



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

Παραδοτέο Π.1.5.2: Μοντέλα αναγνώρισης ασθενειών με έμφαση στη χρήση εικόνων από drone

Πληροφορίες για το έγγραφο

Αριθμός παραδοτέου: **Π1.5.2**

Ενότητα εργασίας: **ΕΕ1**

Επικεφαλής δικαιούχος: **ΕΛΓΟ-ΔΗΜΗΤΡΑ**

Συγγραφείς: **Χρυσή Κόπακα, Κωνσταντίνος Φερεντίνος, Δημήτριος Τσιτσιγιάννης**

Έκδοση: **1.0**

Είδος Παραδοτέου: **Έκθεση**

Ημερομηνία παράδοσης: **31 Οκτωβρίου 2025**

Στοιχεία Πράξης

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

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

Κωδικός πράξης: ΤΑΕΔΡ-0535675

Ακρωνύμιο έργου: InnoPP

Ημερομηνία έναρξης: 15 Μαΐου 2023

Διάρκεια: 28 Μήνες

Συντονιστής Φορέας: Γεωπονικό Πανεπιστήμιο Αθηνών

Συντονιστής/ Επιστημονικός Υπεύθυνος: Ιωάννης Βόντας

Πίνακας Περιεχομένων

1	ΕΙΣΑΓΩΓΗ ΚΑΙ ΣΤΟΧΟΙ	5
2	ΠΕΡΙΓΡΑΦΗ ΤΩΝ ΕΡΓΑΣΙΩΝ	7
2.1	ΓΕΝΙΚΑ ΣΤΟΙΧΕΙΑ	7
2.1.1	Γεωργία Ακριβείας και τηλεπισκόπηση	7
2.1.2	Πλεονεκτήματα και χρήσεις ΣμηΕΑ στη Γεωργία Ακριβείας	8
2.1.3	Μέθοδοι αναγνώρισης ασθενειών σε φυτά	9
2.1.3.1	Μοριακές μέθοδοι	9
2.1.3.2	Φασματοσκοπικές μέθοδοι	9
2.1.3.3	Μέθοδοι εντοπισμού/scouting	9
2.1.3.4	Μέθοδοι τεχνητής νοημοσύνης / βαθιάς μάθησης	10
2.1.4	ΣμηΕΑ για αναγνώριση ασθενειών σε φυτά	10
2.1.4.1	Εξοπλισμός ΣμηΕΑ με ανάλογο αισθητήρα	11
2.2	ΑΥΤΟΜΑΤΟΠΟΙΗΜΕΝΗ ΔΙΑΓΝΩΣΗ ΑΣΘΕΝΕΙΩΝ ΜΕ ΣΜΗΕΑ ΜΕ ΟΠΤΙΚΗ ΚΑΜΕΡΑ	12
2.3	ΣΗΜΑΝΤΙΚΟΤΕΡΕΣ ΠΡΟΚΛΗΣΕΙΣ ΓΙΑ ΤΗΝ ΑΥΤΟΜΑΤΟΠΟΙΗΜΕΝΗ ΔΙΑΓΝΩΣΗ ΑΣΘΕΝΕΙΩΝ ΜΕΣΩ ΣΜΗΕΑ	15
2.3.1	Τρόπος αξιολόγησης και δοκιμής των μοντέλων αναγνώρισης	15
2.3.2	Συνθήκες λήψης των εικόνων	15
2.3.3	Το παρασκήνιο εικόνας (image background)	17
2.3.4	Κατάλληλη ταξινόμηση ασθενειών	18
2.3.5	Κατάλληλες παράμετροι για την αναγνώριση ασθενειών μέσω ΣμηΕΑ	19
2.3.6	Χαμηλή διαθεσιμότητα δεδομένων	19
2.3.7	Περιορισμός διαθεσιμότητας αισθητήρων για διάγνωση ασθενειών	20
2.3.8	Προβληματισμοί σχετικά με πτήσεις ΣμηΕΑ (κανονισμοί, ηθικότητα, κόστος, ασφάλεια)	20
2.4	ΧΡΗΣΗ ΣΜΗΕΑ ΓΙΑ ΑΝΑΓΝΩΡΙΣΗ ΑΣΘΕΝΕΙΩΝ: ΕΙΔΙΚΕΣ ΠΕΡΙΠΤΩΣΕΙΣ & ΠΡΟΤΑΣΕΙΣ	21
2.4.1	Περίπτωση πρώτη: Ροδακινιά	21
2.4.1.1	Αναγνώριση ασθενειών στις ροδακινιές	22
2.4.1.2	Στάδια πρώιμης αναγνώρισης φαιάς σήψης	23
2.4.1.3	Προτεινόμενα μέτρα για την αυτόματη διάγνωση φαιάς σήψης μέσω ΣμηΕΑ	23
2.4.2	Περίπτωση δεύτερη: Εσπεριδοειδή	24
2.4.2.1	Αναγνώριση ασθενειών στα εσπεριδοειδή	24
2.4.2.2	Στάδια πρώιμης αναγνώρισης κορυφοξήρας	25
2.4.2.3	Προτεινόμενα μέτρα για την αυτόματη διάγνωση κορυφοξήρας μέσω ΣμηΕΑ	26
2.4.3	Περίπτωση τρίτη: Αμπέλι	27
2.4.3.1	Αναγνώριση ασθενειών στο αμπέλι	27
2.4.3.2	Αναγνώριση ασθενειών σε αμπέλι: Περίπτωση ωιδίου	27
2.4.3.3	Αναγνώριση ασθενειών σε αμπέλι: Περίπτωση βοτρυτή	29
2.4.3.4	Αναγνώριση ασθενειών σε αμπέλι: Περίπτωση ίσκας	31
2.5	ΕΠΙΘΥΜΗΤΑ ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΚΑΙ ΙΔΙΟΤΗΤΕΣ ΔΕΔΟΜΕΝΩΝ ΑΝΑΠΤΥΞΗΣ ΜΟΝΤΕΛΩΝ	33
2.5.1	Συνθήκες λήψης της εικόνας	33
2.5.2	Το παρασκήνιο εικόνας (image background)	33
2.5.3	Κατάλληλη ταξινόμηση ασθενειών	34
2.5.4	Παράμετροι ΣμηΕΑ για κατάλληλη λήψη εικόνων	34
2.5.5	Διαθεσιμότητα συνόλων δεδομένων	34
2.5.6	Διαθεσιμότητα αισθητήρων	35
2.5.7	Άλλα προβλήματα	35
3	ΣΥΝΟΨΗ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ	36
4	ΠΑΡΑΡΤΗΜΑ Ι	38

Περίληψη του Έργου

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

Σύνοψη της ΕΕ1

Σκοπός της ΕΕ1 του έργου είναι η ανάπτυξη διαγνωστικών εργαλείων και μεθόδων για την ανίχνευση, ταυτοποίηση και παρακολούθηση των εχθρών, των παθογόνων και των χαρακτηριστικών τους. Το αντικείμενο της υποενότητας εργασίας 1.5 («Τεχνολογίες μακροσκοπικής παρακολούθησης και τεχνητή νοημοσύνη για αναγνώριση ασθενειών») στην οποία ανήκει το παρόν παραδοτέο, αφορά τον εντοπισμό και την ανάλυση των προβλημάτων που εμποδίζουν την πρακτική εφαρμογή συστημάτων τεχνητής νοημοσύνης για την αναγνώριση των ασθενειών, καθώς και ο καθορισμός των χαρακτηριστικών και των ιδιοτήτων για την ανάπτυξη και εκπαίδευση μοντέλων, προκειμένου να γίνει εφικτή η μετάβασή τους από την εργαστηριακή εφαρμογή στην πρακτική εφαρμογή τους στον αγρό.

Συνοπτική παρουσίαση του παραδοτέου Π1.4.1

Το παραδοτέο επικεντρώνεται στην ανάλυση και αξιολόγηση της υπάρχουσας βιβλιογραφίας σχετικά με την αυτοματοποιημένη διάγνωση ασθενειών φυτών μέσω Συστημάτων μη Επανδρωμένων Αεροσκαφών (ΣμηΕΑ) και RGB εικόνων. Επιχειρεί να καταγράψει τα κύρια προβλήματα που αντιμετωπίζουν οι ερευνητές κατά τη συλλογή, επεξεργασία και αξιοποίηση δεδομένων πεδίου. Η ανάλυση καλύπτει κρίσιμες παραμέτρους όπως οι συνθήκες λήψης, το παρασκήνιο των εικόνων, η σωστή ταξινόμηση ασθενειών, οι παράμετροι πτήσης των ΣμηΕΑ και η διαθεσιμότητα συνόλων δεδομένων και αισθητήρων. Ειδική αναφορά γίνεται στο γεγονός ότι μεγάλο μέρος της υπάρχουσας έρευνας βασίζεται σε εικόνες εργαστηριακών συνθηκών και όχι πραγματικών συνθηκών στον αγρό, πρόβλημα που μόλις τα τελευταία χρόνια αρχίζει να αντιμετωπίζεται ουσιαστικά. Έμφαση δίνεται σε συγκεκριμένες δενδρώδεις καλλιέργειες (ροδακινιά, εσπεριδοειδή και αμπέλι) και συγκεκριμένα στην αυτοματοποιημένη αναγνώριση ασθενειών όπως η φαιά σήψη ροδακίνων, η κορυφοξήρα εσπεριδοειδών, καθώς και οι ασθένειες ίσκα, வீδιο και τεφρά σήψη (βοτρύτης) αμπέλου. Μέσα από τη βιβλιογραφική ανασκόπηση, προτείνονται λύσεις για βελτίωση της ποιότητας και της ποικιλίας των δεδομένων, όπως η ενίσχυση του μεγέθους συνόλων δεδομένων, η προσεκτική προετοιμασία πτήσεων και η εφαρμογή

τεχνικών επεξεργασίας εικόνας. Το παραδοτέο παρέχει επίσης καθοδήγηση για τις επιθυμητές ιδιότητες των συνόλων δεδομένων που θα διευκολύνουν την ανάπτυξη αξιόπιστων μοντέλων στο μέλλον. Τέλος, αναδεικνύει την ανάγκη συνδυασμού τεχνολογιών, βέλτιστων πρακτικών και προσεκτικού σχεδιασμού πτήσεων ώστε τα συστήματα αναγνώρισης ασθενειών μέσω ΣμηΕΑ να γίνουν λειτουργικά και εφαρμοστέα σε πραγματικές συνθήκες παραγωγής, προσφέροντας πρακτικά οφέλη για τους παραγωγούς και τη φυτοπροστασία.

1 ΕΙΣΑΓΩΓΗ ΚΑΙ ΣΤΟΧΟΙ

Η χρήση μη επανδρωμένων αεροσκαφών (ΣμηΕΑ) σε εφαρμογές γεωργίας ακριβείας έχει λάβει ιδιαίτερη δυναμική τα τελευταία χρόνια, κυρίως λόγω της δυνατότητάς τους να συλλέγουν μεγάλο όγκου οπτικά δεδομένα υψηλής χωρικής ανάλυσης σε πραγματικές συνθήκες αγρού. Παράλληλα, η ταχεία εξέλιξη των μεθόδων υπολογιστικής όρασης και βαθιάς μάθησης (Deep Learning) έχει αναδείξει τις εικόνες RGB από ΣμηΕΑ ως έναν από τους πιο προσιτούς και ευέλικτους αισθητήρες για την αυτοματοποιημένη αναγνώριση φυτοπαθολογικών συμπτωμάτων. Ωστόσο, παρά την εντυπωσιακή έρευνα που έχει παραχθεί, το μεγαλύτερο μέρος της διεθνούς βιβλιογραφίας εξακολουθεί να βασίζεται σε εικόνες εργαστηριακών συνθηκών, προσεκτικά επιλεγμένες και συχνά μη αντιπροσωπευτικές των πραγματικών συνθηκών πεδίου, στοιχείο που περιορίζει σημαντικά τη γενίκευση και τη λειτουργικότητα των σχετικών μοντέλων στην πράξη. Μόλις τα τελευταία χρόνια παρατηρείται μια ουσιαστική μετατόπιση προς την αξιοποίηση δεδομένων σε πραγματικά περιβάλλοντα αγρού, όπου οι εντελώς μη ελεγχόμενες συνθήκες φωτισμού, παρασκηνίου, γωνίας λήψης, ποικιλομορφίας καλλιεργειών και περιβαλλοντικών παραγόντων εκθέτουν τα πραγματικά όρια των μεθόδων αναγνώρισης ασθενειών.

Το παρόν παραδοτέο δε στοχεύει στην ανάπτυξη ενός ακόμη μοντέλου αναγνώρισης ασθενειών, αλλά εστιάζει στις θεμελιώδεις τεχνικές και μεθοδολογικές προκλήσεις που ανακύπτουν όταν επιχειρείται η μετάβαση από εργαστηριακά δεδομένα σε δεδομένα ΣμηΕΑ πραγματικού πεδίου. Μέσα από εστιασμένη βιβλιογραφική ανασκόπηση και κριτική ανάλυση, εξετάζονται ζητήματα που αφορούν τις συνθήκες λήψης από ΣμηΕΑ, τα προβλήματα φωτισμού και παρασκηνίου, τη σωστή ταξινόμηση ασθενειών, τις κατάλληλες παραμέτρους πτήσης, τη διαθεσιμότητα και ποιότητα των συνόλων δεδομένων, καθώς και τις τεχνικές ελλείψεις ή περιορισμούς των RGB αισθητήρων. Παράλληλα προτείνονται και αναλύονται συγκεκριμένες λύσεις και αξιολογείται η αποτελεσματικότητά τους σε πραγματικά σενάρια εφαρμογής.

Ο σκοπός του παρόντος εγγράφου είναι

1. Να συνοψίσει και να αξιολογήσει την υπάρχουσα διεθνή έρευνα σχετικά με μοντέλα αναγνώρισης ασθενειών με χρήση εικόνων από ΣμηΕΑ.
2. Να εντοπίσει τα βασικά τεχνικά εμπόδια που περιορίζουν την αποτελεσματική εφαρμογή των μοντέλων αυτών σε μη ελεγχόμενα περιβάλλοντα αγρού.
3. Να προτείνει συγκεκριμένες κατευθύνσεις και απαιτήσεις για τα σύνολα δεδομένων, τις συνθήκες λήψης και τις παραμέτρους πτήσης που είναι απαραίτητες για τη δημιουργία αξιόπιστων και επιχειρησιακά εφαρμόσιμων συστημάτων διάγνωσης.
4. Να διαμορφώσει ένα σύνολο επιθυμητών χαρακτηριστικών και ιδιοτήτων για δεδομένα ΣμηΕΑ-RGB, ώστε να αποτελέσουν προδιαγραφές σε μελλοντικές προσπάθειες ανάπτυξης μοντέλων αναγνώρισης ασθενειών.

Έτσι, το παραδοτέο συμβάλλει όχι με την παραγωγή ακόμη ενός μοντέλου, αλλά με την καθοριστική τεκμηρίωση των βημάτων, προϋποθέσεων και απαιτήσεων που θα

επιτρέψουν στα μελλοντικά μοντέλα να λειτουργήσουν πραγματικά, αξιόπιστα και μετρήσιμα στον αγρό.

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

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

2. Περιγραφή των Εργασιών: 2.1. Γενικά στοιχεία και σημαντικότερες προκλήσεις για την αυτοματοποιημένη διάγνωση ασθενειών μέσω ΣμηΕΑ σύμφωνα με την τρέχουσα βιβλιογραφία, 2.2. Γενική βιβλιογραφική ανασκόπηση σχετικά με την αυτοματοποιημένη διάγνωση ασθενειών με ΣμηΕΑ με οπτική κάμερα, 2.3. Διερεύνηση των σημαντικότερων προκλήσεων για την αυτοματοποιημένη διάγνωση ασθενειών μέσω ΣμηΕΑ, 2.4. Εξειδικευμένη ανασκόπηση ερευνών σχετικά με τις καλλιέργειες ενδιαφέροντος (εσπεριδοειδή, ροδακινιές, αμπέλια) καθώς και προτεινόμενα μέτρα για την καλύτερη δυνατή πρόγνωση των επιλεγμένων ασθενειών μέσω ΣμηΕΑ (φαιά σήψη ροδακίνων, κορυφοξήρα εσπεριδοειδών, βοτρύτης, wίδιο και ίσκα αμπελιού), 2.5. Διερεύνηση και ανάλυση των επιθυμητών χαρακτηριστικών και ιδιοτήτων των δεδομένων εκπαίδευσης των μοντέλων για την καλύτερη δυνατή διάγνωση ασθενειών μέσω ΣμηΕΑ.

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

4. Παράρτημα: Βιβλιογραφικές αναφορές.

2 ΠΕΡΙΓΡΑΦΗ ΤΩΝ ΕΡΓΑΣΙΩΝ

2.1 Γενικά στοιχεία

2.1.1 Γεωργία Ακριβείας και τηλεπισκόπηση

Η Γεωργία Ακριβείας (Precision Agriculture) γνωρίζει μεγάλη ανάπτυξη τα τελευταία χρόνια λόγω των ποικίλων προνομίων που μπορεί να προσφέρει, τα οποία επικεντρώνονται κυρίως στη μείωση του κόστους εισροών, στην αύξηση των αποδόσεων, και συνεπώς στην αύξηση του κέρδους για τον παραγωγό. Ο τομέας αυτός χρησιμοποιεί στοιχεία των επιστημονικών κλάδων της μηχανικής και της πληροφορικής, τα οποία συνδυάζει και εφαρμόζει στον αγρό με βάση αρχές που χρησιμοποιούνται στη γεωπονική επιστήμη. Μία από τις πιο γνωστές εφαρμογές επικεντρώνεται στη διαχείριση εισροών ανάλογα με τη τοποθεσία (site-specific management), η οποία λαμβάνει την ακριβή ποσότητα γεωργικών εισροών με σκοπό τη βελτιστοποίηση της απόδοσης των καλλιεργειών μέσω νέων τεχνολογιών (Feng et al., 2019). Ταυτόχρονα, έχουν χρησιμοποιηθεί και αρκετές τεχνολογίες όπως τα Ασύρματα Δίκτυα Αισθητήρων (Wireless Sensor Networks - WSNs, Zheng & Yang, 2018), το Διαδίκτυο των πραγμάτων (Internet of Things - IoT, Liu et al., 2019; Fang et al., 2021), η Τεχνητή Νοημοσύνη (Artificial Intelligence - AI, Liakos et al., 2018; Shadrin et al., 2019), ενσωματωμένα λογισμικά (Jinbo et al., 2019; Hsu et al., 2020), μεγάλα δεδομένα (big data, Tantalaki et al., 2019) και τεχνολογία τύπου blockchain (Khan et al., 2020).

Η τηλεπισκόπηση αποτελεί έναν κλάδο ο οποίος έχει παίξει σπουδαίο ρόλο στη γεωργία ακριβείας, καθώς προσφέρει τη δυνατότητα απομακρυσμένης παρακολούθησης καλλιεργειών μέσω εικόνων που έχουν ληφθεί από δορυφορικά, επανδρωμένα ή και από μη-επανδρωμένα εναέρια οχήματα. Ωστόσο οι δορυφορικές εικόνες δεν αποτελούν την καλύτερη δυνατή επιλογή τηλεπισκόπησης καλλιεργειών, λόγω της χαμηλής χωρικής αλλά και χρονικής ανάλυσης. Συχνά απαιτείται να περάσουν μεγάλα χρονικά διαστήματα μεταξύ της απόκτησης και της λήψης των εικόνων και επιπλέον, περιβαλλοντικές συνθήκες, όπως είναι τα σύννεφα ή η εμφάνιση χιονιού, εμποδίζουν την αξιόπιστη χρήση τους (Εικόνα 1.5.2-1). Τα επανδρωμένα αεροσκάφη συνεπάγονται υψηλά κόστη χρήσης και δεν εξυπηρετούν στη λήψη εικόνων για μικρής έκτασης χωράφια (Tsouros et al., 2019). Η χρήση για παρακολούθηση καλλιεργειών μέσω δορυφορικών εικόνων αλλά και επανδρωμένων εναέριων οχημάτων λόγω των προαναφερθέντων περιορισμών, καθιστούν τα Συστήματα μη Επανδρωμένων Αεροσκαφών (κοινώς ΣμηΕΑ ή στην αγγλική ονομασία ως drones ή UAVs) ως μία ελκυστική εναλλακτική προσέγγιση. Τα ΣμηΕΑ αποτελούν την πιο ευέλικτη λύση λόγω της καλύτερης χωρικής, χρονικής εικόνας αλλά και της μικρότερης εξάρτησής τους από καιρικές συνθήκες.



Εικόνα 1.5.2-1: Λήψη δορυφορικής εικόνας για την περιοχή των Χανίων Κρήτης, με χαρακτηριστικό πρόβλημα στη λήψη λόγω νέφωσης. (Πηγή: Copernicus BROWSER).

2.1.2 Πλεονεκτήματα και χρήσεις ΣμηΕΑ στη Γεωργία Ακριβείας

Τα ΣμηΕΑ παρέχουν ένα πλήθος πλεονεκτημάτων κατά τη χρήση τους σε γεωργικές εφαρμογές, όπως το ότι δίνουν τη δυνατότητα λήψης εικόνων υψηλής ανάλυσης σε ημέρες με υψηλή νέφωση (Manfreda et al., 2018), και το ότι η χρήση τους είναι χαμηλού κόστους και είναι πιο εύκολη στη συντήρηση συγκριτικά με τα επανδρωμένα αεροσκάφη (Tsouros et al., 2019). Επιπλέον έχουν χρησιμοποιηθεί για αρκετούς και διαφορετικούς σκοπούς στη γεωργία, όπως στην παρακολούθηση (Bendig et al., 2012; Oliveira et al., 2018; Hashimoto et al., 2019) και χαρτογράφηση καλλιεργειών (Murugan et al., 2017), στη διαχείριση αρδευτικών δικτύων (Albornoz & Giraldo, 2017; Quebrajo et al., 2018), σε ψεκασμό (Huang et al., 2009; Xue et al., 2016; Yanliang et al., 2017; Garre & Harish, 2018), στη διαχείριση ζιζανίων (Rasmussen et al., 2013; Sandler, 2018), στον εντοπισμό εντόμων (Stumph et al., 2019; Roosjen et al., 2020), και στον εντοπισμό πρόσληψης θρεπτικών στοιχείων σε φυτά (Noguera et al., 2021; Costa et al., 2022).

Μία από τις πιο ευρέως διαδεδομένες μεθόδους χρήσης τους είναι η χαρτογράφηση ζιζανίων. Τα ζιζάνια αποτελούν τον κύριο βιοτικό παράγοντα περιορισμού αποδόσεων σε καλλιέργειες, απειλώντας διαρκώς την παγκόσμια επισιτιστική ασφάλεια με ποσοστό περίπου στο 34% (Oerke, 2006). Οι σύγχρονες στρατηγικές διαχείρισης ζιζανίων κρίνονται πλέον ως μη-βιώσιμες (unsustainable), καθώς η χρήση εντατικών οργωμάτων σε συνδυασμό με την αλόγιστη χρήση ζιζανιοκτόνων οδηγούν σε περιβαλλοντικά ρίσκα και συνεπώς, στην εμφάνιση ανθεκτικότητας (Esposito et al., 2023). Η χαρτογράφηση ζιζανίων συντελεί στη δημιουργία χαρτών με ζιζάνια, οι οποίοι οδηγούν στη χρήση κατάλληλης δόσης ζιζανιοκτόνου ανάλογα την περιοχή και τον πληθυσμό των εντοπισμένων ζιζανίων (Site-Specific Weed Management, SSWM).

Άλλη μέθοδος που είναι αρκετά εφαρμοσμένη, είναι η χρήση των ΣμηΕΑ για την παρακολούθηση της ανάπτυξης της βλάστησης και την εκτίμηση απόδοσης της καλλιέργειας. Η έλλειψη μέσων για τη συστηματική παρακολούθηση της προόδου μιας

καλλιέργειας θεωρείται σήμερα ως ένα από τα κυριότερα εμπόδια στην αύξηση της γεωργικής παραγωγικότητας και ποιότητας. Η τακτική συλλογή πληροφοριών και η απεικόνιση των καλλιεργειών με τη χρήση ΣμηΕΑ, μπορούν να συμβάλλουν σε αυξημένες δυνατότητες παρακολούθησης της ανάπτυξης των καλλιεργειών και παράλληλα, στην καταγραφή της μεταβλητότητας υπό διαφόρων παραμέτρων του αγρού (Tsouros et al., 2019).

2.1.3 Μέθοδοι αναγνώρισης ασθενειών σε φυτά

2.1.3.1 Μοριακές μέθοδοι

Η διάγνωση ασθενειών σε φυτά πραγματοποιείται με τη χρήση κατάλληλων μεθόδων, όπως είναι οι μοριακές. Μία από αυτές είναι η ενζυμοσύνδετη ανοσοπροσροφητική δοκιμή-ELISA (enzyme-linked immunosorbent assay), η οποία είναι βασισμένη στις πρωτεΐνες που παράγονται από το παθογόνο. Άλλη μέθοδος μοριακής αναγνώρισης είναι η αλυσιδωτή αντίδραση πολυμεράσης-PCR (polymerase chain reaction), η οποία είναι βασισμένη σε συγκεκριμένες αλληλουχίες του δεσοξυριβοζονουκλεϊνικού οξέος (DNA) των παθογόνων (Mowat & Dawson, 1987; Prithiviraj et al., 2004; Das, 2004). Αξίζει να σημειωθεί ότι οι μοριακές μέθοδοι χρειάζονται λεπτομερή δειγματοληψία και επεξεργασία (Sankaran et al., 2010).

2.1.3.2 Φασματοσκοπικές μέθοδοι

Η φασματοσκοπία έχει χρησιμοποιηθεί αρκετά για την αναγνώριση μοναδικών ασθενειών και τον εντοπισμό προβλημάτων στα φυτά λόγω διαφορετικών παραγόντων (π.χ., στρες ή κάποιου φυτοπαθογόνου) (Sankaran et al., 2010). Η ακριβής εφαρμογή της γίνεται με διάφορες φασματοσκοπικές τεχνικές, όπως μέσω απεικονίσεων φθορισμού (fluorescence imaging) (Bravo et al., 2004; Moshou et al., 2005; Chaerle et al., 2007), μέσω πολυφασματικών / υπερφασματικών απεικονίσεων (multispectral / hyperspectral imaging) (Moshou et al., 2004; Qin et al., 2009; Shafri & Hamdan, 2009), μέσω φασματοσκοπίας σε κοντινό υπέρυθρο (near-infrared spectroscopy) (Xu et al., 2007), αλλά και στο υπέρυθρο (infrared spectroscopy) (Spinelli et al., 2004; Purcell et al., 2009). Άλλη τεχνική που έχει χρησιμοποιηθεί είναι μέσω φασματοσκοπίας φθορισμού (fluorescence spectroscopy) (Atta et al., 2020; Belasque et al., 2008, και οι Saleem et al., 2020 μέσω φασματοσκοπίας φθορισμού προκαλούμενη από laser), η ορατή/πολυζωνική φασματοσκοπία (visible/multiband spectroscopy) (Delalieux et al., 2007; Mishra et al., 2009), και η φασματοσκοπία πυρηνικού μαγνητικού συντονισμού (nuclear magnetic resonance "NMR" spectroscopy) (Choi et al., 2004).

2.1.3.3 Μέθοδοι εντοπισμού/scouting

Άλλη γνωστή μέθοδος αναγνώρισης για τον εντοπισμό φυτικού στρες είναι το scouting ή αλλιώς η μέθοδος ανίχνευσης/αναζήτησης. Η μέθοδος αυτή απαιτεί αρκετή επεξεργασία, κατάλληλες γνώσεις και εξοπλισμό, καθιστώντας την μία αρκετά χρονοβόρα διαδικασία. Μπορεί να γίνει είτε παραδοσιακά (με άτομο/-α να επιβλέπει/-ουν το χωράφι σε συγκεκριμένες χρονικές περιόδους), είτε με τη λήψη ψηφιακών εικόνων. Οι παραδοσιακές μέθοδοι αναγνώρισης είναι υποκειμενικές και συχνά

καταλήγουν σε λάθη (Barbedo, 2016). Οι ψηφιακές εικόνες που περιέχουν συμπτώματα ασθένειας, απεικονίζονται στο ορατό και στο κοντινό του ορατού τμήματος - υπέρυθρο φάσμα, με τις μπάντες να είναι απομονωμένες ή απεικονιζόμενες σε έγχρωμες, πολυφασματικές και υπερφασματικές εικόνες (Arnal Barbedo, 2013). Ένα εργαλείο για την αναγνώριση ασθενειών οφείλει να είναι γρήγορο, κατάλληλο ως προς μία ασθένεια και ευαίσθητο όσον αφορά τα πρώιμα στάδια συμπτωμάτων (López et al., 2003). Η χρήση εξοπλισμένων ΣμηΕΑ με επιλεγμένες κάμερες και αντίστοιχους αισθητήρες για συνεχές scouting καλλιεργειών (UAV-Assisted scouting) σε συνδυασμό με την κατάλληλη λήψη και επεξεργασία των εικόνων, αποτελεί θέμα αυξανόμενου ενδιαφέροντος για την αναγνώριση ασθενειών φυτών σε πρόωρα στάδια.

2.1.3.4 Μέθοδοι τεχνητής νοημοσύνης / βαθιάς μάθησης

Οι τεχνικές βαθιάς μάθησης (deep learning) και συγκεκριμένα, τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks, CNNs) έχουν χρησιμοποιηθεί ευρέως στην αναγνώριση εικόνων και ειδικότερα, στην αυτοματοποιημένη διάγνωση ασθενειών σε φυτά. Τα νευρωνικά δίκτυα μπορούν να εξάγουν σύνθετα χαρακτηριστικά από εικόνες, όπως μορφολογικές και χρωματικές ανωμαλίες. Αρχιτεκτονικές τύπου CNN και πιο πρόσφατα Vision Transformers, επιτρέπουν την ταξινόμηση και εντοπισμό συμπτωμάτων σε φυτά με υψηλή ακρίβεια, ακόμα και σε περιβάλλοντα με ποικίλες συνθήκες φωτισμού και φόντου. Η εφαρμογή αυτών των μεθόδων σε εικόνες από ΣμηΕΑ ενισχύει την κάλυψη μεγάλων εκτάσεων και επιτρέπει την ανάπτυξη συστημάτων έγκαιρης προειδοποίησης για την φυτοπροστασία. Όμως, η εφαρμογή των CNNs προϋποθέτει την ύπαρξη ενός μεγάλου όγκου δεδομένων τα οποία θα χρησιμοποιηθούν για την εκπαίδευση των μοντέλων που στη συνέχεια θα πραγματοποιούν την αυτοματοποιημένη διάγνωση των ασθενειών. Τα δεδομένα αυτά θα πρέπει να περιέχουν όλες τις περιπτώσεις ασθενειών που καλείται το μοντέλο να αναγνωρίζει, να καλύπτουν ένα όσο το δυνατό εκτενέστερο εύρος διαφορετικών περιβαλλοντικών συνθηκών (π.χ., διαφορετικές συνθήκες φωτισμού, σημείων λήψης της εικόνας, τύπων εδάφους, κ.α.) και να έχουν ταυτοποιηθεί ως προς την εκάστοτε ασθένεια από ειδικούς γεωπόνους. Αφού δημιουργηθεί η βάση δεδομένων, θα πρέπει να χωριστεί σε υποσύνολα εκπαίδευσης (train), επαλήθευσης (validation), και δοκιμής (test), όπου τα δύο πρώτα χρησιμοποιούνται κατά τη διαδικασία εκπαίδευσης του μοντέλου αυτοματοποιημένης αναγνώρισης, και το τρίτο κατά τη διαδικασία αξιολόγησης της απόδοσης του τελικού μοντέλου. Η συνηθέστερη κατανομή των εικόνων στα υποσύνολα εκπαίδευσης (και επαλήθευσης) / δοκιμής είναι σε αναλογία 80/20 (Fine, 2006).

2.1.4 ΣμηΕΑ για αναγνώριση ασθενειών σε φυτά

Η παρακολούθηση της κατάστασης που επικρατεί σε μία καλλιέργεια μπορεί να επιτευχθεί μέσω της παρακολούθησης της υγείας των φυτών μέσω ΣμηΕΑ. Σκοπός είναι ο έγκαιρος εντοπισμός ασθενειών, καθώς αυτές μπορούν να προκαλέσουν σημαντικές οικονομικές απώλειες εξαιτίας της μείωσης της ποιότητας αλλά και των αποδόσεων ((Ning et al., 2017; Abbas et al., 2023). Η κατάλληλη ανίχνευση και η εύρεση αξιόπιστων διαγνωστικών μεθόδων για την ταυτοποίηση των αιτιών μόλυνσης είναι

απαραίτητες για την εξοικονόμηση χρόνου και χρημάτων (Singh et al., 2018). Οι παραδοσιακές μέθοδοι αναγνώρισης ασθενειών που πραγματοποιούνται μέσω οπτικής παρατήρησης, είναι υποκειμενικές, χρονοβόρες, ενδεχομένως δαπανηρές αλλά και συχνά όχι τόσο πρακτικές, καθώς ακόμα και εξειδικευμένοι γεωπόνοι δεν μπορούν πάντα να αναγνωρίσουν μία ασθένεια σε πρώιμο στάδιο (Qin et al., 2021).

Οι καλλιέργειες οφείλουν να παρακολουθούνται σε πραγματικό χρόνο για τον εντοπισμό αλλά και για την αποφυγή εξάπλωσης ασθενειών. Όπως συμβαίνει στη χαρτογράφηση των ζιζανίων, αντίστοιχα είναι δυνατή και η χαρτογράφηση ασθενειών (site-specific disease control, SSDC) όπου τα ΣμηΕΑ μπορούν να χρησιμοποιηθούν σε 2 στάδια: i) στο πρώτο στάδιο, κατά το οποίο εμφανίζονται τα πρώιμα στάδια ύπαρξης μιας ασθένειας με (Sandhu et al., 2020) ή χωρίς οπτικές διαφορές (Dunning., 2017; Al-Saddik et al., 2019) και ii) στο δεύτερο στάδιο, κατά το οποίο μπορούν να χρησιμοποιηθούν για την παρακολούθηση της προόδου εφαρμογής φυτοπροστατευτικών μέσων για την αντιμετώπιση εντοπισμένων ασθενειών ή ακόμα και μελλοντικά να μπορέσουν να χρησιμοποιηθούν για τοπικό ψεκασμό (Tsouros et al., 2019).

Όσον αφορά την αναγνώριση ασθενειών, ο Veroustraete (2015) υποστήριξε ότι η εφαρμογή των ΣμηΕΑ για τον εντοπισμό ασθενειών αποτελεί μία πρόκληση, καθώς μεσολαβούν αρκετά εμπόδια από τη θεωρία στην πράξη. Όντως, το ενδιαφέρον για την αυτοματοποιημένη αναγνώριση ασθενειών σε φυτά έχει αυξηθεί τις τελευταίες δύο δεκαετίες, αλλά οι προτεινόμενες τεχνικές είναι αρκετά περιορισμένες και εξαρτώνται από ιδανικές συνθήκες καταγραφής (Barbedo, 2016). Οι ικανότητες αναγνώρισης ασθενειών μέσω ΣμηΕΑ περιλαμβάνουν τον εντοπισμό μικρών αλλαγών στην υγεία των φυτών, όπως είναι η ανώμαλη ανάπτυξη φυτών, ο αποχρωματισμός και η ζημιά των φύλλων, όπου το ανθρώπινο μάτι θα αδυνατούσε να εντοπίσει (Kannan et al., 2025).

2.1.4.1 Εξοπλισμός ΣμηΕΑ με ανάλογο αισθητήρα

Τα ΣμηΕΑ μπορούν να εξοπλιστούν με διαφορετικούς αισθητήρες, ανάλογα με τον σκοπό χρήσης τους. Για παράδειγμα, μπορούν να λάβουν εικόνες μέσω διαφόρων ειδών κάμερας, όπως είναι οι RGB, οι πολυφασματικές, οι υπερφασματικές, οι θερμικές αλλά και με αισθητήρες βάθους (depth sensors). Η επιλογή αισθητήρα εξαρτάται από τον σκοπό της κάθε μελέτης. Το στρες που έχει προκληθεί από ξηρασία μπορεί να εντοπιστεί σε πρώιμα στάδια από θερμικούς αισθητήρες (Ludovisi et al., 2017; Zhou et al., 2020), ενώ πολυφασματικοί και υπερφασματικοί αισθητήρες χρησιμοποιούνται για μακροχρόνιες παρατηρήσεις. Έτσι, μολύνσεις από φυτοπαθογόνους οργανισμούς σε καλλιέργειες μπορούν να διαγνωστούν καλύτερα σε πρώιμα στάδια μέσω υπερφασματικών και θερμικών αισθητήρων, αλλά οι αισθητήρες RGB, οι υπερφασματικοί και οι πολυφασματικοί αισθητήρες μπορούν να χρησιμοποιηθούν για τον εντοπισμό της σοβαρότητας της μόλυνσης (Maes & Steppe, 2019).

2.2 Αυτοματοποιημένη διάγνωση ασθενειών με ΣμηΕΑ με οπτική κάμερα

Όπως προαναφέρθηκε, για να πραγματοποιηθεί η αυτοματοποιημένη αναγνώριση ασθενειών σε φυτά με τη χρήση ΣμηΕΑ, απαιτείται τα ΣμηΕΑ να είναι εξοπλισμένα με κάποιον συγκεκριμένο τύπο κάμερας. Η χρήση των RGB καμερών για τη συγκεκριμένη διεργασία έχει αυξηθεί λόγω αρκετών πλεονεκτημάτων, όπως είναι η χαμηλή τιμή τους, η ευκολία χρήσης τους, το χαμηλό τους βάρος και το ότι εξασφαλίζουν εικόνες υψηλής χωρικής ανάλυσης (Abdulridha et al., 2020).

Αξίζει να σημειωθεί ότι οι κάμερες RGB μπορούν να συλλέξουν μόνο το ορατό ηλεκτρομαγνητικό φάσμα (380nm - 750nm), ενώ δεν είναι όλα τα μήκη κύματος κατάλληλα για την αναγνώριση όλων των ασθενειών στα φυτά (Bock et al., 2020). Μπορούν να χρησιμοποιηθούν για τη συλλογή υψηλής ανάλυσης εικόνων και μπορούν να κάνουν λήψη εικόνων με υψηλή χωρική ανάλυση σε σύγκριση με τα πολυφασματικά συστήματα, παρέχοντας πιο λεπτομερείς χωρικές πληροφορίες για την ανίχνευση και παρακολούθηση ασθενειών των φυτών. Η αρμονική χρήση των καμερών RGB μπορεί να διασφαλίσει την ομοιομορφία στο χρώμα και τον φωτισμό των εικόνων. Έτσι, γίνονται λιγότερα σφάλματα στη διάκριση των υγιών και ασθενών φυτών (Neurane & Baysal-Gurel, 2021).

Υπάρχουν όμως αρκετές προκλήσεις και προβλήματα που δυσκολεύουν την επιτυχή χρήση τους για την αυτοματοποιημένη αναγνώριση ασθενειών σε φυτά. Για παράδειγμα, οι Görlich et al. (2021) χρησιμοποίησαν εικόνες RGB που είχαν ληφθεί από ΣμηΕΑ για τη δημιουργία ενός μοντέλου βαθιάς μάθησης με σκοπό τον αυτοματοποιημένο εντοπισμό της κερκόσπορας (*Cercospora Leaf Spot - CLS*) σε ζαχαρότευτλα. Ενώ η απόδοση του συστήματος ήταν άκρως ικανοποιητική (π.χ., F1-score 88%), παρατηρήθηκαν αρκετές περιπτώσεις στις οποίες έσφαλε, κρίνοντας υγιή φυτά ως ασθενή. Οι συγγραφείς επισήμαναν τους περιορισμούς του συστήματος, υποδुकνεύοντας δυσκολίες στην επισήμανση (annotation) των συμπτωμάτων της ασθένειας στη βάση δεδομένων και της επίδρασης της ανάλυσης των εικόνων στο τελικό αποτέλεσμα. Συγκεκριμένα, πρότειναν αύξηση του μεγέθους του συνόλου δεδομένων, τη βελτίωση ανάλυσης των εικόνων που λήφθηκαν και την εμπλοκή ειδικών φυτοπαθολογίας στη διαδικασία της επισήμανσης (annotation) με σκοπό τη περαιτέρω βελτίωση του συστήματος, ειδικά για την ανίχνευση των πρώιμων συμπτωμάτων και ταυτόχρονα για την ενίσχυση της ακρίβειας του τελικού μοντέλου.

Η μελέτη των Kerkech et al. (2018) ασχολήθηκε με την αυτόματη διάγνωση της ίσκρας σε αμπελώνες. Με ποσοστό επιτυχίας 95,8%, ένα από τα σημαντικότερα προβλήματα που επισήμαναν ήταν η περιορισμένη διαθεσιμότητα δεδομένων με ετικέτες (annotated data) που παρέχονται από ειδικούς.

Οι Pan et al. (2021) διερεύνησαν την αυτοματοποιημένη διάγνωση μέσω ΣμηΕΑ για την κίτρινη σκωρίαση σιταριού με RGB κάμερα. Η αξιοπιστία του μοντέλου πραγματοποιήθηκε μέσω σύγκρισης αρκετών αλγορίθμων, όπως Support Vector Machiner (SVM), Random Forest (RF), back-propagation neural networks (BPNN), Fully

Convolutional Networks (FCN), και το μοντέλο U-Net. Με αφορμή το κύριο πρόβλημα της χειροκίνητης επισήμανσης (annotation) των εικόνων, το οποίο είναι χρονοβόρο και επιρρεπές σε σφάλματα λόγω υποκειμενικών κρίσεων, η ταυτοποίηση των προσβεβλημένων φυτών πραγματοποιήθηκε με τη μέθοδο της επίβλεψης weak-sample. Τα αποτελέσματα του SVM πέτυχαν υψηλή ακρίβεια ταξινόμησης για την εκπαίδευση του μοντέλου βαθιάς μάθησης. Αν και σημειώθηκαν κάποια σφάλματα στη δημιουργία επισημάνσεων, δεν ήταν τόσο σημαντικά, οπότε η μέθοδος αυτή πέτυχε ικανοποιητικά αποτελέσματα αξιοπιστίας και αποδοτικότητας.

Άλλο παράδειγμα αποτελεί η έρευνα των Amarasingham et al. (2022), οι οποίοι χρησιμοποίησαν RGB εικόνες από ΣμηΕΑ για την αναγνώριση της ασθένειας White Leaf Disease (WLD) σε ζαχαρότευτλα. Συγκρίνοντας διαφορετικά μοντέλα βαθιάς μάθησης (YOLOv5, YOLOR, DETR και Faster R-CNN), το πρώτο σημείωσε τα υψηλότερα ποσοστά ακρίβειας αναγνώρισης. Οι συγγραφείς της μελέτης παρατήρησαν ότι υπάρχουν αρκετές προκλήσεις στη χρήση του μοντέλου YOLO για την αναγνώριση ασθενειών στον αγρό, επισημαίνοντας ως κυριότερα προβλήματα την ανάγκη για χρήση υψηλής ανάλυσης RGB εικόνων, την επισήμανση (annotation) των εικόνων ως μία αρκετά χρονοβόρα διαδικασία, αλλά και τις παρεμβολές των φυτών με το παρασκήνιο των εικόνων ή με το έδαφος. Ένας άλλος βασικός περιοριστικός παράγοντας είναι η επένδυση σε ΣμηΕΑ και αισθητήρες. Ωστόσο, το πλεονέκτημα αυτών των μεθόδων είναι ότι παραμένουν πιο οικονομικές σε σύγκριση με την παραδοσιακή μέθοδο αναγνώρισης ασθενειών.

Η βιβλιογραφική ανασκόπηση των Chin et al. (2023) για την αυτοματοποιημένη διάγνωση ασθενειών με χρήση ΣμηΕΑ, χώρισε τα κυριότερα προβλήματα σε δύο κυρίως μέρη: στα διαθέσιμα σύνολα δεδομένων και στην κατασκευή του ίδιου του μοντέλου. Το πρώτο μέρος περιλαμβάνει παραμορφώσεις στο σύνολο των εικόνων, τον περιορισμένο αριθμό δεδομένων που έχουν επισημανθεί από ειδικούς, τη μη-προβλεψιμότητα απόκτησης δεδομένων (τυχαιότητα) και την έλλειψη διαφοροποίησης κατηγοριών στο σύνολο δεδομένων. Όσον αφορά την κατασκευή του μοντέλου, τα κυριότερα προβλήματα περιλαμβάνουν το μικρό μέγεθος του συνόλου δεδομένων για επαρκή εκπαίδευση και τη χρονοβόρα διαδικασία που περιλαμβάνει την εκπαίδευση αλλά και τη διαδικασία επεξεργασίας των δεδομένων που είναι απαραίτητη τις περισσότερες φορές.

Οι Huang et al. (2019) διερεύνησαν την ασθένεια της ελμινθοσπορίωσης στο σιτάρι (HLB - Helminthosporium leaf blotch) μέσω RGB εικόνων που λήφθηκαν από ΣμηΕΑ. Το CNN που εφαρμόστηκε πέτυχε ακρίβεια 91,43% . Το κυριότερο πρόβλημα που επισημάνθηκε, αφορούσε τα παρόμοια συμπτώματα της ασθένειας HLB με άλλες ασθένειες σιταριού, καθιστώντας έτσι δύσκολη τη διάκρισή της από τυχόν άλλες υπάρχουσες ασθένειες.

Οι Guo et al. (2024) μελέτησαν τον εντοπισμό ασθενειών, ζιζανίων και εντόμων σε μία καλλιέργεια ενός παραδοσιακού κινέζικου φαρμακευτικού φυτού (*Cinnamomum Camphora* var. *Borneol* - CCB) χρησιμοποιώντας εικόνες RGB που λήφθηκαν μέσω ΣμηΕΑ. Με τη χρήση 24 δεικτών βλάστησης, έκαναν εξαγωγή των στοιχείων με πολλαπλούς αλγορίθμους μηχανικής μάθησης. Τα πειραματικά αποτελέσματα επιβεβαίωσαν ότι η προτεινόμενη μέθοδος μπορεί να επιτύχει την ακριβή

παρακολούθηση παρασίτων και ασθενειών με μειωμένο αριθμό δειγμάτων εκπαίδευσης, με χαμηλό κόστος και υψηλή ακρίβεια.

Ως προς τα βασικά χαρακτηριστικά των πτήσεων των ΣμηΕΑ (π.χ., ύψος και ταχύτητα πτήσης) και τον τρόπο λήψης των εικόνων (π.χ., ποσοστά επικάλυψης των εικόνων στις δύο διαστάσεις), οι υπάρχουσες μελέτες που κάνουν χρήση εικόνων RGB χρησιμοποιούν σχετικά παρόμοιες μεθόδους, με ελαφρές διαφοροποιήσεις. Για παράδειγμα, οι Kerkech et al. (2018), για την αναγνώριση της ίσκας σε αμπέλια, πραγματοποίησαν πτήσεις στα 25m, με ανάλυση 1 px/cm σε διάσταση εικόνας 4608 x 3456 pixels. Το σύνολο δεδομένων τους αποτελούνταν από 70.560 τμήματα εικόνων, με 17.640 τμήματα για κάθε κλάση, όπου οι κλάσεις είχαν χωριστεί σε έδαφος, υγιές φυτό, πιθανώς προσβεβλημένο φυτό και προσβεβλημένο φυτό. Οι Pan et al. (2021) χρησιμοποίησαν RGB εικόνες από ΣμηΕΑ για τη διάγνωση κίτρινης σκωρίασης στο σιτάρι. Η πτήση πραγματοποιήθηκε στα 30m με ανάλυση 0.7 px/cm και γενικό overlap 90%, και ακολούθησε ταξινόμηση με τρεις κατηγορίες κλάσεων: υγιές σιτάρι, σιτάρι με σκωρίαση και έδαφος. Πραγματοποιήθηκε stitching των ληφθέντων εικόνων και μέσω της μεθόδου sliding-window (μεγέθους 256 x 256), λήφθηκαν 5580 δείγματα. Οι Amarasingam et al. (2022) εξέτασαν την ασθένεια WLD σε ζαχαρότευτλα μέσω RGB εικόνων από ΣμηΕΑ. Η πτήση έγινε στα 20m με ταχύτητα 1.4 m/s και οι εικόνες λήφθηκαν σε ανάλυση 1.1 cm/pixel, με front overlap 75% και side overlap στα 65%. Οι Huang et al. (2019) διερεύνησαν την αυτοματοποιημένη διάγνωση της ασθένειας HLB στο σιτάρι, μέσω RGB εικόνων που λήφθηκαν μέσω ΣμηΕΑ. Η κάμερα είχε ανάλυση 4000 x 3000 pixels, το ύψος ήταν στα 80m, με χωρική ανάλυση 3.4 cm. Η ταξινόμηση των εικόνων γινόταν μέσω των 4 κλάσεων: κανονικό, ελαφρώς ασθενές, μετρίως ασθενές και υψηλά ασθενές. Οι Guo et al. (2024) μελέτησαν την αυτοματοποιημένη διάγνωση από προσβολές εντόμων και ασθενειών σε παραδοσιακά θεραπευτικά δέντρα της Κίνας, χρησιμοποιώντας 100 τυχαία δείγματα RGB εικόνων, από 50 υγιή και από 50 προσβεβλημένα δέντρα. Οι εικόνες ανίχνευσης δημιουργήθηκαν με τη χρήση 7 μοντέλων μηχανικής μάθησης. Η πτήση πραγματοποιήθηκε στα 80 m, με front overlap 80% και side overlap στα 70%. Η έρευνα των Mattupalli et al. (2018) χρησιμοποίησε υψηλής ανάλυσης RGB εικόνες από επανδρωμένα αλλά και μη-επανδρωμένα εναέρια συστήματα με σκοπό την παρακολούθηση και τον εντοπισμό μολύνσεων σε καλλιέργεια αλφάλφας από την ασθένεια που προκαλεί σήψη των ριζών (Phymatotrichopsis root rot - PRR). Τα αποτελέσματα έδειξαν ότι τα ΣμηΕΑ πέτυχαν υψηλά ποσοστά ακρίβειας στον εντοπισμό των φυτών που είχαν μολυνθεί (επιτυχία 90-96%), ενώ τα επανδρωμένα συστήματα πέτυχαν ακόμα υψηλότερη ακρίβεια στις περισσότερες περιπτώσεις (95-100%).

Από την παραπάνω ανασκόπηση της βιβλιογραφίας διαφαίνεται ότι η χρήση ΣμηΕΑ σε συνδυασμό με απλές RGB κάμερες αποτελεί μια ιδιαίτερα αποδοτική και οικονομικά βιώσιμη προσέγγιση για την έγκαιρη διάγνωση φυτοπαθολογικών προβλημάτων. Παρά τις περιορισμένες φασματικές πληροφορίες σε σχέση με πολυφασματικούς ή υπερφασματικούς αισθητήρες, σύγχρονες μέθοδοι βαθιάς μάθησης (κυρίως αρχιτεκτονικές CNN και πιο πρόσφατα vision transformers) κατορθώνουν να εξάγουν διακριτικά μορφομετρικά και χρωματικά χαρακτηριστικά που επαρκούν για υψηλές επιδόσεις αναγνώρισης. Ωστόσο, η βιβλιογραφία αναδεικνύει σημαντικές προκλήσεις, όπως η ευαισθησία στις μεταβολές φωτισμού, η ανάγκη για ολοκληρωμένα και

ποικιλόμορφα σύνολα δεδομένων, καθώς και η χαμηλή μεταφερσιμότητα των μοντέλων (generalization) μεταξύ διαφορετικών καλλιεργειών και συνθηκών πεδίου. Συνολικά, οι υπάρχουσες μελέτες αποδεικνύουν ότι οι RGB εικόνες από ΣμηΕΑ μπορούν να υποστηρίξουν αποτελεσματικά συστήματα έγκαιρης προειδοποίησης και επιχειρησιακής παρακολούθησης ασθενειών, ενώ παράλληλα υπογραμμίζουν την ανάγκη για πιο ρεαλιστικά δεδομένα, εξελιγμένες τεχνικές ενίσχυσης γενίκευσης και ενσωμάτωση χωροχρονικής πληροφορίας ώστε να επιτευχθεί μεγαλύτερη αξιοπιστία σε πραγματικές συνθήκες παραγωγής.

2.3 Σημαντικότερες προκλήσεις για την αυτοματοποιημένη διάγνωση ασθενειών μέσω ΣμηΕΑ

2.3.1 Τρόπος αξιολόγησης και δοκιμής των μοντέλων αναγνώρισης

Τα CNNs έχουν χρησιμοποιηθεί ευρέως για την αναγνώριση ασθενειών σε φυτά και έχουν πετύχει υψηλά ποσοστά αναγνώρισης (αξιοσημείωτες αρχικές εργασίες στον τομέα: Kawasaki et al., 2015; Mohanty et al., 2016; Ferentinos, 2018). Ωστόσο, έχει παρατηρηθεί ότι τα μοντέλα που χρησιμοποιούν ίδια φύσης δεδομένα στην εκπαίδευση και στη δοκιμή, έχουν πετύχει υψηλότερα ποσοστά αναγνώρισης συγκριτικά με δεδομένα τα οποία έχουν ληφθεί σε διαφορετικές συνθήκες (Kudo et al., 2024). Μάλιστα, η υπερεκπαίδευση (overfitting) πολλών από αυτά τα μοντέλα οδηγεί σε σημαντική πτώση της γενικευσιμότητά τους (generalization), καθώς τα μοντέλα με ίδια φύσης δεδομένα στα υποσύνολα εκπαίδευσης και δοκιμής δεν προσαρμόζονται καλά σε νέα δεδομένα, ειδικά αν αυτά έχουν σημαντικές διαφορές στις περιβαλλοντικές συνθήκες λήψης από αυτά με τα οποία εκπαιδεύτηκαν (Khan et al., 2025). Έτσι, έρευνες που χρησιμοποίησαν διαφορετικής φύσης δεδομένα στο υποσύνολο δοκιμής (test set) πέτυχαν πολύ χαμηλότερα ποσοστά ακρίβειας (Boulent et al., 2019; Shibuya et al., 2021).

2.3.2 Συνθήκες λήψης των εικόνων

Υπάρχουν πολλοί παράγοντες οι οποίοι μπορούν να επηρεάσουν τα χαρακτηριστικά μίας εικόνας, ειδικά σε συνθήκες καλλιέργειας τον αγρό, εμποδίζοντας με αυτόν τον τρόπο την ομαλή λειτουργία ενός αυτοματοποιημένου μοντέλου και την επίτευξη υψηλών αποδόσεων χρήσης του. Ο φωτισμός αποτελεί έναν σημαντικό παράγοντα, καθώς μεταβάλλεται με βάση την ώρα λήψης της εικόνας, τη θέση του ήλιου εν συγκρίσει με το φύλλο (σκίαση κτλ.), τις καιρικές συνθήκες, καθώς και άλλες συνθήκες οι οποίες μπορούν να αλλοιώσουν τη λήψη. Η κατοπτρική ανάκλαση (specular lighting, Εικόνα 1.5.2-2) δημιουργείται λόγω υψηλής ανάκλασης σε συγκεκριμένες οπτικές γωνίες. Το φαινόμενο αυτό μπορεί να μειωθεί μέσω της τροποποίησης στη γωνία λήψης ή ακόμα και στην αλλαγή της θέσης του φύλλου, παρόλο που θα υπάρχει σχεδόν πάντα κάποιος βαθμός ανάκλασης (Barbedo, 2013). Η συνεχής παρουσία σκιών και ο άμεσος φωτισμός

(direct illumination) αποτελούν σημαντικές επιπτώσεις στον φωτισμό μίας εικόνας. Υπάρχουν πολλές αναφορές σε προβλήματα αναγνώρισης ασθενειών σε φυτά λόγω αντανακλάσεων που υπήρχαν κατά τις λήψεις όπως στην έρευνα των Bock et al. (2009) για την βακτηρίωση σε δέντρα γκρέιπφρουτ, των Boese et al. (2008) σε αναγνώριση ασθενειών σε θαλάσσιο ζωστήρα (*Zostera marina*) και των Pydipati et al. (2006) στην αναγνώριση μυκοσφαιρέλλας (*Mycosphaerella citri* Whiteside, "greasy spot"), φόμοψης (*Diaporthe citri*, "melanose") και κηλίδωσης εσπεριδοειδών (*Elsinoe fawsettii*, "scab"). Ακόμα και σε ελεγχόμενο περιβάλλον, όπως αυτό του εργαστηρίου, οι Peressotti et al. (2011) παρατήρησαν ότι πιο αυστηρώς ελεγχόμενες συνθήκες αντανάκλασης μπορούν να βελτιώσουν τα αποτελέσματα για τον εντοπισμό μέσω εικόνων σε πολλαπλασιασμό περονόσπορου αμπελιού. Έχουν γίνει αρκετές προσπάθειες στο παρελθόν για τη μέγιστη απομόνωση ποικιλότητας ανακλάσεων, όπως στην έρευνα των Pourreza et al. (2015a, 2015b) και των Clément et al. (2015).



Εικόνα 1.5.2-2: Λήψη από RGB κάμερα σε ζιζάνια ορυζώνα με εμφανές πρόβλημα κατοπτρικής ανάκλασης.

Η γωνία λήψης της εικόνας αποτελεί επίσης σημαντικό παράγοντα. Τα φύλλα πρέπει να βρίσκονται σε πλήρως κάθετη γωνία, έτσι ώστε να βρίσκονται στον κεντρικό άξονα λήψης του οπτικού αισθητήρα. Με αυτόν τον τρόπο γίνεται αποφυγή της δημιουργίας κεκλιμένων γωνιών, οι οποίες αλλοιώνουν την εικόνα αφού καλύπτουν το φύλλωμα και έτσι, εμποδίζουν το επίκεντρο λήψης. Οι Zhou et al. (2014) ανέφεραν ότι η πηγή σφαλμάτων στο πείραμα που εφάρμοσαν για την αναγνώριση κερκόσπορας σε ζαχαρότευτλα ήταν η παρουσία σκιών και κατοπτρικών ανακλάσεων. Μεταξύ τεσσάρων αλγορίθμων για ψηφιακή επεξεργασία (Orientation Code Matching "OCM", Sum of Absolute Differences "SAD", Sum of Squared Differences "SSD" και Normalized Cross-Correlation "NCC") βρέθηκε ότι ο OCM σημείωσε τα καλύτερα αποτελέσματα, ως προς την προσαρμογή του στις αλλαγές φωτισμού. Υποστήριξαν βέβαια ότι αυτό δεν ήταν καθοριστικό και ότι υπάρχουν αρκετά περιθώρια βελτίωσης, κυρίως για τον αλγόριθμο SVM (Support Vector Machine) που χρησιμοποιήθηκε.

2.3.3 Το παρασκήνιο εικόνας (image background)

Το παρασκήνιο μίας εικόνας περιέχει συχνά στοιχεία, τα οποία δυσκολεύουν τη διάκριση στοιχείων σε αυτήν. Ο διαχωρισμός των φύλλων (leaf segmentation) ενός φυτού στην εικόνα αποτελεί το πρώτο και σημαντικότερο βήμα για την αναγνώρισή τους ως υγιή ή προβληματικά. Εάν τοποθετηθούν σε πάνελ λευκού ή μπλε χρώματος, η αναγνώρισή τους μπορεί να γίνει πολύ πιο εύκολα (Barbedo, 2016). Είναι συχνό πρόβλημα όταν υπάρχει πολύπλοκο παρασκήνιο (busy background), καθώς δυσκολεύει αρκετά τη διαδικασία αναγνώρισης ενός φυτού (Εικόνα 1.5.2-3).

Οι Zhang & Meng (2011) διαχώρισαν ευθέως αλλοιώσεις από το φύλλο και το παρασκήνιο, χρησιμοποιώντας μία διαδικασία 2 βημάτων, η οποία έκανε την ταυτοποίηση μέσω ιεράρχησης. Η αναγνώριση έγινε στην ασθένεια της βακτηρίωσης σε λεμόνια, η οποία προκαλείται από το βακτήριο *Xanthomonas axonopodis* pv. *Citri* (Xac). Χρησιμοποίησαν μία βελτιωμένη εκδοχή του αλγορίθμου Adaboost, ο οποίος σε πρώτη φάση διέκρινε τις αλλοιώσεις των φύλλων από το παρασκήνιο και στη συνέχεια τοποθετήθηκε μία παράμετρος αναγνώρισης για τη βακτηρίωση (canker lesion descriptor). Με την εξειδικευμένη αναγνώριση αυτή κατάφεραν να αναγνωρίσουν επιτυχώς συμπτώματα βακτηρίωσης, με υψηλά ποσοστά ακριβείας συγκριτικά ακόμα και με την αναγνώριση από εξειδικευμένους φυτοπαθολόγους. Οι Alenyà et al., (2013) παρουσίασαν μία μέθοδο για την μοντελοποίηση, παρακολούθηση και δειγματοληψία φύλλων, χρησιμοποιώντας εικόνες υπέρυθρης έντασης (infrared-intensity images) και χάρτες εμβάθυνσης (depth maps) μέσω εγκατεστημένης τρισδιάστατης κάμερας σε ένα ρομποτικό χέρι. Το μοντέλο που χρησιμοποιήθηκε ήταν ικανό για την ανίχνευση φύλλων (plant probing) και την ταξινόμησή τους σε σύνθετες επιφάνειες. Έχει παρατηρηθεί ότι στην πλειοψηφία των ερευνών αφαιρείται χειροκίνητα το παρασκήνιο εικόνας (Cui et al., 2009; Cui et al., 2010) ή απομονώνεται το φύλλο από άλλα στοιχεία πριν ληφθεί η εικόνα. Η απομόνωση μπορεί να γίνει με διαφορετικούς τρόπους, όπως με την αποκοπή των φύλλων και την τοποθέτησή τους σε τρυβλία Πέτρι (Olmstead et al., 2001; Peressotti et al., 2011), ή με την τοποθέτηση πάνελ πίσω από το φύλλο (Moya et al., 2005). Ακόμα, έχουν χρησιμοποιηθεί σκάνερ (Berner & Paxson, 2003), κοντέινερ (Pydipati et al., 2006), λευκό παρασκήνιο υπό γυάλινη επιφάνεια (Wiwart et al., 2009), κλειστά κουτιά (De Coninck et al., 2011) και ειδικά σχεδιασμένες συσκευές για τη λήψη εικόνων (Boese et al., 2008; Clément et al., 2015). Προφανώς, τα μοντέλα αυτά δεν διακρίνονται για την πρακτική τους χρήση σε συνθήκες πραγματικής καλλιέργειας στον αγρό, και αυτό αποτελεί έναν άκρως ανασταλτικό παράγοντα ως προς την πρακτική τους χρήση.



Εικόνα 1.5.2-3: Παράδειγμα πολύπλοκου παρασκηνίου σε λήψη υδροπονικής καλλιέργειας σε φράουλα.

2.3.4 Κατάλληλη ταξινόμηση ασθενειών

Η πλειοψηφία των ασθενειών σε φυτά προκαλείται από μύκητες και από βακτήρια. Η μόλυνση από βακτήρια προκαλεί ένα κυρίως σύμπτωμα και η αναγνώρισή τους δεν είναι ιδιαίτερα δύσκολη. Παρατηρείται ζημιά στον φυτικό ιστό, συγκεκριμένα τοπικές ή ολικές νεκρώσεις (μέσω ελκών, σήψεων, πτώσεων φύλλων, ανθρακώσεων), υπερπλασίες αλλά και σχηματισμοί μαζών από μυκήλια και συσσωματώματα σποριών, που αποτελούν χαρακτηριστικά σημάδια μόλυνσης, σε αντίθεση με τα συμπτώματα τα οποία αναφέρονται στο φυτό ή σε φυτικούς ιστούς (Kelman et al., 2024).

Τα περισσότερα συμπτώματα ασθενειών δεν έχουν καθαρά οριοθετημένες άκρες, αλλά σβήνουν σταδιακά μέσα στον υγιή φυτικό ιστό. Αυτό έχει ως αποτέλεσμα τον ασαφή διαχωρισμό των προσβεβλημένων περιοχών, καθιστώντας την ταξινόμηση των υγιών και μολυσμένων φυτών ακόμη πιο δύσκολη. Αν υπάρχει αμφιβολία στην οπτική ή χειροκίνητη αναγνώριση, τότε και η μηχανική οριοθέτηση (machine-based delineation) θα υπόκειται σε αμφισβήτηση. Η μηχανική ταξινόμηση προσφέρει το πλεονέκτημα της συνέπειας στις εικόνες, αλλά αυτό ισχύει μόνο εάν υπάρχει ξεκάθαρος διαχωρισμός. Ωστόσο, υπάρχουν αμφιβολίες σχετικά με τη συνέπεια τέτοιων εικόνων, καθώς τα συμπτώματα συχνά εμφανίζονται σε ακανόνιστες και θολές μορφές. Αυτό ενδέχεται να επηρεάσει την ακρίβεια στον καθορισμό των ορίων (thresholding) και άλλων διαδικασιών, ακόμη και αν υιοθετηθεί κάποιο προσαρμοστικό σχήμα (Barbedo, 2014).

Οι περισσότερες έρευνες ομαδοποιούν τα pixel των εικόνων σε συμπλέγματα (clusters), αντί να πραγματοποιούν διαχωρισμό των περιοχών σε "υγιείς" και "ασθενείς", όπως στις έρευνες των Saradhambal et al. (2018) και Kerkech et al. (2020). Αν η ομαδοποίηση συμπλεγμάτων εφαρμοστεί κατάλληλα, τότε το κάθε τμήμα θα αντιπροσωπεύει τα πιο "οξεία" μέρη της κάθε εικόνας, με τα ανάλογα συμπεράσματα. Το πρόβλημα είναι στην ταξινόμηση των συμπλεγμάτων η οποία γίνεται σχεδόν πάντα χειροκίνητα, αφήνοντας την ανοιχτή σε υποκειμενική αμφισβήτηση. Δυστυχώς δεν υπάρχουν αρκετές λύσεις

για την τμηματοποίηση των συμπτωμάτων, ωστόσο έχουν γίνει κάποιες προσπάθειες ερευνητών για την αποφυγή της τμηματοποίησης. Για παράδειγμα, η έρευνα των Cui et al. (2010) χρησιμοποίησε το κέντρο κατανομής του χρώματος των φύλλων σε πολικό σύστημα συντεταγμένων ως παράγοντα ομαδοποίησης σε 32 δείγματα φύλλων για τη σκωρίαση σε φύλλα σόγιας, με τη μέθοδό τους να ανιχνεύει επαρκώς τα μολυσμένα φύλλα.

2.3.5 Κατάλληλες παράμετροι για την αναγνώριση ασθενειών μέσω ΣμηΕΑ

Οι παράμετροι των συστημάτων ανίχνευσης ΣμηΕΑ όπως είναι το ύψος πτήσης, το ωφέλιμο φορτίο, οι διαθέσιμοι αισθητήρες και ο αποθηκευτικός χώρος για την κατάλληλη λήψη εικόνων, μπορούν να επηρεάσουν την απόδοση των εκτιμήσεων αυτοματοποιημένης αναγνώρισης ασθενειών σε καλλιέργειες. Η χαμηλή διάρκεια πτήσεων λόγω διαφόρων παραγόντων όπως είναι η χωρητικότητα της μπαταρίας, η υπολογιστική ισχύς που χρειάζεται για την εφαρμογή χρήσης αλγορίθμων βαθιάς μάθησης και η χρήση υψηλών ωφελίμων φορτίων αποτελούν επίσης σημαντικές προκλήσεις, οι οποίες μπορούν να επηρεάσουν και να περιορίσουν τη χρήση των ΣμηΕΑ για την αυτοματοποιημένη διάγνωση ασθενειών (Bouguettaya et al., 2023).

Η ανάλυση των εικόνων που έχουν ληφθεί μέσω ΣμηΕΑ είναι αρκετά σημαντική για τη χρήση μοντέλων βαθιάς μάθησης, όπου μπορούν να αποκτηθούν εικόνες υψηλής χωρικής ανάλυσης. Αυτό μπορεί να επιτευχθεί με την πτήση ΣμηΕΑ σε χαμηλό ύψος ή με τη χρήση άλλων τεχνικών αναβάθμισης των εικόνων (Shahi et al., 2023). Το ύψος και συνεπώς, η απόσταση λήψης εικόνων σε ΣμηΕΑ είναι σαφώς μεγαλύτερη από τη λήψη επίγειων εικόνων, οι οποίες μπορούν να επιτύχουν τη λήψη ακόμα και ενός φύλλου σε κάποιο φυτό. Δεδομένου του υψηλού ύψους λήψης εικόνων μέσω ΣμηΕΑ, υποβαθμίζεται η ανάλυση των εικόνων και συνεπώς η ακρίβεια αποτύπωσης των σημείων ενδιαφέροντος (ROI) όπου είναι τα συμπτώματα των ασθενειών στα φυτά.

2.3.6 Χαμηλή διαθεσιμότητα δεδομένων

Οι περισσότεροι τύποι μοντέλων βαθιάς μάθησης για την αυτοματοποιημένη αναγνώριση ασθενειών απαιτούν έναν μεγάλο όγκο δεδομένων για την επιτυχή εκπαίδευσή τους. Ταυτόχρονα, η δημιουργία της βάσης δεδομένων για την εκπαίδευση αυτή προϋποθέτει τη συνήθως χειροκίνητη δημιουργία ετικετών (annotation) για κάθε εικόνα ή για συγκεκριμένα σημεία της κάθε εικόνας από εξειδικευμένο γεωπόνο. Μία σημαντική πρόκληση για την επίλυση του συγκεκριμένου προβλήματος μπορεί να αποτελέσει η δημιουργία ημι-, ακόμα και μη-επιβλεπόμενων μοντέλων μηχανικής μάθησης για την αναγνώριση ασθενειών (Shahi et al., 2023). Μία άλλη λύση είναι η ευρεία διάθεση μεγάλου αριθμού έτοιμων βάσεων δεδομένων και ο διαρκής εμπλουτισμός τους, κάτι το οποίο δυστυχώς δεν έχει επιτευχθεί έως τώρα από τη διεθνή ερευνητική κοινότητα (Arsenovic et al., 2019; Neupane & Baysal-Gurel, 2021).

2.3.7 Περιορισμός διαθεσιμότητας αισθητήρων για διάγνωση ασθενειών

Για τη διάγνωση ασθενειών σε φυτά μπορούν να χρησιμοποιηθούν διαφορετικοί αισθητήρες, όπως είναι οι RGB (οι κλασικοί αισθητήρες στο ορατό φάσμα - red-green-blue), NIR (Near InfraRed spectroscopy), πολυφασματικοί (multispectral) και υπερφασματικοί (hyperspectral). Ο ακριβής εντοπισμός ασθενειών σε φυτά απαιτεί συχνά εξειδικευμένους αισθητήρες υψηλών φασματοσκοπικών φασμάτων. Οι αισθητήρες αυτοί έχουν τη δυνατότητα να διακρίνουν ειδικά χαρακτηριστικά ενός αντικειμένου μεταξύ εκατοντάδων κοντινών φασματικών ζωνών, αλλά ένα σημαντικό πρόβλημα είναι το υψηλό κόστος αγοράς και εφαρμογής τους (Neurane & Baysal-Gurel, 2021). Αντιθέτως, οι RGB αισθητήρες έχουν αρκετά χαμηλό κόστος και έχουν χρησιμοποιηθεί ευρέως για την αναγνώριση ασθενειών σε φυτά μέσω ΣμηΕΑ (Li et al., 2014), ενώ πολλές φορές συνδυάζονται με πολυφασματικούς και υπερφασματικούς αισθητήρες (Zhu et al., 2024; Dolatabadian et al., 2025).

Η ανάπτυξη αισθητήρων που παρέχουν υψηλής ποιότητας χωρική, χρονική και φασματική πληροφορία είναι ακόμα σε εξέλιξη (Hulley et al., 2017; Khanal et al., 2020). Έχουν δημιουργηθεί νέες τεχνολογίες για τη φαινολογική παρακολούθηση των καλλιεργειών, όπως είναι ο φθορισμός από τον ήλιο ή το βραχέως κύματος υπεριώδες φως, αλλά οι αισθητήρες αυτοί επηρεάζονται πολύ από τις κλιματικές συνθήκες (Song et al., 2018).

2.3.8 Προβληματισμοί σχετικά με πτήσεις ΣμηΕΑ (κανονισμοί, ηθικότητα, κόστος, ασφάλεια)

Εκτός από τα τεχνικά προβλήματα που υπάρχουν, οι λήψεις εικόνων μέσω ΣμηΕΑ συνοδεύονται από συγκεκριμένο νομοθετικό πλαίσιο που θέτει ορισμένους περιορισμούς. Η νομοθεσία πιλότων ΣμηΕΑ περιλαμβάνει αρκετές απαγορεύσεις ως προς το ύψος, τις περιοχές πραγματοποίησης πτήσεων καθώς και των ζωνών που επιλέγονται. Η εμπορική χρήση απαιτεί τη λήψη άδειας πιλότου, κατά την οποία το ΣμηΕΑ εγγράφεται σε ειδικό μητρώο και καταγράφεται κάθε φορά η πτήση που πραγματοποιείται σε συγκεκριμένη πλατφόρμα. Σημαντικό πρόβλημα επίσης αποτελούν οι παράνομες πτήσεις, οι οποίες είτε δεν δηλώνονται ποτέ στο σύστημα, είτε πραγματοποιούνται από άτομα που δεν έχουν την απαιτούμενη άδεια (Hassler & Baysal-Gurel, 2019).

Η καταπάτηση προσωπικών δεδομένων αποτελεί επίσης σημαντικό θέμα, καθώς συχνά παρειρισκόμενοι χρήστες σε πτήση ΣμηΕΑ δεν γνωρίζουν τους νόμους περί προστασίας των δεδομένων (GDPR) και έτσι, πραγματοποιούνται πτήσεις οι οποίες καταγράφουν παράνομα δεδομένα τρίτων προσώπων (Stöcker et al., 2017).

Πέρα όμως από τα νομικά προβλήματα, είναι γεγονός ότι οι πτήσεις ΣμηΕΑ είναι αρκετά ακριβές ως προς την εφαρμογή τους. Η αγορά ενός ΣμηΕΑ με την εγκατάσταση των απαραίτητων αισθητήρων και την άδεια πτήσεων υπολογίζεται να φτάνει ένα ποσό άνω

των 8.500 ευρώ (Adão et al., 2017; Hassler & Baysal-Gurel, 2019). Έτσι, οι παραγωγοί μικρής κλίμακας αδυνατούν να υιοθετήσουν τη χρήση των συγκεκριμένων νέων τεχνολογιών στον αγρό. Η απόκτηση του ΣμηΕΑ απαιτεί και την απαραίτητη εκπαίδευση, όχι μόνο ως προς τη διενέργεια πτήσεων αλλά και στη «μετάφραση» των δεδομένων που έχουν αποκτηθεί.

Τέλος, ένα πρόβλημα που δεν έχει διερευνηθεί επαρκώς είναι αυτό της ασφάλειας των καταγραφόμενων δεδομένων και της λειτουργικότητας των ΣμηΕΑ κατά τη διάρκεια πτήσης ως προς πιθανές παρεμβολές, κακόβουλες ή μη.

2.4 Χρήση ΣμηΕΑ για αναγνώριση ασθενειών: Ειδικές περιπτώσεις & προτάσεις

Η παρούσα ενότητα αναφέρεται στη χρήση των ΣμηΕΑ για την αυτοματοποιημένη αναγνώριση συγκεκριμένων ασθενειών σε επιλεγμένες καλλιέργειες και πιο συγκεκριμένα: i) στην αναγνώριση ασθενειών για την καλλιέργεια ροδακινιάς (*Prunus persica*) και μεταξύ αυτών για το αντικείμενο μελέτης που είναι η φαιά σήψη (*Monilinia spp.*), ii) στην αναγνώριση ασθενειών στα εσπεριδοειδή και συγκεκριμένα για την ασθένεια της κορυφοξήρας (*Phoma tracheiphila*), και iii) στην αυτοματοποιημένη διάγνωση στο αμπέλι (*Vitis vinifera*) και συγκεκριμένα για 3 ασθένειες, οι οποίες είναι η ίσκα (*Fomitiporia spp.*), το ωίδιο (*Uncinula necator*) και η τεφρά σήψη (*Botrytis cinerea*).

2.4.1 Περίπτωση πρώτη: Ροδακινιά

Τα ΣμηΕΑ έχουν χρησιμοποιηθεί ευρέως σε καλλιέργειες ροδακινιάς για διαφορετικές χρήσεις. Για παράδειγμα, η έρευνα των Hu et al. (2022) χρησιμοποίησε εικόνες από ΣμηΕΑ για την ομαδοποίηση και παρακολούθηση 259 κομών σε ροδακινιές, με σκοπό τη χαρτογράφηση και βελτίωση του οπωρώνα. Λαμβάνοντας υπόψη ότι οι αεροφωτογραφίες περιείχαν λίγες πληροφορίες, υιοθέτησαν μία διαδικασία αύξησης των υπάρχοντων δεδομένων μέσω ενός αρχιτεκτονικού μοντέλου το οποίο ήταν βασισμένο σε cGANs (conditional generative adversarial networks) για την εξαγωγή των κωμών και ταυτόχρονα για την καλύτερη παρακολούθηση.

Άλλο παράδειγμα αποτελεί η έρευνα των Esehaghbeygi et al. (2010), η οποία χρησιμοποίησε μία υψηλής ανάλυσης CCD κάμερα για την λήψη RGB εικόνων για την ολοκλήρωση της μελέτης του χρώματος και του μεγέθους των ροδάκινων. Έπειτα από την εφαρμογή ενός ειδικά σχεδιασμένου αλγορίθμου για την επεξεργασία εικόνων (edge detection algorithm), τον υπολογισμό του όγκου των φρούτων και τη λειτουργία Mesh για τον εντοπισμό αποχρώσεων, κορεσμών και την ολική «αξία» (value) του ροδάκινου στην εικόνα, τα αποτελέσματα έδειξαν ότι ο εντοπισμός για τα λευκά σημάδια (white spots) ήταν 96.7%, για τις καφέ κηλίδες (brown spots) ήταν 85%, η ακρίβεια της ταξινόμησης μεγεθών ήταν 96% και η ακρίβεια της χρωματικής ταξινόμησης 90%.

Συμπέραναν επίσης ότι η εξάλειψη της επιρροής από άλλες πηγές φωτισμού στον εντοπισμό της ποιότητας παραγόμενων φρούτων σε εξωτερικό περιβάλλον αποτελεί αναπόφευκτο πρόβλημα.

2.4.1.1 Αναγνώριση ασθενειών στις ροδακινιές

Στο παρελθόν έχει χρησιμοποιηθεί ευρέως η καλλιέργεια της ροδακινιάς για την αυτοματοποιημένη διάγνωση ασθενειών μέσω ΣμηΕΑ. Η έρευνα των Alosaimi et al. (2021) εφάρμοσε ένα νέο μοντέλο CNN για τον εντοπισμό ασθενειών σε ροδακινιές. Έπειτα από τη συλλογή 3.199 εικόνων από υγιή και προσβεβλημένα ροδάκινα, εφάρμοσαν το 80% των εικόνων για την εκπαίδευση του επιλεγμένου CNN, 10% για επαλήθευση και 10% για δοκιμές. Η ταξινόμηση των εικόνων σε περιβάλλοντα εξωτερικού χώρου (πεδίο) που περιείχαν ασθένειες πραγματοποιήθηκε από ειδικούς φυτοπαθολογίας. Η προσθήκη αυτή έγινε για να είναι το μοντέλο πιο ακριβές σε πραγματικές συνθήκες, καθώς το υλικό από τις ανοιχτές βάσεις δεδομένων ήταν σε συνθήκες εργαστηρίου. Οι ασθένειες που μελετήθηκαν ήταν η βακτηριακή στιγμάτωση/βακτηριακό έλκος (*Pseudomonas syringae* pv., "Bacterial Canker"), βακτηριακή κηλίδωση (*Xanthomonas* spp., "Bacterial Spot"), καρκίνωμα (*Rhizobium radiobacter/Agrobacterium tumefaciens*, "Crown Gall"), κλαδοσπορίωση/φουζικλάδιο (*Cladosporium carpophilum*, "Peach Scab"), φαιά σήψη (*Monilinia fructicola*, "Brown Rot"), σκωρίαση (*Tranzschelia pruni-spinosae* "Peach Leaf Rust"), κορύνεο (*Wilsonomyces carpophilus*, "Shot hole Disease"), εξώασκος (*Taphrina deformans*, "Peach Leaf Curl"), ιός της σάρκας (*Plum pox virus*, "PPV"), κυτόσπορα (*Cytospora* sp., "Fungal Gummosis") και ωίδιο (*Sphaeroteca pannosa*, "Powdery mildew"). Το μοντέλο που χρησιμοποιήθηκε περιείχε μία προ-εκπαιδευμένη αρχιτεκτονική του VGG-19 (CNN) και στην συνέχεια εφαρμόστηκε το Mask R-CNN για ακόμα πιο ακριβή εντοπισμό των ασθενειών. Το τελικό μοντέλο πέτυχε ποσοστό ακρίβειας αναγνώρισης των αναφερθέντων ασθενειών με ποσοστό αναγνώρισης άνω του 90%.

Οι Huang et al. (2020) διερεύνησαν προβλήματα θορύβου, παρεμβολών από το παρασκήνιο (background interference) αλλά και χαμηλής ικανότητας ανίχνευσης εικόνων σε ασθένειες ροδάκινων. Οι ασθένειες που μελετήθηκαν ήταν η φαιά σήψη (*Monilinia fructicola*), η βακτηριακή κηλίδωση (*Xanthomonas* spp.), η ανθράκωση (*Colletotrichum* spp.) και το φουζικλάδιο (*Cladosporium carpophilum*). Πρότειναν μία μέθοδο ανίχνευσης ασθενειών ροδάκινων βασισμένη σε αλγόριθμο ANLM (Asymptomatic Non-Local Means) με συγχώνευση PCNN (Parallel Convolutional Neural Network) και ELM (Extreme Learning Machine), βελτιστοποιημένη με LPSO (Linear Particle Swarm Optimization). Ο συνδυασμός PCNN-IPELM πέτυχε τα υψηλότερα αποτελέσματα, με τα εξής ποσοστά αναγνώρισης: 88.02% για φαιά σήψη, 90.56% για βακτηριακή κηλίδωση, 85.37% για ανθράκωση, 88.02% για φουζικλάδιο και 89.91% για φυσιολογική κατάσταση ροδάκινων.

Οι Sheikh et al. (2019) εφάρμοσαν ένα CNN για την αναγνώριση ασθενειών καλαμποκιού και ροδάκινων και συγκεκριμένα στα ροδάκινα για τη βακτηριακή κηλίδωση. Τα αποτελέσματα έδειξαν 99.55% ακρίβεια αναγνώρισης στα ροδάκινα.

2.4.1.2 Στάδια πρώιμης αναγνώρισης φαιάς σήψης

Για να πραγματοποιηθεί εγκαίρως η πτήση για την αυτοματοποιημένη διάγνωση ασθενειών, είναι απαραίτητο να προηγηθεί μελέτη που θα λαμβάνει υπόψη τα στάδια ανάπτυξης της καλλιέργειας και την περίοδο κατά την οποία εμφανίζονται τα πρώιμα συμπτώματα της εκάστοτε ασθένειας. Όσον αφορά τη φαιά σήψη των ροδάκινων, ο μεγαλύτερος αριθμός μολυσμάτων σχηματίζεται κατά την περίοδο άνθησης των δέντρων, δηλαδή την άνοιξη (Παναγόπουλος, 2007). Συγκεκριμένα, τα πρώτα συμπτώματα εμφανίζονται στα άνθη περίπου δύο εβδομάδες μετά το άνοιγμά τους, με την εμφάνιση καστανών κηλίδων που επεκτείνονται γρήγορα σε ολόκληρο το άνθος (Εικόνα 1.5.2-4). Τα μολυσμένα άνθη μαραίνονται, συρρικνώνονται και τελικά ξεραίνονται. Εκτός από τα άνθη, η φαιά σήψη μπορεί να προσβάλλει νεαρούς βλαστούς και τους αναπτυσσόμενους καρπούς. Η μόλυνση μπορεί επίσης να προκληθεί μέσω πληγών στους καρπούς, όπου σχηματίζεται αρχικά μια μικρή, επιφανειακή, κυκλική καστανή κηλίδα, η οποία σταδιακά διευρύνεται (Γκατζιλιάκης & Γούτος, 2019).



Εικόνα 1.5.2-4: Προσβολές φαιάς σήψης σε ροδάκινο. **(a):** φυσιολογικό άνθος ροδακινιάς (Πηγή: depositphotos.com), **(b):** Προσβολή από μονίλια σε ροδακινιά με χαρακτηριστική την έκκριση κόμμεος (Πηγή: depositphotos.com), **(c):** Έλκος βλαστού από προσβολή μονίλιας σε ροδάκινο (Πηγή: [αρχείο British Columbia](https://www.britishcolumbia.ca)).

2.4.1.3 Προτεινόμενα μέτρα για την αυτόματη διάγνωση φαιάς σήψης μέσω ΣμηΕΑ

Η αυτοματοποιημένη αναγνώριση της φαιάς σήψης μέσω έγχρωμων εικόνων από ΣμηΕΑ είναι αρκετά περιορισμένη, γιατί συχνά οι προσβολές παραμένουν “κρυμμένες” μέχρι την ωρίμανση των καρπών. Τα ΣμηΕΑ μπορούν να χρησιμοποιηθούν για τον έγκαιρο εντοπισμό στο στάδιο προσβολής των ανθών, εντοπίζοντας τις καφέ μολύνσεις, όπως φάνηκαν στην εικόνα 1.5.2-4, χωρίς αυτό να σημαίνει ότι είναι προληπτικό μέτρο, γιατί παραμένει η πιθανότητα μόλυνσης στο στάδιο ωρίμανσης των καρπών. Η πτήση οφείλει να γίνει σε χαμηλό ύψος και με σύντομο χρόνο λήψης εικόνων, ώστε να εντοπιστούν τα καφέ στίγματα που εμφανίζονται στα άνθη, διευκολύνοντας έτσι τον έγκαιρο εντοπισμό της ασθένειας. Επιπλέον, η πτήση με πολυφασματική κάμερα μπορεί να συμβάλει στην ανίχνευση στρες στα φυτά το οποίο δεν είναι ορατό με το γυμνό μάτι, παρέχοντας δυνατότητα εντοπισμού των πρώιμων σταδίων της ασθένειας. Η έγκαιρη διάγνωση της ασθένειας είναι απαραίτητη ειδικότερα στη περίπτωση μόλυνσης των καρπών, καθώς η ασθένεια αυτή έχει μεγάλη οικονομική σημασία και μπορεί να υποβαθμίσει μεγάλο πληθυσμό δέντρων εάν δεν εντοπιστεί έγκαιρα. Ενδεικτικά, οι

πτήσεις μπορούν να πραγματοποιηθούν στο στάδιο άνθησης, πριν τη συγκομιδή και κατά την ωρίμανση των καρπών. Σύμφωνα με τους Sarkosh et al. (2020) και με ένα τεχνικό δελτίο από το υπουργείο γεωργίας στην Αυστραλία, το ασφαλές ποσοστό προσβολής είναι μέχρι 30%, ενώ πάνω από 40% θεωρείται ως αρκετά υψηλής επικινδυνότητας.

2.4.2 Περίπτωση δεύτερη: Εσπεριδοειδή

Τα ΣμηΕΑ για τη διάγνωση ασθενειών έχουν χρησιμοποιηθεί αρκετά και στα εσπεριδοειδή. Ένα παράδειγμα αποτελεί η έρευνα των Garza et al. (2020), η οποία χρησιμοποίησε ένα ΣμηΕΑ με RGB κάμερα με σκοπό την παρακολούθηση της υγείας φυτών γκρέιπφρουτ, μελετώντας τις ασθένειες του πρασινίσματος (Huanglongbing) και φυτόφθορας (*Phytophthora foot and root rot*). Πραγματοποιήθηκε συσχέτιση του δείκτη TGI (Triangular greenness index) με τη θρεπτική κατάσταση των φυτών, τη φυλλική επιφάνεια, το πρασίνισμα των φύλλων (SPAD), τη φυτόφθορα και το πρασίνισμα (ασθένεια). Τα αποτελέσματα έδειξαν ότι τα εσπεριδοειδή μπορούν να παρακολουθηθούν με τη χρήση εξοπλισμένων ΣμηΕΑ με RGB κάμερες και ότι ο δείκτης TGI μπορεί να χρησιμοποιηθεί για τη διάγνωση ασθενειών σε δέντρα.

2.4.2.1 Αναγνώριση ασθενειών στα εσπεριδοειδή

Οι Abdulridha et al. (2019) εφάρμοσαν μία διαδικασία αναγνώρισης μέσω εικόνων που λήφθηκαν σε εργαστηριακές συνθήκες για την αναγνώριση βακτηριακής κηλίδωσης σε ένα ΣμηΕΑ το οποίο επαλήθευσε τα αποτελέσματα αναγνώρισης σε οπωρώνα μανταρινιών. Στο εργαστήριο αναπτύχθηκε ένα σύστημα εικόνων σε υπερφασματικό εύρος (400-1000nm) σε τρία στάδια, i) ασυμπτωματικό, ii) πρώιμο στάδιο και iii) όψιμο στάδιο σε φύλλα ποικιλίας Sugar Belle. Χρησιμοποίησαν δύο μεθόδους ταξινόμησης, οι οποίες ήταν η Radial Basis function (RBF) και ο αλγόριθμος KNN (K-nearest neighbor). Αφού ολοκληρώθηκε η ανάπτυξη του συστήματος, στη συνέχεια εφαρμόστηκε σε ΣμηΕΑ με σκοπό την αναγνώριση μολυσμένων δέντρων. Η μέθοδος RBF πέτυχε τα υψηλότερα ποσοστά αναγνώρισης (94%, 96% και 100% στα τρία στάδια). Από τη μελέτη 31 δεικτών βλάστησης, ο Water Index (WI) και ο Modified Chlorophyll Absorption in Reflectance Index πέτυχαν τα καλύτερα αποτελέσματα αναγνώρισης βακτηρίωσης σε συνθήκες εργαστηρίου και αγρού, αντίστοιχα.

Οι Chang et al. (2020) χρησιμοποίησαν εικόνες από ΣμηΕΑ για τον έγκαιρο εντοπισμό προσβολής του βακτηρίου *Candidatus liberibacter* (πρασίνισμα) σε πορτοκαλιές. Έπειτα από τη σύγκριση της κόμης μέσω του Canopy Height Model (CHM) και συγκεκριμένων δεικτών βλάστησης μεταξύ των δέντρων (Normalized Difference Vegetation Index "NDVI", Normalized Difference RedEdge "NDRE", Modified Soil Adjusted Vegetation Index "MSAVI" και Chlorophyll Index "CI") δημιουργήθηκαν blocks τα οποία αναγνώριζαν ποια δέντρα είναι θετικά και ποια αρνητικά στο πρασίνισμα. Το πείραμά τους έδειξε ότι οι καλύτεροι δείκτες για τον εντοπισμό πρασινίσματος ήταν ο NDRE και ο CI.

Οι Moriya et al. (2021) μελέτησαν 2 ξεχωριστά σύνολα δεδομένων από εικόνες ΣμηΕΑ για τον εντοπισμό κομμίσωσης εσπεριδοειδών (*Phytophthora spp.*, "Citrus gummosis")

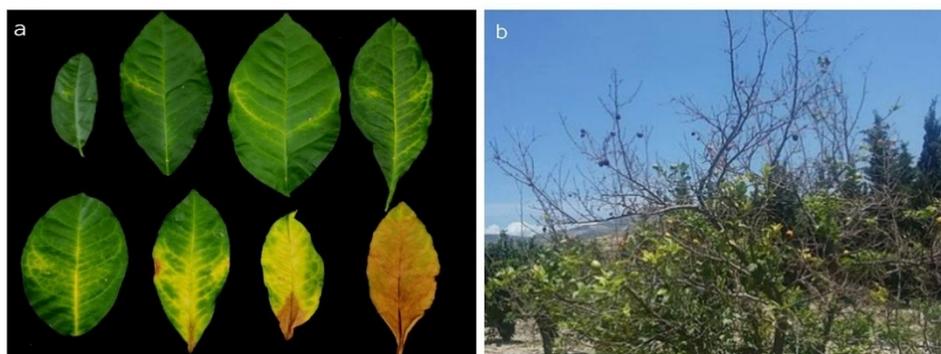
και συγκεκριμένα σε καλλιέργειες πορτοκαλιών. Το πρώτο σύνολο περιελάμβανε υπερφασματικές εικόνες που αποκτήθηκαν με έναν αισθητήρα 25 ζωνών, καλύπτοντας ένα φασματικό εύρος από 500 nm έως 840 nm και το δεύτερο αποτελούνταν από προσομοιωμένες εικόνες πολυφασματικού αισθητήρα 3 ζωνών. Τα αποτελέσματα έδειξαν ότι το πρώτο σύνολο με τις υπερφασματικές εικόνες κρίθηκε αποδοτικότερο από αυτό με τις πολυφασματικές. Οι πολυφασματικές πέτυχαν ακρίβεια 0.79 (F1-score=0.55) για τον χάρτη υγείας που δημιουργήθηκε, ενώ οι υπερφασματικές πέτυχαν ακρίβεια 0.94 (F1-score=0.85).

Οι Khattak et al. (2021) ανέπτυξαν ένα μοντέλο CNN χρησιμοποιώντας τις βάσεις δεδομένων Citrus και PlantVillage, με στόχο την αυτοματοποιημένη διάγνωση ασθενειών στα εσπεριδοειδή, όπως η μαύρη κηλίδωση (black spot), η βακτηριακή κηλίδωση (citrus canker), η κηλίδωση (citrus scab), το πρασίνισμα (greening) και η προσβολή από Melanose. Το σύνολο δεδομένων περιελάμβανε 2.293 εικόνες φρούτων και φύλλων με εμφανείς προσβολές. Οι συγγραφείς ανέφεραν ότι το μοντέλο πέτυχε ακρίβεια 95,65%, αλλά τόνισαν την ανάγκη βελτίωσης, καθώς τα σύνολα δεδομένων που χρησιμοποιήθηκαν περιείχαν περιορισμένο αριθμό εικόνων, γεγονός που αποτελεί έναν περιορισμό της μελέτης.

2.4.2.2 Στάδια πρώιμης αναγνώρισης κορυφοξήρας

Η κορυφοξήρα αποτελεί μύκητα καραντίνας και προκαλεί σοβαρές ζημιές στη λεμονιά, την κιτριά, τη νεραντζιά και το πέργαμο, σε αντίθεση με την πορτοκαλιά, τη μανταρινιά και το γκρέιπφρουτ, τα οποία είναι λιγότερη ευπαθή ως ξενιστές. Ο έγκαιρος εντοπισμός της είναι απαραίτητος γιατί προκαλεί τη σύντομη αποξήρανση των προσβεβλημένων δέντρων.

Η ασθένεια εκδηλώνεται με έναν απότομο μαρασμό, τη ξήρανση των φύλλων σε μερικούς βλαστούς και στη συνέχεια με κατευθυνόμενη αποξήρανση από τη κορυφή προς τα κάτω. Μπορεί επίσης να εκδηλωθεί και με πιο ήπιο τρόπο, ο οποίος είναι με τη χλώρωση ορισμένων φύλλων από βλαστούς. Αρχίζει από τις κύριες νευρώσεις, επεκτείνεται σε ολόκληρο το έλασμα και οι προσβεβλημένοι βλαστοί αποξηραίνονται και εμφανίζονται συνήθως με τη μορφή ημιπληγίας (δηλαδή στη μία πλευρά του δέντρου, Εικόνα 1.5.2-5). Τα συμπτώματα των νέων προσβολών εμφανίζονται συνήθως κατά τους μήνες Μάρτιο μέχρι Μάιο (Παναγόπουλος, 2007). Αξίζει να σημειωθεί ότι η κορυφοξήρα κατατάσσεται στις αδρομυκώσεις, όπου κύριο χαρακτηριστικό προσβολής είναι ο μεταχρωματισμός των αγγείων του ξύλου. Η είσοδος του παθογόνου στο αγγειακό σύστημα του δέντρου επηρεάζει τη μεταφορά θρεπτικών στοιχείων και νερού, προκαλώντας σταδιακή εξασθένιση και μαρασμό του φυτού. Επομένως, η επιτυχή πρώιμη αναγνώριση της κορυφοξήρας θα μπορούσε να γίνει πιο αποδοτική μέσω πολυφασματικών αισθητήρων και όχι μέσω RGB.



Εικόνα 1.5.2-5: Προσβολές από κορυφοξήρα εσπεριδοειδών. **(α):** Σταδιακή χλώρωση φύλλων λεμονιού ποικιλίας *volkameriana* από προσβολή κορυφοξήρας (Aiello et al., 2022), **(β):** Έντονη προσβολή κορυφοξήρας (με χαρακτηριστική ημιπληγία) σε λεμονιά (Πηγή: plantix.net).

2.4.2.3 Προτεινόμενα μέτρα για την αυτόματη διάγνωση κορυφοξήρας μέσω ΣμηΕΑ

Η πρώιμη αναγνώριση της κορυφοξήρας είναι αρκετά δύσκολη, καθώς όπως προαναφέρθηκε τα εξωτερικά συμπτώματα εκφράζονται αφού τα δέντρα έχουν μολυνθεί εσωτερικά (αγγειακά). Τα ΣμηΕΑ μπορούν να εντοπίσουν έντονες προσβολές από χλωρώσεις καθώς και συνθήκες έντονου υδατικού στρες μέσω πολυφασματικών καμερών. Είναι σημαντικό να ληφθεί υπόψη το ιστορικό της καλλιέργειας, η πιθανή ευαισθησία της στην κορυφοξήρα, καθώς και καλλιεργητικές τεχνικές που έχουν εφαρμοστεί για την αποφυγή της, όπως το σωστό κλάδεμα και η απομάκρυνση των προσβεβλημένων κλαδιών.

Τα πρώιμα στάδια της κορυφοξήρας μπορούν να συγχέονται με συμπτώματα που προκαλούνται από ελλείψεις θρεπτικών στοιχείων ή με άλλες ασθένειες όπως είναι η ανθράκωση (*Colletotrichum gloesporioides*), οι προσβολές από φυτόφθορα (*Phytophthora*), καθώς και με ζημιές που οφείλονται σε φυσικά φαινόμενα, όπως είναι ο παγετός, οι ισχυροί άνεμοι ή η ξηρασία. Για τον λόγο αυτό, είναι απαραίτητη μια λεπτομερής μελέτη πριν εξαχθούν συμπεράσματα, ώστε να αποφευχθούν λανθασμένες διαγνώσεις και ενέργειες.

Η πρώιμη αναγνώριση της κορυφοξήρας μέσω ΣμηΕΑ μπορεί να πραγματοποιηθεί το φθινόπωρο, τον χειμώνα ή την άνοιξη, ανάλογα με την πρωιμότητα ή οψιμότητα της ποικιλίας και το στάδιο ανάπτυξης της ασθένειας. Οι αλλαγές στο φάσμα NIR αποτελούν βασικό δείκτη, καθώς η υγιής βλάστηση παρουσιάζει υψηλή ανάκλαση, ενώ η μη-υγιής χαμηλή. Το ίδιο ισχύει και για τους δείκτες NDVI, που ανιχνεύουν μεταβολές στη φυτική υγεία. Θερμικές κάμερες μπορούν να εντοπίσουν αυξημένες θερμοκρασίες στην κόμη των δέντρων, καθώς η κορυφοξήρα όπως προαναφέρθηκε, επηρεάζει τη λειτουργία του αγγειακού συστήματος και διακόπτει τη διαδικασία της διαπνοής, οδηγώντας σε παρατηρήσεις θερμικής αύξησης. Με την πάροδο του χρόνου, πτήσεις με υψηλής ανάλυσης RGB και πολυφασματικές κάμερες μπορούν να εντοπίσουν τα πρώιμα στάδια χλωρώσεων στα φύλλα. Η παρακολούθηση δεικτών όπως NDVI και NDRE, σε

συνδυασμό με τον εντοπισμό θερμικών διαφορών (π.χ. θερμότερα κλαδιά σε σχέση με τον κορμό), προσφέρει σημαντικές ενδείξεις για την πρώιμη διάγνωση της κορυφοξήρας. Ενδεικτικά, οι πτήσεις για τον έγκαιρο εντοπισμό κορυφοξήρας μπορούν να πραγματοποιηθούν στα αρχικά στάδια ανάπτυξης των φύλλων και κατά τη διάρκεια διαμόρφωσης της κόμης των δένδρων.

2.4.3 Περίπτωση τρίτη: Αμπέλι

2.4.3.1 Αναγνώριση ασθενειών στο αμπέλι

Πολλές ασθένειες που επηρεάζουν την κατάσταση φυτικής υγείας των αμπελιών είναι υπεύθυνες για σημαντικά μεγάλες απώλειες αποδόσεων, αφού επηρεάζουν άμεσα την ποιότητα των παραγόμενων σταφυλιών. Το ωίδιο, ο βοτρύτης αλλά και η ίσκα είναι αρκετά σημαντικές ασθένειες αμπελιών, οι οποίες, αν δεν εντοπιστούν εγκαίρως μπορούν να οδηγήσουν σε σημαντικές οικονομικές απώλειες. Συγκεκριμένα, το ωίδιο αποτελεί μία πρόκληση για τους αμπελοπαραγωγούς με διάρκεια άνω των 150 χρόνων (Pirrello et al., 2019), αφήνοντας τα μολυσμένα πρέμνα να είναι επιρρεπή και σε άλλες μυκητολογικές ασθένειες (Gadoury et al., 2001). Ο βοτρύτης μειώνει σημαντικά την ποιότητα των πρέμνων δημιουργώντας σάπισμα με ανεπιθύμητες γεύσεις στα πρέμνα (Steel et al., 2013) και κατατάσσεται στις σημαντικότερες ασθένειες των αμπελιών (Williamson et al., 2007). Τέλος, η ασθένεια της ίσκας μπορεί να οδηγήσει σε σημαντικές μειώσεις αποδόσεων (Hofstetter et al., 2012) αν δεν εντοπιστεί εγκαίρως.

Την τελευταία δεκαετία η αυτοματοποιημένη αναγνώριση ασθενειών στο αμπέλι έχει τραβήξει αρκετά το ενδιαφέρον των ερευνητών. Η αυτοματοποιημένη διάγνωση των ασθενειών αυτών θα μπορούσε να συμβάλλει στον έγκαιρο εντοπισμό και συνεπώς, περιορισμό εξάπλωσής τους.

2.4.3.2 Αναγνώριση ασθενειών σε αμπέλι: Περίπτωση ωιδίου

Οι Pérez-Roncal et al. (2020) χρησιμοποίησαν υπερφασματικές εικόνες για την αναγνώριση ωιδίου (*Erysiphe necator*) σε 30 αμπέλια ποικιλίας Carignan Noir. Οι εικόνες λήφθηκαν σε φασματικό εύρος 900-1700nm μεταξύ 15 υγιών και μεταξύ 15 μολυσμένων αμπελιών. Η επεξεργασία που ακολουθήθηκε, πραγματοποιήθηκε για την εξαγωγή των φασματικών και χωρικών παραμέτρων της εικόνας και έπειτα, δημιουργήθηκαν μοντέλα ταξινόμησης Partial Least Squares Discriminant Analysis (PLS-DA). Ο καλύτερος συνδυασμός διάκρισης των μολυσμένων στελεχών επιτεύχθηκε μέσω PLS-DA, smoothing (SM), Standard Normal Variate (SNV) και mean-centering (MC) με ποσοστό ακριβείας 85,33%.

Οι Vélez et al. (2024) εφάρμοσαν φασματοσκοπία εύρους 350-2500nm για τον έγκαιρο εντοπισμό ωιδίου σε φύλλα αμπελώνα, κατά τη διάρκεια Ιουλίου έως και Σεπτεμβρίου. Τα αποτελέσματα στατιστικής ανάλυσης μέσω της μεθόδου Partial Least Squares Regression (PLSR) έδωσαν $R^2=0,74$, υποδεικνύοντας υψηλή ακρίβεια για την έγκαιρη διάγνωση ωιδίου. Σημαντικές διαφορές σημειώθηκαν μεταξύ υγιών και μολυσμένων φύλλων, ειδικά στα 450nm και 700nm για το ορατό φως και στα 1050 nm, 1425 nm,

1650 nm και 2250 nm για το κοντινό υπέρυθρο φάσμα. Αυτό σημειώθηκε λόγω της βλάβης που προκλήθηκε στον ιστό των φυτών, στην αποδόμηση της χλωροφύλλης και στην απώλεια νερού λόγω του ωιδίου.

Στάδια πρώιμης αναγνώρισης ωιδίου

Το ωίδιο αποτελεί μία από τις σημαντικότερες ασθένειες της αμπέλου και είναι αρκετά διαδεδομένη. Μπορεί να εκφραστεί σε όλα τα μέρη της αμπέλου (βλαστοί, φύλλα, κλαδιά, τσαμπιά), με αρχικό στάδιο τα φύλλα, στα οποία εμφανίζονται ακανόνιστης μορφής χλωρωτικές κηλίδες, οι οποίες καλύπτονται στη συνέχεια με λευκό χνούδι. Παρόμοια συμπτώματα σχηματίζονται στα φύλλα και στους βότρες. Αν η προσβολή γίνει πριν την άνθιση, τότε παρατηρείται το φαινόμενο της ανθόρροιας. Οι ράγες του σταφυλιού καλύπτονται και αυτές από τη λευκή εξάνθηση στα σημεία προσβολής.



Εικόνα 1.5.2-6: Προσβολές από ωίδιο αμπέλου σε διαφορετικά μέρη. **(a):** Χλωρωτικές κηλίδες ακανόνιστης μορφής σε φύλλο (Πηγή: graithros.gr), **(b):** Προσβολή ωιδίου προκαλεί σχίσσιμο των ραγών (Πηγή: kalliergo.gr), **(c):** Προχωρημένο στάδιο προσβολής ωιδίου σε φύλλα όπου οι χλωρωτικές κηλίδες έχουν καλυφθεί από λευκό χνούδι (Πηγή: agroclica.gr), **(d):** Ράγες έχουν καλυφθεί από λευκό χνούδι ωιδίου (Πηγή: kalliergo.gr).

Προτεινόμενα μέτρα για την αυτόματη διάγνωση ωιδίου μέσω ΣμηΕΑ

Όπως φαίνεται και από την Εικόνα 1.5.2-6, τα πρώιμα στάδια έκφρασης του ωιδίου ξεκινούν από τα φύλλα. Με την έναρξη της βλάστησης του αμπελιού (περίπου την άνοιξη, ανάλογα με την πρωιμότητα ή οψιμότητα της ποικιλίας), ξεκινά και η ανάπτυξη του μύκητα. Στα αρχικά στάδια της ασθένειας παρατηρείται ότι η χλωροφύλλη δεν εκφράζεται κανονικά λόγω των αλλοιώσεων στα φύλλα (Εικόνες 1.5.2-6.a, 1.5.2-6.b). Έτσι, πτήσεις ΣμηΕΑ θα μπορούσαν να ανιχνεύσουν τη μειωμένη περιεκτικότητα σε χλωροφύλλη χρησιμοποιώντας τον δείκτη CI (Chlorophyll Index), αλλά και κάποιον σχετικό με την υγρασία όπως είναι ο NDWI (Normalized Difference Water Index), καθώς η μόλυνση από το ωίδιο προκαλεί εμφανείς διαφορές σε αυτές τις δύο παραμέτρους λόγω της ζημιάς που προκαλείται στον ιστό (Vélez et al., 2024).

Αξίζει να σημειωθεί, ότι η χλωροφύλλη μπορεί να εκτιμηθεί μέσω του ορατού φάσματος, ενώ τα ποσοστά υγρασίας, μέσω του κοντινού-υπέρυθρου. Επομένως, απαιτούνται σίγουρα μία RGB κάμερα και μία πολυφασματική. Οι πτήσεις μπορούν να

επαναλαμβάνονται σε όλα τα στάδια ανάπτυξης του αμπελιού, παρέχοντας έτσι συνεχή παρακολούθηση. Επιπλέον, οι Vélez et al. (2024) μελέτησαν συγκεκριμένα τον εντοπισμό του ωιδίου μέσω ΣμηΕΑ, δημιουργώντας τον δείκτη PMVI, ο οποίος μπορεί να χρησιμοποιηθεί για τον έγκαιρο εντοπισμό.

Επιπλέον, μια υψηλής ανάλυσης κάμερα RGB μπορεί να βοηθήσει στον έγκαιρο εντοπισμό των ακανόνιστων χλωρωτικών κηλίδων (Εικόνα 1.5.2-6), που είναι χαρακτηριστικές για την αναγνώριση ωιδίου. Αξίζει να σημειωθεί ότι σε ερυθρές ποικιλίες, ο δείκτης ARI (Anthocyanin Reflectance Index) μπορεί επίσης να αξιοποιηθεί για την ανίχνευση μη φυσιολογικών επιπέδων ανθοκυανίνης στις ράγες. Ανωμαλίες στα επίπεδα ανθοκυανίνης μπορούν να είναι σημάδι για μη-ομαλή ανάπτυξη, πιθανώς λόγω εμφάνισης κάποιας ασθένειας όπως είναι το ωίδιο.

2.4.3.3 Αναγνώριση ασθενειών σε αμπέλι: Περίπτωση βοτρυτή

Οι Vélez et al. (2023a) δημιούργησαν ένα σύνολο δεδομένων από 16.504 πολυφασματικές εικόνες που λήφθηκαν από ΣμηΕΑ, με σκοπό την αναγνώριση της ασθένειας του βοτρυτή (*Botrytis cinerea*) σε έναν μολυσμένο αμπελώνα μεγέθους 1,06 εκταρίων. Οι εικόνες ήταν ύψους 30 μέτρων με πολλαπλές γωνίες λήψης (η πρώτη πτήση σε γωνία 0°, η δεύτερη σε 30°, η τρίτη σε 45° και η τέταρτη σε γωνία 0° σε απογευματινή ώρα). Το σύνολο δεδομένων αυτό δημιουργήθηκε για να βοηθήσει ερευνητές παρόμοιου αντικειμένου, με σκοπό την αυτοματοποιημένη αναγνώριση βοτρυτή σε αμπελώνες. Βασισμένοι στην ίδια έρευνα, οι Vélez et al. (2023b) χρησιμοποίησαν εικόνες από ΣμηΕΑ για την πρόβλεψη ρίσκου μόλυνσης αμπελώνα από την ασθένεια του βοτρυτή (*Botrytis cinerea*). Μέσω των πολυφασματικών εικόνων που λήφθηκαν, δημιουργήθηκε το DTM (Digital Terrain Model), το CHM (Canopy Height Model) και οι δείκτες βλάστησης NDVI και LAI (Leaf Area Index), τα οποία συνδυαστικά αντιπροσωπεύουν την τοπογραφία, την κατάσταση υγείας καθώς και το ύψος και αρχιτεκτονική της κόμης των δέντρων. Τα υγιή αμπέλια διέφεραν σημαντικά από τα μολυσμένα με βοτρυτή (με $p < 0.05$). Αξίζει να σημειωθεί ότι η μεθοδολογία που χρησιμοποιήθηκε συνδυάζει φωτογραμμετρικές και χωρικές τεχνικές αναλύσεων με μεθόδους ταξινόμησης μέσω μηχανικής μάθησης και εμβάθυνση γνώσεων αγρονομικού περιεχομένου με σκοπό την παραγωγή θερμοχάρτων (heatmaps) επιτρεπτής ακριβείας ($R^2 > 0.7$).

Οι Ariza-Sentís et al. (2023) δημιούργησαν στο πλαίσιο του προγράμματος Flexigrobots, το πρώτο διαθέσιμο open-source σύνολο δεδομένων που περιλαμβάνει πολυφασματικές εικόνες από ΣμηΕΑ για την αναγνώριση του βοτρυτή σε πρώιμα στάδια σε αμπέλι. Τα δεδομένα τους περιέχουν 153 φυτά (91 υγιή και 62 μολυσμένα) και το μοντέλο που ανέπτυξαν σημείωσε ποσοστό επιτυχούς αναγνώρισης 70%.

Οι Bélanger et al. (2011) χρησιμοποίησαν φθορισμό για τον εντοπισμό του μορίου resveratrol (ρεσβερατρόλη) στα αμπέλια, ενός παράγωγου του σπιλβενίου με χαρακτηριστικό μπλε χρώμα. Η ρεσβερατρόλη παράγεται από τα αμπέλια ως αμυντικός μηχανισμός ενάντια σε ασθένειες όπως ο βοτρυτής. Μέσω φθορισμού, οι ερευνητές κατάφεραν να ανιχνεύσουν την ασθένεια σε πρώιμα στάδια. Μετά τη μόλυνση των αμπελιών, ο φθορισμός εντόπισε τη ρεσβερατρόλη μόλις 4 μέρες μετά τη μόλυνση (DAI - Days After Inoculation). Επιπλέον, με ανάλυση εικόνων και εντοπισμό ακμών μέσω

UV-epidermal transmittance στα 690 nm, η διάγνωση της μόλυνσης ήταν εφικτή εντός μόλις 6 ωρών μετά τη μόλυνση.

Στάδια πρώιμης αναγνώρισης βοτρυτή

Ο βοτρυτής προσβάλλει όλα τα πράσινα υπέργεια μέρη του πρέμνου, αλλά οι σημαντικότερες ζημιές που προκαλεί είναι λίγο πριν και μετά από τη συγκομιδή (προ και μετασυλλεκτικές σήψεις). Η πιο σοβαρή ζημιά εκδηλώνεται το φθινόπωρο (ή προς τέλος Αυγούστου, αλλά εξαρτάται από την επιλεγμένη ποικιλία), όταν πλησιάζει η ωρίμανση. Στις ράγες εμφανίζεται μία διάχυτη καστανή κηλίδα, η οποία εκτείνεται σε έκταση και σε βάθος. Η ράγα χάνει τη γυαλιστερή της σάρκα και αργότερα, γίνεται επέκταση της προσβολής σε όλη τη σάρκα, στην οποία δημιουργείται μια μαλακή και υδαρής σήψη (Εικόνα 1.5.2-7).



Εικόνα 1.5.2-7: Προσβολές από βοτρυτή αμπέλου σε διαφορετικά μέρη και στάδια ανάπτυξης. **(a):** Προσβολή σε βλαστό (*plantpro.gr*), **(b):** Μολυσμένα άνθη αμπελιού από βοτρυτή (*plantpro.gr*), **(c):** Εμφανής προσβολή βοτρυτή σε πρέμνο (Πηγή: *kalliergo.gr*).

Προτεινόμενα μέτρα για την αυτόματη διάγνωση βοτρυτή μέσω ΣμηΕΑ

Για την κατάλληλη αντιμετώπιση του βοτρυτή, είναι σημαντική η παρακολούθηση του αμπελώνα στο στάδιο της άνθισης. Είναι το πιο επιρρεπές στάδιο γιατί “σκίζεται” το άνθος με σκοπό την έναρξη ανάπτυξης του πρέμνου. Τα ΣμηΕΑ θα μπορούσαν να χρησιμοποιηθούν για την παρακολούθηση της κατάστασης υγείας του αμπελώνα στο στάδιο αυτό, με σκοπό την εύρεση μειωμένων τιμών από πχ. τον δείκτη NDVI, οι οποίες μπορούν να οφείλονται σε προσβολή από βοτρυτή, NDRE λόγω χαμηλότερης ανάκλασης λόγω προσβολής, αλλά και του δείκτη NDWI, καθώς προσβολές από βοτρυτή μπορούν να αναδείξουν χαμηλότερες τιμές. Ο βοτρυτής είναι σημαντικό να εντοπιστεί όσο νωρίτερα γίνεται, γιατί στο στάδιο προσβολής των πρέμνων (Εικόνα 1.5.2-7.c) είναι αργά για να αντιμετωπιστεί και ισχύει ότι όταν η συμπτωματολογία είναι εμφανής, τότε είναι αργά για πρώιμο εντοπισμό (Ariza-Sentís et al., 2023).

Για τον αυτοματοποιημένο εντοπισμό βοτρυτή, η παρακολούθηση μέσω ΣμηΕΑ οφείλει να γίνει στο στάδιο όψιμης ανάπτυξης των ραγών, μέχρι στο στάδιο της συγκομιδής. Η χρήση θερμικής κάμερας μπορεί επίσης να εντοπίσει θερμικές αλλαγές στο αγγειακό σύστημα των αμπελιών (ξύλο), εντοπίζοντας διαφορές στη θερμοκρασία του φυτού και ενδεχομένως τέτοιες αλλαγές να υποδεικνύουν κάποιο είδους στρες, λόγω προσβολής

από βοτρυτή. Θα μπορούσε επίσης να χρησιμοποιηθεί ως επαλήθευση και το open-source σύνολο δεδομένων που δημιουργήθηκε από τους Ariza-Sentís et al. (2023), το οποίο είναι σχεδιασμένο για την πρώιμη αναγνώριση βοτρυτή σε αμπέλια.

2.4.3.4 Αναγνώριση ασθενειών σε αμπέλι: Περίπτωση ίσκας

Οι Di Gennaro et al. (2016) πρότειναν μία μεθοδολογία η οποία χρησιμοποιήθηκε για τη διερεύνηση σχέσεων μεταξύ πολυφασματικών εικόνων υψηλής ανάλυσης (0.05m/pixel) μέσω ΣμηΕΑ με δεδομένα μελέτης πεδίου (ground truth data) από φύλλα που έχουν προσβληθεί από GLSD (Grapevine Leaf Stripe Disease), η οποία είναι αποτέλεσμα της ασθένειας ίσκας (*Fomitiporia mediterranea*, "Esca"). Η λήψη των εικόνων έγινε μεταξύ Ιούνη-Ιούλη του 2012 και 2013, σε ένα πειραματικά μολυσμένο αγρό με βοτρυτή στην Τοσκάνη (Ιταλία). Η έρευνά τους έδειξε ότι υπήρξε υψηλή συσχέτιση του δείκτη NDVI που λήφθηκε από το ΣμηΕΑ και τα συμπτώματα φύλλων με GLSD και συνεπώς, μεγάλη διαφοροποίηση μεταξύ των συμπτωματικών και ασυμπτωματικών φυτών.

Οι Kerkech et al. (2018) εφάρμοσαν μία νέα τεχνική ανίχνευσης ίσκας σε αμπέλια, μέσω χρήσης εικόνων RGB που λήφθηκαν μέσω ΣμηΕΑ. Χώρισαν την κάθε εικόνα σε 3 διαφορετικές διαστάσεις pixel (16 x 16, 32 x 32 και 64 x 64), με σκοπό την ταξινόμηση του κάθε "block" σε υγιές ή ασθενές. Τα καλύτερα αποτελέσματα σημειώθηκαν με τον συνδυασμό των ExR, ExG και ExGR δεικτών βλάστησης σε ανάλυση 16 x 16, με ποσοστό 95.80%, αλλά και με τον συνδυασμό YUV color space με τον δείκτη βλάστησης ExGR στην ανάλυση 32 x 32 και 64 x 64.

Στάδια πρώιμης αναγνώρισης ίσκας

Τα αμπέλια που έχουν προσβληθεί εμφανίζουν τις χαρακτηριστικές "ρίγες τίγρη" (κοινώς και "φύλλα τίγρη") στο φύλλωμά τους, καθόλη την καλλιεργητική περίοδο, με τις πιο έντονες προσβολές να εμφανίζονται το καλοκαίρι και συγκεκριμένα τους μήνες Ιούλιο και Αύγουστο. Τα προσβεβλημένα φύλλα εμφανίζουν αυτές τις ρίγες χαρακτηριστικού χρώματος, και πιο συγκεκριμένα στις ερυθρές ποικιλίες είναι κόκκινου χρώματος ενώ στις λευκές είναι κίτρινου. Τα φύλλα που είναι συμπτωματικά ξεραίνονται και αποκόπτονται πρόωρα. Όσον αφορά την προσβολή στα πρέμνα, δημιουργούνται μικρές, κυκλικές κηλίδες σκούρου χρώματος, οι οποίες περιβάλλονται από ένα δαχτυλίδι χρώματος καφέ-μωβ.

Τα συμπτώματα προσβολής μπορούν να ξεκινάνε από τα φύλλα, στα οποία έχει παρατηρηθεί ότι υπάρχει μείωση στην αφομοίωση του CO₂, σημαντική αύξηση στη μεσοκυττάρια συγκέντρωση CO₂, μείωση στα επίπεδα φθορισμού αλλά και μείωση της συνολικής χλωροφύλλης (Petit et al., 2006).

Εμφανίζεται κυρίως σε ενήλικα πρέμνα, με το συχνότερο εσωτερικό σύμπτωμα της ασθένειας να είναι η λευκή σήψη του ξύλου, η οποία σταδιακά μετατρέπει το σκληρό ξύλο σε μαλακή, σπογγώδη μάζα. Τα συμπτώματα της ίσκας μοιάζουν και με συμπτώματα άλλων αιτιών, όπως είναι οι αδρομυκώσεις, οι τροφοπενίες και οι σηψιρριζίες, και για αυτό τα εξωτερικά στοιχεία δεν είναι επαρκή για τη διάγνωση της προσβολής χωρίς την εσωτερική εξέταση του κορμού (Εικόνα 1.5.2-8).



Εικόνα 1.5.2-8: Προσβολές από ίσκα αμπέλου σε διαφορετικά μέρη. **(α):** Προσβολή ίσκας σε λευκή ποικιλία (Viret & Gindro, 2024), **(β):** Προσβολή ίσκας σε ερυθρή ποικιλία αμπέλου (Viret & Gindro, 2024), **(γ):** Τομή αμπελιού με χαρακτηριστική προσβολή ίσκας (Πηγή: *evineyardapp.com*).

Προτεινόμενα μέτρα για την αυτόματη διάγνωση ίσκας μέσω ΣμηΕΑ

Για τον αποτελεσματικό εντοπισμό της ίσκας σε αμπέλια μέσω της χρήσης ΣμηΕΑ, πρέπει να ληφθούν αρκετά μέτρα υπόψη, καθώς όπως αναφέρθηκε, τα συμπτώματα της συχνά μπερδεύονται με συμπτώματα άλλων παραγόντων και ασθενειών. Επιπλέον, οι παράγοντες συμπτωμάτων δεν έχουν καθοριστεί τελείως αφού πρόκειται για μία ασθένεια η οποία οφείλεται σε σύμπλοκο παθογόνων, και όχι μόνο ενός. Σύμφωνα με τον Παναγόπουλο (2007), η συμπτωματολογική εικόνα των φύλλων οφείλεται στη δράση φαινολικών και άλλων τοξικών ουσιών που παράγονται από τα εμπλεκόμενα παθογόνα αλλά και από το φυτό ως αντίδραση στην προσβολή, και έτσι, μεταφέρονται στα φύλλα μέσω της εξατμισοδιαπνοής.

Επομένως, η διάγνωση της ίσκας μέσω ΣμηΕΑ αποτελεί μια αρκετά απαιτητική διαδικασία. Προληπτικά όμως, πτήσεις με ΣμηΕΑ θα μπορούσαν να πραγματοποιηθούν με σκοπό τον εντοπισμό της κατάστασης υγείας των ξύλων των αμπελιών, μέσω, για παράδειγμα, θερμικής κάμερας. Ο εντοπισμός μη ομαλών ποσοστών θερμοκρασίας στο ξύλο μπορεί να υποδεικνύει κάποια μόλυνση στο εσωτερικό σύστημα. Επιπλέον, κάτι που είναι ακόμα υπό διερεύνηση αποτελεί ο εντοπισμός των μεταβολών στα φαινολικά οξέα, το οποίο ενδεχομένως να μπορούσε να εντοπιστεί μέσω πτήσεων ΣμηΕΑ εξοπλισμένων με πολυφασματική κάμερα. Για παράδειγμα, οι Song et al. (2024) χρησιμοποίησαν πολυφασματικές εικόνες παρμένες από ΣμηΕΑ για τον εντοπισμό των φαινολικών συνθέσεων σε κόμεις από πεύκη. Ταυτόχρονα, μπορούν να εφαρμοστούν πτήσεις με σκοπό την παρακολούθηση της υγείας του αμπελώνα με τους δείκτες NDVI και NDRE. Οι Di Gennaro et al. (2016) βρήκαν ότι μεταβολές του δείκτη NDVI υποδεικνύουν μόλυνση από ίσκα, χωρίς ακόμα να έχει ορατά συμπτώματα στο αμπέλι. Ο εντοπισμός της προσβολής στο στάδιο των φύλλων σημαίνει ότι είναι αργά για κάποια επέμβαση, καθώς η ίσκα είναι μία ασθένεια η οποία χρειάζεται χρόνια για να εκδηλωθεί. Όσο το δυνατόν νωρίτερα εντοπιστεί στο στάδιο "επάσης" στο ξύλο, τόσο πιο αποδοτική πρόκειται να είναι η αντιμετώπισή της.

2.5 Επιθυμητά χαρακτηριστικά και ιδιότητες δεδομένων ανάπτυξης μοντέλων

Στην προηγούμενη ενότητα αναφέρθηκαν τα σημαντικότερα προβλήματα που σχετίζονται με την αυτοματοποιημένη διάγνωση ασθενειών μέσω ΣμηΕΑ. Σε αυτή την Ενότητα, θα αναλυθούν τα συγκεκριμένα προβλήματα και θα προταθούν συγκεκριμένες λύσεις μέσω των οποίων θα προκύψουν τα επιθυμητά χαρακτηριστικά και οι ιδιότητες που θα πρέπει να έχουν τα δεδομένα εκπαίδευσης και δοκιμής των μοντέλων αυτοματοποιημένης αναγνώρισης ασθενειών σε ΣμηΕΑ, με απώτερο στόχο την ουσιαστική εφαρμογή των συστημάτων αυτών σε πραγματικές συνθήκες στον αγρό, σε όσο το δυνατόν μεγαλύτερο εύρος περιβαλλοντικών συνθηκών στο πεδίο.

2.5.1 Συνθήκες λήψης της εικόνας

Όπως αναφέρθηκε, οι συνθήκες λήψης της εικόνας επηρεάζουν σε μεγάλο βαθμό τα αποτελέσματα αναγνώρισης. Προβλήματα όπως η κατοπτρική ανάκλαση, η παρουσία σκιών, ο άμεσος φωτισμός αλλά και η γωνία λήψης μπορούν να μειώσουν αρκετά τη ποιότητα της εικόνας.

Το πρόβλημα της κατοπτρικής ανάκλασης μπορεί να μειωθεί με την πραγματοποίηση πτήσεων νωρίς το πρωί. Οι σκιές και ο άμεσος φωτισμός είναι συχνά αναπόφευκτα φαινόμενα, αλλά υπάρχουν αρκετές μέθοδοι για την αντιμετώπισή τους. Για παράδειγμα, θα βοηθούσε η επέκταση του μεγέθους του συνόλου δεδομένων με την προσθήκη περισσότερων εικόνων, η χρήση πολωτικών φίλτρων στην κάμερα, καθώς και οι εφαρμογές διαδικασιών επεξεργασίας εικόνας (post-processing), όπως η αφαίρεση σκιών, η εξισορρόπηση και η κανονικοποίηση ιστογράμματος. Όσον αφορά τη γωνία λήψης, θα ήταν χρήσιμο να πραγματοποιείται κάποια προκαταρκτική μελέτη πριν από κάθε πτήση, με στόχο την εύρεση και επιλογή της ιδανικότερης γωνίας λήψης. Για παράδειγμα, η έρευνα των Oberti et al. (2014) έδειξε ότι μια γωνία λήψης 40-60° από ΣμηΕΑ είναι ιδανική για την αναγνώριση του ωιδίου σε αμπέλια.

2.5.2 Το παρασκήνιο εικόνας (image background)

Το παρασκήνιο μιας εικόνας είναι κρίσιμο για τη διάκριση των στοιχείων που περιέχει, με κύριο στόχο την αναγνώριση των φυτών και την πρώιμη ανίχνευση οπτικών συμπτωμάτων. Για να εξασφαλιστεί ένα "αρμονικό" παρασκήνιο χωρίς αντιπερισπασμούς, είναι απαραίτητο να προηγηθούν καλλιεργητικές φροντίδες όπως η αφαίρεση ζιζανίων, ώστε η εικόνα να επικεντρώνεται στο καλλιεργούμενο φυτό.

Επιπλέον, η ανάπτυξη εξειδικευμένων αλγορίθμων για την αφαίρεση ή την αγνόηση του παρασκηνίου μπορεί να συμβάλει στην επίλυση του προβλήματος για τα περίπλοκα παρασκήνια στις εικόνες. Η μελέτη των Kamal et al. (2021) εστίασε στην αφαίρεση παρασκηνίου από εικόνες φύλλων, προκειμένου να καθοριστεί η καλύτερη περιοχή ενδιαφέροντος, που στην περίπτωση αυτή ήταν τα φύλλα από διαφορετικά καλλιεργούμενα φυτά.

2.5.3 Κατάλληλη ταξινόμηση ασθενειών

Η ορθή ταξινόμηση ασθενειών στις εικόνες των συνόλων δεδομένων εκπαίδευσης των μοντέλων έχει παρουσιάσει αρκετά προβλήματα, με κυριότερο τη δυσκολία στη λήψη αποφάσεων για την κατάταξη μιας συγκεκριμένης ασθένειας. Μία λύση για το ζήτημα της ορθής ταξινόμησης, είναι η συνεχής επίβλεψη από ειδικούς του κλάδου της φυτοπαθολογίας. Με αυτόν το τρόπο θα μειωθούν οι λανθασμένες αναγνωρίσεις ασθενειών και θα υπάρχει υψηλότερο ποσοστό ακρίβειας όσον αφορά την εκπαίδευση του μοντέλου. Επιπλέον, η αύξηση του μεγέθους του συνόλου δεδομένων αποτελεί καθοριστικό παράγοντα για τη βελτίωση της ποιότητας των αποτελεσμάτων, καθώς επιτρέπει την καλύτερη εκπαίδευση των μοντέλων και, συνεπώς, την επίτευξη υψηλότερης ακρίβειας και ποσοστών αναγνώρισης.

2.5.4 Παράμετροι ΣμηΕΑ για κατάλληλη λήψη εικόνων

Πριν από κάθε πτήση, είναι απαραίτητο να μελετηθεί επαρκώς η καλλιέργεια που θα εξεταστεί, η ασθένεια που πρόκειται να εντοπιστεί, καθώς και η περιοχή ενδιαφέροντος. Οι πτήσεις σε χαμηλό υψόμετρο μπορούν να παρέχουν εικόνες υψηλής χωρικής ανάλυσης με περισσότερες λεπτομέρειες, αλλά ενδέχεται να δημιουργήσουν προβλήματα αλληλοεπικάλυψης. Για την αντιμετώπιση αυτού του προβλήματος, οι πτήσεις μέσω ΣμηΕΑ πρέπει να πραγματοποιούνται με επαναλήψεις, χρησιμοποιώντας διαφορετικές παραμέτρους ύψους και ταχύτητας, ώστε να εξασφαλίζεται η συλλογή πολλαπλών και ποικίλων εικόνων υψηλής λεπτομέρειας.

Ένα επιπλέον ζήτημα που προκύπτει από τη συλλογή μεγάλου αριθμού εικόνων είναι η διαχείριση της κατανάλωσης της μπαταρίας και του αποθηκευτικού χώρου. Ο χειριστής θα πρέπει να διαθέτει αρκετές εφεδρικές μπαταρίες και να σχεδιάσει τη διαδρομή της πτήσης με τέτοιο τρόπο ώστε να αποφεύγονται κενά στη λήψη εικόνων του αγρού. Επιπλέον, είναι απαραίτητη η χρήση καρτών αποθήκευσης με μεγάλη χωρητικότητα για τη διασφάλιση της αποθήκευσης όσο το δυνατόν περισσότερων δεδομένων.

2.5.5 Διαθεσιμότητα συνόλων δεδομένων

Η διαθεσιμότητα συνόλων δεδομένων αποτελεί ένα από τα σημαντικότερα προβλήματα όσον αφορά την επεξεργασία δεδομένων που συλλέγονται μέσω ΣμηΕΑ. Στις περισσότερες περιπτώσεις, οι εικόνες που περιλαμβάνονται σε ένα σύνολο δεδομένων είναι περιορισμένες σε αριθμό, ενώ πολλές από αυτές είναι κακής ποιότητας, γεγονός που οδηγεί σε μη ικανοποιητικά αποτελέσματα και συνεπώς, ελλιπή εκπαίδευση του μοντέλου. Η βάση δεδομένων μπορεί να εμπλουτιστεί εάν ο χειριστής, σε συνεργασία με τον γεωπόνο, οργανώσουν πτήσεις που διασφαλίζουν καθαρές και ευκρινείς εικόνες, σε μεγάλη ποικιλία διαφορετικών, καθαρών και ταυτόχρονα με επαρκή αριθμό εικόνων. Η προετοιμασία της πτήσης, η μελέτη της καλλιέργειας, η χρήση επιπλέον μπαταριών για την πραγματοποίηση περισσότερων πτήσεων, καθώς και η επαρκής χωρητικότητα

αποθήκευσης για τις εικόνες, μπορούν να συμβάλλουν σημαντικά στη δημιουργία ενός ολοκληρωμένου και επαρκούς συνόλου δεδομένων.

Σύμφωνα με τη σχετική βιβλιογραφική ανασκόπηση των Zhou et al. (2024), θα ήταν αρκετά ενδιαφέρον αν θα μπορούσε να γίνει μία "συγχώνευση" διαθέσιμων δεδομένων και εικόνων από διαφορετικούς αισθητήρες (RGB, NIR, multi-hyperspectral) για διαφορετικές ασθένειες. Λόγω της περιορισμένης διαθεσιμότητας, μια τέτοια συγχώνευση (multi-source data fusion) θα μπορούσε να χρησιμοποιήσει τα διαφορετικά χαρακτηριστικά και πλεονεκτήματα διαφορετικών αισθητήρων και να συμβάλλει στην παρακολούθηση και ανάλυση διαφορετικών σταδίων ανάπτυξης μιας καλλιέργειας, έτσι ώστε να εντοπιστούν νέες λύσεις ασθενειών στο ίδιο φάσμα (same spectrum of foreign matter) αλλά και σε διαφορετικά φάσματα (same substance, different spectrum).

2.5.6 Διαθεσιμότητα αισθητήρων

Το πρόβλημα της διαθεσιμότητας αισθητήρων αποτελεί ένα διαρκές ζήτημα για την πραγματοποίηση πτήσεων με χαμηλό κόστος. Η υψηλή ευαισθησία ενός αισθητήρα συνδέεται άμεσα με αυξημένο κόστος, γεγονός που καθιστά αυτή τη λύση λιγότερο προσιτή για το ευρύ κοινό. Από την άλλη, οι RGB κάμερες έχουν αποδειχθεί ως μια οικονομική και εύκολα εφαρμόσιμη επιλογή.

Μία πιθανή λύση θα μπορούσε να είναι η εξέλιξη της τεχνολογίας των RGB καμερών και η περαιτέρω διερεύνηση της χρήσης τους για την αυτοματοποιημένη διάγνωση ασθενειών σε φυτά μέσω ΣμηΕΑ. Επιπλέον για μεγάλες εκτάσεις καλλιέργειών, τα αποτελέσματα μπορούν να επαληθευτούν μέσω της αξιοποίησης δωρεάν δορυφορικών δεδομένων, όπως αυτά που παρέχονται από τις πλατφόρμες Landsat και Copernicus, οι οποίες διαθέτουν δωρεάν μεν δορυφορικές εικόνες αλλά με χαμηλότερη ακρίβεια χωρικής ανάλυσης, που μπορεί να επηρεάσει την επιθυμητή ανίχνευση ασθενειών φυτών.

2.5.7 Άλλα προβλήματα

Η χρήση ΣμηΕΑ έχει διευκολύνει σημαντικά τους παραγωγούς, προσφέροντας αποτελεσματικότητα και ακρίβεια. Ωστόσο, για την ομαλή καταγραφή δεδομένων και την επιτυχή διεξαγωγή πτήσεων, είναι απαραίτητη η τήρηση συγκεκριμένων προδιαγραφών. Ο πιλότος οφείλει να συμμορφώνεται με τους κανονισμούς που ορίζει η Υπηρεσία Πολιτικής Αεροπορίας (ΥΠΑ), ανεξαρτήτως του σκοπού της πτήσης.

Ένα αναπόφευκτο πρόβλημα είναι το υψηλό κόστος εφαρμογής των πτήσεων, το οποίο περιλαμβάνει την ανάγκη καταρτισμένου τεχνικού προσωπικού και εξειδικευμένου εξοπλισμού. Προς το παρόν, η συγκεκριμένη υπηρεσία παραμένει μη προσβάσιμη για αγρότες μικρής κλίμακας. Η επιχορήγηση μικρών παραγωγών θα μπορούσε να συμβάλλει καθοριστικά στην ενίσχυση της βιωσιμότητάς τους. Μια προσωρινή λύση θα μπορούσε να είναι η υλοποίηση επιδοτούμενων προγραμμάτων.

3 ΣΥΝΟΨΗ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ

Η βιβλιογραφική ανάλυση επιβεβαιώνει ότι η αυτοματοποιημένη αναγνώριση ασθενειών σε φυτά μέσω RGB εικόνων από ΣμηΕΑ αποτελεί ένα ταχέως εξελισσόμενο πεδίο, το οποίο τα τελευταία χρόνια μεταβαίνει από καθαρά πειραματικά/εργαστηριακά πλαίσια σε εφαρμογές πραγματικών συνθηκών στον αγρό. Ιστορικά, μεγάλο μέρος των δημοσιευμένων εργασιών βασίστηκε σε εργαστηριακές ή ημι-ελεγχόμενες εικόνες (με απομονωμένα φύλλα, ομοιογενείς συνθήκες φωτισμού και απουσία παρασκηνίου), γεγονός που οδήγησε σε υψηλές αναφερόμενες επιδόσεις αλλά περιορισμένη πρακτική χρησιμότητα. Μόλις τα τελευταία 4–5 χρόνια παρατηρείται συστηματική στροφή της ερευνητικής κοινότητας προς τη συλλογή πραγματικών αεροφωτογραφιών πεδίου, ενσωματώνοντας την πλήρη πολυπλοκότητα των περιβαλλοντικών συνθηκών, και αυτή η μετάβαση αποτελεί καθοριστικό βήμα για την πρακτική αξιοποίηση των συστημάτων αναγνώρισης ασθενειών μέσω ΣμηΕΑ.

Σε τεχνικό επίπεδο, η ανάλυση που πραγματοποιήθηκε δείχνει ότι, παρά τον φασματικό περιορισμό των RGB αισθητήρων, προηγμένα μοντέλα βαθιάς μάθησης (συμπεριλαμβανομένων αρχιτεκτονικών CNN καθώς και Vision Transformers) μπορούν να εξαγάγουν πλούσια χωρικά και ποιοτικά χαρακτηριστικά ακόμη και σε σύνθετα αγροπεριβάλλοντα. Η ενσωμάτωση τεχνικών transfer learning και η αξιοποίηση προεκπαιδευμένων βασικών μοντέλων ενισχύουν περαιτέρω τη γενίκευση των μοντέλων, ιδίως όταν οι συνθήκες λήψης διαφέρουν σημαντικά μεταξύ πτήσεων ή αγροτεμαχίων.

Ωστόσο, η εφαρμογή των παραπάνω μεθόδων υπό πραγματικές συνθήκες παραμένει ιδιαίτερα απαιτητική. Η βιβλιογραφία καταδεικνύει ότι η ποιότητα των εικόνων που συλλέγονται από ΣμηΕΑ επηρεάζεται δραστικά από την ηλιακή γωνία, την ύπαρξη σκιάσεων, την κατοπτρική ανάκλαση, τη γωνία λήψης, την ανομοιογένεια του υποβάθρου, αλλά και το στάδιο ανάπτυξης της καλλιέργειας. Οι περιορισμοί αυτοί συμβαδίζουν άμεσα με την ανάγκη για ποιοτικά και αντιπροσωπευτικά σύνολα δεδομένων. Τα προβλήματα που αναλύονται στο παραδοτέο (συνθήκες λήψης, παρασκηνίο, λανθασμένη ταξινόμηση ασθενειών, παράμετροι πτήσης, περιορισμένη διαθεσιμότητα δεδομένων και αισθητήρων) αντανακλούν σε μεγάλο βαθμό τα κενά που εντοπίζονται διεθνώς στις αντίστοιχες μελέτες.

Η συνολική εικόνα από τη διεθνή βιβλιογραφία και η ανάλυση που πραγματοποιήθηκε με τη διαμόρφωση συγκεκριμένων προτάσεων για την επίλυση των προβλημάτων που εντοπίστηκαν στην ανάπτυξη μοντέλων αυτοματοποιημένης αναγνώρισης ασθενειών, δείχνουν ότι η αποτελεσματική διάγνωση ασθενειών μέσω ΣμηΕΑ απαιτεί:

- Υψηλής ποιότητας και μεγάλης ποικιλομορφίας αεροφωτογραφίες, συλλεγμένες υπό διαφορετικές συνθήκες φωτισμού, διαφορετικές εποχές και από πολλαπλές γωνίες λήψης, ώστε να περιορίζονται τα προβλήματα υπερεξάρτησης των μοντέλων από συγκεκριμένα περιβάλλοντα.
- Εξασφάλιση «καθαρού» και συνεκτικού παρασκηνίου, μέσω καλλιεργητικών παρεμβάσεων, αλλά και με την ανάπτυξη υπολογιστικών τεχνικών απομόνωσης της περιοχής ενδιαφέροντος.

- Ακριβή, εξειδικευμένη και συνεχή φυτοπαθολογική επιμέλεια στις επισημάνσεις (annotations) των δεδομένων εκπαίδευσης των μοντέλων, καθώς η λανθασμένη ταξινόμηση ασθενειών παραμένει ένας από τους κυριότερους λόγους χαμηλής αξιοπιστίας τους.
- Βελτιστοποιημένες παραμέτρους πτήσης ΣμηΕΑ, με χρήση πολλαπλών υψομέτρων, ταχυτήτων και επαναλήψεων, ώστε να καλύπτεται αποτελεσματικά το εύρος της καλλιέργειας και να συλλέγονται δεδομένα πολλαπλής χωρικής κλίμακας.
- Εμπλουτισμό συνόλων δεδομένων μέσω συστηματικών ενεργειών συλλογής πεδίου, καθώς και μέσω τεχνικών multi-source data fusion, αξιοποιώντας τα πλεονεκτήματα δεδομένων από RGB, NIR και πολυφασματικούς αισθητήρες, όπου αυτό είναι δυνατό.
- Ανάπτυξη ελαφρών, ενεργειακά αποδοτικών μοντέλων, ώστε να υποστηρίζεται η σχεδόν πραγματικού χρόνου ανίχνευση επί του ΣμηΕΑ, περιορίζοντας τον όγκο των δεδομένων που χρειάζεται να αποθηκευτεί ή να μεταφερθεί.

Συνολικά, από την παρούσα εργασία προκύπτει ότι η χρήση ΣμηΕΑ με RGB αισθητήρες μπορεί να αποτελέσει μια πλήρως λειτουργική και οικονομικά αποδοτική λύση για την έγκαιρη αναγνώριση ασθενειών σε μεγάλης κλίμακας καλλιέργειες, αρκεί τα σύνολα δεδομένων εκπαίδευσης και δοκιμής να σχεδιάζονται με βάση τα επιθυμητά χαρακτηριστικά που αναλύονται στο παρόν παραδοτέο. Η μετάβαση από τις ελεγχόμενες εργαστηριακές δοκιμές σε πραγματικές συνθήκες πεδίου, σε συνδυασμό με την υιοθέτηση αυστηρών πρωτοκόλλων συλλογής δεδομένων και εξελιγμένων τεχνικών μοντελοποίησης, αποτελούν σήμερα τη βασική προϋπόθεση για την επιχειρησιακή ωρίμανση της τεχνολογίας.

4 ΠΑΡΑΡΤΗΜΑ Ι

Βιβλιογραφικές Αναφορές

1. Abbas, A., Zhang, Z., Zheng, H., Alami, M. M., Alrefaei, A. F., Abbas, Q., ... & Zhou, L. (2023). Drones in plant disease assessment, efficient monitoring, and detection: a way forward to smart agriculture. *Agronomy*, 13(6), 1524.
2. Abdulridha, J., Batuman, O., & Ampatzidis, Y. (2019). UAV-based remote sensing technique to detect citrus canker disease utilizing hyperspectral imaging and machine learning. *Remote Sensing*, 11(11), 1373.
3. Abdulridha, J., Ampatzidis, Y., Qureshi, J., & Roberts, P. (2020). Laboratory and UAV-based identification and classification of tomato yellow leaf curl, bacterial spot, and target spot diseases in tomato utilizing hyperspectral imaging and machine learning. *Remote Sensing*, 12(17), 2732.
4. Adão, T., Hruška, J., Pádua, L., Bessa, J., Peres, E., Morais, R., & Sousa, J. J. (2017). Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry. *Remote sensing*, 9(11), 1110.
5. Al-Saddik, H., Laybros, A., Simon, J. C., & Cointault, F. (2019). Protocol for the definition of a multi-spectral sensor for specific foliar disease detection: Case of "Flavescence dorée". *Phytoplasmas: Methods and Protocols*, 213-238.
6. Albornoz, C., & Giraldo, L. F. (2017, October). Trajectory design for efficient crop irrigation with a UAV. In *2017 IEEE 3rd Colombian Conference on Automatic Control (CCAC)* (pp. 1-6). IEEE.
7. Alenyà, G., Dellen, B., Foix, S., & Torras, C. (2013). Robotized plant probing: Leaf segmentation utilizing time-of-flight data. *IEEE Robotics & Automation Magazine*, 20(3), 50-59.
8. Alosaimi, W., Alyami, H., & Uddin, M. I. (2021). PeachNet: Peach Diseases Detection for Automatic Harvesting. *Computers, Materials & Continua*, 67(2).
9. 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.
10. Ariza-Sentís, M., Vélez, S., & Valente, J. (2023). BBR: An open-source standard workflow based on biophysical crop parameters for automatic Botrytis cinerea assessment in vineyards. *SoftwareX*, 24, 101542.
11. Arsenovic, M., Karanovic, M., Sladojevic, S., Anderla, A., & Stefanovic, D. (2019). Solving current limitations of deep learning based approaches for plant disease detection. *Symmetry*, 11(7), 939.
12. Atta, B. M., Saleem, M., Ali, H., Bilal, M., & Fayyaz, M. (2020). Application of fluorescence spectroscopy in wheat crop: early disease detection and associated molecular changes. *Journal of Fluorescence*, 30, 801-810.
13. Barbedo, J. G. A. (2013). Digital image processing techniques for detecting, quantifying and classifying plant diseases. *SpringerPlus*, 2(1), 660.

14. Barbedo, J. G. A. (2014). An automatic method to detect and measure leaf disease symptoms using digital image processing. *Plant disease*, 98(12), 1709-1716.
15. Barbedo, J. G. A. (2016). A review on the main challenges in automatic plant disease identification based on visible range images. *Biosystems Engineering*, Volume 144, Pages 52-60, ISSN 1537-5110.
16. Bélanger, M. C., Roger, J. M., Cartolaro, P., & Fermaud, M. (2011). Autofluorescence of grape berries following *Botrytis cinerea* infection. *International journal of remote sensing*, 32(14), 3835-3849.
17. Belasque Jr, J., Gasparoto, M. C. G., & Marcassa, L. G. (2008). Detection of mechanical and disease stresses in citrus plants by fluorescence spectroscopy. *Applied Optics*, 47(11), 1922-1926.
18. Bendig, J., Bolten, A., & Bareth, G. (2012) "Introducing a low-cost mini-UAV for thermal-and multispectral-imaging." *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci*, 39, pp.345-349.
19. Berner, D. K., & Paxson, L. K. (2003). Use of digital images to differentiate reactions of collections of yellow starthistle (*Centaurea solstitialis*) to infection by *Puccinia jaceae*. *Biological Control*, 28, 171-179.
20. Bock, C. H., Cook, A. Z., Parker, P. E., & Gottwald, T. R. (2009). Automated image analysis of the severity of foliar citrus canker symptoms. *Plant disease*, 93(6), 660-665.
21. Bock, C. H., Barbedo, J. G., Del Ponte, E. M., Bohnenkamp, D., & Mahlein, A. K. (2020). From visual estimates to fully automated sensor-based measurements of plant disease severity: status and challenges for improving accuracy. *Phytopathology Research*, 2, 1-30.
22. Boese, B. L., Clinton, P. J., Dennis, D., Golden, R. C., & Kim, B. (2008). Digital image analysis of *Zostera marina* leaf injury. *Aquatic Botany*, 88, 87e90.
23. Bouguettaya, A., Zarzour, H., Kechida, A., & Taberkit, A. M. (2023). A survey on deep learning-based identification of plant and crop diseases from UAV-based aerial images. *Cluster Computing*, 26(2), 1297-1317.
24. Boulent, J., Foucher, S., Théau, J., & St-Charles, P. L. (2019). Convolutional neural networks for the automatic identification of plant diseases. *Frontiers in plant science*, 10, 941.
25. Bravo, C., Moshou, D., Oberti, R., West, J., McCartney, A., Bodria, L., & Ramon, H. (2004). Foliar disease detection in the field using optical sensor fusion.
26. Chaerle, L., Lenk, S., Hagenbeek, D., Buschmann, C., & Van Der Straeten, D. (2007). Multicolor fluorescence imaging for early detection of the hypersensitive reaction to tobacco mosaic virus. *Journal of Plant physiology*, 164(3), 253-262.
27. Chang, A., Yeom, J., Jung, J., & Landivar, J. (2020). Comparison of canopy shape and vegetation indices of citrus trees derived from UAV multispectral images for characterization of citrus greening disease. *Remote Sensing*, 12(24), 4122.

28. Chin, R., Catal, C., & Kassahun, A. (2023). Plant disease detection using drones in precision agriculture. *Precision Agriculture*, 24(5), 1663-1682.
29. Choi, Y. H., Tapias, E. C., Kim, H. K., Lefeber, A. W., Erkelens, C., Verhoeven, J. T. J., ... & Verpoorte, R. (2004). Metabolic discrimination of *Catharanthus roseus* leaves infected by phytoplasma using ¹H-NMR spectroscopy and multivariate data analysis. *Plant Physiology*, 135(4), 2398-2410.
30. Clément, A., Verfaillie, T., Lormel, C., & Jaloux, B. (2015). A new colour vision system to quantify automatically foliar discolouration caused by insect pests feeding on leaf cells. *Biosystems Engineering*, 133, 128e140.
31. Costa, L., Kunwar, S., Ampatzidis, Y., & Albrecht, U. (2022). Determining leaf nutrient concentrations in citrus trees using UAV imagery and machine learning. *Precision agriculture*, 1-22.
32. Cui, D., Zhang, Q., Li, M., Zhao, Y., & Hartman, G. L. (2009). Detection of soybean rust using a multispectral image sensor. *Sensing and Instrumentation for Food Quality and Safety*, 3, 49-56.
33. Cui, D., Zhang, Q., Li, M., Hartman, G. L., & Zhao, Y. (2010). Image processing methods for quantitatively detecting soybean rust from multispectral images. *Biosystems Engineering*, 107, 186-193.
34. Das, A. K. (2004). Rapid detection of *Candidatus Liberibacter asiaticus*, the bacterium associated with citrus Huanglongbing (Greening) disease using PCR. *Current Science*, 87(9), 1183-1185.
35. De Coninck, B. M. A., Amand, O., Delaure, S. L., Lucas, S., Hias, N., Weyens, G., et al. (2011). The use of digital image analysis and real-time PCR fine-tunes bioassays for quantification of *Cercospora* leaf spot disease in sugar beet breeding. *Plant Pathology*, 61(1), 76-84.
36. Delalieux, S., van Aardt, J., Keulemans, W., Schrevens, E., Coppin, P., (2007). Detection of biotic stress (*Venturia inaequalis*) in apple trees using hyperspectral data: Non-parametric statistical approaches and physiological implications. *European Journal of Agronomy* 27 (1), 130-143.
37. Di Gennaro, S. F., Battiston, E., Di Marco, S., Facini, O., Matese, A., Nocentini, M., ... & Mugnai, L. (2016). Unmanned Aerial Vehicle (UAV)-based remote sensing to monitor grapevine leaf stripe disease within a vineyard affected by esca complex. *Phytopathologia Mediterranea*, 262-275.
38. Dolatabadian, A., Neik, T. X., Danilevicz, M. F., Upadhyaya, S. R., Batley, J., & Edwards, D. (2025). Image-based crop disease detection using machine learning. *Plant Pathology*, 74(1), 18-38.
39. Dunning, H. (2017). Drones That Detect Early Plant Disease Could Save Crops. *Imperial College London: London, UK*, 1-3.
40. Esehaghbeygi, A., Ardforoushan, M., Monajemi, S. A. H., & Masoumi, A. A. (2010). Digital image processing for quality ranking of saffron peach. *International Agrophysics*, 24(2), 115-120.
41. Esposito, M., Westbrook, A. S., Maggio, A., Cirillo, V., & DiTommaso, A. (2023). Neutral weed communities: The intersection between crop productivity, biodiversity, and weed ecosystem services. *Weed Science*, 71(4), 301-311.

42. Fang, H., He, Y., Zhang, Q., Zhang, J., & Shi, Y. (2021). Field Condition Sensing Technology. *Agricultural Internet of Things: Technologies and Applications*, 155-183.
43. Feng, X., Yan, F., & Liu, X. (2019). Study of wireless communication technologies on Internet of Things for precision agriculture. *Wireless Personal Communications*, 108(3), 1785-1802.
44. Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and electronics in agriculture*, 145, 311-318.
45. Fine, T. L. (2006). *Feedforward neural network methodology*. Springer Science & Business Media.
46. Gadoury, D. M., Seem, R. C., Ficke, A., & Wilcox, W. F. (2001). The epidemiology of powdery mildew on Concord grapes. *Phytopathology*, 91(10), 948-955.
47. Garre, P., & Harish, A. (2018, December). Autonomous agricultural pesticide spraying uav. In *IOP Conference Series: Materials Science and Engineering* (Vol. 455, p. 012030). IOP Publishing.
48. Garza, B. N., Ancona, V., Enciso, J., Perotto-Baldivieso, H. L., Kunta, M., & Simpson, C. (2020). Quantifying citrus tree health using true color UAV images. *Remote Sensing*, 12(1), 170.
49. Görlich, F., Marks, E., Mahlein, A. K., König, K., Lottes, P., & Stachniss, C. (2021). UAV-based classification of cercospora leaf spot using RGB images. *Drones*, 5(2), 34.
50. Guo, H., Cheng, Y., Liu, J., & Wang, Z. (2024). Low-cost and precise traditional Chinese medicinal tree pest and disease monitoring using UAV RGB image only. *Scientific Reports*, 14(1), 25562.
51. Hashimoto, N., Saito, Y., Maki, M., & Homma, K. (2019). Simulation of reflectance and vegetation indices for unmanned aerial vehicle (UAV) monitoring of paddy fields. *Remote Sensing*, 11(18), 2119.
52. Hassler, S. C., & Baysal-Gurel, F. (2019). Unmanned aircraft system (UAS) technology and applications in agriculture. *Agronomy*, 9(10), 618.
53. Hofstetter, V., Buyck, B., Croll, D., Viret, O., Couloux, A., & Gindro, K. (2012). What if esca disease of grapevine were not a fungal disease?. *Fungal Diversity*, 54, 51-67.
54. Hsu, T. C., Yang, H., Chung, Y. C., & Hsu, C. H. (2020). A Creative IoT agriculture platform for cloud fog computing. *Sustainable Computing: Informatics and Systems*, 28, 100285.
55. Hu, J., Zhang, Y., Zhao, D., Yang, G., Chen, F., Zhou, C., & Chen, W. (2022). A robust deep learning approach for the quantitative characterization and clustering of peach tree crowns based on UAV images. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-13.
56. Huang, Y., Hoffmann, W. C., Lan, Y., Wu, W., & Fritz, B. K. (2009). Development of a spray system for an unmanned aerial vehicle platform. *Applied Engineering in Agriculture*, 25(6), 803-809.

57. Huang, H., Deng, J., Lan, Y., Yang, A., Zhang, L., Wen, S., ... & Deng, Y. (2019). Detection of helminthosporium leaf blotch disease based on UAV imagery. *Applied Sciences*, 9(3), 558.
58. Huang, S., Zhou, G., He, M., Chen, A., Zhang, W., & Hu, Y. (2020). Detection of peach disease image based on asymptotic non-local means and PCNN-IPELM. *IEEE Access*, 8, 136421-136433.
59. Hulley, G., Hook, S., Fisher, J., & Lee, C. (2017, July). ECOSTRESS, A NASA Earth-Ventures Instrument for studying links between the water cycle and plant health over the diurnal cycle. In *2017 IEEE international geoscience and remote sensing symposium (IGARSS)* (pp. 5494-5496). IEEE.
60. Jinbo, C., Xiangliang, C., Han-Chi, F., & Lam, A. (2019). RETRACTED ARTICLE: Agricultural product monitoring system supported by cloud computing. *Cluster Computing*, 22(Suppl 4), 8929-8938.
61. Kannan, S., Desouza, V. A., Nughal, J., Das, S., Bhattacharyya, U. K., & Yadav, A. (2025). Artificial intelligence and drone-assisted plant disease diagnosis: A review of advancements and challenges.
62. Kawasaki, Y., Uga, H., Kagiwada, S., & Iyatomi, H. (2015). Basic study of automated diagnosis of viral plant diseases using convolutional neural networks. In *Advances in Visual Computing: 11th International Symposium, ISVC 2015, Las Vegas, NV, USA, December 14-16, 2015, Proceedings, Part II 11* (pp. 638-645). Springer International Publishing.
63. Kelman, A. , Pelczar, . Michael J. , Shurtleff, . Malcolm C. and Pelczar, . Rita M. (2024, October 30). *plant disease*. *Encyclopedia Britannica*. <https://www.britannica.com/science/plant-disease>
64. Kerkech, M., Hafiane, A., & Canals, R. (2018). Deep leaning approach with colorimetric spaces and vegetation indices for vine diseases detection in UAV images. *Computers and electronics in agriculture*, 155, 237-243.
65. Kerkech, M., Hafiane, A., & Canals, R. (2020). Vine disease detection in UAV multispectral images using optimized image registration and deep learning segmentation approach. *Computers and Electronics in Agriculture*, 174, 105446.
66. Khan, P. W., Byun, Y. C., & Park, N. (2020). IoT-blockchain enabled optimized provenance system for food industry 4.0 using advanced deep learning. *Sensors*, 20(10), 2990.
67. Khan, S. U., Alsuhaibani, A., Alabduljabbar, A., Almarshad, F., Altherwy, Y. N., & Akram, T. (2025). A review on automated plant disease detection: motivation, limitations, challenges, and recent advancements for future research. *Journal of King Saud University Computer and Information Sciences*, 37(3), 34.
68. Khanal, S., Kc, K., Fulton, J. P., Shearer, S., & Ozkan, E. (2020). Remote sensing in agriculture—accomplishments, limitations, and opportunities. *Remote Sensing*, 12(22), 3783.
69. Khattak, A., Asghar, M. U., Batool, U., Asghar, M. Z., Ullah, H., Al-Rakhami, M., & Gumaei, A. (2021). Automatic detection of citrus fruit and leaves diseases using deep neural network model. *IEEE access*, 9, 112942-112954.

70. Kudo, S., Kagiwada, S., & Iyatomi, H. (2024). Few-shot Metric Domain Adaptation: Practical Learning Strategies for an Automated Plant Disease Diagnosis. *arXiv preprint arXiv:2412.18859*.
71. Li, L., Zhang, Q., & Huang, D. (2014). A review of imaging techniques for plant phenotyping. *Sensors, 14*(11), 20078-20111.
72. Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors, 18*(8), 2674.
73. Liu, S., Guo, L., Webb, H., Ya, X., & Chang, X. (2019). Internet of Things monitoring system of modern eco-agriculture based on cloud computing. *Ieee Access, 7*, 37050-37058.
74. López, M. M., Bertolini, E., Olmos, A., Caruso, P., Gorris, M. T., Llop, P., ... & Cambra, M. (2003). Innovative tools for detection of plant pathogenic viruses and bacteria. *International Microbiology, 6*, 233-243.
75. Ludovisi, R., Tauro, F., Salvati, R., Khoury, S., Mugnozza Scarascia, G., & Harfouche, A. (2017). UAV-based thermal imaging for high-throughput field phenotyping of black poplar response to drought. *Frontiers in plant science, 8*, 1681.
76. Maes, W. H., & Steppe, K. (2019). Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. *Trends in plant science, 24*(2), 152-164.
77. Manfreda, S., McCabe, M. F., Miller, P. E., Lucas, R., Pajuelo Madrigal, V., Mallinis, G., ... & Toth, B. (2018). On the use of unmanned aerial systems for environmental monitoring. *Remote sensing, 10*(4), 641.
78. Mattupalli, C., Moffet, C. A., Shah, K. N., & Young, C. A. (2018). Supervised classification of RGB aerial imagery to evaluate the impact of a root rot disease. *Remote sensing, 10*(6), 917.
79. Mishra, A. R., Moshou, D., Bravo, C., Oberti, R., West, J., Bodria, L., McCartney, A., & Ramon, H. (2005). Plant disease detection based on data fusion of hyper-spectral and multi-spectral fluorescence imaging using Kohonen maps. *Real-Time Imaging, 11*(2), 75-83.
80. Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in plant science, 7*, 215232.
81. Mowat, W. P., & Dawson, S. (1987). Detection and identification of plant viruses by ELISA using crude sap extracts and unfractionated antisera. *Journal of virological methods, 15*(3), 233-247.
82. Moya, E. A., Barralesa, L. R., & Apablaza, G. E. (2005). Assessment of the disease severity of squash powdery mildew through visual analysis, digital image analysis and validation of these methodologies. *Crop Protection, 24*, 785e789.
83. Murugan, D., Garg, A., & Singh, D. (2017). Development of an adaptive approach for precision agriculture monitoring with drone and satellite data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 10*(12), 5322-5328.

84. Neupane, K., & Baysal-Gurel, F. (2021). Automatic identification and monitoring of plant diseases using unmanned aerial vehicles: A review. *Remote Sensing*, 13(19), 3841.
85. Ning, Y., Liu, W., & Wang, G. L. (2017). Balancing immunity and yield in crop plants. *Trends in plant science*, 22(12), 1069-1079.
86. Noguera, M., Aquino, A., Ponce, J. M., Cordeiro, A., Silvestre, J., Arias-Calderón, R., ... & Andújar, J. M. (2021). Nutritional status assessment of olive crops by means of the analysis and modelling of multispectral images taken with UAVs. *Biosystems Engineering*, 211, 1-18.
87. Oberti, R., Marchi, M., Tirelli, P., Calcante, A., Iriti, M., & Borghese, A. N. (2014). Automatic detection of powdery mildew on grapevine leaves by image analysis: Optimal view-angle range to increase the sensitivity. *Computers and Electronics in Agriculture*, 104, 1-8.
88. Oliveira, H. C., Guizilini, V. C., Nunes, I. P., & Souza, J. R. (2018). Failure detection in row crops from UAV images using morphological operators. *IEEE Geoscience and Remote Sensing Letters*, 15(7), 991-995.
89. Oerke, E. C. (2006). Crop losses to pests. *The Journal of agricultural science*, 144(1), 31-43.
90. Olmstead, J. W., Lang, G. A., & Grove, G. G. (2001). Assessment of severity of powdery mildew infection of sweet cherry leaves by digital image analysis. *Hortscience*, 36(1), 107e111.
91. Pan, Q., Gao, M., Wu, P., Yan, J., & Li, S. (2021). A deep-learning-based approach for wheat yellow rust disease recognition from unmanned aerial vehicle images. *Sensors*, 21(19), 6540.
92. Peressotti, E., Duchene, E., Merdinoglu, D., & Mestre, P. (2011). A semi-automatic non-destructive method to quantify grapevine downy mildew sporulation. *Journal of Microbiological Methods*, 84, 265e271.
93. Pérez-Roncal, C., López-Maestresalas, A., Lopez-Molina, C., Jarén, C., Urrestarazu, J., Santesteban, L. G., & Arazuri, S. (2020). Hyperspectral imaging to assess the presence of powdery mildew (*Erysiphe necator*) in cv. Carignan noir grapevine bunches. *Agronomy*, 10(1), 88.
94. Petit, A. N., Vaillant, N., Boulay, M., Clément, C., & Fontaine, F. (2006). Alteration of photosynthesis in grapevines affected by esca. *Phytopathology*, 96(10), 1060-1066.
95. Pirrello, C., Mizzotti, C., Tomazetti, T. C., Colombo, M., Bettinelli, P., Prodorutti, D., ... & Vezzulli, S. (2019). Emergent Ascomycetes in viticulture: an interdisciplinary overview. *Frontiers in plant science*, 10, 1394.
96. Pourreza, A., Lee, W. S., Ehsani, R., Schueller, J. K., & Raveh, E. (2015a). An optimum method for real-time in-field detection of Huanglongbing disease using a vision sensor. *Computers and Electronics in Agriculture*, 110, 221-232.
97. Pourreza, A., Lee, W. S., Etxeberria, E., & Banerjee, A. (2015b). An evaluation of a vision-based sensor performance in Huanglongbing disease identification. *biosystems engineering*, 130, 13-22. Atta

98. Prithiviraj, B., Vikram, A., Kushalappa, A. C., & Yaylayan, V. (2004). Volatile metabolite profiling for the discrimination of onion bulbs infected by *Erwinia carotovora* ssp. *carotovora*, *Fusarium oxysporum* and *Botrytis allii*. *European Journal of Plant Pathology*, *110*, 371-377.
99. Purcell, D. E., O'Shea, M. G., Johnson, R. A., & Kokot, S. (2009). Near-infrared spectroscopy for the prediction of disease ratings for Fiji leaf gall in sugarcane clones. *Applied Spectroscopy*, *63*(4), 450-457.
100. Pydipati, R., Burks, T. F., & Lee, W. S. (2006). Identification of citrus disease using color texture features and discriminant analysis. *Computers and Electronics in Agriculture*, *52*(1e2), 49e59.
101. Qin, J., Burks, T. F., Ritenour, M. A., & Bonn, W. G. (2009). Detection of citrus canker using hyperspectral reflectance imaging with spectral information divergence. *Journal of food engineering*, *93*(2), 183-191.
102. Qin, J., Wang, B., Wu, Y., Lu, Q., & Zhu, H. (2021). Identifying pine wood nematode disease using UAV images and deep learning algorithms. *Remote Sensing*, *13*(2), 162.
103. Quebrajo, L., Perez-Ruiz, M., Pérez-Urrestarazu, L., Martínez, G., & Egea, G. (2018). Linking thermal imaging and soil remote sensing to enhance irrigation management of sugar beet. *Biosystems Engineering*, *165*, 77-87.
104. Rasmussen, J., Nielsen, J., Garcia-Ruiz, F., Christensen, S., & Streibig, J. C. (2013). Potential uses of small unmanned aircraft systems (UAS) in weed research. *Weed research*, *53*(4), 242-248.
105. Roosjen, P. P., Kellenberger, B., Kooistra, L., Green, D. R., & Fahrenttrapp, J. (2020). Deep learning for automated detection of *Drosophila suzukii*: potential for UAV-based monitoring. *Pest Management Science*, *76*(9), 2994-3002.
106. Saleem, M., Atta, B. M., Ali, Z., & Bilal, M. (2020). Laser-induced fluorescence spectroscopy for early disease detection in grapefruit plants. *Photochemical & Photobiological Sciences*, *19*, 713-721.
107. Sandhu, M., Hadawale, P., Momin, S., & Khachane, A. (2020). Plant disease detection using ML and UAV. *International Research Journal of Engineering and Technology (IRJET)*, *7*(03), 5352-5357.
108. Sandler, H. A. (2018). Weed management in cranberries: A historical perspective and a look to the future. *Agriculture*, *8*(9), 138.
109. Sankaran, S., Mishra, A., Ehsani, R., & Davis, C. (2010). A review of advanced techniques for detecting plant diseases. *Computers and electronics in agriculture*, *72*(1), 1-13.
110. Sarkhosh, A., Shahkoomahally, S., Richmond-Cosie, L. M., & Harmon, P. (2020). Peach Brown Rot: HS1357, 2/2020. *EDIS*, *2020*(1).
111. Saradhambal, G., Dhivya, R., Latha, S., & Rajesh, R. (2018). Plant disease detection and its solution using image classification. *International Journal of Pure and Applied Mathematics*, *119*(14), 879-884.
112. Shadrin, D., Menshchikov, A., Somov, A., Bornemann, G., Hauslage, J., & Fedorov, M. (2019). Enabling precision agriculture through embedded sensing

- with artificial intelligence. *IEEE Transactions on Instrumentation and Measurement*, 69(7), 4103-4113.
113. Shafri, H. Z., & Hamdan, N. (2009). Hyperspectral imagery for mapping disease infection in oil palm plantation using vegetation indices and red edge techniques. *American Journal of Applied Sciences*, 6(6), 1031.
 114. 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.
 115. Sheikh, M. H., Mim, T. T., Reza, M. S., Rabby, A. S. A., & Hossain, S. A. (2019, July). Detection of maize and peach leaf diseases using image processing. In *2019 10th international conference on computing, communication and networking technologies (ICCCNT)* (pp. 1-7). IEEE.
 116. Shibuya, S., Cap, Q. H., Nagasawa, S., Kagiwada, S., Uga, H., & Iyatomi, H. (2021). Validation of prerequisites for correct performance evaluation of image-based plant disease diagnosis using reliable 221k images collected from actual fields. In *AI for Agriculture and Food Systems*.
 117. Singh, A. K., Ganapathysubramanian, B., Sarkar, S., & Singh, A. (2018). Deep learning for plant stress phenotyping: trends and future perspectives. *Trends in plant science*, 23(10), 883-898.
 118. Song, L., Guanter, L., Guan, K., You, L., Huete, A., Ju, W., & Zhang, Y. (2018). Satellite sun-induced chlorophyll fluorescence detects early response of winter wheat to heat stress in the Indian Indo-Gangetic Plains. *Global change biology*, 24(9), 4023-4037.
 119. Spinelli, F., Noferini, M., & Costa, G. (2004, July). Near infrared spectroscopy (NIRs): Perspective of fire blight detection in asymptomatic plant material. In *X International Workshop on Fire Blight 704* (pp. 87-90).
 120. Steel, C. C., Blackman, J. W., & Schmidtke, L. M. (2013). Grapevine bunch rots: impacts on wine composition, quality, and potential procedures for the removal of wine faults. *Journal of agricultural and food chemistry*, 61(22), 5189-5206.
 121. Stöcker, C., Bennett, R., Nex, F., Gerke, M., & Zevenbergen, J. (2017). Review of the current state of UAV regulations. *Remote sensing*, 9(5), 459.
 122. Song, Z., Xu, C., Luan, Q., & Li, Y. (2024). Multitemporal UAV study of phenolic compounds in slash pine canopies. *Remote Sensing of Environment*, 315, 114454.
 123. Stumph, B., Virto, M. H., Medeiros, H., Tabb, A., Wolford, S., Rice, K., & Leskey, T. (2019, May). Detecting invasive insects with unmanned aerial vehicles. In *2019 International Conference on Robotics and Automation (ICRA)* (pp. 648-654). IEEE.
 124. Tantalaki, N., Souravlas, S., & Roumeliotis, M. (2019). Data-driven decision making in precision agriculture: The rise of big data in agricultural systems. *Journal of agricultural & food information*, 20(4), 344-380.
 125. Tsouros, D. C., Bibi, S., & Sarigiannidis, P. G. (2019). A review on UAV-based applications for precision agriculture. *Information*, 10(11), 349.

126. Vélez, S., Ariza-Sentís, M., & Valente, J. (2023a). Dataset on unmanned aerial vehicle multispectral images acquired over a vineyard affected by *Botrytis cinerea* in northern Spain. *Data in Brief*, 46, 108876.
127. Vélez, S., Ariza-Sentís, M., & Valente, J. (2023b). Mapping the spatial variability of *Botrytis* bunch rot risk in vineyards using UAV multispectral imagery. *European Journal of Agronomy*, 142, 126691.
128. Vélez, S., Barajas, E., Rubio, J. A., Pereira-Obaya, D., & Rodríguez-Pérez, J. R. (2024). Field-Deployed Spectroscopy from 350 to 2500 Nm: A Promising Technique for Early Identification of Powdery Mildew Disease (*Erysiphe necator*) in Vineyards. *Agronomy*, 14(3), 634.
129. Veroustraete, F. (2015). The rise of the drones in agriculture. *EC agriculture*, 2(2), 325-327.
130. Viret, O., & Gindro, K. (2024). Wood diseases. In *Science of Fungi in Grapevine*. https://doi.org/10.1007/978-3-031-68663-4_5
131. Williamson, B., Tudzynski, B., Tudzynski, P., & Van Kan, J. A. (2007). *Botrytis cinerea*: the cause of grey mould disease. *Molecular plant pathology*, 8(5), 561-580.
132. Wiwart, M., Fordonski, G., Zuk-Golaszewska, K., & Suchowilska, E. (2009). Early diagnostics of macronutrient deficiencies in three legume species by color image analysis. *Computers and Electronics in Agriculture*, 65, 125e132.
133. Xu, H. R., Ying, Y. B., Fu, X. P., & Zhu, S. P. (2007). Near-infrared spectroscopy in detecting leaf miner damage on tomato leaf. *Biosystems Engineering*, 96(4), 447-454.
134. Xue, X., Lan, Y., Sun, Z., Chang, C., & Hoffmann, W. C. (2016). Develop an unmanned aerial vehicle based automatic aerial spraying system. *Computers and electronics in agriculture*, 128, 58-66.
135. Yanliang, Z., Qi, L., & Wei, Z. (2017). Design and test of a six-rotor unmanned aerial vehicle (UAV) electrostatic spraying system for crop protection. *International Journal of Agricultural and Biological Engineering*, 10(6), 68-76.
136. Zhang, M., & Meng, Q. (2011). Automatic citrus canker detection from leaf images captured in field. *Pattern Recognition Letters*, 32(15), 2036-2046.
137. Zheng, J., & Yang, W. (2018). Design of a Precision Agriculture Leakage Seeding System Based on Wireless Sensors. *International Journal of Online Engineering*, 14(5).
138. Zhou, R., Kaneko, S. I., Tanaka, F., Kayamori, M., & Shimizu, M. (2014). Disease detection of *Cercospora* Leaf Spot in sugar beet by robust template matching. *Computers and electronics in agriculture*, 108, 58-70.
139. Zhou, J., Zhou, J., Ye, H., Ali, M. L., Nguyen, H. T., & Chen, P. (2020). Classification of soybean leaf wilting due to drought stress using UAV-based imagery. *Computers and Electronics in Agriculture*, 175, 105576.
140. Zhu H, Lin C, Liu G, Wang D, Qin S, Li A, Xu J-L and He Y (2024) Intelligent agriculture: deep learning in UAV-based remote sensing imagery for crop

diseases and pests detection. *Front. Plant Sci.* 15:1435016. doi: 10.3389/fpls.2024.1435016.

141. Γκατζιλάκης, Χ. & Γούτος, Δ. (2019). Ασθένειες των πυρηνόκαρπων. Εργαστήριο Φυτοπαθολογίας & Βακτηριολογίας, Ελληνικό Μεσογειακό Πανεπιστήμιο. Εκπαιδευτικό σύγγραμμα.
142. Παναγόπουλος, Χ. Γ. (2007). Ασθένειες καρποφόρων δέντρων και αμπέλου. Αθήνα: Εκδόσεις Σταμούλης. ISBN 978-960-351-677-4.