προ-επεξεργασία των εικόνων, με σκοπό να βοηθήσει τη συγκεκριμένη αρχιτεκτονική και να εξάγει πιο εύκολα τα σημεία ενδιαφέροντος (Hasan et al., 2021). Οι εικόνες με υψηλή ανάλυση χωρίζονται κάποιες φορές σε συγκεκριμένο αριθμό τμημάτων (patches) για να μειωθεί η υπολογιστική πολυπλοκότητα (Hasan et al., 2021). Για παράδειγμα, η έρευνα των Rasti et al. (2019) χώρισε τις εικόνες ανάλυσης 5120 x 3840 σε 56 κομμάτια. Οι Yu et al. (2019) χαμήλωσαν τις εικόνες του συνόλου δεδομένων που χρησιμοποίησαν στα 1224 x 1024 pixel, για να παραμείνουν οι απαιτήσεις της εκπαίδευσης των μοντέλων χαμηλές σε μνήμη.

Οι πιο ευρέως χρησιμοποιούμενες τεχνικές προ-επεξεργασίας εικόνων για την είσοδό τους στα μοντέλα αυτοματοποιημένου εντοπισμού ζιζανίων είναι το resizing (π.χ., Zhang, 2023; Genze et al., 2024) και το tiling (π.χ., Shahi et al., 2023; Sandoval-Pillajo et al., 2025). Το resizing, δηλαδή η αλλαγή (συνήθως μείωση) του μεγέθους των εικόνων, είναι η πιο απλή μέθοδος που μπορεί να χρησιμοποιηθεί αλλά κρύβει "κινδύνους", καθώς μπορεί να χάσει αρκετούς εντοπισμούς μικρών αντικειμένων σε μεγάλες εικόνες (Hallström et al., 2025). Ανάλογα με την αρχική αναλογία διαστάσεων μήκους/ύψους των διαθέσιμων εικόνων και της αντίστοιχης αναλογίας που απαιτεί το

εκάστοτε μοντέλο για τις εικόνες εισόδου του, υπάρχει περίπτωση να απαιτηθεί η διαδικασία του padding (π.χ., Shahi et al., 2023), εάν είναι επιθυμητή η διατήρηση της αρχικής αναλογίας των εικόνων. Το padding προσθέτει έξτρα pixel στη συνολική εικόνα ώστε να επιτευχθεί το επιθυμητό μέγεθος εισόδου. Η μέθοδος αυτή χρησιμοποιείται αρκετά, αλλά μπορεί να επιφέρει σφάλματα, καθώς το μοντέλο εκπαιδεύεται και στα "κενά" pixel, κάτι που μπορεί να οδηγήσει σε λανθασμένα αποτελέσματα. Από την άλλη πλευρά, το tiling διατηρεί την αναλογία των αντικειμένων σε σχέση με το μέγεθός τους αφού η αρχική εικόνα μεγάλης ανάλυσης κόβεται σε μικρότερα τμήματα (tiles). Σημαντικό μειονέκτημα της μεθόδου αυτής είναι ότι "χάνει" το γενικό πλαίσιο (global context) της εικόνας, καθώς τα μικρότερα κομμάτια δεν αντιπροσωπεύουν τη συνολική εικόνα και ενδεχομένως να χάνονται σημαντικές σχέσεις - παρουσιάσεις των ζιζανίων σε σχέση με, π.χ., τα καλλιεργούμενα φυτά.

Στη παρούσα εργασία μελετήθηκαν και οι δύο τρόποι προ-επεξεργασίας των εικόνων, το resizing (με padding) και το tiling. Μαζί με την επιλογή του τελικού μοντέλου, σκοπός ήταν να διερευνηθεί ποια από αυτές τις μεθόδους έδωσε τα υψηλότερα αποτελέσματα εντοπισμού και αναγνώρισης.

2.2 Βάση δεδομένων ανάπτυξης μοντέλων

Η βάση δεδομένων για την ανάπτυξη των μοντέλων βασίστηκε σε εικόνες που λήφθηκαν σε καλλιέργειες τομάτας στη Θήβα, στην Αλιάρτο και στο πειραματικό αγρό του Μπενακείου Φυτοπαθολογικού Ινστιτούτου (ΜΦΙ), με εικόνες RGB που λήφθηκαν μέσω στατικής κάμερας ύψους 3μ. και μέσω ΣμηΕΑ σε ύψη πτήσης 3-10 μέτρων. Τα είδη ζιζανίων ενδιαφέροντος προσδιορίστηκαν βάσει της υπάρχουσας βιοποικιλότητας κατά την έναρξη των πειραμάτων. Στο φωτογραφικό υλικό που συλλέχθηκε δεν βρέθηκε κάποιο ωφέλιμο ζιζάνιο, οπότε δόθηκε έμφαση μόνο σε ανταγωνιστικά.

2.2.1 Συλλογή δεδομένων

Τα δεδομένα συλλέχθηκαν από 6 διαφορετικές περιοχές και συγκεκριμένα από 2 καλλιεργούμενες εκτάσεις στην Αλιάρτο Θήβας (Εικόνα 1.4.1-2 ii, αγροτεμάχια 1 και 2), 1 καλλιεργούμενη έκταση στο Μουρίκι Θήβας (εικόνα ii, αγροτεμάχιο 3), 2 εκτάσεις στο Νεοχωράκι Θήβας (εικόνα ii, αγροτεμάχια 4 και 5) και από τον πειραματικό αγρό με τα επιλεγμένα ζιζάνια στο εργαστήριο ζιζανιολογίας του ΜΦΙ διαστάσεων 8 x 1μ. (εικόνα ii, αγροτεμάχιο 6).



Εικόνα 1.4.1-2: Απεικόνιση των σημείων λήψης δεδομένων στον χάρτη σε i) απομακρυσμένη όψη και ii) κοντινότερη όψη.

Τα δεδομένα συλλέχθηκαν μέσω δύο μεθόδων λήψης: α) από κάμερα RGB εξοπλισμένη σε ΣμηΕΑ (drone: DJI Mini 4 Pro, κάμερα: 48 MPixel, 1/1.3-inch CMOS), και β) από κάμερα κινητού τηλεφώνου (μοντέλο Samsung Galaxy A54 με κάμερα τριπλών φακών, τύπου Macro 5MP, Ευρυγώνιου 50MP και υπερευρυγώνιου 12MP, αντιστοίχως). Το ύψος λήψης για τις εικόνες που λήφθηκαν μέσω ΣμηΕΑ ήταν από 3 μέτρα έως 10 μέτρα, ενώ η κάμερα κινητού τηλεφώνου ήταν τοποθετημένη σε ύψος 3 μέτρων. Οι εικόνες που λήφθηκαν ήταν διαφόρων αναλύσεων (4080x3060, 4032x2268 και 3840x2160).

2.2.2 Καλλιέργεια και είδη ζιζανίων ενδιαφέροντος

Με βάση τις υπάρχουσες δυνατότητες και τους ερευνητικούς στόχους του έργου, επιλέχθηκε η καλλιέργεια τομάτας για την ανάπτυξη και αξιολόγηση των μοντέλων αυτοματοποιημένης αναγνώρισης ζιζανίων. Με βάση τη συγκεκριμένη καλλιέργεια ενδιαφέροντος, επιλέχθηκαν τα ακόλουθα 4 είδη ζιζανίων που αποτελούν τα "ζιζάνια ενδιαφέροντος" του συστήματος, δηλαδή αυτά τα οποία θα αναγνωρίζει το τελικό μοντέλο αυτοματοποιημένης αναγνώρισης και εντοπισμού ζιζανίων:

Βλίτο, *Amaranthus retroflexus* (Liliopsida, Poaceae)

Είναι μονοετές, ανοιξιάτικο ζιζάνιο και φυτρώνει νωρίς την άνοιξη έως και καλοκαίρι, σχεδόν σε όλες τις καλλιέργειες. Το βλίτο είναι πολύ διαδεδομένο ζιζάνιο στις ανοιξιάτικες καλλιέργειες και το δεύτερο σε σπουδαιότητα ζιζάνιο στην Ελλάδα, μετά από την αγριάδα. Αναπτύσσει πυκνούς πληθυσμούς και έχει στενόμακρες, έμμισχες, κοκκινωπές στη κάτω επιφάνεια κοτυληδόνες. Ο βλαστός είναι όρθιος, ύψους συνήθως 50-90cm, απλός ή συνηθέστερα διακλαδισμένος, χωρίς τρίχες στο κάτω μέρος, τραχύς με τρίχες στο πάνω μέρος, πρασινωπός - ελαφρά κοκκινωπός επάνω (γραμμώσεις), συνήθως κόκκινος στο κάτω μέρος (βάση). Τα φύλλα είναι εναλλάξ, απλά, λογχοειδή-

ωοειδή και με περιφέρεια ελαφρά οδοντωτή, ανοιχτοπράσινη και στη κάτω επιφάνεια έχει βελούδινη υφή. Τα άνθη είναι πρασινωπά, αφανή σε πυκνό-συμπαγή στάχυ, βρίσκονται στη κορυφή του βλαστού και ο καρπός είναι σχεδόν σφαιρικού σχήματος, με ανώμαλη τραχιά επιφάνεια. Ο σπόρος είναι στρογγυλός-φακοειδής, μικρός, μαύρος-καφέ, γυαλιστερός και βάρους 0,4 mg. Πολλαπλασιάζεται με σπόρους, οι οποίοι εμφανίζουν κλιμακωτό φύτρωμα και η ταξιανθία είναι σταχειοειδής, πυκνή και συμπαγής.

Λουβουδιά, *Chenopodium album* (Liliopsida, Chenopodiaceae)

Η λουβουδιά φυτρώνει νωρίς την άνοιξη έως και καλοκαίρι, σε χαμηλότερες θερμοκρασίες από το βλήτο. Προτιμά εδάφη πλούσια σε άζωτο και χούμο, αμμώδη ή πηλώδη. Πολλαπλασιάζεται με σπόρο (3 έως 20 χιλ./φυτό) και παρουσιάζει μεγάλη ποικιλομορφία στο σχήμα των φύλλων και στο χρωματισμό φύλλων και βλαστών. Έχει στενόμακρες - ωοειδείς κοτυληδόνες, οι οποίες είναι σαρκώδεις με μικρό μίσχο αλευρώδους επιχρίσματος στη πάνω επιφάνεια και κοκκινωπό-βιολετί χρώμα στη κάτω. Ο βλαστός είναι ύψος 20-200 cm, όρθιος, διακλαδισμένος (μπορεί και να μην είναι), λείος, πράσινος με κοκκινωπές ή πορφυρές κατά μήκος γραμμώσεις και αυλακώσεις. Τα φύλλα διαφέρουν στο σχήμα, είναι εναλλάξ, απλά, έμμισχα, τριγωνικά μέχρι λογχοειδή (τα πάνω) με περιφέρεια οδοντωτή, λεία ή κυμματοειδή, με αλευρώδες επίχρισμα στη πάνω και κάτω επιφάνεια, ενώ στα μικρά φυτά και σε ορισμένες περιπτώσεις στα μεγάλα, η κάτω επιφάνεια είναι κοκκινωπή. Το άνθος είναι πολύ μικρό, πρασινωπό, σε σωρούς στις μασχάλες των πάνω φύλλων και ο καρπός είναι κάψα με πολύ λεπτή μεμβράνη, πολύ μικρού μεγέθους (1-1,5 mm). Ο σπόρος είναι σχήματος φακού-δίσκου, με βαθούλωμα στην άκρη, χρώματος μαύρου ή καφέ και με λεία επιφάνεια ή δικτυωτή. Πολλαπλασιάζεται με σπόρους, οι οποίοι διατηρούν τη βιωσιμότητά τους στο έδαφος για πολλά χρόνια. Δεν διασπείρονται με τον άνεμο και απαιτούν υψηλή θερμοκρασία για να φυτρώσουν.

Κύπερη, *Cyperus esculentus* (Liliopsida, Cyperaceae)

Είναι πολυετές μονοκοτυλήδονο και αναπτύσσεται σε αμμώδεις, παράκτιες, καλλιεργούμενες ή χέρσες τοποθεσίες. Ο βλαστός είναι χαρακτηριστικός στο σχήμα (τριγωνικός) γεμάτος και χωρίς γόνατα. Τα φύλλα είναι πολλά μαζί στη βάση, βαθυπράσινα στο χρώμα, σχετικά στενά. Το άνθος είναι πολυανθή σταχύδια, ταξιανθίας σύνθετου σκιαδίου. Ο καρπός είναι αχάινιο, μικρός, ο σπόρος μικρός (χρώμα όπως ο καρπός) και οι ρίζες και τα ριζώματα είναι λεπτά, με κίτρινες διογκώσεις οι οποίες είναι ωοειδείς ή σφαιρικές, μεγέθους φουντουκιού. Πολλαπλασιάζεται κύρια με κονδύλους και σπανιότερα με σπόρο.

Αντράκλα, *Portulaca oleracea* (Magnoliopsida, Portulacaceae)

Είναι μονοετές ανοιξιότιμο και πολλαπλασιάζεται με σπόρο (μέχρι 50.000/φυτό) που φυτρώνει αργά άνοιξη - νωρίς καλοκαίρι. Οι κοτυληδόνες είναι επιμήκειες - ωοειδείς, σαρκώδεις, κοκκινωπές στη κάτω επιφάνεια και ο βλαστός είναι στην αρχή όρθιος, μετά πλαγιαστός - έρπων, σαρκώδης κοκκινωπός, γυαλιστερός, διακλαδιζόμενος που σχηματίζει κύκλους. Εκτός από τα πρώτα και τα τελευταία στη κορυφή όλα τα άλλα εναλλάξ, απλά, άμμισχα, χοντρά, σαρκώδη, βαθυπράσινα ή κοκκινωπά - πράσινα, φαρδύτερα στη κορυφή από ότι στη βάση, άτριχα. Το άνθος είναι μικρό και βρίσκεται στις μασχάλες των φύλλων και είναι κίτρινα, ένα-ένα ή 2-3 μαζί. Ο καρπός είναι κάψα, σφαιρικού σχήματος, μήκους 4-9mm.

2.2.3 Δημιουργία βάσης δεδομένων

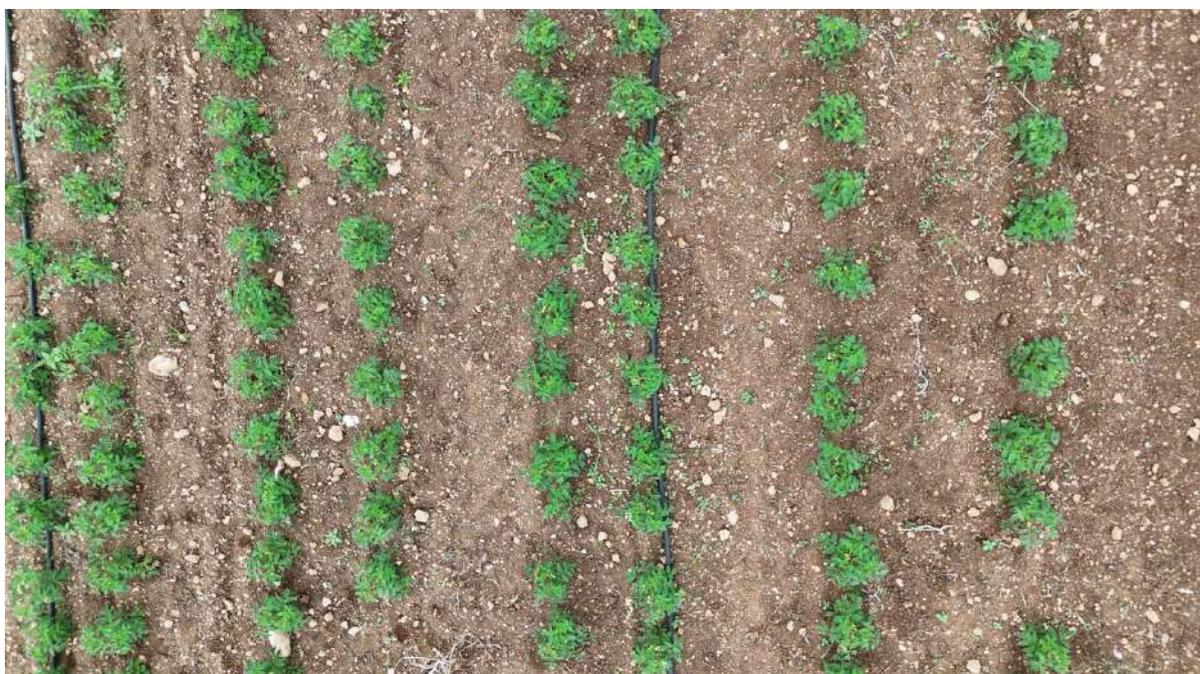
2.2.3.1 Πρώτη βάση δεδομένων

Η πρώτη βάση δεδομένων δημιουργήθηκε από εικόνες RGB που λήφθηκαν μέσω ΣμηΕΑ και μέσω κάμερας κινητού τηλεφώνου, σε ύψος 3-10 μέτρων και 3 μέτρων, αντίστοιχα. Το ΣμηΕΑ κατέγραψε με βίντεο στις επιλεγμένες εκτάσεις καλλιέργειας τομάτας που περιγράφηκαν παραπάνω. Από τα βίντεο αυτά πραγματοποιήθηκε εξαγωγή εικόνων, με επιλογή συγκεκριμένων καρτέ (frames) μέσω της χρήσης κατάλληλου προγράμματος (script) που αναπτύχθηκε στη γλώσσα προγραμματισμού Python. Το αρχικό πλήθος των εικόνων που λήφθηκε ήταν 2662, αλλά μετά από ειδικό χειρισμό και περαιτέρω επιλογή των δεδομένων, το τελικό σύνολο περιείχε 1064 εικόνες. Οι αναλύσεις των εικόνων ήταν ποικίλες, με διαστάσεις 4080x3060, 4032x2268 και 3840x2160 pixels. Η δημιουργία ετικετών για το κάθε ζιζάνιο (annotation) πραγματοποιήθηκε με το πρόγραμμα LabelImg² και η βάση δεδομένων χωρίστηκε σε δεδομένα για την εκπαίδευση (training set), για την επαλήθευση κατά τη διάρκεια της εκπαίδευσης (validation set), και για τη δοκιμή (test set), σε αναλογίες 70/10/20 αντίστοιχα, δηλαδή 744 εικόνες για το training, 106 για το validation και 214 για το test. Οι εικόνες που λήφθηκαν, εκτός από τα διαφορετικά ύψη λήψης, περιείχαν επίσης διαφορετικές συνθήκες φωτισμού και σύνθεσης εδάφους, όπως φαίνεται και στα παρακάτω παραδείγματα (Εικόνες 1.4.1-3, 1.4.1-4, 1.4.1-5).

² <https://github.com/HumanSignal/labelimg>



Εικόνα 1.4.1-3: Εικόνα λήψης από ΣμηΕΑ σε ύψος 6 μέτρων χωρίς επεξεργασία φωτισμού.



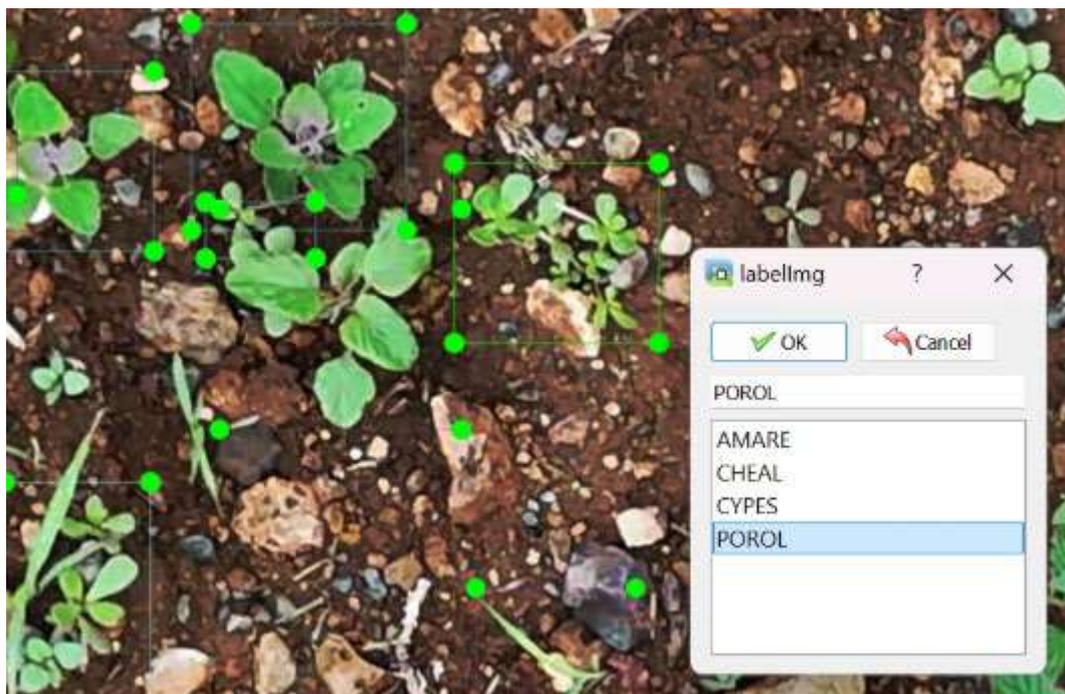
Εικόνα 1.4.1-4: Εικόνα λήψης από ΣμηΕΑ σε ύψος 8 μέτρων χωρίς επεξεργασία φωτισμού.



Εικόνα 1.4.1-5: Λήψη από στατική κάμερα κινητού τηλεφώνου στα 3 μέτρα, σε διαφορετικές συνθήκες εδάφους από τις λήψεις ΣμηΕΑ χωρίς επεξεργασία φωτισμού.

Παρακάτω φαίνονται κάποια παραδείγματα δημιουργίας ετικετών μέσω του προγράμματος LabelImg, από εικόνες λήψης ΣμηΕΑ (Εικόνες 1.4.1-6, 1.4.1-7) και κάμερας κινητού τηλεφώνου (Εικόνες 1.4.1-5 και 1.4.1-8). Τα ονόματα των ετικετών αντιστοιχούν στα ακρωνύμια του κάθε ζιζανίου ενδιαφέροντος σύμφωνα με τη βάση δεδομένων EPPO - European and Mediterranean Plant Protection Organization (EPPO, 2025): "AMARE" για το βλίτο, "CHEAL" για τη λουβουδιά, "CYPES" για την κύπερη και "POROL" για την αντράκλα.

Τα instances (ξεχωριστές εμφανίσεις του κάθε ζιζανίου) που παράχθηκαν έδειξαν ότι η κύπερη ήταν το κυρίαρχο ζιζάνιο με σχεδόν 7000 εμφανίσεις στο σύνολο των εικόνων που χρησιμοποιήθηκε για την εκπαίδευση (training & validation sets), η αντράκλα είχε περίπου 2000 εμφανίσεις, η λουβουδιά περίπου 1100 και το βλίτο σχεδόν 850 (Εικόνα 1.4.1-9).



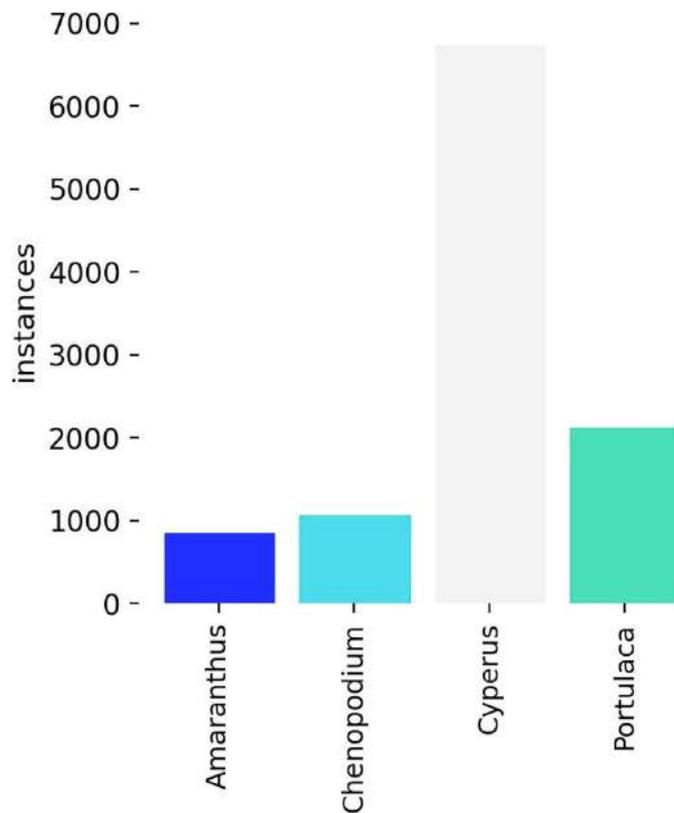
Εικόνα 1.4.1-6: Δημιουργία ετικέτας "POROL" σε μεγεθυμένη εικόνα λήψης ΣμηΕΑ με επεξεργασία του φωτισμού.



Εικόνα 1.4.1-7: Λήψη εικόνας ΣμηΕΑ διαφορετικού ύψους με πολλαπλές ετικέτες ζιζανίων με επεξεργασία φωτισμού.



Εικόνα 1.4.1-8: Δημιουργία ετικετών σε εικόνα λήψης κινητού τηλεφώνου, με εμφανείς διαφορετικές συνθήκες εδάφους από τις προηγούμενες λήψεις και με επεξεργασία φωτισμού.

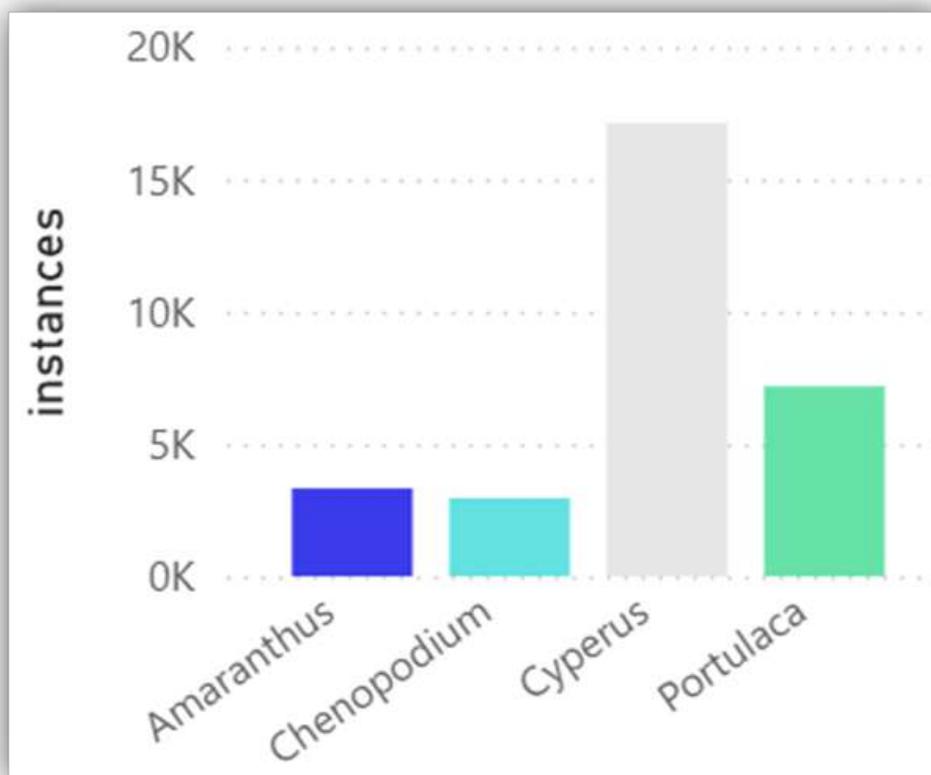


Εικόνα 1.4.1-9: Πλήθος εμφανίσεων της κάθε κατηγορίας (instances) στη πρώτη βάση δεδομένων.

2.2.3.2 Δεύτερη βάση δεδομένων

Ο δεύτερος τρόπος ανάπτυξης της βάσης δεδομένων πραγματοποιήθηκε με την τεχνική image tiling, δηλαδή, όπως προαναφέρθηκε, οι εικόνες από το αρχικό σύνολο δεδομένων με διαφορετικές αναλύσεις (4080x3060, 4032x2268 και 3840x2160 pixels) “κόπηκαν” σε μικρότερα κομμάτια (640x640 pixels), με τις αντίστοιχες ετικέτες των ζιζανίων τους (Παράρτημα ΙΙ - Πρόγραμμα 1). Έτσι, η δεύτερη βάση δεδομένων που δημιουργήθηκε ήταν αρκετά μεγαλύτερη, με περίπου 17.500 εικόνες. Για τη δεύτερη βάση δεδομένων, οι εικόνες χωρίστηκαν πάλι σε αναλογία 70/10/20 (training/validation/testing), δηλαδή 12.290, 1755 και 3513, αντίστοιχα.

Και η δεύτερη βάση δεδομένων παρουσίασε αρκετά μεγάλο πρόβλημα στην ανισορροπία κλάσεων (Εικόνα 1.4.1-10), με την κύπερη πάλι να είναι η περισσότερο εμφανιζόμενη (περίπου 17000 instances), η αντράκλα περίπου στις 7000, το βλίτο στις 4000 και η λουβουδιά στις 3000. Η συνολική αύξηση των εμφανίσεων των ζιζανίων σε σχέση με την αρχική βάση δεδομένων οφείλεται κυρίως στον τρόπο τμηματοποίησης των εικόνων (tiling), ο οποίος περιείχε κάποιο ποσοστό επικάλυψης ώστε να χαθεί όσο το δυνατό μικρότερος αριθμός ζιζανίων στα σημεία τμηματοποίησης.



Εικόνα 1.4.1-10: Πλήθος εμφανίσεων της κάθε κατηγορίας (instances) στη δεύτερη βάση δεδομένων.

2.3 Εκπαίδευση μοντέλων

Τα μοντέλα που αναπτύχθηκαν και αξιολογήθηκαν στην πρώτη εκπαίδευση (με ολόκληρες εικόνες) περιείχαν αρχιτεκτονικές των μοντέλων αναγνώρισης αντικειμένων YOLOv8 (Jocher et al., 2023) και YOLO11 (Jocher & Qiu, 2024), ενώ η δεύτερη προσπάθεια εκπαίδευσης (με τμήματα εικόνων) έγινε με μοντέλα Faster R-CNN (Ren et al., 2015), Vision Transformers (Vaswani et al., 2017) και YOLO11.

Οι δείκτες αξιολόγησης (metrics) που χρησιμοποιήθηκαν είναι οι εξής:

- Precision:

$$P = \frac{TP}{TP + FP}$$

- Recall:

$$R = \frac{TP}{TP + FN}$$

όπου:

TP: true positive (σωστός εντοπισμός και αναγνώριση ζιζανίου)

FP: false positive (λανθασμένος εντοπισμός ή/και αναγνώριση ζιζανίου)

FN: false negative (μη εντοπισμός ζιζανίου)

- mAP (mean average precision) και συγκεκριμένα mAP_{50} :

Το average precision (*AP*) για την κάθε κλάση (δηλ., για το κάθε ζιζάνιο προς αναγνώριση) είναι το εμβαδόν της καμπύλης precision-recall για το συγκεκριμένο ζιζάνιο:

$$AP = \int_0^1 p(r) dr$$

και το mAP δίνεται από τον μέσο όρο αυτών των *AP* για το σύνολο των ζιζανίων:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

όπου $N=4$.

Στη συγκεκριμένη εφαρμογή χρησιμοποιείται το mAP_{50} δηλαδή το mAP με όριο του intersection over union (IoU) στο 50%.

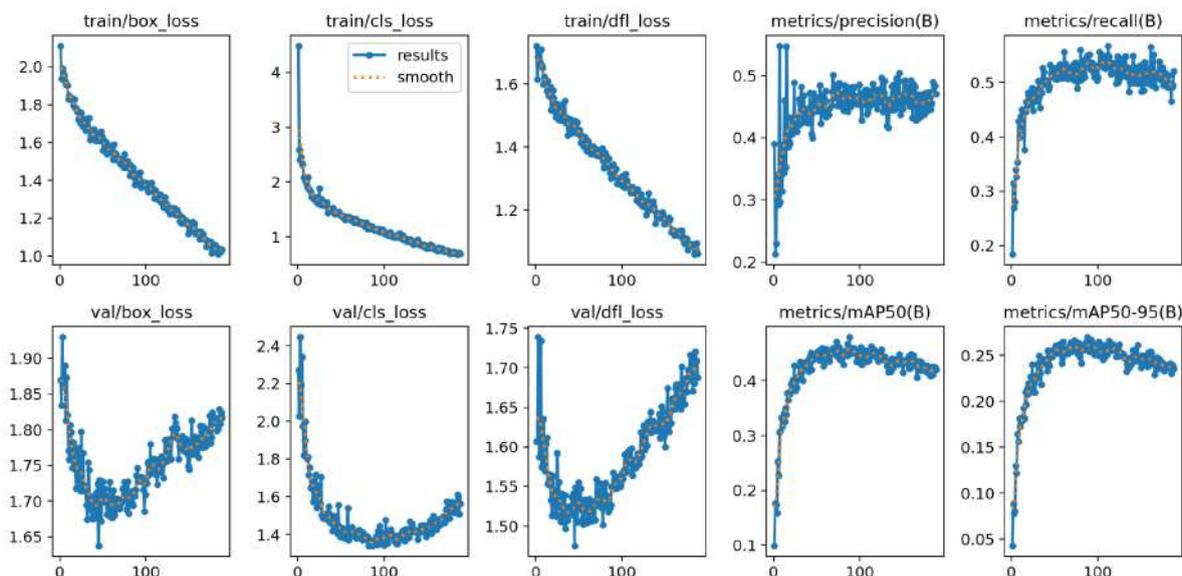
- F_1 score:

$$F_1 = 2 \frac{P \cdot R}{P + R}$$

2.3.1 Πρώτη εκπαίδευση μοντέλων - Ολόκληρες εικόνες εισόδου

Κατά την πρώτη εκπαίδευση των μοντέλων δοκιμάστηκαν διαφορετικές αναλύσεις εικόνων εισόδου (από 640x640 έως 3840x3840) και διαφορετικά μεγέθη batch (από 2 έως 16, αντιστρόφως ανάλογα της ανάλυσης των εικόνων εισόδου ώστε να είναι διαχειρίσιμα με βάση τη διαθέσιμη μνήμη των καρτών γραφικών (GPU) που χρησιμοποιήθηκαν για την εκπαίδευση των μοντέλων). Ο μέγιστος αριθμός επαναλήψεων (epochs) ορίστηκε στις 300, με όριο πρόωρου τερματισμού το 100 (δηλαδή, η διαδικασία της εκπαίδευσης τερματίζεται όταν για 100 συνεχόμενες επαναλήψεις δεν υπάρξει βελτίωση της απόδοσης στο validation set). Ο αλγόριθμος βελτιστοποίησης που επιλέχθηκε ήταν ο stochastic gradient descent (SGD), με τις προεπιλεγμένες τιμές για τις βασικές του παραμέτρους: αρχικό και τελικό learning rate 0.01 και 0.0001, αντίστοιχα, και momentum ίσο με 0.937. Στον Πίνακα 1.4.1-1 φαίνονται κάποιοι βασικοί πειραματισμοί ως προς τις διαφορετικές αρχιτεκτονικές του μοντέλου YOLO11 και τις διαφορετικές αναλύσεις εικόνων εισόδου, ανάλογα με τις δυνατότητες της διαθέσιμης υπολογιστικής ισχύος, κυρίως ως προς τη μνήμη των GPU (χρησιμοποιήθηκε ένας υπολογιστής με επεξεργαστή Intel i9, 32GB RAM, 2 GPU NVIDIA GeForce (μία RTX 4080 με μνήμη 16GB και μία RTX 4090 με μνήμη 24GB) σε περιβάλλον CUDA®, με λειτουργικό σύστημα Ubuntu 24.10). Οι 5 αρχιτεκτονικές του μοντέλου YOLO11 που δοκιμάστηκαν ήταν η nano (n), small (s), medium (m), large (l) και extra large (x). Δόθηκε έμφαση στην ανάλυση των εικόνων εισόδου, λόγω του μικρού μεγέθους των προς εντοπισμό ζιζανίων σε σχέση με τα μεγέθη των εικόνων. Τα μεγέθη της ανάλυσης (παράμετρος "Img size" στον πίνακα) αφορούν την εκάστοτε σμίκρυνση των αρχικών εικόνων ώστε να εισαχθούν στα μοντέλα. Π.χ., το 640 σημαίνει ότι πραγματοποιήθηκε σμίκρυνση των εικόνων εισόδου σε ανάλυση 640x640. Το batch size ήταν κάθε φορά το μέγιστο δυνατό ώστε να είναι δυνατή η διαχείριση των δεδομένων εκπαίδευσης από τη διαθέσιμη μνήμη των GPU (40GB).

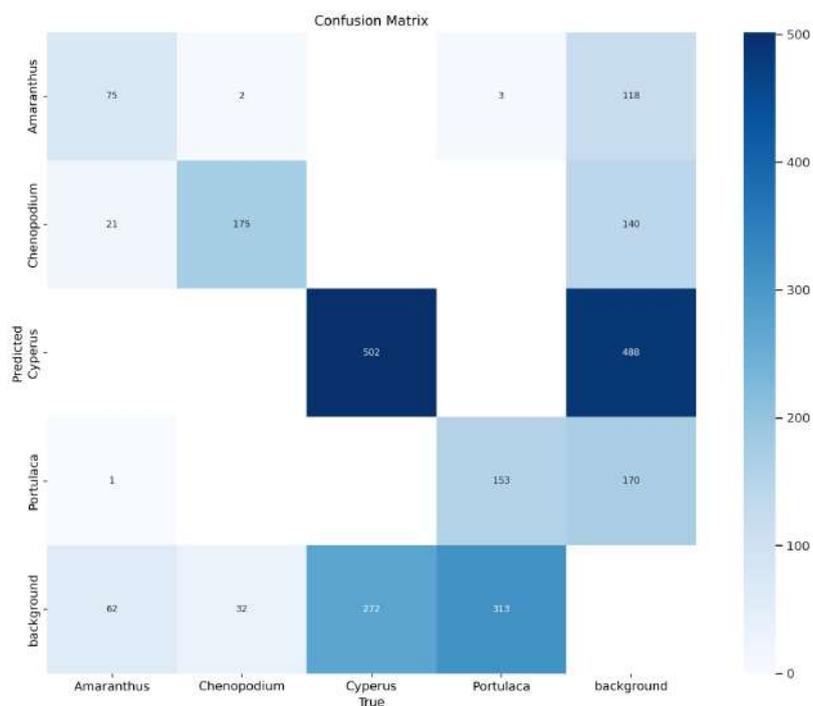
Το τελικό μοντέλο που επιλέχθηκε ήταν το μοντέλο YOLO11l (αρχιτεκτονική large), με μέγεθος εικόνας εισόδου 1920 pixel, το οποίο, στο validation set, έδωσε τα καλύτερα συνολικά αποτελέσματα απόδοσης με $mAP_{50} = 0.48$ και $F1\text{-score} = 0.512$, όπως φαίνεται παρακάτω και στην εικόνα 1.4.1-11.



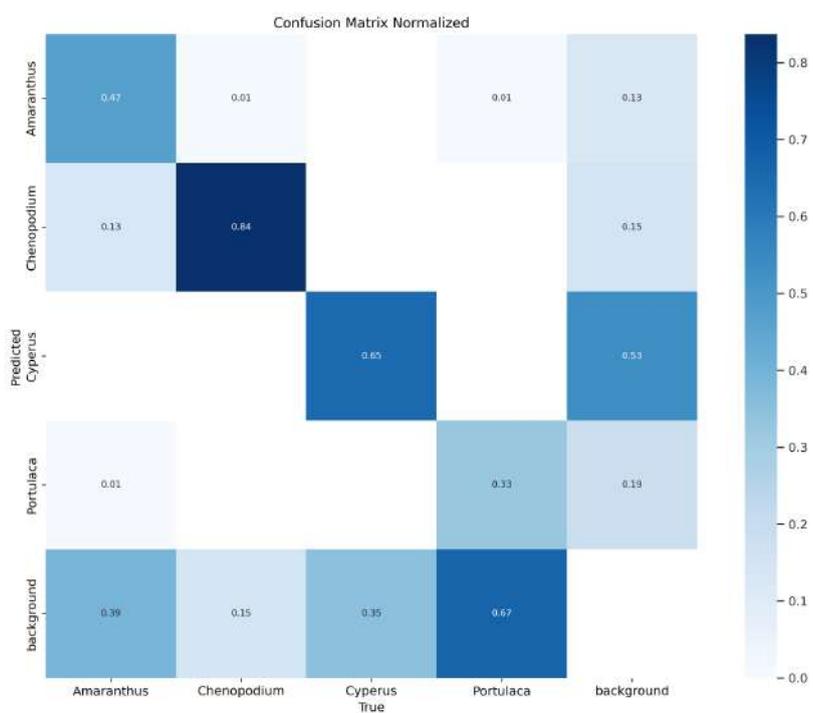
Εικόνα 1.4.1-11: Πορεία εκπαίδευσης ενός από τα δύο τελικά μοντέλα αναγνώρισης και εντοπισμού ζιζανίων, βασισμένου στο μοντέλο YOLO11l.

Πίνακας 1.4.1-1: Διαφορετικά μοντέλα τύπου YOLO με διαφορετικές παραμέτρους εκπαίδευσης και με τα ανάλογα αποτελέσματα (στο validation set).

Model	Max. epochs	Batch size	Img size	Precision	Recall	mAP ₅₀	F1-score
11n	300	16	640	0.304	0.275	0.215	0.289
11n	300	2	3840	0.48	0.517	0.459	0.498
11s	300	16	640	0.332	0.305	0.247	0.318
11s	300	16	1280	0.45	0.461	0.383	0.455
11s	300	4	2560	0.429	0.565	0.46	0.488
11s	300	2	3200	0.517	0.507	0.466	0.512
11m	300	16	640	0.393	0.314	0.292	0.349
11m	300	16	1088	0.432	0.482	0.396	0.456
11m	100	16	1280	0.485	0.487	0.431	0.486
11m	300	2	2560	0.475	0.541	0.467	0.506
11l	300	16	640	0.5	0.303	0.306	0.377
11l	300	8	1280	0.469	0.486	0.432	0.477
11l	300	4	1920	0.48	0.549	0.48	0.512
11l	300	2	2560	0.473	0.509	0.47	0.490
11x	300	16	640	0.424	0.339	0.301	0.377
11x	300	2	2240	0.487	0.51	0.453	0.498



(a)



(b)

Εικόνα 1.4.1-12: Το confusion matrix της απόδοσης του YOLO11l (padding) στο validation set, (a) σε πλήθος εντοπισμών, και (b) σε ποσοστά (normalized).

Από τα confusion matrices (Εικόνα 1-4.1-12a, Εικόνα 1.4.1-12b) φαίνεται ότι το μοντέλο (YOLO11l) πετυχαίνει την καλύτερη απόδοση αναγνώρισης και εντοπισμού στη περίπτωση της κύπερης (Cyperus), ενώ η χαμηλότερη απόδοση παρουσιάζεται στην αντράκλα. Πιο συγκεκριμένα, τα 75 από τα 159 instances του Amaranthus (47%) αναγνωρίστηκαν επιτυχώς, τα 21 (13%) αναγνωρίστηκαν εσφαλμένα ως Chenopodium, το 1 (1%) ως Portulaca και τα 62 (39%) δεν εντοπίστηκαν. Τα 175 από τα 209 instances του Chenopodium (84%) αναγνωρίστηκαν επιτυχώς, τα 2 (1%) Amaranthus αναγνωρίστηκαν εσφαλμένα ως Chenopodium και 32 (15%) δεν εντοπίστηκαν. Τα 502 από τα 774 instances του Cyperus (65%) αναγνωρίστηκαν επιτυχώς, ενώ 272 (35%) δεν αναγνωρίστηκαν. Τέλος, αναγνωρίστηκαν επιτυχώς 153 από τα 469 instances του Portulaca (33%).

2.3.2 Δεύτερη εκπαίδευση μοντέλων - Τμηματοποιημένες εικόνες εισόδου

Κατά τη δεύτερη ενότητα εκπαίδευσης μοντέλων, δοκιμάστηκαν εικόνες ανάλυσης 640 x 640 pixel από το δεύτερο σύνολο δεδομένων με τις περίπου 17.000 τμηματοποιημένες εικόνες. Σκοπός ήταν η εύρεση του καταλληλότερου μοντέλου που θα παρουσίαζε τα υψηλότερα αποτελέσματα εντοπισμού και σωστής αναγνώρισης. Δοκιμάστηκαν 3 μοντέλα βαθιάς μάθησης για τον αυτόματο εντοπισμό ζιζανίων: Faster R-CNN, YOLO, Vision Transformer.

2.3.2.1 Ανάπτυξη μοντέλων Faster R-CNN

Το κάθε CNN τύπου Faster R-CNN χρησιμοποιεί ένα Region Proposal Network (RPN), το οποίο είναι ένα πλήρως συνελκτικό δίκτυο που προσφέρει πιθανές περιοχές με ποικίλες κλίμακες και αναλογίες διαστάσεως, ενώ εφαρμόζεται παράλληλα και ένα δίκτυο ταξινόμησης (classification network) στις προτεινόμενες περιοχές. Στη παρούσα εργασία μελετήθηκαν 4 διαφορετικά RPNs (EfficientNetB0, MobileNetV3, RegNetY και ResNet50) για την εύρεση του καταλληλότερου.

Χρησιμοποιήθηκαν δύο υπολογιστές με διαφορετικά χαρακτηριστικά στον καθένα (Υπολογιστής 1: Intel i9 10900X, 32 GB RAM, NVIDIA 3080 Ti και Υπολογιστής 2: AMD Ryzen 7, 16 GB RAM, NVIDIA RTX 4050) και πραγματοποιήθηκαν 8 εκπαιδεύσεις στο σύνολο (4 στον κάθε υπολογιστή). Οι παράμετροι της εκπαίδευσης (epoch, batch size, learning rate) ήταν ανάλογες με τα χαρακτηριστικά του κάθε υπολογιστή - επομένως διέφεραν ανά υπολογιστή και αντίστοιχα, ανά RPN. Τα χαρακτηριστικά εκπαίδευσης και τα αποτελέσματα στο test set φαίνονται στον Πίνακα 1.4.1-2.

Πίνακας 1.4.1-2: Αποτελέσματα των εκπαιδευόμενων μοντέλων *Faster R-CNN* ανά υπολογιστή και *RPN*, στα *test set*. Με *bold* τιμές αναδεικνύονται τα υψηλότερα αποτελέσματα.

Model	Epochs	Batch	Worker s	Precision	Recall	mAP50	F1- score
Resnet50-PC1	70	8	8	0.325	0.459	0.149	0.38
Resnet50-PC2	75	4	4	0.468	0.622	0.291	0.534
MobileNetV3- Large-PC1	100	8	16	0.536	0.636	0.34	0.581
MobileNetV3- Large-PC2	90	4	4	0.515	0.64	0.329	0.57
EfficientNet_b0 -PC1	100	8	8	0.602	0.701	0.422	0.647
EfficientNet_b0 -PC2	90	4	8	0.603	0.755	0.455	0.67
RegNetY-PC1	40	6	8	0.535	0.682	0.364	0.599
RegNetY-PC2	45	16	8	0.542	0.721	0.39	0.618

2.3.2.2 Ανάπτυξη μοντέλων Vision Transformer

Όπως προαναφέρθηκε, τα vision transformer μοντέλα έχουν χρησιμοποιηθεί ευρέως για τον αυτόματο εντοπισμό ζιζανίων. Η εκπαίδευση πραγματοποιήθηκε στο τμηματοποιημένο σύνολο δεδομένων, σε υπολογιστή με τα εξής χαρακτηριστικά: Intel i9 10900X, 32 GB RAM, NVIDIA 3080 Ti. Εξετάστηκαν δύο μοντέλα Transformer, το RT-DETR-v2 και το Swin.

Το RT-DETR-v2 εκπαιδεύτηκε για 72 epochs, learning rate 0.0001 και batch size 8, ενώ το Swin σε 36 epochs, με 2 workers, learning rate στο 0.0001 (warmup + piecewise

decay) και batch size 1. Τα χαρακτηριστικά εκπαίδευσης και τα αποτελέσματα στο test set φαίνονται στον Πίνακα 1.4.1-3.

Πίνακας 1.4.1-3: Αποτελέσματα των εκπαιδευόμενων μοντέλων Vision Transformer στα test set. Με bold τιμές αναδεικνύονται τα υψηλότερα αποτελέσματα.

Model	Epochs	Batch	Workers	Precision	Recall	mAP50	F1-score
RT-DETR-V2	72	8	4	0.548	0.705	0.548	0.497
SWIN	36	1	2	0.44	0.585	0.717	0.505

2.3.2.3 Ανάπτυξη μοντέλου YOLO11

Με αφορμή την υψηλή απόδοση του YOLO11 σε πρόσφατες έρευνες αυτόματου εντοπισμού ζιζανίων (Gangadharan et al., 2025; Zhang et al., 2025), δοκιμάστηκε η απόδοσή του και στο τμηματοποιημένο σύνολο δεδομένων. Το μοντέλο ήταν το YOLO11m και εκπαιδεύτηκε σε 100 epochs, με batch size 32 και learning rate 0.01. Τα χαρακτηριστικά εκπαίδευσης και τα αποτελέσματα στο test set φαίνονται στον Πίνακα 1.4.1-4.

Πίνακας 1.4.1-4: Αποτελέσματα του YOLO11m στο test set, με τμηματοποιημένες εικόνες εισόδου.

Model	Epochs	Batch	Workers	Precision	Recall	mAP50	F1-score
YOLO11m	100	32	8	0.776	0.777	0.828	0.776

2.4 Αξιολόγηση τελικών μοντέλων

Η αξιολόγηση των τελικών μοντέλων έγινε με τη δοκιμή τους στο test set, δηλαδή στις εικόνες εκείνες που κρατήθηκαν εκτός της διαδικασίας εκπαίδευσης, ώστε τα μοντέλα να αξιολογηθούν σε εικόνες που δεν είχαν ήδη «δει». Ο Πίνακας 1.4.1-5 παρουσιάζει

συγκεντρωτικά τις τιμές των βασικών metrics για τα καλύτερα μοντέλα της κάθε κατηγορίας. Όπως γίνεται εμφανές, τον σημαντικότερο ρόλο στην απόδοση εντοπισμού και αναγνώρισης ζιζανίων παίζει ο τύπος των εικόνων εισόδου, με τις τμηματοποιημένες εικόνες να ευνοούν εμφανώς τις αποδόσεις. Μεταξύ των μοντέλων που χρησιμοποιούν τμηματοποιημένες εικόνες, την καλύτερη απόδοση είχε το μοντέλο YOLO.

Πίνακας 1.4.1-5. Συγκεντρωτικά αποτελέσματα της απόδοσης δοκιμής (test set) των επικρατέστερων τύπων της κάθε κατηγορίας μοντέλων.

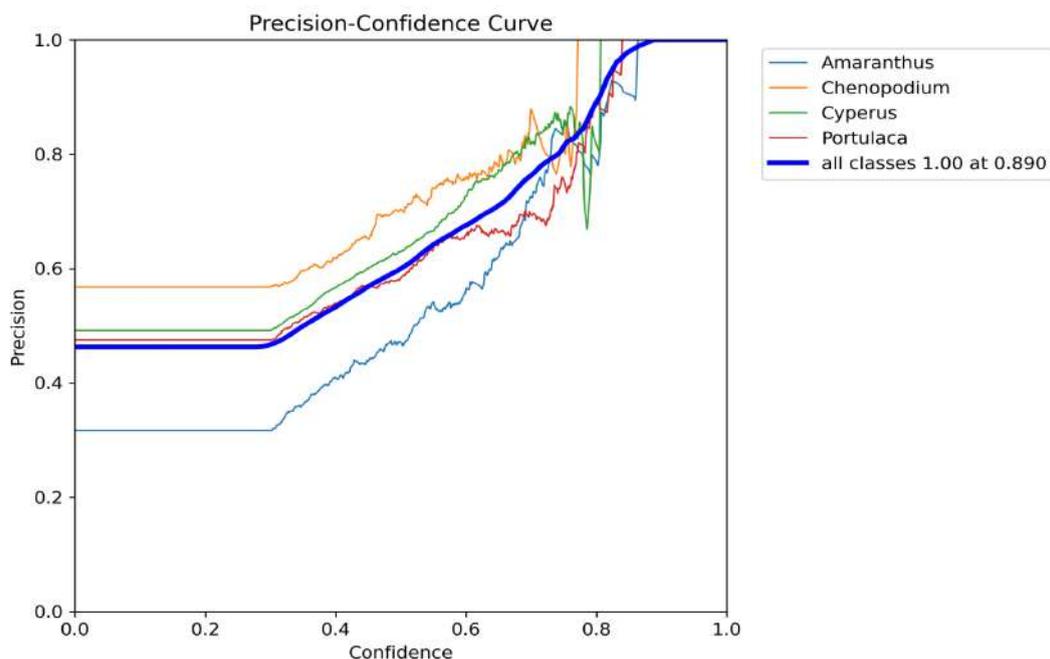
Μοντέλο	Αρχιτεκτονική / τύπος	Εικόνες εισόδου	Precision	Recall	mAP50	F1-score
YOLO11	large	Ολόκληρες	0.472	0.520	0.468	0.495
YOLO11	medium	Tiled	0.776	0.777	0.828	0.776
Faster R-CNN	EfficientNet_b0	Tiled	0.603	0.755	0.455	0.670
Transformer	SWIN	Tiled	0.440	0.585	0.717	0.505

Παρακάτω παρουσιάζεται αναλυτικά η αξιολόγηση των 2 βασικών μοντέλων YOLO11 που αναπτύχθηκαν, με χρήση ολόκληρων εικόνων εισόδου και με χρήση τμηματοποιημένων εικόνων εισόδου, αντίστοιχα.

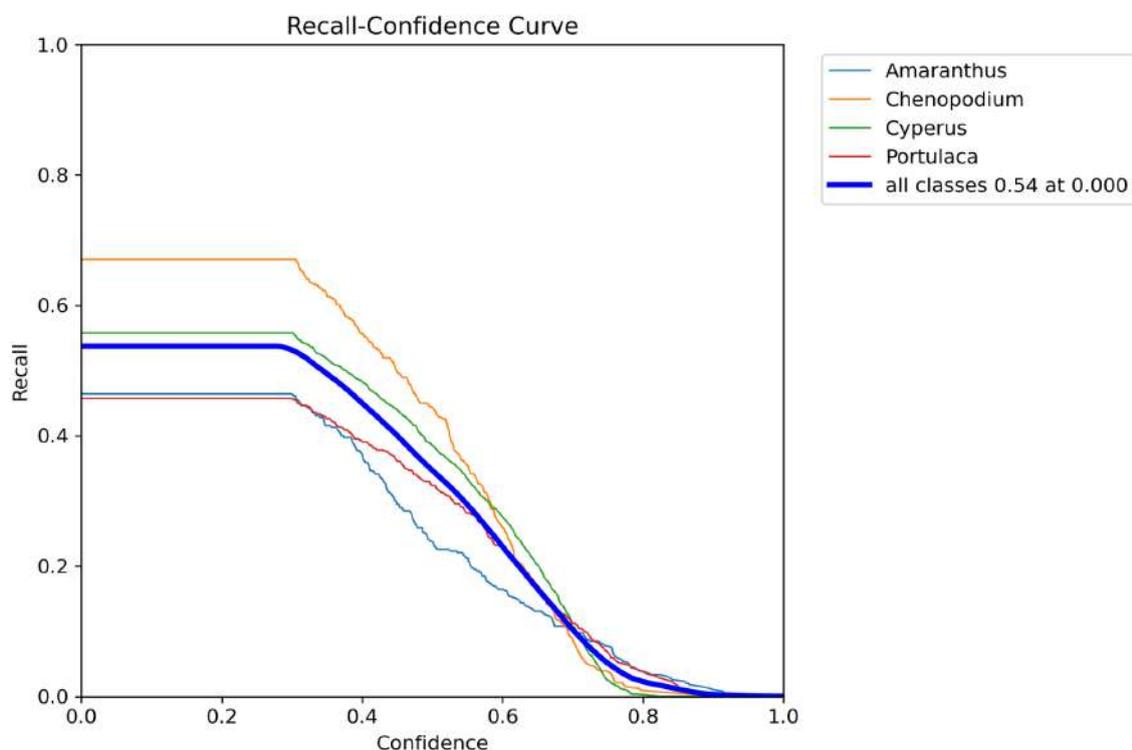
2.4.1 YOLO11 με ολόκληρες εικόνες εισόδου

Για την αξιολόγηση των τελικών μοντέλων δημιουργήθηκαν τα διαγράμματα "Precision-Confidence" (Εικόνα 1.4.1-13), "Recall-Confidence" (Εικόνα 1.4.1-14), "Precision-Recall (Εικόνα 1.4.1-15)" και "F1-Confidence" (Εικόνα 1.4.1-16) που αφορούν το test set.

Το διάγραμμα Precision-Confidence (Εικόνα 1.4.1-13) δείχνει την ακρίβεια (Precision) σε σχέση με τα επίπεδα εμπιστοσύνης (Confidence Levels), δηλαδή πόσο ακριβές είναι το μοντέλο στην αναγνώριση ανάλογα με τον βαθμό βεβαιότητάς του. Γενικότερα, τα επίπεδα εμπιστοσύνης χωρίζονται σε 3 κατηγορίες, με ποσοστά < 70% να είναι χαμηλά, ποσοστά < 89% να είναι μετρίως ικανοποιητικά και από 90% και πάνω να θεωρούνται πολύ ικανοποιητικά. Υψηλό precision σημαίνει ότι το ποσοστό των σωστών προβλέψεων στο σύνολο των προβλέψεων του μοντέλου είναι υψηλό, ενώ χαμηλό precision αντιστοιχεί σε υψηλό ποσοστό λανθασμένων προβλέψεων. Επειδή υπάρχουν πολλές αυξομειώσεις, πρέπει να ληφθεί υπόψη και το διάγραμμα Recall-Confidence, καθώς μπορεί μεν το μοντέλο να κάνει σωστές προβλέψεις (high precision), αλλά ταυτόχρονα να μην εντοπίζει μεγάλο αριθμών ζιζανίων (χαμηλό recall). Συγκριτικά με την κάθε κλάση, η λουβουδιά έχει την καλύτερη ακρίβεια, το βλίτο ξεκινάει πολύ χαμηλά αλλά βελτιώνεται αργά, ενώ η αντράκλα και η κύπερη δεν δείχνουν μεγάλη βελτίωση.



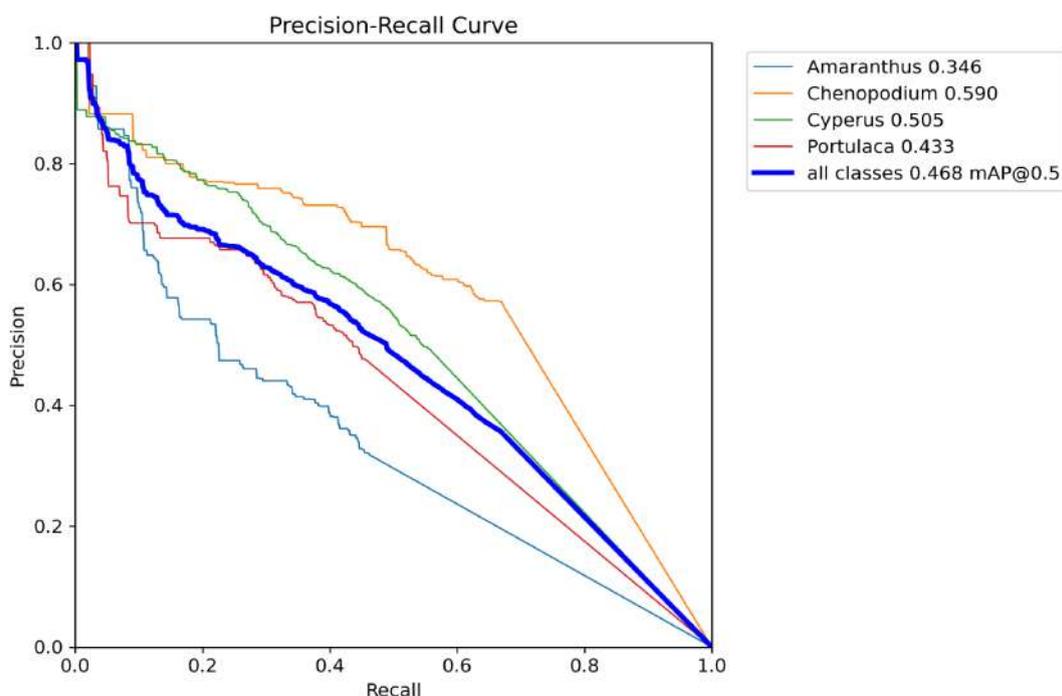
Εικόνα 1.4.1-13: Απεικόνιση καμπύλης Precision-Confidence για τα 4 ζιζάνια και το μοντέλο συνολικά - YOLO11l.



Εικόνα 1.4.1-14: Απεικόνιση καμπύλης Recall-Confidence για τα 4 ζιζάνια και το μοντέλο συνολικά - YOLO11l.

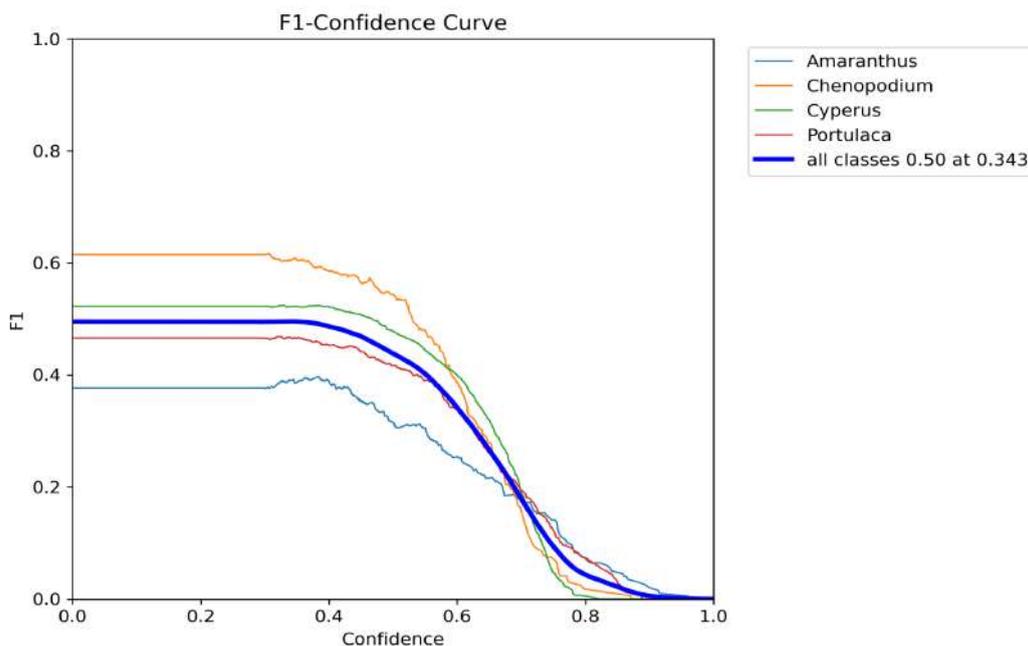
Αντίστοιχα, το διάγραμμα Recall-Confidence (Εικόνα 1.4.1-14) απεικονίζει το καλύτερο recall, με τη κύπερη και λουβουδιά να είναι σχετικά ικανοποιητικές, ενώ το βλίτο και η άντρακλα να δείχνουν αρκετά χαμηλά αποτελέσματα, χάνοντας αρκετές μετρήσεις.

Το διάγραμμα Precision-Recall (Εικόνα 1.4.1-15) εφαρμόζεται στην αξιολόγηση των μοντέλων και ειδικότερα, σε αυτά που έχουν ανομοιόμορφο σύνολο δεδομένων εκπαίδευσης. Όσο πιο υψηλή είναι η καμπύλη σε ύψος (precision) και πλάτος (recall), τόσο αποδοτικότερο είναι το μοντέλο στην ανίχνευση. Σύμφωνα και με τα αποτελέσματα, η λουβουδιά ("CHEAL") πέτυχε τα υψηλότερα αποτελέσματα, ακολουθούμενη από την κύπερη ("CYPES"), ενώ τα χαμηλότερα αποτελέσματα ήταν της αντράκλας ("POROL") και τέλος του βλίτου ("AMARE"). Αξίζει να σημειωθεί ότι παρόλο που η κύπερη εντοπίστηκε περίπου 3 φορές περισσότερο σε αριθμό από τη λουβουδιά, η λουβουδιά έδωσε τα καλύτερα αποτελέσματα εντοπισμού.

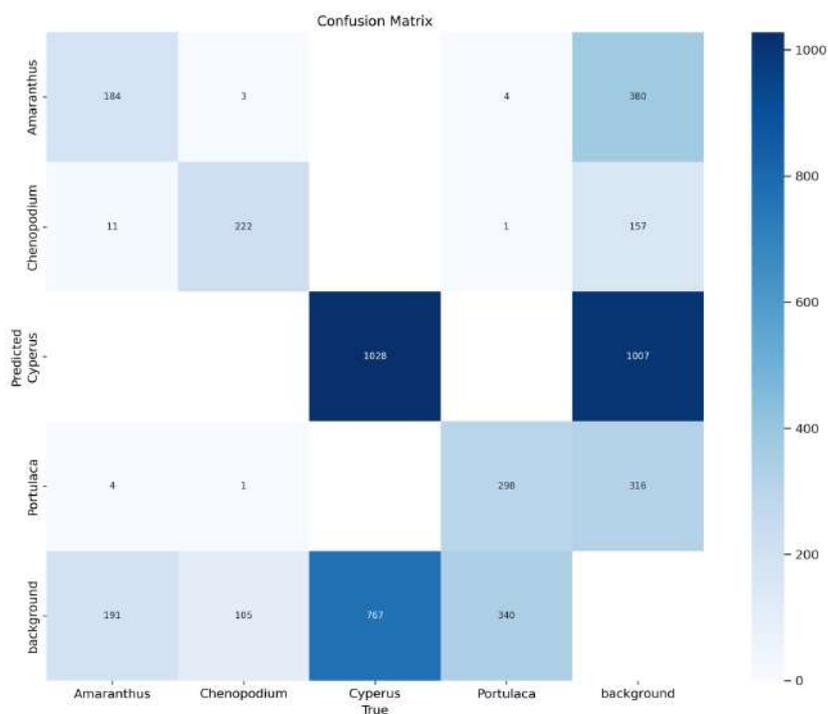


Εικόνα 1.4.1-15: Απεικόνιση καμπύλης Precision-Recall για τα 4 ζιζάνια και το μοντέλο συνολικά - YOLO11l.

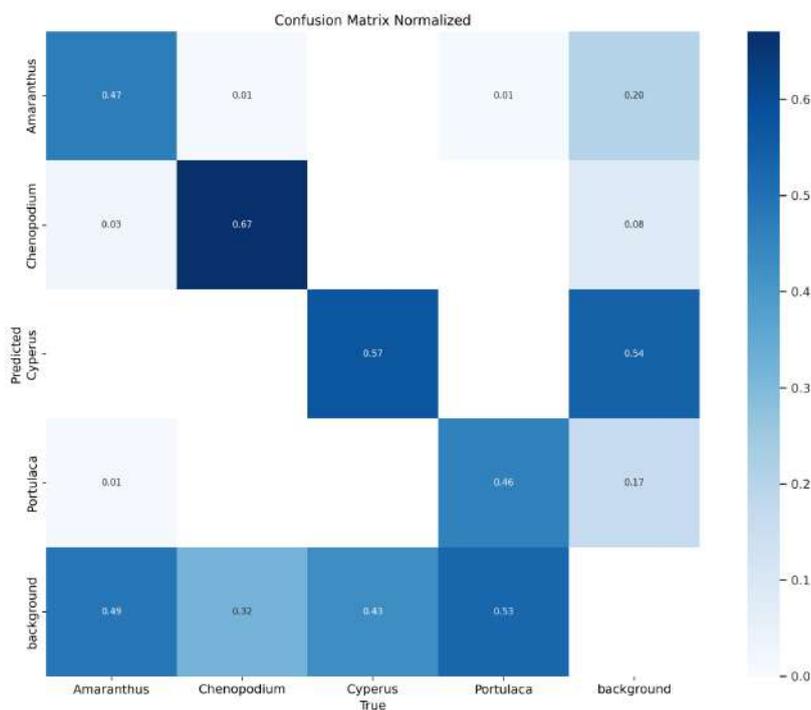
Έτσι, σύμφωνα και με το διάγραμμα "F1-Confidence" (Εικόνα 1.4.1-16), η λουβουδιά έχει την καλύτερη ισορροπία, η κύπερη ήταν σχετικά ικανοποιητική και το βλίτο με την αντράκλα έδωσαν τα χαμηλότερα αποτελέσματα.



Εικόνα 1.4.1-16: Απεικόνιση καμπύλης F1-Confidence για τα 4 ζιζάνια και το μοντέλο συνολικά - YOLO11l.



(a)



(b)

Εικόνα 1.4.1-17: Το confusion matrix της απόδοσης του τελικού μοντέλου στο test set, (a) σε πλήθος εντοπισμών, και (b) σε ποσοστά (normalized).

```

Ultraalytics 8.3.55 Python-3.12.3 torch-2.5.1+cu124 CUDA:0 (NVIDIA GeForce RTX 4090, 24217MiB)
                                                                CUDA:1 (NVIDIA GeForce RTX 4080, 16079MiB)
YOLO11l summary (fused): 464 layers, 25,282,396 parameters, 0 gradients, 86.6 GFLOPs
val: Scanning /home/dinos/Desktop/Work/InnoPP/yolo/images_1064/labels/test.cache... 214 images,
      Class      Images  Instances  Box(P)      R      mAP50  mAP50-95): 100%|
      all         214      3159      0.475      0.52      0.468      0.281
      Amaranthus   48       390      0.335      0.446      0.346      0.212
      Chenopodium  67       331      0.572      0.646      0.59       0.391
      Cyperus     164     1795      0.504      0.542      0.505      0.267
      Portulaca   49       643      0.491      0.446      0.433      0.254
Speed: 2.9ms preprocess, 26.5ms inference, 0.0ms loss, 2.5ms postprocess per image
    
```

Εικόνα 1.4.1-18: Τα αποτελέσματα του τελικού μοντέλου στο test set, σε σχέση με το Precision, Recall, mAP₅₀ και mAP₅₀₋₉₅ για το κάθε ζιζάνιο ξεχωριστά και για το σύνολό τους.

Στο test set, τα 184 instances από τα 390 του Amaranthus (47%) αναγνωρίστηκαν επιτυχώς, ενώ 11 αναγνωρίστηκαν εσφαλμένα ως Chenopodium (3%), 4 ως Portulaca (1%) και 191 (49%) δεν αναγνωρίστηκαν στο παρασκήνιο. Τα 272 instances από τα 331 του Chenopodium (67%) αναγνωρίστηκαν επιτυχώς, ενώ 3 (1%) Amaranthus αναγνωρίστηκαν εσφαλμένα ως Chenopodium και 105 (32%) δεν αναγνωρίστηκαν. Στη συνέχεια, 1028 instances του Cyperus (57%) αναγνωρίστηκαν επιτυχώς, ενώ 767 (43%) δεν αναγνωρίστηκαν στο παρασκήνιο. Τέλος, 298 instances του Portulaca

(46%) αναγνωρίστηκαν επιτυχώς, ενώ 4 *Amaranthus* (1%) αναγνωρίστηκαν εσφαλμένα ως *Portulaca*.

Παρακάτω ακολουθούν κάποιες ενδεικτικές προβλέψεις του μοντέλου, με την πρώτη εικόνα σε κάθε περίπτωση να δείχνει τα επισημασμένα ζιζάνια που αποτελούν το "ground truth", και τη δεύτερη να απεικονίζει τις προβλέψεις του επιλεγμένου μοντέλου (predictions).

Στη πρώτη περίπτωση (Εικόνα 1.4.1-19) παρατηρούνται σχετικά παρόμοια αποτελέσματα μεταξύ ground truth και προβλέψεων του μοντέλου, με τη μόνη εικόνα που παρατηρήθηκαν εμφανείς διαφορές να είναι η πρώτη από το τέλος. Στο ground truth παρατηρήθηκαν πληθυσμοί κύπερης και λουβουδιάς, ενώ το μοντέλο έχει αναγνωρίσει και τα 4 ζιζάνια, με παρόμοιο αριθμό αναγνώρισης κύπερης, βλίτου και λουβουδιάς. Αξίζει να σημειωθεί ότι στις εικόνες 1 και 2 από την πρώτη και τρίτη σειρά, τα αποτελέσματα του ground-truth με του μοντέλου είναι αρκετά παραπλήσια, με μεγάλη ομοιότητα στις αναγνώρισεις.

Στη δεύτερη περίπτωση σύγκρισης (Εικόνα 1.4.1-20), παρατηρήθηκε ότι το μοντέλο δεν εντόπισε αρκετά ζιζάνια, πιθανώς λόγω του μεγαλύτερου ύψους λήψης. Αξίζει να σημειωθεί ότι στην τρίτη και τέταρτη εικόνα της τρίτης σειράς, το μοντέλο εντόπισε (ορθά) πολλά περισσότερα ζιζάνια από αυτά που είχαν επισημανθεί ως ground-truth.

Σχετικά με τη τρίτη περίπτωση (Εικόνα 1.4.1-21), το μοντέλο έχει εντοπίσει μεγάλο αριθμό πληθυσμών κύπερης (1η και 2η εικόνα πρώτη σειράς, 2η εικόνα δεύτερης σειράς, 2η εικόνα τρίτης σειράς, 1η και 2η εικόνα τέταρτης σειράς), συγκριτικά με το ground-truth. Επιπλέον, στις εικόνες της τελευταίας στήλης υπάρχουν μεν αρκετές επισημάνσεις ζιζανίων, αλλά το μοντέλο φαίνεται να έχει εντοπίσει μεγάλο αριθμό βλίτων και λουβουδιών, ενώ στο ground-truth φαίνεται ότι υπάρχει ποικιλία από όλα τα ζιζάνια.

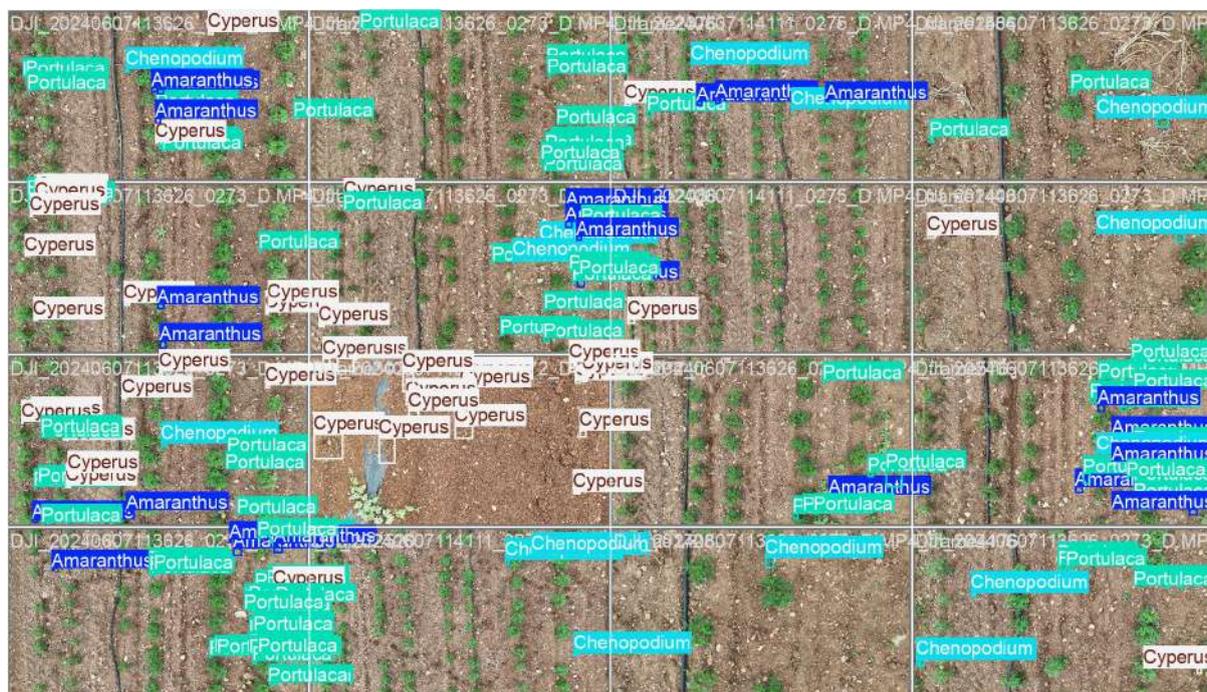


(a)

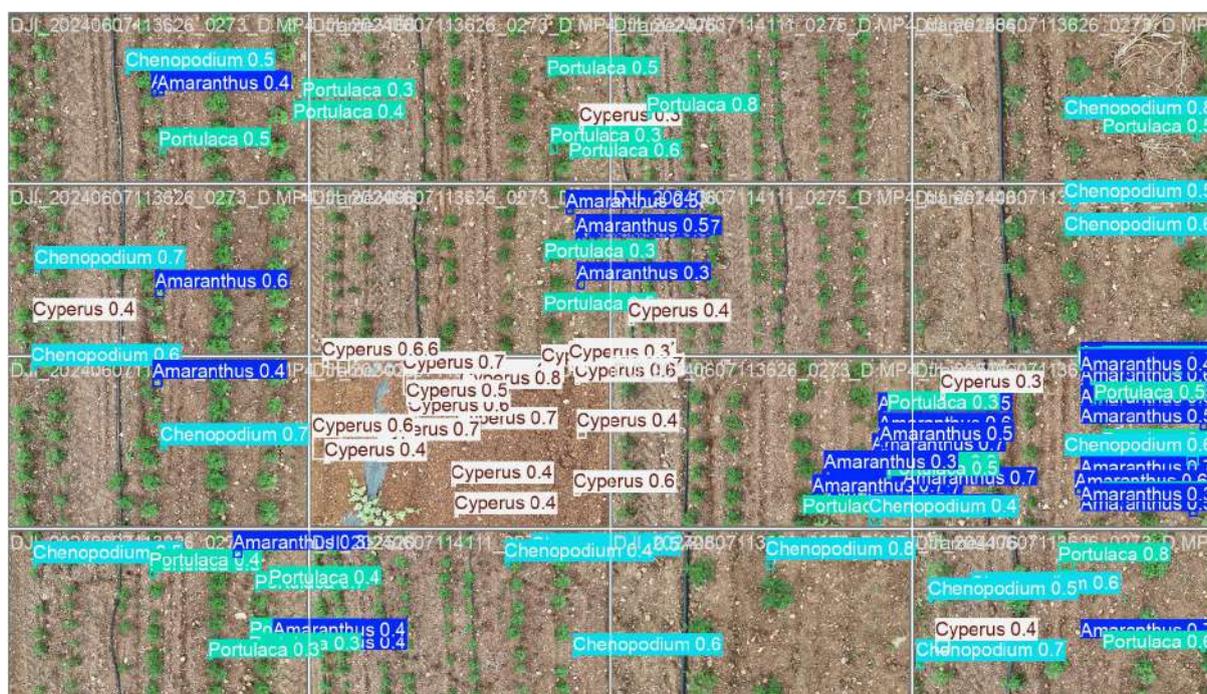


(b)

Εικόνα 1.4.1-19: Τα αποτελέσματα του τελικού μοντέλου στο test set, σε σχέση με το Precision, Recall, mAP₅₀ και mAP₅₀₋₉₅ για το κάθε ζιζάνιο ξεχωριστά και για το σύνολό τους.. Πρώτο δείγμα προβλέψεων του μοντέλου. (a) Ground truth, (b) predictions.

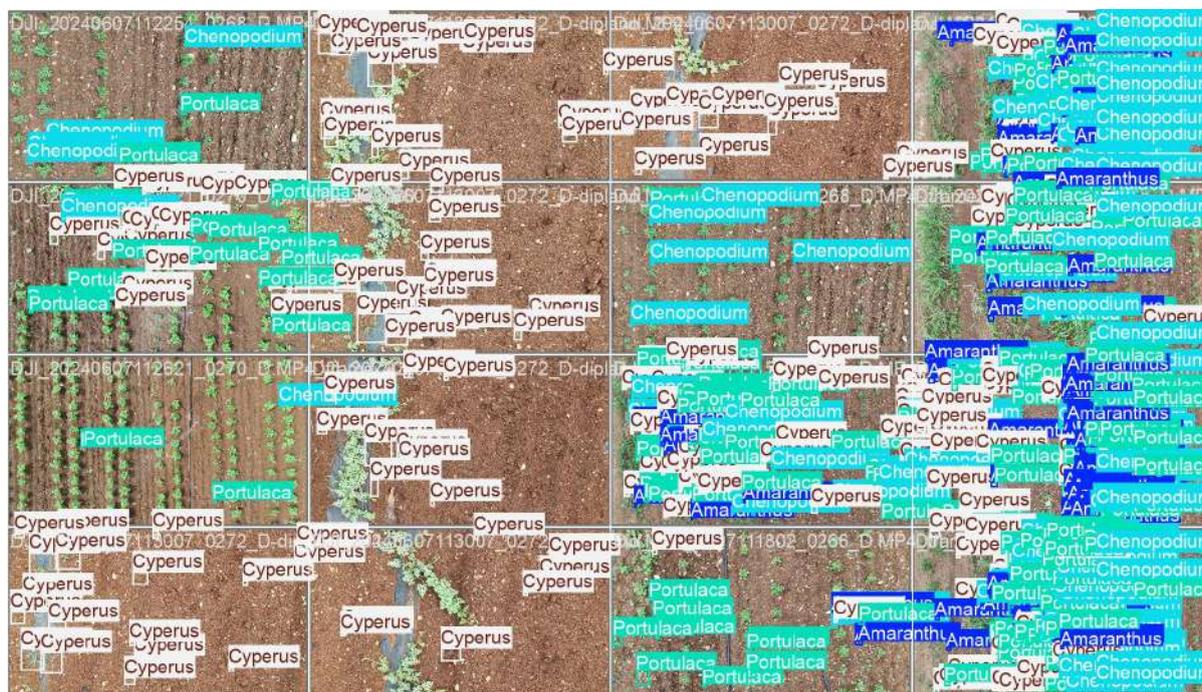


(a)

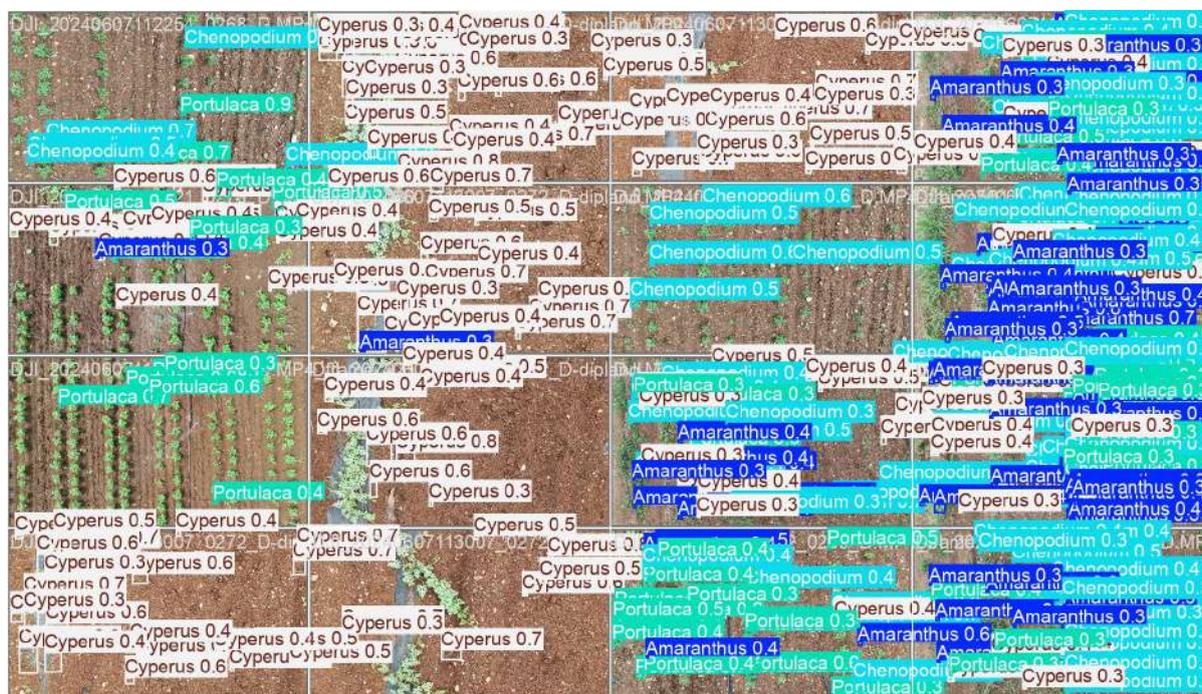


(b)

Εικόνα 1.4.1-20: Δεύτερο δείγμα προβλέψεων του μοντέλου. (a) Ground truth, (b) predictions.



(a)

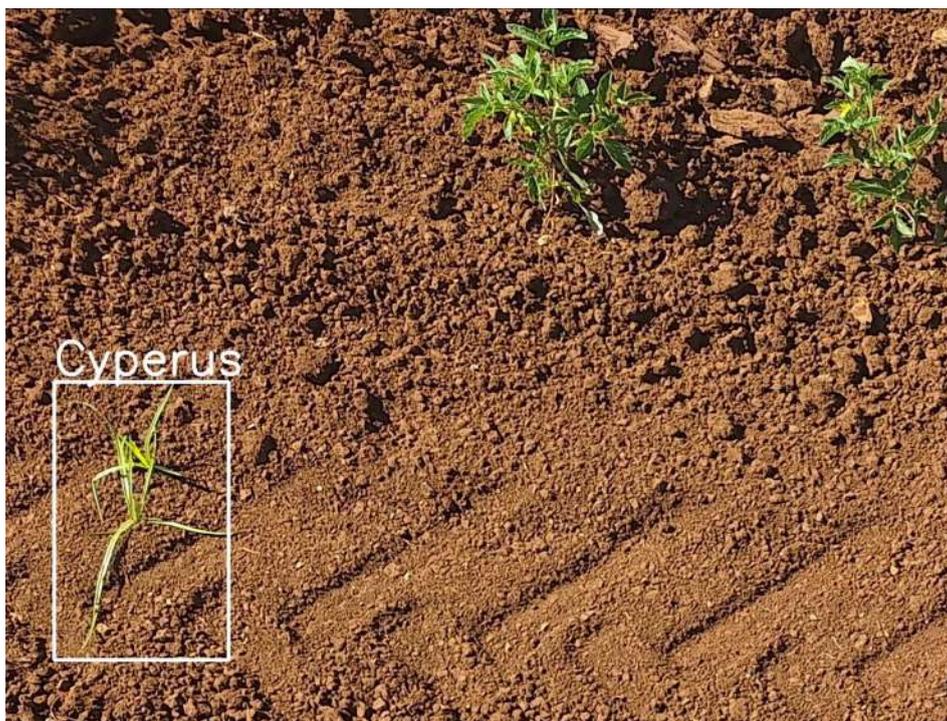


(b)

Εικόνα 1.4.1-21: Τρίτο δείγμα προβλέψεων του μοντέλου. (a) Ground truth, (b) predictions.

Συμπερασματικά, οι σχετικά χαμηλές τιμές των metrics οφείλονται εν μέρει στο πολύ μεγάλο πλήθος ζιζανίων στην πλειοψηφία των εικόνων και στο επακόλουθο γεγονός ότι δεν ήταν δυνατόν να επισημανθεί το 100% των υπαρχόντων ζιζανίων, επομένως πολλοί σωστοί εντοπισμοί και αναγνωρίσεις του μοντέλου προσμετρούνται ως εσφαλμένες προβλέψεις (false positives) στον υπολογισμό των metrics της απόδοσής του. Επίσης, σε πολλές περιπτώσεις, κάποιες επικαλύψεις ζιζανίων φαίνεται να έχουν επισημανθεί ως ένα ζιζάνιο, ενώ το μοντέλο καταφέρνει να διακρίνει ότι πρόκειται για περισσότερα, όπως φαίνεται χαρακτηριστικά στην Εικόνα 1.4.1-22. Στην περίπτωση αυτή, η ορθή πρόβλεψη του μοντέλου προσμετράται ως εσφαλμένη στον υπολογισμό των metrics απόδοσης.

Χαρακτηριστικό παράδειγμα είναι και η δεύτερη περίπτωση σύγκρισης, όπου το μοντέλο "έχασε" αρκετές επισημάνσεις, πιθανώς λόγω του μεγάλου ύψους πτήσης. Όπως αναφέρθηκε και στην Εικόνα 1.4.1-1 (υποενότητα 2.1.1), υπάρχουν πολλές προκλήσεις για την αυτόματη αναγνώριση ζιζανίων σε συνθήκες αγρού (διαφορετικός φωτισμός, σκιάσεις, ομοιότητες ζιζανίων και φυτών), και εκεί ενδεχομένως να φαίνονται οι αδυναμίες του μοντέλου.



(a)



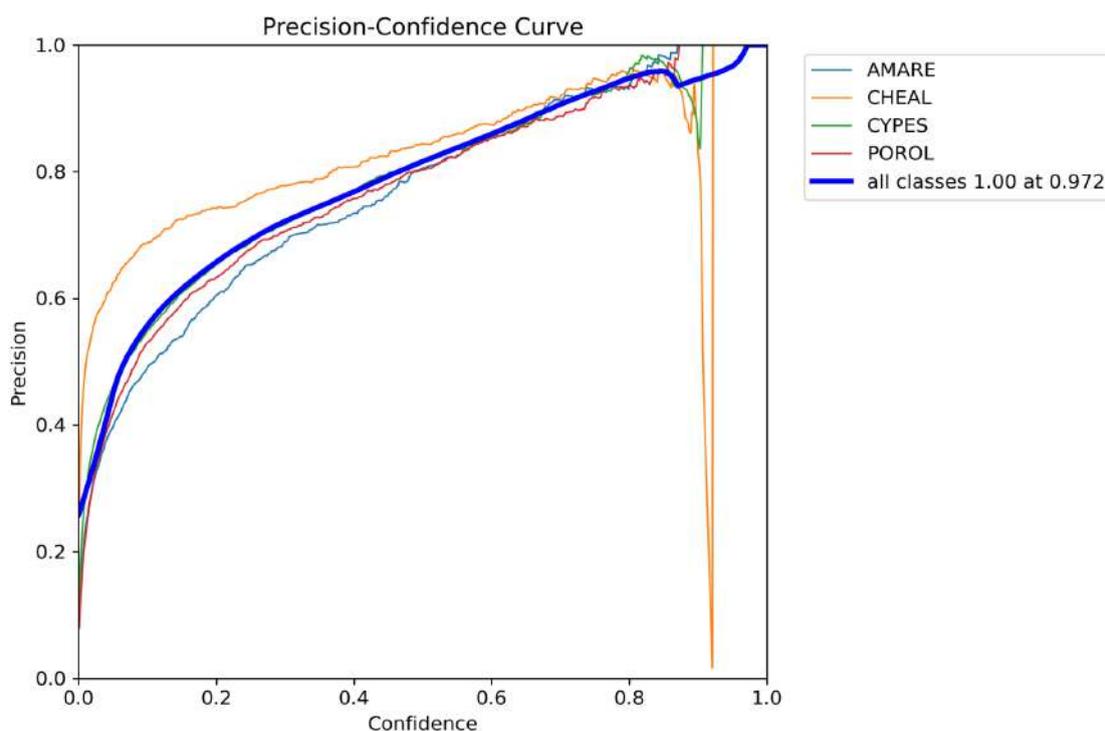
(b)

Εικόνα 1.4.1-22: (a) Ground truth με εσφαλμένη επισήμανση δύο ζιζανίων ως ένα. (b) Σωστή αναγνώριση του μοντέλου ως δύο ξεχωριστά ζιζάνια. (Οι εικόνες είναι σε μεγέθυνση).

2.4.2 YOLO11 με τμηματοποιημένες εικόνες εισόδου (tiling)

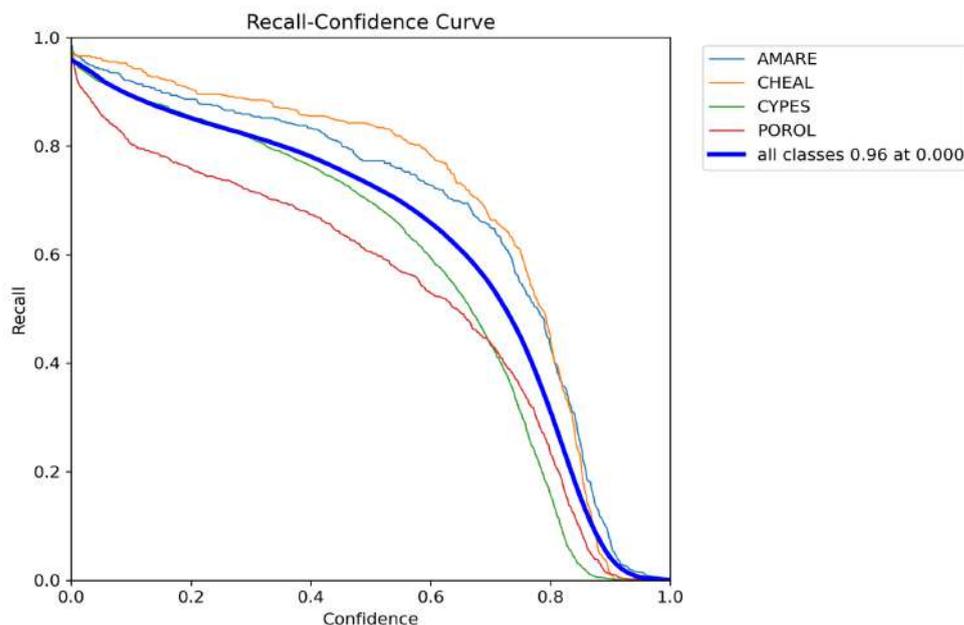
Ακολουθούν οι καμπύλες Precision-Confidence (Εικόνα 1.4.1-23), Recall-Confidence (Εικόνα 1.4.1-24), Precision-Recall (Εικόνα 1.4.1-25) και F1-Confidence (Εικόνα 1.4.1-26) για τα αποτελέσματα του test set με το YOLO11m στο σύνολο δεδομένων με τις τμηματοποιημένες εικόνες (tiled).

Σε γενικές γραμμές το μοντέλο σημείωσε ομαλά αποτελέσματα με ελάχιστες εξαιρέσεις. Για παράδειγμα, στη σχέση Precision-Confidence φαίνεται ότι η λουβουδιά σε υψηλά επίπεδα confidence σημείωσε χαμηλό αριθμό, που αυτό σημαίνει ότι το μοντέλο δεν ήταν αρκετά σίγουρο στον εντοπισμό του σε ποσοστό περίπου 95% "σιγουριάς". Αξίζει να σημειωθεί ότι η λουβουδιά (CHEAL) ήταν το ζιζάνιο με τους λιγότερους εντοπισμούς σε σχέση με τα υπόλοιπα και πιθανώς αυτή η πτώση να οφείλεται σε μεγάλο βαθμό λόγω ανεπάρκειας εκπαίδευσης σε αντίστοιχες ετικέτες.



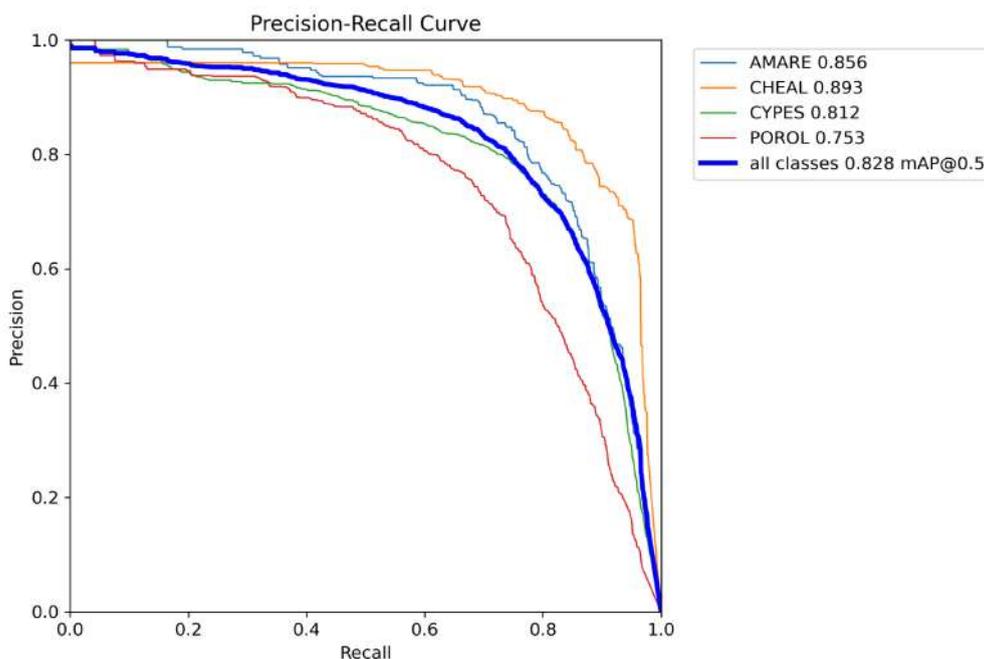
Εικόνα 1.4.1-23: Απεικόνιση καμπύλης Precision-Confidence για τα 4 ζιζάνια και το μοντέλο YOLO11m συνολικά.

Ακολουθεί η καμπύλη Recall-Confidence, στην οποία φαίνεται ότι η σχέση AMARE και CHEAL διατηρήθηκε ομαλά, ενώ CYPES και POROL ήταν λίγο χαμηλότερη.

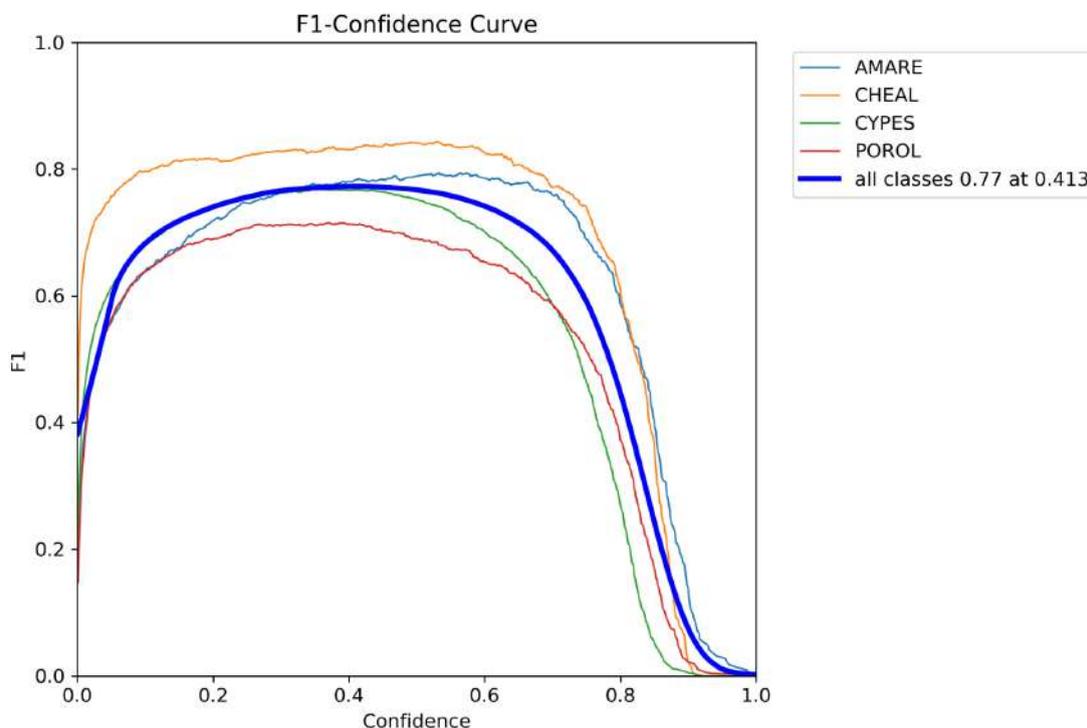


Εικόνα 1.4.1-24: Απεικόνιση καμπύλης Recall-Confidence για τα 4 ζιζάνια και το μοντέλο YOLO11m συνολικά.

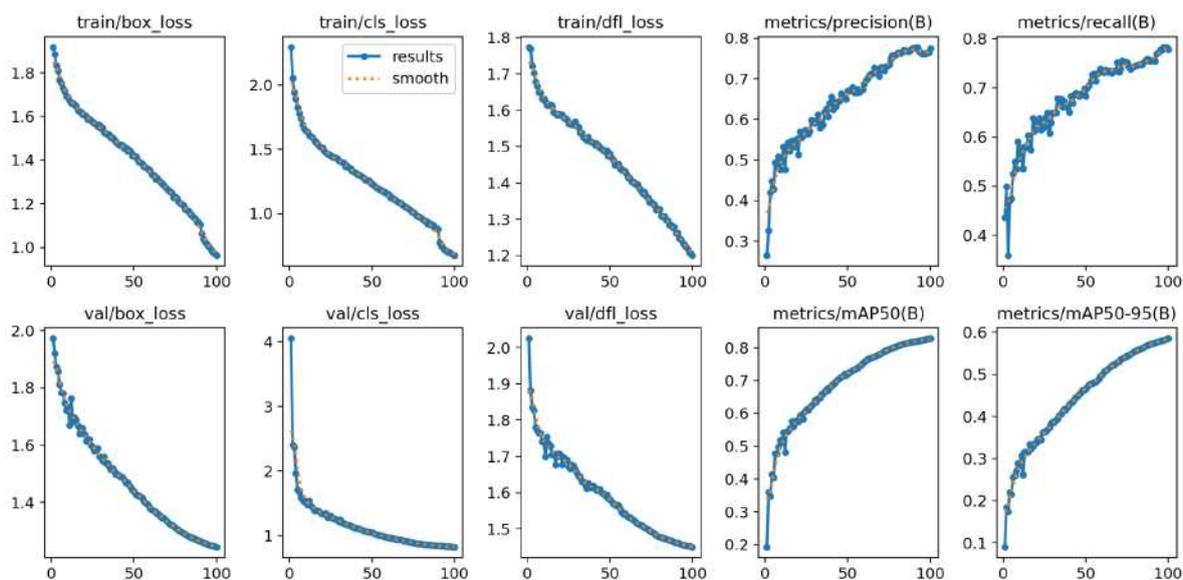
Στις καμπύλες Precision-Recall και F1-Confidence, σημειώθηκε παρόμοια σχέση στις κλάσεις, με AMARE και CHEAL να έχουν υψηλότερα αποτελέσματα ενώ οι τάξεις CYPES και POROL σημείωσαν χαμηλότερα αποτελέσματα συγκριτικά με το σύνολο.



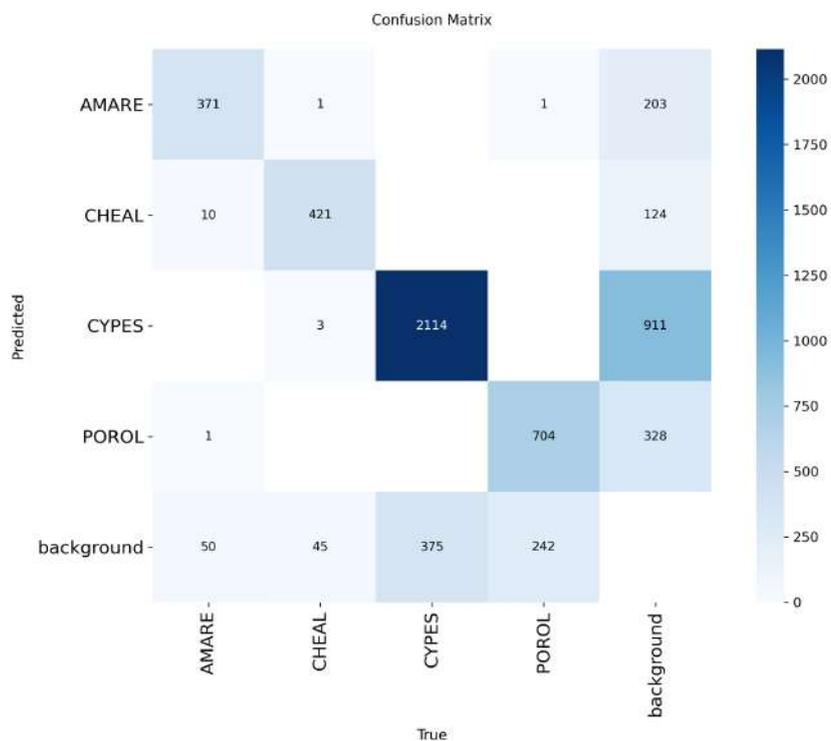
Εικόνα 1.4.1-25: Απεικόνιση καμπύλης Precision-Recall για τα 4 ζιζάνια και το μοντέλο YOLO11m συνολικά.



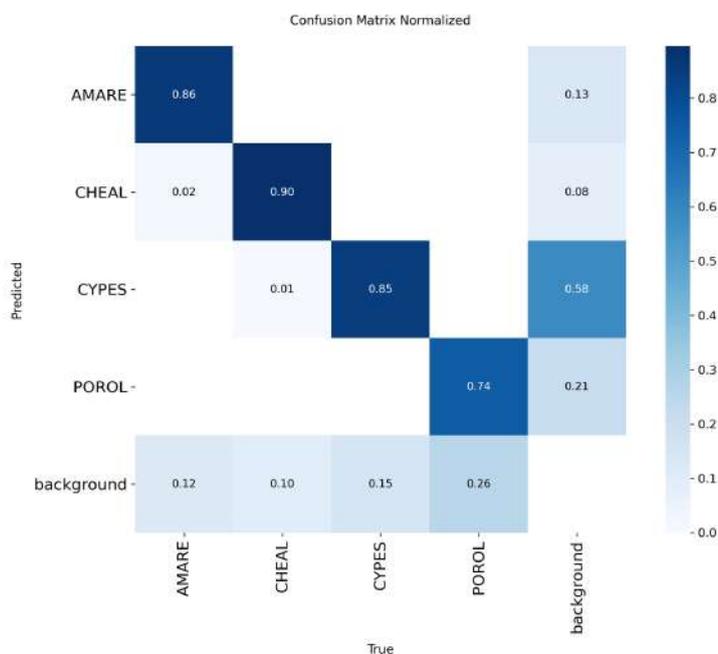
Εικόνα 1.4.1-26: Απεικόνιση καμπύλης F1-Confidence για τα 4 ζιζάνια και το μοντέλο συνολικά.



Εικόνα 1.4.1-27: Πορεία εκπαίδευσης του δεύτερου τελικού μοντέλου αναγνώρισης και εντοπισμού ζιζανίων, βασισμένου στο μοντέλο YOLO11m (tiled).



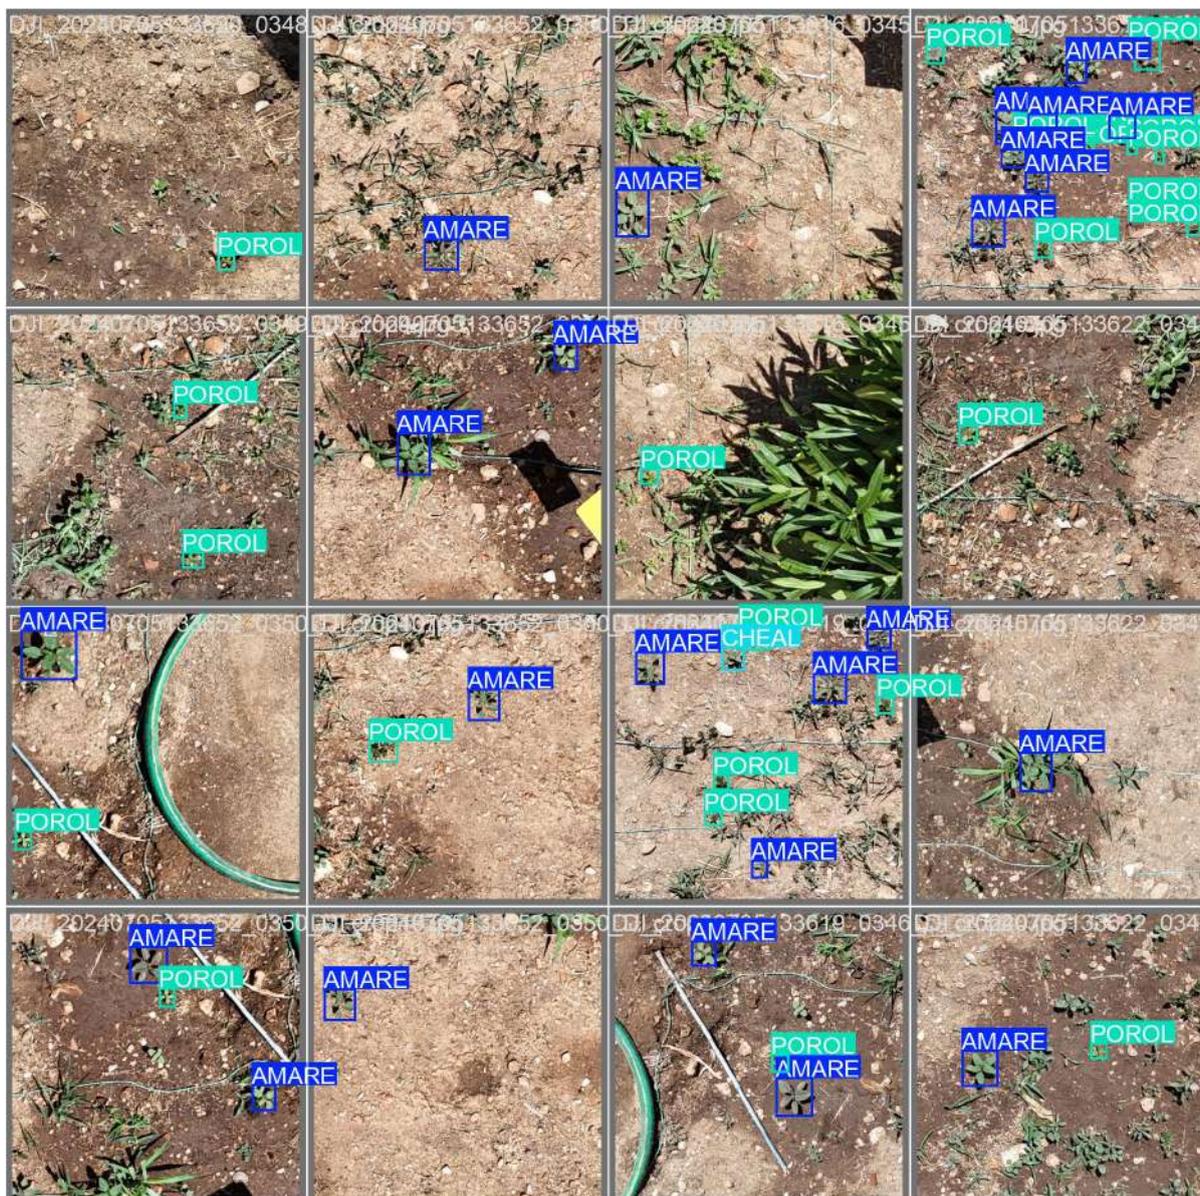
(a)



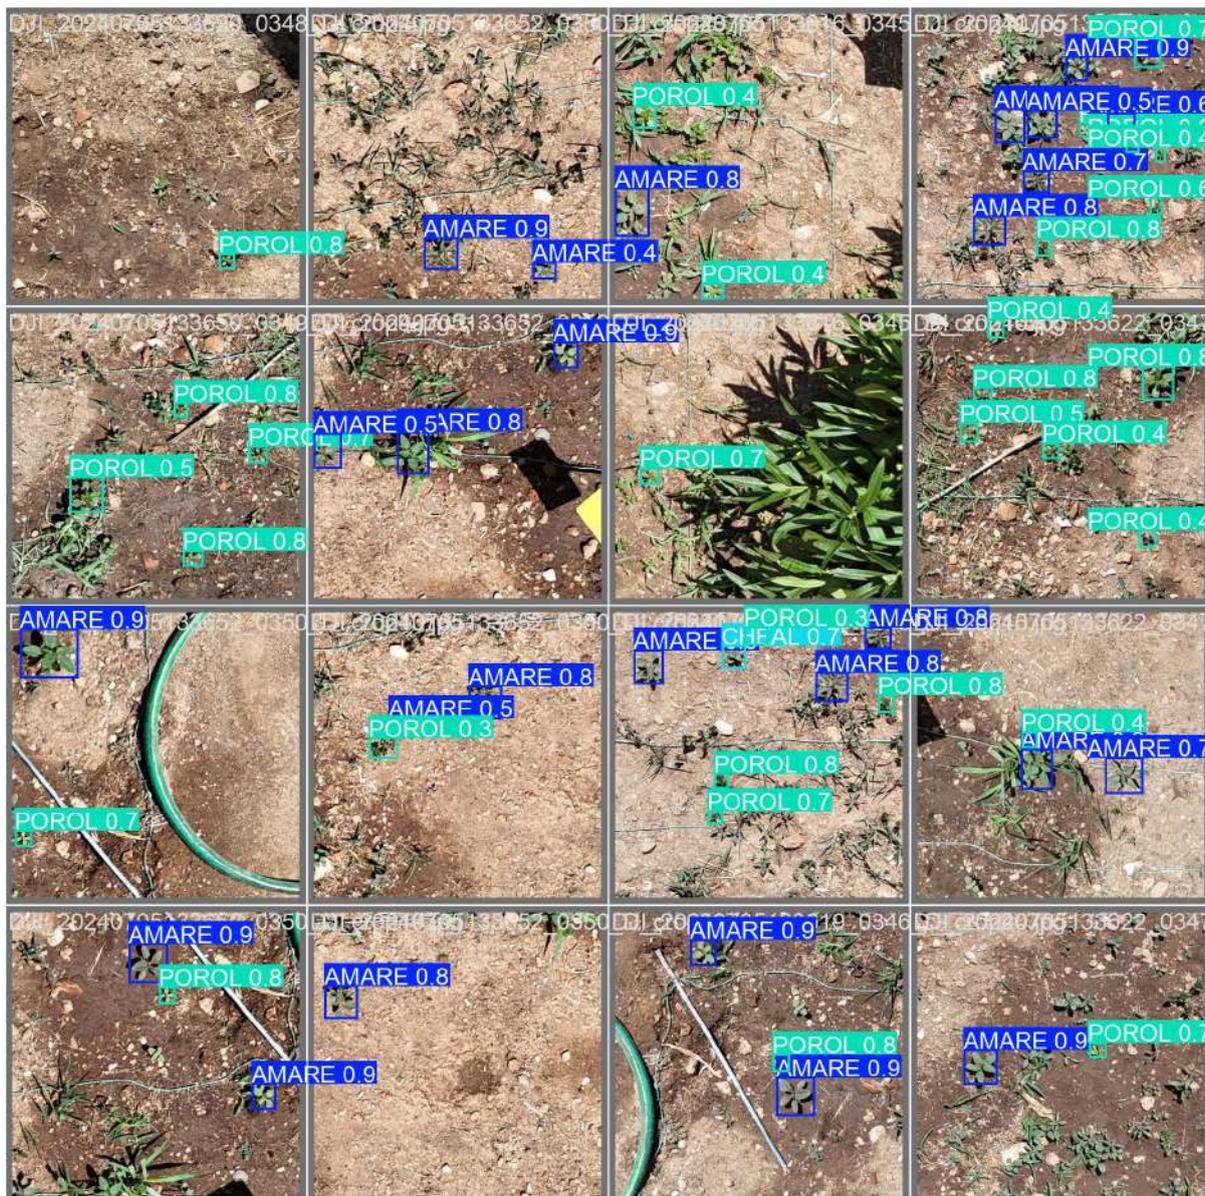
(b)

Εικόνα 1.4.1-28: Το confusion matrix της απόδοσης του μοντέλου YOLO11m στο testing set, (a) σε πλήθος εντοπισμών, και (b) σε ποσοστά (normalized).

Ακολουθούν δείγματα εικόνων που συγκρίνουν την πραγματική θέση των ζιζανίων (a - ground truth) σε σύγκριση με τις παραγόμενες προβλέψεις του μοντέλου (b - predictions). Όπως παρατηρείται, το μοντέλο αναγνώρισε αρκετά ικανοποιητικά τα ζιζάνια στις εικόνες του test set, ενώ υπάρχουν και περιπτώσεις που εντοπίζει ζιζάνια τα οποία δεν είχαν αρχικά επισημανθεί (οι συγκεκριμένες προβλέψεις, ενώ είναι σωστές, λαμβάνονται ως λανθασμένες (false positive) στον υπολογισμό των metrics απόδοσης).



(a)



(b)

Εικόνα 1.4.1-29: Δείγμα προβλέψεων του μοντέλου YOLO11m. (α) Ground truth, (β) predictions.



(a)

2.5 Δημιουργία χαρτών ζιζανίων

Η χαρτογράφηση ζιζανίων μέσω εικόνων λήψης από ΣμηΕΑ και χρήσης CNNs για την αναγνώρισή τους, είναι μία τεχνική η οποία χρησιμοποιείται όλο και περισσότερο για τη διαχείριση ζιζανίων βάσει τοποθεσίας (site-specific weed management - SSWM). Οι περισσότερες μελέτες χαρτογράφησης ακολουθούν την τακτική που ονομάζεται "image-stitching", δηλαδή τη χαρτογράφηση καλλιεργείων μέσω ένωσης πολλαπλών εικόνων λήψης ενός ΣμηΕΑ, σε μία εικόνα που λέγεται ορθοφωτοχάρτης, η οποία είναι υψηλής ανάλυσης και διακρίνονται σε αυτήν περαιτέρω χαρακτηριστικά, όπως είναι τα φυτά καλλιέργειας και τα ζιζάνια που έχουν αναπτυχθεί. Αξίζει να σημειωθεί ότι είναι η συγκεκριμένη διαδικασία είναι αρκετά απαιτητική, καθώς η λήψη εικόνων επηρεάζεται από αρκετούς παράγοντες, όπως είναι οι καιρικές συνθήκες, η ευκρίνεια των ζιζανίων αλλά και η κατάλληλη εκπαίδευση των μοντέλων. Η χαρτογράφηση ζιζανίων είναι ένα πολύτιμο εργαλείο, καθώς μπορεί να δείξει την πυκνότητα ζιζανίων, και έτσι ο παραγωγός να έχει μία πλήρη εικόνα για την κατάσταση που επικρατεί στο χωράφι και να πάρει την κατάλληλη απόφαση για την τεχνική ζιζανιοκτονίας που θα ακολουθήσει.

Η επεξεργασία των δεδομένων που προέκυψαν από τις πτήσεις με ΣμηΕΑ, σε συνδυασμό με τις προβλέψεις του μοντέλου, μπορούν να δημιουργήσουν διαφορετικούς χάρτες ζιζανίων, οι οποίοι εξυπηρετούν διαφορετικούς σκοπούς. Αναφορικά, η υποενότητα 2.5.2.1 θα ασχοληθεί με τη δημιουργία χαρτών που θα απεικονίζουν το ζιζάνιο που βρίσκεται σε πλειοψηφία ανά καρέ λήψης, η υποενότητα 2.5.2.2 με τη σχετική πυκνότητα των ζιζανίων συγκριτικά με τα υπόλοιπα (ένας χάρτης για κάθε διαφορετικό είδος ζιζανίου), ενώ η υποενότητα 2.5.2.3 ασχολείται με τη χαρτογράφηση ζιζανίων με την απόλυτη πυκνότητά τους (και σε αυτή την περίπτωση, ένας χάρτης για κάθε διαφορετικό είδος ζιζανίου). Αξίζει να σημειωθεί ότι η υποενότητα 2.5.2 είναι απαραίτητο βήμα για τη σύνθεση χαρτών ζιζανίων, ανεξάρτητα από την κατηγορία που θα επιλεγεί: κυριαρχίας (2.5.2.1), σχετικής πυκνότητας (2.5.2.2) ή απόλυτης πυκνότητας (2.5.2.3).

2.5.1 Σύντομη βιβλιογραφική ανασκόπηση

Οι Wang et al. (2023) δημιούργησαν μία βάση δεδομένων με ΣμηΕΑ σε πτήσεις ύψους 30 μέτρων, με εικόνες RGB σε ελεγχόμενες συνθήκες πειραματικού αγρού καλλιέργειας σιταριού. Στις εικόνες (ανάλυσης 8708 x 1178) δημιουργήθηκε ο δείκτης CIVE (Color Index of Vegetation) για να διαχωριστούν τα pixel εδάφους με τα pixel βλάστησης. Αφού δημιούργησαν χειροκίνητα ετικέτες στον ορθοφωτοχάρτη, χώρισαν τον χάρτη σε 6 εικόνες και χρησιμοποίησαν 3 εικόνες για την εκπαίδευση του μοντέλου, 1 για το validation και 2 για τη δοκιμή (testing). Στη συνέχεια, χώρισαν τις εικόνες υψηλής ανάλυσης σε τμήματα (tiles) ανάλυσης 256 x 256, χρησιμοποίησαν δύο CNNs (UNet και DeepLabv3+) για την αναγνώριση ζιζανίων και πέτυχαν 87% mIoU (Mean Intersection over Union) και 69% weed IoU. Οι Fraccaro et al. (2022) συνέλεξαν 54.300 έγχρωμες και πολυφασματικές εικόνες μέσω ΣμηΕΑ σε ύψος πτήσης 45 μέτρων (ανάλυση 1 cm και 3 cm, αντίστοιχα), ανάλυσης 1024 x 1024 pixel. Αφού εφάρμοσαν το UNet (με ResNet34 backbone), σύγκριναν τον εντοπισμό ζιζανίων σε δύο

περιπτώσεις (i. μόνο έγχρωμες εικόνες και ii. έγχρωμες και πολυφασματικές εικόνες) και πέτυχαν ακρίβεια άνω του 0.9. Οι Pflanz et al. (2018) εξέτασαν τη τεχνική Bag of Visual Words (BOVM) για τη δημιουργία χαρτών ζιζανίων μέσω ταξινόμησης ζιζανίων από εικόνες που λήφθηκαν σε χαμηλό υψόμετρο (1 και 6 μέτρα) με ΣμηΕΑ σε καλλιέργεια σιταριού για πέντε επιλεγμένα ζιζάνια (*Matricaria recutita* - χαμομήλι, *Papaver rhoeas* - παπαρούνα, *Veronica hederifolia* - βερόνικα, *Viola arvensis* - αγριοπανσές). Η εκπαίδευση έγινε με τη μέθοδο μηχανικής μάθησης Support Vector Machine και πέτυχαν αρκετά υψηλά αποτελέσματα χαρτογράφησης στο χαμομήλι, ενώ η βερόνικα και ο αγριοπανσές δεν αναγνωρίζονταν με τόση επιτυχία, αφού το μοντέλο σε πολλές περιπτώσεις δεν μπορούσε να διακρίνει τα φυτά μεταξύ τους.

2.5.2 Μεθοδολογία δημιουργίας χαρτών ζιζανίων από βίντεο ΣμηΕΑ

Πτήσεις μέσω ΣμηΕΑ για τη δημιουργία βάσης δεδομένων με σκοπό τον αυτοματοποιημένο εντοπισμό ζιζανίων, μπορούν να χρησιμοποιηθούν και για τη χαρτογράφηση ζιζανίων στον αγρό (precision weed mapping). Οι πτήσεις ΣμηΕΑ καταγράφουν μαζί με την πτήση, ένα αρχείο μορφής .srt, το οποίο περιέχει σε μορφή κειμένου τα metadata της κάθε πτήσης, όπως είναι η λήψη του κάθε καρέ εικόνας, το ύψος πτήσης, τη χρονοσήμανση λήψης και το γεωγραφικό ύψος και πλάτος. Αξίζει να σημειωθεί ότι στις πτήσεις που πραγματοποιήθηκαν, το ΣμηΕΑ λάμβανε βίντεο και έτσι έγινε η εξαγωγή των ληφθέντων καρέ εικόνας για να αναλυθεί ο χάρτης "καρέ προς καρέ".

Για τη δημιουργία χαρτών ζιζανίων, χρειάζεται η μετατροπή του αρχείου .srt σε μορφή συμβατή με το λογισμικό επεξεργασίας που θα επιλεγθεί για τη δημιουργία χαρτών (Παράρτημα ΙΙ, Πρόγραμμα 2), όπως είναι για παράδειγμα το QGIS (QGIS Computer Software, 2025). Ο χάρτης που θα παραχθεί (Εικόνα 1.4.1-31), περιέχει με μπλε σημεία (vectors) τα καρέ που έχουν παραχθεί από το ΣμηΕΑ.



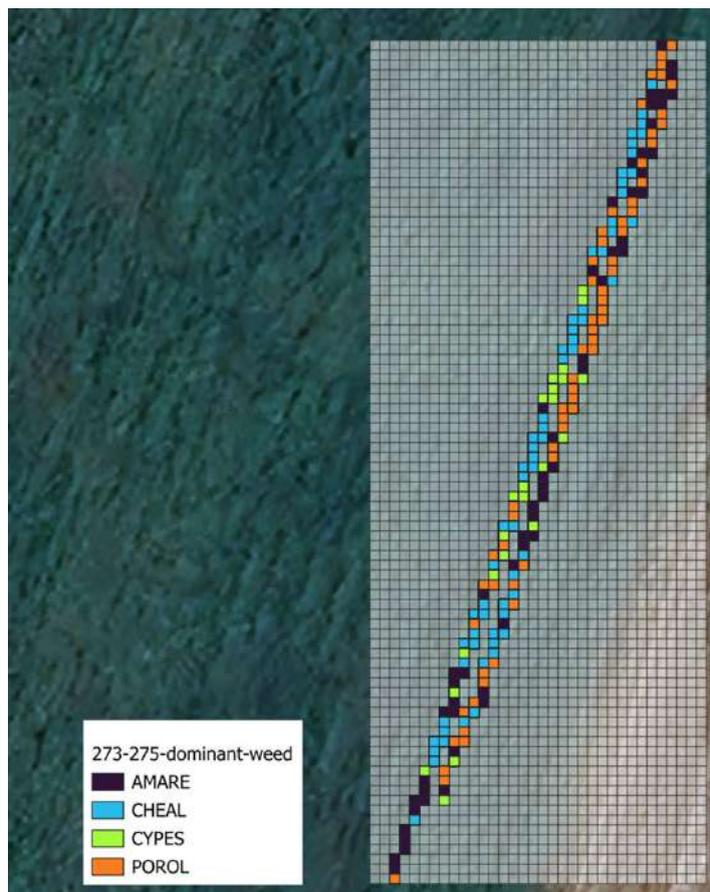
Εικόνα 1.4.1-31: Δύο από τα χωράφια στα οποία πραγματοποιήθηκε πτήση με ΣμηΕΑ. Οι μπλε κουκίδες απεικονίζουν τα καρέ εικόνας που λήφθηκαν κατά τη διάρκεια κάθε πτήσης.

2.5.2.1 Χάρτες επικρατέστερου (κυρίαρχου) ζιζανίου

Η υποενότητα 2.5.2.1 παρουσιάζει τη χαρτογράφηση ζιζανίων τα οποία παρουσιάζονται κατά πλειοψηφία σε κάθε καρτέ. Η κάθε χρωματισμένη κουκίδα (vector) αντιστοιχεί στο ζιζάνιο που εμφανίστηκε περισσότερες φορές συγκριτικά με τα άλλα, δηλαδή μωβ αν τα περισσότερα ήταν βλίτα ("AMARE"), μπλε αν τα περισσότερα ήταν λουβουδιές ("CHEAL"), πράσινη αν τα περισσότερα ήταν κύπερες ("CYPES") και πορτοκαλί αν τα περισσότερα ήταν άντρακλα ("POROL"). Το πρόγραμμα που χρησιμοποιήθηκε για τη μετατροπή των αρχείων με το επικρατέστερο ζιζάνιο παρουσιάζεται στο Παράρτημα 2 - Πρόγραμμα 3. Αφού φορτωθούν και τα δύο είδη αρχείων (.srt με metadata και αντιστοιχία των προβλέψεων του μοντέλου αναγνώρισης σε κάθε καρτέ εικόνας), μπορεί να παραχθεί ένας χάρτης ζιζανίων όπως φαίνεται στις εικόνες 1.4.1-32 και 1.4.1-33.



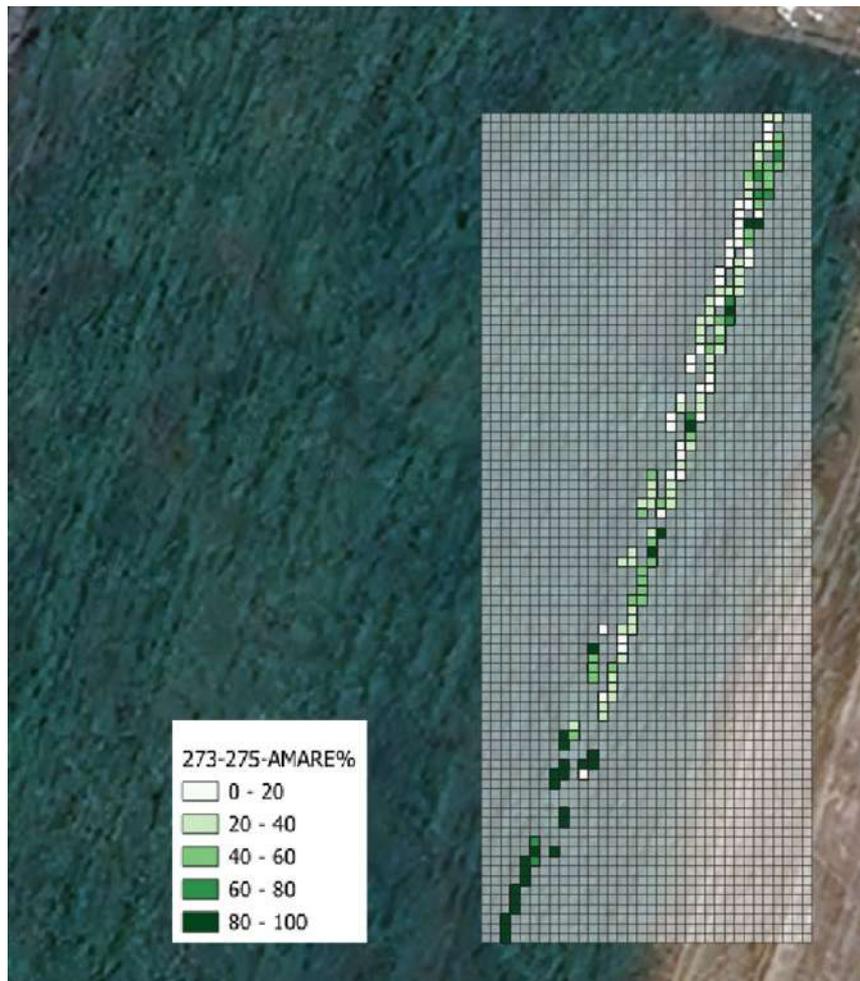
Εικόνα 1.4.1-32: Δημιουργία χαρτών ζιζανίων με το κάθε χρώμα να αντιστοιχεί στο επικρατέστερο ζιζάνιο ανά καρτέ λήψης.



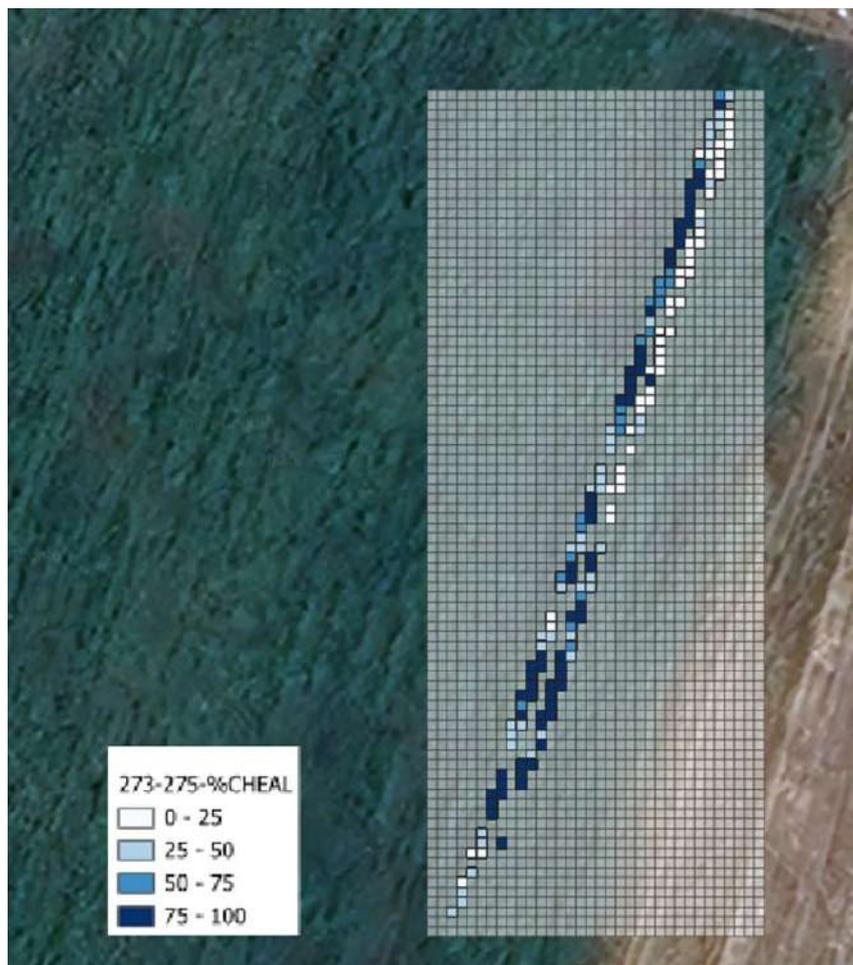
Εικόνα 1.4.1-33: Δημιουργία χαρτών ζιζανίων με το κάθε χρώμα να αντιστοιχεί στο επικρατέστερο ζιζάνιο ανά καρτέ λήψης.

2.5.2.2 Χάρτες σχετικής πυκνότητας ζιζανίων

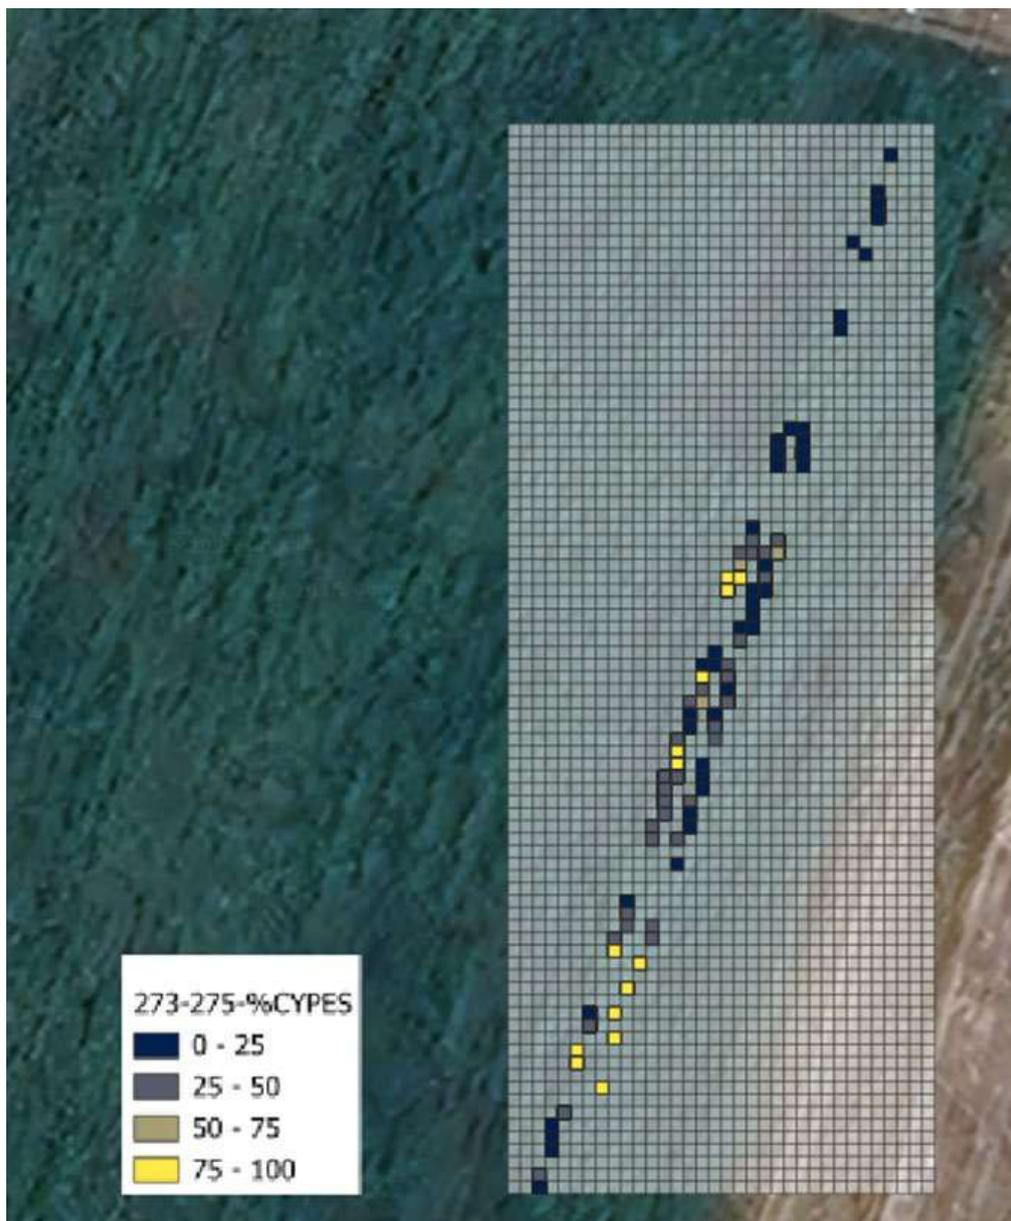
Παραπάνω αναφέρθηκε η περίπτωση απεικόνισης ζιζανίων ως ένα χρώμα για το ζιζάνιο που εμφανίζεται περισσότερο (κυρίαρχο). Εδώ παρουσιάζεται μία δεύτερη προσέγγιση, η οποία εξετάζει το ποσοστό ζιζανιοκάλυψης ανά καρτέ εικόνας, καθώς σε πολλές λήψεις αναγνωρίζεται πάνω από ένα είδος ζιζανίου. Το πρόγραμμα 3 (Παράρτημα ΙΙ) συγχωνεύει τις προβλέψεις του μοντέλου αναγνώρισης και τα metadata που παρήχθησαν από τα αρχεία .srt (Πρόγραμμα 1) και εμφανίζει το ποσοστό ζιζανιοκάλυψης ανά ζιζάνιο, σε αντίθεση με το Πρόγραμμα 2 που εμφανίζει μόνο το κυρίαρχο ζιζάνιο ανά καρτέ. Με αυτόν τον τρόπο δημιουργούνται χάρτες σχετικής πυκνότητας των ζιζανίων ενδιαφέροντος (εικόνες 1.4.1-34 - 1.4.1-37).



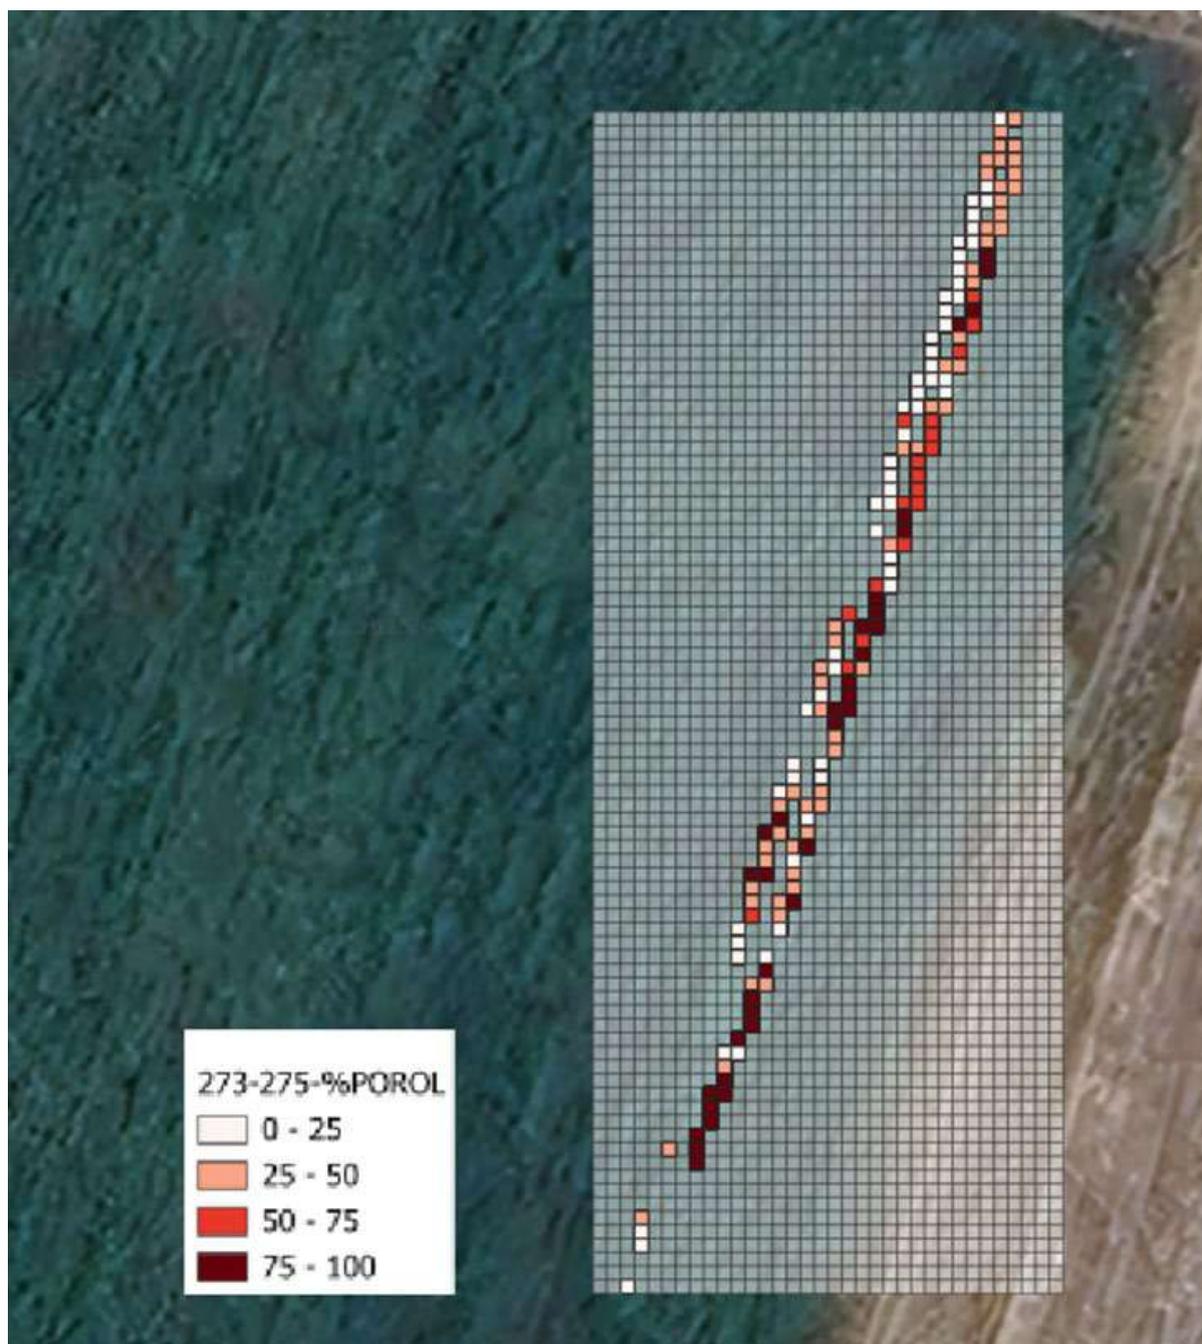
Εικόνα 1.4.1-34: Απεικόνιση σχετικής πυκνότητας κάλυψης βλίτου ("AMARE") συγκριτικά με τα υπόλοιπα ζιζάνια.



Εικόνα 1.4.1-35: Απεικόνιση σχετικής πυκνότητας κάλυψης λουβουδιάς ("CHEAL") συγκριτικά με τα υπόλοιπα ζιζάνια.



Εικόνα 1.4.1-36: Απεικόνιση σχετικής πυκνότητας κάλυψης κύπερης ("CYPES") συγκριτικά με τα υπόλοιπα ζιζάνια.



Εικόνα 1.4.1-37: Απεικόνιση σχετικής πυκνότητας κάλυψης αντράκλας ("POROL") συγκριτικά με τα υπόλοιπα ζιζάνια.

2.5.2.3 Χάρτες απόλυτης πυκνότητας ζιζανίων

Στην υποενότητα 2.5.2.3 παρουσιάστηκε η περίπτωση χαρτογράφησης ζιζανίων, στην οποία απεικονίζεται κάθε ζιζάνιο σε σχετικά ποσοστά κάλυψης, συγκριτικά με τα υπόλοιπα. Η παρούσα υποενότητα θα παρουσιάσει την απόλυτη πυκνότητα ζιζανίων ανά καρτέ, αποτυπώνοντας τα αντίστοιχα εύρη πλήθους τού κάθε είδους με διαφορετικό χρωματισμό (Ειόνες 1.4.1-38 - 1.4.1-41). Για τη δημιουργία αυτών των χαρτών

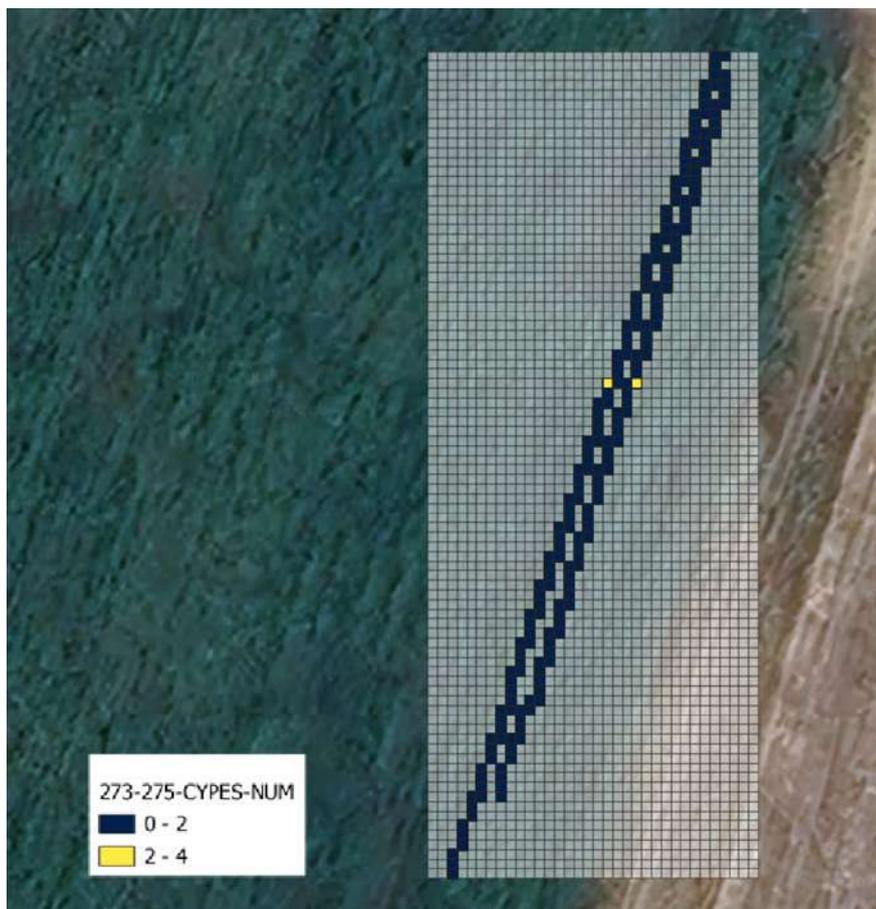
αναπτύχθηκαν δύο προγράμματα που παρουσιάζονται στο Παράρτημα ΙΙ (Προγράμματα 4i και 4ii).



Εικόνα 1.4.1-38: Απεικόνιση απόλυτης πυκνότητας κάλυψης βλίτου ("AMARE"), ανεξάρτητα από την εμφάνιση άλλων ζιζανίων.



Εικόνα 1.4.1-39: Απεικόνιση απόλυτης πυκνότητας κάλυψης λουβουδιάς ("CHEAL"), ανεξάρτητα από την εμφάνιση άλλων ζιζανίων.



Εικόνα 1.4.1-40: Απεικόνιση απόλυτης πυκνότητας κάλυψης κύπερης ("CYPES"), ανεξάρτητα από την εμφάνιση άλλων ζιζανίων.



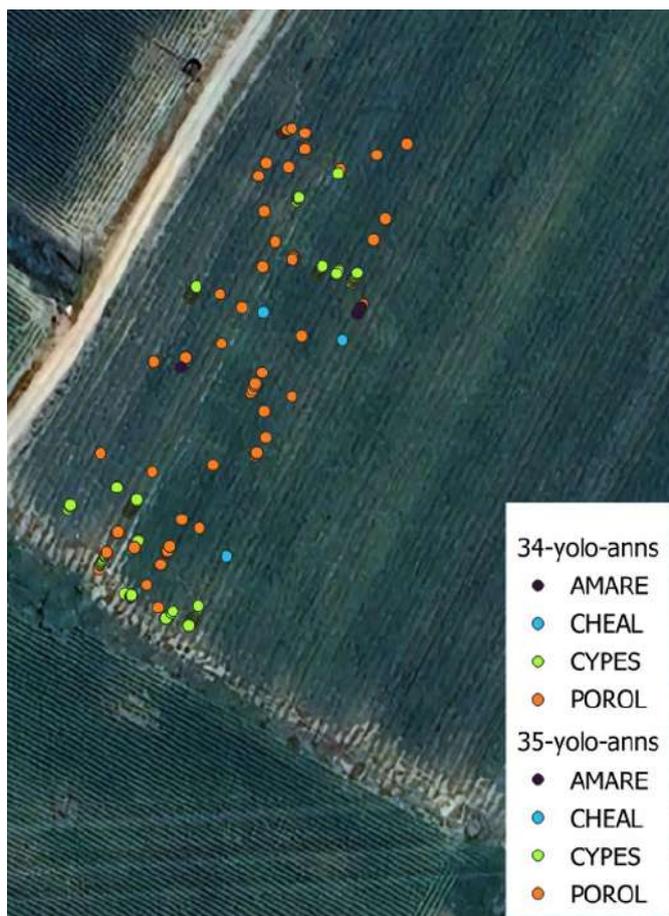
Εικόνα 1.4.1-41: Απεικόνιση απόλυτης πυκνότητας κάλυψης αντράκλας ("POROL"), ανεξάρτητα από την εμφάνιση άλλων ζιζανίων.

2.5.3 Επαλήθευση δημιουργίας χαρτών ζιζανίων σε νέα δεδομένα

Η ενότητα 2.5.2 ασχολήθηκε μεθοδικά με τη δημιουργία χαρτών ζιζανίων μέσω των προβλέψεων του επιλεγμένου μοντέλου αναγνώρισης στη βάση δεδομένων που δημιουργήθηκε από εικόνες που λήφθηκαν τον Μάιο του 2024. Η παρούσα ενότητα επαληθεύει τη χρήση του μοντέλου για τη δημιουργία χαρτών ζιζανίων σε νέα δεδομένα, κάτι το οποίο αποτελεί κρίσιμο μέτρο για την αξιολόγηση ενός μοντέλου. Τα βίντεο λήφθηκαν σε νέα καλλιεργητική περίοδο (Μάιος 2025) σε καλλιέργεια τομάτας και σε διαφορετικά αγροτεμάχια. Θα ακολουθήσουν οι υποενότητες 2.5.3.1, 2.5.3.2 και 2.5.3.3, που θα εφαρμόσουν τις τεχνικές που αναφέρθηκαν στις υποενότητες 2.5.2.1, 2.5.2.2 και 2.5.2.3, αντίστοιχα, στα νέα δεδομένα.

2.5.3.1 Χάρτες επικρατέστερου (κυρίαρχου) ζιζανίου

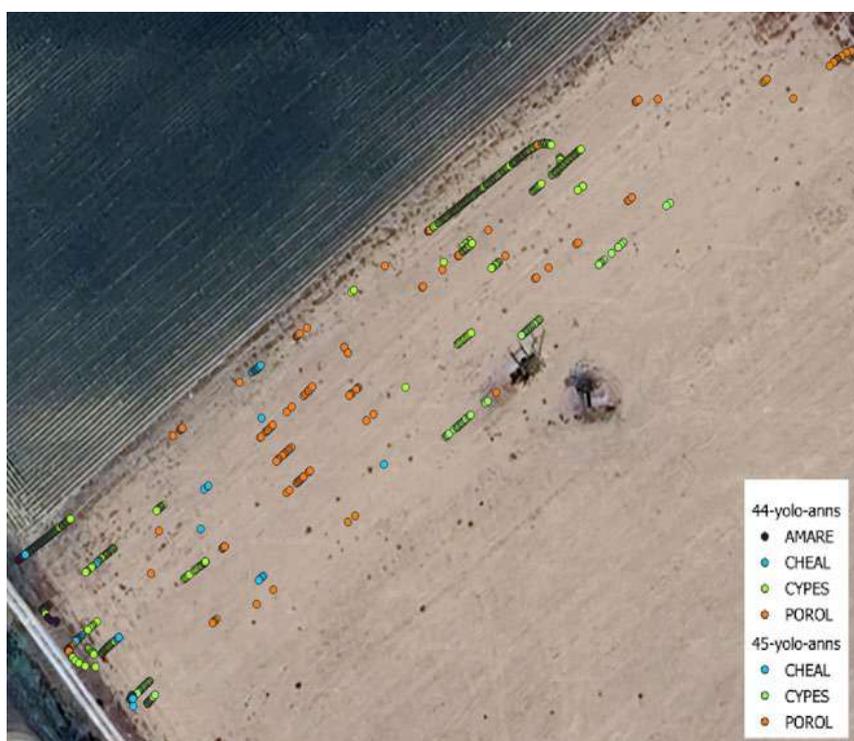
Αφού προηγήθηκε η επεξεργασία που αναφέρθηκε στην ενότητα 2.5.2.1, παρήχθησαν οι νέοι χάρτες ζιζανίων για τα τους νέους αγρούς, με κωδικούς "34", "35", "39", "44", "45", "56" και "57". Ακολουθούν οι χάρτες κυρίαρχου ζιζανίου κατά σειρά, για τους νέους αγρούς επαλήθευσης του μοντέλου, για τη χρονιά 2025 (εικόνες 1.4.1-41 - 1.4.1-45).



Εικόνα 1.4.1-42: Χάρτης επικρατέστερου ζιζανίου για τους αγρούς με κωδικό "34" και "35".



Εικόνα 1.4.1-43: Χάρτης επικρατέστερου ζιζανίου για τον αγρό με κωδικό "39".



Εικόνα 1.4.1-44: Χάρτης επικρατέστερου ζιζανίου για τους αγρούς με κωδικό "44" και "45".



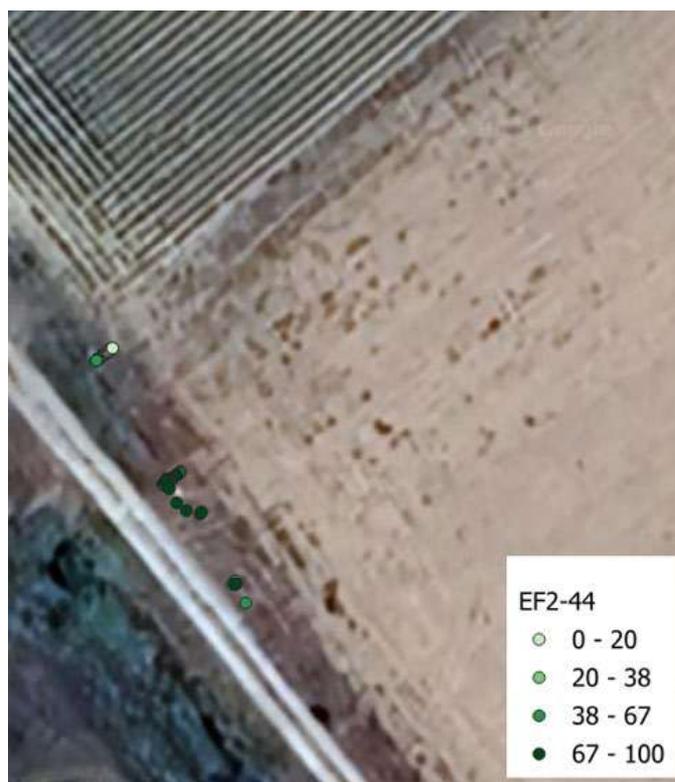
Εικόνα 1.4.1-45: Χάρτης επικρατέστερου ζιζανίου για τους αγρούς με κωδικό "56" και "57".

2.5.3.2 Χάρτες σχετικής πυκνότητας ζιζανίων

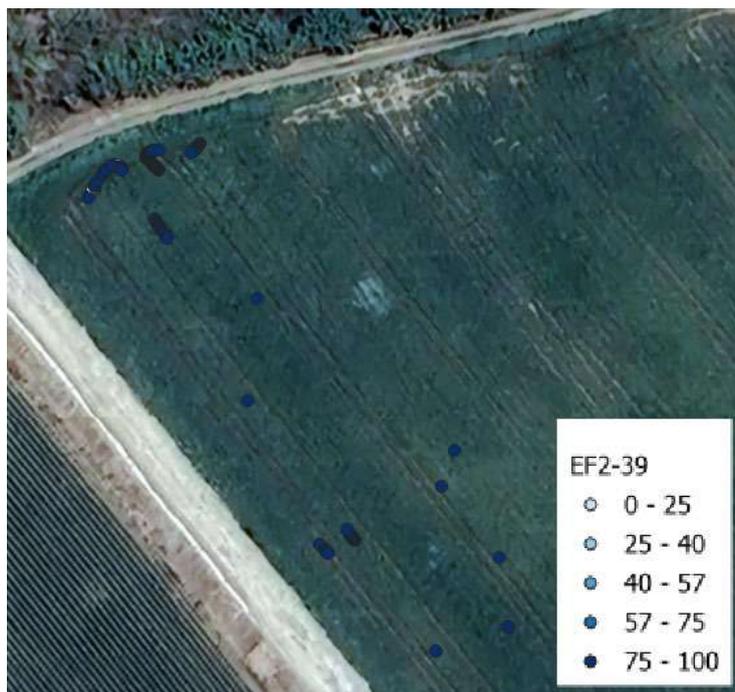
Αφού γίνει η μετατροπή των στοιχείων, μπορούν να δημιουργηθούν οι αντίστοιχοι χάρτες της υποενότητας 2.5.2.2, δηλαδή της σχετικής πυκνότητας ζιζανίων. Αξίζει να σημειωθεί ότι οι καινούριοι χάρτες δεν έχουν τόσες προβλέψεις όσο οι πρώτοι του 2024, καθώς υπήρχαν λιγότεροι εντοπισμοί ζιζανίων σε κάποιες περιπτώσεις. Οι χάρτες σχετικής πυκνότητας ζιζανίων για τη νέα καλλιεργητική περίοδο παρουσιάζονται στις παρακάτω εικόνες, οι οποίες περιέχουν για κάθε ζιζάνιο έναν ξεχωριστό χάρτη. Αξίζει να σημειωθεί ότι οι αγροί με κωδικό "45", "56" και "57" δεν περιείχαν βλίτα, ενώ οι εντοπισμοί βλίτων γενικότερα ήταν σε αρκετά χαμηλό ποσοστό εν συγκρίσει με τα υπόλοιπα ζιζάνια ενδιαφέροντος. Κατά σειρά, ακολουθούν οι χάρτες για τους αγρούς με τους περισσότερους εντοπισμούς ζιζανίων ("39", "44" και "45) ως εξής: "AMARE", "CHEAL", "CYPES" και "POROL".



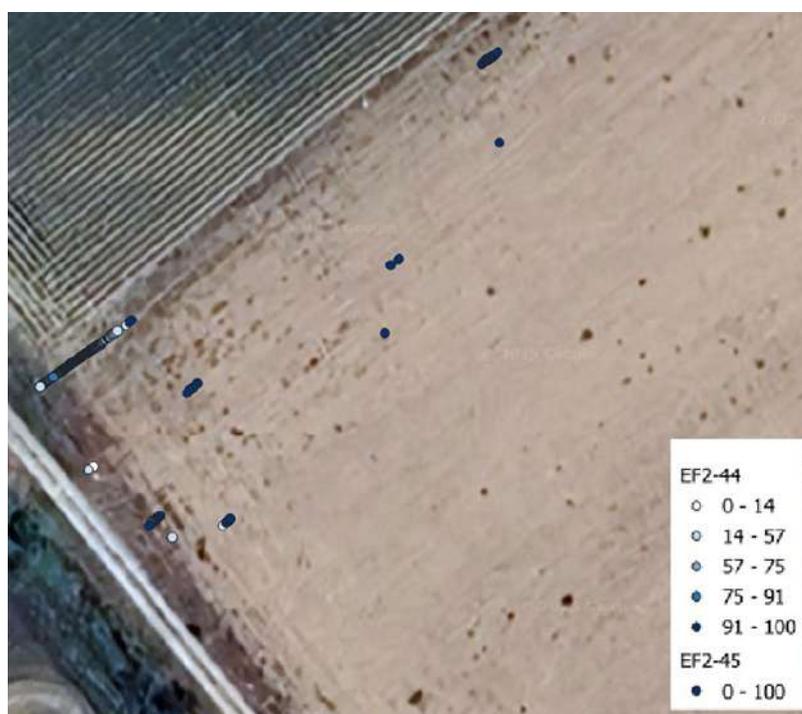
Εικόνα 1.4.1-46: Χάρτης με σχετικό ποσοστό κάλυψης του ζιζανίου "AMARE" στον αγρό "39".



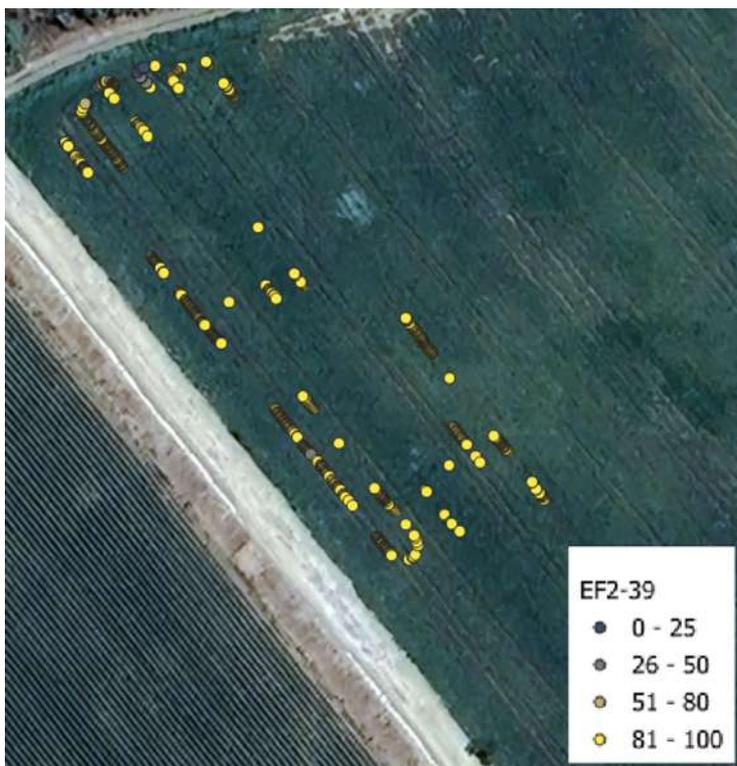
Εικόνα 1.4.1-47: Χάρτης με σχετικό ποσοστό κάλυψης του ζιζανίου "AMARE" στον αγρό "44" (ο "45" δεν είχε βλίτα).



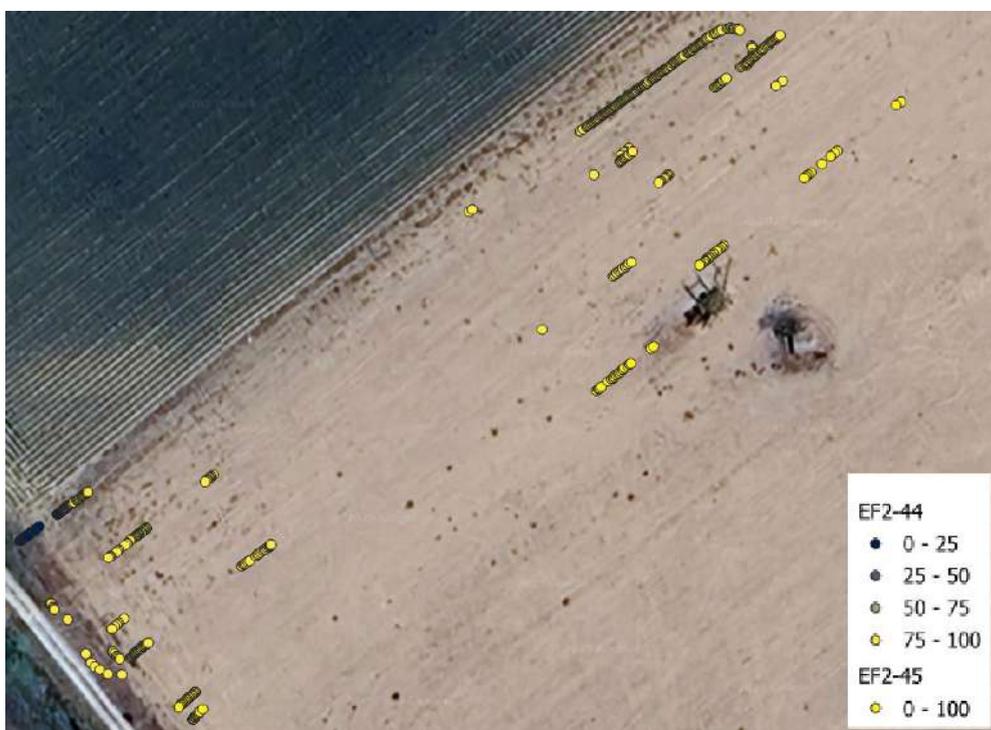
Εικόνα 1.4.1-48: Χάρτης με σχετικό ποσοστό κάλυψης του ζιζανίου "CHEAL" στον αγρό "39".



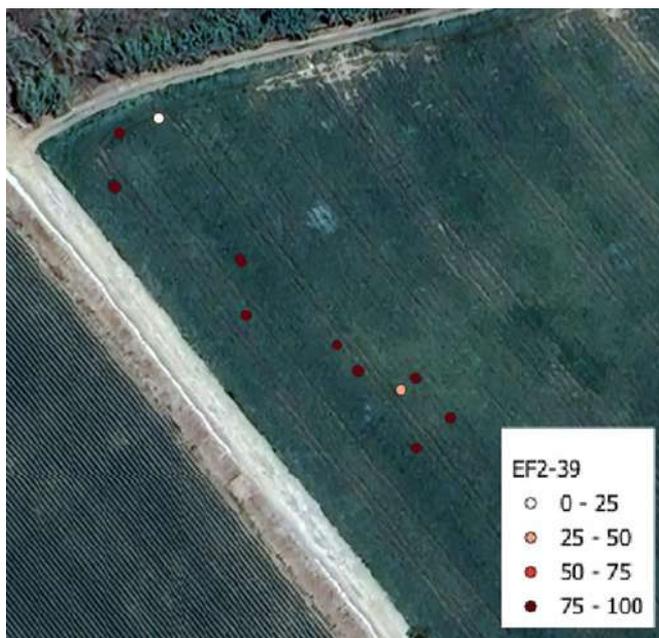
Εικόνα 1.4.1-49: Χάρτης με σχετικό ποσοστό κάλυψης του ζιζανίου "CHEAL" στους αγρούς "44" και "45".



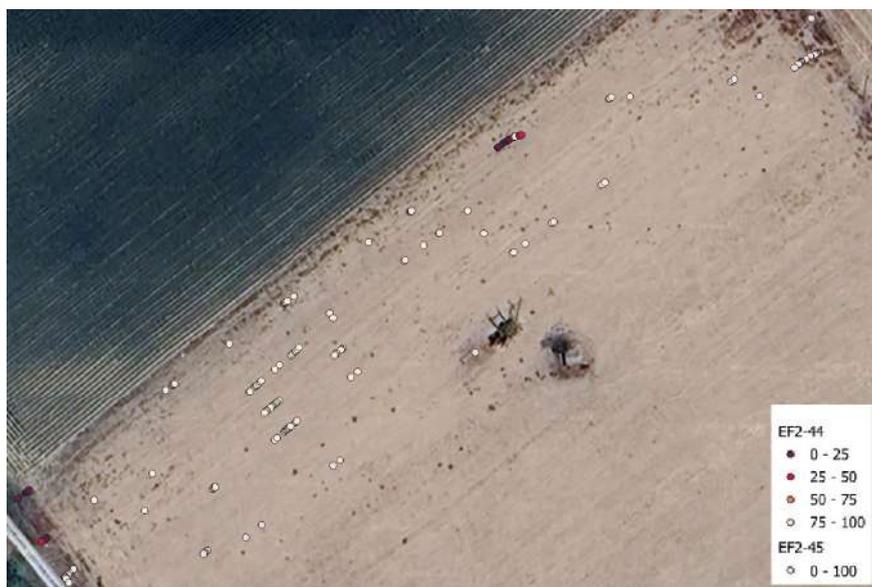
Εικόνα 1.4.1-50: Χάρτης με σχετικό ποσοστό κάλυψης του ζιζανίου "CYPES" στον αγρό "39".



Εικόνα 1.4.1-51: Χάρτης με σχετικό ποσοστό κάλυψης του ζιζανίου "CYPES" στους αγρούς "44" και "45".



Εικόνα 1.4.1-52: Χάρτης με σχετικό ποσοστό κάλυψης του ζιζανίου "POROL" στον αγρό "39".



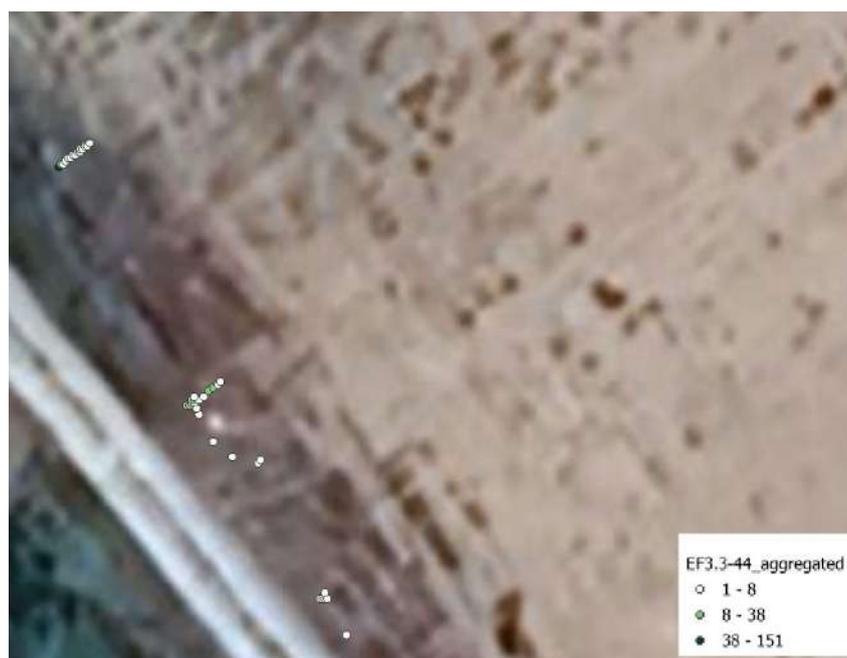
Εικόνα 1.4.1-53: Χάρτης με σχετικό ποσοστό κάλυψης του ζιζανίου "POROL" στους αγρούς "44" και "45".

2.5.3.3 Χάρτες απόλυτης πυκνότητας ζιζανίων

Αντίστοιχα, η παρούσα υποενότητα παρουσιάζει τη δημιουργία χαρτών που απεικονίζουν την απόλυτη πυκνότητα των ζιζανίων, δηλαδή τον αριθμό των ζιζανίων που εντοπίζονται ανά κατηγορία, ανεξάρτητα από τα υπόλοιπα. Παρόμοια με την υποενότητα 2.5.2.3, ακολουθούν οι χάρτες για τους αγρούς με την απόλυτη πυκνότητα ζιζανίων ("39", "44" και "45) ως εξής: "AMARE", "CHEAL", "CYPES" και "POROL".



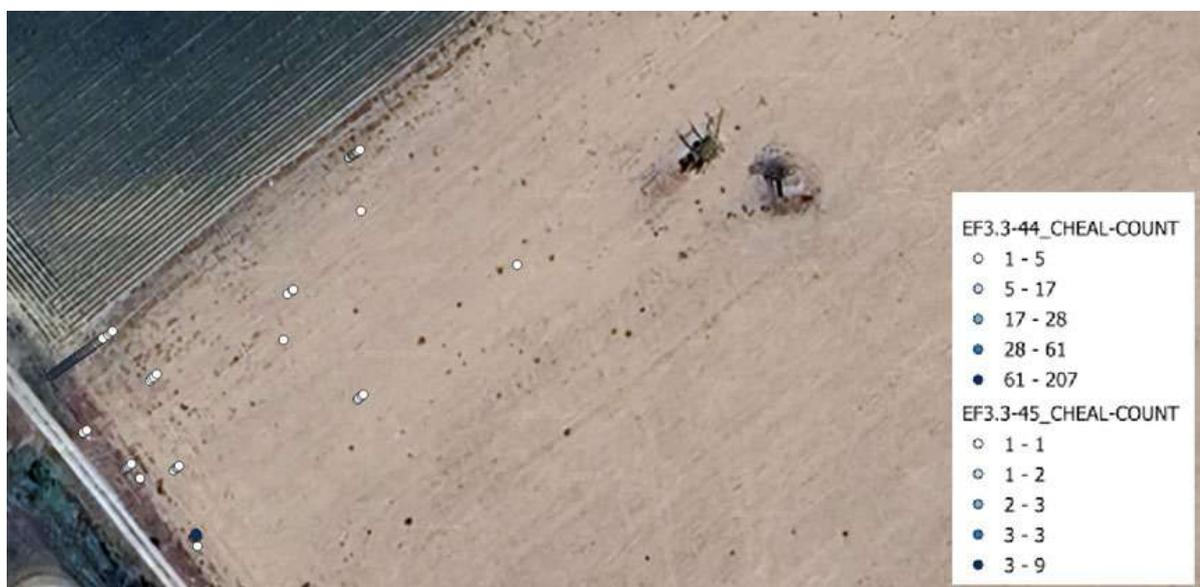
Εικόνα 1.4.1-54: Χάρτης με τον απόλυτο αριθμό κάλυψης του ζιζανίου "AMARE" για τον αγρό με κωδικό "39".



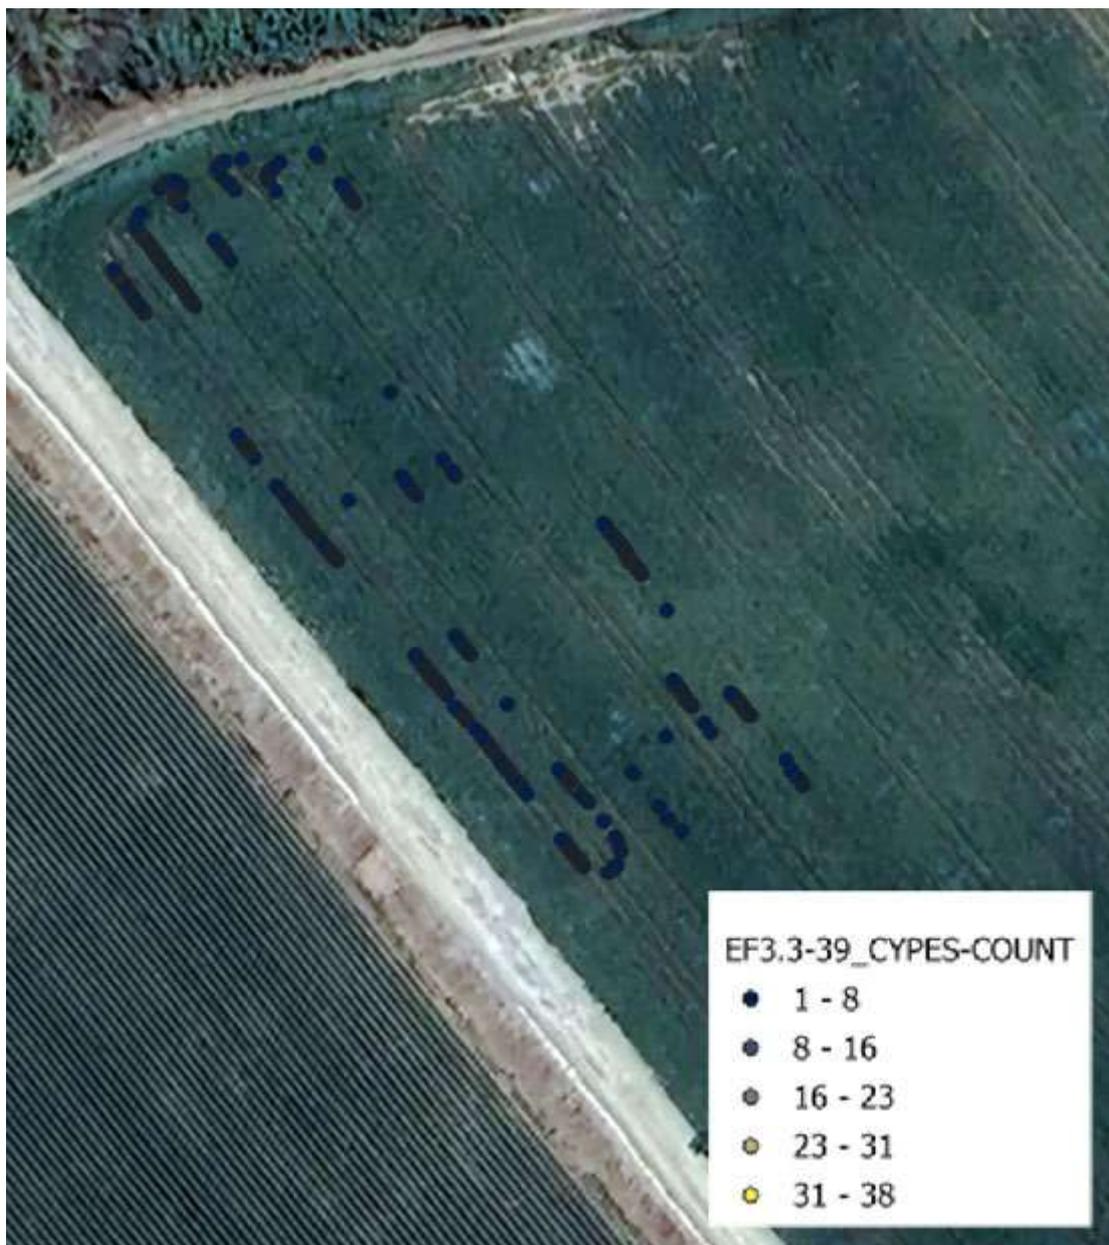
Εικόνα 1.4.1-55: Χάρτης με τον απόλυτο αριθμό κάλυψης του ζιζανίου "AMARE" τον αγρό με κωδικό "44".



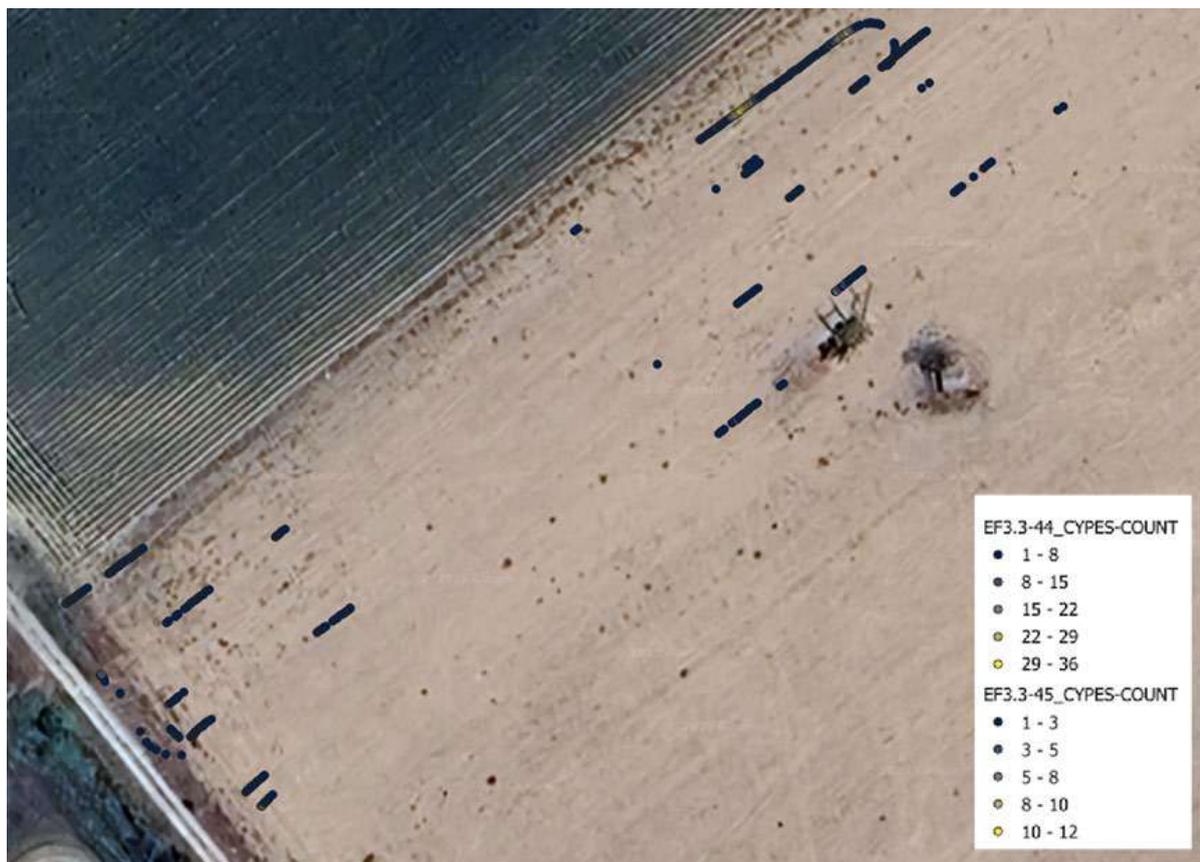
Εικόνα 1.4.1-56: Χάρτης με τον απόλυτο αριθμό κάλυψης του ζιζανίου "CHEAL" για τον αγρό με κωδικό "39".



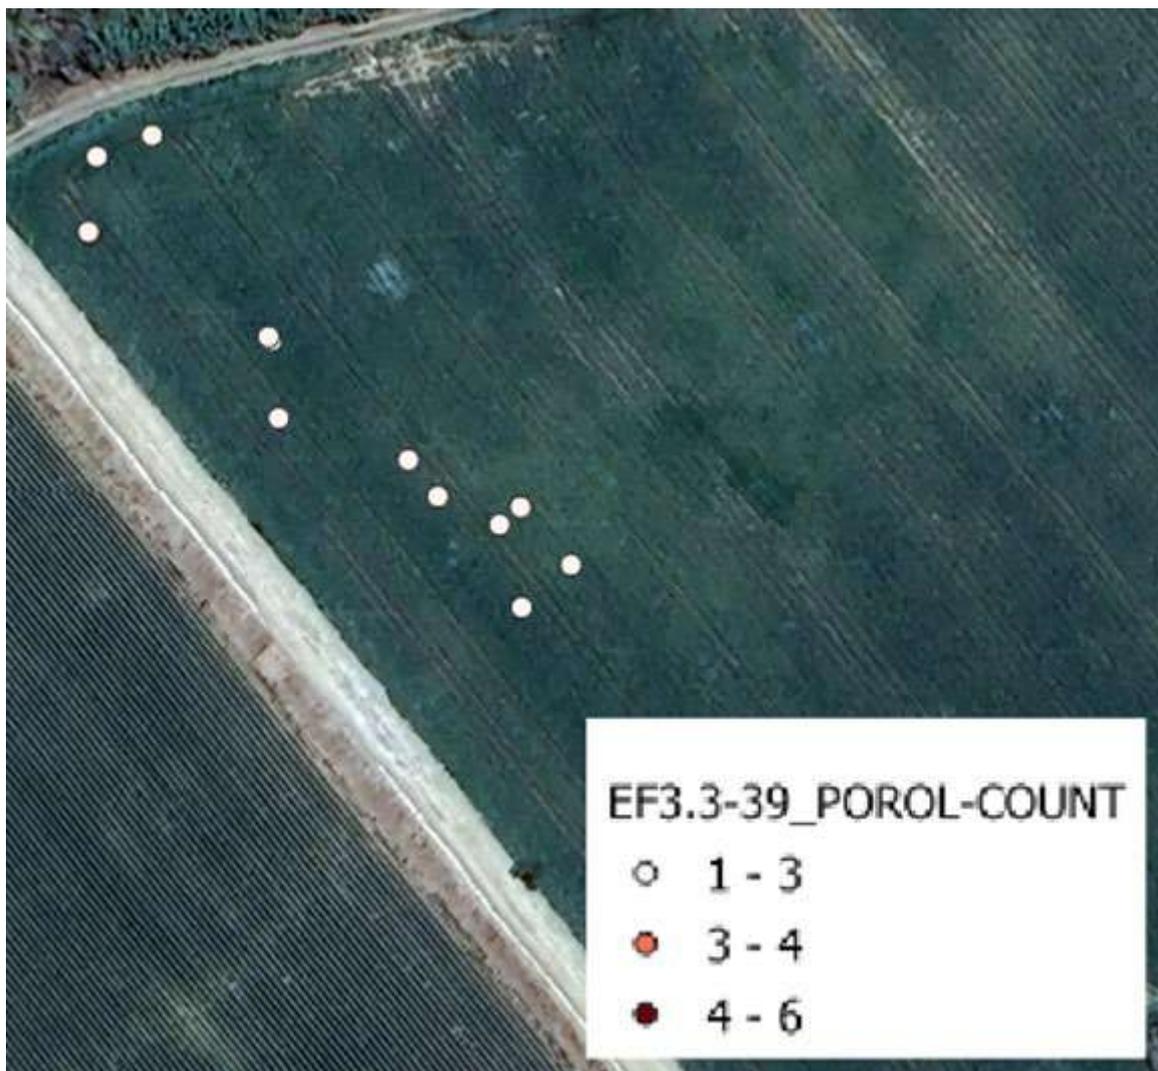
Εικόνα 1.4.1-57: Χάρτης με τον απόλυτο αριθμό κάλυψης του ζιζανίου "CHEAL" τους αγρούς "44" και "45".



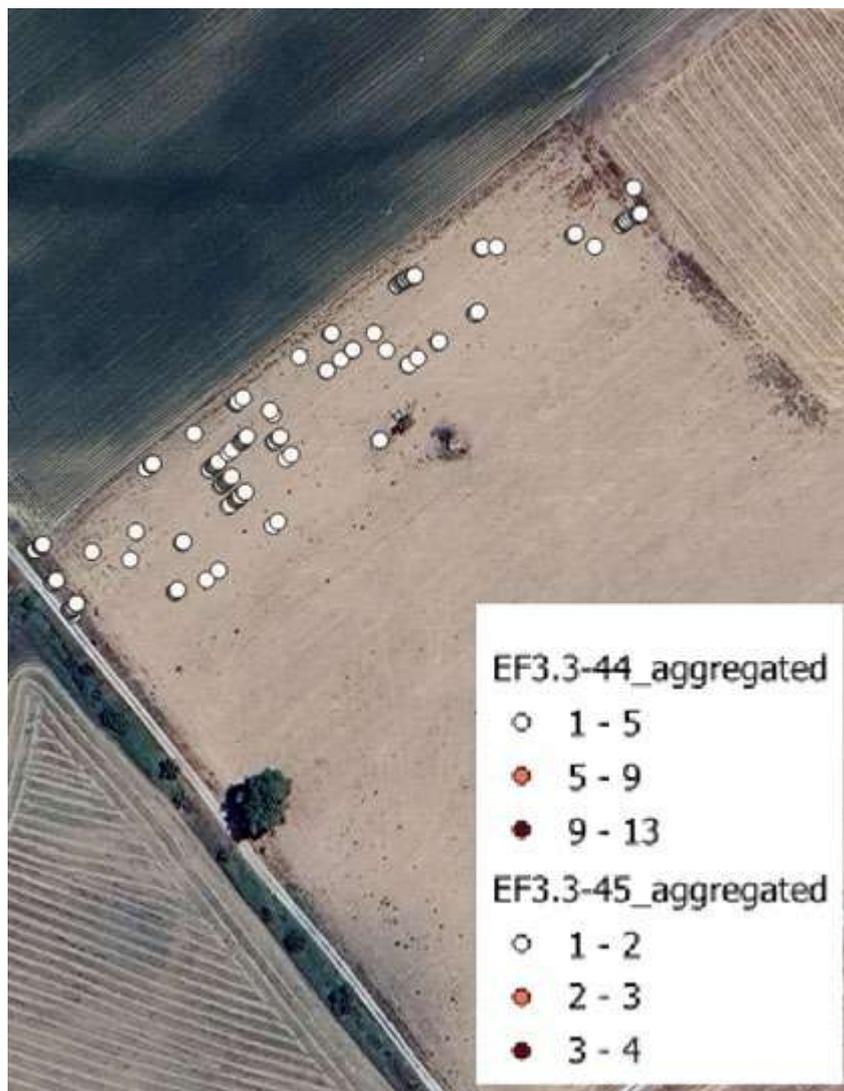
Εικόνα 1.4.1-58: Χάρτης με τον απόλυτο αριθμό κάλυψης του ζιζανίου "CYPES" για τον αγρό με κωδικό "39".



Εικόνα 1.4.1-59: Χάρτης με τον απόλυτο αριθμό κάλυψης του ζιζανίου "CYPES" για τους αγρούς "44" και "45".



Εικόνα 1.4.1-60: Χάρτης με τον απόλυτο αριθμό κάλυψης του ζιζανίου "POROL" για τον αγρό με κωδικό "39".



Εικόνα 1.4.1-61: Χάρτης με τον απόλυτο αριθμό κάλυψης του ζιζανίου "POROL" για τους αγρούς "44" και "45".

2.6 Συζήτηση

Τα μοντέλα βαθιάς μάθησης έχουν χρησιμοποιηθεί σε μεγάλο βαθμό τα τελευταία χρόνια για τον αυτοματοποιημένο εντοπισμό ζιζανίων σε καλλιέργειες. Ο αυτοματοποιημένος εντοπισμός ζιζανίων σε συνθήκες αγρού είναι αρκετά απαιτητικός, καθώς προϋποθέτει την ανάλυση εικόνων που έχουν ληφθεί σε μη-ελεγχόμενες συνθήκες, οι οποίες ενδέχεται να μην είναι πάντα ιδανικές για τη λήψη εικόνων. Άλλο σημαντικό πρόβλημα είναι το ύψος λήψης των εικόνων, καθώς σε μεγάλο ύψος τα ζιζάνια δεν μπορούν να αναγνωριστούν με ακρίβεια, λόγω του μικρότερου σχετικού μεγέθους τους στη συνολική εικόνα. Οι εικόνες υψηλής ανάλυσης προκαλούν συχνά προβλήματα μνήμης στο προς ανάπτυξη μοντέλο, οδηγώντας την αναγκαστική μείωση της ανάλυσής τους, με ανάλογες επιπτώσεις στην απόδοση των μοντέλων που εκπαιδεύονται με αυτές. Η δημιουργία ετικετών σε ένα μεγάλο πλήθος εικόνων που

είναι απαραίτητες για την εκπαίδευση των μοντέλων, είναι επίσης μία χρονοβόρος διαδικασία που απαιτεί εξειδικευμένο προσωπικό. Η δημιουργία μιας βάσης δεδομένων υψηλής ποικιλομορφίας, με διαφορετικές συνθήκες εδάφους, ύψους, ακόμα και μέσω λήψης (είτε μέσω ΣμηΕΑ είτε κάμερας), μπορεί να οδηγήσει σε σαφώς υψηλότερα ποσοστά επιτυχούς αναγνώρισης.

Η βάση δεδομένων που δημιουργήθηκε και αναπτύχθηκε στην παρούσα μελέτη, περιείχε μεγάλη ανομοιομορφία στις κλάσεις δεδομένων (υποενότητα 2.2.3), κάτι το οποίο αποτελεί συχνό πρόβλημα για την αυτοματοποιημένη αναγνώριση ζιζανίων. Η ανομοιομορφία στη βάση δεδομένων προκαλεί προβλήματα μεροληψίας (biased model) ως προς την κλάση που υπερτερεί αριθμητικά, καθώς και μείωση της απόδοσης λόγω overfitting (Ali-Gombe & Elyan, 2019), δηλαδή της "υπερεκπαίδευσης" των μοντέλων αποκλειστικά στα δεδομένα εκπαίδευσης που οδηγεί στη μείωση της δυνατότητας γενίκευσης (generalization), που αποτελεί ένα πολύ βασικό απαιτούμενο χαρακτηριστικό (το να μπορούν να λειτουργήσουν αποδοτικά και σε νέα δεδομένα). Παρόλη τη δυσκολία στη διαχείριση της ανομοιομορφίας των εκπαιδευόμενων κλάσεων, το επιλεγμένο μοντέλο έδωσε αρκετά ικανοποιητικά αποτελέσματα με βάση τα μέτρα αξιολόγησης (Precision=0.776, Recall=0.777, mAP_{50} =0.828 και F1-score=0.776). Η πραγματική αξιολόγηση όμως του μοντέλου είναι αρκετά δύσκολη, καθώς η βάση δεδομένων εκπαίδευσής του βασίζεται σε εικόνες διαφορετικού ύψους (3-10μ.), όπου όσο μεγαλύτερο το ύψος, τόσο πιο δύσκολη ήταν η αναγνώριση. Το μοντέλο επαληθεύτηκε και σε πτήσεις της επόμενης καλλιεργητικής περιόδου από αυτήν των δεδομένων εκπαίδευσης (2025) σε καλλιέργεια τομάτας, εντοπίζοντας και αναγνωρίζοντας επαρκώς τα ζιζάνια ενδιαφέροντος. Τα αποτελέσματα δεν ήταν τόσο καλά συγκριτικά με των πτήσεων του 2024, κρίνονται όμως άκρως ικανοποιητικά.

Οι πτήσεις σε χαμηλότερο ύψος σίγουρα προσδίδουν καλύτερα αποτελέσματα αναγνώρισης, αλλά δημιουργούν άλλες προκλήσεις, όπως την ανάγκη για μεγαλύτερη διάρκεια μπαταρίας, αφού οι πτήσεις σε χαμηλό ύψος είναι και πιο χρονοβόρες για την κάλυψη συγκεκριμένης περιοχής. Άλλο σημαντικό πρόβλημα είναι η ανάγκη για μεγαλύτερο αποθηκευτικό χώρο, λόγω χαμηλότερης επικάλυψης των χωραφιών σε πτήσεις χαμηλού ύψους. Υπάρχουν πολλά σημεία στα οποία το μοντέλο χρήζει βελτίωσης, όπως είναι η εκπαίδευση σε μεγαλύτερο εύρος συνθηκών (διαφορετικός φωτισμός, διαφορετικές συστάσεις εδαφών, διαφορετικά ύψη λήψης), με περισσότερα είδη ζιζανίων σε διαφορετικά στάδια ανάπτυξης.

Η χαρτογράφηση ζιζανίων που παρουσιάστηκε στην υποενότητα 2.5 ακολούθησε διαφορετική προσέγγιση από αυτή των ερευνών που αναφέρθηκαν, διότι δεν πραγματοποιήθηκε πτήση ΣμηΕΑ σε μεγάλο ύψος και δεν εφαρμόστηκε image-stitching, συνεπώς δεν δημιουργήθηκε ορθοφωτοχάρτης που να περιέχει την καλλιέργεια ενδιαφέροντος (τομάτα) και τα εντοπισμένα ζιζάνια. Οι χάρτες που παρουσιάστηκαν μπορούν να χρησιμοποιηθούν ως μία πρώτη εικόνα για τον παραγωγό, ενδεικτική για την κατάσταση που επικρατεί στον αγρό σχετικά με τη ζιζανιοκάλυψη της καλλιέργειας, το ποσοστό κάλυψης αλλά και για τον απόλυτο πληθυσμό των ζιζανίων που εντοπίζονται.

Ως προς τις συγκεκριμένες αναγνωρίσεις του μοντέλου, το βλίτο ήταν το λιγότερο εντοπισμένο ζιζάνιο σε σχέση με όλα τα υπόλοιπα και επιπλέον, τα στάδια ανάπτυξης του μοιάζουν αρκετά με άλλα είδη του ίδιου γένους (*Amaranthus palmeri*, *Amaranthus blitum*). Ο εμπλουτισμός της βάσης δεδομένων με περισσότερες εικόνες ενδεχομένως να οδηγήσει σε αρκετά υψηλότερα αποτελέσματα εντοπισμού. Η λουβουδιά έδωσε τα καλύτερα αποτελέσματα αναγνώρισης, τα φύλλα της ήταν αρκετά διακριτά σε όλα τα στάδια αναγνώρισης και πέτυχε τα υψηλότερα ποσοστά επιτυχούς εντοπισμού και αναγνώρισης (Precision 0.831, Recall 0.887). Η κύπερη παρόλο που είχε τις περισσότερες εμφανίσεις, δεν είχε τόσο υψηλά ποσοστά επιτυχούς αναγνώρισης όσο η λουβουδιά (Precision 0.763, Recall 0.735). Αυτό ενδεχομένως να οφείλεται στο γεγονός ότι και η κύπερη μοιάζει σε όλα τα στάδια ανάπτυξης και διακρινόταν αρκετά εύκολα. Το κυριότερο πρόβλημα στην αναγνώρισή της είναι ότι υπήρχε συχνά αλληλοεπικάλυψη των ζιζανίων μεταξύ τους (Εικόνα 1.4.1-62) και δεν ήταν εύκολη η αναγνώρισή της ως μεμονωμένο φυτό.



Εικόνα 1.4.1-62: Παράδειγμα μεγάλου αριθμού κύπερης σε ένα χωράφι δειγματοληψίας. Όπως φαίνεται, οι κύπερες "καλύπτουν" η μία την άλλη και έτσι η μεμονωμένη αναγνώριση της έγινε αρκετά δύσκολη.

Η αντράκλα είχε επίσης αρκετά χαμηλά αποτελέσματα. Αυτό ενδεχομένως να οφείλεται στο γεγονός ότι εικόνες της αντράκλας λήφθηκαν σε αρκετά στάδια ανάπτυξης και αυτό να οδήγησε στην αδυναμία του μοντέλου να την αναγνωρίζει επαρκώς, όπως συνέβη και με το βλίτο. Τα διαφορετικά στάδια ανάπτυξης των ζιζανίων είναι αρκετά συχνό πρόβλημα στην αυτοματοποιημένη αναγνώριση ζιζανίων, καθώς ενδέχεται να διαφέρουν αρκετά από το αρχικό στο τελικό, με αποτέλεσμα το μοντέλο να μην αναγνωρίζει επαρκώς το ίδιο ζιζάνιο σε διαφορετικά στάδια ανάπτυξης, σε συνδυασμό και με το φαινόμενο της αλληλοεπικάλυψης (Εικόνες 1.4.1-63 και 1.4.1-64).



Εικόνα 1.4.1-63: Από αριστερά στα δεξιά, τρία στάδια ανάπτυξης της αντράκλας "POROL", με εμφανή διαφορά ανάπτυξης από το αρχικό στο τελικό (Πηγή: *Wisconsin Horticulture*, 2025).



1.4.1-64: Επικάλυψη ζιζανίων αντράκλας ("POROL") από τη βάση δεδομένων που αναπτύχθηκε, με αποτέλεσμα την αδυναμία δημιουργίας ξεχωριστών ετικετών.

Τέλος, υπάρχουν κάποια περιθώρια βελτίωσης όπως για παράδειγμα, ο εμπλουτισμός της βάσης δεδομένων σε σχέση με τα υπόλοιπα ζιζάνια, έτσι ώστε να μειωθεί το πρόβλημα ανομοιομορφίας στις εμφανίσεις των ζιζανίων. Ο εμπλουτισμός της βάσης δεδομένων για την εκπαίδευση των μοντέλων είναι κρίσιμος για τη βελτίωση των

μοντέλων αναγνώρισης, με εικόνες μεγάλης ευκρίνειας για επιλεγμένα ζιζάνια ενδιαφέροντος. Ως επιπλέον μέτρο αντιμετώπισης, χρειάζεται επίσης ο διαχωρισμός των σταδίων ανάπτυξης για να είναι η αναγνώριση πιο αποδοτική, καθώς η συγχώνευση όλων των σταδίων ανάπτυξης ως μία ενιαία κλάση ζιζανίου οδηγεί σε μεγαλύτερη αβεβαιότητα του μοντέλου ως προς την κατάλληλη αναγνώριση. Επιπλέον, θα πρέπει να γίνει η δοκιμή περισσότερων μοντέλων βαθιάς μάθησης με σκοπό την εύρεση των καταλληλότερων με βάση συγκεκριμένες παραμέτρους, όπως είναι ο συνολικός χρόνος εκπαίδευσης, ο χρόνος αναγνώρισης των ζιζανίων καθώς και το υπολογιστικό κόστος του κάθε μοντέλου.

3 ΣΥΝΟΨΗ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ

Η παρούσα εργασία μελέτησε τη δημιουργία μοντέλων βαθιάς μάθησης για τον αυτοματοποιημένο εντοπισμό ζιζανίων μέσω εικόνων RGB από Συστήματα μη Επανδρωμένων Αεροσκαφών (ΣμηΕΑ) και στη συνέχεια, χρησιμοποίησε τις προβλέψεις του τελικού μοντέλου αναγνώρισης για τη δημιουργία χαρτών ζιζανίων. Αφού προσδιορίστηκαν οι βασικές απαιτήσεις και προδιαγραφές για τη δημιουργία τέτοιων συστημάτων σε πραγματικές συνθήκες καλλιέργειας, δοκιμάστηκαν διάφοροι τύποι μοντέλων βαθιάς μάθησης (τόσο συνελκτικών νευρωνικών δικτύων όσο και πιο πρόσφατων μοντέλων τύπου vision transformers) για την ανάπτυξη του τελικού μοντέλου αυτοματοποιημένου εντοπισμού και αναγνώρισης τεσσάρων ειδών ζιζανίων σε καλλιέργεια τομάτας, το οποίο δοκιμάστηκε και αξιολογήθηκε. Τα αποτελέσματα ήταν αρκετά ικανοποιητικά, καθώς ανταποκρίνονται σε συνθήκες πραγματικού αγρού, ενώ εντοπίστηκαν αρκετά σημεία βελτίωσης για το μοντέλο συνολικά αλλά και ως προς το κάθε ζιζάνιο.

Συμπερασματικά, η χαρτογράφηση ζιζανίων μέσω εικόνων που έχουν ληφθεί από ΣμηΕΑ και η χρήση μοντέλων βαθιάς μάθησης, μπορούν να βοηθήσουν στην επιλεκτική διαχείριση ζιζανίων στον αγρό, συμβάλλοντας στη μείωση ζιζανιοκτόνων και συνεπώς, σε έναν πιο φιλικό προς το περιβάλλον τρόπο καταπολέμησής τους. Παράλληλα, οι χάρτες ζιζανίων που έχουν δημιουργηθεί με βάση τις προβλέψεις του μοντέλου αυτοματοποιημένης αναγνώρισης ζιζανίων μπορούν να χρησιμοποιηθούν σαν ένα πολύ καλό γνωστικό εργαλείο, ως προς το ποια είναι τα κυρίαρχα ζιζάνια σε ένα χωράφι, σε τι σχετικό ποσοστό, αλλά ακόμα και ποιο είναι το απόλυτο πλήθος εμφάνισής τους.

Ως μελλοντικές βελτιώσεις στο παρόν έργο μπορούν να θεωρηθούν ο εμπλουτισμός της βάσης δεδομένων με περισσότερα ζιζάνια, η διερεύνηση επιπλέον τύπων μοντέλων, ειδικά με το δεδομένο ότι τα μοντέλα αυτά εντάσσονται σε ένα ραγδαία αναπτυσσόμενο ερευνητικό πεδίο, αυτό της τεχνητής νοημοσύνης, και τέλος, η ακριβής γεω-αναφορά των προβλέψεων με σκοπό τη δημιουργία χαρτών ζιζανίων με συγκεκριμένες ποσότητες στοχευμένου ζιζανιοκτόνου, παρεμβαίνοντας με έναν πιο φιλικό για το περιβάλλον και τη δημόσια υγεία τρόπο εφαρμογής φυτοπροστατευτικών προϊόντων.

4 ΠΑΡΑΡΤΗΜΑ Ι

Βιβλιογραφικές Αναφορές

1. Ahmad, J., Muhammad, K., Ahmad, I., Ahmad, W., Smith, M. L., Smith, L. N., ... & Mehmood, I. (2018). Visual features based boosted classification of weeds for real-time selective herbicide sprayer systems. *Computers in Industry*, 98, 23-33.
2. Alam, M., Alam, M. S., Roman, M., Tufail, M., Khan, M. U., & Khan, M. T. (2020, April). Real-time machine-learning based crop/weed detection and classification for variable-rate spraying in precision agriculture. In *2020 7th international conference on electrical and electronics engineering (ICEEE)* (pp. 273-280). IEEE.
3. Almalky, A. M., & Ahmed, K. R. (2023). Deep learning for detecting and classifying the growth stages of *Consolida regalis* weeds on fields. *Agronomy*, 13(3), 934.
4. Ali-Gombe, A., & Elyan, E. (2019). MFC-GAN: Class-imbalanced dataset classification using multiple fake class generative adversarial network. *Neurocomputing*, 361, 212-221.
5. Barrero, O., & Perdomo, S. A. (2018). RGB and multispectral UAV image fusion for Gramineae weed detection in rice fields. *Precision agriculture*, 19, 809-822.
6. Bakhshipour, A., & Jafari, A. (2018). Evaluation of support vector machine and artificial neural networks in weed detection using shape features. *Computers and Electronics in Agriculture*, 145, 153-160.
7. Beeharry, Y., & Bassoo, V. (2020, November). Performance of ANN and AlexNet for weed detection using UAV-based images. In *2020 3rd International Conference on Emerging Trends in Electrical, Electronic and Communications Engineering (ELECOM)* (pp. 163-167). IEEE.
8. Chang-Tao, Z., Rui-Feng, W., Yu-Hao, T., Xiao-Xu, P., & Wen-Hao, S. (2024). Automatic Lettuce Weed Detection and Classification Based on Optimized Convolutional Neural Networks for Robotic Weed Control. *Agronomy*, (12), 2838.
9. Chen, J., Wang, H., Zhang, H., Luo, T., Wei, D., Long, T., & Wang, Z. (2022). Weed detection in sesame fields using a YOLO model with an enhanced attention mechanism and feature fusion. *Computers and Electronics in Agriculture*, 202, 107412.
10. Dang, F., Chen, D., Lu, Y., & Li, Z. (2023). YOLOWeeds: A novel benchmark of YOLO object detectors for multi-class weed detection in cotton production systems. *Computers and Electronics in Agriculture*, 205, 107655.
11. Deng, L., Miao, Z., Zhao, X., Yang, S., Gao, Y., Zhai, C., & Zhao, C. (2025). HAD-YOLO: An Accurate and Effective Weed Detection Model Based on Improved YOLOV5 Network. *Agronomy*, 15(1), 57.
12. Di Cicco, M., Potena, C., Grisetti, G., & Pretto, A. (2017, September). Automatic model based dataset generation for fast and accurate crop and weeds detection.

- In 2017 *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* (pp. 5188-5195). IEEE.
13. Diez, Y., Kentsch, S., Fukuda, M., Caceres, M. L. L., Moritake, K., & Cabezas, M. (2021). Deep learning in forestry using uav-acquired rgb data: A practical review. *Remote Sensing*, 13(14), 2837.
 14. El Alaoui, A., & Mousannif, H. (2025). Enhancing weed detection through knowledge distillation and attention mechanism. *Frontiers in Robotics and AI*, 12, 1654074..
 15. Fawakherji, M., Youssef, A., Bloisi, D., Pretto, A., & Nardi, D. (2019, February). Crop and weeds classification for precision agriculture using context-independent pixel-wise segmentation. In *2019 third IEEE international conference on robotic computing (IRC)* (pp. 146-152). IEEE.
 16. Fletcher, R. S. (2016). Using vegetation indices as input into random forest for soybean and weed classification. *American Journal of Plant Sciences*, 7(15), 2186-2198.
 17. Fraccaro, P., Butt, J., Edwards, B., Freckleton, R. P., Childs, D. Z., Reusch, K., & Comont, D. (2022). A deep learning application to map weed spatial extent from unmanned aerial vehicles imagery. *Remote Sensing*, 14(17), 4197.
 18. Gangadharan, S., Immidichetty, S., Gandhamueni, S., Mupparaju, Y., Gottipati, S., & Simon, U. J. J. (2025). *Precision weed detection using YOLOv11 for enhanced agriculture management*. *International Journal of Agriculture Extension and Social Development*, 8(5), 659–666.
<https://doi.org/10.33545/26180723.2025.v8.i5i.1965>
 19. Gao, J., French, A. P., Pound, M. P., He, Y., Pridmore, T. P., & Pieters, J. G. (2020). Deep convolutional neural networks for image-based *Convolvulus sepium* detection in sugar beet fields. *Plant methods*, 16, 1-12.
 20. García-Navarrete, O. L., Correa-Guimaraes, A., & Navas-Gracia, L. M. (2024). Application of Convolutional Neural Networks in Weed Detection and Identification: A Systematic Review. *Agriculture*, 14(4), 568.
 21. Genze, N., Vahl, W. K., Groth, J., Wirth, M., Grieb, M., & Grimm, D. G. (2024). Manually annotated and curated Dataset of diverse Weed Species in Maize and Sorghum for Computer Vision. *Scientific Data*, 11(1), 109.
 22. Gée, C., & Denimal, E. (2020). RGB image-derived indicators for spatial assessment of the impact of broadleaf weeds on wheat biomass. *Remote Sensing*, 12(18), 2982.
 23. Giselsson, T. M., Jørgensen, R. N., Jensen, P. K., Dyrmann, M., & Midtiby, H. S. (2017). A public image database for benchmark of plant seedling classification algorithms. *arXiv preprint arXiv:1711.05458*.
 24. Goyal, R., Nath, A., Niranjana, U., & Sharda, R. (2025). Analyzing the performance of deep convolutional neural network models for weed identification in potato fields. *Crop Protection*, 188, 107035.

25. Gómez, A., Moreno, H., & Andújar, D. (2025). Intelligent Inter-and Intra-Row Early Weed Detection in Commercial Maize Crops. *Plants*, 14(6), 881.
26. Guo, Y., Yin, G., Sun, H., Wang, H., Chen, S., Senthilnath, J., ... & Fu, Y. (2020). Scaling effects on chlorophyll content estimations with RGB camera mounted on a UAV platform using machine-learning methods. *Sensors*, 20(18), 5130.
27. Hallström, E., Fatsis-Kavalopoulos, N., Bimpis, M., Wählby, C., Hast, A., & Andersson, D. I. (2025). CombiANT reader: Deep learning-based automatic image processing tool to robustly quantify antibiotic interactions. *PLOS Digital Health*, 4(7), e0000669.
28. Hasan, A. M., Sohel, F., Diepeveen, D., Laga, H., & Jones, M. G. (2021). A survey of deep learning techniques for weed detection from images. *Computers and electronics in agriculture*, 184, 106067.
29. Hasan, A. M., Diepeveen, D., Laga, H., Jones, M. G., & Sohel, F. (2023). Image patch-based deep learning approach for crop and weed recognition. *Ecological informatics*, 78, 102361.
30. Haug, S., & Ostermann, J. (2015). A crop/weed field image dataset for the evaluation of computer vision based precision agriculture tasks. In *Computer Vision-ECCV 2014 Workshops: Zurich, Switzerland, September 6-7 and 12, 2014, Proceedings, Part IV 13* (pp. 105-116). Springer International Publishing.
31. Hemamalini, P., Chandraprakash, M. K., Laxman, R. H., Rathinakumari, C., & Suneetha, K. (2025). Thermal Canopy Segmentation in Tomato Plants: A Novel Approach with Integration of YOLOv8-C and FastSAM. *Smart Agricultural Technology*, 100806.
32. Hennessy, P. J., Esau, T. J., Schumann, A. W., Zaman, Q. U., Corscadden, K. W., & Farooque, A. A. (2022). Evaluation of cameras and image distance for CNN-based weed detection in wild blueberry. *Smart Agricultural Technology*, 2, 100030.
33. Hou, L., Samaras, D., Kurc, T. M., Gao, Y., Davis, J. E., & Saltz, J. H. (2016). Patch-based convolutional neural network for whole slide tissue image classification. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2424-2433).
34. Hu, J., Gong, H., Li, S., Mu, Y., Guo, Y., Sun, Y., ... & Bao, Y. (2024). Cotton Weed-YOLO: A Lightweight and Highly Accurate Cotton Weed Identification Model for Precision Agriculture. *Agronomy*, 14(12), 2911.
35. Hu, R., Su, W. H., Li, J. L., & Peng, Y. (2024). Real-time lettuce-weed localization and weed severity classification based on lightweight YOLO convolutional neural networks for intelligent intra-row weed control. *Computers and Electronics in Agriculture*, 226, 109404.
36. Islam, N., Rashid, M. M., Wibowo, S., Wasimi, S., Morshed, A., Xu, C., & Moore, S. (2020, August). Machine learning based approach for Weed Detection in Chilli field using RGB images. In *The International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery* (pp. 1097-1105). Cham: Springer International Publishing.

37. Jia, Z., Zhang, M., Yuan, C., Liu, Q., Liu, H., Qiu, X., ... & Shi, J. (2024). ADL-YOLOv8: A Field Crop Weed Detection Model Based on Improved YOLOv8. *Agronomy*, 14(10), 2355.
38. Jiang, K., Afzaal, U., & Lee, J. (2022). Transformer-based weed segmentation for grass management. *Sensors*, 23(1), 65.
39. Jin, X., Zhang, J., Wang, F., Zhao, M., Wang, Y., Yang, J., ... & Zhou, B. (2025). PHRF-RTDETR: A lightweight weed detection method for upland rice based on RT-DETR. *Frontiers in Plant Science*, 16, 1556275.
40. Jocher, G., Chaurasia, A., & Qiu, J. (2023). *Ultralytics YOLOv8* (Version 8.0.0) Computer Software Ultralytics. <https://github.com/ultralytics/ultralytics>.
41. Jocher, G., & Qiu, J. (2024). *Ultralytics YOLO11* (Version 11.0.0) ComputersoftwareComputer softwareComputersoftware. Ultralytics. <https://github.com/ultralytics/ultralytics>.
42. Jonak, M., Mucha, J., Jezek, S., Kovac, D., & Cziria, K. (2024). SPAGRI-AI: Smart precision agriculture dataset of aerial images at different heights for crop and weed detection using super-resolution. *Agricultural Systems*, 216, 103876.
43. Kavyapriya, V. K., Fathima, A., Shwetha, M. K., Yuvabharathi, P., Ramesh, P., AMB, D. A., & Bhuvaneshwari, P. T. V. (2023, July). CNN Based Identification of weeds in Tomato Farm. In *2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT)* (pp. 1-6). IEEE.
44. Khurana, G., & Bawa, N. K. (2021). Weed detection approach using feature extraction and KNN classification. In *Advances in Electromechanical Technologies: Select Proceedings of TEMT 2019* (pp. 671-679). Springer Singapore.
45. Kiala, Z., Mutanga, O., Odindi, J., & Peerbhay, K. (2019). Feature selection on sentinel-2 multispectral imagery for mapping a landscape infested by parthenium weed. *Remote Sensing*, 11(16), 1892.
46. Kim, D. W., Kim, Y., Kim, K. H., Kim, H. J., & Chung, Y. S. (2019). Case study: Cost-effective weed patch detection by multi-spectral camera mounted on unmanned aerial vehicle in the buckwheat field. *Korean Journal of Crop Science*, 64(2), 159-164.
47. Lameski, P., Zdravevski, E., Trajkovik, V., & Kulakov, A. (2017). Weed detection dataset with RGB images taken under variable light conditions. In *ICT Innovations 2017: Data-Driven Innovation. 9th International Conference, ICT Innovations 2017, Skopje, Macedonia, September 18-23, 2017, Proceedings 9* (pp. 112-119). Springer International Publishing.
48. Liu, B., & Bruch, R. (2020). Weed detection for selective spraying: a review. *Current Robotics Reports*, 1, 19-26.
49. López-Correa, J. M., Moreno, H., Ribeiro, A., & Andújar, D. (2022). Intelligent weed management based on object detection neural networks in tomato crops. *Agronomy*, 12(12), 2953.

50. Okamoto, H., Murata, T., Kataoka, T., & Hata, S. (2004). Weed detection using hyperspectral imaging. In *Automation Technology for Off-Road Equipment Proceedings of the 2004 Conference* (p. 47). American Society of Agricultural and Biological Engineers.
51. Okamoto, H., Murata, T., Kataoka, T., & HATA, S. I. (2007). Plant classification for weed detection using hyperspectral imaging with wavelet analysis. *Weed biology and Management*, 7(1), 31-37.
52. Olsen, A., Konovalov, D. A., Philippa, B., Ridd, P., Wood, J. C., Johns, J., ... & White, R. D. (2019). DeepWeeds: A multiclass weed species image dataset for deep learning. *Scientific reports*, 9(1), 2058.
53. Osorio, K., Puerto, A., Pedraza, C., Jamaica, D., & Rodríguez, L. (2020). A deep learning approach for weed detection in lettuce crops using multispectral images. *AgriEngineering*, 2(3), 471-488.
54. Pflanz, M., Nordmeyer, H., & Schirrmann, M. (2018). Weed mapping with UAS imagery and a bag of visual words based image classifier. *Remote Sensing*, 10(10), 1530.
55. PyTorch, 2020. Ai for ag: Production machine learning for agriculture. <https://medium.com/pytorch/ai-for-ag-production-machine-learning-for-agriculture-e8cfdb9849a1>.
56. Qu, H. R., & Su, W. H. (2024). Deep Learning-Based Weed-Crop Recognition for Smart Agricultural Equipment: A Review. *Agronomy*, 14(2), 363.
57. Rasti, P., Ahmad, A., Samiei, S., Belin, E., & Rousseau, D. (2019). Supervised image classification by scattering transform with application to weed detection in culture crops of high density. *Remote Sensing*, 11(3), 249.
58. Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28.
59. Sa, I., Chen, Z., Popović, M., Khanna, R., Liebisch, F., Nieto, J., & Siegart, R. (2017). weednet: Dense semantic weed classification using multispectral images and mav for smart farming. *IEEE robotics and automation letters*, 3(1), 588-595.
60. Saha, D., Hanson, A., & Shin, S. Y. (2016, October). Development of enhanced weed detection system with adaptive thresholding and support vector machine. In *Proceedings of the International Conference on Research in Adaptive and Convergent Systems* (pp. 85-88).
61. Saleem, M. H., Potgieter, J., & Arif, K. M. (2022). Weed detection by faster RCNN model: An enhanced anchor box approach. *Agronomy*, 12(7), 1580.
62. Saleh, A., Hatano, S., & Azghadi, M. R. (2025). Weed Detection in Challenging Field Conditions: A Semi-Supervised Framework for Overcoming Shadow Bias and Data Scarcity. *arXiv preprint arXiv:2508.19511*.
63. Sandoval-Pillajo, L., García-Santillán, I., Pusedá-Chulde, M., & Giret, A. (2025). Weed Detection Based on Deep Learning from UAV Imagery: A Review. *Smart Agricultural Technology*, 101147.

64. Shahi, T. B., Dahal, S., Sitaula, C., Neupane, A., & Guo, W. (2023). Deep learning-based weed detection using UAV images: A comparative study. *Drones*, 7(10), 624.
65. Sharma, A., Kumar, V., & Longchamps, L. (2024). Comparative performance of YOLOv8, YOLOv9, YOLOv10, YOLOv11 and Faster R-CNN models for detection of multiple weed species. *Smart Agricultural Technology*, 9, 100648.
66. Su, D., Qiao, Y., Kong, H., & Sukkarieh, S. (2021). Real time detection of inter-row ryegrass in wheat farms using deep learning. *Biosystems Engineering*, 204, 198-211.
67. Sun, H., Liu, T., Wang, J., Zhai, D., & Yu, J. (2024). Evaluation of two deep learning-based approaches for detecting weeds growing in cabbage. *Pest Management Science*, 80(6), 2817-2826.
68. Teimouri, N., Dyrmann, M., Nielsen, P. R., Mathiassen, S. K., Somerville, G. J., & Jørgensen, R. N. (2018). Weed growth stage estimator using deep convolutional neural networks. *Sensors*, 18(5), 1580.
69. Tian, Z., Hao, H., Dai, G., & Li, Y. (2024). Optimizing tomato detection and counting in smart greenhouses: A lightweight YOLOv8 model incorporating high-and low-frequency feature transformer structures. *Network: Computation in Neural Systems*, 1-37.
70. Wang, A., Qian, W., Li, A., Xu, Y., Hu, J., Xie, Y., & Zhang, L. (2024). NVW-YOLOv8s: An improved YOLOv8s network for real-time detection and segmentation of tomato fruits at different ripeness stages. *Computers and Electronics in Agriculture*, 219, 108833.
71. Wang, Q., Cheng, M., Huang, S., Cai, Z., Zhang, J., & Yuan, H. (2022). A deep learning approach incorporating YOLO v5 and attention mechanisms for field real-time detection of the invasive weed *Solanum rostratum* Dunal seedlings. *Computers and Electronics in Agriculture*, 199, 107194.
72. Wang, Y., Ha, T., Aldridge, K., Duddu, H., Shirtliffe, S., & Stavness, I. (2023). Weed mapping with convolutional neural networks on high resolution whole-field images. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 505-514).
73. Yu, J., Sharpe, S. M., Schumann, A. W., & Boyd, N. S. (2019a). Deep learning for image-based weed detection in turfgrass. *European journal of agronomy*, 104, 78-84.
74. Yu, J., Schumann, A. W., Cao, Z., Sharpe, S. M., & Boyd, N. S. (2019b). Weed detection in perennial ryegrass with deep learning convolutional neural network. *Frontiers in plant science*, 10, 1422.
75. Zhang, J. L., Su, W. H., Zhang, H. Y., & Peng, Y. (2022). SE-YOLOv5x: An optimized model based on transfer learning and visual attention mechanism for identifying and localizing weeds and vegetables. *Agronomy*, 12(9), 2061.
76. Zhang, J. (2023). Weed recognition method based on hybrid CNN-transformer model. *Frontiers in Computing and Intelligent Systems*, 4(2), 72-77.

77. Zhang, Y., Xu, Y., Hou, J., & Song, Y. (2025). LMS-YOLO11n: A Lightweight Multi-Scale Weed Detection Model. *International Journal of Advanced Computer Science & Applications*, 16(1).

78. Zheng, L., Yi, J., He, P., Tie, J., Zhang, Y., Wu, W., & Long, L. (2024). Improvement of the YOLOv8 Model in the Optimization of the Weed Recognition Algorithm in Cotton Field. *Plants*, 13(13), 1843.

Ιστοσελίδες

1. EPPO (2025) EPPO Global Database. <https://gd.eppo.int> [February, 2025]
2. GitHub repository Slanj/yolo-tiling retrieved from <https://github.com/slanj/yolo-tiling/tree/main> [November, 2025]
3. QGIS.org (2025). QGIS Geographic Information System. Open Source Geospatial Foundation Project. <http://qgis.org>
4. Wisconsin Horticulture (2025). Common Purslane, *Portulaca Oleracea* [June, 2025].

5 ΠΑΡΑΡΤΗΜΑ ΙΙ

Πρόγραμμα 1: Μετατροπή .srt αρχείων για τα metadata σε αναγνωρίσιμη μορφή για QGIS

```
import re
import pandas as pd
srt_file = r"Users/.../file.srt" # Replace path to your SRT file
frames = []
with open (srt_file, "r") as file:
    data = file.read()
# Updated regex to match your SRT format
pattern = r"FrameCnt: (\d+).*(\d{4}-\d{2}-\d{2}
\d{2}:\d{2}:\d{2}\.\d{3}).*?\[iso: \d+\] \[shutter: [\d/.]+\] \[fnum: [\d.]+\]
\[ev: \d+\] \[color_md: \w+\] \[focal_len: [\d.]+\] \[latitude: ([\d\.\-]+\])
\[longitude: ([\d\.\-]+\]) \[rel_alt: ([\d\.\-]+\])"
matches = re.finditer(pattern, data, re.DOTALL)
# Extract matched data and store it in a list
for match in matches:
    frame_num = int(match.group(1))
    timestamp = match.group(2)
    latitude = float(match.group(3))
    longitude = float(match.group(4))
    rel_altitude = float(match.group(5))
    frames.append([frame_num, timestamp, latitude, longitude, rel_altitude])
# Convert to a DataFrame and save to CSV
df = pd.DataFrame(frames, columns=["FrameNum", "Timestamp", "Latitude",
"Longitude", "Rel_Altitude"])
df.to_csv("frame_metadata.csv", index=False)
print("CSV file created: frame_metadata.csv")
```

Πρόγραμμα 2: Ενσωμάτωση label σε αντίστοιχο καρέ εικόνας

```
import os
import re
import pandas as pd

# Path to your main YOLO annotation folder containing subfolders
yolo_main_folder = r"C:/Users/..." # .txt annotations of the YOLO model
frame_metadata_file = r"C:/Users/.../metadata.csv"

# Load the frame metadata
frame_metadata = pd.read_csv(frame_metadata_file)

annotations = []
frame_num_pattern = re.compile(r"(\d+)\.txt")

# Loop through each folder in the main YOLO folder
for root, dirs, files in os.walk(yolo_main_folder):
    for txt_file in files:
        if txt_file.endswith(".txt"):
            match = frame_num_pattern.search(txt_file)
            if match:
                frame_num = int(match.group(1)) # Extract the frame number
                frame_data = frame_metadata[frame_metadata["FrameNum"] ==
frame_num]

                if not frame_data.empty:
```

```

lat, lon = frame_data.iloc[0]["Latitude"],
frame_data.iloc[0]["Longitude"]

# Read the YOLO annotation file
with open(os.path.join(root, txt_file), "r") as file:
    for line in file:
        class_id, x_center, y_center, width, height =
map(float, line.strip().split())
        annotations.append([
            frame_num, class_id, lat, lon, x_center,
y_center, width, height
        ])

# Save all annotations to a single CSV
df_annotations = pd.DataFrame(
    annotations,
    columns=["FrameNum", "ClassID", "Latitude", "Longitude", "X_Center",
"Y_Center", "Width", "Height"]
)
df_annotations.to_csv("all_yolo_annotations.csv", index=False)

print("All YOLO annotations saved to all_yolo_annotations.csv")

```

Πρόγραμμα 3: Απεικόνιση ποσοστών ζιζανιοκάλυψης ανά καρτέ

```

import os
import pandas as pd
from collections import Counter

# Paths
yolo_folder = r"C:\Users\...\cnn-annotations" # Replace with actual folder
path
metadata_file = r"C:\Users\...\metadata.csv" # Replace with actual metadata
file path
output_csv = "weed_coverage_with_coords.csv"

# Load metadata with GPS coordinates
metadata_df = pd.read_csv(metadata_file)

# Initialize dictionary to store counts
frame_counts = {}

# Loop through YOLO annotation files
for txt_file in os.listdir(yolo_folder):
    if txt_file.endswith(".txt"):
        # Extract frame number from filename
        try:
            frame_num = int(txt_file.split("_")[-1].split(".txt")[0]) # Adjust
if naming is different
        except ValueError:
            print(f"Skipping file: {txt_file} (Invalid frame number)")
            continue

        # Read YOLO annotations
        with open(os.path.join(yolo_folder, txt_file), "r") as file:
            lines = file.readlines()

        # Count occurrences of each class
        class_counts = Counter([int(line.split()[0]) for line in lines])
        total_weeds = sum(class_counts.values())

```

```
# Store as percentages
if total_weeds > 0:
    frame_counts[frame_num] = {
        class_id: (count / total_weeds) * 100 for class_id, count in
class_counts.items()
    }

# Convert to DataFrame
weed_df = pd.DataFrame.from_dict(frame_counts, orient="index").reset_index()
weed_df.rename(columns={"index": "FrameNum"}, inplace=True)

# Merge with metadata
merged_df = pd.merge(weed_df, metadata_df, on="FrameNum", how="left")

# Save to CSV for QGIS
merged_df.to_csv(output_csv, index=False)
print(f"CSV saved: {output_csv}")
```

Πρόγραμμα 4.i): Μέρος Α' για απόλυτη κάλυψη ζιζανίων

```
import os
import pandas as pd
from collections import defaultdict

# Path to YOLO annotation files
yolo_folder = r"C:\Users\...\cnn-annotations" # <-- Change this

# Metadata CSV with FrameNum, Latitude, Longitude
metadata_file = r"C:\Users\...\metadata.csv" # <-- Change this

# Output folder for individual weed CSVs (optional)
output_folder = r"C:\Users\...\split_annotations"
os.makedirs(output_folder, exist_ok=True)

# Output CSV with absolute counts + coordinates
final_output = "weed_counts_with_coords.csv"

# Class ID to weed name mapping
class_id_to_name = {
    0: "AMARE",
    1: "CHEAL",
    2: "CYPES",
    3: "POROL"
}

# Initialize storage
per_weed_data = defaultdict(list)
frame_counts = defaultdict(lambda: defaultdict(int))

# Process annotation files
for file in os.listdir(yolo_folder):
    if not file.endswith(".txt"):
        continue
    frame_num = int(file.split("_")[-1].split(".txt")[0])
```

```

with open(os.path.join(yolo_folder, file), "r") as f:
    for line in f:
        parts = line.strip().split()
        if len(parts) < 5:
            continue
        class_id = int(parts[0])
        if class_id not in class_id_to_name:
            continue

        # For individual CSV
        weed_name = class_id_to_name[class_id]
        per_weed_data[weed_name].append({
            "FrameNum": frame_num,
            "ClassID": class_id,
            "X_center": float(parts[1]),
            "Y_center": float(parts[2]),
            "Width": float(parts[3]),
            "Height": float(parts[4])
        })

        # For counts per frame
        frame_counts[frame_num][weed_name] += 1

# Save individual CSVs
for weed_name, records in per_weed_data.items():
    df = pd.DataFrame(records)
    df.to_csv(os.path.join(output_folder, f"{weed_name}.csv"), index=False)
    print(f"Saved {weed_name}.csv")

# Create final counts DataFrame
rows = []
for frame_num, counts in frame_counts.items():
    row = {"FrameNum": frame_num}
    for weed_name in class_id_to_name.values():
        row[f"{weed_name}_Count"] = counts.get(weed_name, 0)
    rows.append(row)

counts_df = pd.DataFrame(rows)

# Load metadata and merge
metadata_df = pd.read_csv(metadata_file)
merged_df = pd.merge(counts_df, metadata_df, on="FrameNum", how="left")

# Save final output
merged_df.to_csv(final_output, index=False)
print(f"Saved final counts with coordinates to {final_output}")

```

Πρόγραμμα 4.ii): Μέρος Β' για απόλυτη κάλυψη ζιζανίων

```

import os
import pandas as pd
from collections import defaultdict

```

```
# --- INPUT PATHS (Update These!) ---
yolo_folder = r"C:\Users\chryk\Downloads\InnoPP\weed-mapping\DEUTERO-
ATTEMPT\PREDS\34\labels-DJI_20250523132540_0434_D"
metadata_file = r"C:\Users\chryk\Downloads\InnoPP\weed-mapping\DEUTERO-
ATTEMPT\srt-se-qgis-(1)\34-metadata.csv"
output_folder = r"C:\Users\chryk\Downloads\InnoPP\weed-mapping\DEUTERO-
ATTEMPT\EF3\i\34"
os.makedirs(output_folder, exist_ok=True)

# --- OUTPUT FILES ---
frame_output = os.path.join(output_folder, "EF3.3-34_per_frame.csv")
aggregated_output = os.path.join(output_folder, "EF3.3-34_aggregated.csv")

# --- Class ID Mapping ---
class_id_to_name = {
    0: "AMARE",
    1: "CHEAL",
    2: "CYPES",
    3: "POROL"
}

# --- 1. Parse YOLO Annotations ---
per_weed_data = defaultdict(list)
frame_counts = defaultdict(lambda: defaultdict(int))

for file in os.listdir(yolo_folder):
    if not file.endswith(".txt"):
        continue
    frame_num = int(file.split("_")[-1].split(".txt")[0])
    with open(os.path.join(yolo_folder, file), "r") as f:
        for line in f:
            parts = line.strip().split()
            if len(parts) < 5:
                continue
            class_id = int(parts[0])
            if class_id not in class_id_to_name:
                continue
            weed_name = class_id_to_name[class_id]

            per_weed_data[weed_name].append({
                "FrameNum": frame_num,
                "ClassID": class_id,
                "X_center": float(parts[1]),
                "Y_center": float(parts[2]),
                "Width": float(parts[3]),
                "Height": float(parts[4])
            })
            frame_counts[frame_num][weed_name] += 1

# --- 2. Save per-weed files (optional) ---
for weed_name, records in per_weed_data.items():
    df = pd.DataFrame(records)
    df.to_csv(os.path.join(output_folder, f"{weed_name}.csv"), index=False)

# --- 3. Build per-frame DataFrame ---
rows = []
for frame_num, counts in frame_counts.items():
    row = {"FrameNum": frame_num}
    for weed_name in class_id_to_name.values():
        row[f"{weed_name}_Count"] = counts.get(weed_name, 0)
    rows.append(row)
```

```
counts_df = pd.DataFrame(rows)
counts_df["FrameNum"] = counts_df["FrameNum"].astype(int)

# --- 4. Load metadata (only FrameNum, Lat, Lon, Timestamp) ---
metadata_df = pd.read_csv(metadata_file)[["FrameNum", "Latitude", "Longitude",
"Timestamp", "Rel_Altitude"]]
merged_df = pd.merge(counts_df, metadata_df, on="FrameNum", how="left")

# --- 5. Save per-frame data (optional) ---
merged_df.to_csv(frame_output, index=False)
print(f"Saved per-frame data to: {frame_output}")

# --- 6. Aggregate by Location (Latitude + Longitude) ---
aggregated = merged_df.groupby(["Latitude", "Longitude"], as_index=False).agg({
    "AMARE_Count": "sum",
    "CHEAL_Count": "sum",
    "CYPES_Count": "sum",
    "POROL_Count": "sum",
    "Rel_Altitude": "mean",
    "FrameNum": "count", # You can rename this to FramesPerPoint if you want
    "Timestamp": "first" # Optional: timestamp of first frame in group
})

# --- 7. Save final CSV for QGIS ---
aggregated.to_csv(aggregated_output, index=False)
print(f"Saved aggregated QGIS-ready file to: {aggregated_output}")
```

Πρόγραμμα 5): Τμηματοποίηση εικόνων μεγάλης ανάλυσης με αντίστοιχες ετικέτες ζιζανίων σε κομμάτια 640 x 640 pixel.

```
import os

import cv2

import numpy as np

from PIL import Image

# === CONFIGURATION ===

IMG_DIR = r'C:\Users\...' # Input image directory
LABEL_DIR = r'C:\Users\...' # YOLO-style .txt label directory
OUTPUT_IMG_DIR = r'C:\Users\...'
OUTPUT_LABEL_DIR = r'C:\Users\...'

CROP_SIZE = 640

OVERLAP = 0.5 # 50% overlap

EXTENSIONS = ['.jpg', '.JPG']

RETAINED_THRESHOLD = 0.9 #  Only keep boxes with 90% of original area inside crop
```

```
# === UTILITIES ===

os.makedirs(OUTPUT_IMG_DIR, exist_ok=True)
os.makedirs(OUTPUT_LABEL_DIR, exist_ok=True)

def read_yolo_labels(label_path, img_w, img_h):
    boxes = []

    if not os.path.exists(label_path):
        return boxes

    with open(label_path, 'r') as f:
        for line in f:
            parts = line.strip().split()

            if len(parts) != 5:
                continue

            cls, x_center, y_center, w, h = map(float, parts)

            x_center *= img_w
            y_center *= img_h

            w *= img_w
            h *= img_h

            xmin = int(x_center - w / 2)
            ymin = int(y_center - h / 2)
            xmax = int(x_center + w / 2)
            ymax = int(y_center + h / 2)

            boxes.append((int(cls), xmin, ymin, xmax, ymax))

    return boxes

def save_crop_and_label(crop_img, crop_boxes, crop_index, base_filename,
crop_coords):
    crop_filename = f"{base_filename}_crop{crop_index}.jpg"
    crop_path = os.path.join(OUTPUT_IMG_DIR, crop_filename)

    # Convert from NumPy BGR to PIL RGB
    Image.fromarray(cv2.cvtColor(crop_img, cv2.COLOR_BGR2RGB)).save(crop_path)
```

```
# Save corresponding YOLO label
label_filename = crop_filename.replace('.jpg', '.txt')
label_path = os.path.join(OUTPUT_LABEL_DIR, label_filename)
xmin_crop, ymin_crop = crop_coords
with open(label_path, 'w') as f:
    for cls, xmin, ymin, xmax, ymax in crop_boxes:
        new_xmin = max(0, xmin - xmin_crop)
        new_ymin = max(0, ymin - ymin_crop)
        new_xmax = min(CROP_SIZE, xmax - xmin_crop)
        new_ymax = min(CROP_SIZE, ymax - ymin_crop)

        # Reject tiny boxes
        if new_xmax - new_xmin < 2 or new_ymax - new_ymin < 2:
            continue

        # Convert to YOLO format
        cx = (new_xmin + new_xmax) / 2 / CROP_SIZE
        cy = (new_ymin + new_ymax) / 2 / CROP_SIZE
        w = (new_xmax - new_xmin) / CROP_SIZE
        h = (new_ymax - new_ymin) / CROP_SIZE
        f.write(f"{cls} {cx:.6f} {cy:.6f} {w:.6f} {h:.6f}\n")

def crop_image_and_labels(image_path, boxes, base_filename):
    img = cv2.imread(image_path)
    if img is None:
        print(f"Failed to read image: {image_path}")
        return

    h, w = img.shape[:2]
    step = int(CROP_SIZE * (1 - OVERLAP))
    crop_index = 0
```

```

for y in range(0, h - CROP_SIZE + 1, step):
    for x in range(0, w - CROP_SIZE + 1, step):
        crop = img[y:y+CROP_SIZE, x:x+CROP_SIZE]
        crop_boxes = []

        for cls, xmin, ymin, xmax, ymax in boxes:
            # Calculate intersection with crop
            ixmin = max(xmin, x)
            iymin = max(ymin, y)
            ixmax = min(xmax, x + CROP_SIZE)
            iymax = min(ymax, y + CROP_SIZE)

            if ixmax <= ixmin or iymax <= iymin:
                continue # No overlap

            # NEW Retention logic: how much of the original bbox is in the
crop
            inter_area = (ixmax - ixmin) * (iymax - iymin)
            orig_area = (xmax - xmin) * (ymax - ymin)
            retained_ratio = inter_area / orig_area

            if retained_ratio < RETAINED_THRESHOLD:
                continue # Too little of the object retained

            crop_boxes.append((cls, xmin, ymin, xmax, ymax))

        if crop_boxes:
            save_crop_and_label(crop, crop_boxes, crop_index,
base_filename, (x, y))
            crop_index += 1

# === MAIN PROCESS ===
image_files = [f for f in os.listdir(IMG_DIR) if os.path.splitext(f)[1] in
EXTENSIONS]

for img_file in image_files:

```

```
base_filename = os.path.splitext(img_file)[0]
img_path = os.path.join(IMG_DIR, img_file)
label_path = os.path.join(LABEL_DIR, base_filename + '.txt')

img = cv2.imread(img_path)
if img is None:
    continue

h, w = img.shape[:2]
boxes = read_yolo_labels(label_path, w, h)
if not boxes:
    continue # Skip images with no labels
crop_image_and_labels(img_path, boxes, base_filename)

print("☑ Cropping complete. Output in:", OUTPUT_IMG_DIR)
```