

2026

bö ' ½ - Ç ½ µ Å ã . ± ã , µ ½ µ ¹ î ½ Æ í » » É ½
 bö ¼ µ µ ¹ ⁰ ì ½ µ â drone ⁰ ± ¹ Ä µ Ç ½ ¹ ⁰
 bö ¼ · Ç ± ½ ¹ ⁰ ® Â ¼ ¬ , · ã · â

bö £ ç Å ² ± » ¹ î Ä · â , á ì ´ á ç ¼ ç â

bö Á ì ³ Á ± ¼ ¼ ± " · ¼ ì ã ¹ ± â " ¹ ç ⁰ · ã · â , £ Ç ç » ® Ÿ ¹ ⁰ ç ½ ç ¼ ¹ ⁰ î ½ · à ¹ ã ä · ¼ î ½ ⁰ ± ¹ " ¹ ç ⁰ ·

bö ± ½ µ à ¹ ã ä ® ¼ ¹ ç · µ ¬ à ç » ¹ â ¬ æ ç ä

<http://hdl.handle.net/11728/13554>

Downloaded from HEPHAESTUS Repository, Neapolis University institutional repository



**Πανεπιστήμιο Νεάπολις
Πάφου**

**Σχολή Οικονομικών, Διοίκησης και
Πληροφορικής**

**Τμήμα
Πληροφορικής**

**ΤΙΤΛΟΣ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ:
ΑΝΙΧΝΕΥΣΗ ΑΣΘΕΝΕΙΩΝ ΦΥΛΛΩΝ ΕΛΙΑΣ ΜΕ
ΕΙΚΟΝΕΣ DRONE ΚΑΙ ΤΕΧΝΙΚΕΣ ΜΗΧΑΝΙΚΗΣ
ΜΑΘΗΣΗΣ**

Όνοματεπώνυμο φοιτητή: Πρόδρομος Σουβαλιώτης

Όνοματεπώνυμο επιβλέπουσας: Σαλώμη Ευριπίδου

Πάφος (2026)

Πνευματικά δικαιώματα

Copyright © Πρόδρομος Σουβαλιώτης, 2026

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Η έγκριση της Διπλωματικής Εργασίας από το Πανεπιστημίου Νεάπολις δεν υποδηλώνει απαραίτητως και αποδοχή των απόψεων του συγγραφέα εκ μέρους του Πανεπιστημίου.

Σελίδα Εγκυρότητας

Όνοματεπώνυμο Φοιτητή: Πρόδρομος Σουβαλιώτης

Τίτλος Διπλωματικής Εργασίας: Ανίχνευση ασθενειών φύλλων ελιάς με εικόνες drone και τεχνικές μηχανικής μάθησης

Η παρούσα Διπλωματική Εργασία εκπονήθηκε στο πλαίσιο των σπουδών για την απόκτηση προπτυχιακού τίτλου στο Πανεπιστήμιο Νεάπολις και εγκρίθηκε στις [ημερομηνία έγκρισης] από τα μέλη της Εξεταστικής Επιτροπής.

Εξεταστική Επιτροπή:

Πρώτος επιβλέπων (Πανεπιστήμιο Νεάπολις Πάφος).....[ονοματεπώνυμο, βαθμίδα] Μέλος Εξεταστικής Επιτροπής:[ονοματεπώνυμο, βαθμίδα]

Ἡ ΥΠΕΥΘΥΝΗ ΔΗΛΩΣΗ

Ο Πρόδρομος Σουβαλιώτης, γνωρίζοντας τις συνέπειες της λογοκλοπής, δηλώνω υπεύθυνα ότι η παρούσα εργασία με τίτλο «Ανίχνευση ασθενειών φύλλων ελιάς με εικόνες drone και τεχνικές μηχανικής μάθησης», αποτελεί προϊόν αυστηρά προσωπικής εργασίας και όλες οι πηγές που έχω χρησιμοποιήσει, έχουν δηλωθεί κατάλληλα στις βιβλιογραφικές παραπομπές και αναφορές. Τα σημεία όπου έχω χρησιμοποιήσει ιδέες, κείμενο ή/και πηγές άλλων συγγραφέων, αναφέρονται ευδιάκριτα στο κείμενο με την κατάλληλη παραπομπή και η σχετική αναφορά περιλαμβάνεται στο τμήμα των βιβλιογραφικών αναφορών με πλήρη περιγραφή.

Ο Δηλών

Πρόδρομος Σουβαλιώτης

ΕΥΧΑΡΙΣΤΙΕΣ

Η παρούσα προπτυχιακή διατριβή εκπονήθηκε στο πλαίσιο του Προγράμματος Σπουδών Πληροφορικής της Σχολής Οικονομικών, Διοίκησης και Πληροφορικής του Πανεπιστημίου Νεάπολις Πάφου, κατά το ακαδημαϊκό έτος 2025–2026.

Θα ήθελα αρχικά να εκφράσω την ειλικρινή μου ευγνωμοσύνη προς την επιβλέπουσα καθηγήτριά μου, Σαλώμη Ευριπίδου, για την πολύτιμη καθοδήγηση, τη συνεχή υποστήριξη και τη διαρκή διάθεση συνεργασίας καθ' όλη τη διάρκεια της εκπόνησης της εργασίας. Η καθοδήγησή της υπήρξε καθοριστική τόσο στη διαμόρφωση του επιστημονικού περιεχομένου όσο και στην ανάπτυξη των ερευνητικών μου δεξιοτήτων.

Ευχαριστώ επίσης θερμά όλα τα μέλη του Τμήματος Πληροφορικής για τις γνώσεις και την έμπνευση που μου προσέφεραν κατά τη διάρκεια των σπουδών μου, συμβάλλοντας ουσιαστικά στη διαμόρφωση της ακαδημαϊκής μου πορείας.

Ιδιαίτερες ευχαριστίες οφείλω στην οικογένειά μου, για τη συνεχή συμπαράσταση και την υπομονή τους σε όλη τη διάρκεια των σπουδών μου. Η αμέριστη στήριξή τους αποτέλεσε το πιο σταθερό θεμέλιο για την ολοκλήρωση αυτής της προσπάθειας.

Τέλος, ευχαριστώ τους φίλους και συμφοιτητές μου για τη βοήθεια, την ενθάρρυνση και τις στιγμές συνεργασίας που μοιραστήκαμε κατά τη διάρκεια της πτυχιακής αυτής πορείας.

ΠΕΡΙΛΗΨΗ

Η παρούσα πτυχιακή εργασία εξετάζει την ανίχνευση ασθενειών φύλλων ελιάς με αξιοποίηση τεχνικών μηχανικής μάθησης, βαθιάς μάθησης και ανάλυσης εικόνας, σε συνδυασμό με τη χρήση μη επανδρωμένου εναέριου οχήματος χαμηλού κόστους. Ειδικότερα, αντικείμενο της μελέτης αποτελεί η ανάπτυξη και συγκριτική αξιολόγηση δύο διαφορετικών προσεγγίσεων ταξινόμησης εικόνων για τη διάκριση μεταξύ υγιών φύλλων ελιάς και φύλλων προσβεβλημένων από την ασθένεια peacock spot.

Για την εκπαίδευση και την αρχική αξιολόγηση των μοντέλων χρησιμοποιήθηκε σύνολο δεδομένων από την πλατφόρμα Kaggle, το οποίο περιλάμβανε συνολικά 430 εικόνες φύλλων ελιάς, εκ των οποίων 210 αντιστοιχούσαν σε υγιή φύλλα και 220 σε φύλλα με συμπτώματα της ασθένειας. Στο πλαίσιο της εργασίας υλοποιήθηκαν και συγκρίθηκαν δύο μεθοδολογικές προσεγγίσεις. Η πρώτη βασίστηκε σε κλασική μηχανική μάθηση, με χρήση του ταξινομητή Support Vector Machine (SVM) και εξαγωγή χαρακτηριστικών Histogram of Oriented Gradients (HOG). Η δεύτερη βασίστηκε σε τεχνικές βαθιάς μάθησης μέσω μεταφοράς μάθησης (Transfer Learning), με αξιοποίηση της πλατφόρμας Teachable Machine. Πριν από την εκπαίδευση των μοντέλων εφαρμόστηκαν διαδικασίες προεπεξεργασίας εικόνας, όπως αλλαγή μεγέθους και ομογενοποίηση των δεδομένων εισόδου.

Πέρα από την αξιολόγηση στο οργανωμένο σύνολο δεδομένων, πραγματοποιήθηκε επιτόπια αξιολόγηση των εκπαιδευμένων μοντέλων σε πραγματικές συνθήκες ελαιώνα, με χρήση drone DJI Tello. Το drone χρησιμοποιήθηκε ως μέσο real-time εφαρμογής των αλγορίθμων στο πεδίο, ώστε να εξεταστεί η συμπεριφορά τους σε περιβάλλον με αυξημένη μεταβλητότητα, όπως μεταβολές φωτισμού, πολύπλοκο φόντο, επικάλυψη φύλλων και θόλωση λόγω κίνησης. Η διαδικασία αυτή δεν χρησιμοποιήθηκε για τη δημιουργία νέου συνόλου εκπαίδευσης, αλλά για τον έλεγχο της ικανότητας γενίκευσης των μοντέλων σε ρεαλιστικές συνθήκες λειτουργίας.

Τα αποτελέσματα της μελέτης έδειξαν ότι το μοντέλο SVM + HOG παρουσίασε μέτρια απόδοση και μεγαλύτερη ευαισθησία στις συνθήκες πεδίου, ενώ το μοντέλο Transfer Learning εμφάνισε σαφώς καλύτερη σταθερότητα, υψηλότερη ακρίβεια και πιο αξιόπιστη συμπεριφορά κατά τη real-time αξιολόγηση. Τα ευρήματα αυτά υποδεικνύουν ότι, παρότι οι κλασικές μέθοδοι μηχανικής μάθησης μπορούν να αξιοποιηθούν σε βασικά προβλήματα ταξινόμησης εικόνων, οι τεχνικές βαθιάς μάθησης είναι καταλληλότερες για εφαρμογές ανίχνευσης ασθενειών σε πραγματικές συνθήκες γεωργίας ακριβείας.

Συνολικά, η εργασία αναδεικνύει ότι ο συνδυασμός ανάλυσης εικόνας, τεχνητής νοημοσύνης και χαμηλού κόστους εναέριων πλατφορμών μπορεί να αποτελέσει μια πρακτική και υποσχόμενη προσέγγιση για την υποστήριξη της παρακολούθησης της υγείας των καλλιεργειών και της έγκαιρης διάγνωσης φυτικών ασθενειών.

Λέξεις-κλειδιά: ελιά, ασθένειες φύλλων, peacock spot, μηχανική μάθηση, βαθιά μάθηση, transfer learning, drone, γεωργία ακριβείας

ABSTRACT

This undergraduate thesis investigates the detection of olive leaf diseases through the use of machine learning, deep learning, and image-based analysis supported by a low-cost unmanned aerial vehicle. More specifically, the study focuses on the development and comparative evaluation of two different image classification approaches for distinguishing between healthy olive leaves and leaves affected by *peacock spot* disease.

For the training and initial evaluation of the models, a dataset obtained from the Kaggle platform was used. The dataset consisted of 430 olive leaf images, including 210 healthy leaves and 220 leaves showing symptoms of *peacock spot*. Within the framework of the study, two methodological approaches were implemented and compared. The first approach was based on a classical machine learning model using a Support Vector Machine (SVM) classifier combined with Histogram of Oriented Gradients (HOG) feature extraction. The second approach was based on deep learning through Transfer Learning using the Teachable Machine platform. Before training, the images were subjected to preprocessing procedures, including resizing and input standardization.

In addition to the evaluation on the organized dataset, an in-field real-time assessment of the trained models was carried out in an olive grove using a DJI Tello drone. In this phase, the drone was used as a platform for the real-time application and testing of the algorithms under actual field conditions, rather than for the creation of a new training dataset. This process made it possible to examine the behavior and generalization ability of the models in environments characterized by increased variability, such as changes in lighting, complex background, overlapping leaves, and motion blur.

The results of the study showed that the SVM + HOG model achieved moderate performance and exhibited greater sensitivity to real-world field conditions. In contrast, the Transfer Learning model demonstrated clearly better stability, higher accuracy, and more reliable behavior during real-time evaluation. These findings indicate that although classical machine learning methods can be used for basic image classification tasks, deep learning approaches are more suitable for disease detection applications under realistic precision agriculture conditions.

Overall, the study highlights that the combination of image analysis, artificial intelligence, and low-cost aerial platforms can provide a practical and promising approach for supporting crop health monitoring and the early diagnosis of plant diseases.

Keywords: olive leaves, disease detection, peacock spot, machine learning, deep learning, transfer learning, drone, precision agriculture

Περιεχόμενα

ΕΥΧΑΡΙΣΤΙΕΣ	4
ΠΕΡΙΛΗΨΗ	5
ABSTRACT	6
Περιεχόμενα	7
Κατάλογος Εικόνων	9
Κατάλογος Πινάκων	10
Κεφάλαιο 1: Εισαγωγή	11
Κεφάλαιο 2: Βιβλιογραφική Ανασκόπηση	13
2.1 Υπολογιστική Όραση και Τεχνητή Νοημοσύνη στη Γεωργία Ακριβείας: Θεωρητικό Πλαίσιο και Ανασκοπικές Προσεγγίσεις	13
2.2 Κλασικές Μέθοδοι Ανίχνευσης Ασθενειών Φύλλων με Επεξεργασία Εικόνας και Μηχανική Μάθηση	14
2.3 Βαθιά Μάθηση στην Αναγνώριση Φυτικών Ασθενειών: Συνελκτικά Δίκτυα, Μεταφορά Μάθησης και Τμηματοποίηση	15
2.4 Δεδομένα Πεδίου και Ικανότητα Γενίκευσης Μοντέλων σε Ρεαλιστικά Περιβάλλοντα Καλλιέργειας	17
2.5 Μη Επανδρωμένα Εναέρια Οχήματα στη Γεωργία Ακριβείας: Συλλογή Δεδομένων, Τηλεπισκόπηση και Ανάλυση Εικόνας για Ανίχνευση Ασθενειών	19
2.6 Ελιά: Βιολογικό Υπόβαθρο Ασθενειών Φυλλώματος, Έγκαιρη Διάγνωση και Πρόγνωση Κινδύνου	21
2.7 Ανίχνευση και Ταξινόμηση Ασθενειών Φύλλων Ελιάς με Τεχνικές Μηχανικής και Βαθιάς Μάθησης	23
2.8 Ασθένειες φύλλων ελιάς	24
2.9 Εφαρμογές του SVM στην αυτόματη ανίχνευση ασθενειών φυτών	27
2.10 Ερευνητικό κενό και θέση της παρούσας εργασίας	31
Κεφάλαιο 3: Μεθοδολογία Έρευνας	32
3.1 Ερευνητικός σχεδιασμός	32
3.2 Περιγραφή συνόλων δεδομένων (dataset)	32
3.3 Επιτόπια δοκιμή με drone σε πραγματικές συνθήκες	33
3.4 Προεπεξεργασία εικόνων	34
3.5 Εκπαίδευση μοντέλου SVM + HOG	34
3.6 Εκπαίδευση μοντέλου Transfer Learning	35
3.7 Real-time σύστημα με drone	36
3.8 Μετρικές αξιολόγησης	37
3.9 Περιγραφή πειραμάτων	39
Κεφάλαιο 4: Αποτελέσματα	40
4.1 Περιγραφή πειραματικών συνθηκών	40
4.2 Αποτελέσματα μοντέλου SVM	41
4.3 Αποτελέσματα μοντέλου Transfer Learning	42
4.4 Συγκριτική ανάλυση μοντέλων	43
4.5 Αποτελέσματα real-time αξιολόγησης	44
4.6 Συζήτηση αποτελεσμάτων	49
Κεφάλαιο 5: Συμπεράσματα	51
5.1 Συνοπτικά ευρήματα	51
5.2 Απάντηση στα ερευνητικά ερωτήματα	52

5.3 Πρακτική αξία της προσέγγισης	52
5.4 Περιορισμοί της μελέτης	53
5.5 Μελλοντική εργασία	54
5.6 Επίλογος	55
Βιβλιογραφία	56
Παραρτήματα	61
Παράρτημα Α – Ενδεικτικές εικόνες του συνόλου δεδομένων	61
Παράρτημα Β – Ενδεικτικά αποτελέσματα ταξινόμησης φύλλων ελιάς σε εσωτερικό χώρο	67
Παράρτημα Γ – Ενδεικτικός κώδικας υλοποίησης του μοντέλου SVM + HOG.....	71
Παράρτημα Δ – Ενδεικτικός κώδικας υλοποίησης του μοντέλου Transfer Learning / Teachable Machine	78

Κατάλογος Εικόνων

Εικόνα 4.1 – Ορθή αναγνώριση προσβεβλημένου φύλλου από το μοντέλο Transfer Learning	45
Εικόνα 4.2 – Δεύτερο παράδειγμα ορθής αναγνώρισης από το μοντέλο Transfer Learning	46
Εικόνα 4.3 – Πρόβλεψη του μοντέλου SVM + HOG με σχετικά υψηλή βεβαιότητα. 47	
Εικόνα 4.4 – Πρόβλεψη του μοντέλου SVM + HOG σε πιο σύνθετες συνθήκες λήψης	48
Εικόνα 4.5 – Παράδειγμα μειωμένης βεβαιότητας του μοντέλου SVM + HOG	49
Εικόνα A.1 – Ενδεικτικό υγιές φύλλο ελιάς	61
Εικόνα A.2 – Δεύτερο παράδειγμα υγιούς φύλλου ελιάς	62
Εικόνα A.3 – Τρίτο παράδειγμα υγιούς φύλλου ελιάς.....	63
Εικόνα A.4 – Φύλλο ελιάς με πρώιμα συμπτώματα peacock spot	64
Εικόνα A.5 – Φύλλο ελιάς με εμφανή συμπτώματα προσβολής	65
Εικόνα A.6 – Φύλλο ελιάς με προχωρημένη προσβολή από peacock spot	66
Εικόνα B.1 – Ορθή αναγνώριση υγιούς φύλλου σε εσωτερικό χώρο.....	67
Εικόνα B.2 – Δεύτερο παράδειγμα ορθής αναγνώρισης υγιούς φύλλου σε εσωτερικό χώρο	68
Εικόνα B.3 – Ορθή αναγνώριση υγιούς φύλλου σε εσωτερικό χώρο.....	69
Εικόνα B.4 – Ορθή αναγνώριση προσβεβλημένου φύλλου με μέγιστη βεβαιότητα... 70	
Εικόνα B.5 – Αναγνώριση προσβεβλημένου φύλλου με υψηλή πιθανότητα	71
Εικόνα B.6 – Ορθή αναγνώριση έντονα προσβεβλημένου φύλλου σε εσωτερικό χώρο	71

Κατάλογος Πινάκων

Πίνακας 4.1: Περιγραφή του συνόλου δεδομένων.	41
Πίνακας 4.2: Μετρικές απόδοσης των μοντέλων ταξινόμησης.	43
Πίνακας 4.3: Συγκριτική αξιολόγηση των δύο μοντέλων.	43
Πίνακας 4.4: Αποτελέσματα real-time αξιολόγησης.	44

ΚΕΦΑΛΑΙΟ 1: Εισαγωγή

Η γεωργική παραγωγή αντιμετωπίζει ολοένα και μεγαλύτερες προκλήσεις που σχετίζονται με την κλιματική μεταβλητότητα, την ανάγκη αύξησης της παραγωγικότητας, τη μείωση της χρήσης χημικών εισροών και τη βελτίωση της βιωσιμότητας των καλλιεργητικών πρακτικών. Στο πλαίσιο αυτό, η αξιοποίηση ψηφιακών τεχνολογιών στη γεωργία έχει οδηγήσει στην ανάπτυξη νέων προσεγγίσεων διαχείρισης των καλλιεργειών, με βασικότερη τη γεωργία ακριβείας. Η προσέγγιση αυτή βασίζεται στη συλλογή και ανάλυση δεδομένων από το αγροτικό περιβάλλον, με στόχο την υποστήριξη πιο στοχευμένων και αποτελεσματικών αποφάσεων σε επίπεδο καλλιέργειας.

Ιδιαίτερο ενδιαφέρον παρουσιάζει η χρήση τεχνητής νοημοσύνης και υπολογιστικής όρασης για την παρακολούθηση της υγείας των φυτών και την έγκαιρη ανίχνευση ασθενειών. Οι τεχνικές αυτές επιτρέπουν την αυτόματη ανάλυση εικόνων φύλλων ή καλλιεργειών, μετατρέποντας οπτικά χαρακτηριστικά, όπως αλλαγές χρώματος, υφής ή μορφολογίας, σε πληροφορία χρήσιμη για τη λήψη καλλιεργητικών αποφάσεων. Παράλληλα, η ανάπτυξη μη επανδρωμένων εναέριων οχημάτων (UAV/drones) έχει ενισχύσει σημαντικά τη δυνατότητα συλλογής δεδομένων σε μεγάλη κλίμακα και με υψηλή χωρική ανάλυση, καθιστώντας εφικτή την παρακολούθηση καλλιεργειών σε πραγματικές συνθήκες αγρού.

Η καλλιέργεια της ελιάς αποτελεί έναν από τους σημαντικότερους τομείς της μεσογειακής γεωργίας, τόσο σε οικονομικό όσο και σε περιβαλλοντικό επίπεδο. Οι ασθένειες που προσβάλλουν το φύλλωμα της ελιάς μπορούν να οδηγήσουν σε μείωση της φωτοσυνθετικής επιφάνειας, εξασθένηση των δέντρων και τελικά σε απώλειες παραγωγής. Η έγκαιρη και αξιόπιστη ανίχνευση των συμπτωμάτων αποτελεί κρίσιμο παράγοντα για την αποτελεσματική φυτοπροστασία και τη βιώσιμη διαχείριση των ελαιώνων.

Παρά τη σημαντική πρόοδο που έχει σημειωθεί στον τομέα της αναγνώρισης φυτικών ασθενειών μέσω τεχνικών μηχανικής και βαθιάς μάθησης, εξακολουθούν να υπάρχουν προκλήσεις που σχετίζονται με την εφαρμογή των συστημάτων αυτών σε πραγματικές συνθήκες πεδίου. Η μεταβλητότητα φωτισμού, η πολυπλοκότητα του φόντου, η ποιότητα των εικόνων από οικονομικά προσβάσιμες πλατφόρμες UAV και η περιορισμένη διαθεσιμότητα αντιπροσωπευτικών συνόλων δεδομένων αποτελούν παράγοντες που επηρεάζουν την απόδοση των μοντέλων.

Στο πλαίσιο αυτό, η παρούσα εργασία διερευνά τη δυνατότητα ανάπτυξης και αξιολόγησης ενός συστήματος ανίχνευσης ασθενειών φύλλων ελιάς μέσω εικόνων που συλλέγονται από drone χαμηλού κόστους. Η μελέτη εστιάζει στη συγκριτική αξιολόγηση διαφορετικών προσεγγίσεων μηχανικής μάθησης και βαθιάς μάθησης, καθώς και στη διερεύνηση της συμπεριφοράς των μοντέλων σε πραγματικό χρόνο. Στόχος είναι η ανάδειξη των δυνατοτήτων αλλά και των περιορισμών των τεχνολογιών αυτών σε ρεαλιστικά σενάρια γεωργίας ακριβείας.

1. Κατά πόσο είναι εφικτή η ανίχνευση ασθενειών φύλλων ελιάς μέσω ανάλυσης εικόνας με χρήση τεχνικών μηχανικής μάθησης και βαθιάς μάθησης;

2. Ποια από τις δύο προσεγγίσεις, δηλαδή το μοντέλο SVM + HOG ή το μοντέλο Transfer Learning, παρουσιάζει καλύτερη απόδοση στην ταξινόμηση υγιών και προσβεβλημένων φύλλων ελιάς;
3. Σε ποιο βαθμό τα εκπαιδευμένα μοντέλα μπορούν να διατηρήσουν ικανοποιητική απόδοση όταν εφαρμόζονται σε πραγματικές συνθήκες πεδίου μέσω drone χαμηλού κόστους;
4. Ποιοι περιβαλλοντικοί και τεχνικοί παράγοντες, όπως ο φωτισμός, το φόντο, η γωνία λήψης και η ποιότητα της εικόνας, επηρεάζουν περισσότερο την απόδοση των μοντέλων;
5. Πόσο κατάλληλη και πρακτικά αξιοποιήσιμη είναι η συγκεκριμένη προσέγγιση για μελλοντικές εφαρμογές γεωργίας ακριβείας στην ελαιοκαλλιέργεια;

Η εργασία οργανώνεται σε πέντε κεφάλαια. Στο πρώτο κεφάλαιο παρουσιάζονται το αντικείμενο, ο σκοπός και τα ερευνητικά ερωτήματα της μελέτης. Στο δεύτερο κεφάλαιο αναπτύσσεται η θεωρητική επισκόπηση της σχετικής βιβλιογραφίας, με έμφαση στις τεχνικές μηχανικής μάθησης, βαθιάς μάθησης, υπολογιστικής όρασης και χρήσης UAV στη γεωργία ακριβείας. Στο τρίτο κεφάλαιο περιγράφεται η μεθοδολογία της έρευνας, το σύνολο δεδομένων, η διαδικασία εκπαίδευσης των μοντέλων και ο τρόπος αξιολόγησής τους. Στο τέταρτο κεφάλαιο παρουσιάζονται και αναλύονται τα πειραματικά αποτελέσματα, τόσο στο οργανωμένο σύνολο δεδομένων όσο και στις real-time δοκιμές. Τέλος, στο πέμπτο κεφάλαιο παρατίθενται τα συμπεράσματα της εργασίας, οι περιορισμοί της μελέτης και προτάσεις για μελλοντική έρευνα.

ΚΕΦΑΛΑΙΟ 2: Βιβλιογραφική Ανασκόπηση

2.1 Υπολογιστική Όραση και Τεχνητή Νοημοσύνη στη Γεωργία Ακριβείας: Θεωρητικό Πλαίσιο και Ανασκοπικές Προσεγγίσεις

Η έννοια της γεωργίας ακριβείας (precision agriculture) συνδέεται στενά με την ευρύτερη προσέγγιση του smart farming (έξυπνη γεωργία), η οποία μετατοπίζει τη διαχείριση της καλλιέργειας από πρακτικές βασισμένες κυρίως στην εμπειρία προς ένα μοντέλο λήψης αποφάσεων που στηρίζεται σε δεδομένα. Στο πλαίσιο αυτό, αξιοποιούνται τεχνολογίες όπως το Internet of Things (IoT), αισθητήρες πεδίου, συστήματα γεωεντοπισμού, τεχνητή νοημοσύνη και αυτοματισμοί, με στόχο τη συλλογή πληροφοριών για το έδαφος, τις καιρικές συνθήκες και την κατάσταση της καλλιέργειας και τη μετατροπή τους σε πρακτικές καλλιεργητικές αποφάσεις (IBM, n.d.).

Η βασική αρχή της έξυπνης γεωργίας είναι η βελτιστοποίηση της χρήσης εισροών (νερό, λίπανση, φυτοπροστατευτικά), ώστε αυτές να εφαρμόζονται στοχευμένα και όχι ομοιόμορφα σε όλο τον αγρό. Με τον τρόπο αυτό επιδιώκεται ταυτόχρονα αύξηση της παραγωγικότητας, μείωση του κόστους και περιορισμός των περιβαλλοντικών επιπτώσεων (Agrirs, 2023). Παράλληλα, η αξιοποίηση δεδομένων σε πραγματικό χρόνο επιτρέπει καλύτερο χρονισμό καλλιεργητικών παρεμβάσεων και ενισχύει τη δυνατότητα παρακολούθησης της υγείας των φυτών, στοιχείο ιδιαίτερα σημαντικό για εφαρμογές έγκαιρης ανίχνευσης ασθενειών.

Ωστόσο, η υιοθέτηση πρακτικών smart farming συνοδεύεται και από προκλήσεις. Το υψηλό αρχικό κόστος εξοπλισμού, η ανάγκη για ψηφιακές δεξιότητες και η απαίτηση ύπαρξης κατάλληλης υποδομής συνδεσιμότητας μπορούν να λειτουργήσουν ως περιοριστικοί παράγοντες, ιδιαίτερα για μικρούς παραγωγούς ή περιοχές με χαμηλό επίπεδο τεχνολογικής υποστήριξης (Agrirs, 2023). Επιπλέον, η αποτελεσματικότητα των συστημάτων αυτών εξαρτάται από την ικανότητα ενσωμάτωσης των δεδομένων στη γεωργική πράξη, ώστε να οδηγούν σε ουσιαστικές αποφάσεις και όχι απλώς σε συσσώρευση πληροφοριών χωρίς πρακτική αξιοποίηση (IBM, n.d.).

Συνολικά, το smart farming και η γεωργία ακριβείας αποτελούν βασικούς πυλώνες του ψηφιακού μετασχηματισμού της γεωργίας, συμβάλλοντας στη δημιουργία πιο αποδοτικών, ανθεκτικών και περιβαλλοντικά βιώσιμων συστημάτων παραγωγής.

Στο πλαίσιο αυτό, η αξιοποίηση τεχνικών τεχνητής νοημοσύνης και υπολογιστικής όρασης αποτελεί βασικό εργαλείο για την ανάλυση δεδομένων καλλιέργειας και την ανάπτυξη εφαρμογών παρακολούθησης της υγείας των φυτών.

Η ενσωμάτωση της υπολογιστικής όρασης και της τεχνητής νοημοσύνης στη γεωργία ακριβείας αποτελεί ένα από τα πλέον δυναμικά και ταχέως εξελισσόμενα ερευνητικά πεδία των τελευταίων ετών. Η συστηματική ανασκόπηση των Liakos et al. (2018) χαρτογραφεί διεξοδικά τις βασικές κατηγορίες εφαρμογών τεχνητής νοημοσύνης στη γεωργία, με ιδιαίτερη έμφαση στην ανάλυση εικόνων για την παρακολούθηση καλλιεργειών, τον ποιοτικό έλεγχο αγροτικών προϊόντων και την έγκαιρη ανίχνευση φυτικών ασθενειών. Οι συγγραφείς αναδεικνύουν ότι η αξία της εικόνας είτε προέρχεται από επίγειες λήψεις είτε από εναέρια μέσα αυξάνεται σημαντικά όταν

συνδυάζεται με αλγορίθμους ικανούς να μετατρέπουν οπτικά χαρακτηριστικά, όπως το χρώμα, η υφή και η μορφολογία, σε αξιοποιήσιμη πληροφορία για τη λήψη αποφάσεων στο αγροτικό περιβάλλον. Παράλληλα, τονίζεται ότι η αποτελεσματική εφαρμογή τέτοιων συστημάτων προϋποθέτει κατάλληλη υπολογιστική υποδομή, πρόσβαση σε μεγάλους όγκους δεδομένων και χρήση σύγχρονων μοντέλων μηχανικής και βαθιάς μάθησης.

Συμπληρωματικά, η ανασκόπηση των Gavhale και Gawande (2014) αποτελεί κλασικό σημείο αναφοράς για τη δομή των συστημάτων ανίχνευσης ασθενειών φύλλων με επεξεργασία εικόνας. Η εργασία παρουσιάζει αναλυτικά τα επιμέρους στάδια ενός τυπικού pipeline, ξεκινώντας από τη λήψη της εικόνας και συνεχίζοντας με την προεπεξεργασία, την τμηματοποίηση, την εξαγωγή χαρακτηριστικών και την τελική ταξινόμηση. Ιδιαίτερη σημασία αποδίδεται στο γεγονός ότι η παραδοσιακή οπτική επιθεώρηση από ειδικούς δεν μπορεί να εφαρμοστεί αποτελεσματικά σε μεγάλη κλίμακα, γεγονός που καθιστά αναγκαία την ανάπτυξη αυτοματοποιημένων μεθόδων. Ταυτόχρονα, στην εργασία επισημαίνονται βασικές προκλήσεις της ανάλυσης εικόνων σε πραγματικές συνθήκες, όπως η μεταβλητότητα φωτισμού, το σύνθετο φόντο και οι δυσκολίες ακριβούς τμηματοποίησης, οι οποίες επηρεάζουν καθοριστικά την αξιοπιστία των συστημάτων στο πεδίο.

Η πιο πρόσφατη ανασκόπηση του Sarkar (2023) συνοψίζει την εξέλιξη της έρευνας στον τομέα της διάγνωσης ασθενειών φύλλων την περίοδο 2010–2022, καλύπτοντας τόσο προσεγγίσεις μηχανικής μάθησης όσο και βαθιάς μάθησης. Η ανάλυση καταδεικνύει ότι τα μοντέλα βαθιάς μάθησης τείνουν να υπερέχουν όταν διατίθενται επαρκή και αντιπροσωπευτικά σύνολα δεδομένων, ωστόσο η απόδοσή τους επηρεάζεται έντονα από παράγοντες όπως η ανισορροπία κλάσεων, ο θόρυβος, το σύνθετο οπτικό περιβάλλον και κυρίως η προέλευση των δεδομένων. Η διάκριση μεταξύ εργαστηριακών και πεδίου δεδομένων αναδεικνύεται ως κρίσιμη, καθώς τα μοντέλα που εκπαιδεύονται σε ελεγχόμενες συνθήκες συχνά παρουσιάζουν μειωμένη γενίκευση όταν εφαρμόζονται σε ρεαλιστικά σενάρια. Το ζήτημα αυτό αποκτά ιδιαίτερη σημασία σε εφαρμογές που βασίζονται σε εναέρια δεδομένα από UAV, όπου η πολυπλοκότητα του περιβάλλοντος καθιστά απαραίτητο τον ρεαλιστικό πειραματικό σχεδιασμό και την αυστηρή αξιολόγηση.

2.2 Κλασικές Μέθοδοι Ανίχνευσης Ασθενειών Φύλλων με Επεξεργασία Εικόνας και Μηχανική Μάθηση

Οι κλασικές προσεγγίσεις ανίχνευσης ασθενειών φύλλων βασίζονται σε συνδυασμό τεχνικών επεξεργασίας εικόνας και παραδοσιακών αλγορίθμων μηχανικής μάθησης, όπου η εξαγωγή χαρακτηριστικών πραγματοποιείται χειροκίνητα πριν από το στάδιο της ταξινόμησης. Χαρακτηριστικό παράδειγμα αποτελεί η εργασία των Ganatra και Patel (2020), η οποία προτείνει ένα ολοκληρωμένο σύστημα ανίχνευσης και πολυκλασικής ταξινόμησης ασθενειών φύλλων. Το προτεινόμενο pipeline περιλαμβάνει στάδια προεπεξεργασίας, τμηματοποίησης και εξαγωγής χαρακτηριστικών που σχετίζονται με το χρώμα, την υφή, το σχήμα και τη μορφολογία των φύλλων. Στη συνέχεια, αξιολογούνται διάφοροι ταξινομητές, όπως οι Random Forest, Support Vector Machines, k-Nearest Neighbors και τεχνητά νευρωνικά δίκτυα.

Τα αποτελέσματα δείχνουν ότι ο Random Forest εμφανίζει ιδιαίτερα ανταγωνιστική απόδοση, αναδεικνύοντας ότι η προσεκτική μηχανική χαρακτηριστικών μπορεί να οδηγήσει σε υψηλά ποσοστά ακρίβειας ακόμη και χωρίς τη χρήση βαθιάς μάθησης. Παράλληλα, η εργασία υπογραμμίζει τον περιορισμό αυτών των μεθόδων σε περιβάλλοντα με έντονες μεταβολές φωτισμού, γωνίας λήψης και φόντου.

Στην ίδια κατεύθυνση, η μελέτη των Patil και Burkralli (2021) παρουσιάζει μια τυπική εφαρμογή παραδοσιακών τεχνικών μηχανικής μάθησης, υλοποιημένη στο περιβάλλον WEKA. Οι συγγραφείς εστιάζουν στην τμηματοποίηση του φύλλου από φυσικό φόντο και στην εξαγωγή χρωματικών και υφικών χαρακτηριστικών, τα οποία χρησιμοποιούνται για την εκπαίδευση και σύγκριση διαφόρων ταξινομητών, όπως SVM, KNN, Random Forest, AdaBoost, Naïve Bayes και MLP. Η μελέτη αναδεικνύει ότι ακόμη και μικρά σύνολα δεδομένων μπορούν να αξιοποιηθούν αποτελεσματικά, υπό την προϋπόθεση προσεκτικής επιλογής χαρακτηριστικών, ενώ επισημαίνεται ότι σε ορισμένες περιπτώσεις τα χρωματικά χαρακτηριστικά επαρκούν για τον διαχωρισμό υγιών και ασθενών φύλλων. Το εύρημα αυτό είναι ιδιαίτερα σημαντικό για εφαρμογές πρώιμου ελέγχου (screening), πριν την υιοθέτηση πιο σύνθετων και υπολογιστικά απαιτητικών μοντέλων.

Η εργασία των Elliott et al. (2022), δημοσιευμένη στο περιοδικό Plant Methods, λειτουργεί ως ενδεικτική «γέφυρα» μεταξύ χειροκίνητης ανάλυσης εικόνων και αυτοματοποιημένων μεθόδων μηχανικής μάθησης. Οι συγγραφείς συγκρίνουν την εκτίμηση της σοβαρότητας της ασθένειας cassava bacterial blight μέσω του λογισμικού ImageJ, με μια προσέγγιση βασισμένη σε Support Vector Machines. Το ImageJ αποτελεί ένα ευρέως χρησιμοποιούμενο επιστημονικό λογισμικό ανάλυσης εικόνων, το οποίο επιτρέπει τη μέτρηση χαρακτηριστικών μιας εικόνας, όπως η επιφάνεια προσβεβλημένων περιοχών, η ένταση χρώματος και άλλες μορφολογικές ιδιότητες. Στη συγκεκριμένη μελέτη, το εργαλείο χρησιμοποιήθηκε για την ποσοτικοποίηση της έκτασης των συμπτωμάτων στα φύλλα μέσω ημι-χειροκίνητης ανάλυσης των εικόνων. Τα αποτελέσματα καταδεικνύουν ότι και οι δύο μέθοδοι μπορούν να οδηγήσουν σε αξιόπιστες εκτιμήσεις, ωστόσο η προσέγγιση μηχανικής μάθησης παρουσιάζει σαφές πλεονέκτημα ως προς την κλιμάκωση και την ταχύτητα επεξεργασίας μεγάλου όγκου εικόνων. Το συμπέρασμα αυτό αποκτά ιδιαίτερη σημασία σε σενάρια όπου η χρήση UAV οδηγεί στη μαζική παραγωγή δεδομένων.

2.3 Βαθιά Μάθηση στην Αναγνώριση Φυτικών Ασθενειών: Συνελικτικά Δίκτυα, Μεταφορά Μάθησης και Τμηματοποίηση

Η είσοδος της βαθιάς μάθησης στον χώρο της διάγνωσης φυτικών ασθενειών μέσω εικόνων συνδέεται άμεσα με τη δυνατότητα των συνελικτικών νευρωνικών δικτύων (CNN) να μαθαίνουν αναπαραστάσεις χαρακτηριστικών απευθείας από τα δεδομένα, χωρίς την ανάγκη χειροκίνητης εξαγωγής χρώματος, υφής ή μορφολογίας. Ένα από τα πρώιμα και συχνά αναφερόμενα έργα στο πεδίο είναι η μελέτη των Sladojevic et al. (2016), η οποία προτείνει ένα πλαίσιο ταξινόμησης ασθενειών από εικόνες φύλλων με χρήση βαθιών συνελικτικών δικτύων. Η αξία της συγκεκριμένης εργασίας έγκειται στο ότι τεκμηριώνει τη μετάβαση από τις «χειροποίητες» περιγραφές χαρακτηριστικών σε learned representations, δείχνοντας πως η αύξηση της απόδοσης μπορεί να προκύψει

όχι μόνο από ισχυρότερους ταξινομητές, αλλά κυρίως από την αυτόματη εξαγωγή διακριτικών μοτίβων σε πολλαπλά επίπεδα αφαίρεσης. Ιδιαίτερη έμφαση δίνεται στην ενίσχυση δεδομένων (data augmentation) ως μηχανισμό που αυξάνει την ανθεκτικότητα του μοντέλου σε μεταβολές της εικόνας, ενώ η συστηματική οργάνωση κλάσεων και η πειθαρχημένη διαδικασία προεπεξεργασίας αναδεικνύονται ως κρίσιμες προϋποθέσεις για αξιόπιστη εκπαίδευση.

Σε ευρύτερη κλίμακα, η μελέτη των Mohanty et al. (2016) αποτελεί σημείο αναφοράς στον τομέα της αναγνώρισης ασθενειών φυτών μέσω βαθιάς μάθησης, καθώς αξιοποίησε το δημόσια διαθέσιμο σύνολο δεδομένων PlantVillage, το οποίο περιλαμβάνει μεγάλο αριθμό εικόνων φύλλων φυτών με διάφορες ασθένειες. Το συγκεκριμένο dataset χρησιμοποιείται ευρέως στη βιβλιογραφία ως σημείο αναφοράς για την αξιολόγηση αλγορίθμων αναγνώρισης ασθενειών φυτών. Στη μελέτη αυτή εξετάστηκε η δυνατότητα των συνελκτικών νευρωνικών δικτύων (CNN) να ανιχνεύουν ασθένειες φυτών με πολύ υψηλές επιδόσεις σε πολυκλασικό πλαίσιο ταξινόμησης. Η βασική συνεισφορά της εργασίας δεν περιορίζεται μόνο στην επίτευξη πολύ υψηλών τιμών ακρίβειας και F1-score σε ελεγχόμενα δεδομένα, αλλά κυρίως στην ανάδειξη του προβλήματος της γενίκευσης των μοντέλων. Συγκεκριμένα, όταν το εκπαιδευμένο μοντέλο δοκιμάστηκε σε εικόνες «πραγματικού κόσμου», οι οποίες περιλάμβαναν διαφορετικά φόντα, μεταβαλλόμενο φωτισμό και μεγαλύτερη ποικιλία στο οπτικό περιβάλλον, παρατηρήθηκε σημαντική μείωση της απόδοσης. Το εύρημα αυτό υποδεικνύει ότι τα μοντέλα που εκπαιδεύονται σε εργαστηριακά ή ελεγχόμενα σύνολα δεδομένων ενδέχεται να παρουσιάζουν υπερεκτίμηση της απόδοσής τους. Το συμπέρασμα αυτό είναι ιδιαίτερα σημαντικό για εφαρμογές σε πραγματικές συνθήκες αγρού, καθώς αναδεικνύει ότι η ανάπτυξη αξιόπιστων συστημάτων ανίχνευσης ασθενειών απαιτεί ετερογενή δεδομένα εκπαίδευσης, κατάλληλο σχεδιασμό αξιολόγησης και δοκιμές σε ρεαλιστικά περιβάλλοντα.

Σημαντική εξέλιξη στην κατεύθυνση αύξησης της αξιοπιστίας αποτελεί η προσέγγιση που ενσωματώνει τμηματοποίηση (segmentation) πριν από την τελική ταξινόμηση, ώστε το μοντέλο να εστιάζει στις βιολογικά σχετικές περιοχές και να περιορίζει τον «θόρυβο» από το περιβάλλον. Η μελέτη των Chowdhury et al. (2021) παρουσιάζει ένα χαρακτηριστικό παράδειγμα τέτοιου πλαισίου, συνδυάζοντας δίκτυα τμηματοποίησης τύπου U-Net (και παραλλαγές του) με σύγχρονες αρχιτεκτονικές ταξινόμησης όπως το EfficientNet. Η μεθοδολογική αξία της εργασίας είναι ότι αποτυπώνει ένα ολοκληρωμένο pipeline όπου η τμηματοποίηση δεν αντιμετωπίζεται ως δευτερεύον βήμα προεπεξεργασίας, αλλά ως κεντρικό στάδιο που επηρεάζει το τι «βλέπει» το μοντέλο ταξινόμησης. Έτσι, η επιτυχία δεν αποδίδεται μόνο στην ισχύ της αρχιτεκτονικής, αλλά και στη συστηματική απομόνωση του φύλλου ή/και των προσβεβλημένων περιοχών, κάτι που είναι ιδιαίτερος σημαντικό σε περιβάλλοντα με σύνθετο φόντο, συνθήκη που προσεγγίζει άμεσα τις εναέριες λήψεις και τα δεδομένα αγρού. Επιπρόσθετα, η εργασία ενισχύει τη συζήτηση γύρω από την πολυκλασική ταξινόμηση, αναδεικνύοντας ότι η αύξηση αριθμού κλάσεων επιβαρύνει την πολυπλοκότητα του προβλήματος και απαιτεί προσεκτικό χειρισμό ανισορροπίας κλάσεων και ενίσχυσης δεδομένων.

Η ανάγκη τεκμηριωμένης σύγκρισης μεταξύ παραδοσιακών αλγορίθμων μηχανικής μάθησης και βαθιάς μάθησης καλύπτεται από συγκριτικές μελέτες που αξιολογούν

πολλαπλά μοντέλα στο ίδιο πρόβλημα, με κοινές μετρικές και σταθερό πρωτόκολλο. Η εργασία των Sujatha et al. (2021) ανήκει σε αυτή την κατηγορία, καθώς συγκρίνει αλγορίθμους μηχανικής μάθησης (π.χ. SVM, Random Forest, Stochastic Gradient Descent) με προεκπαιδευμένες αρχιτεκτονικές βαθιάς μάθησης (π.χ. VGG, Inception) για την ανίχνευση ασθενειών φύλλων. Η συμβολή της εργασίας δεν έγκειται μόνο στο συμπέρασμα ότι τα μοντέλα βαθιάς μάθησης υπερτερούν συχνά, αλλά κυρίως στην ανάδειξη των όρων υπό τους οποίους αυτό συμβαίνει: η επιτυχία των CNN συνδέεται με την ικανότητα αυτόματης εξαγωγής χαρακτηριστικών, ωστόσο συνοδεύεται από αυξημένες απαιτήσεις σε δεδομένα, υπολογιστικούς πόρους και ρυθμίσεις εκπαίδευσης. Παράλληλα, τονίζεται ότι η αξιολόγηση δεν μπορεί να εξαντλείται στην ακρίβεια, καθώς σε πολυκλασικά ή ανισόρροπα σύνολα δεδομένων η χρήση precision, recall, F1-score και άλλων μετρικών είναι καθοριστική για ουσιαστική ερμηνεία της απόδοσης.

Συνολικά, η βιβλιογραφία στη βαθιά μάθηση για διάγνωση ασθενειών αναδεικνύει ένα σαφές συμπέρασμα: τα CNN και η μεταφορά μάθησης μπορούν να παράγουν πολύ υψηλές επιδόσεις σε ελεγχόμενα σύνολα δεδομένων και προσφέρουν ισχυρότερη διακριτική ικανότητα από τις κλασικές προσεγγίσεις, όμως η μετάβαση σε πραγματικές συνθήκες απαιτεί αντιμετώπιση του προβλήματος γενίκευσης μέσω ετερογενών datasets, αυστηρών πρωτοκόλλων αξιολόγησης και μεθοδολογικών επιλογών όπως η τμηματοποίηση που περιορίζει την επίδραση του φόντου. Η κατανόηση αυτών των παραμέτρων είναι κρίσιμη, διότι προετοιμάζει τη μετάβαση προς το επόμενο θεματικό επίπεδο: δεδομένα πεδίου και εναέρια συλλογή εικόνων, όπου οι συνθήκες λήψης μεταβάλλονται έντονα και οι απαιτήσεις αξιοπιστίας γίνονται αυστηρότερες.

2.4 Δεδομένα Πεδίου και Ικανότητα Γενίκευσης Μοντέλων σε Ρεαλιστικά Περιβάλλοντα Καλλιέργειας

Η απόδοση συστημάτων μηχανικής και βαθιάς μάθησης για την ανίχνευση φυτικών ασθενειών μέσω εικόνων εξαρτάται σε καθοριστικό βαθμό από τη φύση των δεδομένων που χρησιμοποιούνται κατά την εκπαίδευση και την αξιολόγηση των μοντέλων. Όπως επισημαίνεται στη μελέτη των Mohanty et al. (2016), μεγάλο μέρος της πρώιμης έρευνας βασίστηκε σε εικόνες που συλλέχθηκαν σε ελεγχόμενα ή ημιελεγχόμενα περιβάλλοντα, με ομοιόμορφο φόντο και περιορισμένη οπτική μεταβλητότητα. Αν και αυτή η προσέγγιση διευκόλυνε την επίτευξη υψηλών επιδόσεων, ταυτόχρονα οδήγησε στην ανάπτυξη μοντέλων με περιορισμένη ικανότητα γενίκευσης όταν εφαρμόστηκαν σε πραγματικές συνθήκες αγρού. Η ίδια προβληματική αναδεικνύεται και σε μεταγενέστερες ανασκοπήσεις, όπου τονίζεται ότι η υψηλή ακρίβεια σε εργαστηριακά δεδομένα δεν αποτελεί απαραίτητα αξιόπιστο δείκτη της πραγματικής επιχειρησιακής απόδοσης των μοντέλων σε περιβάλλοντα καλλιέργειας.

Η ανάγκη μετάβασης από εργαστηριακά σύνολα δεδομένων σε δεδομένα πεδίου αναδεικνύεται έντονα στη σύγχρονη βιβλιογραφία. Σύμφωνα με τον Sarkar (2023), τα δεδομένα πεδίου χαρακτηρίζονται από σύνθετο και ετερογενές φόντο, μεταβαλλόμενο φωτισμό, σκιάσεις, επικαλύψεις φύλλων και διαφοροποιήσεις που σχετίζονται με το στάδιο ανάπτυξης των φυτών και τις επικρατούσες περιβαλλοντικές συνθήκες. Οι Shahi et al. (2023) υπογραμμίζουν ότι οι παράγοντες αυτοί αυξάνουν σημαντικά τη

δυσκολία του προβλήματος και καθιστούν εμφανή τα όρια μοντέλων που έχουν εκπαιδευτεί αποκλειστικά σε «καθαρά» δεδομένα. Ως αποτέλεσμα, η αξιολόγηση σε ρεαλιστικά περιβάλλοντα θεωρείται πλέον απαραίτητη προϋπόθεση για την ανάπτυξη αξιόπιστων συστημάτων ανίχνευσης ασθενειών.

Στο πλαίσιο αυτό, το σύνολο δεδομένων FieldPlant προτείνεται ως χαρακτηριστικό παράδειγμα dataset πεδίου που στοχεύει στη ρεαλιστική αποτύπωση των συνθηκών καλλιέργειας. Όπως περιγράφεται από τους Pacal et al. (2023), το FieldPlant περιλαμβάνει εικόνες φυτών που έχουν συλλεχθεί απευθείας από τον αγρό, με φυσική μεταβλητότητα φωτισμού και σύνθετο φόντο, και συνοδεύονται από επισημειώσεις σχεδιασμένες ώστε να είναι χρήσιμες για πρακτικές εφαρμογές ανίχνευσης ασθενειών. Η σημασία τέτοιων συνόλων δεδομένων έγκειται στο ότι επιτρέπουν την αξιολόγηση της πραγματικής ικανότητας γενίκευσης των μοντέλων και όχι απλώς της απόδοσής τους σε ιδανικές ή τεχνητά ελεγχόμενες συνθήκες.

Ένας επιπλέον κρίσιμος παράγοντας που σχετίζεται με τα δεδομένα πεδίου αφορά την ποιότητα και την αξιοπιστία των επισημειώσεων. Σε πολλές περιπτώσεις, τα οπτικά συμπτώματα των ασθενειών είναι ήπια ή δυσδιάκριτα, ιδιαίτερα στα πρώιμα στάδια προσβολής, γεγονός που αυξάνει την πιθανότητα σφαλμάτων κατά την ετικετοποίηση των εικόνων. Η ανασκόπηση των Buonauro et al. (2023) για το olive leaf spot υπογραμμίζει ότι η ασθένεια μπορεί να εμφανίζει λανθάνουσα φάση, δηλαδή μια περίοδο κατά την οποία το παθογόνο έχει ήδη μολύνει το φύλλο αλλά τα ορατά συμπτώματα δεν είναι ακόμη εμφανή ή είναι πολύ περιορισμένα. Η ιδιαιτερότητα αυτή δυσχεραίνει την οπτική διάγνωση της ασθένειας και καθιστά απαραίτητη την επισημείωση των δεδομένων από ειδικούς, όπως φυτοπαθολόγους ή γεωπόνους. Παρόμοια, οι Pacal et al. (2023) τονίζουν ότι η ποιότητα του ground truth, δηλαδή των σωστών ετικετών που αποδίδονται στις εικόνες, αποτελεί βασική προϋπόθεση για την εκπαίδευση μοντέλων που προορίζονται για εφαρμογή σε πραγματικές συνθήκες αγρού.

Τα δεδομένα πεδίου εισάγουν επίσης έντονα φαινόμενα ανισορροπίας κλάσεων, καθώς οι υγιείς περιπτώσεις συχνά υπερσχύουν αριθμητικά των ασθενών, ιδιαίτερα σε περιόδους χαμηλής έντασης προσβολής. Οι Sujatha et al. (2021) επισημαίνουν ότι σε τέτοια σενάρια η αποκλειστική χρήση της ακρίβειας (accuracy) μπορεί να οδηγήσει σε παραπλανητικά συμπεράσματα, καθώς ένα μοντέλο μπορεί να εμφανίζεται «ακριβές» απλώς προβλέποντας την κυρίαρχη κλάση. Αντίστοιχα, οι Shahi et al. (2023) προτείνουν τη χρήση μετρικών όπως το recall και το F1-score, οι οποίες αποτυπώνουν πιο ρεαλιστικά την ικανότητα ανίχνευσης των ασθενών περιπτώσεων σε πραγματικές συνθήκες.

Συνολικά, η βιβλιογραφία καταδεικνύει ότι η ανάπτυξη αξιόπιστων συστημάτων ανίχνευσης ασθενειών δεν εξαρτάται αποκλειστικά από την επιλογή προηγμένων αλγορίθμων μηχανικής ή βαθιάς μάθησης. Αντιθέτως, απαιτείται προσεκτικός σχεδιασμός της συλλογής δεδομένων, αξιόπιστη επισημείωση και ρεαλιστικά πρωτόκολλα αξιολόγησης που λαμβάνουν υπόψη τη μεταβλητότητα του αγρού. Η εστίαση σε δεδομένα πεδίου αποτελεί αναγκαίο βήμα για τη γεφύρωση του χάσματος μεταξύ εργαστηριακής έρευνας και πρακτικής εφαρμογής και δημιουργεί το υπόβαθρο

για τη χρήση εναέριων πλατφορμών συλλογής δεδομένων, όπου η πολυπλοκότητα του περιβάλλοντος αυξάνεται περαιτέρω (Mohanty et al., 2016· Zhang et al., 2023).

2.5 Μη Επανδρωμένα Εναέρια Οχήματα στη Γεωργία Ακριβείας: Συλλογή Δεδομένων, Τηλεπισκόπηση και Ανάλυση Εικόνας για Ανίχνευση Ασθενειών

Η αξιοποίηση μη επανδρωμένων εναέριων οχημάτων (UAV/drones) στη γεωργία ακριβείας αποτελεί μία από τις σημαντικότερες τεχνολογικές εξελίξεις των τελευταίων ετών, καθώς επιτρέπει συλλογή χωρικών δεδομένων υψηλής ανάλυσης με μεγάλη συχνότητα επανάληψης και χαμηλότερο επιχειρησιακό κόστος σε σχέση με εναλλακτικές λύσεις εναέριας αποτύπωσης. Το ιδιαίτερο πλεονέκτημα των UAV για φυτοπαθολογικές εφαρμογές είναι ότι μετατρέπουν την παρακολούθηση της υγείας των φυτών σε συστηματική διαδικασία καταγραφής, όπου οι οπτικές μεταβολές (κηλιδώσεις, χλωρώσεις, ανομοιογένειες κόμης) μπορούν να εντοπιστούν σε πρώιμα στάδια και να συσχετισθούν με παρεμβάσεις διαχείρισης στο χωράφι.

Η ανασκόπηση των Dutta και Goswami (2020) παρουσιάζει τα UAV ως βασικό εργαλείο της γεωργίας ακριβείας, επισημαίνοντας ότι η υψηλή χωρική ανάλυση, η δυνατότητα γρήγορων επαναληπτικών πτήσεων και η ευελιξία στη χρήση διαφορετικών αισθητήρων (RGB, NIR και θερμικών) μετατρέπουν τα drones σε αποτελεσματικές πλατφόρμες συλλογής δεδομένων για την έγκαιρη ανίχνευση φυτικής καταπόνησης (plant stress). Η καταπόνηση αυτή μπορεί να οφείλεται σε παράγοντες όπως έλλειψη νερού, ασθένειες, θρεπτικές ανεπάρκειες ή άλλες περιβαλλοντικές πιέσεις που επηρεάζουν την υγεία των φυτών. Ιδιαίτερη έμφαση δίνεται στη χρήση δεικτών βλάστησης, όπως ο NDVI (Normalized Difference Vegetation Index), οι οποίοι επιτρέπουν την ανίχνευση μεταβολών στη φυσιολογική κατάσταση της καλλιέργειας πριν αυτές γίνουν ορατές με γυμνό μάτι. Επιπλέον, η χρήση τέτοιων δεδομένων μπορεί να υποστηρίξει στοχευμένες καλλιεργητικές παρεμβάσεις, όπως ακριβέστερη άρδευση ή εφαρμογή φυτοπροστατευτικών μέτρων, συμβάλλοντας στη μείωση εισροών και απωλειών παραγωγής.

Η ανασκοπική εργασία των Zhang et al. (2022) συνδέει με πιο συστηματικό τρόπο τα UAV με τη φυτική φαινοτυπική ανάλυση υπό συνθήκες αγρού, υποστηρίζοντας ότι η εναέρια καταγραφή γεφυρώνει το κενό ανάμεσα σε ελεγχόμενες πειραματικές συνθήκες και πραγματικά αγροοικοσυστήματα. Η μελέτη τεκμηριώνει τη συμβολή πολυφασματικών, υπερφασματικών και θερμικών αισθητήρων στην εξαγωγή δεικτών που σχετίζονται με φωτοσυνθετική δραστηριότητα, θρεπτική κατάσταση, βιομάζα και υδατικό στρες, τονίζοντας ότι η επιχειρησιακή αξία των UAV αυξάνεται όταν τα δεδομένα συνδυάζονται με αναλυτικές μεθόδους μηχανικής μάθησης, λόγω του μεγάλου όγκου και της πολυπλοκότητάς τους.

Η ανασκόπηση των Olson και Andersen (2021) εστιάζει περισσότερο στη συστηματική διάσταση της εναέριας τηλεπισκόπησης: τύποι UAV, κατηγορίες αισθητήρων, διαδικασίες επεξεργασίας εικόνων και πρακτικές απαιτήσεις γεωαναφοράς και δημιουργίας ορθομωσαϊκών. Η συμβολή της εργασίας είναι ότι μετατοπίζει την έμφαση από το μοντέλο ανάλυσης στο σύνολο της αλυσίδας παραγωγής δεδομένων,

τεκμηριώνοντας πως παράγοντες όπως ο καιρός, η ποιότητα λήψης, η διαχείριση του όγκου δεδομένων και η αξιοπιστία της φωτογραμμετρικής επεξεργασίας επηρεάζουν άμεσα την τελική χρησιμότητα των δεδομένων για εφαρμογές ανίχνευσης ασθενειών.

Η εργασία του Nunes (2023) τοποθετεί τη χρήση UAV σε ένα ευρύτερο πλαίσιο υιοθέτησης τεχνολογίας στη γεωργία, παρουσιάζοντας τόσο τις κατηγορίες drones (multi-rotor, fixed-wing, υβριδικά) όσο και την αντιστοίχιση τύπου UAV–εφαρμογής. Η ανάλυση αναδεικνύει τη διάκριση μεταξύ αποστολών κοντινής επιτήρησης/ακριβείας (όπου υπερέχουν τα πολυκόπτερα) και εκτεταμένης χαρτογράφησης (όπου υπερέχουν τα fixed-wing), ενώ υπογραμμίζει περιορισμούς όπως η διάρκεια πτήσης, το ωφέλιμο φορτίο και οι κανονιστικές απαιτήσεις, οι οποίοι επηρεάζουν τη σχεδίαση ενός ρεαλιστικού πρωτοκόλλου συλλογής δεδομένων.

Σε επίπεδο “state of the art”, η ανασκόπηση των Shahi et al. (2023) συγκεντρώνει πρόσφατες προσεγγίσεις ανίχνευσης ασθενειών με UAV και βαθιά μάθηση, καλύπτοντας ένα ευρύ φάσμα μεθοδολογιών που εκτείνεται από την ταξινόμηση εικόνων έως την τμηματοποίηση και την ανίχνευση αντικειμένων. Η μελέτη επισημαίνει ότι οι σημαντικότερες προκλήσεις σχετίζονται με τη μεταβλητότητα των συνθηκών πεδίου, την ανάγκη για μεγάλα και καλά επισημασμένα σύνολα δεδομένων, καθώς και με τη γενίκευση των μοντέλων σε διαφορετικές καλλιέργειες, ποικιλίες και συνθήκες λήψης. Η εργασία αναδεικνύει ότι η επιτυχία συστημάτων ανίχνευσης ασθενειών που βασίζονται σε UAV δεν εξαρτάται μόνο από την υπολογιστική αρχιτεκτονική των μοντέλων, αλλά και από την ποιότητα του πρωτοκόλλου συλλογής και επεξεργασίας των δεδομένων.

Η μελέτη των Amarasingam et al. (2022) αποτελεί αντιπροσωπευτικό παράδειγμα μετάβασης από “image-level classification” σε “object detection” για εναέρια δεδομένα, καθώς αξιολογεί σύγχρονα μοντέλα ανίχνευσης (με έμφαση σε YOLO αρχιτεκτονικές) για τον εντοπισμό φυτών με συμπτώματα White Leaf Disease σε εικόνες UAV. Η σημασία τέτοιων προσεγγίσεων έγκειται στο ότι υπηρετούν άμεσα επιχειρησιακές ανάγκες, καθώς δεν αρκούνται στην αναγνώριση κατηγορίας, αλλά προσδιορίζουν χωρικά τη θέση του προβλήματος, επιτρέποντας στοχευμένες παρεμβάσεις σε τμήματα αγρού ή σε συγκεκριμένες γραμμές καλλιέργειας.

Η εργασία του Maes (2025) παρέχει πρακτικές κατευθύνσεις για UAV mapping flights με snapshot αισθητήρες, αναλύοντας παραμέτρους όπως το ύψος πτήσης και το GSD, οι επικαλύψεις εικόνων, η ταχύτητα, η γωνία λήψης και η χρήση σημείων ελέγχου εδάφους (GCPs). Η αξία της μελέτης στη σχεδίαση ερευνητικών πρωτοκόλλων είναι ότι τεκμηριώνει πώς οι επιλογές πτήσης επηρεάζουν τη γεωμετρική και ραδιομετρική ποιότητα των εικόνων, άρα και την αξιοπιστία των μοντέλων μηχανικής μάθησης που χρησιμοποιούνται στη συνέχεια για ανίχνευση ασθενειών.

Η εργασία των Vélez et al. (2022) παρουσιάζει ένα υψηλής ανάλυσης UAV RGB dataset πάνω από δενδρόνα, συνοδευόμενο από φωτογραμμετρικά προϊόντα (orthomosaic, DEM, point cloud) και τεκμηριωμένη μεθοδολογία συλλογής με χρήση GCPs. Αν και δεν αφορά άμεσα φυτοπαθολογία, είναι ιδιαίτερα χρήσιμη βιβλιογραφικά επειδή αποτυπώνει τι σημαίνει “καλά τεκμηριωμένο” UAV dataset στην πράξη, δηλαδή σαφείς συνθήκες λήψης, επαναληψιμότητα και παροχή προϊόντων που επιτρέπουν είτε ανάλυση σε επίπεδο μεμονωμένων εικόνων είτε σε επίπεδο χαρτών.

Συνολικά, η βιβλιογραφία σχετικά με UAV στη γεωργία ακριβείας συγκλίνει στο ότι τα drones δεν αποτελούν απλώς μέσο “λήψης φωτογραφιών”, αλλά κρίσιμο κρίκο σε μία αλυσίδα που ξεκινά από τον σχεδιασμό πτήσης και καταλήγει σε επιχειρησιακές αποφάσεις. Η μετάβαση σε ρεαλιστικά δεδομένα πεδίου και η ανάπτυξη μοντέλων που μπορούν να λειτουργήσουν αξιόπιστα υπό μεταβαλλόμενες συνθήκες αποτελούν το βασικό υπόβαθρο για εφαρμογές ανίχνευσης ασθενειών σε δενδρώδεις καλλιέργειες, όπως η ελιά.

Η ποιότητα των εικόνων που συλλέγονται από UAV, ιδιαίτερα όταν χρησιμοποιούνται οικονομικά προσβάσιμες πλατφόρμες, δεν εξαρτάται μόνο από την ανάλυση της κάμερας αλλά και από τις συνθήκες και τις παραμέτρους της λήψης. Παράγοντες όπως το ύψος πτήσης και το αντίστοιχο GSD (Ground Sampling Distance), η ταχύτητα του drone, η πιθανή θόλωση λόγω κίνησης, τα ποσοστά επικάλυψης των εικόνων, η επιλογή κατακόρυφης (nadir) ή λοξής γωνίας λήψης, καθώς και η χρήση σημείων ελέγχου εδάφους (Ground Control Points – GCPs) για γεωαναφορά, επηρεάζουν άμεσα την ποιότητα των δεδομένων που συλλέγονται. Οι παράγοντες αυτοί επηρεάζουν επίσης την ακρίβεια των παραγόμενων ορθομωσαϊκών και, κατ’ επέκταση, την αξιοπιστία των δεδομένων που χρησιμοποιούνται ως είσοδος σε αλγορίθμους μηχανικής μάθησης.

Οι πρακτικές κατευθυντήριες οδηγίες για πτήσεις χαρτογράφησης που συνοψίζονται από τον Maes (2025) δείχνουν ότι η τυποποίηση των παραμέτρων λήψης αποτελεί βασική προϋπόθεση για την παραγωγή συγκρίσιμων και επαναλήψιμων δεδομένων, ιδιαίτερα σε εφαρμογές όπου απαιτείται η ανίχνευση μικρών ή πρώιμων συμπτωμάτων ασθενειών στα φυτά.

2.6 Ελιά: Βιολογικό Υπόβαθρο Ασθενειών Φυλλώματος, Έγκαιρη Διάγνωση και Πρόγνωση Κινδύνου

Η ανίχνευση ασθενειών της ελιάς μέσω υπολογιστικής όρασης και τεχνητής νοημοσύνης προϋποθέτει σαφή κατανόηση του βιολογικού και επιδημιολογικού πλαισίου των ασθενειών-στόχων. Η ορθότητα των κλάσεων, η ερμηνεία των συμπτωμάτων και η επιλογή χρόνου/τρόπου συλλογής δεδομένων εξαρτώνται άμεσα από το πώς εξελίσσεται η ασθένεια στον χρόνο, ποιες περιβαλλοντικές συνθήκες την ευνοούν και πότε τα συμπτώματα γίνονται οπτικά διακριτά.

Η ανασκόπηση των Buonaurio et al. (2023) παρέχει μια εκτενή και επικαιροποιημένη σύνθεση για το olive leaf spot (*Venturia oleaginea*), αναδεικνύοντας τη μεγάλη οικονομική σημασία της ασθένειας και το βασικό πρόβλημα της έγκαιρης διάγνωσης λόγω λανθάνουσας φάσης και δυσδιάκριτων πρώιμων συμπτωμάτων. Η εργασία συστηματοποιεί τη γνώση για κύκλο ζωής, επιδημιολογία και πρακτικές διαχείρισης, ενώ υπογραμμίζει ότι οι περιορισμοί στη χρήση χαλκούχων σκευασμάτων ενισχύουν την ανάγκη ανάπτυξης εναλλακτικών, πιο βιώσιμων στρατηγικών. Η θεμελιώδης συμβολή της ανασκόπησης είναι ότι ορίζει γιατί η “έγκαιρη ανίχνευση” αποτελεί κρίσιμη προτεραιότητα και γιατί οι τεχνολογίες παρακολούθησης (όπως UAV και υπολογιστική όραση) μπορούν να ενταχθούν λειτουργικά σε ένα πλαίσιο ολοκληρωμένης διαχείρισης.

Η εργασία των Scibetta et al. (2020) τεκμηριώνει ότι η έγκαιρη διάγνωση της ασθένειας olive leaf spot (OLS), γνωστής και ως κυκλοκόνιο της ελιάς, δεν βασίζεται αποκλειστικά στην οπτική παρατήρηση. Οι συγγραφείς ανέπτυξαν και εφάρμοσαν μέθοδο qPCR για την ανίχνευση και ποσοτικοποίηση του παθογόνου σε ασυμπτωματικά φύλλα. Η μελέτη δείχνει ότι ο εντοπισμός του παθογόνου μπορεί να προηγείται σημαντικά της εμφάνισης ορατών συμπτωμάτων, γεγονός που επηρεάζει την επιδημιολογική κατανόηση της νόσου και τον χρονισμό των παρεμβάσεων. Για εφαρμογές υπολογιστικής όρασης, η εργασία αναδεικνύει ένα σημαντικό μεθοδολογικό ζήτημα: το ground truth των δεδομένων μπορεί να βασίζεται και σε μοριακή επιβεβαίωση, ιδιαίτερα σε πρώιμα στάδια όπου η οπτική ταξινόμηση των συμπτωμάτων είναι αβέβαιη.

Η μελέτη των Thomidis et al. (2021) εξετάζει την ασθένεια olive leaf spot (κυκλοκόνιο της ελιάς) από την οπτική της πρόγνωσης κινδύνου, αξιολογώντας προγνωστικά μοντέλα που βασίζονται σε περιβαλλοντικές μεταβλητές, όπως η θερμοκρασία και η διάρκεια διαβροχής των φύλλων. Τα αποτελέσματα της εργασίας δείχνουν ότι η εμφάνιση της νόσου συνδέεται στενά με συγκεκριμένες περιόδους ευνοϊκών περιβαλλοντικών συνθηκών, οι οποίες μπορούν να προβλεφθούν και να αξιοποιηθούν για στοχευμένη φυτοπροστασία. Η χρήση τέτοιων προγνωστικών μοντέλων στο πλαίσιο της ψηφιακής γεωργίας επιτρέπει πιο στρατηγική παρακολούθηση των καλλιεργειών, καθώς ο χρονισμός ελέγχων ή πτήσεων UAV μπορεί να επικεντρωθεί σε περιόδους αυξημένου κινδύνου, βελτιώνοντας την αποτελεσματικότητα τόσο της επιτήρησης όσο και των καλλιεργητικών παρεμβάσεων.

Η εργασία των Abuamsha et al. (2013) εξετάζει συστηματικά την εμφάνιση και τη σοβαρότητα της OLS σε διαφορετικές ποικιλίες ελιάς υπό πραγματικές συνθήκες καλλιέργειας, αναδεικνύοντας τη σημαντική ποικιλιακή διαφοροποίηση στην ευπάθεια. Η μελέτη ενισχύει τη θέση ότι η εκτίμηση της νόσου απαιτεί συνδυασμό δεικτών (incidence και severity) και ότι οι περιβαλλοντικοί παράγοντες επηρεάζουν τη χρονική εξέλιξη της προσβολής. Για την ανάπτυξη μοντέλων όρασης, το κεντρικό μήνυμα είναι ότι η οπτική έκφραση της νόσου μπορεί να μεταβάλλεται ανά ποικιλία και περίοδο, άρα η αντιπροσωπευτικότητα των δεδομένων αποτελεί κρίσιμη παράμετρο για γενίκευση.

Η μελέτη των Rhouma et al. (2013) εστιάζει στη γενετική και φαινοτυπική διαφοροποίηση ανθεκτικότητας απέναντι στην OLS σε υβρίδια ελιάς, αξιοποιώντας τόσο επιτόπιες παρατηρήσεις όσο και εργαστηριακές δοκιμές τεχνητού εμβολιασμού. Η εργασία αναδεικνύει ότι η ανθεκτικότητα δεν είναι μονοδιάστατο χαρακτηριστικό, αλλά προκύπτει από συνδυασμούς μορφολογικών και φυσιολογικών παραμέτρων, ενώ επισημαίνει την αξία αξιόπιστων πρωτοκόλλων αξιολόγησης για διαλογή γενετικού υλικού. Για την υπολογιστική όραση, η σημασία είναι έμμεση αλλά ουσιαστική: υποδεικνύει ότι η ένταση και η μορφή συμπτωμάτων μπορεί να σχετίζονται με χαρακτηριστικά φύλλου, άρα η οπτική ταξινόμηση επηρεάζεται από βιολογικές διαφοροποιήσεις που πρέπει να λαμβάνονται υπόψη στη δόμηση των κλάσεων και στην ερμηνεία των αποτελεσμάτων.

Η εργασία των Estudillo et al. (2025) μεταφέρει τη συζήτηση σε πιο σύγχρονο γενετικό/γονιδιωματικό επίπεδο, διερευνώντας υποψήφια γονίδια ανθεκτικότητας της

ελιάς έναντι του παθογόνου που προκαλεί scab/leaf spot, με έμφαση σε ομόλογα μοτίβα ανθεκτικότητας που είναι γνωστά από άλλα φυτικά συστήματα. Η μελέτη συνδυάζει συγκριτική γονιδιοματική με δεδομένα πεδίου μακράς διάρκειας, υποστηρίζοντας ότι η ανθεκτικότητα πρέπει να εξετάζεται και ως “ανθεκτική στον χρόνο” ιδιότητα στο πλαίσιο πραγματικών καλλιεργητικών πρακτικών. Η συμβολή της στο ευρύτερο πλαίσιο της παρούσας θεματολογίας είναι ότι δείχνει πως η ανίχνευση ασθενειών δεν είναι τελικό ζητούμενο αλλά μέρος ολοκληρωμένης στρατηγικής που περιλαμβάνει επιλογή ποικιλιών και μείωση εξάρτησης από χημικές εισροές, στοιχείο ιδιαίτερα σημαντικό για βιώσιμα συστήματα ελαιοκαλλιέργειας.

2.7 Ανίχνευση και Ταξινόμηση Ασθενειών Φύλλων Ελιάς με Τεχνικές Μηχανικής και Βαθιάς Μάθησης

Η εφαρμογή τεχνικών μηχανικής και βαθιάς μάθησης στην ανίχνευση ασθενειών φύλλων ελιάς αποτελεί ένα σχετικά εξειδικευμένο ερευνητικό πεδίο, το οποίο έχει μελετηθεί λιγότερο σε σύγκριση με άλλες καλλιέργειες. Για τον λόγο αυτό, η σχετική βιβλιογραφία είναι ιδιαίτερα σημαντική για την κατανόηση των υφιστάμενων προσεγγίσεων αλλά και των ερευνητικών κενών που εξακολουθούν να υπάρχουν.

Ιδιαίτερη σημασία έχουν οι βιολογικές και μορφολογικές ιδιαιτερότητες της ελιάς, οι οποίες επηρεάζουν άμεσα την ανάπτυξη και την αξιολόγηση συστημάτων υπολογιστικής όρασης. Παράγοντες όπως η μορφολογία των φύλλων, η διαφοροποίηση μεταξύ ποικιλιών και η συχνά ανομοιογενής εμφάνιση των συμπτωμάτων των ασθενειών καθιστούν την ανίχνευση μέσω εικόνων πιο απαιτητική σε σύγκριση με άλλες καλλιέργειες.

Η εργασία των Uğuz και Uysal (2021) αποτελεί μια μελέτη που εστιάζει στην ταξινόμηση ασθενειών φύλλων ελιάς με χρήση συνελκτικών νευρωνικών δικτύων (CNN) και τεχνικών μεταφοράς μάθησης. Οι συγγραφείς αξιολογούν διαφορετικές αρχιτεκτονικές CNN σε σενάρια διάκρισης μεταξύ υγιών φύλλων και φύλλων που έχουν προσβληθεί από ασθένειες, όπως το peacock spot (γνωστό και ως olive leaf spot ή κυκλοκόνιο της ελιάς). Η ασθένεια αυτή προκαλεί χαρακτηριστικές κυκλικές σκούρες κηλίδες στα φύλλα, οι οποίες συχνά περιβάλλονται από κιτρινωπό δακτύλιο και μπορεί να οδηγήσουν σε πρόωρη φυλλόπτωση και μείωση της παραγωγής. Για την αντιμετώπιση του περιορισμένου όγκου δεδομένων, οι συγγραφείς εφαρμόζουν τεχνικές ενίσχυσης δεδομένων (data augmentation). Τα αποτελέσματα της μελέτης δείχνουν ότι η προσεκτική ρύθμιση των παραμέτρων εκπαίδευσης και η χρήση κατάλληλων μετρικών αξιολόγησης, πέραν της απλής ακρίβειας, συμβάλλουν ουσιαστικά στη βελτίωση της ικανότητας γενίκευσης των μοντέλων.

Ιδιαίτερης σημασίας για εφαρμογές σε πραγματικές συνθήκες πεδίου είναι η εργασία των Ksibi et al. (2022), η οποία συνδέει άμεσα την καλλιέργεια της ελιάς με εικόνες UAV και βαθιά μάθηση. Οι συγγραφείς προτείνουν ένα υβριδικό μοντέλο, το MobiRes-Net, σχεδιασμένο ώστε να επιτυγχάνει ισορροπία μεταξύ ακρίβειας και υπολογιστικής αποδοτικότητας, στοιχείο κρίσιμο για εφαρμογές που βασίζονται σε εναέρια δεδομένα. Η μελέτη περιγράφει αναλυτικά τη διαδικασία συλλογής και προεπεξεργασίας εικόνων drone, τη χρήση ενίσχυσης δεδομένων και την αξιολόγηση με μετρικές όπως precision,

recall και F1-score. Η εργασία αποδεικνύει τη δυνατότητα επιχειρησιακής ανίχνευσης ασθενειών ελιάς με UAV, ενώ ταυτόχρονα αναδεικνύει τις προκλήσεις γενίκευσης σε διαφορετικές συνθήκες λήψης.

Η μελέτη των Alshammari et al. (2023) προτείνει μια εναλλακτική προσέγγιση που δεν περιορίζεται αποκλειστικά σε καθαρά συνελκτικά δίκτυα, αλλά συνδυάζει επιλογή χαρακτηριστικών και βελτιστοποίηση πριν την τελική ταξινόμηση. Η εργασία δείχνει ότι, σε περιπτώσεις περιορισμένων συνόλων δεδομένων, η υβριδική αυτή στρατηγική μπορεί να βελτιώσει την απόδοση και να μειώσει τον κίνδυνο υπερεφαρμογής. Η σημασία της μελέτης για την ελιά έγκειται στο ότι υπογραμμίζει τη σημασία της ποιότητας και της αντιπροσωπευτικότητας των εισόδων, ιδιαίτερα όταν η συλλογή μεγάλου όγκου δεδομένων είναι δύσκολη ή δαπανηρή.

Η εργασία των Pacal et al. (2025) κινείται προς πιο σύγχρονες αρχιτεκτονικές βαθιάς μάθησης, αξιοποιώντας δομές τύπου MetaFormer και μηχανισμούς προσοχής για την ανίχνευση ασθενειών φύλλων ελιάς. Η μελέτη αναδεικνύει ότι τα παραδοσιακά συνελκτικά δίκτυα, αν και αποτελεσματικά, ενδέχεται να περιορίζονται στην αποτύπωση τοπικών μοτίβων, ενώ οι αρχιτεκτονικές προσοχής μπορούν να συλλάβουν πιο σφαιρικές σχέσεις στην εικόνα. Η συμβολή της εργασίας είναι κυρίως ενδεικτική της κατεύθυνσης που ακολουθεί η έρευνα, δείχνοντας πώς πιο προχωρημένα μοντέλα επιχειρούν να ξεπεράσουν περιορισμούς προηγούμενων προσεγγίσεων.

Σε αντίθεση με τις παραπάνω βαθιές προσεγγίσεις, η εργασία των Sinha και Shekhawat (2020) αποτελεί χαρακτηριστικό παράδειγμα κλασικής επεξεργασίας εικόνας για την ανίχνευση ασθενειών φύλλων ελιάς, με έμφαση σε χαρακτηριστικά υφής για την αναγνώριση κηλιδώσεων όπως το peacock leaf spot. Η μελέτη βασίζεται σε τμηματοποίηση και εξαγωγή στατιστικών χαρακτηριστικών υφής, τα οποία χρησιμοποιούνται για την ταξινόμηση των φύλλων. Η εργασία καταδεικνύει τη διακριτική ικανότητα της υφής ως οπτικού χαρακτηριστικού στις ασθένειες της ελιάς, ενώ ταυτόχρονα λειτουργεί ως σημείο αναφοράς για τη σύγκριση με πιο σύγχρονες προσεγγίσεις βαθιάς μάθησης.

Συνολικά, η βιβλιογραφία που εστιάζει στην ελιά καταδεικνύει ότι οι τεχνικές βαθιάς μάθησης υπερέχουν σε ακρίβεια και ευρωστία όταν υποστηρίζονται από επαρκή και αντιπροσωπευτικά δεδομένα, ωστόσο η συλλογή τέτοιων δεδομένων παραμένει πρόκληση. Παράλληλα, υβριδικές ή κλασικές προσεγγίσεις διατηρούν τη σημασία τους σε σενάρια περιορισμένων πόρων, προσφέροντας εναλλακτικές λύσεις για πρώιμο εντοπισμό ή πιλοτικές εφαρμογές. Η ανάγκη συνδυασμού εναέριας συλλογής δεδομένων, βιολογικής κατανόησης των ασθενειών και κατάλληλων μοντέλων μάθησης αναδεικνύεται ως κεντρικό συμπέρασμα για την ανάπτυξη αξιόπιστων συστημάτων ανίχνευσης ασθενειών φύλλων ελιάς.

2.8 Ασθένειες φύλλων ελιάς

Η ελιά αποτελεί μία από τις σημαντικότερες δενδρώδεις καλλιέργειες στις μεσογειακές χώρες, με ιδιαίτερη οικονομική, περιβαλλοντική και πολιτισμική αξία. Η υγεία του φυλλώματος είναι κρίσιμη για την παραγωγικότητα του δέντρου, καθώς πολλές ασθένειες εκδηλώνονται αρχικά στα φύλλα και μπορούν να επηρεάσουν άμεσα τη

φωτοσυνθετική ικανότητα, τη ζωτικότητα του φυτού και τελικά την ποσότητα και την ποιότητα της παραγωγής. Για τον λόγο αυτό, η σύντομη παρουσίαση των βασικών ασθενειών των φύλλων της ελιάς είναι απαραίτητη, ώστε να κατανοείται καλύτερα και το αντικείμενο της παρούσας εργασίας.

Μία από τις σημαντικότερες μυκητολογικές ασθένειες της ελιάς είναι το olive peacock spot, γνωστό και ως olive leaf spot ή κυκλοκόνιο, το οποίο προκαλείται από τον μύκητα *Spilocaea oleagina* (συν. *Venturia oleaginea*). Η ασθένεια προσβάλλει κυρίως τα φύλλα, όπου εμφανίζονται χαρακτηριστικές κυκλικές σκούρες κηλίδες που συχνά θυμίζουν «μάτι παγωνιού». Σε περιπτώσεις έντονης προσβολής, μπορεί να προκληθεί σημαντική μείωση της φωτοσυνθετικής επιφάνειας, εξασθένηση των δέντρων, πρόωρη φυλλόπτωση και τελικά ποσοτικές και ποιοτικές απώλειες στην παραγωγή, ιδιαίτερα όταν οι μολύνσεις επαναλαμβάνονται για περισσότερες από μία καλλιεργητικές περιόδους.

Η μελέτη των Buljubašić et al. (2012) δείχνει ότι το βασικό επιδημιολογικό πρόβλημα της ασθένειας δεν περιορίζεται μόνο στις εμφανείς κηλίδες στα φύλλα, αλλά σχετίζεται και με την παρουσία λανθανουσών μολύνσεων, δηλαδή μολύνσεων κατά τις οποίες το παθογόνο υπάρχει ήδη στο φύλλο χωρίς να έχουν ακόμη εμφανιστεί σαφή ορατά συμπτώματα. Το στοιχείο αυτό είναι ιδιαίτερα σημαντικό, επειδή μπορεί να οδηγήσει σε υποεκτίμηση της πραγματικής πίεσης της ασθένειας στον αγρό όταν η εκτίμηση βασίζεται μόνο στην απλή οπτική παρατήρηση. Για την αξιόπιστη αξιολόγηση του κυκλοκονίου, οι συγγραφείς χρησιμοποίησαν τεχνική αποκάλυψης λανθανουσών κηλίδων με εμβάπτιση των φύλλων σε διάλυμα NaOH 5%, δείχνοντας ότι σε αρκετές περιπτώσεις απαιτούνται ειδικότερες μέθοδοι για την ασφαλή εκτίμηση της προσβολής.

Η ίδια μελέτη καταγράφει επίσης πολύ μεγάλη μεταβλητότητα στην ένταση της προσβολής μεταξύ διαφορετικών ελαιοκομικών περιοχών, γεγονός που αναδεικνύει τον ρόλο του μικροκλίματος και των τοπικών καλλιεργητικών πρακτικών στην επιδημιολογία της ασθένειας. Παράγοντες όπως η υψηλή υγρασία, η διάρκεια διαβροχής των φύλλων, ο ανεπαρκής αερισμός της κόμης και οι ιδιαίτερες συνθήκες κάθε περιοχής φαίνεται να επηρεάζουν σημαντικά την ανάπτυξη και τη διασπορά του παθογόνου. Παράλληλα, αναδεικνύεται και η σημασία της ποικιλιακής διαφοροποίησης, καθώς ορισμένες ποικιλίες εμφανίζονται πιο ευπαθείς σε σχέση με άλλες. Τα ευρήματα αυτά δείχνουν ότι το κυκλοκόνιο δεν αποτελεί μια ομοιόμορφη ή εύκολα προβλέψιμη ασθένεια, αλλά ένα πρόβλημα που απαιτεί συστηματική παρακολούθηση και στοχευμένη διαχείριση.

Αντίστοιχα, το πρακτικό εκπαιδευτικό κείμενο Tutorial 8 – Peacock Spot του Australian Olives (2020) παρουσιάζει με σαφή τρόπο τα βασικά χαρακτηριστικά της ασθένειας, εστιάζοντας ιδιαίτερα στη διάγνωση, στις ευνοϊκές συνθήκες μόλυνσης και στη διαχείρισή της σε επίπεδο ελαιώνα. Σύμφωνα με το κείμενο, η ασθένεια ευνοείται κυρίως από συνθήκες παρατεταμένης διαβροχής των φύλλων, όπως η βροχή, η πρωινή δροσιά και η αυξημένη υγρασία σε πυκνή κόμη, σε συνδυασμό με ήπιες θερμοκρασίες. Σε ξηρότερες περιόδους, το παθογόνο μπορεί να παραμένει σε λανθάνουσα κατάσταση και να επανενεργοποιείται όταν οι συνθήκες γίνουν ξανά ευνοϊκές. Επιπλέον, επισημαίνεται ότι η διασπορά του μολύσματος γίνεται κυρίως με το νερό, μέσω

σταγονιδίων βροχής ή άρδευσης, γεγονός που εξηγεί γιατί η ασθένεια είναι στενά συνδεδεμένη με περιβάλλοντα αυξημένης υγρασίας και ανεπαρκούς αερισμού.

Το ίδιο κείμενο δίνει και πρακτική κατεύθυνση ως προς τη διαχείριση της ασθένειας, αναδεικνύοντας τη σημασία της ολοκληρωμένης φυτοπροστασίας. Η μείωση της υγρασίας στο εσωτερικό της κόμης μέσω κατάλληλου κλαδέματος, η αποφυγή πρακτικών που αυξάνουν τη διαβροχή των φύλλων και η χρήση φυτοπροστατευτικών μέτρων όταν αναμένονται ευνοϊκές συνθήκες μόλυνσης αποτελούν βασικά στοιχεία αποτελεσματικής αντιμετώπισης. Παράλληλα, υπογραμμίζεται ότι υπάρχουν διαφορές στην ευαισθησία των ποικιλιών, κάτι που προσφέρει επιπλέον δυνατότητες προληπτικής διαχείρισης μέσω της επιλογής κατάλληλου φυτικού υλικού.

Συνολικά, η βιβλιογραφία δείχνει ότι το κυκλοκόνιο της ελιάς αποτελεί ασθένεια ιδιαίτερης σημασίας όχι μόνο λόγω της συχνότητάς του, αλλά και επειδή η έγκαιρη και αξιόπιστη διάγνωσή του είναι δύσκολη σε πραγματικές συνθήκες αγρού. Η ύπαρξη λανθανουσών μολύνσεων, η χωρική μεταβλητότητα της προσβολής, η επίδραση του μικροκλίματος και η ποικιλιακή διαφοροποίηση καθιστούν αναγκαία τη χρήση πιο συστηματικών και τεχνολογικά υποστηριζόμενων προσεγγίσεων παρακολούθησης. Στο πλαίσιο αυτό, η αξιοποίηση εικόνων και τεχνικών υπολογιστικής όρασης αποκτά ιδιαίτερη σημασία, καθώς μπορεί να συμβάλει στην έγκαιρη αναγνώριση των συμπτωμάτων και στη βελτίωση της διαχείρισης της ασθένειας στον ελαιώνα.



Εικόνα 1. Υγιές φύλλο ελιάς.



Εικόνα 2. Φύλλο ελιάς με συμπτώματα κυκλοκονίου (olive peacock spot / olive leaf spot).

2.9 Εφαρμογές του SVM στην αυτόματη ανίχνευση ασθενειών φυτών

Στη βιβλιογραφία της αυτόματης ανίχνευσης ασθενειών φυτών, ο αλγόριθμος Support Vector Machine (SVM) κατέχει ιδιαίτερα σημαντική θέση, καθώς έχει αξιοποιηθεί εκτενώς σε συστήματα που συνδυάζουν επεξεργασία εικόνας και μηχανική μάθηση για τη διάγνωση φυτοπαθολογικών προβλημάτων. Οι σχετικές μελέτες δείχνουν ότι ο SVM αποτελεί μια αποτελεσματική επιλογή, ιδιαίτερα σε περιπτώσεις όπου η ταξινόμηση βασίζεται σε χειροποίητα χαρακτηριστικά χρώματος, υφής και σχήματος, τα οποία εξάγονται μετά από κατάλληλη προεπεξεργασία και τμηματοποίηση των εικόνων.

Μια σημαντική μελέτη στον τομέα αυτό παρουσιάζεται από τους Hussein και Abbas (2019), οι οποίοι προτείνουν ένα σύστημα ανίχνευσης ασθενειών φύλλων βασισμένο σε τεχνικές επεξεργασίας εικόνας και στον αλγόριθμο SVM. Στόχος της εργασίας είναι η ανάπτυξη ενός υπολογιστικού εργαλείου ικανού να υποστηρίξει τους γεωργούς και τους ειδικούς φυτοπροστασίας στη γρήγορη και αξιόπιστη διάγνωση ασθενειών, μειώνοντας την ανάγκη για χρονοβόρες και δαπανηρές επιτόπιες επιθεωρήσεις. Η προτεινόμενη μεθοδολογία αποτελείται από δύο βασικές φάσεις: τη δημιουργία βάσης γνώσης και τη φάση διάγνωσης. Στην πρώτη φάση συλλέγονται εικόνες φύλλων φυτών και εφαρμόζονται τεχνικές προεπεξεργασίας, όπως cropping για την αφαίρεση του φόντου, αλλαγή μεγέθους σε σταθερή ανάλυση και βελτίωση της ποιότητας μέσω Fuzzy Histogram Equalization. Στη συνέχεια πραγματοποιείται εξαγωγή χαρακτηριστικών χρώματος και υφής, τα οποία χρησιμοποιούνται για τη δημιουργία του συνόλου δεδομένων εκπαίδευσης του ταξινομητή. Η επιλογή των χαρακτηριστικών βασίζεται κυρίως σε πληροφορίες υφής που υπολογίζονται μέσω του πίνακα Gray Level Co-occurrence Matrix (GLCM), καθώς και σε χαρακτηριστικά χρώματος που συμβάλλουν στη διάκριση μεταξύ υγιών και προσβεβλημένων περιοχών των φύλλων.

Το σύνολο δεδομένων της μελέτης των Hussein και Abbas περιλαμβάνει 799 εικόνες φύλλων από τρεις καλλιέργειες, δηλαδή σιτάρι, τομάτα και αγγούρι. Για κάθε καλλιέργεια εξετάζονται τρεις διαφορετικές ασθένειες, καθώς και η υγιής κατάσταση του φυτού. Τα δεδομένα χωρίζονται σε ποσοστό 80% για εκπαίδευση και 20% για δοκιμή, ενώ η ταξινόμηση πραγματοποιείται με SVM χρησιμοποιώντας quadratic kernel. Η αξιολόγηση του συστήματος γίνεται μέσω πίνακα σύγκρισης και μετρικών ακρίβειας. Τα αποτελέσματα δείχνουν ότι το προτεινόμενο σύστημα επιτυγχάνει συνολική ακρίβεια 88,1%, με υψηλότερη επίδοση στην αναγνώριση προσβεβλημένων φύλλων σε σύγκριση με την αναγνώριση υγιών. Οι συγγραφείς επισημαίνουν επίσης ότι η αύξηση του αριθμού των δειγμάτων εκπαίδευσης και η κατάλληλη ρύθμιση των παραμέτρων του SVM μπορούν να βελτιώσουν περαιτέρω την απόδοση του συστήματος. Συνολικά, η μελέτη αναδεικνύει τη δυνατότητα εφαρμογής κλασικών τεχνικών μηχανικής μάθησης, σε συνδυασμό με επεξεργασία εικόνας, για την ανάπτυξη πρακτικών εργαλείων διάγνωσης ασθενειών φυτών.

Στο ίδιο ερευνητικό πλαίσιο εντάσσεται και η εργασία των Padol και Yadav (2016), η οποία επικεντρώνεται στην αυτόματη ανίχνευση ασθενειών φύλλων αμπελιού με χρήση SVM. Η μελέτη εξετάζει ειδικότερα την έγκαιρη διάγνωση μυκητιακών ασθενειών, όπως το Downy Mildew και το Powdery Mildew, οι οποίες επηρεάζουν σημαντικά την παραγωγικότητα των αμπελιών. Η προτεινόμενη μεθοδολογία περιλαμβάνει αρχικά τη συλλογή εικόνων φύλλων μέσω ψηφιακής κάμερας και στη συνέχεια μια σειρά από στάδια προεπεξεργασίας, όπως αλλαγή μεγέθους, thresholding για την απομόνωση των πράσινων περιοχών και Gaussian filtering για τη μείωση του θορύβου. Ακολουθεί η διαδικασία τμηματοποίησης μέσω του αλγορίθμου K-means clustering, ώστε να διαχωριστούν οι περιοχές που παρουσιάζουν συμπτώματα ασθένειας από τις υγιείς περιοχές του φύλλου.

Μετά την τμηματοποίηση, εξάγονται χαρακτηριστικά υφής και χρώματος. Συγκεκριμένα, χρησιμοποιούνται εννέα χαρακτηριστικά υφής και εννέα χαρακτηριστικά χρώματος στο χρωματικό χώρο HSV, με σκοπό την αποτελεσματικότερη αναπαράσταση των ιδιοτήτων των προσβεβλημένων περιοχών. Για την τελική ταξινόμηση εφαρμόζεται γραμμικός ταξινομητής SVM, ο οποίος εκπαιδεύεται ώστε να διαχωρίζει τις δύο βασικές κατηγορίες ασθενειών. Το σύνολο δεδομένων της μελέτης αποτελείται από 137 εικόνες φύλλων αμπελιού, από τις οποίες 110 χρησιμοποιούνται για εκπαίδευση και 27 για δοκιμή. Τα αποτελέσματα δείχνουν συνολική ακρίβεια ταξινόμησης 88,89%, με ιδιαίτερα υψηλή επίδοση στην αναγνώριση της ασθένειας Downy Mildew. Η εργασία αυτή επιβεβαιώνει ότι ο συνδυασμός τεχνικών επεξεργασίας εικόνας, τμηματοποίησης με K-means και ταξινόμησης με SVM μπορεί να αποτελέσει μια αποτελεσματική προσέγγιση για την αυτόματη διάγνωση ασθενειών φυτών, ενώ παράλληλα υπογραμμίζει τη σημασία χρήσης μεγαλύτερων συνόλων δεδομένων και υβριδικών μοντέλων για περαιτέρω βελτίωση της απόδοσης.

Από τις παραπάνω μελέτες γίνεται εμφανές ότι οι κλασικές προσεγγίσεις με SVM ήταν ιδιαίτερα διαδεδομένες στα πρώτα στάδια ανάπτυξης συστημάτων αναγνώρισης ασθενειών φυτών, κυρίως λόγω της καλής τους απόδοσης σε μικρά ή μεσαίου μεγέθους σύνολα δεδομένων. Ωστόσο, η εξέλιξη των υπολογιστικών μεθόδων οδήγησε σταδιακά

σε πιο σύνθετα μοντέλα, τα οποία συνδυάζουν παραδοσιακές τεχνικές επεξεργασίας εικόνας με πολλαπλούς περιγραφείς χαρακτηριστικών και σύγχρονους ταξινομητές.

Χαρακτηριστικό παράδειγμα αυτής της μετάβασης αποτελεί η μελέτη των Krithika et al. (2019), οι οποίοι προτείνουν ένα υβριδικό μοντέλο για την αναγνώριση ασθενειών σε φύλλα τομάτας, συνδυάζοντας τεχνικές επεξεργασίας εικόνας και μεθόδους μηχανικής μάθησης. Σκοπός της μελέτης είναι η ανάπτυξη ενός συστήματος που θα επιτρέπει την έγκαιρη αναγνώριση ασθενειών, ώστε να διευκολύνεται η λήψη μέτρων αντιμετώπισης και να περιορίζονται οι απώλειες στην αγροτική παραγωγή. Η μεθοδολογία βασίζεται σε μια πολυσταδιακή διαδικασία, όπου αρχικά οι εικόνες των φύλλων τομάτας προεπεξεργάζονται με αλλαγή μεγέθους σε 256×256 pixels και βελτίωση της ποιότητας μέσω Histogram Equalization. Στη συνέχεια εφαρμόζεται K-means clustering για την τμηματοποίηση των εικόνων και τον εντοπισμό των προσβεβλημένων περιοχών, ενώ contour tracing χρησιμοποιείται για την εξαγωγή των ορίων του φύλλου και τη βελτίωση της συνολικής ανάλυσης.

Για την αναπαράσταση των πληροφοριών των εικόνων αξιοποιούνται πολλαπλοί περιγραφείς χαρακτηριστικών, όπως ο Discrete Wavelet Transform (DWT), η Principal Component Analysis (PCA) και ο πίνακας GLCM. Οι τεχνικές αυτές επιτρέπουν την εξαγωγή χαρακτηριστικών υφής και δομής από τις εικόνες των φύλλων, τα οποία συνδυάζονται σε ενιαίο διάνυσμα χαρακτηριστικών και δίνονται ως είσοδος σε διαφορετικούς ταξινομητές. Στο τελικό στάδιο της μελέτης πραγματοποιείται σύγκριση μεταξύ τριών αλγορίθμων ταξινόμησης, δηλαδή SVM, K-Nearest Neighbor (KNN) και Convolutional Neural Network (CNN). Η αξιολόγηση πραγματοποιείται σε σύνολο δεδομένων PlantVillage με εικόνες φύλλων τομάτας που αντιστοιχούν σε έξι διαφορετικούς τύπους ασθενειών. Τα αποτελέσματα δείχνουν ότι ο ταξινομητής CNN επιτυγχάνει την υψηλότερη ακρίβεια, περίπου 99%, ενώ οι μέθοδοι KNN και SVM επιτυγχάνουν περίπου 97% και 88% αντίστοιχα. Η σύγκριση αυτή αναδεικνύει την υπεροχή των βαθιών νευρωνικών δικτύων σε σύνθετα προβλήματα αναγνώρισης προτύπων, ιδίως όταν είναι διαθέσιμα μεγαλύτερα και πιο αντιπροσωπευτικά σύνολα δεδομένων.

Παρά τη σταδιακή επικράτηση των μεθόδων βαθιάς μάθησης, οι αλγόριθμοι SVM συνεχίζουν να αξιοποιούνται σε πιο εξειδικευμένες ή υβριδικές προσεγγίσεις, ιδιαίτερα όταν ζητούμενο είναι η ισορροπία ανάμεσα στην ακρίβεια, την υπολογιστική αποδοτικότητα και τη δυνατότητα ερμηνείας των αποτελεσμάτων. Ενδεικτική είναι η εργασία των Sahu και Pandey (2022), οι οποίοι προτείνουν ένα βελτιστοποιημένο υβριδικό μοντέλο πολλαπλών κλάσεων για την αναγνώριση ασθενειών φύλλων. Η μελέτη στοχεύει στην ανάπτυξη ενός συστήματος που μπορεί να εντοπίζει έγκαιρα τις ασθένειες μέσω επεξεργασίας εικόνας και τεχνικών μηχανικής μάθησης, συμβάλλοντας στη μείωση των απωλειών παραγωγής και στη βελτίωση της ποιότητας των καλλιεργειών.

Η προτεινόμενη μεθοδολογία βασίζεται στον συνδυασμό Random Forest και Multiclass Support Vector Machine, σχηματίζοντας το υβριδικό μοντέλο HRF-MCSVM. Πριν από την ταξινόμηση, οι εικόνες φύλλων υφίστανται preprocessing, όπως cropping, αλλαγή μεγέθους, εξομάλυνση, βελτίωση αντίθεσης και μετατροπή χρωματικού χώρου, με στόχο την καλύτερη ανάδειξη των συμπτωμάτων των

ασθενειών. Έπειτα εφαρμόζεται Spatial Fuzzy C-Means για την τμηματοποίηση των προσβεβλημένων περιοχών, με σκοπό τη βελτίωση της ακρίβειας και την αποτελεσματικότερη απομόνωση των περιοχών ενδιαφέροντος. Το σύστημα αξιολογείται στο μεγάλο σύνολο δεδομένων PlantVillage, το οποίο περιλαμβάνει περισσότερες από 54.000 εικόνες υγιών και προσβεβλημένων φύλλων από διαφορετικές καλλιέργειες και τύπους ασθενειών. Επιπλέον, χρησιμοποιείται ο αλγόριθμος βελτιστοποίησης TDO για τη ρύθμιση κρίσιμων παραμέτρων του SVM, όπως το εύρος του Gaussian kernel και τα όρια απόφασης, με στόχο τη μεγιστοποίηση της απόδοσης. Τα αποτελέσματα δείχνουν ότι το HRF-MCSVM επιτυγχάνει υψηλή ακρίβεια ταξινόμησης και βελτιωμένη απόδοση σε σύγκριση με πιο συμβατικές μεθόδους, γεγονός που επιβεβαιώνει ότι οι SVM-based προσεγγίσεις παραμένουν ιδιαίτερα χρήσιμες όταν ενσωματώνονται σε πιο σύνθετες υβριδικές αρχιτεκτονικές.

Μια διαφορετική, αλλά εξίσου χαρακτηριστική εφαρμογή του SVM σε πραγματικές συνθήκες πεδίου παρουσιάζεται από τη Naila και συνεργάτες (2020), οι οποίοι προτείνουν μια ταχεία μέθοδο αναγνώρισης της ασθένειας rice false smut βασισμένη σε χαρακτηριστικά Histogram of Oriented Gradients (HOG) και ταξινόμηση μέσω SVM. Η μελέτη στοχεύει στην αντιμετώπιση των περιορισμών των παραδοσιακών μεθόδων διάγνωσης, οι οποίες είναι χρονοβόρες και συχνά εμφανίζουν μειωμένη ακρίβεια υπό φυσικές συνθήκες καλλιέργειας. Η προτεινόμενη μεθοδολογία περιλαμβάνει αρχικά την απόκτηση εικόνων απευθείας από ορυζώνες, στοιχείο που ενισχύει τη ρεαλιστικότητα της αξιολόγησης. Στο στάδιο της προεπεξεργασίας εφαρμόζεται τμηματοποίηση βασισμένη σε χρωματικό κατώφλι στον χώρο HSV, ώστε να απομονωθεί η περιοχή ενδιαφέροντος που αντιστοιχεί στις προσβεβλημένες περιοχές, ενώ alpha/gamma correction χρησιμοποιείται για τη βελτίωση της ποιότητας των εικόνων και τη μείωση της επίδρασης του φωτισμού.

Για την εξαγωγή χαρακτηριστικών χρησιμοποιείται η μέθοδος HOG, η οποία είναι ανθεκτική σε γεωμετρικές και οπτικές παραμορφώσεις της εικόνας. Τα αρχικά διανύσματα χαρακτηριστικών υψηλής διάστασης, συγκεκριμένα 1764 διαστάσεων, μειώνονται μέσω PCA, ώστε να καταστεί δυνατή η αποδοτικότερη ταξινόμηση. Στη συνέχεια, τα μειωμένα χαρακτηριστικά δίνονται ως είσοδος σε SVM ταξινομητή με μη γραμμική πυρηνική συνάρτηση, με στόχο τον διαχωρισμό μεταξύ υγιών και προσβεβλημένων φυτών. Η αξιολόγηση του συστήματος πραγματοποιείται σε σύνολο 725 εικόνων, από τις οποίες 500 χρησιμοποιούνται για εκπαίδευση και 225 για δοκιμή. Τα αποτελέσματα δείχνουν αναμενόμενη ακρίβεια περίπου 80,6%, ενώ η πραγματική ακρίβεια στο σύνολο δοκιμών ανέρχεται σε 78,56%. Παρότι η απόδοση είναι χαμηλότερη σε σύγκριση με σύγχρονες μεθόδους βαθιάς μάθησης, η εργασία αναδεικνύει τα πλεονεκτήματα των κλασικών τεχνικών μηχανικής μάθησης σε περιπτώσεις περιορισμένων δεδομένων και ανάγκης για γρήγορη επεξεργασία. Έτσι, καταδεικνύεται ότι ο συνδυασμός HOG χαρακτηριστικών και SVM ταξινόμησης μπορεί να αποτελέσει μια πρακτική λύση για την έγκαιρη ανίχνευση ασθενειών σε γεωργικές εφαρμογές.

Συνοψίζοντας, η βιβλιογραφία δείχνει ότι ο SVM αποτέλεσε έναν από τους πιο σημαντικούς και ευρέως χρησιμοποιούμενους αλγορίθμους στην αυτόματη αναγνώριση ασθενειών φυτών. Από τα πρώιμα συστήματα που στηρίζονταν σε εξαγωγή χαρακτηριστικών χρώματος και υφής, έως τα πιο πρόσφατα υβριδικά μοντέλα

που συνδυάζουν SVM με Random Forest, PCA, HOG ή τεχνικές τμηματοποίησης όπως Spatial Fuzzy C-Means, ο αλγόριθμος αυτός έχει αποδείξει τη χρησιμότητά του σε διαφορετικά καλλιεργητικά και υπολογιστικά περιβάλλοντα. Παράλληλα, η σύγκριση με σύγχρονες αρχιτεκτονικές βαθιάς μάθησης δείχνει ότι, αν και τα CNN συχνά επιτυγχάνουν υψηλότερη ακρίβεια σε μεγάλα σύνολα δεδομένων, οι SVM-based μέθοδοι εξακολουθούν να αποτελούν αξιόπιστες, ευέλικτες και υπολογιστικά αποδοτικές λύσεις για πολλές εφαρμογές γεωργίας ακριβείας.

2.10 Ερευνητικό κενό και θέση της παρούσας εργασίας

Παρά τη σημαντική πρόοδο που έχει σημειωθεί τα τελευταία χρόνια στην ανάπτυξη συστημάτων ανίχνευσης φυτικών ασθενειών με χρήση τεχνικών μηχανικής και βαθιάς μάθησης, η εφαρμογή των μεθόδων αυτών σε πραγματικές συνθήκες αγρού εξακολουθεί να παρουσιάζει σημαντικές προκλήσεις. Μεγάλο μέρος της σχετικής βιβλιογραφίας βασίζεται σε εικόνες που έχουν συλλεχθεί σε ελεγχόμενα ή ημιελεγχόμενα περιβάλλοντα, όπου το φόντο είναι απλό, ο φωτισμός σχετικά σταθερός και η μεταβλητότητα των συνθηκών περιορισμένη. Αν και τα δεδομένα αυτά διευκολύνουν την ανάπτυξη και αξιολόγηση αλγορίθμων, συχνά οδηγούν σε μοντέλα με περιορισμένη ικανότητα γενίκευσης όταν εφαρμόζονται σε πραγματικά αγροτικά περιβάλλοντα.

Επιπλέον, σε αρκετές μελέτες η συλλογή δεδομένων πραγματοποιείται με τη χρήση προηγμένων UAV πλατφορμών και εξειδικευμένων αισθητήρων, οι οποίοι συνεπάγονται υψηλό κόστος εξοπλισμού και λειτουργίας. Το γεγονός αυτό περιορίζει τη δυνατότητα άμεσης υιοθέτησης των προτεινόμενων λύσεων από μικρούς ή μεσαίους παραγωγούς, καθώς και από πιλοτικές εφαρμογές σε πραγματικές καλλιεργητικές συνθήκες.

Στην περίπτωση της καλλιέργειας της ελιάς, οι δυσκολίες αυτές ενισχύονται περαιτέρω λόγω της μορφολογίας των φύλλων, της ποικιλιακής διαφοροποίησης και της συχνά ανομοιογενούς εμφάνισης των συμπτωμάτων των ασθενειών. Παράλληλα, η ύπαρξη λανθανουσών μολύνσεων και η έντονη χωρική μεταβλητότητα της προσβολής καθιστούν την αξιόπιστη ανίχνευση ακόμη πιο απαιτητική, ιδιαίτερα όταν χρησιμοποιούνται εικόνες πεδίου με σύνθετο φόντο και μεταβαλλόμενες συνθήκες φωτισμού.

Συνεπώς, ο συνδυασμός χρήσης οικονομικά προσβάσιμων UAV πλατφορμών, συλλογής πραγματικών δεδομένων πεδίου και αξιοποίησης εργαλείων μηχανικής μάθησης που μπορούν να εφαρμοστούν σε ρεαλιστικά σενάρια παραμένει σχετικά λιγότερο διερευνημένος στη βιβλιογραφία. Η παρούσα εργασία τοποθετείται ακριβώς σε αυτό το ερευνητικό σημείο, διερευνώντας τη δυνατότητα ανάπτυξης ενός λειτουργικού συστήματος ανίχνευσης ασθενειών φύλλων ελιάς με χρήση εικόνων που συλλέγονται από drone χαμηλού κόστους και μεθόδων μηχανικής και βαθιάς μάθησης που μπορούν να αξιοποιηθούν σε πραγματικές συνθήκες καλλιέργειας.

ΚΕΦΑΛΑΙΟ 3: Μεθοδολογία Έρευνας

3.1 Ερευνητικός σχεδιασμός

Η παρούσα εργασία ακολουθεί μία συγκριτική πειραματική μεθοδολογία με στόχο τη διερεύνηση της αποτελεσματικότητας διαφορετικών τεχνικών ανάλυσης εικόνας και μηχανικής μάθησης στην ανίχνευση ασθενειών φύλλων ελιάς. Ειδικότερα, ο ερευνητικός σχεδιασμός στηρίζεται στη σύγκριση δύο διακριτών προσεγγίσεων ταξινόμησης εικόνων: μίας κλασικής μεθόδου μηχανικής μάθησης, βασισμένης στον ταξινομητή Support Vector Machine (SVM) με εξαγωγή χαρακτηριστικών Histogram of Oriented Gradients (HOG), και μίας προσέγγισης βαθιάς μάθησης, βασισμένης σε τεχνικές μεταφοράς μάθησης (Transfer Learning) μέσω της πλατφόρμας Teachable Machine.

Η επιλογή των δύο αυτών μεθόδων επιτρέπει τη σύγκριση δύο διαφορετικών λογικών προσέγγισης του ίδιου προβλήματος. Η πρώτη προσέγγιση στηρίζεται σε χειροκίνητη αναπαράσταση της εικόνας μέσω προκαθορισμένων χαρακτηριστικών και στη συνέχεια σε εκπαίδευση ενός παραδοσιακού ταξινομητή. Η δεύτερη προσέγγιση βασίζεται στη δυνατότητα των συνελκτικών νευρωνικών δικτύων να μαθαίνουν αυτόματα τα κατάλληλα χαρακτηριστικά από τα δεδομένα, χωρίς ρητή σχεδίαση από τον ερευνητή. Η σύγκριση των δύο προσεγγίσεων δεν αποσκοπεί μόνο στην καταγραφή της διαφοράς στην απόδοση, αλλά και στην κατανόηση των πλεονεκτημάτων και περιορισμών κάθε μεθόδου σε συνθήκες εφαρμογής σχετικές με τη γεωργία ακριβείας.

Η μεθοδολογία οργανώνεται σε διαδοχικά στάδια. Αρχικά επιλέγεται και περιγράφεται το σύνολο δεδομένων που χρησιμοποιείται για την εκπαίδευση και αξιολόγηση των μοντέλων. Στη συνέχεια εφαρμόζονται βασικά στάδια προεπεξεργασίας εικόνας, ακολουθεί η εκπαίδευση των δύο μοντέλων και η αξιολόγησή τους μέσω τυπικών μετρικών ταξινόμησης. Τέλος, πραγματοποιείται επιτόπια δοκιμή των ήδη εκπαιδευμένων μοντέλων με χρήση drone σε πραγματικό ελαιώνα, ώστε να εξεταστεί η λειτουργικότητά τους σε συνθήκες πεδίου.

3.2 Περιγραφή συνόλων δεδομένων (dataset)

Για την εκπαίδευση των μοντέλων χρησιμοποιήθηκε οργανωμένο σύνολο δεδομένων από την πλατφόρμα Kaggle, το οποίο περιλαμβάνει εικόνες φύλλων ελιάς κατανεμημένες σε δύο βασικές κατηγορίες: υγιή φύλλα και φύλλα προσβεβλημένα από την ασθένεια peacock spot. Το σύνολο δεδομένων αποτελείται συνολικά από 430 εικόνες, εκ των οποίων 210 αντιστοιχούν σε υγιή φύλλα και 220 σε φύλλα που εμφανίζουν συμπτώματα της ασθένειας.

Οι εικόνες του dataset ήταν αποθηκευμένες σε μορφή JPEG και χρησιμοποιήθηκαν ως βασικό σύνολο εκπαίδευσης για τα δύο μοντέλα που αναπτύχθηκαν στην εργασία. Πριν από την εισαγωγή τους στους αλγόριθμους, οι εικόνες οργανώθηκαν ανά κατηγορία και υποβλήθηκαν σε βασική προεπεξεργασία, ώστε να είναι κατάλληλες για τη διαδικασία εκπαίδευσης. Για λόγους ομοιομορφίας, όλες οι εικόνες προσαρμόστηκαν σε κοινές διαστάσεις 128×128 pixels. Επιπλέον, εφαρμόστηκε τυχαία αναδιάταξη (shuffle) των δειγμάτων πριν από την εκπαίδευση, ώστε να αποφεύγεται η διαδοχική

εμφάνιση εικόνων της ίδιας κατηγορίας και να ενισχύεται η σταθερότητα της μαθησιακής διαδικασίας.

Στην παρούσα εργασία δεν πραγματοποιήθηκε εσωτερικός διαχωρισμός του dataset σε υποσύνολα εκπαίδευσης και ελέγχου. Αντίθετα, το σύνολο των 430 εικόνων χρησιμοποιήθηκε για την εκπαίδευση των μοντέλων, ενώ η αξιολόγησή τους πραγματοποιήθηκε σε δεύτερη φάση, μέσω εξωτερικού ελέγχου σε πραγματικές συνθήκες πεδίου, με χρήση drone DJI Tello σε φύλλα από πραγματικό ελαιώνα. Η συγκεκριμένη επιλογή έγινε ώστε να εξεταστεί η συμπεριφορά των εκπαιδευμένων μοντέλων σε πιο ρεαλιστικό περιβάλλον εφαρμογής, έξω από τα όρια του οργανωμένου συνόλου δεδομένων.

Η επιλογή του συγκεκριμένου dataset κρίθηκε κατάλληλη για την παρούσα εργασία, καθώς παρέχει σαφώς επισημασμένα δείγματα για πρόβλημα δυαδικής ταξινόμησης. Η σχετικά ισορροπημένη αναλογία μεταξύ των δύο κατηγοριών συμβάλλει στη μείωση του κινδύνου μεροληψίας του μοντέλου προς μία μόνο κλάση και διευκολύνει την εκμάθηση των βασικών οπτικών χαρακτηριστικών που διαφοροποιούν τα υγιή φύλλα από τα προσβεβλημένα. Ωστόσο, επειδή το οργανωμένο dataset δεν αποτυπώνει πλήρως την πολυπλοκότητα του πραγματικού αγροτικού περιβάλλοντος, κρίθηκε αναγκαίο να συμπληρωθεί η μεθοδολογία με επιτόπια δοκιμή των μοντέλων σε πραγματικές συνθήκες.

3.3 Επιτόπια δοκιμή με drone σε πραγματικές συνθήκες

Πέρα από το οργανωμένο σύνολο δεδομένων εκπαίδευσης, στην παρούσα εργασία χρησιμοποιήθηκε drone τύπου DJI Tello για την επιτόπια δοκιμή των ήδη εκπαιδευμένων μοντέλων σε πραγματικές συνθήκες ελαιώνα. Είναι σημαντικό να διευκρινιστεί ότι το drone δεν χρησιμοποιήθηκε για τη συλλογή νέου συνόλου δεδομένων με σκοπό την εκπαίδευση ή την επέκταση του dataset, αλλά αποκλειστικά ως εργαλείο ελέγχου της λειτουργίας των μοντέλων στο πεδίο.

Η χρήση του drone εντάχθηκε στη μεθοδολογία ως στάδιο εφαρμογής και όχι ως στάδιο δημιουργίας δεδομένων. Σκοπός ήταν να εξεταστεί κατά πόσο τα μοντέλα που είχαν ήδη εκπαιδευτεί μπορούν να αναγνωρίζουν σωστά υγιή και προσβεβλημένα φύλλα όταν καλούνται να λειτουργήσουν σε ένα πραγματικό αγροτικό περιβάλλον. Με άλλα λόγια, το ενδιαφέρον της εργασίας δεν περιορίστηκε στη θεωρητική ή εργαστηριακή αξιολόγηση των αλγορίθμων, αλλά επεκτάθηκε στη δοκιμή της πρακτικής τους λειτουργικότητας.

Η επιτόπια δοκιμή πραγματοποιήθηκε σε δικά μου ελαιόδεντρα, σε περιβάλλον φυσικού φωτισμού και πραγματικής καλλιεργητικής συνθήκης. Κατά τη διάρκεια της διαδικασίας, το drone χρησιμοποιήθηκε για την παρατήρηση φύλλων σε διαφορετικές γωνίες, αποστάσεις και θέσεις μέσα στην κόμη του δέντρου. Η συγκεκριμένη προσέγγιση ήταν ιδιαίτερα χρήσιμη, καθώς επέτρεψε την αξιολόγηση των μοντέλων σε συνθήκες όπου η εικόνα επηρεάζεται από παράγοντες όπως η μεταβολή φωτισμού, η σκίαση, η επικάλυψη φύλλων, το φυσικό φόντο του ελαιώνα και η πιθανή θόλωση λόγω μικροκινήσεων.

Η επιτόπια αξιολόγηση μέσω drone είχε επομένως χαρακτήρα λειτουργικού και εφαρμοσμένου ελέγχου. Μέσα από αυτή τη διαδικασία εξετάστηκε εάν τα μοντέλα μπορούν να αναγνωρίζουν με επάρκεια τα βασικά χαρακτηριστικά των δύο κατηγοριών και να διατηρούν ικανοποιητική συμπεριφορά εκτός του οργανωμένου συνόλου εκπαίδευσης. Το στοιχείο αυτό είναι ιδιαίτερα σημαντικό για εφαρμογές γεωργίας ακριβείας, στις οποίες το ζητούμενο δεν είναι μόνο η υψηλή απόδοση σε ελεγχόμενα δεδομένα, αλλά κυρίως η αξιόπιστη λειτουργία σε πραγματικές συνθήκες χρήσης.

3.4 Προεπεξεργασία εικόνων

Η προεπεξεργασία των εικόνων αποτέλεσε κρίσιμο στάδιο της μεθοδολογίας, καθώς η ποιότητα και η ομοιογένεια των δεδομένων εισόδου επηρεάζουν άμεσα την απόδοση τόσο των κλασικών όσο και των σύγχρονων μοντέλων ταξινόμησης. Στο πλαίσιο της παρούσας εργασίας εφαρμόστηκαν βασικές διαδικασίες προεπεξεργασίας με στόχο την ενοποίηση της μορφής των εικόνων και τη διευκόλυνση της επόμενης φάσης της ανάλυσης.

Αρχικά, όλες οι εικόνες αναπροσαρμόστηκαν σε σταθερές διαστάσεις 128×128 pixels, ώστε να μπορούν να εισαχθούν στα μοντέλα με συνεπή και ομοιόμορφο τρόπο. Η αλλαγή μεγέθους είναι ιδιαίτερα σημαντική σε προβλήματα ταξινόμησης εικόνας, διότι οι αλγόριθμοι απαιτούν είσοδο με κοινή μορφή και σταθερές διαστάσεις. Παράλληλα, μέσω της διαδικασίας αυτής επιτυγχάνεται μείωση της υπολογιστικής απαίτησης, χωρίς να χάνεται η βασική οπτική πληροφορία που είναι απαραίτητη για την αναγνώριση των κατηγοριών.

Στη συνέχεια, πραγματοποιήθηκε βασική ομογενοποίηση των εικόνων, ώστε να περιοριστούν αποκλίσεις που σχετίζονται με τις αρχικές συνθήκες λήψης. Η ύπαρξη εικόνων με διαφορετική φωτεινότητα, αντίθεση ή οπτική έμφαση μπορεί να επηρεάσει την ικανότητα των μοντέλων να μάθουν ουσιαστικά χαρακτηριστικά. Για τον λόγο αυτό, η προεπεξεργασία λειτούργησε ως στάδιο προσαρμογής του υλικού σε πιο συνεπή μορφή.

Στην περίπτωση της μεθόδου SVM + HOG, η προεπεξεργασία συνδέεται άμεσα με την ποιότητα των εξαγόμενων χαρακτηριστικών. Εφόσον τα χαρακτηριστικά HOG βασίζονται στην ανάλυση τοπικών κλίσεων και ακμών, οποιαδήποτε έντονη ασυνέπεια στην εικόνα μπορεί να επηρεάσει αρνητικά την τελική αναπαράσταση. Αντίθετα, στην περίπτωση της προσέγγισης Transfer Learning, η προεπεξεργασία είναι πιο περιορισμένη, καθώς το προεκπαιδευμένο δίκτυο αναλαμβάνει να αντλήσει αυτόματα τα κατάλληλα χαρακτηριστικά από τις εικόνες. Παρ' όλα αυτά, η βασική ομοιομορφία στην είσοδο παραμένει απαραίτητη για τη σταθερή λειτουργία του μοντέλου.

3.5 Εκπαίδευση μοντέλου SVM + HOG

Η πρώτη μεθοδολογική προσέγγιση που εφαρμόστηκε στην εργασία βασίστηκε στη συνδυαστική χρήση της εξαγωγής χαρακτηριστικών Histogram of Oriented Gradients (HOG) και του ταξινομητή Support Vector Machine (SVM). Η προσέγγιση αυτή αντιπροσωπεύει μία κλασική λογική μηχανικής μάθησης, σύμφωνα με την οποία η

εικόνα δεν χρησιμοποιείται απευθείας ως είσοδος στον ταξινομητή, αλλά μετατρέπεται αρχικά σε ένα διάνυσμα χαρακτηριστικών που περιγράφει βασικές δομικές πληροφορίες της.

Για την εφαρμογή της μεθόδου, όλες οι εικόνες προσαρμόστηκαν αρχικά σε διαστάσεις 128×128 pixels. Στη συνέχεια, από κάθε εικόνα εξήχθησαν χαρακτηριστικά HOG, τα οποία αποτυπώνουν την τοπική κατανομή των ακμών και των προσανατολισμένων κλίσεων φωτεινότητας. Η επιλογή των χαρακτηριστικών HOG κρίθηκε κατάλληλη, επειδή μπορούν να περιγράψουν τη δομή, το περίγραμμα και σε έναν βαθμό τη μορφολογική διαφοροποίηση μεταξύ υγιών και προσβεβλημένων φύλλων ελιάς.

Τα εξαγόμενα χαρακτηριστικά χρησιμοποιήθηκαν ως είσοδος στον ταξινομητή SVM, με στόχο τη διάκριση μεταξύ των δύο κατηγοριών του προβλήματος, δηλαδή των υγιών φύλλων και των φύλλων που παρουσιάζουν συμπτώματα της ασθένειας peacock spot. Στην παρούσα εργασία χρησιμοποιήθηκε μη γραμμικός πυρήνας (kernel), καθώς το πρόβλημα της ταξινόμησης δεν θεωρήθηκε αυστηρά γραμμικά διαχωρίσιμο στον χώρο χαρακτηριστικών. Η επιλογή αυτή κρίθηκε κατάλληλη για την καλύτερη αποτύπωση πιο σύνθετων σχέσεων μεταξύ των εξαγόμενων χαρακτηριστικών.

Η προσέγγιση SVM + HOG παρουσιάζει το πλεονέκτημα της σχετικά απλής υλοποίησης και της μειωμένης υπολογιστικής απαίτησης σε σύγκριση με βαθύτερα μοντέλα μάθησης. Ωστόσο, η αποτελεσματικότητά της εξαρτάται σημαντικά από την ποιότητα των χαρακτηριστικών που έχουν εξαχθεί, καθώς και από τις ρυθμίσεις τόσο της διαδικασίας HOG όσο και του ίδιου του ταξινομητή. Για τον λόγο αυτό, η προσέγγιση αυτή χρησιμοποιήθηκε στην εργασία ως σημείο σύγκρισης με τη δεύτερη, βαθύτερη μεθοδολογική προσέγγιση που βασίστηκε σε Transfer Learning.

3.6 Εκπαίδευση μοντέλου Transfer Learning

Η δεύτερη προσέγγιση που χρησιμοποιήθηκε στην παρούσα εργασία βασίστηκε σε τεχνικές βαθιάς μάθησης και συγκεκριμένα στη μεταφορά μάθησης μέσω της πλατφόρμας Teachable Machine. Η προσέγγιση αυτή αξιοποιεί προεκπαιδευμένο συνελκτικό νευρωνικό δίκτυο εικόνας, το οποίο έχει ήδη μάθει γενικά οπτικά χαρακτηριστικά από μεγάλο όγκο δεδομένων και στη συνέχεια προσαρμόζεται στο ειδικό πρόβλημα της διάκρισης μεταξύ υγιών φύλλων ελιάς και φύλλων προσβεβλημένων από την ασθένεια peacock spot.

Η βασική αρχή της μεταφοράς μάθησης είναι ότι ένα δίκτυο που έχει εκπαιδευτεί σε ευρύ και γενικό σύνολο εικόνων μπορεί να μεταφέρει μέρος της γνώσης του σε ένα νέο, πιο εξειδικευμένο πρόβλημα. Η προσέγγιση αυτή είναι ιδιαίτερα χρήσιμη όταν το διαθέσιμο σύνολο δεδομένων δεν είναι πολύ μεγάλο, καθώς επιτρέπει την αξιοποίηση έτοιμων οπτικών αναπαραστάσεων χωρίς να απαιτείται εκπαίδευση ενός βαθιού νευρωνικού δικτύου από την αρχή.

Στο πλαίσιο της παρούσας εργασίας, οι εικόνες οργανώθηκαν σε δύο κλάσεις, μία για τα υγιή φύλλα και μία για τα προσβεβλημένα φύλλα, και στη συνέχεια εισήχθησαν στην πλατφόρμα Teachable Machine για την εκπαίδευση του μοντέλου. Όλες οι εικόνες

είχαν ήδη προσαρμοστεί σε κοινές διαστάσεις 128×128 pixels, ώστε να εξασφαλίζεται ομοιομορφία στην είσοδο του συστήματος.

Η εκπαίδευση πραγματοποιήθηκε μέσω της πλατφόρμας Teachable Machine, η οποία αξιοποιεί τεχνικές μεταφοράς μάθησης και προεκπαιδευμένα συνελκτικά νευρωνικά δίκτυα εικόνας. Ωστόσο, στο πλαίσιο της παρούσας εργασίας δεν ήταν διαθέσιμες αναλυτικές πληροφορίες σχετικά με το ακριβές αρχιτεκτονικό υπόβαθρο του προεκπαιδευμένου μοντέλου, ούτε καταγράφηκαν με ακρίβεια όλες οι εσωτερικές παράμετροι εκπαίδευσης, όπως ο αριθμός των epochs και το batch size. Για τον λόγο αυτό, η περιγραφή της μεθοδολογίας εστιάζει κυρίως στη λογική της προσέγγισης, στην οργάνωση των δεδομένων, στη διαδικασία εκπαίδευσης και στην αξιολόγηση της συμπεριφοράς του μοντέλου σε οργανωμένο και πραγματικό περιβάλλον εφαρμογής.

Σε αντίθεση με την προσέγγιση SVM + HOG, στην περίπτωση του Transfer Learning δεν απαιτήθηκε χειροκίνητη εξαγωγή χαρακτηριστικών. Το ίδιο το νευρωνικό δίκτυο ανέλαβε να μάθει αυτόματα τα οπτικά χαρακτηριστικά που είναι περισσότερο χρήσιμα για τη διάκριση των δύο κατηγοριών. Σε χαμηλά επίπεδα του δικτύου αναγνωρίζονται απλά μοτίβα, όπως ακμές και τοπικές μεταβολές φωτεινότητας, ενώ σε βαθύτερα επίπεδα σχηματίζονται πιο σύνθετες αναπαραστάσεις που σχετίζονται με μορφολογικές και υφικές διαφοροποιήσεις των φύλλων.

Για την υλοποίηση της προσέγγισης βαθιάς μάθησης αξιοποιήθηκε η πλατφόρμα Teachable Machine, η οποία βασίζεται σε τεχνικές Transfer Learning και συνελκτικά νευρωνικά δίκτυα. Στο πλαίσιο της εργασίας πραγματοποιήθηκε προεπεξεργασία των δεδομένων, οργάνωση των κλάσεων, εκπαίδευση του μοντέλου και αξιολόγηση της απόδοσής του τόσο σε οργανωμένο dataset όσο και σε συνθήκες πραγματικού χρόνου μέσω drone. Παρότι το Teachable Machine παρέχει ένα απλοποιημένο περιβάλλον εκπαίδευσης μοντέλων, η αξιολόγηση, η συγκριτική ανάλυση, η συλλογή και ο έλεγχος των δεδομένων, καθώς και η real-time εφαρμογή, αποτέλεσαν αντικείμενο σχεδιασμού και πειραματικής διερεύνησης στο πλαίσιο της παρούσας εργασίας.

3.7 Real-time σύστημα με drone

Ένα από τα βασικά στάδια της μεθοδολογίας ήταν η επιτόπια δοκιμή των εκπαιδευμένων μοντέλων σε συνθήκες πραγματικού χρόνου. Για τον σκοπό αυτό χρησιμοποιήθηκε το RoboMaster TT της DJI, ένα μικρού μεγέθους μη επανδρωμένο εναέριο όχημα, το οποίο διαθέτει ενσωματωμένη κάμερα ανάλυσης 5 MP, πεδίο θέασης 82.6° και δυνατότητα λήψης βίντεο ανάλυσης HD 720p στα 30 fps. Επιπλέον, υποστηρίζει αποθήκευση εικόνων σε μορφή JPG και βίντεο σε μορφή MP4, χαρακτηριστικά που το καθιστούν κατάλληλο για πειραματικές εφαρμογές υπολογιστικής όρασης σε μικρή κλίμακα.

Στην παρούσα εργασία το drone δεν χρησιμοποιήθηκε για τη δημιουργία νέου συνόλου εκπαίδευσης, αλλά ως μέσο επιτόπιας εφαρμογής και ελέγχου των ήδη εκπαιδευμένων αλγορίθμων σε πραγματικές συνθήκες ελαιώνα. Η φάση αυτή είχε ως βασικό στόχο να διερευνηθεί κατά πόσο τα μοντέλα που είχαν εκπαιδευτεί στο οργανωμένο σύνολο δεδομένων μπορούν να διατηρήσουν ικανοποιητική συμπεριφορά όταν εφαρμόζονται

σε μη ελεγχόμενο περιβάλλον, όπου η εικόνα επηρεάζεται από φυσικούς και πρακτικούς περιορισμούς της λήψης πεδίου.

Οι λήψεις πραγματοποιήθηκαν σε χαμηλό ύψος πτήσης, περίπου 1 μέτρο από το έδαφος, ώστε να είναι δυνατή η παρατήρηση του φυλλώματος σε κοντινή απόσταση και υπό συνθήκες που προσεγγίζουν μια πρακτική επιτόπια εφαρμογή. Η επιτόπια αξιολόγηση δεν περιορίστηκε σε μία μόνο λήψη ή σε μία μεμονωμένη χρονική στιγμή, αλλά επαναλήφθηκε πολλές φορές σε διαφορετικές ώρες της ημέρας, με κύρια έμφαση στις μεσημεριανές ώρες. Με τον τρόπο αυτό κατέστη δυνατή η εξέταση της συμπεριφοράς των μοντέλων υπό διαφορετικές φωτιστικές συνθήκες, καθώς οι δοκιμές πραγματοποιήθηκαν τόσο σε περιβάλλον έντονης ηλιοφάνειας όσο και σε συνθήκες συννεφιάς.

Η επιλογή διαφορετικών χρονικών στιγμών και φωτιστικών συνθηκών κρίθηκε ιδιαίτερα σημαντική, καθώς η απόδοση ενός συστήματος υπολογιστικής όρασης επηρεάζεται άμεσα από τη φυσική μεταβλητότητα του αγροτικού περιβάλλοντος. Παράγοντες όπως οι σκιές, οι ανακλάσεις, η μεταβαλλόμενη ένταση φωτισμού, η γωνία παρατήρησης, η επικάλυψη φύλλων και η πολυπλοκότητα του φυσικού φόντου μπορούν να μεταβάλουν σημαντικά το οπτικό περιεχόμενο της εικόνας και, κατά συνέπεια, να επηρεάσουν την αξιοπιστία της πρόβλεψης.

Για τον λόγο αυτό, η real-time εφαρμογή με το RoboMaster TT αποτέλεσε ουσιαστικό μέρος της ερευνητικής διαδικασίας, καθώς επέτρεψε την αποτίμηση της ικανότητας γενίκευσης των μοντέλων πέρα από τα όρια του οργανωμένου dataset. Με άλλα λόγια, η επιτόπια αυτή δοκιμή συνέδεσε τη θεωρητική αξιολόγηση των αλγορίθμων με το πρακτικό ζητούμενο της εφαρμογής τους στη γεωργία ακριβείας, αναδεικνύοντας τις δυνατότητες αλλά και τις δυσκολίες που προκύπτουν όταν ένα μοντέλο καλείται να λειτουργήσει σε πραγματικές συνθήκες πεδίου.

3.8 Μετρικές αξιολόγησης

Η αξιολόγηση των δύο μοντέλων πραγματοποιήθηκε με χρήση βασικών και καθιερωμένων μετρικών ταξινόμησης, οι οποίες επιτρέπουν την ποσοτική αποτίμηση της απόδοσης κάθε προσέγγισης. Για την παρούσα εργασία, όπου το πρόβλημα διατυπώνεται ως δυαδική ταξινόμηση μεταξύ υγιών και προσβεβλημένων φύλλων ελιάς, κρίθηκε απαραίτητη η χρήση περισσότερων της μίας μετρικών, ώστε η αξιολόγηση να μην περιορίζεται μόνο σε μία γενική εκτίμηση της ορθότητας των προβλέψεων, αλλά να περιγράφει και το είδος των σφαλμάτων που παράγονται.

Η βασική δομή πάνω στην οποία στηρίζονται οι μετρικές αξιολόγησης είναι ο πίνακας σύγχυσης (confusion matrix). Ο πίνακας αυτός συνοψίζει τις προβλέψεις ενός μοντέλου σε τέσσερις βασικές κατηγορίες:

- True Positive (TP): αριθμός προσβεβλημένων φύλλων που το μοντέλο αναγνώρισε σωστά ως προσβεβλημένα.
- True Negative (TN): αριθμός υγιών φύλλων που το μοντέλο αναγνώρισε σωστά ως υγιή.

- False Positive (FP): αριθμός υγιών φύλλων που το μοντέλο ταξινόμησε λανθασμένα ως προσβεβλημένα.
- False Negative (FN): αριθμός προσβεβλημένων φύλλων που το μοντέλο ταξινόμησε λανθασμένα ως υγιή.

Στο συγκεκριμένο πρόβλημα, οι παραπάνω κατηγορίες έχουν ιδιαίτερη πρακτική σημασία. Ένα false negative είναι ιδιαίτερα κρίσιμο, επειδή αντιστοιχεί σε περίπτωση όπου ένα φύλλο με ασθένεια δεν εντοπίζεται από το σύστημα και θεωρείται λανθασμένα υγιές. Ένα τέτοιο σφάλμα μπορεί να οδηγήσει σε καθυστέρηση λήψης μέτρων αντιμετώπισης. Από την άλλη πλευρά, ένα false positive οδηγεί σε υπερεκτίμηση του προβλήματος, καθώς ένα υγιές φύλλο χαρακτηρίζεται λανθασμένα ως ασθενές. Επομένως, για την αξιολόγηση ενός τέτοιου συστήματος δεν αρκεί μόνο η συνολική ακρίβεια, αλλά απαιτείται πιο ολοκληρωμένη προσέγγιση.

Η πρώτη μετρική που χρησιμοποιήθηκε είναι η ακρίβεια (accuracy), η οποία εκφράζει το ποσοστό των συνολικά σωστών προβλέψεων επί του συνολικού αριθμού δειγμάτων:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Η accuracy δίνει μία συνολική εικόνα της επίδοσης του μοντέλου, αλλά από μόνη της δεν αρκεί για την πλήρη ερμηνεία της συμπεριφοράς του, ιδιαίτερα όταν ένα μοντέλο μπορεί να αποδίδει καλά στη μία κατηγορία και χειρότερα στην άλλη.

Για τον λόγο αυτό χρησιμοποιήθηκε επίσης η μετρική precision, η οποία εκφράζει το ποσοστό των σωστών θετικών προβλέψεων μεταξύ όλων των δειγμάτων που το μοντέλο χαρακτήρισε ως θετικά:

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

Στην παρούσα εργασία, η precision δείχνει πόσα από τα φύλλα που αναγνωρίστηκαν από το μοντέλο ως προσβεβλημένα ήταν πράγματι προσβεβλημένα. Η μετρική αυτή είναι σημαντική, διότι αποτυπώνει την αξιοπιστία των θετικών προβλέψεων του μοντέλου.

Η επόμενη μετρική είναι η ανάκληση (recall), η οποία εκφράζει το ποσοστό των πραγματικά θετικών περιπτώσεων που εντοπίστηκαν επιτυχώς από το μοντέλο:

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

Στο συγκεκριμένο πρόβλημα, η recall είναι ιδιαίτερα σημαντική, καθώς δείχνει την ικανότητα του συστήματος να εντοπίζει πραγματικά τα προσβεβλημένα φύλλα. Υψηλή τιμή recall σημαίνει ότι το σύστημα χάνει λίγες περιπτώσεις ασθένειας, κάτι που είναι ιδιαίτερα κρίσιμο σε εφαρμογές γεωργίας ακριβείας.

Τέλος, χρησιμοποιήθηκε ο δείκτης F1-score, ο οποίος αποτελεί τον αρμονικό μέσο των precision και recall και προσφέρει μια πιο ισορροπημένη εικόνα της απόδοσης του μοντέλου:

$$F1\text{-score} = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$$

Ο δείκτης F1-score είναι ιδιαίτερα χρήσιμος όταν επιδιώκεται ταυτόχρονα καλή ικανότητα εντοπισμού των προσβεβλημένων φύλλων και ικανοποιητική αξιοπιστία στις θετικές προβλέψεις. Με άλλα λόγια, επιτρέπει τη συνδυαστική αποτίμηση της απόδοσης ενός μοντέλου χωρίς να υπερτονίζεται μονομερώς μόνο μία διάσταση της συμπεριφοράς του.

Η επιλογή των παραπάνω μετρικών κρίθηκε κατάλληλη για την παρούσα εργασία, επειδή το πρόβλημα της ανίχνευσης ασθενειών φύλλων ελιάς δεν απαιτεί μόνο τη μέτρηση της συνολικής επιτυχίας, αλλά και την προσεκτική κατανόηση των διαφορετικών τύπων σφαλμάτων. Η συνδυαστική χρήση accuracy, precision, recall και F1-score παρέχει συνεπώς μια πιο ολοκληρωμένη και επιστημονικά τεκμηριωμένη εικόνα της απόδοσης των εξεταζόμενων μοντέλων.

3.9 Περιγραφή πειραμάτων

Η πειραματική διαδικασία οργανώθηκε σε δύο διαδοχικές φάσεις. Στην πρώτη φάση πραγματοποιήθηκε η εκπαίδευση των δύο μοντέλων με χρήση του οργανωμένου συνόλου δεδομένων από την πλατφόρμα Kaggle. Στόχος της φάσης αυτής ήταν τα μοντέλα να μάθουν τα βασικά χαρακτηριστικά που διαφοροποιούν τα υγιή φύλλα από τα προσβεβλημένα. Μετά την εκπαίδευση, ακολούθησε η αρχική αξιολόγηση των μοντέλων με χρήση των μετρικών ταξινόμησης που παρουσιάστηκαν στην προηγούμενη ενότητα.

Η δεύτερη φάση της πειραματικής διαδικασίας αφορούσε την επιτόπια δοκιμή των ήδη εκπαιδευμένων μοντέλων σε πραγματικές συνθήκες ελαιώνα, με χρήση drone DJI Tello. Σε αυτή τη φάση δεν πραγματοποιήθηκε νέα εκπαίδευση ούτε δημιουργήθηκε νέο dataset, αλλά εφαρμόστηκαν τα έτοιμα μοντέλα σε πραγματικό περιβάλλον για να ελεγχθεί η λειτουργικότητά τους. Η διαδικασία αυτή είχε ιδιαίτερη σημασία, καθώς επέτρεψε την εξέταση της συμπεριφοράς των αλγορίθμων απέναντι σε περιβαλλοντικές συνθήκες που δεν μπορούν να αναπαρασταθούν πλήρως σε ένα οργανωμένο σύνολο εικόνων.

Η συνολική σχεδίαση των πειραμάτων επέτρεψε τόσο την αποτίμηση της βασικής απόδοσης των αλγορίθμων σε οργανωμένο περιβάλλον όσο και την εξέταση της πρακτικής τους λειτουργίας στο πεδίο. Με τον τρόπο αυτό, τα συμπεράσματα της εργασίας δεν βασίζονται αποκλειστικά σε θεωρητική αξιολόγηση, αλλά ενισχύονται και από στοιχεία εφαρμοσμένου ελέγχου, τα οποία είναι απαραίτητα για την εκτίμηση της καταλληλότητας των μεθόδων σε εφαρμογές γεωργίας ακριβείας.

Κεφάλαιο 4 – Αποτελέσματα

4.1 Περιγραφή πειραματικών συνθηκών

Η πειραματική διαδικασία της παρούσας εργασίας σχεδιάστηκε με στόχο την ανάπτυξη και συγκριτική αξιολόγηση δύο διαφορετικών προσεγγίσεων ανίχνευσης ασθενειών φύλλων ελιάς μέσω εικόνας. Οι δύο προσεγγίσεις που εξετάστηκαν ήταν ένα μοντέλο κλασικής μηχανικής μάθησης, βασισμένο σε ταξινομητή Support Vector Machine (SVM) με χαρακτηριστικά HOG, και ένα μοντέλο βαθιάς μάθησης βασισμένο σε τεχνικές μεταφοράς μάθησης (Transfer Learning) μέσω της πλατφόρμας Teachable Machine.

Για την εκπαίδευση των μοντέλων χρησιμοποιήθηκε οργανωμένο σύνολο δεδομένων από την πλατφόρμα Kaggle, το οποίο περιλάμβανε συνολικά 430 εικόνες φύλλων ελιάς. Από αυτές, οι 210 αντιστοιχούσαν σε υγιή φύλλα και οι 220 σε φύλλα προσβεβλημένα από την ασθένεια peacock spot. Η σχετική ισορροπία μεταξύ των δύο κατηγοριών συνέβαλε στη μείωση της πιθανότητας μεροληψίας κατά την εκπαίδευση των μοντέλων και επέτρεψε μια πιο αξιόπιστη σύγκριση των δύο αλγοριθμικών προσεγγίσεων.

Πέρα από τη χρήση του οργανωμένου dataset, πραγματοποιήθηκε και επιτόπια αξιολόγηση των εκπαιδευμένων μοντέλων σε πραγματικές συνθήκες πεδίου. Οι real-time δοκιμές έγιναν σε πραγματικό ελαιώνα, δηλαδή σε εξωτερικό αγροτικό περιβάλλον, με χρήση του drone RoboMaster TT (DJI). Η διαδικασία αυτή είχε ως στόχο να εξεταστεί κατά πόσο τα μοντέλα μπορούν να αναγνωρίζουν σωστά υγιή και προσβεβλημένα φύλλα όταν εφαρμόζονται εκτός του ελεγχόμενου πλαισίου του dataset.

Οι λήψεις πραγματοποιήθηκαν υπό φυσικές συνθήκες φωτισμού, τόσο σε περιβάλλον ηλιοφάνειας όσο και σε συνθήκες συννεφιάς, ώστε να διερευνηθεί η συμπεριφορά των μοντέλων σε διαφορετικές φωτιστικές μεταβολές. Οι δοκιμές δεν περιορίστηκαν σε μία μόνο χρονική στιγμή, αλλά επαναλήφθηκαν σε διαφορετικές ώρες της ημέρας, με κύρια έμφαση στις μεσημεριανές ώρες. Το drone πετούσε σε χαμηλό ύψος, περίπου 1 μέτρο από το έδαφος, ενώ οι λήψεις πραγματοποιήθηκαν σε διαφορετικές γωνίες παρατήρησης και με μικρές διαφοροποιήσεις στην απόσταση από το φύλλωμα, ώστε να προσομοιωθούν πιο ρεαλιστικές συνθήκες χρήσης.

Κατά τη real-time αξιολόγηση χρησιμοποιήθηκαν πολλαπλές δοκιμές και διαδοχικά στιγμιότυπα από τη ζωντανή ροή εικόνας του drone. Οι δοκιμές αυτές περιλάμβαναν περιπτώσεις με σκιά, οπτικό θόρυβο, επικάλυψη φύλλων, καθώς και παραδείγματα όπου η αναγνώριση ήταν δυσκολότερη λόγω σύνθετου φόντου ή μεταβολών στη γωνία λήψης. Οι συνθήκες αυτές είναι ιδιαίτερα σημαντικές, καθώς αντιστακλούν τα πραγματικά προβλήματα που καλούνται να αντιμετωπίσουν τα συστήματα υπολογιστικής όρασης σε εφαρμογές γεωργίας ακριβείας.

Η συνδυαστική χρήση οργανωμένων δεδομένων εκπαίδευσης και real-time αξιολόγησης σε πεδίο επέτρεψε όχι μόνο την αποτίμηση της βασικής απόδοσης των μοντέλων, αλλά και την εξέταση της ικανότητάς τους να γενικεύουν σε πιο απαιτητικές και ρεαλιστικές συνθήκες εφαρμογής. Με τον τρόπο αυτό, η αξιολόγηση της εργασίας

δεν περιορίστηκε σε εργαστηριακό επίπεδο, αλλά επεκτάθηκε και στην πρακτική διερεύνηση της λειτουργικότητας των μοντέλων στο φυσικό περιβάλλον του ελαιώνα.

Dataset	Healthy	Peacock Spot	Total
Kaggle Dataset	210	220	430

Πίνακας 4.1: Περιγραφή του συνόλου δεδομένων.

Ο Πίνακας 4.1 παρουσιάζει τη συνολική κατανομή του συνόλου δεδομένων που χρησιμοποιήθηκε στην παρούσα εργασία. Το dataset αποτελείται από 430 εικόνες φύλλων ελιάς, εκ των οποίων 210 αντιστοιχούν σε υγιή φύλλα και 220 σε φύλλα προσβεβλημένα από την ασθένεια peacock spot. Η σχεδόν ισομερής κατανομή των δύο κατηγοριών θεωρείται ικανοποιητική για την εκπαίδευση και τη συγκριτική αξιολόγηση των δύο μοντέλων, καθώς περιορίζει την πιθανότητα μεροληπτικής μάθησης υπέρ της μίας κλάσης.

4.2 Αποτελέσματα μοντέλου SVM

Το μοντέλο SVM, το οποίο εκπαιδεύτηκε με χρήση χαρακτηριστικών HOG, παρουσίασε accuracy 0.81, γεγονός που δείχνει ότι ταξινομήσε σωστά το 81% των δειγμάτων. Η τιμή αυτή υποδηλώνει ικανοποιητική συνολική απόδοση στο επίπεδο της βασικής ταξινόμησης και δείχνει ότι το μοντέλο ήταν σε θέση να διακρίνει σε σημαντικό βαθμό μεταξύ υγιών και προσβεβλημένων φύλλων. Ωστόσο, η accuracy από μόνη της δεν επαρκεί για την πλήρη ερμηνεία της συμπεριφοράς του συστήματος, ιδιαίτερα σε ένα πρόβλημα ανίχνευσης ασθένειας, όπου έχει ιδιαίτερη σημασία και το είδος των σφαλμάτων που παράγονται.

Η τιμή του precision 0.79 δείχνει ότι όταν το μοντέλο ταξινομεί ένα φύλλο ως προσβεβλημένο, η πρόβλεψή του είναι σωστή σε αρκετά υψηλό ποσοστό, χωρίς όμως να είναι απολύτως αξιόπιστη. Με άλλα λόγια, ένα μέρος των φύλλων που χαρακτηρίζονται ως ασθενή από το μοντέλο είναι στην πραγματικότητα υγιή, γεγονός που αντιστοιχεί σε ψευδώς θετικές προβλέψεις. Η μετρική αυτή είναι σημαντική, καθώς δείχνει πόσο αξιόπιστες είναι οι θετικές ενδείξεις του συστήματος.

Ακόμη μεγαλύτερη σημασία για το συγκεκριμένο πρόβλημα έχει η τιμή του recall 0.83, καθώς αυτή δείχνει πόσα από τα πραγματικά προσβεβλημένα φύλλα εντοπίστηκαν σωστά. Η συγκεκριμένη τιμή δείχνει ότι το μοντέλο εντόπισε το μεγαλύτερο μέρος των πραγματικά ασθενών φύλλων, ωστόσο δεν κατόρθωσε να τα αναγνωρίσει όλα. Στην πράξη, αυτό σημαίνει ότι εξακολουθούν να υπάρχουν περιπτώσεις ψευδώς αρνητικών προβλέψεων, δηλαδή φύλλα με ασθένεια που ταξινομούνται λανθασμένα ως υγιή. Σε μια εφαρμογή έγκαιρης ανίχνευσης φυτικών ασθενειών, τέτοιο είδος σφάλματος είναι ιδιαίτερα σημαντικό, καθώς μπορεί να οδηγήσει σε καθυστέρηση της παρέμβασης.

Ο δείκτης F1-score 0.81 δείχνει ότι το μοντέλο παρουσιάζει σχετικά ισορροπημένη συμπεριφορά μεταξύ precision και recall. Η τιμή αυτή υποδηλώνει ότι το μοντέλο δεν

είναι αμελητέο ή αποτυχημένο, αλλά διατηρεί μια μέση προς καλή επίδοση χωρίς όμως να επιτυγχάνει το επίπεδο σταθερότητας και αξιοπιστίας που θα απαιτούνταν για πιο απαιτητικές εφαρμογές πεδίου.

Η συνολική ερμηνεία των μετρικών οδηγεί στο συμπέρασμα ότι το μοντέλο SVM + HOG μπορεί να λειτουργήσει ως μια βασική προσέγγιση ταξινόμησης, αλλά παρουσιάζει περιορισμούς στην αναγνώριση της ασθένειας peacock spot. Οι περιορισμοί αυτοί σχετίζονται πιθανότατα με τη φύση των χαρακτηριστικών HOG, τα οποία εστιάζουν κυρίως σε ακμές, περιγράμματα και τοπικές δομές της εικόνας, χωρίς να αποτυπώνουν με την ίδια αποτελεσματικότητα τις χρωματικές και υφικές αλλοιώσεις που χαρακτηρίζουν τα προσβεβλημένα φύλλα.

4.3 Αποτελέσματα μοντέλου Transfer Learning

Το μοντέλο Transfer Learning παρουσίασε accuracy 0.90, γεγονός που δείχνει ότι ταξινόμησε σωστά το 90% των δειγμάτων και επομένως εμφάνισε σαφώς καλύτερη συνολική απόδοση σε σχέση με το μοντέλο SVM. Η διαφορά αυτή είναι σημαντική, καθώς υποδηλώνει ότι η προσέγγιση βαθιάς μάθησης κατάφερε να διαχωρίσει με μεγαλύτερη επιτυχία τα υγιή από τα προσβεβλημένα φύλλα.

Η τιμή του precision 0.89 δείχνει ότι όταν το μοντέλο προβλέπει πως ένα φύλλο είναι ασθενές, η πρόβλεψη αυτή είναι σε πολύ μεγάλο βαθμό σωστή. Η υψηλή αυτή τιμή υποδηλώνει ότι το σύστημα παράγει λιγότερα ψευδώς θετικά αποτελέσματα σε σχέση με το SVM και συνεπώς εμφανίζει μεγαλύτερη αξιοπιστία όταν χαρακτηρίζει ένα φύλλο ως προσβεβλημένο.

Ιδιαίτερα σημαντική είναι και η τιμή του recall 0.91, καθώς δείχνει ότι το μοντέλο εντόπισε σωστά το 91% των πραγματικά προσβεβλημένων φύλλων. Στην παρούσα εργασία, η recall αποτελεί κρίσιμη μετρική, διότι το ζητούμενο δεν είναι μόνο η γενική ορθότητα της ταξινόμησης, αλλά κυρίως η έγκαιρη και αξιόπιστη αναγνώριση των περιπτώσεων ασθένειας. Ένα ψευδώς αρνητικό αποτέλεσμα, δηλαδή ένα άρρωστο φύλλο που αναγνωρίζεται λανθασμένα ως υγιές, μπορεί να έχει πρακτική σημασία σε εφαρμογές γεωργίας ακριβείας. Συνεπώς, η υψηλή τιμή recall του μοντέλου Transfer Learning αποτελεί ιδιαίτερα θετικό εύρημα.

Ο δείκτης F1-score 0.90 επιβεβαιώνει ότι το μοντέλο παρουσιάζει πολύ καλή ισορροπία μεταξύ precision και recall. Η τιμή αυτή δείχνει ότι το σύστημα δεν είναι απλώς πιο ακριβές συνολικά, αλλά και πιο συνεπές ως προς τη συνδυαστική ικανότητά του να εντοπίζει τα πραγματικά ασθενή φύλλα και να διατηρεί υψηλή αξιοπιστία στις θετικές προβλέψεις του.

Η συνολική εικόνα των μετρικών καταδεικνύει ότι το μοντέλο Transfer Learning υπερέχει σαφώς έναντι της προσέγγισης SVM + HOG. Η ανώτερη αυτή επίδοση μπορεί να αποδοθεί στη δυνατότητα των συνελκτικών νευρωνικών δικτύων να μαθαίνουν αυτόματα πιο σύνθετα και πολυεπίπεδα χαρακτηριστικά από τις εικόνες, αξιοποιώντας πληροφορία που σχετίζεται όχι μόνο με τη γεωμετρία, αλλά και με τη μορφολογία, το χρώμα και την υφή των προσβεβλημένων περιοχών. Ως αποτέλεσμα, η προσέγγιση

βαθιάς μάθησης εμφανίζεται πιο κατάλληλη για το συγκεκριμένο πρόβλημα αναγνώρισης.

4.4 Συγκριτική ανάλυση μοντέλων

Η σύγκριση των δύο μοντέλων αναδεικνύει σαφείς διαφορές τόσο στη θεωρητική προσέγγιση όσο και στην πρακτική απόδοση.

Πίνακας 4.2: Μετρικές απόδοσης των μοντέλων ταξινόμησης.

Model	Accuracy	Precision	Recall	F1-score
SVM + HOG	0.81	0.79	0.83	0.81
Transfer Learning	0.90	0.89	0.91	0.90

Ο Πίνακας 4.2 παρουσιάζει τις βασικές μετρικές αξιολόγησης των δύο μοντέλων ταξινόμησης, δηλαδή accuracy, precision, recall και F1-score. Παρατηρείται ότι το μοντέλο Transfer Learning εμφανίζει καλύτερη επίδοση σε όλες τις μετρικές, γεγονός που υποδηλώνει πιο αποτελεσματική ικανότητα διάκρισης μεταξύ υγιών και προσβεβλημένων φύλλων. Η βελτιωμένη τιμή του F1-score, που συνδυάζει precision και recall, ενισχύει το συμπέρασμα ότι το μοντέλο βαθιάς μάθησης δεν είναι μόνο πιο ακριβές συνολικά, αλλά και πιο ισορροπημένο ως προς την αναγνώριση των δύο κατηγοριών.

Criterion	SVM + HOG	Transfer Learning
Accuracy (dataset)	0.81	0.90
Precision	0.79	0.89
Recall	0.83	0.91
F1-score	0.81	0.90
Real-time correct predictions	30/40	35/40
Real-time accuracy	0.75	0.875

Πίνακας 4.3: Συγκριτική αξιολόγηση των δύο μοντέλων.

Όπως παρουσιάζεται στον Πίνακα 4.3, το μοντέλο Transfer Learning υπερέχει του SVM + HOG τόσο στις βασικές μετρικές ταξινόμησης στο οργανωμένο dataset όσο και στην επιτόπια real-time αξιολόγηση. Ειδικότερα, εμφανίζει υψηλότερη accuracy, precision, recall και F1-score, γεγονός που υποδηλώνει καλύτερη συνολική ικανότητα διάκρισης μεταξύ υγιών και προσβεβλημένων φύλλων. Παράλληλα, στις real-time δοκιμές το μοντέλο Transfer Learning πέτυχε 35 σωστές προβλέψεις σε σύνολο 40 περιπτώσεων, δηλαδή real-time accuracy 87.5%, ενώ το μοντέλο SVM + HOG πέτυχε 30 σωστές προβλέψεις σε 40 περιπτώσεις, δηλαδή real-time accuracy 75%.

Τα παραπάνω ευρήματα δείχνουν ότι το μοντέλο Transfer Learning παρουσιάζει πιο σταθερή συμπεριφορά όταν εφαρμόζεται σε πραγματικές συνθήκες πεδίου. Στην παρούσα εργασία, η έννοια της σταθερότητας αναφέρεται στη συνέπεια των προβλέψεων του μοντέλου όταν μεταβάλλονται οι συνθήκες λήψης, όπως ο φωτισμός, η γωνία παρατήρησης, η παρουσία σύνθετου φόντου και η επικάλυψη φύλλων. Με βάση τις παρατηρήσεις από τις real-time δοκιμές, το μοντέλο Transfer Learning διατήρησε υψηλότερο ποσοστό σωστών προβλέψεων και μικρότερη ευαισθησία στις μεταβολές του περιβάλλοντος σε σύγκριση με το SVM + HOG.

4.5 Αποτελέσματα real-time αξιολόγησης

Η αξιολόγηση σε πραγματικό χρόνο αποτέλεσε ένα από τα κρίσιμότερα στάδια της παρούσας εργασίας, καθώς επέτρεψε τη διερεύνηση της πρακτικής λειτουργικότητας των δύο μοντέλων σε πραγματικές συνθήκες πεδίου. Σε αντίθεση με την αξιολόγηση στο οργανωμένο σύνολο δεδομένων, η real-time εφαρμογή πραγματοποιήθηκε σε πραγματικό ελαιώνα, όπου οι εικόνες επηρεάζονταν από μεταβαλλόμενο φωτισμό, σύνθετο φυσικό φόντο, επικάλυψη φύλλων, διαφοροποιήσεις στη γωνία λήψης και μικρομεταβολές που σχετίζονταν με την κίνηση του drone. Οι συνθήκες αυτές καθιστούν το πρόβλημα της ταξινόμησης πιο απαιτητικό, αλλά ταυτόχρονα πιο αντιπροσωπευτικό για πιθανή εφαρμογή σε συστήματα γεωργίας ακριβείας.

Κατά τη real-time αξιολόγηση εξετάστηκαν συνολικά 40 frames για κάθε μοντέλο. Το μοντέλο SVM + HOG παράγαγε 30 σωστές προβλέψεις, 6 λανθασμένες και 4 προβλέψεις στην κατηγορία uncertain. Οι uncertain περιπτώσεις αντιστοιχούν σε στιγμιότυπα στα οποία το σύστημα δεν κατέληξε σε επαρκώς σαφή και σταθερή απόφαση, γεγονός που υποδηλώνει αυξημένη ευαισθησία σε περιβαλλοντικές μεταβολές. Αντίθετα, το μοντέλο Transfer Learning παράγαγε 35 σωστές προβλέψεις και 5 λανθασμένες, χωρίς να καταγραφούν uncertain περιπτώσεις. Το εύρημα αυτό υποδηλώνει μεγαλύτερη σταθερότητα και πιο συνεπή συμπεριφορά του μοντέλου βαθιάς μάθησης στις πραγματικές συνθήκες του ελαιώνα.

Model	Total Frames	Correct	Incorrect	Uncertain
SVM + HOG	40	30	6	4
Transfer Learning	40	35	5	0

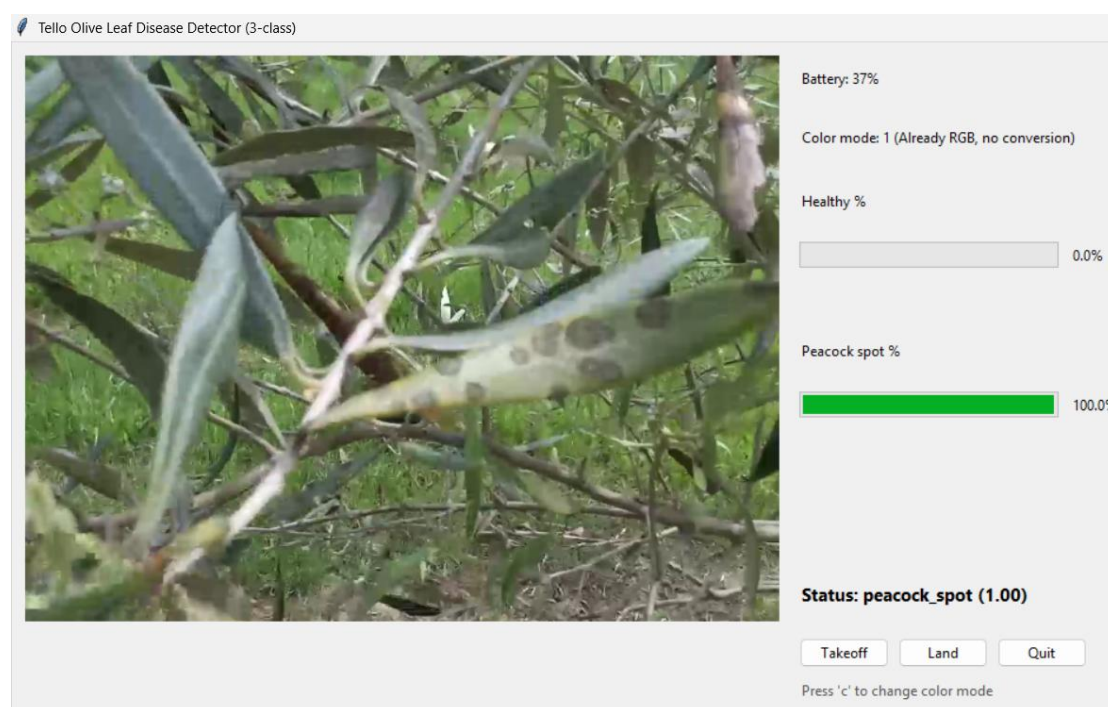
Πίνακας 4.4: Αποτελέσματα real-time αξιολόγησης.

Ο Πίνακας 4.4 συνοψίζει τα αποτελέσματα της real-time αξιολόγησης των δύο μοντέλων. Παρατηρείται ότι το μοντέλο Transfer Learning πέτυχε υψηλότερο αριθμό σωστών προβλέψεων και ταυτόχρονα δεν παρουσίασε uncertain αποφάσεις, σε αντίθεση με το SVM + HOG. Με βάση τα δεδομένα του πίνακα, η real-time ακρίβεια του μοντέλου SVM + HOG αντιστοιχεί σε $30/40 = 0.75$, ενώ του μοντέλου Transfer Learning σε $35/40 = 0.875$. Η διαφορά αυτή είναι ουσιαστική, καθώς δείχνει ότι το

μοντέλο βαθιάς μάθησης διατηρεί πιο αποτελεσματική συμπεριφορά όταν εφαρμόζεται σε μη ελεγχόμενες συνθήκες πεδίου.

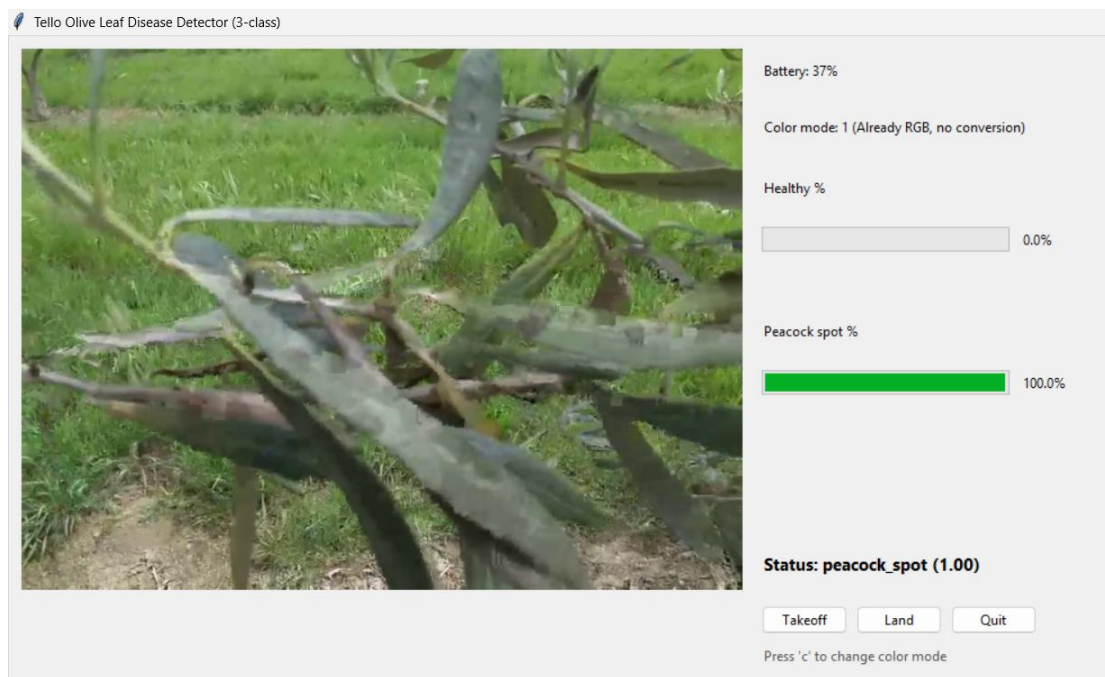
Η πρακτική σημασία των παραπάνω αποτελεσμάτων είναι ιδιαίτερα σημαντική. Στην περίπτωση του SVM + HOG, η ύπαρξη uncertain προβλέψεων δείχνει ότι το μοντέλο δεν ανταποκρίνεται με την ίδια σταθερότητα όταν μεταβάλλονται το φόντο, ο φωτισμός και η διάταξη του φυλλώματος στο οπτικό πεδίο. Αντίθετα, το Transfer Learning εμφανίζει μεγαλύτερη ανοχή στην οπτική πολυπλοκότητα του περιβάλλοντος, γεγονός που ενισχύει την εκτίμηση ότι μπορεί να αξιοποιηθεί αποτελεσματικότερα σε πραγματικές εφαρμογές ανίχνευσης ασθενειών.

Για την πληρέστερη ερμηνεία των real-time αποτελεσμάτων, παρατίθενται στη συνέχεια ενδεικτικά στιγμιότυπα από τη λειτουργία των δύο μοντέλων στο πεδίο. Τα παραδείγματα αυτά δεν αποτελούν απλώς συμπληρωματικό οπτικό υλικό, αλλά συμβάλλουν ουσιαστικά στην κατανόηση της συμπεριφοράς των αλγορίθμων υπό διαφορετικές συνθήκες λήψης.



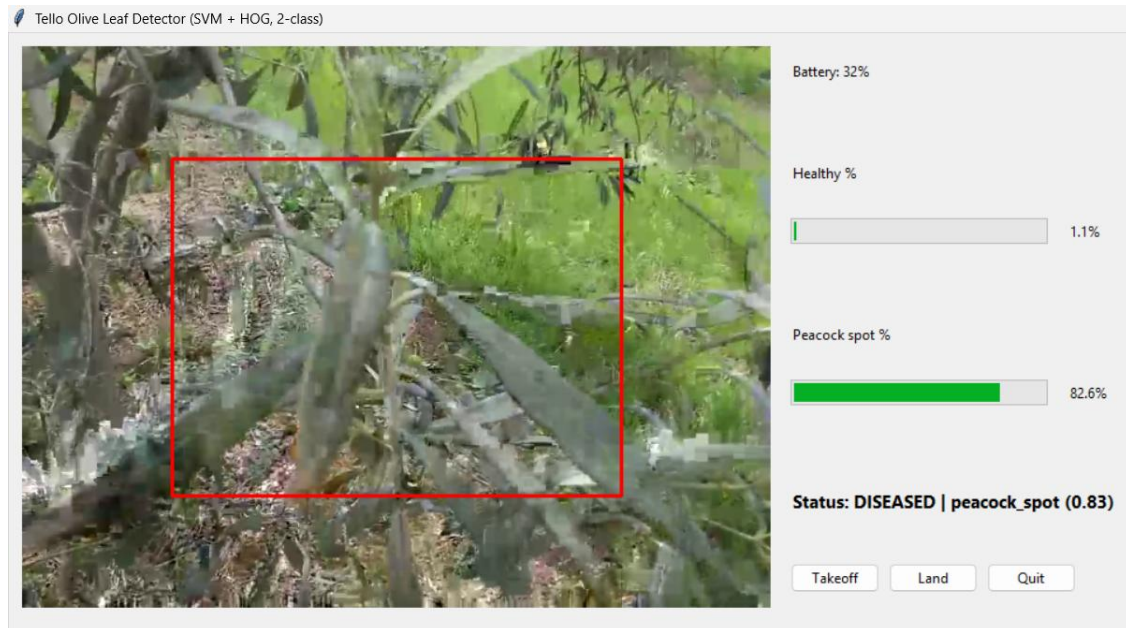
Εικόνα 4.1 – Ορθή αναγνώριση προσβεβλημένου φύλλου από το μοντέλο Transfer Learning

Στην εικόνα 4.1 παρουσιάζεται παράδειγμα real-time πρόβλεψης του μοντέλου Transfer Learning σε φύλλο με εμφανή συμπτώματα της ασθένειας peacock spot. Το μοντέλο ταξινομεί το δείγμα ως προσβεβλημένο με πολύ υψηλή βεβαιότητα, γεγονός που δείχνει ότι μπορεί να αναγνωρίζει αποτελεσματικά σαφή και ορατά συμπτώματα ακόμη και σε φυσικό περιβάλλον λήψης.



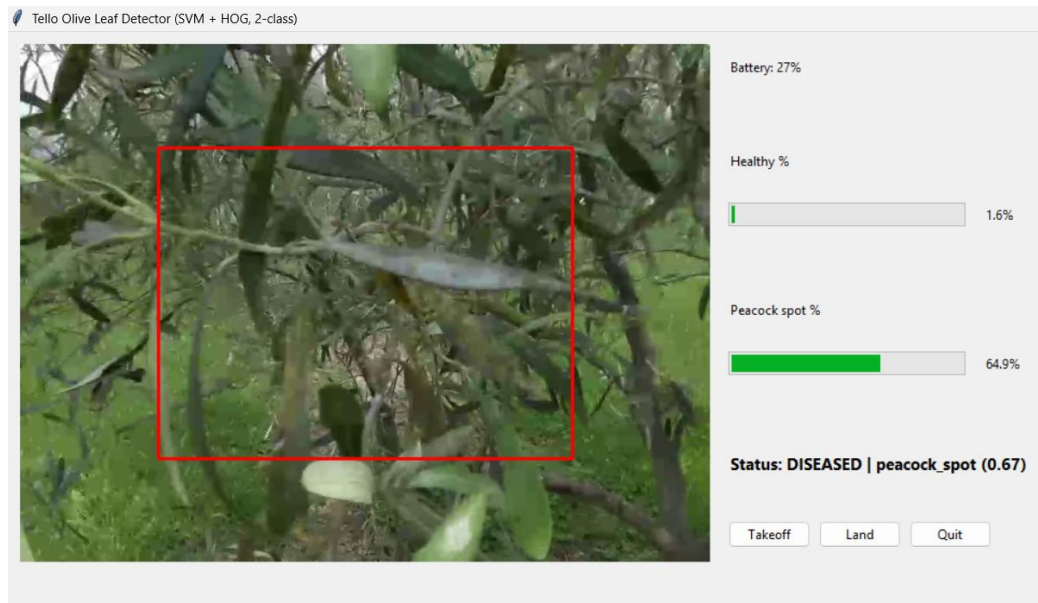
Εικόνα 4.2 – Δεύτερο παράδειγμα ορθής αναγνώρισης από το μοντέλο Transfer Learning

Η εικόνα 4.2 παρουσιάζει δεύτερο παράδειγμα επιτυχούς πρόβλεψης από το μοντέλο Transfer Learning σε διαφορετική γωνία λήψης. Η σταθερά υψηλή πιθανότητα υπέρ της κατηγορίας *peacock spot* ενισχύει το συμπέρασμα ότι το μοντέλο εμφανίζει καλή ικανότητα γενίκευσης και διατηρεί σταθερή συμπεριφορά σε πραγματικές συνθήκες πεδίου.



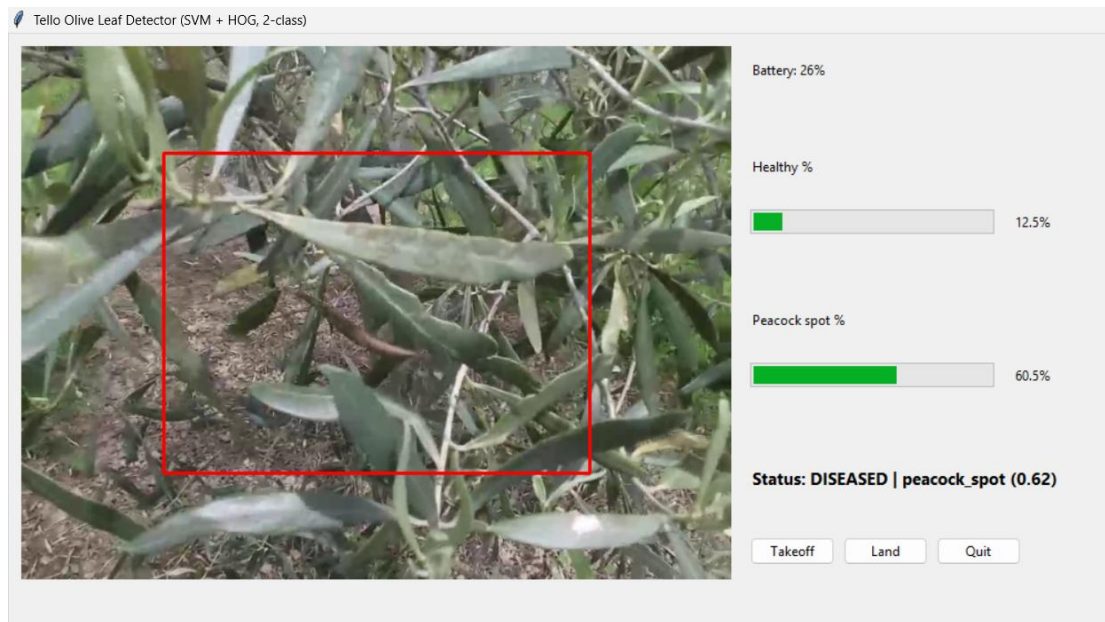
Εικόνα 4.3 – Πρόβλεψη του μοντέλου SVM + HOG με σχετικά υψηλή βεβαιότητα

Η εικόνα 4.3 παρουσιάζεται περίπτωση κατά την οποία το μοντέλο SVM + HOG ταξινομεί το δείγμα ως προσβεβλημένο με πιθανότητα περίπου 82,6%. Το αποτέλεσμα αυτό δείχνει ότι το μοντέλο μπορεί να αναγνωρίζει περιπτώσεις με πιο έντονα και ορατά συμπτώματα. Ωστόσο, ακόμη και σε αυτή την περίπτωση η βεβαιότητά του παραμένει χαμηλότερη σε σχέση με την αντίστοιχη συμπεριφορά του μοντέλου Transfer Learning.



Εικόνα 4.4 – Πρόβλεψη του μοντέλου SVM + HOG σε πιο σύνθετες συνθήκες λήψης

Η εικόνα 4.4 παρουσιάζει παράδειγμα στο οποίο το μοντέλο SVM + HOG εξακολουθεί να ταξινομεί το δείγμα ως προσβεβλημένο, αλλά με χαμηλότερη πιθανότητα, περίπου 64,9%. Η μείωση της βεβαιότητας συνδέεται πιθανότατα με τη μεγαλύτερη πολυπλοκότητα του φόντου, την παρουσία περισσότερων φύλλων στο οπτικό πεδίο και τις διαφοροποιήσεις του φωτισμού. Το παράδειγμα αυτό δείχνει ότι το SVM είναι πιο ευαίσθητο στις μεταβολές του περιβάλλοντος.



Εικόνα 4.5 – Παράδειγμα μειωμένης βεβαιότητας του μοντέλου SVM + HOG

Η εικόνα 4.5 παρουσιάζεται ένα ακόμη παράδειγμα real-time λειτουργίας του μοντέλου SVM + HOG, όπου το σύστημα ταξινομεί το φύλλο ως προσβεβλημένο με πιθανότητα περίπου 60,5%. Παρότι η τελική πρόβλεψη είναι σωστή, η μειωμένη βεβαιότητα υποδηλώνει χαμηλότερη σταθερότητα και μεγαλύτερη ευαισθησία του μοντέλου σε συνθήκες πεδίου, όπως σύνθετο φόντο, σκίαση και διαφοροποιήσεις στη γωνία λήψης.

Τα ενδεικτικά στιγμιότυπα της real-time λειτουργίας επιβεβαιώνουν ότι η συμπεριφορά των δύο μοντέλων διαφοροποιείται ουσιαστικά σε πραγματικές συνθήκες πεδίου. Το μοντέλο Transfer Learning εμφανίζει μεγαλύτερη σταθερότητα και υψηλότερη βεβαιότητα στις προβλέψεις του, ακόμη και όταν μεταβάλλονται η γωνία λήψης, ο φωτισμός και η σύνθεση του φόντου. Αντίθετα, το μοντέλο SVM + HOG, παρότι σε αρκετές περιπτώσεις μπορεί να οδηγηθεί στη σωστή κατηγορία, παρουσιάζει συχνότερα χαμηλότερες πιθανότητες και μεγαλύτερη αβεβαιότητα, κάτι που αποτυπώνεται και στις 4 uncertain προβλέψεις της real-time αξιολόγησης. Το εύρημα αυτό ενισχύει το συνολικό συμπέρασμα της εργασίας, σύμφωνα με το οποίο τα μοντέλα βαθιάς μάθησης είναι καταλληλότερα για real-time εφαρμογές ανίχνευσης ασθενειών σε μη ελεγχόμενες συνθήκες πεδίου.

4.6 Συζήτηση αποτελεσμάτων

Η ανάλυση των αποτελεσμάτων οδηγεί σε σημαντικά επιστημονικά συμπεράσματα σχετικά με την επιλογή αλγορίθμων για εφαρμογές γεωργίας ακριβείας.

Πρώτον, επιβεβαιώνεται ότι η ποιότητα και η ποικιλία των δεδομένων επηρεάζουν καθοριστικά την απόδοση των μοντέλων. Τα μοντέλα που εκπαιδεύονται σε ελεγχόμενα datasets δυσκολεύονται να προσαρμοστούν σε δεδομένα πραγματικού κόσμου.

Δεύτερον, διαπιστώνεται ότι οι παραδοσιακές μέθοδοι μηχανικής μάθησης, αν και υπολογιστικά αποδοτικές, δεν είναι κατάλληλες για σύνθετα προβλήματα εικόνας. Η αδυναμία τους να συλλάβουν πολύπλοκα χαρακτηριστικά περιορίζει την αποτελεσματικότητά τους.

Τρίτον, η χρήση τεχνικών βαθιάς μάθησης και μεταφοράς μάθησης προσφέρει σημαντικά πλεονεκτήματα, όπως αυξημένη ακρίβεια, καλύτερη γενίκευση και μεγαλύτερη ανθεκτικότητα σε θόρυβο.

Συνολικά, τα αποτελέσματα της εργασίας υποδεικνύουν ότι για εφαρμογές real-time ανίχνευσης ασθενειών μέσω drone, τα μοντέλα βαθιάς μάθησης αποτελούν την πλέον κατάλληλη επιλογή.

ΚΕΦΑΛΑΙΟ 5 – Συμπεράσματα

5.1 Συνοπτικά ευρήματα

Η παρούσα εργασία είχε ως βασικό στόχο τη διερεύνηση της δυνατότητας ανίχνευσης ασθενειών φύλλων ελιάς μέσω τεχνικών υπολογιστικής όρασης και μηχανικής μάθησης, με έμφαση στη σύγκριση διαφορετικών προσεγγίσεων ταξινόμησης εικόνας και στην αξιολόγηση της συμπεριφοράς τους σε συνθήκες που προσεγγίζουν την πραγματική γεωργική εφαρμογή. Στο πλαίσιο αυτό, υλοποιήθηκαν και συγκρίθηκαν δύο διακριτές μεθοδολογικές προσεγγίσεις: μία κλασική μέθοδος μηχανικής μάθησης βασισμένη στον ταξινομητή Support Vector Machine (SVM) σε συνδυασμό με εξαγωγή χαρακτηριστικών Histogram of Oriented Gradients (HOG), και μία προσέγγιση βαθιάς μάθησης βασισμένη σε τεχνικές μεταφοράς μάθησης μέσω της πλατφόρμας Teachable Machine.

Τα αποτελέσματα του Κεφαλαίου 4 έδειξαν με σαφήνεια ότι το μοντέλο Transfer Learning υπερέχει του μοντέλου SVM + HOG σε όλες τις βασικές μετρικές αξιολόγησης. Ειδικότερα, το μοντέλο Transfer Learning παρουσίασε accuracy 0.90, precision 0.89, recall 0.91 και F1-score 0.90, ενώ το μοντέλο SVM + HOG παρουσίασε accuracy 0.81, precision 0.79, recall 0.83 και F1-score 0.81. Η διαφορά αυτή δείχνει ότι το μοντέλο βαθιάς μάθησης δεν ήταν μόνο συνολικά πιο ακριβές, αλλά και πιο αποτελεσματικό τόσο ως προς την αξιοπιστία των θετικών προβλέψεων όσο και ως προς την ικανότητά του να εντοπίζει τα πραγματικά προσβεβλημένα φύλλα.

Η ανάλυση των μετρικών δείχνει επίσης ότι η υπεροχή του Transfer Learning δεν περιορίζεται σε μια γενική βελτίωση της accuracy, αλλά επεκτείνεται και στις μετρικές recall και F1-score, οι οποίες είναι ιδιαίτερα σημαντικές για το συγκεκριμένο πρόβλημα. Η υψηλότερη τιμή recall του μοντέλου Transfer Learning σημαίνει ότι το σύστημα εντόπισε μεγαλύτερο ποσοστό των πραγματικά ασθενών φύλλων, μειώνοντας έτσι τον κίνδυνο ψευδώς αρνητικών προβλέψεων. Αντίστοιχα, η υψηλότερη τιμή F1-score δείχνει καλύτερη ισορροπία μεταξύ precision και recall, γεγονός που υποδηλώνει πιο σταθερή και λειτουργικά χρήσιμη συμπεριφορά.

Η διαφορά μεταξύ των δύο προσεγγίσεων έγινε ακόμη πιο εμφανής στη real-time αξιολόγηση σε πραγματικές συνθήκες πεδίου. Στις επιτόπιες δοκιμές, το μοντέλο Transfer Learning πέτυχε 35 σωστές προβλέψεις σε 40 frames και δεν παρουσίασε uncertain περιπτώσεις, ενώ το μοντέλο SVM + HOG πέτυχε 30 σωστές προβλέψεις σε 40 frames, με 4 uncertain προβλέψεις. Τα αποτελέσματα αυτά επιβεβαιώνουν ότι το μοντέλο βαθιάς μάθησης διαθέτει καλύτερη ικανότητα γενίκευσης και μεγαλύτερη ανθεκτικότητα σε παράγοντες όπως η μεταβολή του φωτισμού, το σύνθετο φόντο, οι σκιές και η επικάλυψη φύλλων.

Ένα από τα σημαντικότερα συμπεράσματα της εργασίας είναι, επομένως, ότι η αξιολόγηση των μοντέλων αποκλειστικά πάνω σε οργανωμένα σύνολα δεδομένων δεν επαρκεί για την ουσιαστική αποτίμηση της λειτουργικότητάς τους. Παρότι και τα δύο μοντέλα παρουσίασαν λειτουργική συμπεριφορά στο οργανωμένο dataset, η επιτόπια δοκιμή σε πραγματικό ελαιώνα ανέδειξε πιο καθαρά την υπεροχή του Transfer Learning. Το εύρημα αυτό δείχνει ότι η ικανότητα γενίκευσης ενός μοντέλου σε

πραγματικές συνθήκες πεδίου αποτελεί κρίσιμο κριτήριο για την πρακτική αξιοποίησή του στον τομέα της γεωργίας ακριβείας.

5.2 Απάντηση στα ερευνητικά ερωτήματα

Τα αποτελέσματα της παρούσας εργασίας επιτρέπουν την εξαγωγή σαφών απαντήσεων στα βασικά ερευνητικά ερωτήματα που τη διέπουν. Το πρώτο ερώτημα αφορά το κατά πόσο είναι εφικτή η ανίχνευση ασθενειών φύλλων ελιάς μέσω ανάλυσης εικόνων. Με βάση τα ευρήματα της μελέτης, μπορεί να υποστηριχθεί ότι η ανίχνευση αυτή είναι πράγματι εφικτή, υπό την προϋπόθεση ότι χρησιμοποιούνται κατάλληλες μεθοδολογίες και ότι η αξιολόγηση δεν περιορίζεται αποκλειστικά σε ελεγχόμενα δεδομένα.

Το δεύτερο ερώτημα αφορά τη σχετική απόδοση διαφορετικών κατηγοριών αλγορίθμων. Η σύγκριση μεταξύ SVM + HOG και Transfer Learning έδειξε ότι τα μοντέλα βαθιάς μάθησης υπερτερούν σαφώς σε προβλήματα αυτού του τύπου. Η υπεροχή αυτή αποδίδεται κυρίως στην ικανότητά τους να μαθαίνουν αυτόματα πιο σύνθετες και ανθεκτικές αναπαραστάσεις των οπτικών δεδομένων, αξιοποιώντας πληροφορία που σχετίζεται με το χρώμα, την υφή, τη μορφολογία και τη χωρική οργάνωση των συμπτωμάτων, σε αντίθεση με τις παραδοσιακές προσεγγίσεις που στηρίζονται σε προκαθορισμένα χαρακτηριστικά. Ενώ ο SVM μπορεί να προσφέρει μια αρχική και υπολογιστικά απλή λύση, η ικανότητά του να ανταποκρίνεται σε πιο σύνθετα οπτικά περιβάλλοντα είναι περιορισμένη. Αντίθετα, τα μοντέλα μεταφοράς μάθησης εμφανίζουν καλύτερη προσαρμογή, μεγαλύτερη σταθερότητα και υψηλότερη ικανότητα γενίκευσης.

Το τρίτο ερώτημα σχετίζεται με το κατά πόσο ένα τέτοιο σύστημα μπορεί να λειτουργήσει σε πραγματικές συνθήκες πεδίου. Η επιτόπια δοκιμή με drone έδειξε ότι η εφαρμογή των αλγορίθμων σε πραγματικό περιβάλλον είναι δυνατή, αλλά ταυτόχρονα κατέδειξε ότι δεν αποδίδουν όλες οι μέθοδοι το ίδιο καλά. Το μοντέλο Transfer Learning φάνηκε να ανταποκρίνεται πιο αποτελεσματικά σε πραγματικές εικόνες, ενώ το μοντέλο SVM εμφάνισε μεγαλύτερη αβεβαιότητα και μειωμένη σταθερότητα στις προβλέψεις του.

Τέλος, η εργασία απαντά και στο ερώτημα της σημασίας των συνθηκών λήψης εικόνας. Επιβεβαιώθηκε ότι παράγοντες όπως ο φωτισμός, οι σκιές, το φόντο, η επικάλυψη φύλλων και η πιθανή θόλωση λόγω κίνησης επηρεάζουν αισθητά την απόδοση των μοντέλων. Η επίδραση αυτή είναι εντονότερη σε προσεγγίσεις που βασίζονται σε χειροποίητα χαρακτηριστικά, όπως το SVM + HOG, καθώς τέτοιες μέθοδοι εμφανίζουν μεγαλύτερη ευαισθησία σε μεταβολές της οπτικής δομής της εικόνας και μικρότερη ανθεκτικότητα σε σύνθετες συνθήκες πεδίου. Επομένως, η αποτελεσματική ανίχνευση ασθενειών δεν εξαρτάται αποκλειστικά από τον αλγόριθμο, αλλά και από τη ρεαλιστική αξιολόγησή του σε συνθήκες που προσεγγίζουν το πραγματικό περιβάλλον εφαρμογής.

5.3 Πρακτική αξία της προσέγγισης

Η παρούσα εργασία δεν περιορίζεται σε θεωρητικό ή αμιγώς πειραματικό επίπεδο, αλλά παρουσιάζει σαφή πρακτική αξία στον τομέα της γεωργίας ακριβείας. Η δυνατότητα εφαρμογής εκπαιδευμένων μοντέλων ανίχνευσης ασθενειών σε συνδυασμό με χρήση drone χαμηλού κόστους αναδεικνύει τη δυναμική ανάπτυξης συστημάτων παρακολούθησης της φυτικής υγείας που είναι λειτουργικά, οικονομικά προσιτά και δυνητικά εφαρμόσιμα σε πραγματικές καλλιέργειες.

Η πρακτική σημασία της προσέγγισης αυτής έγκειται, πρώτον, στο ότι μπορεί να υποστηρίξει τον έγκαιρο εντοπισμό προβλημάτων στο φύλλωμα της ελιάς. Η έγκαιρη αναγνώριση προσβολών είναι κρίσιμη, διότι επιτρέπει την ταχύτερη λήψη καλλιεργητικών αποφάσεων και την πιο στοχευμένη εφαρμογή μέτρων φυτοπροστασίας. Η δυνατότητα αυτή μπορεί να περιορίσει τη μη αναγκαία ή γενικευμένη χρήση φυτοφαρμάκων, να ενισχύσει την ακρίβεια των επεμβάσεων και να συμβάλει στη μείωση του περιβαλλοντικού αποτυπώματος της καλλιέργειας. Παράλληλα, η προσέγγιση αυτή μπορεί να μειώσει την ανάγκη για αποκλειστικά χειροκίνητη παρακολούθηση των δέντρων, η οποία είναι συχνά χρονοβόρα, υποκειμενική και δύσκολη στην εφαρμογή σε μεγάλες καλλιεργητικές εκτάσεις. Επομένως, η ενσωμάτωση τέτοιων τεχνολογιών μπορεί να λειτουργήσει υποστηρικτικά προς μια πιο στοχευμένη, αποδοτική και βιώσιμη μορφή γεωργικής διαχείρισης.

Επιπλέον, η χρήση χαμηλού κόστους τεχνολογιών, όπως το DJI Tello και πλατφόρμες ανάπτυξης μοντέλων όπως το Teachable Machine, αναδεικνύει ότι η τεχνολογία της τεχνητής νοημοσύνης δεν είναι απαραίτητα απρόσιτη ή περιορισμένη μόνο σε εξειδικευμένα εργαστήρια και ερευνητικά κέντρα. Αντίθετα, μπορεί να μετατραπεί σε πρακτικό εργαλείο για μικρότερης κλίμακας εφαρμογές, δοκιμές πεδίου ή πιλοτικά συστήματα σε αγροτικό περιβάλλον. Η διάσταση αυτή είναι ιδιαίτερα σημαντική, καθώς συνδέει την ακαδημαϊκή έρευνα με τη δυνατότητα μελλοντικής αξιοποίησης σε πραγματικές παραγωγικές συνθήκες.

5.4 Περιορισμοί της μελέτης

Παρά τα θετικά αποτελέσματα και τη σαφή ερευνητική συμβολή της εργασίας, υπάρχουν ορισμένοι περιορισμοί που πρέπει να αναγνωριστούν, καθώς επηρεάζουν την έκταση στην οποία μπορούν να γενικευθούν τα συμπεράσματα. Ο πρώτος και σημαντικότερος περιορισμός αφορά το μέγεθος και τη φύση του χρησιμοποιούμενου συνόλου δεδομένων. Αν και το dataset από την πλατφόρμα Kaggle ήταν επαρκές για τη βασική εκπαίδευση και σύγκριση των δύο μοντέλων, παραμένει σχετικά περιορισμένο σε σχέση με την ποικιλία των συνθηκών που μπορεί να συναντώνται σε πραγματικές καλλιέργειες ελιάς.

Ένας δεύτερος σημαντικός περιορισμός σχετίζεται με τη διαφορά μεταξύ οργανωμένων δεδομένων και πραγματικού αγροτικού περιβάλλοντος. Τα μοντέλα εκπαιδεύτηκαν σε ένα δομημένο και επισημασμένο σύνολο εικόνων, αλλά η πρακτική τους εφαρμογή δοκιμάστηκε σε φύλλα από πραγματικό ελαιώνα, όπου το οπτικό περιβάλλον είναι πολύ πιο σύνθετο. Αν και αυτή η επιτόπια δοκιμή αποτελεί ισχυρό

στοιχείο της εργασίας, παραμένει περιορισμένης κλίμακας και δεν συνιστά πλήρως τυποποιημένο σύνολο πεδίου για εκτεταμένη στατιστική αποτίμηση.

Επιπλέον, η χρήση drone χαμηλού κόστους, παρότι ενισχύει την πρακτική αξία της εργασίας, συνοδεύεται και από τεχνικούς περιορισμούς. Παράγοντες όπως η σταθερότητα της λήψης, η ανάλυση της κάμερας, η θόλωση λόγω μικροκινήσεων και η ευαισθησία στον φωτισμό μπορούν να επηρεάσουν την ποιότητα της εικόνας και κατ' επέκταση την αξιοπιστία των προβλέψεων. Η παρατήρηση αυτή είναι σημαντική, καθώς δείχνει ότι η τεχνολογική προσβασιμότητα συνοδεύεται συχνά από περιορισμούς στην ακρίβεια και στη σταθερότητα του οπτικού υλικού.

Τέλος, πρέπει να σημειωθεί ότι η χρήση της πλατφόρμας Teachable Machine, αν και ιδιαίτερα χρήσιμη και πρακτική για την υλοποίηση ενός μοντέλου βαθιάς μάθησης, περιορίζει σε κάποιον βαθμό τον πλήρη έλεγχο των εσωτερικών παραμέτρων της εκπαίδευσης. Η αξιοποίηση εργαλείων no-code προσφέρει σημαντική απλότητα, ταχύτητα ανάπτυξης και ευκολία υλοποίησης, στοιχεία που καθιστούν τέτοιες πλατφόρμες ιδιαίτερα ελκυστικές για πειραματικές εφαρμογές. Παρ' όλα αυτά, η ευκολία αυτή συνοδεύεται από περιορισμένη δυνατότητα λεπτομερούς πειραματικού ελέγχου, αναλυτικής ρύθμισης υπερπαραμέτρων και εξαντλητικής τεχνικής βελτιστοποίησης του μοντέλου. Αυτό σημαίνει ότι, αν και επιτεύχθηκε καλή πρακτική απόδοση, δεν υπήρχε η δυνατότητα εξαντλητικής πειραματικής βελτιστοποίησης όλων των τεχνικών λεπτομερειών του μοντέλου, όπως θα ήταν εφικτό σε μια πλήρη υλοποίηση σε εξειδικευμένο προγραμματιστικό περιβάλλον.

Ένας επιπλέον περιορισμός της παρούσας εργασίας αφορά το γεγονός ότι το πρόβλημα διατυπώθηκε και αντιμετωπίστηκε ως πρόβλημα δυαδικής ταξινόμησης, δηλαδή διάκριση μεταξύ υγιών και προσβεβλημένων φύλλων. Η προσέγγιση αυτή ήταν κατάλληλη για τους στόχους της μελέτης και για το διαθέσιμο σύνολο δεδομένων, ωστόσο δεν καλύπτει περιπτώσεις πολυκατηγορικής ταξινόμησης, όπου θα απαιτούνταν η διάκριση μεταξύ διαφορετικών τύπων ασθενειών ή διαφορετικών βαθμών προσβολής. Επομένως, τα συμπεράσματα της εργασίας αφορούν κυρίως τη βασική ανίχνευση παρουσίας ή απουσίας ασθένειας και δεν μπορούν να επεκταθούν χωρίς περαιτέρω διερεύνηση σε πιο σύνθετα προβλήματα διαγνωστικής κατηγοριοποίησης.

5.5 Μελλοντική εργασία

Η παρούσα εργασία δημιουργεί ένα ουσιαστικό υπόβαθρο για περαιτέρω έρευνα και ανάπτυξη στον τομέα της αυτόματης ανίχνευσης ασθενειών φύλλων ελιάς. Μία πρώτη και ιδιαίτερα σημαντική κατεύθυνση μελλοντικής επέκτασης αφορά τη δημιουργία μεγαλύτερων και πιο αντιπροσωπευτικών συνόλων δεδομένων, τα οποία θα περιλαμβάνουν εικόνες από διαφορετικές περιοχές, ποικιλίες ελιάς, στάδια ανάπτυξης των φύλλων και ποικίλες περιβαλλοντικές συνθήκες. Η επέκταση αυτή θα μπορούσε να βελτιώσει αισθητά την ικανότητα γενίκευσης των μοντέλων και να οδηγήσει σε πιο αξιόπιστα και σταθερά αποτελέσματα.

Μία δεύτερη κατεύθυνση αφορά τη χρήση πιο προηγμένων αρχιτεκτονικών βαθιάς μάθησης. Αν και η προσέγγιση Transfer Learning που εφαρμόστηκε στην εργασία

απέδωσε καλύτερα από τον SVM, υπάρχουν ακόμη πιο εξειδικευμένες αρχιτεκτονικές που θα μπορούσαν να αξιοποιηθούν, όπως νεότερα συνελκτικά δίκτυα, μοντέλα attention ή αρχιτεκτονικές ανίχνευσης αντικειμένων όπως το YOLO. Η χρήση τέτοιων μεθόδων θα μπορούσε να οδηγήσει όχι μόνο σε καλύτερη ταξινόμηση, αλλά και σε ταχύτερο και πιο ακριβή εντοπισμό προσβεβλημένων περιοχών σε πραγματικές συνθήκες πεδίου.

Επιπλέον, ιδιαίτερο ενδιαφέρον παρουσιάζει η δυνατότητα μετάβασης από απλή ταξινόμηση εικόνας σε πιο σύνθετες λειτουργίες, όπως η semantic segmentation των προσβεβλημένων περιοχών του φύλλου. Μια τέτοια προοπτική θα ήταν ιδιαίτερα χρήσιμη σε πραγματικές εφαρμογές, καθώς δεν θα αρκούσε μόνο να δηλώνεται αν ένα φύλλο είναι υγιές ή προσβεβλημένο, αλλά θα μπορούσε να αποτυπώνεται και η ακριβής θέση ή έκταση της προσβολής.

Τέλος, μελλοντική εργασία θα μπορούσε να εξετάσει την ενσωμάτωση του συστήματος σε ένα πιο ολοκληρωμένο πλαίσιο γεωργίας ακριβείας. Σε ένα τέτοιο σενάριο, τα δεδομένα εικόνας από drone θα μπορούσαν να συνδυάζονται με άλλες πηγές πληροφορίας, όπως αισθητήρες περιβάλλοντος, γεωχωρικά δεδομένα ή μετεωρολογικές μεταβλητές. Ιδιαίτερο ενδιαφέρον θα είχε και η αξιοποίηση τεχνικών multispectral imaging, οι οποίες θα μπορούσαν να προσφέρουν πληροφορία πέρα από το ορατό φάσμα και να βελτιώσουν περαιτέρω τη δυνατότητα έγκαιρης ανίχνευσης φυτικών ασθενειών.

5.6 Επίλογος

Η παρούσα πτυχιακή εργασία κατέδειξε ότι η ανίχνευση ασθενειών φύλλων ελιάς μέσω ανάλυσης εικόνας αποτελεί ένα εφικτό και ουσιαστικό πεδίο εφαρμογής της μηχανικής μάθησης στη γεωργία ακριβείας. Η συγκριτική μελέτη μεταξύ της κλασικής προσέγγισης SVM + HOG και της προσέγγισης βαθιάς μάθησης μέσω Transfer Learning ανέδειξε ότι, παρόλο που οι παραδοσιακές μέθοδοι μπορούν να προσφέρουν μια λειτουργική αρχική λύση, τα μοντέλα βαθιάς μάθησης εμφανίζουν σαφώς καλύτερη απόδοση, μεγαλύτερη σταθερότητα και αυξημένη ικανότητα γενίκευσης, ιδιαίτερα όταν εφαρμόζονται σε πραγματικές συνθήκες πεδίου.

Η επιτόπια δοκιμή των εκπαιδευμένων μοντέλων σε ελαιώνα με χρήση drone χαμηλού κόστους έδωσε στην εργασία ιδιαίτερη πρακτική αξία, καθώς επέτρεψε την αξιολόγηση των αλγορίθμων όχι μόνο σε οργανωμένα δεδομένα αλλά και σε ένα ρεαλιστικό περιβάλλον εφαρμογής. Το βασικό συμπέρασμα που προκύπτει είναι ότι ο συνδυασμός ανάλυσης εικόνας, τεχνητής νοημοσύνης και οικονομικά προσιτών εναέριων μέσων μπορεί να αποτελέσει μια υποσχόμενη βάση για την ανάπτυξη σύγχρονων συστημάτων παρακολούθησης της υγείας των καλλιεργειών. Παρά τους επιμέρους περιορισμούς της μελέτης, η εργασία επιβεβαιώνει ότι η αξιοποίηση τεχνικών βαθιάς μάθησης στην ελαιοκαλλιέργεια μπορεί να συμβάλει ουσιαστικά στην έγκαιρη διάγνωση ασθενειών και στη μελλοντική υποστήριξη πιο αποδοτικών και βιώσιμων γεωργικών πρακτικών.

Βιβλιογραφία

1. Abuamsha, R., Salman, M., & Abu-Blan, H. (2013). Evaluation of the incidence and severity of olive leaf spot caused by *Spilocaea oleagina* in Palestine. *Journal of Agriculture and Environment for International Development*, 107(2), 203–209.
2. Alshammari, H. H., Taloba, A. I., & Shahin, O. R. (2023). Identification of olive leaf disease through optimized deep learning approach. *Alexandria Engineering Journal*, 72, 213–224. <https://doi.org/10.1016/j.aej.2023.03.081>
3. Amarasingam, N., Gonzalez, F., Salgadoe, A. S. A., Sandino, J., & Powell, K. (2022). Detection of white leaf disease in sugarcane crops using UAV-derived RGB imagery with existing deep learning models. *Remote Sensing*, 14(23), 6137. <https://doi.org/10.3390/rs14236137>
4. Buonauro, R., Almadi, L., Famiani, F., Moretti, C., Agosteo, G. E., & Schena, L. (2023). Olive leaf spot caused by *Venturia oleaginea*: An updated review. *Frontiers in Plant Science*, 13, 1061136. <https://doi.org/10.3389/fpls.2022.1061136>
5. Chowdhury, M. E. H., Rahman, T., Khandakar, A., Ayari, M. A., Khan, A. U., Khan, M. S., Al-Emadi, N., Reaz, M. B. I., Islam, M. T., & Ali, S. H. M. (2021). Automatic and reliable leaf disease detection using deep learning techniques. *AgriEngineering*, 3(2), 294–312. <https://doi.org/10.3390/agriengineering3020020>
6. Dutta, G., & Goswami, P. (2020). Application of drone in agriculture: A review. *International Journal of Chemical Studies*, 8(5), 181–187. <https://doi.org/10.22271/chemi.2020.v8.i5d.10529>
7. Elliott, J., et al. (2022). A comparison of ImageJ and machine learning based image analysis methods to measure cassava bacterial blight disease severity. *Plant Methods*, 18, 100. <https://doi.org/10.1186/s13007-022-00906-x>
8. Estudillo, C., Pérez-Rial, A., Guerrero-Páez, F. A., Díez, C. M., Moral, J., & Die, J. V. (2025). Characterization of olive-resistant genes against *Spilocaea oleagina*, the causal agent of scab. *Agronomy*, 15(2), 452. <https://doi.org/10.3390/agronomy15020452>

9. Ganatra, N., & Patel, D. (2020). A multiclass plant leaf disease detection using image processing and machine learning techniques.
10. Gavhale, K. R., & Gawande, U. (2014). An overview of the research on plant leaves disease detection using image processing techniques. *IOSR Journal of Computer Engineering*, *16*(1), 10–16.
11. Ksibi, A., Ayadi, M., Soufiene, B. O., Jamjoom, M. M., & Ullah, Z. (2022). MobiRes-Net: A hybrid deep learning model for detecting and classifying olive leaf diseases. *Applied Sciences*, *12*(20), 10278. <https://doi.org/10.3390/app122010278>
12. Lamsal, R., et al. (2024). Introducing image classification through no-code Teachable Machine platform: An intuitive approach for novice learners.
13. Liakos, K. G., et al. (2018). Computer vision and artificial intelligence in precision agriculture for grain crops. *Computers and Electronics in Agriculture*, *153*, 69–81. <https://doi.org/10.1016/j.compag.2018.07.043>
14. Maes, W. H. (2025). Practical guidelines for performing UAV mapping flights with snapshot sensors. *Remote Sensing*, *17*(4), 606. <https://doi.org/10.3390/rs17040606>
15. Maharjan, U., et al. (2024). Introducing vegetable classification through Teachable Machine platform.
16. Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, *7*, 1419. <https://doi.org/10.3389/fpls.2016.01419>
17. Olson, D., & Andersen, J. (2021). Review on unmanned aerial vehicles, remote sensors, imagery processing, and their applications in agriculture. *Agronomy Journal*, *113*(2), 971–992. <https://doi.org/10.1002/agj2.20595>
18. Pacal, I., Kilicarslan, S., Ozdemir, B., Deveci, M., & Kadry, S. (2025). Efficient and autonomous detection of olive leaf diseases using AI-enhanced

MetaFormer. *Artificial Intelligence Review*, 58(10), 303.
<https://doi.org/10.1007/s10462-025-11131-y>

19. Patil, N., & Burkpalli, V. (2021). A perspective view of cotton leaf image classification using machine learning algorithms using WEKA. *Journal of Food Quality* (Hindawi), 2021, 9367778. <https://doi.org/10.1155/2021/9367778>
20. Rhouma, A., Chettaoui, M., Krid, S., Elbsir, H., Msallem, M., & Triki, M. A. (2013). Evaluation of susceptibility of an olive progeny (Picholine × Meski) to olive leaf spot disease caused by *Fusicladium oleagineum*. *European Journal of Plant Pathology*, 135, 23–33. <https://doi.org/10.1007/s10658-012-0062-x>
21. Patrício, D. I., & Rieder, R. (2018). *Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review*. *Computers and Electronics in Agriculture*, 153, 69–81. <https://doi.org/10.1016/j.compag.2018.08.001>
22. Scibetta, S., Agosteo, G. E., Abdelfattah, A., Li Destri Nicosia, M. G., Cacciola, S. O., & Schena, L. (2020). Development and application of a quantitative PCR detection method to quantify *Venturia oleaginea* in asymptomatic olive (*Olea europaea*) leaves. *Phytopathology*, 110(3), 547–555. <https://doi.org/10.1094/PHYTO-07-19-0227-R>
23. Shahi, T. B., Xu, C.-Y., Neupane, A., & Guo, W. (2023). Recent advances in crop disease detection using UAV and deep learning techniques. *Remote Sensing*, 15(9), 2450. <https://doi.org/10.3390/rs15092450>
24. Sinha, A., & Shekhawat, R. S. (2020). Olive spot disease detection and classification using analysis of leaf image textures. *Procedia Computer Science*, 167, 2328–2336. <https://doi.org/10.1016/j.procs.2020.03.285>
25. Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanovic, D. (2016). Deep neural networks based recognition of plant diseases by leaf image classification. *Computational Intelligence and Neuroscience*, 2016, 3289801. <https://doi.org/10.1155/2016/3289801>
26. Sujatha, R., Chatterjee, J. M., Jhanjhi, N. Z., & Brohi, S. N. (2021). Performance of deep learning vs machine learning in plant leaf disease detection.

Microprocessors and Microsystems, 80, 103615.
<https://doi.org/10.1016/j.micpro.2020.103615>

27. Thomidis, T., Michos, K., Chatzipapadopoulos, F., & Tampaki, A. (2021). Evaluation of two predictive models for forecasting olive leaf spot in Northern Greece. *Plants*, 10(6), 1200. <https://doi.org/10.3390/plants10061200>
28. Uğuz, S., & Uysal, N. (2021). Classification of olive leaf diseases using deep convolutional neural networks. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-020-05235-5>
29. Vélez, S., Vacas, R., Martín, H., Ruano-Rosa, D., & Álvarez, S. (2022). High-resolution UAV RGB imagery dataset for precision agriculture and 3D photogrammetric reconstruction captured over a pistachio orchard in Spain. *Data*, 7(11), 157. <https://doi.org/10.3390/data7110157>
30. Zhang, C., Zhou, G., & Li, Z. (2022). Unmanned aerial vehicles for plant phenotyping and precision agriculture: A review. *Frontiers in Plant Science*, 13, 1061136. <https://doi.org/10.3389/fpls.2022.1061136>
31. Buljubašić, I., Bjeliš, M., & Marušić, I. (2012). An assessment of peacock olive leaf spot (*Spilocaea oleagina* [Castagne] Hughes) attack in olive growing areas. *Glasilo biljne zaštite*, 12(4), 341–347.
32. Australian Olives. (2020). *Tutorial 8 – Peacock spot*. Australian Olives.
33. Shields, R. (2023, April). *What is smart farming and the benefits and drawbacks of it?* Agricultural Recruitment Specialists. <https://www.agrirs.co.uk/blog/2023/04/what-is-smart-farming-and-the-benefits-and-drawbacks-of-it>
34. Gomstyn, A., & Jonker, A. (n.d.). *What is smart farming?* IBM Think. <https://www.ibm.com/think/topics/smart-farming>
35. Sahu, S. K., & Pandey, M. (2022). An optimal hybrid multiclass SVM for plant leaf disease detection using spatial Fuzzy C-Means model. *Expert Systems with Applications*, 194, 118989. <https://doi.org/10.1016/j.eswa.2022.118989>
36. Naila, S., Yu, J. J., Yang, N., Kashif, H., Tang, J., & Wang, A. Y. (2020). A rapid recognition method for rice false smut based on HOG features and SVM

classification. *Journal of Physics: Conference Series*, 1576, 012018.
<https://doi.org/10.1088/1742-6596/1576/1/012018>

37. Hussein, M. A., & Abbas, A. H. (2019). Plant leaf disease detection using support vector machine. *Al-Mustansiriyah Journal of Science*, 30(1), 105–110.
<https://doi.org/10.23851/mjs.v30i1.487>
38. Padol, P. B., & Yadav, A. A. (2016). SVM classifier based grape leaf disease detection. In *2016 Conference on Advances in Signal Processing (CASP)* (pp. 175–178). IEEE.
39. Sahu, S. K., & Pandey, M. (2022). An optimal hybrid multiclass SVM for plant leaf disease detection using spatial Fuzzy C-Means model. *Expert Systems with Applications*, 194, Article 118989. <https://doi.org/10.1016/j.eswa.2022.118989>
40. Sharma, R., Panigrahi, A., Garanayak, M., Chakravarty, S., Paikaray, B. K., & Pattanaik, L. (2022). *Tomato leaf disease detection using machine learning*. In Proceedings of the ACI'22 Workshop on Advances in Computational Intelligence, its Concepts & Applications (ISIC 2022). CEUR Workshop Proceedings.

Παραρτήματα

Στην ενότητα αυτή παρατίθεται συμπληρωματικό υλικό που υποστηρίζει την πειραματική διαδικασία και την ερμηνεία των αποτελεσμάτων της παρούσας εργασίας. Τα παραρτήματα περιλαμβάνουν ενδεικτικές εικόνες του συνόλου δεδομένων, στιγμιότυπα από τη real-time λειτουργία του συστήματος με drone, καθώς και πρόσθετα αποτελέσματα αξιολόγησης που δεν εντάχθηκαν στο κύριο σώμα του κειμένου, ώστε να διατηρηθεί η συνοχή και η αναγνωσιμότητα της εργασίας.

Παράρτημα Α – Ενδεικτικές εικόνες του συνόλου δεδομένων

Στο Παράρτημα Α παρατίθενται ενδεικτικές εικόνες από το σύνολο δεδομένων που χρησιμοποιήθηκε στην παρούσα εργασία για την εκπαίδευση και αξιολόγηση των μοντέλων ταξινόμησης. Οι εικόνες περιλαμβάνουν τόσο υγιή φύλλα ελιάς όσο και φύλλα με εμφανή συμπτώματα της ασθένειας peacock spot. Η παράθεση αντιπροσωπευτικών παραδειγμάτων κρίνεται σημαντική, καθώς επιτρέπει την οπτική κατανόηση των διαφορών μεταξύ των δύο κατηγοριών και υποστηρίζει την ερμηνεία της διαδικασίας ταξινόμησης.



Εικόνα Α.1 – Ενδεικτικό υγιές φύλλο ελιάς

Η εικόνα παρουσιάζει ένα υγιές φύλλο ελιάς χωρίς ορατές αλλοιώσεις, κηλιδώσεις ή αποχρωματισμούς. Η ομοιομορφία του χρώματος και η απουσία νεκρωτικών περιοχών αποτελούν βασικά μορφολογικά χαρακτηριστικά της υγιούς κατηγορίας.



Εικόνα Α.2 – Δεύτερο παράδειγμα υγιούς φύλλου ελιάς

Στο συγκεκριμένο παράδειγμα παρατηρείται επίσης ένα υγιές φύλλο, με φυσιολογική μορφολογία και ομοιόμορφη υφή. Η συμπερίληψη περισσότερων του ενός υγιών δειγμάτων είναι σημαντική, ώστε να αποτυπώνεται η φυσική μεταβλητότητα ακόμη και εντός της ίδιας κατηγορίας.



Εικόνα Α.3 – Τρίτο παράδειγμα υγιούς φύλλου ελιάς

Η εικόνα απεικονίζει ένα ακόμη υγιές φύλλο ελιάς, ελαφρώς διαφορετικό ως προς το μήκος και το σχήμα, αλλά χωρίς συμπτώματα ασθένειας. Η ύπαρξη τέτοιων διαφοροποιήσεων βοηθά τα μοντέλα να μαθαίνουν γενικότερα χαρακτηριστικά της υγιούς κλάσης.



Εικόνα Α.4 – Φύλλο ελιάς με πρώιμα συμπτώματα peacock spot

Στην εικόνα παρατηρούνται αρχικά συμπτώματα της ασθένειας peacock spot, με ήπιες κηλιδώσεις και αποχρωματισμούς στην επιφάνεια του φύλλου. Τέτοιες περιπτώσεις είναι ιδιαίτερα σημαντικές για την εκπαίδευση των μοντέλων, καθώς αποτελούν οριακές καταστάσεις ταξινόμησης.



Εικόνα Α.5 – Φύλλο ελιάς με εμφανή συμπτώματα προσβολής

Η εικόνα παρουσιάζει πιο έντονη προσβολή, με εκτεταμένες κηλίδες και ανομοιογενή χρωματική αλλοίωση. Τα χαρακτηριστικά αυτά αποτελούν τυπική οπτική έκφραση της νόσου και διευκολύνουν τη διάκριση από τα υγιή φύλλα.



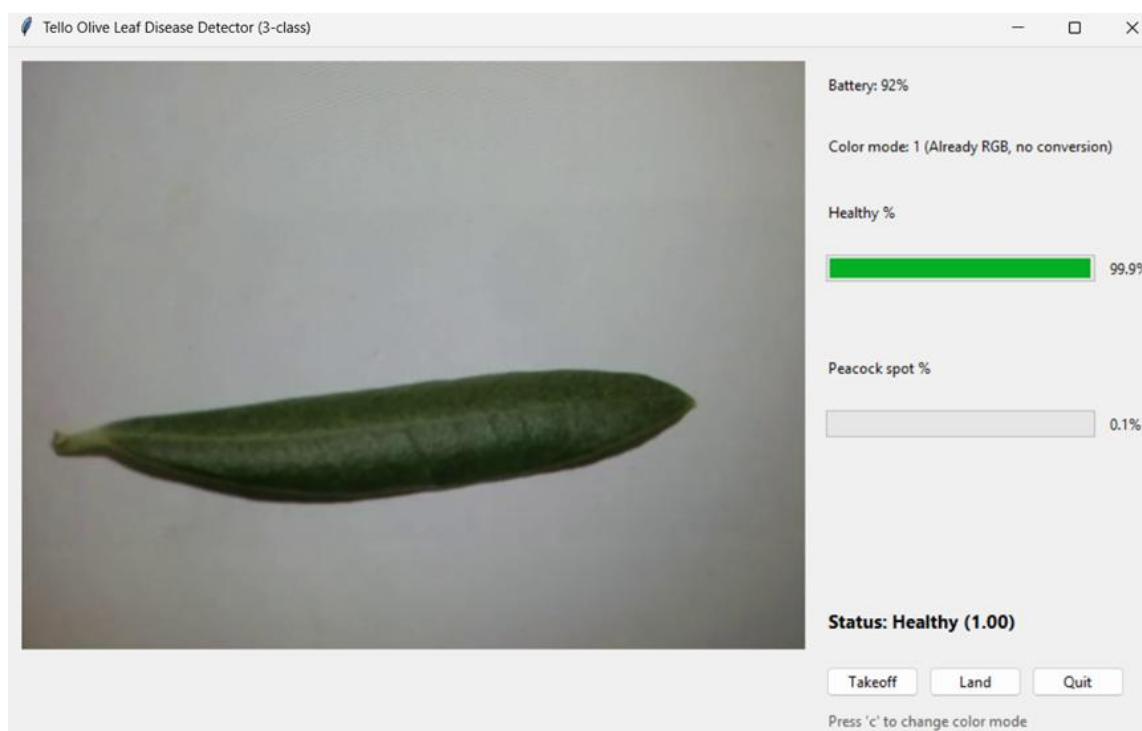
Εικόνα Α.6 – Φύλλο ελιάς με προχωρημένη προσβολή από peacock spot

Στο συγκεκριμένο παράδειγμα καταγράφεται προχωρημένο στάδιο προσβολής, με έντονες σκουρόχρωμες κηλίδες και εκτεταμένο κιτρίνισμα του φύλλου. Η εικόνα αυτή είναι ιδιαίτερα χρήσιμη, καθώς αναδεικνύει τα πιο σαφή μορφολογικά χαρακτηριστικά της ασθένειας.

Οι παραπάνω εικόνες δείχνουν ότι η οπτική διαφοροποίηση μεταξύ υγιών και προσβεβλημένων φύλλων δεν είναι πάντοτε απόλυτα σαφής, ιδιαίτερα στα αρχικά στάδια της ασθένειας. Το γεγονός αυτό εξηγεί εν μέρει τη δυσκολία της ταξινόμησης και υπογραμμίζει τη σημασία χρήσης κατάλληλων μοντέλων μηχανικής μάθησης με ικανότητα γενίκευσης σε διαφορετικά επίπεδα προσβολής.

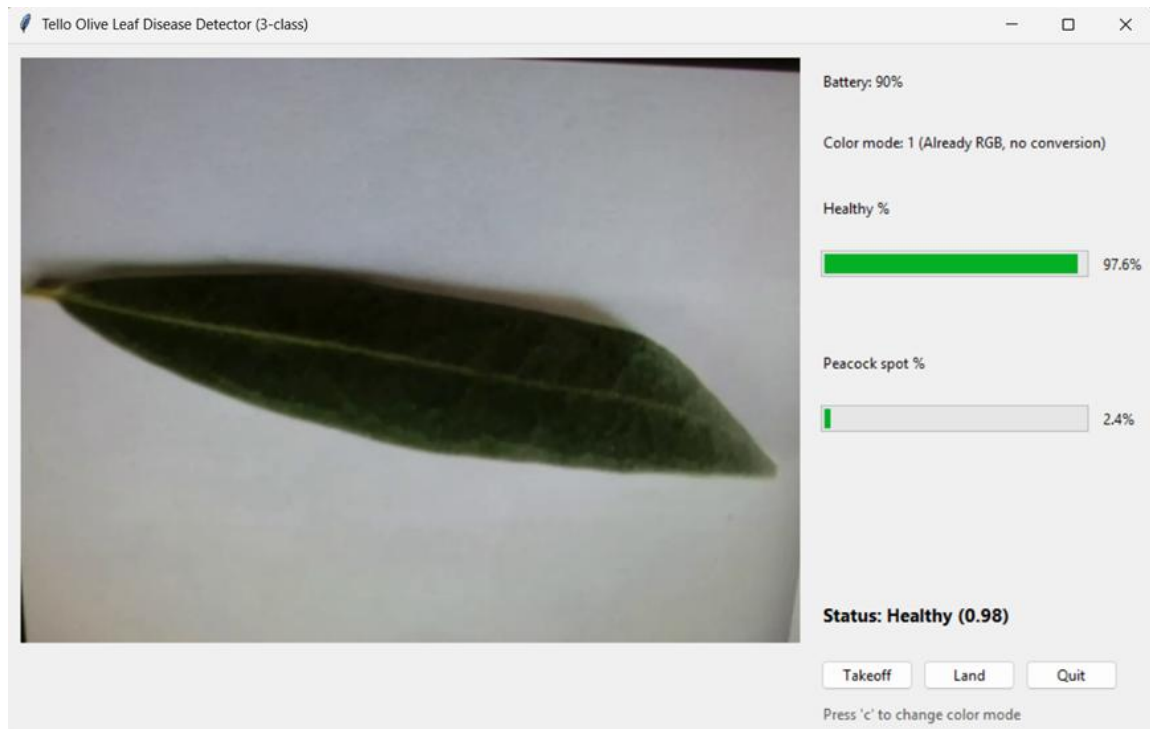
Παράρτημα Β – Ενδεικτικά αποτελέσματα ταξινόμησης φύλλων ελιάς σε εσωτερικό χώρο

Στο Παράρτημα Β παρουσιάζονται ενδεικτικά αποτελέσματα από αρχικές δοκιμές του μοντέλου Transfer Learning σε εσωτερικό χώρο, με χρήση μεμονωμένων φύλλων ελιάς τοποθετημένων σε ουδέτερο φόντο. Οι δοκιμές αυτές πραγματοποιήθηκαν πριν από την εφαρμογή του συστήματος σε πραγματικές συνθήκες πεδίου και είχαν ως στόχο τον αρχικό έλεγχο της λειτουργικότητας και της σταθερότητας του μοντέλου σε ένα περισσότερο ελεγχόμενο περιβάλλον λήψης. Η χρήση απλού φόντου και στατικών δειγμάτων επέτρεψε την καθαρότερη παρατήρηση της συμπεριφοράς του συστήματος τόσο σε υγιή φύλλα όσο και σε φύλλα με εμφανή συμπτώματα της ασθένειας peacock spot. Τα παρακάτω στιγμιότυπα λειτουργούν ως συμπληρωματική οπτική τεκμηρίωση της απόδοσης του μοντέλου και υποστηρίζουν την ποιοτική ερμηνεία των αποτελεσμάτων της εργασίας.



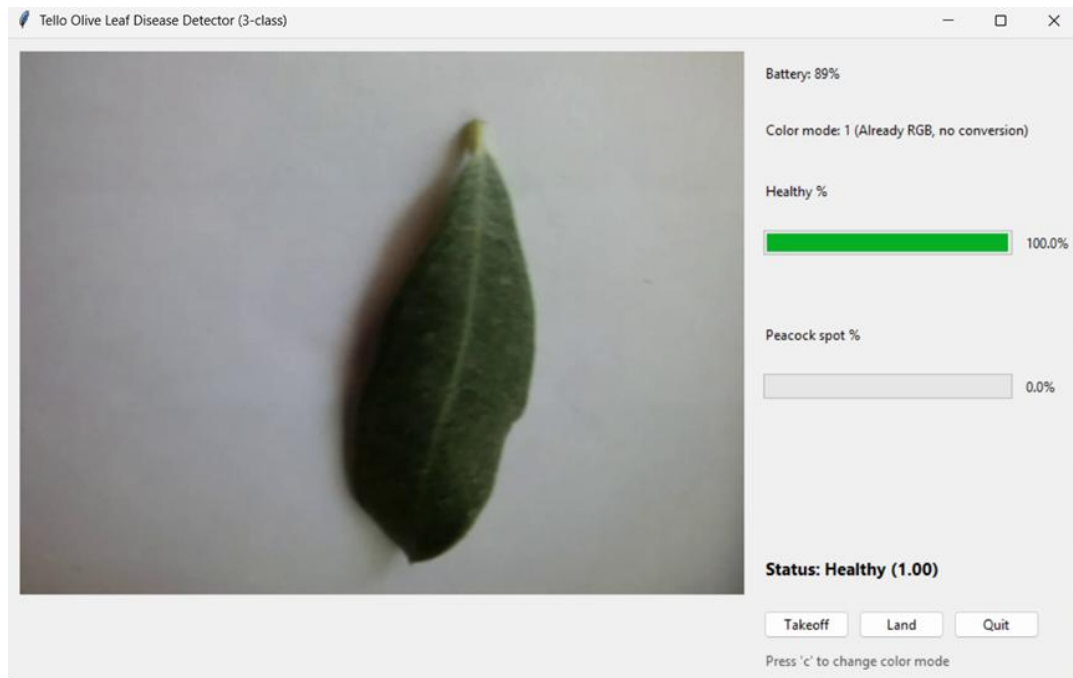
Εικόνα Β.1 – Ορθή αναγνώριση υγιούς φύλλου σε εσωτερικό χώρο

Στο συγκεκριμένο παράδειγμα παρουσιάζεται το αποτέλεσμα ταξινόμησης ενός υγιούς φύλλου ελιάς σε εσωτερικό περιβάλλον δοκιμής. Το μοντέλο κατατάσσει το δείγμα στην κατηγορία Healthy με πιθανότητα 99,9%, ενώ η πιθανότητα για την κατηγορία peacock spot παραμένει μόλις στο 0,1%. Η πρόβλεψη αυτή δείχνει ότι, σε συνθήκες απλού φόντου και περιορισμένης οπτικής πολυπλοκότητας, το σύστημα μπορεί να αναγνωρίζει με πολύ υψηλή βεβαιότητα τα υγιή δείγματα.



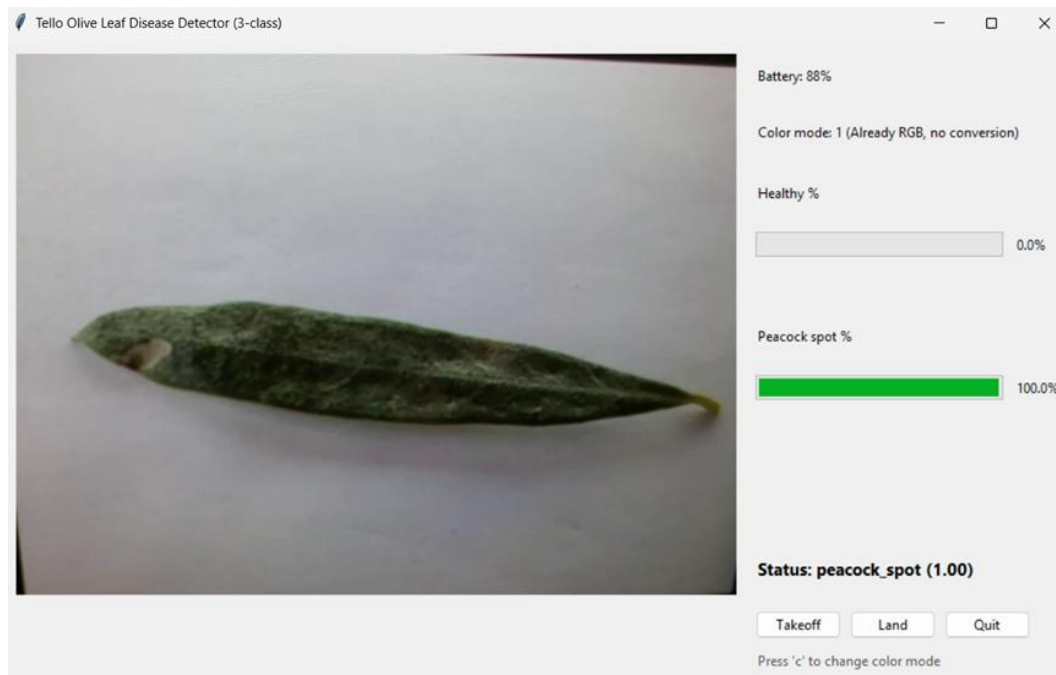
Εικόνα Β.2 – Δεύτερο παράδειγμα ορθής αναγνώρισης υγιούς φύλλου σε εσωτερικό χώρο

Στο συγκεκριμένο στιγμιότυπο παρουσιάζεται ένα ακόμη υγιές φύλλο ελιάς, το οποίο ταξινομείται από το μοντέλο στην κατηγορία Healthy με πιθανότητα 97,6%, ενώ η πιθανότητα για την κατηγορία peacock spot περιορίζεται στο 2,4%. Παρότι η βεβαιότητα είναι ελαφρώς χαμηλότερη σε σχέση με το προηγούμενο παράδειγμα, η τελική πρόβλεψη παραμένει σαφής και σωστή. Το αποτέλεσμα αυτό δείχνει ότι το μοντέλο διατηρεί σταθερή συμπεριφορά και σε διαφορετικό υγιές δείγμα, επιβεβαιώνοντας την ικανότητά του να αναγνωρίζει σωστά φύλλα χωρίς ορατά συμπτώματα ασθένειας.



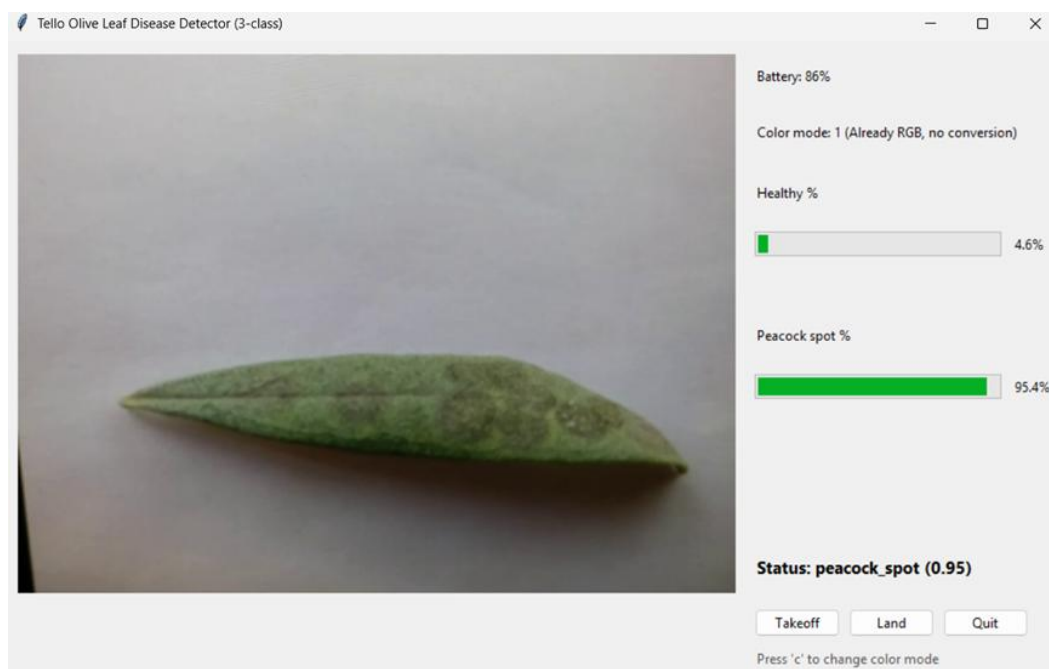
Εικόνα Β.3 – Ορθή αναγνώριση υγιούς φύλλου σε εσωτερικό χώρο

Στο παρόν στιγμιότυπο το μοντέλο Transfer Learning ταξινομεί σωστά το φύλλο ως υγιές, αποδίδοντας πιθανότητα 100,0% στην κατηγορία Healthy και 0,0% στην κατηγορία peacock spot. Το αποτέλεσμα αυτό υποδηλώνει πολύ υψηλό βαθμό βεβαιότητας της πρόβλεψης και επιβεβαιώνει ότι, σε ελεγχόμενες συνθήκες εσωτερικού χώρου, το μοντέλο είναι σε θέση να αναγνωρίζει με ακρίβεια φύλλα χωρίς εμφανή συμπτώματα ασθένειας.



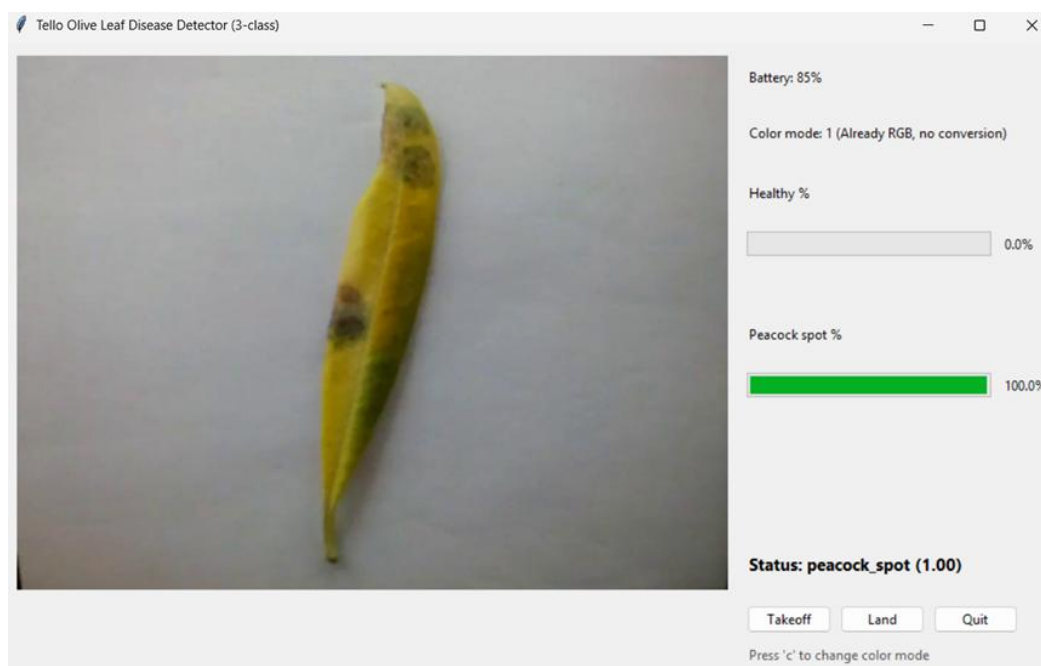
Εικόνα Β.4 – Ορθή αναγνώριση προσβεβλημένου φύλλου με μέγιστη βεβαιότητα

Στο παρόν στιγμιότυπο παρουσιάζεται φύλλο ελιάς με εμφανή συμπτώματα προσβολής, το οποίο το μοντέλο Transfer Learning ταξινομεί στην κατηγορία peacock spot με πιθανότητα 100,0%, ενώ η πιθανότητα για την κατηγορία Healthy είναι 0,0%. Η απόλυτη αυτή βεβαιότητα της πρόβλεψης δείχνει ότι το σύστημα μπορεί να αναγνωρίζει με πολύ υψηλή αξιοπιστία δείγματα στα οποία τα συμπτώματα της ασθένειας είναι οπτικά σαφή και ευδιάκριτα.



Εικόνα Β.5 – Αναγνώριση προσβεβλημένου φύλλου με υψηλή πιθανότητα

Στην εικόνα αυτή το μοντέλο κατατάσσει το φύλλο στην κατηγορία peacock spot με πιθανότητα 95,4%, ενώ αποδίδει 4,6% στην κατηγορία Healthy. Παρότι η βεβαιότητα είναι ελαφρώς χαμηλότερη σε σύγκριση με άλλα παραδείγματα, η τελική πρόβλεψη παραμένει σαφώς σωστή. Το αποτέλεσμα αυτό δείχνει ότι το μοντέλο διατηρεί υψηλή απόδοση ακόμη και σε περιπτώσεις όπου τα συμπτώματα εμφανίζονται με πιο ήπια ή ανομοιόμορφη οπτική έκφραση.



Εικόνα Β.6 – Ορθή αναγνώριση έντονα προσβεβλημένου φύλλου σε εσωτερικό χώρο

Στο συγκεκριμένο παράδειγμα παρουσιάζεται φύλλο με έντονη χλωρωτική αλλοίωση και εμφανείς κηλιδώσεις, το οποίο το μοντέλο ταξινομεί ως peacock spot με πιθανότητα 100,0%. Η πρόβλεψη αυτή είναι πλήρως συμβατή με τη μορφολογική εικόνα του δείγματος και ενισχύει την εκτίμηση ότι το μοντέλο μπορεί να αναγνωρίζει με ιδιαίτερα υψηλή βεβαιότητα προχωρημένες ή έντονα ορατές μορφές της ασθένειας.

Παράρτημα Γ – Ενδεικτικός κώδικας υλοποίησης του μοντέλου SVM + HOG

Στο παρόν παράρτημα παρατίθεται ενδεικτικός κώδικας της υλοποίησης της προσέγγισης SVM + HOG που χρησιμοποιήθηκε στην παρούσα εργασία. Η παράθεση του κώδικα αποσκοπεί στην τεχνική τεκμηρίωση της μεθοδολογίας που ακολουθήθηκε, καθώς και στην ενίσχυση της αναπαραγωγιμότητας της πειραματικής διαδικασίας. Ειδικότερα, παρουσιάζονται αφενός ο κώδικας εκπαίδευσης και αξιολόγησης του μοντέλου πάνω στο οργανωμένο σύνολο δεδομένων και αφετέρου ο κώδικας real-time εφαρμογής του εκπαιδευμένου μοντέλου με χρήση του drone DJI Tello. Η

συγκεκριμένη προσέγγιση βασίζεται στην εξαγωγή χαρακτηριστικών Histogram of Oriented Gradients (HOG) από τις εικόνες και στην ταξινόμησή τους μέσω Support Vector Machine (SVM).

```
import os
import glob
import cv2
import numpy as np

from sklearn.model_selection import train_test_split
from sklearn.pipeline import Pipeline
from sklearn.preprocessing import StandardScaler
from sklearn.svm import SVC
from sklearn.metrics import classification_report, confusion_matrix, accuracy_score
import joblib

# ===== ΠΥΘΜΙΣΕΙΣ =====
DATASET_DIR = "dataset"
CLASSES = ["Healthy", "peacock_spot", "aculus_olearius"]

IMG_SIZE = (128, 128) # resize πριν το HOG
TEST_SIZE = 0.2
RANDOM_STATE = 42

SAVE_MODEL = True
MODEL_OUT = "svm_hog_model.joblib"

def list_images(folder):
    exts = ("*.jpg", "*.jpeg", "*.png", "*.bmp", "*.webp")
    files = []
    for e in exts:
        files.extend(glob.glob(os.path.join(folder, e)))
    return files

def load_dataset(dataset_dir, classes):
    images = []
    labels = []

    for label_id, cls in enumerate(classes):
        cls_dir = os.path.join(dataset_dir, cls)
        if not os.path.isdir(cls_dir):
            raise FileNotFoundError(f'Λείπει ο φάκελος: {cls_dir}')

        files = list_images(cls_dir)
        if len(files) == 0:
            raise FileNotFoundError(f'Δεν βρέθηκαν εικόνες στον φάκελο: {cls_dir}')

        for fp in files:
            img = cv2.imread(fp)
            if img is None:
                continue
            images.append(img)
            labels.append(label_id)

    return images, np.array(labels, dtype=np.int64)

def make_hog(win_size):
```

```

w, h = win_size
return cv2.HOGDescriptor(
    _winSize=(w, h),
    _blockSize=(32, 32),
    _blockStride=(16, 16),
    _cellSize=(16, 16),
    _nbins=9
)

def hog_features(images, img_size=(128, 128)):
    hog = make_hog(img_size)
    feats = []

    for img in images:
        gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
        gray = cv2.resize(gray, img_size)
        f = hog.compute(gray)
        feats.append(f.flatten())

    return np.array(feats, dtype=np.float32)

def main():
    print("Loading dataset...")
    imgs, y = load_dataset(DATASET_DIR, CLASSES)
    print(f"Loaded {len(imgs)} images.")

    print("Extracting HOG features...")
    X = hog_features(imgs, IMG_SIZE)
    print("X shape:", X.shape)

    X_train, X_test, y_train, y_test = train_test_split(
        X, y,
        test_size=TEST_SIZE,
        random_state=RANDOM_STATE,
        stratify=y
    )

    # Pipeline: scaling + SVM
    clf = Pipeline([
        ("scaler", StandardScaler()),
        ("svm", SVC(kernel="rbf", C=10.0, gamma="scale", probability=True))
    ])

    print("Training SVM...")
    clf.fit(X_train, y_train)

    print("Evaluating...")
    y_pred = clf.predict(X_test)

    acc = accuracy_score(y_test, y_pred)
    print("\nAccuracy:", round(acc, 4))

    print("\nConfusion Matrix (rows=true, cols=pred):")
    print(confusion_matrix(y_test, y_pred))

    print("\nClassification Report:")
    print(classification_report(y_test, y_pred, target_names=CLASSES))

```

```

if SAVE_MODEL:
    joblib.dump(clf, MODEL_OUT)
    print("\nSaved:", MODEL_OUT)

if __name__ == "__main__":
    main()

```

Κώδικας Γ.1 – Εκπαίδευση και αξιολόγηση του μοντέλου SVM + HOG

Ο παραπάνω κώδικας υλοποιεί τη διαδικασία εκπαίδευσης και αξιολόγησης του μοντέλου SVM + HOG. Αρχικά πραγματοποιείται φόρτωση των εικόνων από τους αντίστοιχους φακέλους του dataset, οι οποίοι αντιστοιχούν στις κατηγορίες Healthy, peacock_spot και aculus_olearius. Στη συνέχεια εφαρμόζεται προεπεξεργασία των εικόνων με μετατροπή σε κλίμακα του γκρι και αλλαγή μεγέθους στα 128×128 pixels, ώστε να εξασφαλίζεται ομοιομορφία στην είσοδο του αλγορίθμου.

Ακολούθως, από κάθε εικόνα εξάγονται χαρακτηριστικά HOG με συγκεκριμένες παραμέτρους παραθύρου, block, stride, cell size και αριθμού bins, έτσι ώστε η αρχική εικόνα να μετατρέπεται σε διάνυσμα χαρακτηριστικών κατάλληλο για ταξινόμηση. Μετά την εξαγωγή των χαρακτηριστικών, τα δεδομένα διαχωρίζονται σε σύνολο εκπαίδευσης και σύνολο ελέγχου με αναλογία 80% και 20% αντίστοιχα, με χρήση stratified διαχωρισμού ώστε να διατηρείται η κατανομή των κλάσεων.

Για την ταξινόμηση χρησιμοποιείται pipeline που περιλαμβάνει κανονικοποίηση των χαρακτηριστικών με StandardScaler και ταξινομητή SVM με πυρήνα RBF, τιμή C ίση με 10.0 και gamma=scale. Τέλος, ο κώδικας υπολογίζει βασικές μετρικές αξιολόγησης, όπως accuracy, confusion matrix και classification report, ενώ προβλέπεται και αποθήκευση του τελικού εκπαιδευμένου μοντέλου σε αρχείο joblib για μελλοντική χρήση. Ο συγκεκριμένος κώδικας εκφράζει την κλασική προσέγγιση μηχανικής μάθησης της εργασίας, στην οποία η ποιότητα της ταξινόμησης εξαρτάται άμεσα από την ποιότητα των χειροποίητων χαρακτηριστικών που εξάγονται από την εικόνα.

```

import tkinter as tk
from tkinter import ttk
import cv2
from PIL import Image, ImageTk
import joblib
from collections import deque

from djitellopy import Tello

# ===== ΠΥΘΜΙΣΕΙΣ =====
MODEL_PATH = "svm_hog_model.joblib"
CLASSES = ["Healthy", "peacock_spot"]

INFER_EVERY_N_FRAMES = 2

# ROI: κάνε inference στο κέντρο για να κόψεις φόντο/χαρτί/άκρες
USE_CENTER_ROI = True
ROI_SCALE = 0.60

# Σταθεροποίηση απόφασης: πλειοψηφία τελευταίων N προβλέψεων
VOTE_WINDOW = 10

```

```

# Αν η max πιθανότητα είναι μικρή, δείξε "UNCERTAIN"
UNCERTAIN_THRESH = 0.60

# smoothing για bars
SMOOTH_ALPHA = 0.25

# HOG ίδιο με training
IMG_SIZE = (128, 128)

def make_hog(win_size):
    w, h = win_size
    return cv2.HOGDescriptor(
        _winSize=(w, h),
        _blockSize=(32, 32),
        _blockStride=(16, 16),
        _cellSize=(16, 16),
        _nbins=9
    )

class TelloDiseaseGUI:
    def __init__(self, root):
        self.root = root
        self.root.title("Tello Olive Leaf Detector (SVM + HOG, 2-class)")

        # Load SVM model
        self.clf = joblib.load(MODEL_PATH)

        # HOG
        self.hog = make_hog(IMG_SIZE)

        # Tello
        self.tello = Tello()
        self.tello.connect()
        self.battery = self.tello.get_battery()
        self.tello.streamon()
        self.frame_read = self.tello.get_frame_read()

        # UI
        top = tk.Frame(root, padding=10)
        top.pack(fill="both", expand=True)

        self.video_label = tk.Label(top)
        self.video_label.grid(row=0, column=0, rowspan=10, padx=(0, 15))

        self.battery_label = tk.Label(top, text=f"Battery: {self.battery}%")
        self.battery_label.grid(row=0, column=1, sticky="w")

        self.bars = {}
        self._make_bar(top, row=2, title="Healthy %", key="Healthy")
        self._make_bar(top, row=5, title="Peacock spot %", key="peacock_spot")

        self.status_label = tk.Label(top, text="Status: ---", font=("Segoe UI", 11, "bold"))
        self.status_label.grid(row=8, column=1, columnspan=2, sticky="w", pady=(12, 0))

        btns = tk.Frame(top)
        btns.grid(row=9, column=1, columnspan=2, sticky="w", pady=(12, 0))
        tk.Button(btns, text="Takeoff", command=self.takeoff).grid(row=0, column=0, padx=(0, 8))

```

```

    ttk.Button(btns, text="Land", command=self.land).grid(row=0, column=1, padx=(0, 8))
    ttk.Button(btns, text="Quit", command=self.on_close).grid(row=0, column=2)

    # state
    self.smooth = {k: None for k in CLASSES}
    self.pred_history = deque(maxlen=VOTE_WINDOW)
    self.frame_count = 0

    self.update_loop()
    self.root.protocol("WM_DELETE_WINDOW", self.on_close)

def _make_bar(self, parent, row, title, key):
    ttk.Label(parent, text=title).grid(row=row, column=1, sticky="w", pady=(10, 0))
    var = tk.DoubleVar(value=0.0)
    bar = tk.Progressbar(parent, maximum=100, variable=var, length=220)
    bar.grid(row=row + 1, column=1, sticky="w")
    txt = ttk.Label(parent, text="0.0%")
    txt.grid(row=row + 1, column=2, sticky="w", padx=(10, 0))
    self.bars[key] = (var, txt)

def takeoff(self):
    try:
        self.tello.takeoff()
    except Exception as e:
        self.status_label.config(text=f"Status: Takeoff error: {e}")

def land(self):
    try:
        self.tello.land()
    except Exception as e:
        self.status_label.config(text=f"Status: Land error: {e}")

def on_close(self):
    try:
        self.tello.streamoff()
    except:
        pass
    try:
        self.tello.end()
    except:
        pass
    self.root.destroy()

def center_roi(self, frame):
    if not USE_CENTER_ROI:
        return frame
    h, w = frame.shape[:2]
    rh, rw = int(h * ROI_SCALE), int(w * ROI_SCALE)
    y1 = max(0, (h - rh) // 2)
    x1 = max(0, (w - rw) // 2)
    return frame[y1:y1 + rh, x1:x1 + rw]

def hog_features_one(self, frame_bgr):
    gray = cv2.cvtColor(frame_bgr, cv2.COLOR_BGR2GRAY)
    gray = cv2.resize(gray, IMG_SIZE)
    f = self.hog.compute(gray).flatten().astype("float32")
    return f.reshape(1, -1)

def update_loop(self):
    frame = self.frame_read.frame

```

```

if frame is None:
    self.root.after(30, self.update_loop)
    return

self.frame_count += 1

if self.frame_count % INFER_EVERY_N_FRAMES == 0:
    roi = self.center_roi(frame)

    X = self.hog_features_one(roi)
    probs = self.clf.predict_proba(X)[0]

    # probabilities με βάση τη σειρά του CLASSES
    vals = {CLASSES[i]: float(probs[i]) for i in range(len(CLASSES))}

    # smoothing
    for name, p in vals.items():
        if self.smooth[name] is None:
            self.smooth[name] = p
        else:
            self.smooth[name] = (1 - SMOOTH_ALPHA) * self.smooth[name] + SMOOTH_ALPHA
* p

    # update bars
    for name in CLASSES:
        pct = 100.0 * self.smooth[name]
        var, txt = self.bars[name]
        var.set(pct)
        txt.config(text=f"{pct:.1f}%")

    # best class + uncertainty
    best = max(vals, key=vals.get)
    best_p = vals[best]

    self.pred_history.append(best)
    vote_best = max(set(self.pred_history), key=self.pred_history.count)

    if best_p < UNCERTAIN_THRESH:
        msg = f"Status: UNKNOWN | UNCERTAIN (max={best_p:.2f})"
    else:
        overall = "HEALTHY" if vote_best == "Healthy" else "DISEASED"
        msg = f"Status: {overall} | {vote_best} ({best_p:.2f})"

    self.status_label.config(text=msg)

    # battery update
    if self.frame_count % (INFER_EVERY_N_FRAMES * 30) == 0:
        try:
            self.battery_label.config(text=f"Battery: {self.tello.get_battery()}%")
        except:
            pass

    # Preview
    show = cv2.resize(frame, (640, 480))
    show_rgb = show

    if USE_CENTER_ROI:
        h, w = show.shape[:2]
        rh, rw = int(h * ROI_SCALE), int(w * ROI_SCALE)
        y1 = (h - rh) // 2

```

```

x1 = (w - rw) // 2
cv2.rectangle(show_rgb, (x1, y1), (x1 + rw, y1 + rh), (255, 0, 0), 2)

im = Image.fromarray(show_rgb)
imgtk = ImageTk.PhotoImage(image=im)
self.video_label.imgtk = imgtk
self.video_label.config(image=imgtk)

self.root.after(15, self.update_loop)

if __name__ == "__main__":
    root = tk.Tk()
    app = TelloDiseaseGUI(root)
    root.mainloop()

```

Κώδικας Γ.2 – Real-time εφαρμογή του μοντέλου SVM + HOG με χρήση DJI Tello

Ο παραπάνω κώδικας παρουσιάζει την υλοποίηση της real-time εφαρμογής του μοντέλου SVM + HOG σε περιβάλλον Python, με σύνδεση στο drone DJI Tello. Η εφαρμογή αυτή αξιοποιεί το ήδη αποθηκευμένο μοντέλο SVM και λαμβάνει συνεχόμενα frames από τη ροή βίντεο του drone, προκειμένου να πραγματοποιεί online ταξινόμηση των δεδομένων εικόνας.

Πιο συγκεκριμένα, ο κώδικας δημιουργεί ένα γραφικό περιβάλλον χρήστη με χρήση της βιβλιοθήκης tkinter, στο οποίο εμφανίζεται η εικόνα από την κάμερα του drone, το επίπεδο μπαταρίας, οι μπάρες πιθανότητας για τις κατηγορίες Healthy και peacock_spot, καθώς και η τελική πρόβλεψη του συστήματος. Για τον περιορισμό της επίδρασης του φόντου, εφαρμόζεται επιλογή κεντρικής περιοχής ενδιαφέροντος (center ROI), ενώ τα χαρακτηριστικά HOG εξάγονται μόνο από τη συγκεκριμένη περιοχή του frame.

Επιπλέον, ενσωματώνονται μηχανισμοί σταθεροποίησης της πρόβλεψης, όπως smoothing των πιθανοτήτων, πλειοψηφική απόφαση σε παράθυρο διαδοχικών προβλέψεων και όριο αβεβαιότητας, κάτω από το οποίο η έξοδος επισημαίνεται ως uncertain ή unknown. Η υλοποίηση αυτή είναι ιδιαίτερα σημαντική, διότι μεταφέρει το θεωρητικό μοντέλο ταξινόμησης από το περιβάλλον του οργανωμένου dataset σε συνθήκες πραγματικού χρόνου, όπου το σύστημα καλείται να λειτουργήσει σε δυναμικό και μη ελεγχόμενο περιβάλλον.

Παράρτημα Δ – Ενδεικτικός κώδικας υλοποίησης του μοντέλου Transfer Learning / Teachable Machine

Στο παρόν παράρτημα παρουσιάζεται ενδεικτικός κώδικας της real-time εφαρμογής του μοντέλου Transfer Learning που αναπτύχθηκε μέσω της πλατφόρμας Teachable Machine. Η συγκεκριμένη υλοποίηση αξιοποιεί το εξαγόμενο μοντέλο σε μορφή TensorFlow Lite και επιτρέπει την εφαρμογή του σε πραγματικό χρόνο πάνω στη ζωντανή ροή εικόνας του drone DJI Tello. Η παράθεση του κώδικα αποσκοπεί στην τεχνική αποτύπωση του τρόπου με τον οποίο το θεωρητικό μοντέλο βαθιάς μάθησης ενσωματώθηκε σε λειτουργικό σύστημα πρόβλεψης.

```

import tkinter as tk
from tkinter import ttk
import numpy as np

```

```

import cv2
from PIL import Image, ImageTk

from djitellopy import Tello
from tensorflow.lite.python.interpreter import Interpreter

MODEL_PATH = "model_unquant.tflite"
LABELS_PATH = "labels.txt"

INFER_EVERY_N_FRAMES = 2

# Προαιρετικό smoothing για να μην “τρεμοπαίζει”
SMOOTH_ALPHA = 0.25 # 0.1 πιο smooth, 0.3 πιο γρήγορο

class TelloDiseaseGUI:
    def __init__(self, root):
        self.root = root
        self.root.title("Tello Olive Leaf Disease Detector (3-class)")

        # ----- Load labels -----
        with open(LABELS_PATH, "r", encoding="utf-8") as f:
            self.labels = [line.strip().split(" ", 1)[-1] for line in f if line.strip()]
            self.label_to_index = {name: i for i, name in enumerate(self.labels)}

        # Έλεγχος ότι υπάρχουν οι νέες κλάσεις (θα σε σώσει από “λάθη ονομάτων”)
        required = ["Healthy", "peacock_spot"]
        missing = [x for x in required if x not in self.label_to_index]
        if missing:
            raise ValueError(
                f"Λείπουν labels: {missing}. "
                f"Βρέθηκαν: {self.labels}. "
                f"Φτιάξε τα class names στο Teachable Machine να ταιριάζουν ΑΚΡΙΒΩΣ."
            )

        # ----- Load TFLite model -----
        self.interpreter = Interpreter(model_path=MODEL_PATH)
        self.interpreter.allocate_tensors()
        self.input_details = self.interpreter.get_input_details()
        self.output_details = self.interpreter.get_output_details()

        self.in_h = int(self.input_details[0]["shape"][1])
        self.in_w = int(self.input_details[0]["shape"][2])

        # ----- Connect to Tello -----
        self.tello = Tello()
        self.tello.connect()
        self.battery = self.tello.get_battery()

        self.tello.streamon()
        self.frame_read = self.tello.get_frame_read()

        # ----- Color mode handling -----
        self.color_mode = 1
        self.root.bind("c", self.cycle_color_mode)

        # smoothing state
        self.smooth = {name: None for name in required}

        # ----- UI -----

```

```

top = ttk.Frame(root, padding=10)
top.pack(fill="both", expand=True)

self.video_label = ttk.Label(top)
self.video_label.grid(row=0, column=0, rowspan=12, padx=(0, 15))

self.battery_label = ttk.Label(top, text=f"Battery: {self.battery}%")
self.battery_label.grid(row=0, column=1, sticky="w")

self.mode_label = ttk.Label(top, text=self._mode_text())
self.mode_label.grid(row=1, column=1, columnspan=2, sticky="w", pady=(6, 0))

# --- Bars ---
self._make_bar(top, row=2, title="Healthy %", var_name="Healthy")
self._make_bar(top, row=5, title="Peacock spot %", var_name="peacock_spot")

self.status_label = ttk.Label(top, text="Status: ---", font=("Segoe UI", 11, "bold"))
self.status_label.grid(row=11, column=1, columnspan=2, sticky="w", pady=(12, 0))

btns = ttk.Frame(top)
btns.grid(row=12, column=1, columnspan=2, sticky="w", pady=(12, 0))

ttk.Button(btns, text="Takeoff", command=self.takeoff).grid(row=0, column=0, padx=(0, 8))
ttk.Button(btns, text="Land", command=self.land).grid(row=0, column=1, padx=(0, 8))
ttk.Button(btns, text="Quit", command=self.on_close).grid(row=0, column=2)

self.hint_label = ttk.Label(top, text="Press 'c' to change color mode", foreground="#555")
self.hint_label.grid(row=13, column=1, columnspan=2, sticky="w", pady=(10, 0))

self.frame_count = 0
self.update_loop()
self.root.protocol("WM_DELETE_WINDOW", self.on_close)

def _make_bar(self, parent, row, title, var_name):
    ttk.Label(parent, text=title).grid(row=row, column=1, sticky="w", pady=(10, 0))
    var = tk.DoubleVar(value=0.0)
    bar = ttk.Progressbar(parent, maximum=100, variable=var, length=220)
    bar.grid(row=row + 1, column=1, sticky="w")
    txt = ttk.Label(parent, text="0.0%")
    txt.grid(row=row + 1, column=2, sticky="w", padx=(10, 0))

# κράτα references
if not hasattr(self, "bars"):
    self.bars = {}
self.bars[var_name] = (var, bar, txt)

def _mode_text(self):
    if self.color_mode == 0:
        return "Color mode: 0 (BGR -> RGB)"
    if self.color_mode == 1:
        return "Color mode: 1 (Already RGB, no conversion)"
    return "Color mode: 2 (Force channel swap)"

def cycle_color_mode(self, event=None):
    self.color_mode = (self.color_mode + 1) % 3
    self.mode_label.config(text=self._mode_text())

def frame_to_rgb(self, frame):
    if self.color_mode == 0:
        return cv2.cvtColor(frame, cv2.COLOR_BGR2RGB)

```

```

elif self.color_mode == 1:
    return frame
else:
    return frame[:, :, :-1]

def preprocess_for_model(self, frame_bgr):
    img = cv2.resize(frame_bgr, (self.in_w, self.in_h))
    img_rgb = self.frame_to_rgb(img)
    x = img_rgb.astype(np.float32)
    x = (x / 127.5) - 1.0
    return np.expand_dims(x, axis=0)

def infer(self, frame_bgr):
    x = self.preprocess_for_model(frame_bgr)
    self.interpreter.set_tensor(self.input_details[0]["index"], x)
    self.interpreter.invoke()
    return self.interpreter.get_tensor(self.output_details[0]["index"])[0]

def takeoff(self):
    try:
        self.tello.takeoff()
    except Exception as e:
        self.status_label.config(text=f"Status: Takeoff error: {e}")

def land(self):
    try:
        self.tello.land()
    except Exception as e:
        self.status_label.config(text=f"Status: Land error: {e}")

def on_close(self):
    try:
        self.tello.streamoff()
    except:
        pass
    try:
        self.tello.end()
    except:
        pass
    self.root.destroy()

def update_loop(self):
    frame = self.frame_read.frame
    if frame is None:
        self.root.after(30, self.update_loop)
        return

    self.frame_count += 1

    if self.frame_count % INFER_EVERY_N_FRAMES == 0:
        probs = self.infer(frame)

        # διάβασε τις πιθανότητες
        vals = {}
        for name in ["Healthy", "peacock spot"]:
            idx = self.label_to_index[name]
            vals[name] = float(probs[idx])

        # smoothing
        for name, p in vals.items():

```

```

        if self.smooth[name] is None:
            self.smooth[name] = p
        else:
            self.smooth[name] = (1 - SMOOTH_ALPHA) * self.smooth[name] + SMOOTH_ALPHA
    * p

    # update bars
    for name in ["Healthy", "peacock_spot"]:
        pct = 100.0 * self.smooth[name]
        var, _ , txt = self.bars[name]
        var.set(pct)
        txt.config(text=f"{pct:.1f}%")

    # status = max class
    best_name = max(self.smooth, key=self.smooth.get)
    best_p = self.smooth[best_name]
    self.status_label.config(text=f"Status: {best_name} ({best_p:.2f}")

    # battery update
    if self.frame_count % (INFER_EVERY_N_FRAMES * 30) == 0:
        try:
            self.battery_label.config(text=f"Battery: {self.tello.get_battery()}%")
        except:
            pass

    # Preview
    show = cv2.resize(frame, (640, 480))
    show_rgb = self.frame_to_rgb(show)

    im = Image.fromarray(show_rgb)
    imgtk = ImageTk.PhotoImage(image=im)
    self.video_label.imgtk = imgtk
    self.video_label.config(image=imgtk)

    self.root.after(15, self.update_loop)

if __name__ == "__main__":
    root = tk.Tk()
    app = TelloDiseaseGUI(root)
    root.mainloop()

```

Κώδικας Δ.1 – Real-time εφαρμογή του μοντέλου Transfer Learning με χρήση TensorFlow Lite και DJI Tello

Ο παραπάνω κώδικας υλοποιεί τη real-time εφαρμογή του μοντέλου Transfer Learning, αξιοποιώντας το αρχείο model_unquant.tflite και το αντίστοιχο αρχείο labels.txt που προέρχονται από την εξαγωγή του μοντέλου της πλατφόρμας Teachable Machine. Με την εκκίνηση της εφαρμογής φορτώνονται οι ετικέτες των κατηγοριών και δεσμεύεται ο TFLite interpreter, ο οποίος είναι υπεύθυνος για την εκτέλεση της πρόβλεψης σε κάθε frame.

Στη συνέχεια πραγματοποιείται σύνδεση με το drone DJI Tello, ενεργοποίηση της ζωντανής ροής βίντεο και δημιουργία γραφικού περιβάλλοντος χρήστη, στο οποίο εμφανίζονται η εικόνα της κάμερας, η μπαταρία, η λειτουργία χρωματικού μετασχηματισμού, οι μπάρες πιθανότητας για τις κατηγορίες Healthy και peacock_spot, καθώς και η τελική έξοδος του μοντέλου. Κατά το στάδιο της προεπεξεργασίας, κάθε frame αλλάζει μέγεθος σύμφωνα με τις απαιτήσεις του

μοντέλου, μετατρέπεται κατάλληλα ως προς τα χρωματικά κανάλια και κανονικοποιείται στο εύρος τιμών που απαιτεί το TensorFlow Lite μοντέλο.

Η εφαρμογή εκτελεί πρόβλεψη ανά καθορισμένο αριθμό frames, με στόχο τη μείωση του υπολογιστικού φορτίου, ενώ παράλληλα εφαρμόζεται smoothing στις πιθανότητες ώστε να περιορίζονται οι απότομες μεταβολές και το «τρέμουλο» στην έξοδο του συστήματος. Η τελική πρόβλεψη βασίζεται στη μεγαλύτερη εξομαλυμένη πιθανότητα μεταξύ των δύο κύριων κατηγοριών. Η υλοποίηση αυτή αναδεικνύει τον πρακτικό τρόπο με τον οποίο ένα προεκπαιδευμένο μοντέλο βαθιάς μάθησης μπορεί να μεταφερθεί από ένα περιβάλλον no-code, όπως το Teachable Machine, σε λειτουργικό σύστημα πραγματικού χρόνου με χρήση Python και drone.

Συμπέρασμα για τα παραρτήματα κώδικα

Οι παραπάνω κώδικες αποτυπώνουν σε τεχνικό επίπεδο τις δύο βασικές αλγοριθμικές προσεγγίσεις που συγκρίθηκαν στην παρούσα εργασία. Από τη μία πλευρά, η υλοποίηση SVM + HOG εκφράζει μια πιο παραδοσιακή λογική μηχανικής μάθησης, όπου απαιτείται ρητή εξαγωγή χαρακτηριστικών από τις εικόνες πριν από την ταξινόμηση. Από την άλλη πλευρά, η υλοποίηση του μοντέλου Transfer Learning δείχνει τον τρόπο με τον οποίο ένα σύγχρονο μοντέλο βαθιάς μάθησης μπορεί να ενσωματωθεί σε real-time εφαρμογή με χρήση TensorFlow Lite.

Η σύγκριση των δύο κωδίκων δεν αναδεικνύει μόνο διαφορετικές τεχνικές υλοποίησης, αλλά και διαφορετική φιλοσοφία επεξεργασίας της πληροφορίας εικόνας. Η παράθεση των κωδίκων στα παραρτήματα ενισχύει τη διαφάνεια της μεθοδολογίας, διευκολύνει την κατανόηση της πειραματικής διαδικασίας και συμβάλλει στην αναπαραγωγικότητα της έρευνας.