



ΔΙΕΘΝΕΣ
ΠΑΝΕΠΙΣΤΗΜΙΟ
ΤΗΣ ΕΛΛΑΔΟΣ

ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ

ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ
ΚΑΙ ΗΛΕΚΤΡΟΝΙΚΩΝ ΣΥΣΤΗΜΑΤΩΝ

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

«Ολοκληρωμένες Τεχνικές Αντίληψης και
Συνεργατικού Ελέγχου Σμηνών UAV για Προληπτική
Ανάλυση και Παρέμβαση στη Γεωργία Ακριβείας:
Μια Ανασκόπηση Τεχνολογιών και Τάσεων»



Φοιτητής
Παναγιώτης Ιορδανίδης
Αρ. Μητρώου: 185183

Επιβλέπων
Κωνσταντίνος Α. Τσιντώτας
Επίκουρος Καθηγητής

Ιανουάριος 2026

Τίτλος Π.Ε.: Ολοκληρωμένες Τεχνικές Αντίληψης και Συνεργατικού Ελέγχου Σμηνών UAV
για Προληπτική Ανάλυση και Παρέμβαση στη Γεωργία Ακριβείας:

Μια Ανασκόπηση Τεχνολογιών και Τάσεων

Κωδικός Π.Ε.: 25256

Όνοματεπώνυμο φοιτητή: Παναγιώτης Ιορδανίδης

Όνοματεπώνυμο εισηγητή: Κωνσταντίνος Α. Τσιντώτας

Ημερομηνία ανάληψης Π.Ε.: 09/04/2025

Ημερομηνία περάτωσης Π.Ε. 23/01/2026

Βεβαιώνω ότι είμαι ο συγγραφέας αυτής της εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, έχω καταγράψει τις όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών, εικόνων και κειμένου, είτε αυτές αναφέρονται ακριβώς είτε παραφρασμένες. Επιπλέον, βεβαιώνω ότι αυτή η εργασία προετοιμάστηκε από εμένα προσωπικά, ειδικά ως πτυχιακή εργασία, στο Τμήμα Μηχανικών Πληροφορικής και Ηλεκτρονικών Συστημάτων του ΔΙ.ΠΑ.Ε.

Η παρούσα εργασία αποτελεί πνευματική ιδιοκτησία του φοιτητή Ιορδανίδη Παναγιώτη που την εκπόνησε. Στο πλαίσιο της πολιτικής ανοικτής πρόσβασης, ο συγγραφέας/δημιουργός εκχωρεί στο Διεθνές Πανεπιστήμιο της Ελλάδος άδεια χρήσης του δικαιώματος αναπαραγωγής, δανεισμού, παρουσίασης στο κοινό και ψηφιακής διάχυσης της εργασίας διεθνώς, σε ηλεκτρονική μορφή και σε οποιοδήποτε μέσο, για διδακτικούς και ερευνητικούς σκοπούς, άνευ ανταλλάγματος. Η ανοικτή πρόσβαση στο πλήρες κείμενο της εργασίας, δεν σημαίνει καθ' οιονδήποτε τρόπο παραχώρηση δικαιωμάτων διανοητικής ιδιοκτησίας του συγγραφέα/δημιουργού, ούτε επιτρέπει την αναπαραγωγή, αναδημοσίευση, αντιγραφή, πώληση, εμπορική χρήση, διανομή, έκδοση, μεταφόρτωση (downloading), ανάρτηση (uploading), μετάφραση, τροποποίηση με οποιονδήποτε τρόπο, τμηματικά ή περιληπτικά της εργασίας, χωρίς τη ρητή προηγούμενη έγγραφη συναίνεση του συγγραφέα/δημιουργού.

Η έγκριση της πτυχιακής εργασίας από το Τμήμα Μηχανικών Πληροφορικής και Ηλεκτρονικών Συστημάτων του Διεθνούς Πανεπιστημίου της Ελλάδος, δεν υποδηλώνει απαραίτητα και αποδοχή των απόψεων του συγγραφέα, εκ μέρους του Τμήματος.

Πρόλογος

Η επιλογή του θέματος της παρούσας πτυχιακής προέκυψε από την ανάγκη για πιο βιώσιμες και προληπτικές πρακτικές στη γεωργία ακριβείας, όπου η έγκαιρη ανίχνευση καταπόνησης, ασθενειών και υδατικών ελλείψεων μπορεί να μειώσει τις απώλειες. Με προσωπικό ενδιαφέρον στη σύζευξη της τεχνητής νοημοσύνης και των ρομποτικών συστημάτων, επέλεξα να μελετήσω πώς UAVs, με έμφαση στα σμήνη UAV, που μπορούν να προσφέρουν υψηλής ανάλυσης δεδομένα και να υποστηρίξουν στοχευμένες παρεμβάσεις στις καλλιέργειες. Μέσα από τη συστηματική ανασκόπηση της πρόσφατης βιβλιογραφίας, χαρτογραφήθηκαν και συγκρίθηκαν τεχνολογίες ροής αντίληψης, αισθητήρες, δείκτες βλάστησης και μοντέλα μηχανικής και βαθιάς μάθησης, με στόχο τη σύνθεση μιας συνεκτικής εικόνας για το πεδίο και την ανάδειξη των ερευνητικών κενών. Το βασικό όφελος για μένα ήταν η ουσιαστική εμπάθυνση στις ροές αντίληψης των UAVs και η αξιολόγηση των μοντέλων, η καλλιέργεια κριτικής σκέψης στη σύγκριση μεθόδων και η διαμόρφωση τεκμηριωμένων κατευθύνσεων για μελλοντική έρευνα και εφαρμογή σε πραγματικές γεωργικές συνθήκες.

Περίληψη

Η παρούσα πτυχιακή εργασία πραγματεύεται τη συστηματική ανασκόπηση και συγκριτική ανάλυση των σύγχρονων τεχνολογιών που αφορούν τη χρήση UAV και σμηνών UAV στη γεωργία ακριβείας, με έμφαση στην αντίληψη του περιβάλλοντος, την αξιοποίηση δεικτών βλάστησης και την εφαρμογή μεθόδων μηχανικής και βαθιάς μάθησης. Στόχος της εργασίας είναι η χαρτογράφηση των επικρατέστερων τεχνολογιών και η τεκμηρίωση των τάσεων που διαμορφώνουν τις σύγχρονες προσεγγίσεις UAV, ώστε να εξαχθούν συμπεράσματα και κατευθύνσεις που υποστηρίζουν τόσο την ερευνητική εξέλιξη όσο και την πρακτική υιοθέτηση των τεχνολογιών στο αγροτικό πεδίο. Μέσα από τη σύνθεση και τη συγκριτική αξιολόγηση της πρόσφατης διεθνούς βιβλιογραφίας, η εργασία αναδεικνύει τις τεχνολογικές επιλογές που εμφανίζονται με τη μεγαλύτερη συχνότητα και αποτελεσματικότητα στις εφαρμογές γεωργίας ακριβείας. Ιδιαίτερη έμφαση δίνεται στους τύπους αισθητήρων που χρησιμοποιούνται στα UAVs, στους δείκτες βλάστησης που αξιοποιούνται για την αποτίμηση της κατάστασης των καλλιεργειών, καθώς και στα μοντέλα μηχανικής και βαθιάς μάθησης που επιτυγχάνουν υψηλές επιδόσεις σε εργασίες ανίχνευσης καταπόνησης, ασθeneιών και υδατικών ελλείψεων. Παράλληλα, εξετάζεται ο ρόλος της συνεργατικής λειτουργίας σμηνών UAV, η οποία αναδεικνύεται ως μια πολλά υποσχόμενη προσέγγιση για την κάλυψη μεγάλων αγροτικών εκτάσεων και την υποστήριξη προληπτικών παρεμβάσεων σε πραγματικό χρόνο. Τα συμπεράσματα που προκύπτουν σκιαγραφούν τις κυρίαρχες τάσεις και τα ερευνητικά κενά του πεδίου, προσφέροντας ένα συνεκτικό πλαίσιο αναφοράς για μελλοντική έρευνα και για τη σταδιακή μετάβαση από πειραματικές εφαρμογές σε ώριμες και επιχειρησιακά αξιοποιήσιμες λύσεις στον τομέα της γεωργίας.

Integrated Perception and Swarm Control Techniques for Preventive Intervention in Precision Agriculture Using UAVs: A Review of Emerging Technologies and Trends

Panagiotis Iordanidis

Abstract

This thesis focuses on a systematic review and comparative analysis of contemporary technologies related to the use of Unmanned Aerial Vehicles (UAVs) and UAV swarms in precision agriculture, with particular emphasis on environmental perception, the exploitation of vegetation indices, and the application of machine learning and deep learning methods. The aim of the study is to map the prevailing technological solutions and to document the trends shaping modern UAV-based approaches, in order to derive conclusions and directions that support both research advancement and the practical adoption of these technologies in agricultural environments. Through the synthesis and comparative evaluation of recent international literature, the thesis highlights the technological choices that appear most frequently and demonstrate the highest effectiveness in precision agriculture applications. Special emphasis is placed on the types of sensors deployed on UAV platforms, the vegetation indices used to assess crop condition, and the machine learning and deep learning models that achieve high performance in tasks such as stress detection, disease identification, and water deficit assessment. At the same time, the role of cooperative UAV swarm operation is examined and identified as a particularly promising approach for covering large agricultural areas and supporting preventive, real-time interventions. The conclusions drawn outline the dominant trends and existing research gaps in the field, providing a coherent reference framework for future research and for the gradual transition from experimental studies to mature, operationally viable solutions in agriculture.

Ευχαριστίες

Θα ήθελα να ευχαριστήσω την οικογένειά μου και τη σύντροφό μου για την αδιάλειπτη συναισθηματική στήριξη, την ενθάρρυνση, και την πίστη στις προσπάθειές μου, στοιχεία που αποτέλεσαν σημαντική πηγή δύναμης και κινήτρου για την ολοκλήρωση της παρούσας πτυχιακής εργασίας. Επίσης θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή μου, κ. Κωνσταντίνο Α. Τσιντώτα, για την πολύτιμη επιστημονική καθοδήγηση και τις εύστοχες παρατηρήσεις καθ' όλη τη διάρκεια εκπόνησης της παρούσας πτυχιακής εργασίας.

Περιεχόμενα

Πρόλογος	ii
Περίληψη	iii
Abstract	iv
Ευχαριστίες	v
Περιεχόμενα	vi
Κατάλογος Σχημάτων	vii
Κατάλογος Πινάκων	vii
1 Εισαγωγή	1
1.1 Εισαγωγή	1
1.2 Γεωργία ακριβείας και ο ρόλος των UAVs	1
1.3 Σκοπός της εργασίας	3
1.4 Ερευνητικά ερωτήματα	4
2 Μεθοδολογία	5
2.1 Μεθοδολογία	5
2.2 Κριτήρια εισαγωγής-αποκλεισμού	5
3 Ροή αντίληψης στα UAVs	7
3.1 Σμήνη απο UAV	7
3.1.1 Αρχιτεκτονικές σχηματισμού ελέγχου σε σμήνη UAV	8
3.1.2 Μέθοδοι σχηματισμού ελέγχου σε σμήνη μη επανδρωμένων εναέριων οχημάτων	11
3.2 Συλλογή δεδομένων	13
3.3 Επεξεργασία δεδομένων	16
3.3.1 Φωτογραμμετρικές τεχνικές	16
3.3.2 Δείκτες βλάστησης	18
3.3.3 Τεχνικές μηχανικής μάθησης	28
3.3.4 Τεχνικές βαθιάς μάθησης	30
4 Ταξινόμηση των τεχνικών ανίχνευσης ασθενειών μέσω UAV	31
4.1 Ταξινόμηση μεθόδων	31
4.2 Δείκτες βλάστησης	32
4.3 Μέθοδοι μηχανικής μάθησης	34
4.4 Μέθοδοι βαθιάς μάθησης	37
5 Αποτελέσματα έρευνας και συμπεράσματα	41
6 Προκλήσεις και ερευνητικά κενά	48
ΒΙΒΛΙΟΓΡΑΦΙΑ	50

Κατάλογος Σχημάτων

1.1	Εφαρμογή λιπάσματος σε καλλιέργεια. [1]	3
2.1	Διάγραμμα ροής PRISMA της διαδικασίας επιλογής μελετών για τη Συστηματική Ανασκόπηση Βιβλιογραφίας (SLR).	6
3.1	Στοχευμένη εφαρμογή λιπάσματος σε καλλιέργεια απο σμήνος UAV. [1]	8
3.2	Κεντριοποιημένη αρχιτεκτονική	9
3.3	Αποκεντρωμένη αρχιτεκτονική	10
3.4	Κατανεμημένη αρχιτεκτονική	11
3.5	Κάμερα RGB [2]	13
3.6	Πολυφασματική κάμερα [3]	14
3.7	Θερμική κάμερα [4]	14
3.8	LiDAR κάμερα [5]	15
3.9	SAR κάμερα [6]	16
3.10	Ψηφιακό Μοντέλο Εδάφους. [7]	17
3.11	Χάρτης δείκτη βλάστησης NDVI. [8]	19
3.12	Χάρτης δείκτη βλάστησης. [9]	24
3.13	Σάρωση καλλιέργειας. [10]	29
4.1	Ταξινόμηση των μεθόδων.	32
4.2	Ροή μεθόδων μηχανικής μάθησης.	35
4.3	Ροή μεθόδων βαθιάς μάθησης.	38
5.1	Κατανομή των μελετών ως προς τον τύπο αισθητήρα UAV που χρησιμοποιήθηκε για εφαρμογές με δείκτες βλάστησης και μεθόδους μηχανικής και βαθιάς μάθησης.	42
5.2	Συχνότητα εμφάνισης των δεικτών βλάστησης στις μελέτες που αξιοποιούν τους δείκτες βλάστησης είτε άμεσα είτε ως χαρακτηριστικά εισόδου σε μοντέλα μηχανικής μάθησης.	44
5.3	Κατανομή των μελετών ως προς τις μεθόδους που χρησιμοποιήθηκαν.	45
5.4	Συχνότητα εμφάνισης των μοντέλων μηχανικής μάθησης στις μελέτες της ανασκόπησης.	46
5.5	Συχνότητα εμφάνισης των μοντέλων βαθιάς μάθησης στις μελέτες της ανασκόπησης.	47

Κατάλογος Πινάκων

4.1	Σύνοψη μελετών για την ανίχνευση ασθενειών μέσω δεικτών βλάστησης. Οι συντομογραφίες που χρησιμοποιούνται είναι οι εξής: MS (Πολυφασματικός).	34
4.2	Σύνοψη μελετών μηχανικής μάθησης (ML), για ανίχνευση ασθενειών με τη χρήση UAV. Οι συντομογραφίες που χρησιμοποιούνται είναι οι εξής: HS (Υπερφασματικός), MS (Πολυφασματικός), VIs (Δείκτες βλάστησης), ΦΖ (Φασματικές ζώνες).	37
4.3	Σύνοψη μελετών βαθιάς μάθησης (DL) με μοντέλα ταξινόμησης, για ανίχνευση ασθενειών καλλιεργειών με χρήση UAV. Οι συντομογραφίες που χρησιμοποιούνται είναι οι εξής: HS (Υπερφασματικός), MS (Πολυφασματικός), Α (Ακρίβεια), ΟΑ (Ολική Ακρίβεια).	40
4.4	Σύνοψη μελετών βαθιάς μάθησης (DL) με μοντέλα τμηματοποίησης, για ανίχνευση ασθενειών με τη χρήση UAV. Οι συντομογραφίες που χρησιμοποιούνται είναι οι εξής: HS (Υπερφασματικός), MS (Πολυφασματικός).	41

Κεφάλαιο 1ο: Εισαγωγή

1.1 Εισαγωγή

Η γεωργία ακριβείας έχει αναδειχθεί ως ένα από τα πιο δυναμικά πεδία τεχνολογικής καινοτομίας των τελευταίων ετών, καθώς οι παραγωγοί καλούνται να ανταποκριθούν σε αυξανόμενες απαιτήσεις παραγωγικότητας, μείωσης κόστους και βιώσιμης διαχείρισης των φυσικών πόρων. Ένα από τα πιο κρίσιμα προβλήματα της σύγχρονης γεωργίας είναι η έγκαιρη ανίχνευση της καταπόνησης, των ασθενειών και των υδατικών ελλείψεων των καλλιεργειών, παράγοντες που επηρεάζουν άμεσα τόσο την απόδοση όσο και την ποιότητά τους [11]. Η καθυστερημένη διάγνωση τέτοιων καταστάσεων οδηγεί συχνά σε μη αναστρέψιμες απώλειες, αυξημένη χρήση φυτοφαρμάκων και νερού, καθώς και σε σημαντική υποβάθμιση της περιβαλλοντικής και οικονομικής βιωσιμότητας [12].

Οι παραδοσιακές μέθοδοι παρακολούθησης βασίζονται κυρίως σε επίγειους ελέγχους, οπτική επιθεώρηση από τους αγρότες ή τη χρήση περιορισμένων σημειακών αισθητήρων [13]. Αν και αυτές οι μέθοδοι παραμένουν χρήσιμες, παρουσιάζουν σημαντικούς περιορισμούς, δηλαδή είναι χρονοβόρες, δεν καλύπτουν μεγάλες εκτάσεις, δεν προσφέρουν συχνά δεδομένα σε πραγματικό χρόνο και δεν επιτρέπουν έγκαιρες παρεμβάσεις με υψηλή ακρίβεια. Ως αποτέλεσμα, κρίσιμες αλλαγές στη βλάστηση συχνά ανιχνεύονται όταν τα συμπτώματα έχουν ήδη γίνει ορατά, δηλαδή σε στάδια όπου οι απώλειες είναι δύσκολο να αντιστραφούν.

Η ανάγκη για προληπτική αντίληψη και έγκαιρη λήψη αποφάσεων καθιστά απαραίτητη την υιοθέτηση τεχνολογιών που μπορούν να παρέχουν υψηλής ανάλυσης χωρικά και υψηλής συχνότητας χρονικά δεδομένα, χρησιμοποιώντας σύγχρονες τεχνικές ανάλυσης μέσω τεχνητής νοημοσύνης. Σε αυτό το πλαίσιο, τα μη επανδρωμένα εναέρια οχήματα (Unmanned Aerial Vehicles - UAV) αποτελούν ένα από τα πιο ισχυρά εργαλεία για την παρακολούθηση, ανάλυση και πρόγνωση της κατάστασης των καλλιεργειών.

Η συνεισφορά της παρούσας εργασίας έγκειται στη συστηματική χαρτογράφηση, σύγκριση και σύνθεση της σύγχρονης επιστημονικής βιβλιογραφίας που αφορά τη χρήση UAV και σημνών UAV στη γεωργία ακριβείας. Μέσα από μια οργανωμένη ανασκόπηση πρόσφατων μελετών, αναλύονται και συγκρίνονται τεχνολογίες αντίληψης, τύποι αισθητήρων, δείκτες βλάστησης, καθώς και μέθοδοι μηχανικής και βαθιάς μάθησης που εφαρμόζονται για την έγκαιρη ανίχνευση καταπόνησης, ασθενειών και υδατικών ελλείψεων των καλλιεργειών. Η συνθετική αυτή προσέγγιση στοχεύει στη διαμόρφωση μιας συνεκτικής εικόνας του πεδίου, στην ανάδειξη κυρίαρχων τεχνολογικών τάσεων και στον εντοπισμό ερευνητικών κενών που μπορούν να αποτελέσουν βάση για μελλοντική έρευνα και εφαρμογές.

1.2 Γεωργία ακριβείας και ο ρόλος των UAVs

Ως γεωργία ακριβείας ορίζουμε την στρατηγική διαχείρισης που χρησιμοποιεί πληροφορίες σχετικές με τις καλλιέργειες και την τεχνολογία, για να συλλέξει, να επεξεργαστεί και να αναλύσει χωρικά και χρονικά δεδομένα με σκοπό την καθοδήγηση σε συγκεκριμένες πρακτικές για την βελτίωση της απόδοσης, παραγωγικότητας και βιωσιμότητας της αγροτικής παραγωγής [14].

Μέσω των UAVs, στη γεωργία ακριβείας, χρησιμοποιούνται αισθητήρες και τεχνικές ελέγχου που κατα-

γράφουν και ανιχνεύουν περιοχές όπου μπορεί να εμφανίζονται ασθένειες στις καλλιέργειες. Τα UAVs έχουν εξελιχθεί σε βασικό πυλώνα της γεωργίας ακριβείας λόγω της δυνατότητάς τους να συλλέγουν δεδομένα υψηλής ανάλυσης με ταχύτητα, οικονομικά και με μεγάλη ευελιξία. Σε αντίθεση με τα επίγεια συστήματα ή τις δορυφορικές πλατφόρμες, τα UAVs μπορούν να πετούν χαμηλά, να χαρτογραφούν μεγάλες εκτάσεις μέσα σε λίγα λεπτά και να πραγματοποιούν τακτικές ή ακόμη και καθημερινές αποστολές παρακολούθησης. Έτσι τα UAVs χρησιμοποιούνται ήδη σε ποικίλες εφαρμογές όπως παρακολούθηση της υγείας των φυτών, ανίχνευση ασθενειών, εκτίμηση ανάπτυξης και απόδοσης, και διαχείριση ζιζανίων. Με τη βοήθεια κατάλληλων αισθητήρων, τα UAVs μπορούν να εντοπίζουν περιοχές μέσα στο χωράφι που χρειάζονται ειδική διαχείριση και να δίνουν στους αγρότες τη δυνατότητα να αντιδρούν έγκαιρα όπου παρουσιάζεται πρόβλημα.

Παρόλο που τα μεμονωμένα UAVs έχουν φέρει επανάσταση στην παρακολούθηση των καλλιεργειών, εμφανίζουν εγγενείς περιορισμούς όσον αφορά την εμβέλεια, τον χρόνο πτήσης και το ωφέλιμο φορτίο τους. Τα περισσότερα εμπορικά UAVs έχουν περιορισμένη αυτονομία περίπου 20–40 λεπτά [15], γεγονός που απαιτεί συχνές διακοπές για επαναφόρτιση ή αλλαγή μπαταριών, ιδίως όταν καλύπτουν μεγάλες εκτάσεις. Ομοίως, το βάρος που μπορούν να μεταφέρουν με αισθητήρες ή δεξαμενές ψεκασμού είναι περιορισμένο, επιβάλλοντας όρια σε επιχειρησιακές εφαρμογές μεγάλης κλίμακας [15]. Για να ξεπεραστούν αυτά τα όρια, η ερευνητική κοινότητα αλλά και η βιομηχανία στρέφονται σε συστήματα σμηνών UAV, όπου πολλαπλά UAVs συνεργάζονται ταυτόχρονα. Ένα σμήνος UAV, μέσω κατάλληλου συντονισμού και ελέγχου, μπορεί να εκτελεί αποστολές συλλογικά, μοιράζοντας τον φόρτο εργασίας, και έτσι να επεκτείνει την καλυπτόμενη έκταση και να αυξήσει δραστικά την αποδοτικότητα της επιχείρησης. Σε μια συνεργατική αποστολή, τα UAVs μπορούν να χωριστούν για να καλύψουν διαφορετικές ζώνες της καλλιέργειας ή να αναλάβουν διαφορετικές διεργασίες ταυτόχρονα, επιτυγχάνοντας σημαντικά ταχύτερη ολοκλήρωση σε σύγκριση με την διαδοχική χρήση ενός μόνο UAV.

Επιπλέον, τα συστήματα σμήνους UAV προσφέρουν αυξημένη αξιοπιστία και ανθεκτικότητα. Σε περίπτωση που κάποιο UAV αντιμετωπίσει βλάβη ή δυσλειτουργία, τα υπόλοιπα μπορούν να συνεχίσουν και να ολοκληρώσουν την αποστολή, διατηρώντας έτσι την επιχειρησιακή συνέχεια. Αυτό το πλεονέκτημα δεν μπορεί να υπάρξει σε μια προσέγγιση όπου χρησιμοποιείται ένα UAV, όπου μια βλάβη θα σήμαινε διακοπή της αποστολής. Παράλληλα, τα μέλη ενός σμήνους μπορούν να προσαρμόζουν δυναμικά την κατανομή των εργασιών βάσει των εκάστοτε συνθηκών και απαιτήσεων του πεδίου. Για παράδειγμα, κάποια UAVs του σμήνους μπορούν να επικεντρωθούν σε περιοχές με ενδείξεις καταπόνησης, ενώ άλλα χαρτογραφούν γενικότερα την καλλιέργεια [16].

Η αξιοποίηση σμηνών UAV στη γεωργία ακριβείας συνδυάζει τα γνωστά πλεονεκτήματα των UAVs, όπως ευελιξία, υψηλή ανάλυση και συχνότητα συλλογής δεδομένων, μαζί με κλιμακούμενη κάλυψη και αποδοτικότητα. Έτσι, ανοίγει ο δρόμος για την αποτελεσματική παρακολούθηση μεγάλων εκμεταλλεύσεων σε πραγματικό χρόνο, κάτι που αποτελεί προϋπόθεση για πλήρως αυτοματοποιημένες καλλιέργειες στο μέλλον. Ήδη, σε ερευνητικό επίπεδο, καταγράφονται σημαντικά πρώτα βήματα σε τεχνικές συνεργατικού ελέγχου σμήνους, αν και το πεδίο βρίσκεται ακόμη σε αρχικό στάδιο ανάπτυξης και αντιμετωπίζει πολύπλευρες προκλήσεις όπως συντονισμός σε πολύπλοκα περιβάλλοντα. Παρά τις δυσκολίες, η τάση είναι σαφής, καθώς η συνεργατική χρήση πολλαπλών UAV θεωρείται πολλά υποσχόμενη λύση για να καλυφθούν οι αυξανόμενες ανάγκες παρακολούθησης και διαχείρισης στη γεωργία ακριβείας.



Σχήμα 1.1: Εφαρμογή λιπάσματος σε καλλιέργεια. [1]

1.3 Σκοπός της εργασίας

Βάσει των παραπάνω, ο σκοπός της παρούσας πτυχιακής εργασίας είναι η χαρτογράφηση, σύγκριση και αξιολόγηση των σύγχρονων τεχνολογιών ροής της αντίληψης σε UAV και σμήνη UAV, με έμφαση στην προληπτική ανίχνευση καταπονήσεων, ασθενειών και υδατικών ελλείψεων στις καλλιέργειες. Ειδικότερα, η εργασία επικεντρώνεται στις εξελίξεις της περιόδου 2020–2025, κατά την οποία σημειώθηκε ραγδαία πρόοδος στους τομείς αυτούς. Η επιλογή αυτής της χρονικής περιόδου στοχεύει στο να καλύψει την πλέον πρόσφατη βιβλιογραφία, δεδομένου ότι η έρευνα γύρω από τη χρήση UAV στη γεωργία εξελίσσεται με ταχύ ρυθμό και απαιτεί επικαιροποιημένη επισκόπηση. Μέσα από την ανασκόπηση αυτή, επιχειρείται: (α) να καταγραφούν οι κυριότερες τεχνολογικές προσεγγίσεις που έχουν προταθεί για την αντίληψη και τη συλλογή πληροφοριών από UAV όπως προηγμένα οπτικά και φασματικά συστήματα και αλγόριθμοι τεχνητής νοημοσύνης για ανίχνευση συμπτωμάτων, (β) να παρουσιαστούν οι μεθοδολογίες που συνδυάζουν δεδομένα από ετερογενείς αισθητήρες προκειμένου να ενισχυθεί η αξιοπιστία και ακρίβεια στην εκτίμηση της κατάστασης των καλλιεργειών, και (γ) να συγκεντρωθούν οι στρατηγικές έξυπνου ελέγχου σμήνους που εφαρμόζονται για τον συντονισμό πολλαπλών UAVs με τρόπο αποδοτικό και αυτόνομο. Με τη χαρτογράφηση αυτών των τεχνολογιών, η εργασία αποσκοπεί να αναδείξει τις τρέχουσες δυνατότητες αλλά και τους περιορισμούς της κάθε προσέγγισης, συμβάλλοντας έτσι στην κατανόηση του πώς μπορούν να συνδυαστούν οι εξελιγμένες αυτές τεχνικές για ένα ολοκληρωμένο σύστημα προληπτικής παρακολούθησης των καλλιεργειών. Τέλος, η σύνθεση των αποτελεσμάτων θα επιτρέψει την εξαγωγή συμπερασμάτων σχετικά με το ποιες τεχνολογίες ή συνδυασμοί υπερέχουν σε συγκεκριμένα σενάρια, καθώς και θα υποδείξει ενδεχόμενες μελλοντικές κατευθύνσεις έρευνας.

1.4 Ερευνητικά ερωτήματα

Με γνώμονα τον παραπάνω σκοπό, διατυπώθηκαν τα ακόλουθα ερευνητικά ερωτήματα (EE1–EE5), στα οποία θα δώσει απαντήσεις η εργασία:

EE1: Ποιοι τύποι αισθητήρων χρησιμοποιούνται συχνότερα στη βιβλιογραφία και από ποιους παράγοντες καθορίζεται η επιλογή τους;

EE2: Ποιοι δείκτες βλάστησης εμφανίζονται συχνότερα στις μελέτες και ποιοι αναδεικνύονται ως οι πιο αποτελεσματικοί ανά περίπτωση;

EE3: Ποια μοντέλα μηχανικής μάθησης κυριαρχούν στις σύγχρονες μελέτες με βάση τη δημοφιλία και την αποτελεσματικότητά τους;

EE4: Ποια μοντέλα βαθιάς μάθησης κυριαρχούν στις σύγχρονες μελέτες με βάση τη δημοφιλία και την αποτελεσματικότητά τους;

EE5: Πώς ο συνδυασμός αισθητήρων, δεικτών βλάστησης και μοντέλων επηρεάζει την απόδοση, και σε ποιο βαθμό τα χαρακτηριστικά εισόδου καθορίζουν την τελική ακρίβεια σε σχέση με τον ίδιο τον αλγόριθμο;

Κεφάλαιο 2ο: Μεθοδολογία

2.1 Μεθοδολογία

Η παρούσα εργασία ακολουθεί τη μεθοδολογική προσέγγιση της Συστηματικής Ανασκόπησης της Βιβλιογραφίας (Systematic Literature Review – SLR), η οποία αποτελεί μία δομημένη και διαφανή διαδικασία συλλογής, αξιολόγησης και σύνθεσης επιστημονικών μελετών. Στόχος της ανασκόπησης είναι να εντοπίσει, να συγκρίνει και να αξιολογήσει τις πλέον σύγχρονες τεχνολογίες αντίληψης, συγχώνευσης αισθητήρων και μεθοδολογιών μηχανικής και βαθιάς μάθησης που χρησιμοποιούνται από UAVs για τον προληπτικό εντοπισμό καταπόνησης, ασθενειών και υδατικών ελλείψεων σε καλλιέργειες στη γεωργία ακριβείας.

Η επιλογή συστηματικής ανασκόπησης είναι απολύτως συμβατή με τη φύση του θέματος, καθώς η τεχνολογία της γεωργίας ακριβείας με UAV εξελίσσεται ταχύτατα και απαιτείται αυστηρή οργάνωση της βιβλιογραφίας για την εξαγωγή συγκριτικών συμπερασμάτων. Επιπλέον, αρκετές από τις τεχνολογίες ροής και τεχνητής νοημοσύνης που χρησιμοποιούνται στα UAVs αποτελούν πρόσφατες ερευνητικές εξελίξεις, ιδιαίτερα μετά το 2020, γεγονός που καθιστά απαραίτητη τη διαχρονικά περιορισμένη αλλά και την εντατική ανασκόπηση της πλέον επικαιροποιημένης γνώσης. Ο σχεδιασμός της διαδικασίας SLR βασίστηκε στις διεθνείς κατευθυντήριες οδηγίες PRISMA [17], προσαρμοσμένες στο αντικείμενο της γεωργίας ακριβείας και της τεχνολογίας των UAVs.

Για τον εντοπισμό των άρθρων, χρησιμοποιήθηκε ένα συνδυαστικό σύνολο λέξεων-κλειδιών, όπως: «precision agriculture», «UAV perception pipeline», «UAV swarms», «early stress detection», «UAV disease detection», «vegetation indices UAV», «ML/DL techniques». Οι συγκεκριμένες λέξεις-κλειδιά επιλέχθηκαν βάσει της ορολογίας που χρησιμοποιείται στη σύγχρονη βιβλιογραφία του MDPI και των τεχνικών που αναλύουν συστηματικά σε σχετικές μελέτες. Με βάση τις προκαθορισμένες λέξεις-κλειδιά και τους συνδυασμούς τους εντοπίστηκαν περίπου 300 άρθρα που σχετίζονταν δυνητικά με UAVs κατά την περίοδο 2020–2025. Μετά από ανάγνωση των τίτλων και των περιλήψεων, αφαιρέθηκαν άρθρα που δεν αφορούσαν τη γεωργία ακριβείας, δεν ασχολούνταν με ροή αντίληψης, συγχώνευση αισθητήρων, δεν παρείχαν τεχνικό βάθος ή μεθοδολογικό περιεχόμενο σχετικό με UAV συστήματα σε συνδυασμό με μεθόδους τεχνητής νοημοσύνης. Με βάση τα παραπάνω, απορρίφθηκαν περίπου 160 άρθρα, με αποτέλεσμα να μείνουν 140 για τη φάση της πλήρους αξιολόγησης. Στη συνέχεια τα άρθρα εξετάστηκαν με πλήρη ανάγνωση και επιλέχθηκαν αυτά που είχαν θεματική συνάφεια, τεχνική ποιότητα και μεθοδολογία, παρουσία τεχνικών ροής αντίληψης και ελέγχου, τεχνικές μηχανικής και βαθιάς μάθησης, και την εφαρμογή τους σε προληπτικές διαδικασίες που αφορούν τις καλλιέργειες. Από τα 140 άρθρα της φάσης αυτής κρίθηκαν ως κατάλληλα τα 69, τα οποία συμπεριλήφθηκαν και στην τελική σύνθεση της συστηματικής ανασκόπησης.

2.2 Κριτήρια εισαγωγής-αποκλεισμού

Τα άρθρα που επιλέχθηκαν για πλήρη ανάλυση πληρούσαν τα ακόλουθα κριτήρια:

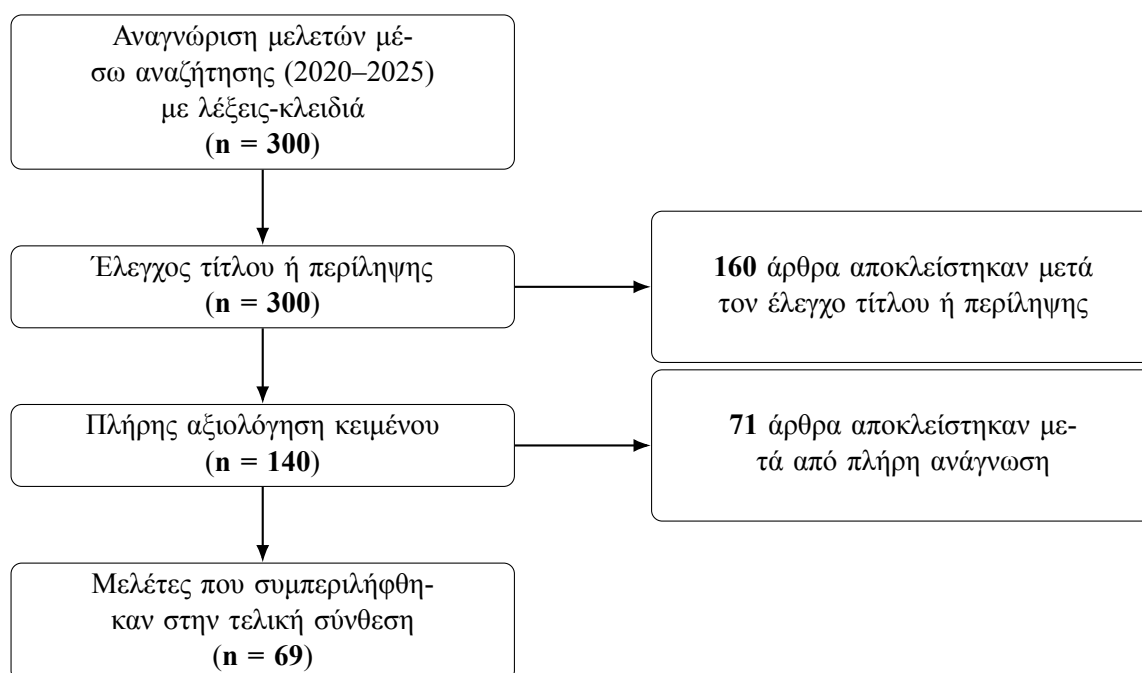
1. Απαιτήθηκε σαφής θεματική συνάφεια με τη χρήση UAVs ή UAV σημών σε εφαρμογές της γεωργίας ακριβείας.

2. Τα άρθρα έπρεπε να σχετίζονται με UAV εφαρμογές στη γεωργία ακριβείας, όπως ανίχνευση ασθενειών, καταπόνησης και υδάτινων ελλείψεων.

3. Οι μελέτες έπρεπε να εστιάζουν ρητά σε τεχνολογίες ροής αντίληψης, συλλογή δεδομένων μέσω αισθητήρων, επεξεργασία δεδομένων, εξαγωγή χαρακτηριστικών, και εκπαίδευση μοντέλων τεχνητής νοημοσύνης. Συγκεκριμένα, συμπεριλήφθηκαν έρευνες που αναλύουν αισθητήρες όπως RGB, πολυφασματικούς, υπερφασματικούς, θερμικούς και LiDAR. Επίσης συμπεριλήφθηκαν στην ανασκόπηση έρευνες που περιλάμβαναν φωτογραμμετρικές τεχνικές, δείκτες βλάστησης και αλγορίθμους μηχανικής και βαθιάς μάθησης.

4. Συμπεριλήφθηκαν άρθρα μεταξύ 2020-2025, προκειμένου η ανασκόπηση να εστιάσει στις πλέον πρόσφατες εξελίξεις του πεδίου. Επίσης αντιστοιχεί και στην περίοδο με τη μεγαλύτερη ερευνητική δραστηριότητα και τεχνολογική πρόοδο στον τομέα των UAVs για εφαρμογές στη γεωργία ακριβείας.

Τα άρθρα αποκλείστηκαν όταν αφορούσαν μη γεωργικές εφαρμογές UAV όπως επιτήρηση κυκλοφορίας, ασφάλεια, μεταφορές. Αφαιρέθηκαν μελέτες χαμηλής τεχνικής πληρότητας, όπως περιγραφικές παρουσιάσεις των UAVs χωρίς να εμβαθύνουν στις τεχνικές λεπτομέρειες των αισθητήρων ή τις τεχνικές μηχανικής και βαθιάς μάθησης που χρησιμοποιούνται. Αποκλείστηκαν επίσης παλαιότερες έρευνες που δεν ενσωματώνουν σύγχρονα συστήματα ροής αντίληψης με τεχνητή νοημοσύνη.



Σχήμα 2.1: Διάγραμμα ροής PRISMA της διαδικασίας επιλογής μελετών για τη Συστηματική Ανασκόπηση Βιβλιογραφίας (SLR).

Κεφάλαιο 3ο: Ροή αντίληψης στα UAVs

Η αντίληψη στα UAVs αποτελεί τη βασική ικανότητα που επιτρέπει την αυτόνομη κατανόηση του γεωργικού περιβάλλοντος. Στη γεωργία ακριβείας, η αντίληψη των UAVs περιγράφει τη διαδικασία από άκρο σε άκρο μέσω της οποίας η πλατφόρμα σαρώνει το χωράφι, εξάγει δεδομένα και παρέχει χρήσιμες πληροφορίες που υποστηρίζουν εργασίες, όπως ο ψεκασμός, η ανίχνευση καταπόνησης, η έγκαιρη αναγνώριση ασθενειών και ο συντονισμός σημνών UAV. Η αντίληψη περιλαμβάνει τη μετατροπή ακατέργαστων δεδομένων, που λαμβάνονται από κάμερες RGB, πολυφασματικούς και υπερφασματικούς αισθητήρες, LiDAR, θερμικούς αισθητήρες, σε χρήσιμα ερμηνεύσιμα χαρακτηριστικά που μπορούν να καθοδηγήσουν τη λήψη αποφάσεων σε πραγματικό χρόνο.

Οι σύγχρονες διαδικασίες αντίληψης των UAVs συνδέονται στενά με την εξέλιξη των αισθητήρων και την ανάλυση δεδομένων με βάση την τεχνητή νοημοσύνη. Οι αεροφωτογραφίες υψηλής ανάλυσης υποστηρίζουν την έγκαιρη διάγνωση των ασθενειών, επιτρέποντας στα UAV να ανιχνεύουν λεπτές διακυμάνσεις στην ανακλαστικότητα της βλάστησης ή στη θερμοκρασία του φυλλώματος πολύ πριν γίνουν ορατές στο ανθρώπινο μάτι. Οι αισθητήρες επιτρέπουν την εκτίμηση της βιομάζας, της περιεκτικότητας σε χλωροφύλλη και των επιπέδων αζώτου, οδηγώντας σε πιο ακριβή παρακολούθηση της υγείας των φυτών και της δυναμικής τους ανάπτυξης. Όταν ενσωματώνονται σε μοντέλα μηχανικής μάθησης, αυτές οι μέθοδοι ανίχνευσης παρέχουν σημαντικές πληροφορίες, επιτρέποντας στα UAVs να χαρτογραφούν ζιζάνια, να ανιχνεύουν ασθένειες και να εκτιμούν τη μελλοντική απόδοση της καλλιέργειας με αυξανόμενη ακρίβεια.

Επιπλέον, η αντίληψη είναι ένας κρίσιμος παράγοντας για την αυτόνομη λήψη αποφάσεων σε σμήνη UAV. Τα UAVs που λειτουργούν συλλογικά βασίζονται στην κοινή αντίληψη για να συντονίζουν τις διαδρομές πτήσης, να αποφεύγουν εμπόδια, να διατηρούν σχηματισμούς και να προσαρμόζονται σε δυναμικά γεωργικά περιβάλλοντα, τα οποία εξετάζονται αναλυτικά στη συνέχεια της παρούσας ενότητας.

3.1 Σμήνη απο UAV

Η γεωργία ακριβείας βασίζεται στη συνεχή και έγκαιρη παρακολούθηση των καλλιεργειών, με στόχο την προληπτική ανίχνευση προβλημάτων όπως διάφορες ασθένειες ή έλλειψη νερού. Κεντρικό στοιχείο για την αποτελεσματική λειτουργία των σημνών UAV είναι ο σχηματισμός ελέγχου (formation control), δηλαδή ο συντονισμένος έλεγχος της σχετικής θέσης και κίνησης των UAVs, όπως φαίνεται στο σχήμα 3.1. Στο πλαίσιο της γεωργίας ακριβείας, ο σχηματισμός ελέγχου δεν αποσκοπεί μόνο στη διατήρηση μιας σωστής γεωγραφικής θέσης, αλλά στη βελτιστοποίηση της συλλογής δεδομένων και στην έγκαιρη ανίχνευση και πρόληψη όπως ο στοχευμένος ψεκασμός ή η επαναληπτική επιθεώρηση περιοχών υψηλού κινδύνου.

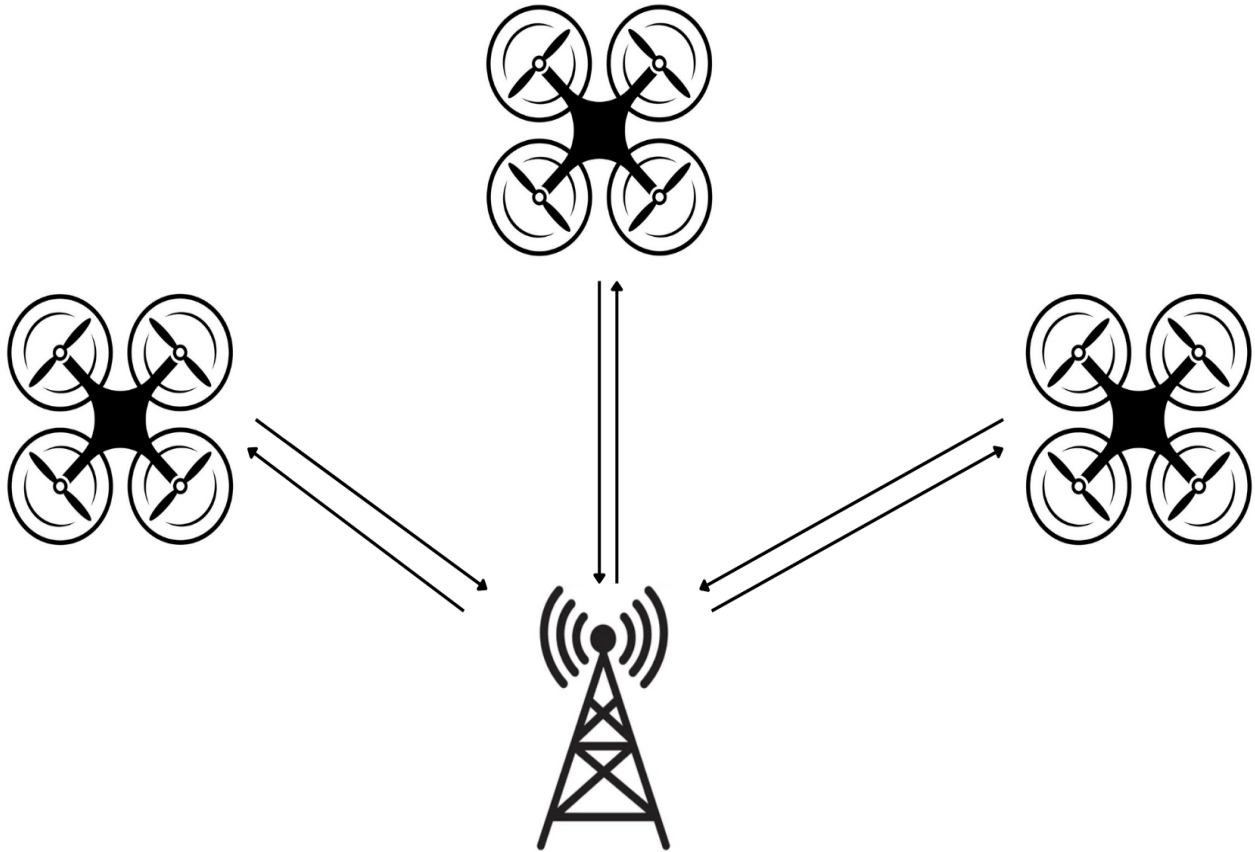


Σχήμα 3.1: Στοχευμένη εφαρμογή λιπάσματος σε καλλιέργεια απο σμήνος UAV. [1]

3.1.1 Αρχιτεκτονικές σχηματισμού ελέγχου σε σμήνη UAV


Οι αρχιτεκτονικές σχηματισμού ελέγχου καθορίζουν το πώς κατανέμεται η λήψη αποφάσεων στο σμήνος και πώς ρέει η πληροφορία μεταξύ των UAVs. Στη γεωργία ακριβείας, η επιλογή αρχιτεκτονικής επηρεάζει άμεσα τη χρονική απόκριση και την αξιοπιστία των προληπτικών εφαρμογών στις καλλιέργειες.

Κεντροκοποιημένη αρχιτεκτονική: Στην κεντροκοποιημένη αρχιτεκτονική (Centralized Architecture), όπως φαίνεται στο σχήμα 3.2, ένας κεντρικός κόμβος (π.χ. σταθμός εδάφους ή κεντρικό UAV) συλλέγει όλα τα δεδομένα, λαμβάνει τις αποφάσεις και αποστέλλει εντολές στα επιμέρους UAVs. Το κύριο πλεονέκτημα της προσέγγισης αυτής είναι η απλότητα στον σχεδιασμό και η συνοχή στη λήψη αποφάσεων. Ωστόσο, η κεντροκοποιημένη αρχιτεκτονική παρουσιάζει σοβαρούς περιορισμούς σε θέματα καθυστέρησης επικοινωνίας και ανθεκτικότητας, καθώς η αποτυχία του κεντρικού κόμβου μπορεί να οδηγήσει σε πλήρη κατάρρευση του σμήνους [16]. Στη γεωργία ακριβείας, η προσέγγιση αυτή είναι κατάλληλη για προγραμματισμένες αποστολές χαρτογράφησης, όπου η πτήση, το ύψος και το μοτίβο κάλυψης είναι εκ των προτέρων καθορισμένα. Ωστόσο, σε σενάρια προληπτικής ανίχνευσης, όπως αιφνίδια εμφάνιση καταπόνησης λόγω καύσωνα, η κεντροκοποιημένη αρχιτεκτονική παρουσιάζει περιορισμούς, καθώς η καθυστέρηση επικοινωνίας και το μοναδικό σημείο αστοχίας (single point of failure) μειώνουν την ικανότητα άμεσης αντίδρασης του συστήματος.



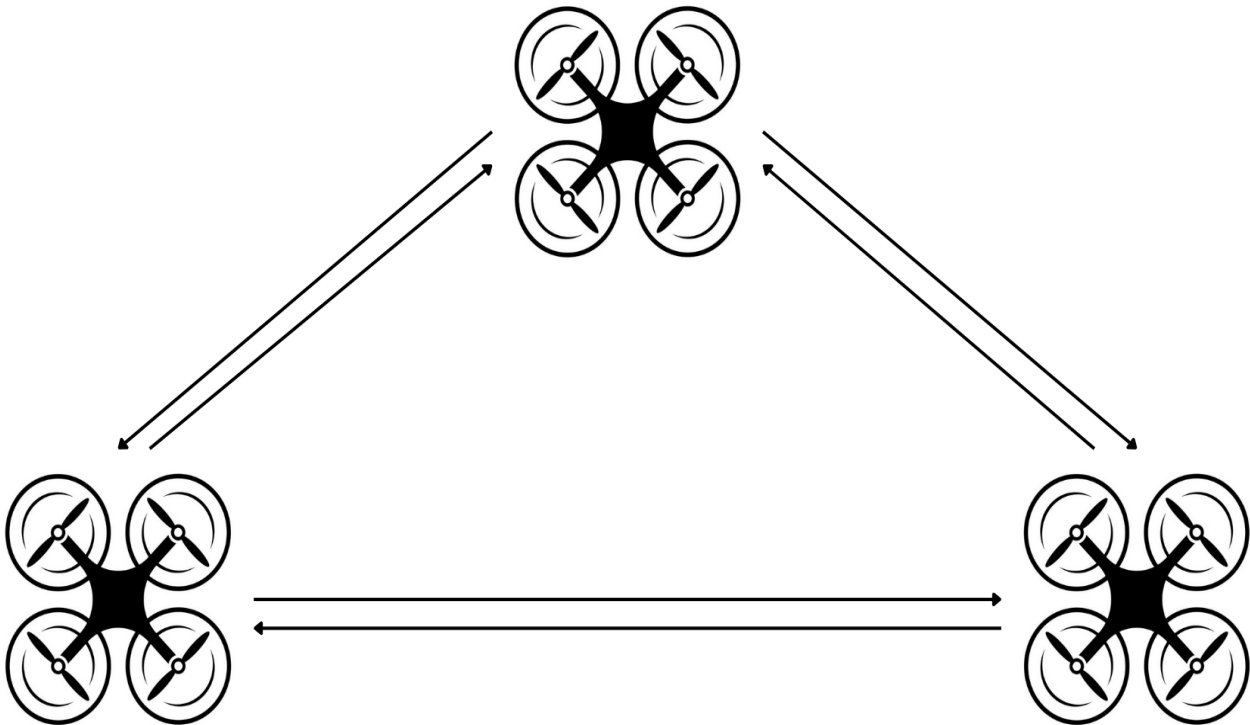
Σχήμα 3.2: Κεντροποιημένη αρχιτεκτονική

Αποκεντρωμένη αρχιτεκτονική: Στην αποκεντρωμένη αρχιτεκτονική (Decentralized Architecture), όπως φαίνεται στο σχήμα 3.3, κάθε UAV λειτουργεί ως αυτόνομη μονάδα, λαμβάνοντας αποφάσεις βάσει των δεδομένων που λαμβάνει από τους αισθητήρες του, ενώ η πληροφορία που ανταλλάσσει από τα γειτονικά UAVs είναι περιορισμένη. Δεν υπάρχει κεντρικός κόμβος, ενώ ο σχηματισμός διατηρείται μέσω των τοπικών κανόνων και αλληλεπιδράσεων [16]. Η αρχιτεκτονική αυτή ενισχύει την ανθεκτικότητα του σμήνους, καθώς η αποτυχία ενός UAV δεν επηρεάζει καθοριστικά τη συνολική λειτουργία του συστήματος. Ωστόσο, η έλλειψη ενός κεντρικού κόμβου που δίνει πληροφορίες, μπορεί να δυσκολέψει τον ακριβή συγχρονισμό και τη διατήρηση σύνθετων σχηματισμών. Σε καλλιέργειες όπου μπορεί να εμφανιστούν τοπικά φαινόμενα όπως υδάτινη έλλειψη ή αρχικές ενδείξεις ασθένειας μπορούν να ανιχνευθούν και να διερευνηθούν άμεσα μέσω της ταυτόχρονης συλλογής δεδομένων από ετερογενείς αισθητήρες που φέρει το κάθε UAV του σμήνους, χωρίς να απαιτείται κεντρική παρέμβαση.



Σχήμα 3.3: Αποκεντρωμένη αρχιτεκτονική

Κατανεμημένη αρχιτεκτονική: Η κατανεμημένη αρχιτεκτονική (Distributed Architecture), όπως φαίνεται στο σχήμα 3.4, συνδυάζει την αυτονομία των UAVs με τη συνεργατική λήψη αποφάσεων μέσω συνεχούς ανταλλαγής πληροφορίας. Κάθε UAV διαθέτει μερική εικόνα της καλλιέργειας, ωστόσο οι αποφάσεις προκύπτουν συλλογικά, με στόχο τη βελτιστοποίηση της συνολικής αποστολής. Η κατανεμημένη προσέγγιση προσφέρει αυξημένη ευελιξία και προσαρμοστικότητα, κάνοντάς την κατάλληλη για παρεμβάσεις σε πραγματικό χρόνο, αλλά απαιτεί αξιόπιστα δίκτυα επικοινωνίας και αυξημένους υπολογιστικούς πόρους [18]. Η κατανεμημένη αρχιτεκτονική επιτρέπει την ταχεία συλλογική αντίδραση του σμήνους σε ανωμαλίες των καλλιιεργειών. Για παράδειγμα, πολλαπλά UAVs μπορούν να συμφωνήσουν δυναμικά στην ανακατανομή τους πάνω από περιοχές υψηλού κινδύνου, ενισχύοντας την έγκαιρη παρέμβαση και την προληπτική λήψη αποφάσεων.



Σχήμα 3.4: Κατανεμημένη αρχιτεκτονική

3.1.2 Μέθοδοι σχηματισμού ελέγχου σε σμήνη μη επανδρωμένων εναέριων οχημάτων

Οι μέθοδοι σχηματισμού ελέγχου των σμηνών βασίζονται σε κάποιες παραδοσιακές στρατηγικές. Οι μέθοδοι αυτές μπορούν να ταξινομηθούν σε 5 βασικές κατηγορίες οι οποίες θα αναλυθούν παρακάτω, την μέθοδο ηγέτη-ακόλουθου (leader–follower), εικονικής δομής (virtual structure), συμπεριφορικές μέθοδοι (behavior-based), συναινετικοί μέθοδοι (consensus-based) και τεχνητών δυναμικών πεδίων (Artificial Potential Fields – APF).

Ηγέτης-Ακόλουθος: Η μέθοδος Ηγέτης-Ακόλουθος βασίζεται στην καθοδήγηση του σμήνους από ένα ή περισσότερα UAVs-ηγέτες. Στη γεωργία ακριβείας, ο ηγέτης μπορεί να ακολουθεί προκαθορισμένες διαδρομές χαρτογράφησης, ενώ οι ακόλουθοι συλλέγουν συμπληρωματικά δεδομένα. Η μέθοδος αυτή είναι απλή και αποτελεσματική για συστηματικό έλεγχο καλλιεργειών, ωστόσο σε περίπτωση που ο ηγέτης παρουσιάσει κάποιο πρόβλημα, είναι πολύ πιθανό να επηρεαστεί το σύνολο του σμήνους, λόγω της εξάρτησης του από αυτόν [19].

Εικονική δομή: Στη μέθοδο εικονικής δομής, το σμήνος αντιμετωπίζεται ως ένα ενιαίο σώμα. Η προσέγγιση αυτή επιτρέπει υψηλή ακρίβεια στη διατήρηση του σχηματισμού και είναι ιδιαίτερα χρήσιμη σε εφαρμογές υψηλής ακρίβειας, όπως η πολυφασματική χαρτογράφηση καλλιεργειών για την έγκαιρη ανίχνευση ασθενειών. Η σταθερότητα του σχηματισμού διασφαλίζει ομοιογενή δεδομένα, γεγονός κρίσιμο για αξιόπιστη προληπτική ανάλυση. Παρόλα αυτά εμφανίζει μειωμένη ευελιξία σε δυναμικά περιβάλλοντα [20].

Συμπεριφορικές μέθοδοι: Οι συμπεριφορικές μέθοδοι βασίζονται σε απλούς κανόνες συμπεριφοράς που χειρίζονται τοπικά και ανάλογα με την κατάσταση των γειτονικών UAVs. Αυτοί οι κανόνες μπορεί να είναι η διατήρηση κοντινής απόστασης με το γειτονικό UAV, η αποφυγή συγκρούσεων και η ευθυγράμμιση προς την ίδια κατεύθυνση με τα γειτονικά UAVs. Αυτή η μέθοδος κάνει τα UAVs πιο εύελικτα και τα βοηθάει να αυτοδιοργανώνονται σε δυναμικά περιβάλλοντα, κρατώντας σωστό σχηματισμό και ακολουθώντας την τροχιά που τους έχει ανατεθεί αποφεύγοντας τυχόν εμπόδια [21].

Συναινετικοί μέθοδοι: Οι συναινετικοί μέθοδοι επιτρέπουν στα UAVs ενός σμήνους να συντονίζουν τη συμπεριφορά τους, χωρίς την ύπαρξη κεντρικού ελεγκτή. Κάθε UAV προσαρμόζει την κατάστασή του αξιοποιώντας πληροφορίες που ανταλλάσσει με τα γειτονικά του UAVs, με στόχο τη σταδιακή σύγκλιση του συνόλου του σμήνους σε κοινή ταχύτητα και προσανατολισμό. Η συγκεκριμένη προσέγγιση ενισχύει την ανθεκτικότητα του συστήματος, καθώς περιορίζει την ύπαρξη μοναδικού σημείου αστοχίας και επιτρέπει την εύκολη επέκταση του σμήνους. Παρά τα πλεονεκτήματά της, η αποτελεσματικότητα των συναινετικών μεθόδων εξαρτάται σε μεγάλο βαθμό από την αξιοπιστία της επικοινωνίας μεταξύ των UAVs και την ταχύτητα σύγκλισης των αλγορίθμων, ιδίως σε δυναμικά περιβάλλοντα [22].

Τεχνητά δυναμικά πεδία: Οι μέθοδοι τεχνητών δυναμικών πεδίων βασίζονται στη χρήση εικονικών δυνάμεων που επηρεάζουν την κίνηση κάθε UAV, κατευθύνοντάς το προς τις επιθυμητές θέσεις εντός του σχηματισμού και απομακρύνοντάς το από εμπόδια ή γειτονικά UAVs. Μέσω της πληροφορίας που προέρχεται από τους αισθητήρες ή την ανταλλαγή δεδομένων, τα UAVs ρυθμίζουν συνεχώς την τροχιά τους ώστε να διατηρείται η συνοχή και η ασφάλεια του σμήνους. Στη γεωργία ακριβείας, οι μέθοδοι τεχνητών δυναμικών επιτρέπουν τη δυναμική αναδιάταξη UAVs γύρω από περιοχές υψηλού κινδύνου, διατηρώντας ασφαλείς αποστάσεις και αποφεύγοντας συγκρούσεις. Τα χαρακτηριστικά αυτά αποδεικνύονται ιδιαίτερα χρήσιμα για την έγκαιρη και στοχευμένη προληπτική παρακολούθηση των καλλιεργειών [23].

Οι αρχιτεκτονικές και οι μέθοδοι σχηματισμού ελέγχου που παρουσιάστηκαν αποτελούν το θεμέλιο για τον αποτελεσματικό συντονισμό των σμηνών UAV, ωστόσο η επιχειρησιακή τους αξία εξαρτάται άμεσα από την ικανότητα των UAV να αντιλαμβάνονται το γεωργικό περιβάλλον στο οποίο δραστηριοποιούνται. Ο σχηματισμός, η συνεργασία και η συλλογική λήψη αποφάσεων προϋποθέτουν αξιόπιστη και έγκαιρη πληροφόρηση σχετικά με την κατάσταση των καλλιεργειών και τις μεταβαλλόμενες συνθήκες του αγρού. Για τον λόγο αυτό, η έννοια της αντίληψης αποτελεί τον επόμενο κρίσιμο άξονα της ροής λειτουργίας των UAV, καθώς συνδέει τον έλεγχο και τον συντονισμό των σμηνών με τη συλλογή, την επεξεργασία και την ερμηνεία των δεδομένων που υποστηρίζουν τις προληπτικές εφαρμογές της γεωργίας ακριβείας.

3.2 Συλλογή δεδομένων

Η ροή της αντίληψης των UAVs ξεκινάει με τη συλλογή δεδομένων μέσω ενσωματωμένων αισθητήρων. Η ποιότητα των δεδομένων που συλλέγουμε από τους αισθητήρες, δηλαδή μεγάλος όγκος και υψηλής ευκρίνειας δεδομένα σε μικρό χρονικό διάστημα, παίζει σημαντικό ρόλο στη γεωργία ακριβείας καθώς καθορίζουν την ακρίβεια των πληροφοριών που δέχονται τα μοντέλα που παίρνουν τις αποφάσεις. Οι αισθητήρες που έχουν τα νέα UAVs που χρησιμοποιούνται στη γεωργία ακριβείας αναλύονται παρακάτω.

RGB κάμερες: Οι RGB (Red Green Blue) κάμερες χρησιμοποιούνται κυρίως για χαρτογράφηση και παρακολούθηση των καλλιεργειών. Μπορούν να καταγράψουν το ορατό φως δηλαδή μήκη κύματος μεταξύ 400-700 nm (νανόμετρα). Είναι χαμηλές σε κόστος και μπορούν να καταγράψουν εικόνες υψηλής ευκρίνειας. Η επεξεργασία της πληροφορίας που λαμβάνουν είναι σχετικά απλή. Το κύριο μειονέκτημα, είναι η ακαταλληλότητά τους για την ανάλυση βλάστησης η οποία απαιτεί πληροφορίες εκτός του ορατού φάσματος. Για αυτό συνήθως χρησιμοποιούνται μαζί με άλλους αισθητήρες.



Σχήμα 3.5: Κάμερα RGB [2]

Πολυφασματικοί και υπερφασματικοί αισθητήρες: Οι πολυφασματικοί αισθητήρες καταγράφουν 4 έως 6 κανάλια, στις περιοχές του ορατού 400–700 nm και του εγγύς υπέρυθρου 700–1000 nm. Αντίθετα, οι υπερφασματικοί αισθητήρες μπορούν να καταγράψουν εκατοντάδες στενές φασματικές ζώνες, καλύπτοντας συχνά ένα εύρος από 400 έως 2500 nm με φασματική ανάλυση 2–10 nm. Αυτοί οι αισθητήρες είναι απαραίτητοι για την αξιολόγηση της υγείας των φυτών και την έγκαιρη ανίχνευση καταπόνησης. Ένα μειονέκτημα των πολυφασματικών αισθητήρων είναι η ευαισθησία τους σε διάφορες καιρικές συνθήκες. Επίσης οι υπερφασματικοί αισθητήρες παράγουν πολύ μεγάλο όγκο δεδομένων τα οποία μπορεί να επιβραδύνουν την διαδικασία της επεξεργασίας που γίνεται από τα μοντέλα μηχανικής μάθησης.



Σχήμα 3.6: Πολυφασματική κάμερα [3]

Θερμικές κάμερες: Οι θερμικές κάμερες λειτουργούν κυρίως στο μήκος κύματος από 7.5-14 μm (μικρόμετρα), τη λεγόμενη υπέρυθη, και έχουν θερμική ανάλυση από 0.5°C-0.1°C. Όλα τα αντικείμενα που έχουν θερμοκρασία πάνω από το απόλυτο 0, δηλαδή -273°C, εκπέμπουν υπέρυθη ακτινοβολία. Οι θερμικές κάμερες ανιχνεύουν αυτή την ακτινοβολία και τη μεταφράζουν σε εικόνα, όπου τα θερμά αντικείμενα απεικονίζονται σε αποχρώσεις του κόκκινου, ενώ τα κρύα αντικείμενα σε αποχρώσεις του μπλε χρώματος. Οι θερμικές κάμερες παρέχουν ακριβή δεδομένα για τη θερμότητα των καλλιεργειών επιτρέποντας τα μοντέλα τεχνητής νοημοσύνης να ελέγχουν την ποσότητα ποτίσματος που χρειάζονται οι καλλιέργειες.



Σχήμα 3.7: Θερμική κάμερα [4]

LiDAR: Τα LiDAR (Light Detection and Ranging) είναι αισθητήρες οι οποίοι χρησιμοποιούνται για την τρισδιάστατη χαρτογράφηση του εδάφους. Τα LiDAR εκπέμπουν παλμούς λέιζερ και μετράνε τον χρόνο επιστροφής και την κατεύθυνση της εκπομπής. Με αυτό τον τρόπο ο αισθητήρας καταγράφει την απόσταση κάθε σημείου στην επιφάνεια και δημιουργεί έναν τρισδιάστατο χάρτη του εδάφους με πολύ υψηλή ακρίβεια. Μειονεκτήματά τους είναι η περιορισμένη χρήση τους σε πυκνές καλλιέργειες και το υψηλό κόστος του εξοπλισμού.



Σχήμα 3.8: LiDAR κάμερα [5]

SAR: Τα SAR (Synthetic Aperture Radar) είναι αισθητήρες, οι οποίοι χρησιμοποιούνται για τη χαρτογράφηση των καλλιεργειών. Εκπέμπουν παλμούς μικροκυμάτων τα οποία πέφτουν στο έδαφος, κάποια μικροκύματα ανακλώνται ή μπορεί να απορροφηθούν, αυτό εξαρτάται από την υγρασία του εδάφους, την δομή της βλάστησης, το σχήμα των φυλλωμάτων και των κλαδιών. Τα πλεονέκτηματά τους σε σχέση με άλλους αισθητήρες είναι ότι δεν χρειάζονται φως και διαπερνούν τα σύννεφα, τη βροχή και την ομίχλη. Μειονεκτήματά τους είναι η απαίτηση υψηλής τεχνικής κατάρτισης και το μεγάλο κόστος.



Σχήμα 3.9: SAR κάμερα [6]

Η συλλογή δεδομένων μέσω των διαφορετικών τύπων αισθητήρων αποτελεί ένα απαραίτητο στάδιο της ροής αντίληψης των UAVs, ωστόσο τα ακατέργαστα δεδομένα από μόνα τους δεν επαρκούν για τη στήριξη τεκμηριωμένων αποφάσεων στη γεωργία ακριβείας. Για να μετατραπούν οι εικόνες και οι μετρήσεις των αισθητήρων σε χρήσιμη και ερμηνεύσιμη πληροφορία, απαιτείται η εφαρμογή κατάλληλων μεθόδων επεξεργασίας και ανάλυσης. Το επόμενο στάδιο της ροής αντίληψης επικεντρώνεται, επομένως, στην επεξεργασία των συλλεγόμενων δεδομένων, όπου μέσω φωτογραμμετρικών τεχνικών, δεικτών βλάστησης και μεθόδων μηχανικής και βαθιάς μάθησης εξάγονται δομημένες πληροφορίες που υποστηρίζουν την ανίχνευση καταπόνησης, ασθενειών και τη λήψη αποφάσεων σε πραγματικό χρόνο.


3.3 Επεξεργασία δεδομένων

Η αποτελεσματική αντίληψη στα UAVs βασίζεται σε μια ισχυρή και πολυεπίπεδη ροή επεξεργασίας δεδομένων, η οποία μετατρέπει τις ακατέργαστες εικόνες από τις κάμερες, και τα δεδομένα από τις μετρήσεις των αισθητήρων σε ολοκληρωμένα και δομημένα σύνολα δεδομένων τα οποία χρησιμοποιούνται για τη λήψη αποφάσεων σε πραγματικό χρόνο και την ανίχνευση ευπαθειών στις καλλιέργειες. Η επεξεργασία των δεδομένων δεν είναι ένα συμπληρωματικό βήμα, αλλά ο βασικός μηχανισμός της διαδικασίας αντίληψης των UAVs. Για την επεξεργασία αυτών των δεδομένων χρησιμοποιούνται φωτογραμμετρικές τεχνικές και δείκτες βλάστησης (Vegetation index - Vi) σε συνδυασμό τεχνικές μηχανικής μάθησης, οι οποίες θα αναλυθούν παρακάτω.

3.3.1 Φωτογραμμετρικές τεχνικές

Οι φωτογραμμετρικές τεχνικές αποτελούν θεμελιώδες στοιχείο της ροής επεξεργασίας δεδομένων στα UAVs, καθώς επιτρέπουν την ακριβή ανακατασκευή τρισδιάστατων αναπαραστάσεων γεωργικών καλλιεργειών από πολλαπλές επικαλυπτόμενες δισδιάστατες εικόνες. Στην ουσία, η φωτογραμμετρία είναι μια ακριβής γεωγραφική αναπαράσταση μιας καλλιέργειας η οποία δημιουργείται με την καταγραφή

πολλών εικόνων στην ίδια περιοχή από πολλές διαφορετικές οπτικές γωνίες. Μέσω αυτών των φωτογραμμετρικών τεχνικών δημιουργούνται λεπτομερή τρισδιάστατα μοντέλα, ψηφιακά μοντέλα υψομέτρου (Digital Elevation Models - DEM), σχήμα 3.10, και ορθοφωτογραφίες.[3]



Σχήμα 3.10: Ψηφιακό Μοντέλο Εδάφους. [7]

Οι αισθητήρες των UAVs βοηθάνε στην κατασκευή τρισδιάστατων μοντέλων με πολύ υψηλή ανάλυση, σε αντίθεση με τους δορυφόρους. Αυτό συμβαίνει λόγω της καταγραφής εικόνων σε μικρή απόσταση από το έδαφος. Επιπλέον, σε πολλές περιπτώσεις απαιτείται η λήψη πολλών επικαλυπτόμενων εικόνων για τη συλλογή των απαραίτητων πληροφοριών ώστε να είναι εφικτή η ορθή παρακολούθηση και μελέτη των καλλιεργειών. Αυτά τα τρισδιάστατα μοντέλα παρέχουν πληροφορίες σχετικά με τα χαρακτηριστικά των καλλιεργειών όπως το ύψος ή πυκνότητα των φυτών, βοηθώντας έτσι στη δημιουργία χαρτών δεικτών Βλάστησης (Vegetation Indices Map). Επίσης μπορούν να χρησιμοποιηθούν ως εργαλεία σε άλλες τεχνικές.[3]

Οι φωτογραμμετρικές τεχνικές εφαρμόζονται κυρίως για την κατασκευή ορθοφωτοχαρτών και ψηφιακών μοντέλων υψομέτρου. Χρησιμοποιούνται για την άντληση τρισδιάστατων πληροφοριών σχετικά με την βλάστηση των καλλιεργειών. Ψηφιακό μοντέλο υψομέτρου θεωρείται κάθε ψηφιακή αναπαράσταση του εδάφους και η δημιουργία τους βασίζεται σε αρχεία καταγραφών της επιφάνειας της γης. Τα ψηφιακά μοντέλα υψομέτρου χωρίζονται σε δύο κατηγορίες, τα ψηφιακά μοντέλα επιφάνειας (Digital Surface Model - DSM) και τα ψηφιακά μοντέλα εδάφους (Digital Terrain Model - DTM), οι οποίες θα αναλυθούν

παρακάτω.

Αρχικά, ο αλγόριθμος χρησιμοποιεί το αρχείο καταγραφής από το UAV, για να παρέχει αρχικές εκτιμήσεις για τη θέση και τον προσανατολισμό κάθε εικόνας. Στη συνέχεια, εφαρμόζει τη διαδικασία εναέριας τριγωνοποίησης, μέσω της οποίας υπολογίζει τις πραγματικές θέσεις των εικόνων από μια εναέρια αποστολή.

Κατά τη διάρκεια αυτής της διαδικασίας, ο αλγόριθμος δημιουργεί έναν μεγάλο αριθμό συζευγμένων σημείων που αναγνωρίζονται σε πολλές εικόνες. Έπειτα, με τη διαδικασία συνόρθωσης δέσμης μπλοκ (bundle block adjustment) χρησιμοποιεί αυτά τα αυτοματοποιημένα συζευγμένα σημεία ώστε να βελτιστοποιήσει τις θέσεις και τους προσανατολισμούς των φωτογραφιών, παράγοντας μεγάλο αριθμό παρατηρήσεων, οι οποίες χρησιμοποιούνται για να εξαχθεί μια αποδοτική λύση μέσω της μεθόδου προσαρμογής ελαχίστων τετραγώνων [24].

Για να ελεγχθεί το πόσο ακριβές είναι το αποτέλεσμα της μεθόδου, ο αλγόριθμος περιλαμβάνει και κάποια σημεία ελέγχου. Στη συνέχεια, οι εικόνες χρησιμοποιούνται για τη δημιουργία ενός ψηφιακού μοντέλου επιφάνειας, το οποίο παρέχει μια λεπτομερή αναπαράσταση της επιφάνειας του εδάφους, συμπεριλαμβανομένων των αντικειμένων που βρίσκονται πάνω σε αυτή, όπως δέντρα, φυτά ή κτίρια.

Στη συνέχεια δημιουργείται το ψηφιακό μοντέλο εδάφους, το οποίο αναπαριστά το υψόμετρο του εδάφους από την επιφάνεια της Γης, χωρίς όμως να συμπεριλαμβάνει αντικείμενα όπως κτήρια ή δέντρα.

Αφού ο αλγόριθμος δημιουργήσει το ψηφιακό μοντέλο εδάφους, μπορεί να εκτελεστεί η διαδικασία ορθοδιόρθωσης (orthorectification) ώστε να αφαιρεθεί η παραμόρφωση από τις αρχικές εικόνες. Στη συνέχεια, ο αλγόριθμος συνδυάζει τις επιμέρους εικόνες σε ένα ορθομοσαϊκό, ώστε να παραχθεί μια ενιαία εικόνα της καλλιέργειας, στην επιθυμητή ανάλυση. Αυτά τα μοντέλα είναι πολύτιμα, καθώς παρέχουν πληροφορίες για το ύψος της βλάστησης, την αρχιτεκτονική των θόλων, την πυκνότητα και τη συνολική ανάπτυξη των καλλιεργειών [25].

Τα ψηφιακά μοντέλα υψομέτρου μπορούν επίσης να χρησιμοποιηθούν για τη δημιουργία ορθοφωτογραφιών. Σε αντίθεση με τις τυπικές αεροφωτογραφίες, οι ορθοφωτογραφίες διατηρούν τις πραγματικές αποστάσεις και ενσωματώνουν τρισδιάστατες δομικές πληροφορίες. Οι φωτογραμμετρικές τεχνικές εφαρμόζονται εκτενώς στη γεωργία ακριβείας και είναι απαραίτητες για την κατασκευή χαρτών με δείκτες βλάστησης.


3.3.2 Δείκτες βλάστησης

Οι Δείκτες βλάστησης (Vegetation Indices - VIs) αποτελούν ένα από τα πλέον διαδεδομένα εργαλεία στη γεωργία ακριβείας, καθώς επιτρέπουν τη μετατροπή φασματικών δεδομένων σε δείκτες που περιγράφουν τη κατάσταση της βλάστησης. Η ευρεία χρήση τους οφείλεται στο γεγονός ότι παρέχουν αξιόπιστες πληροφορίες σχετικά με τις καλλιέργειες, υποστηρίζοντας διαδικασίες παρακολούθησης, αξιολόγησης και λήψης αποφάσεων.

Οι δείκτες βλάστησης βασίζονται στη διαφορετική συμπεριφορά της βλάστησης σε επιμέρους περιοχές του ηλεκτρομαγνητικού φάσματος. Τα φυτά παρουσιάζουν χαρακτηριστικά απορρόφησης και ανάκλα-

σης, τα οποία συνδέονται άμεσα με τη χλωροφύλλη, τη δομή του φυλλώματος και τη γενικότερη φυσιολογική τους κατάσταση. Οι μαθηματικοί συνδυασμοί φασματικών ζωνών που χρησιμοποιούνται για τον υπολογισμό των δεικτών βλάστησης έχουν σχεδιαστεί με σκοπό να ενισχύουν τη συμβολή της φυτικής πληροφορίας και να μειώνουν την επίδραση εξωτερικών παραγόντων, όπως το υπόβαθρο του εδάφους ή οι μεταβολές του φωτισμού, οι οποίοι ενδέχεται να αλλοιώσουν την ακρίβεια της ανάλυσης.

Η δημιουργία των δεικτών βλάστησης εντάσσεται σε μια ολοκληρωμένη αλυσίδα επεξεργασίας δεδομένων για την παρακολούθηση των καλλιεργειών. Αρχικά, τα δεδομένα συλλέγονται από πλατφόρμες, όπως μη επανδρωμένα εναέρια οχήματα, και στη συνέχεια υφίστανται στάδια προεπεξεργασίας. Οι δείκτες μπορούν να υπολογιστούν είτε σε επίπεδο μεμονωμένων εικόνων είτε μετά τη δημιουργία ορθοφωτοχαρτών που απεικονίζουν ολόκληρη την καλλιεργούμενη περιοχή, όπως φαίνεται στο σχήμα 3.11, προσφέροντας τη δυνατότητα ανάλυσης σε διαφορετικές χωρικές κλίμακες και διευκολύνοντας τη συγκριτική μελέτη δεδομένων σε βάθος χρόνου.



Σχήμα 3.11: Χάρτης δείκτη βλάστησης NDVI. [8]

Η εξαγωγή πολλαπλών δεικτών βλάστησης αποτελεί καθιερωμένη πρακτική, καθώς κάθε δείκτης αποτυπώνει διαφορετικές πτυχές της κατάστασης της βλάστησης. Μέσω της συνδυαστικής ανάλυσης πολλών δεικτών βλάστησης καθίσταται εφικτή η εκτίμηση ποικίλων βιολογικών και φυσιολογικών παραμέτρων, όπως η βιομάζα και η υδάτινη καταπόνηση. Οι δείκτες αυτοί παρέχουν αξιόπιστες πληροφορίες, γεγονός που τους καθιστά ιδιαίτερα χρήσιμους για τη συστηματική παρακολούθηση της κατάστασης των

καλλιεργειών.

Ένα από τα βασικά πεδία εφαρμογής των δεικτών βλάστησης είναι η παρακολούθηση της φυλλώματος της καλλιεργείας και η εκτίμηση χαρακτηριστικών που σχετίζονται με την παραγωγικότητα. Οι πληροφορίες που εξάγονται από τους δείκτες βλάστησης έχουν αποδειχθεί αποτελεσματικές για την εκτίμηση της απόδοσης των καλλιεργειών, του δείκτη ποσότητας φυλλώματος και της υδατικής καταπόνησης, επιτρέποντας τον εντοπισμό ανομοιογενειών εντός της καλλιεργείας. Η δυνατότητα αυτή είναι ιδιαίτερα κρίσιμη για την εφαρμογή πρακτικών γεωργίας ακριβείας, καθώς υποστηρίζει στοχευμένες παρεμβάσεις.

Ιδιαίτερη σημασία έχει η χρήση των δεικτών βλάστησης στην ανίχνευση φυτικών ασθενειών, όπου οι δείκτες λειτουργούν ως έμμεσοι δείκτες φυτικής καταπόνησης. Εξάγονται από εικόνες καλλιεργειών και χρησιμοποιούνται ως ανεξάρτητες μεταβλητές σε αναλύσεις συσχέτισης και παλινδρόμησης, με στόχο τη συσχέτισή τους με μετρήσεις σοβαρότητας ασθενειών που προκύπτουν από επιτόπιες παρατηρήσεις. Η προσέγγιση αυτή επιτρέπει την ποσοτική εκτίμηση της υγείας των καλλιεργειών και την έγκαιρη αναγνώριση προβλημάτων.

Οι δείκτες βλάστησης με την ενσωμάτωσή τους σε μοντέλα μηχανικής μάθησης χρησιμοποιούνται ως χαρακτηριστικά εισόδου και όχι ως τελικά κριτήρια απόφασης, επιτρέποντας την πιο ευέλικτη αξιοποίηση της πληροφορίας που περιέχουν και οδηγώντας σε υψηλότερα επίπεδα ακρίβειας στην εκτίμηση ασθενειών.

Η αποτελεσματικότητα των δεικτών βλάστησης εξαρτάται άμεσα από τον τύπο των αισθητήρων που χρησιμοποιούνται για τη συλλογή των δεδομένων. Οι πολυφασματικοί αισθητήρες προσφέρουν έναν ισορροπημένο συνδυασμό κόστους και φασματικής πληροφορίας, ενώ οι υπερφασματικοί αισθητήρες, αν και πιο πλούσιοι σε δεδομένα, συνοδεύονται από αυξημένες απαιτήσεις σε κόστος και επεξεργασία. Παράλληλα, οι αισθητήρες RGB, λόγω της ευρείας διαθεσιμότητας και του χαμηλού κόστους τους, παραμένουν ιδιαίτερα ελκυστικοί, παρότι περιορίζονται στο ορατό φάσμα και ενδέχεται να μην αποτυπώνουν κρίσιμες πληροφορίες για ορισμένες μορφές φυτικής καταπόνησης. Οι δείκτες βλάστησης αποτελούν θεμελιώδες εργαλείο της γεωργίας ακριβείας, λειτουργώντας ως κρίσιμος σύνδεσμος μεταξύ, ανάλυσης δεδομένων από εικόνες και τεκμηριωμένης λήψης αποφάσεων. Παρακάτω παρουσιάζονται οι δείκτες με τις περισσότερες αναφορές σε βιβλιογραφίες σχετικά με τη γεωργία ακριβείας μέσω των UAVs.

Κανονικοποιημένος δείκτης διαφοράς βλάστησης (NDVI): Ο κανονικοποιημένος δείκτης διαφοράς βλάστησης (NDVI) είναι ένας από τους πιο δημοφιλείς δείκτες βλάστησης που χρησιμοποιούνται στη γεωργία ακριβείας και στην παρακολούθηση με βάση τα UAVs. Πρόκειται για έναν δείκτη που προκύπτει από την αντίθεση μεταξύ της ανακλαστικότητας των φυτών στην περιοχή του κόκκινου (Red) και του εγγύς υπέρυθρου (NIR) του ηλεκτρομαγνητικού φάσματος. Σε υγιή βλάστηση, η χλωροφύλλη απορροφά έντονα το κόκκινο φως για τη φωτοσύνθεση, ενώ η εσωτερική δομή των φύλλων αντανακλά μεγάλο μέρος της ακτινοβολίας του εγγύς υπέρυθρου. Ο NDVI εκμεταλλεύεται αυτή τη συμπεριφορά για να ποσοτικοποιήσει τη φυσιολογική κατάσταση της βλάστησης.

Μαθηματικά, ο NDVI εκφράζεται ως:

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (1)$$

Αυτή η φόρμουλα ομαλοποιεί τα φαινόμενα φωτισμού και τη μεταβλητότητα των αισθητήρων, παράγοντας τιμές που θεωρητικά κυμαίνονται από -1 έως $+1$. Σε γεωργικά περιβάλλοντα, οι υψηλότερες τιμές NDVI αντιστοιχούν συνήθως σε πυκνά, υγιή φυλλώματα, ενώ οι χαμηλότερες τιμές υποδηλώνουν καταπονημένη, αραιή ή κατεστραμμένη βλάστηση. Οι πολυφασματικοί αισθητήρες που είναι τοποθετημένοι σε UAV επιτρέπουν τον υπολογισμό του NDVI σε πολύ υψηλή χωρική ανάλυση, καθιστώντας δυνατή την αξιολόγηση της κατάστασης των καλλιεργειών σε επίπεδο αγροτεμαχίου ή ακόμη και φυτού [13]. Οι ασθένειες των φυτών που ταξινομούνται ως βιοτική καταπόνηση αλλάζουν τα χρωστικά των φύλλων, τη δομή του φυλλώματος και την κυτταρική ακεραιότητα. Αυτές οι φυσιολογικές αλλαγές τροποποιούν τα πρότυπα φασματικής ανάκλασης, μειώνοντας την ανάκλαση του εγγύς υπέρυθρου και αυξάνοντας την ανάκλαση του κόκκινου, γεγονός που με τη σειρά του οδηγεί σε μετρήσιμη μείωση του NDVI. Ως αποτέλεσμα, ο NDVI χρησιμεύει ως έμμεσος δείκτης της παρουσίας και της σοβαρότητας της ασθένειας, ακόμη και πριν τα συμπτώματα γίνουν σαφώς ορατά στο ανθρώπινο μάτι. Οι περιοχές με προσβεβλημένες καλλιέργειες παρουσιάζουν σταθερά χαμηλότερες τιμές NDVI σε σύγκριση με τις υγιείς ζώνες αναφοράς, επιτρέποντας την έγκαιρη ανίχνευση και χωρική οριοθέτηση των εστιών μόλυνσης. Αυτό είναι ιδιαίτερα πολύτιμο για την προληπτική διαχείριση των καλλιεργειών, καθώς επιτρέπει στους αγρότες να παρεμβαίνουν πριν η ασθένεια εξαπλωθεί σε όλο το χωράφι.

Τα κύρια πλεονεκτήματα του NDVI είναι η απλότητα, η ευκολία ερμηνείας και η αξιοπιστία του, χαρακτηριστικά που το καθιστούν κατάλληλο για μεγάλης κλίμακας παρακολούθηση καλλιεργειών. Είναι υπολογιστικά ελαφρύς και εύκολα συγκρίσιμος στο χρόνο, γεγονός που υποστηρίζει την ανάλυσή της χρονικής εξέλιξης των ασθενειών. Ωστόσο, το NDVI έχει και περιορισμούς. Μπορεί να κορεστεί σε πυκνά φυλλώματα, μειώνοντας την ευαισθησία σε μεταγενέστερα στάδια ανάπτυξης, και μπορεί να ανταποκρίνεται με παρόμοιο τρόπο σε διαφορετικές πηγές καταπόνησης όπως έλλειψη θρεπτικών ουσιών, υδάτινη καταπόνηση, και ασθένειες. Για το λόγο αυτό, στη γεωργία ακριβείας τα σύγχρονα συστήματα συνδυάζουν όλο και περισσότερο τον NDVI με δείκτες κόκκινου άκρου (red-edge), χαρακτηριστικά υφής και ταξινομήσεις βασισμένες στην τεχνητή νοημοσύνη, προκειμένου να βελτιώσουν την αποτελεσματικότητα της διάγνωσης.

Κανονικοποιημένος δείκτης βλάστησης διαφοράς πράσινου (GNDVI): Ο κανονικοποιημένος δείκτης βλάστησης διαφοράς πράσινου (GNDVI) είναι ένας προηγμένος δείκτης βλάστησης που χρησιμοποιείται στη γεωργία ακριβείας για την αξιολόγησή της υγείας των καλλιεργειών με αυξημένη ευαισθησία στη συγκέντρωση χλωροφύλλης και στην πρόιμη φυσιολογική καταπόνηση. Παρόμοια με τον NDVI, ο GNDVI προέρχεται από δεδομένα πολυφασματικής ανάκλασης, αλλά αντικαθιστά την κόκκινη ζώνη με την πράσινη ζώνη, καθιστώντας τον ιδιαίτερα αποτελεσματικό για την ανίχνευση λεπτών αλλαγών στην κατάσταση των φυτών που προηγούνται των ορατών συμπτωμάτων.

Μαθηματικά, ο GNDVI εκφράζεται ως:

$$\text{GNDVI} = \frac{\text{NIR} - \text{Green}}{\text{NIR} + \text{Green}} \quad (2)$$

Η χρήση της πράσινης ζώνης βασίζεται στη φυτική φυσιολογία, η πράσινη ανακλαστικότητα επηρεάζεται σε μεγάλο βαθμό από την περιεκτικότητα σε χλωροφύλλη και την κατάσταση του αζώτου, οι οποίες συχνά επηρεάζονται στα αρχικά στάδια της ανάπτυξης της νόσου. Ως αποτέλεσμα, ο GNDVI τείνει να

ανταποκρίνεται νωρίτερα από τον NDVI όταν οι καλλιέργειες υφίστανται βιοτική καταπόνηση [13]. Οι ασθένειες των φυτών διαταράσσουν την αποτελεσματικότητα της φωτοσύνθεσης, καθώς αποικοδομούν τη χλωροφύλλη, αλλοιώνουν τη δομή των φύλλων και παρεμποδίζουν την απορρόφηση θρεπτικών ουσιών. Αυτές οι αλλαγές επηρεάζουν άμεσα την ανακλαστικότητα στην πράσινη περιοχή του φάσματος, ενώ ταυτόχρονα μειώνουν την ανακλαστικότητα στο εγγύς υπέρυθρο. Δίνοντας έμφαση στην αντίθεση εγγύς υπέρυθρου και πράσινου, ο δείκτης GNDVI παρέχει έναν δείκτη πιο ευαίσθητο στη χλωροφύλλη από τον δείκτη NDVI. Ο GNDVI συσχετίζεται στενά με τη συγκέντρωση αζώτου στα φύλλα, την πυκνότητα της χλωροφύλλης και τη φωτοσυνθετική δραστηριότητα, παράμετροι που συχνά μειώνονται πριν εμφανιστούν μακροσκοπικά συμπτώματα της νόσου. Οι χαμηλότερες τιμές GNDVI συνδέονται σταθερά με μειωμένη δραστηριότητα χλωροφύλλης που προκαλείται από παθογόνα, επιτρέποντας την ιεράρχηση των περιοχών που χρειάζονται θεραπεία. Όταν ενσωματώνονται σε αλγόριθμους παλινδρόμησης ή ταξινόμησης, τα χαρακτηριστικά που βασίζονται στο GNDVI έχουν αποδειχθεί ότι βελτιώνουν την προγνωστική απόδοση για τη χαρτογράφηση ασθενειών των καλλιεργειών, ειδικά όταν συνδυάζονται με άλλους φασματικούς δείκτες.

Το κύριο πλεονέκτημα του GNDVI έγκειται στην αυξημένη ευαισθησία του στην καταπόνηση που σχετίζεται με τη χλωροφύλλη, γεγονός που τον καθιστά ιδανικό για την έγκαιρη ανίχνευση ασθενειών και την προληπτική διαχείριση των καλλιεργειών. Είναι επίσης λιγότερο επιρρεπής σε φαινόμενα κορεσμού από τον NDVI σε μέτρια πυκνές επιφάνειες φυλλωμάτων. Ωστόσο, όπως όλοι οι δείκτες βλάστησης, ο GNDVI δεν είναι ειδικός για κάθε ασθένεια. Η μείωση του GNDVI μπορεί επίσης να οφείλεται σε έλλειψη αζώτου ή καταπόνηση από την έλλειψη νερού. Κατά συνέπεια, η βέλτιστη πρακτική στη γεωργία ακριβείας περιλαμβάνει τη χρήση του GNDVI ως μέρος ενός συστήματος πολλαπλών δεικτών και τεχνητής νοημοσύνης, και όχι ως αυτόνομο διαγνωστικό εργαλείο.

Κανονικοποιημένος δείκτης διαφοράς ερυθρού ορίου (NDRE): Ο κανονικοποιημένος δείκτης διαφοράς ερυθρού ορίου (NDRE) είναι ένας δείκτης βλάστησης που έχει σχεδιαστεί ειδικά για να καταγράφει τις λεπτές φυσιολογικές αλλαγές στις καλλιέργειες, ιδίως εκείνες που σχετίζονται με τη συγκέντρωση χλωροφύλλης σε πυκνά ή ώριμα φυλλώματα. Ο NDRE βασίζεται στη λογική του NDVI, αλλά αντικαθιστά την κόκκινη ζώνη με τη ζώνη κόκκινου άκρου, μια στενή φασματική περιοχή που βρίσκεται μεταξύ των κόκκινων και των εγγύς υπέρυθρων μηκών κύματος και είναι ιδιαίτερα ευαίσθητη στη δυναμική της χλωροφύλλης.

Μαθηματικά, ο NDRE εκφράζεται ως:

$$\text{NDRE} = \frac{\text{NIR} - \text{Red Edge}}{\text{NIR} + \text{Red Edge}} \quad (3)$$

Η ζώνη κόκκινου άκρου ανταποκρίνεται έντονα στις διακυμάνσεις της περιεκτικότητας σε χλωροφύλλη, ενώ επηρεάζεται λιγότερο από τα φαινόμενα κορεσμού που συνήθως περιορίζουν τον NDVI σε μεταγενέστερα στάδια ανάπτυξης. Αυτό καθιστά τον NDRE ιδιαίτερα πολύτιμο για την προηγμένη παρακολούθηση ασθενειών σε καλά αναπτυγμένες καλλιέργειες [11]. Κάποιες ασθένειες των φυτών παρεμποδίζουν τη φωτοσύνθεση, αποικοδομώντας τα χρωστικά της χλωροφύλλης και διαταράσσοντας την εσωτερική δομή των φύλλων. Αυτές οι φυσιολογικές αλλοιώσεις συχνά δεν καταγράφονται επαρκώς από τους δεί-

κτες που βασίζονται στη ζώνη του κόκκινου, όταν το φύλλωμα είναι πυκνό. Ωστόσο, η περιοχή του κόκκινου άκρου μεταβάλλεται αισθητά με τις αλλαγές στη συγκέντρωση χλωροφύλλης, επιτρέποντας στον NDRE να ανιχνεύει μέτριο και πρώιμο στάδιο καταπόνησης, ακόμη και όταν οι τιμές NDVI παραμένουν σχετικά σταθερές. Μελέτες αναφέρουν σταθερά ισχυρές συσχετίσεις μεταξύ του NDRE και της περιεκτικότητας των φύλλων σε χλωροφύλλη, της κατάστασης του αζώτου και της φωτοσυνθετικής απόδοσης. Ως αποτέλεσμα, ο NDRE παρέχει αυξημένη ευαισθησία την καταπόνηση που προκαλείται από ασθένειες σε σύγκριση με τους παραδοσιακούς δείκτες. Πέρα από την ανίχνευση, ο NDRE χρησιμοποιείται συχνά για την υποστήριξη της αξιολόγησης της σοβαρότητας της νόσου και της οριοθέτησης της ζώνης διαχείρισης. Η σταδιακή μείωση των τιμών NDRE σε ένα χωράφι υποδηλώνει μείωση της χλωροφύλλης λόγω της εξέλιξης της νόσου. Με την ομαδοποίηση των τιμών NDRE ή τη χρήση προσεγγίσεων βασισμένων στην παλινδρόμηση, οι ερευνητές μπορούν να εκτιμήσουν την ένταση της νόσου στο χώρο και να παρέμβουν στοχευμένα. Η ακρίβεια πρόβλεψης του NDRE βελτιώνεται σημαντικά όταν αυτός συνδυάζεται με δείκτες βλάστησης όπως ο NDVI και ο GNDVI.

Ο NDRE απαιτεί αισθητήρες με ειδική ζώνη κόκκινου άκρου, κάτι που μπορεί να αυξήσει το κόστος του συστήματος. Επιπλέον, όπως και άλλοι φασματικοί δείκτες, ο NDRE δεν είναι αποκλειστικά ειδικός για ασθένειες, καθώς παρόμοιες φασματικές αποκρίσεις μπορεί να προκύψουν από έλλειψη θρεπτικών ουσιών ή νερού. Κατά συνέπεια, ο NDRE είναι πιο αποτελεσματικός όταν συνδυάζεται με άλλους δείκτες ή διαγνωστικά πλαίσια με τη βοήθεια τεχνητής νοημοσύνης.

Δείκτης αναλογίας βλάστησης (RVI): Ο δείκτης αναλογίας βλάστησης (RVI) είναι ένας από τους πρώτους και πιο απλούς εννοιολογικά δείκτες βλάστησης που χρησιμοποιούνται στη γεωργία ακριβείας. Σε αντίθεση με τους κανονικοποιημένους δείκτες, ο RVI βασίζεται σε μια άμεση αναλογία μεταξύ της ανακλαστικότητας στο εγγύς υπέρυθρο και στο κόκκινο, εκμεταλλευόμενος την έντονη αντίθεση μεταξύ αυτών των δύο φασματικών περιοχών στην υγιή βλάστηση.


Μαθηματικά, ο RVI εκφράζεται ως:

$$RVI = \frac{NIR}{Red} \quad (4)$$

Τα υγιή φυτά αντανακλούν έντονα την ακτινοβολία στο εγγύς υπέρυθρο λόγω της εσωτερικής δομής των φύλλων, ενώ απορροφούν το κόκκινο φως λόγω της χλωροφύλλης. Ως αποτέλεσμα, οι υψηλότερες τιμές RVI υποδηλώνουν έντονη, υγιή βλάστηση, ενώ οι χαμηλές τιμές RVI σχετίζονται με έλλειψη νερού, ζημιές ή ασθένειες των φυτών. Παρά την απλότητά του, ο RVI εξακολουθεί να χρησιμοποιείται στη γεωργία ακριβείας, ιδίως για σχετικές συγκρίσεις και ανάλυση τάσεων [26]. Οι ασθένειες των καλλιεργειών επηρεάζουν τόσο τη συγκέντρωση χλωροφύλλης όσο και τη δομή του φυλλώματος, οδηγώντας σε μειωμένη απορρόφηση στην κόκκινη ζώνη και μειωμένη ανακλαστικότητα στη ζώνη του εγγύς υπέρυθρου. Αυτές οι συνδυασμένες επιδράσεις προκαλούν μείωση του λόγου NIR/Red, ο οποίος καταγράφεται άμεσα από τον RVI. Επειδή ο RVI δεν είναι κανονικοποιημένος, μπορεί να είναι ιδιαίτερα ευαίσθητος σε απόλυτες αλλαγές στην ανακλαστικότητα που προκαλούνται από φυσιολογική υποβάθμιση λόγω ασθενειών. Στα αρχικά στάδια της ασθένειας, η ελαφρά απώλεια χλωροφύλλης ήδη μεταβάλλει την ανακλαστικότητα του κόκκινου, ενώ οι προχωρημένες μολύνσεις διαταράσσουν περαιτέρω την κυτταρική δομή των φύλλων, μειώνοντας την ανακλαστικότητα του εγγύς υπέρυθρου. Κατά συνέπεια, η μείωση των τιμών του RVI μπορεί να ερμηνευθεί ως ένδειξη της επιδείνωσης της ασθένειας. Ο RVI χρησιμοποιείται για την

χαρτογράφηση της σοβαρότητας μιας ασθένειας, ιδιαίτερα σε συνθήκες χαμηλής έως μέτριας βιομάζας. Ωστόσο, λόγω της έλλειψης κανονικοποίησης, ο RVI είναι πιο ευαίσθητος στη μεταβλητότητα του φωτισμού, στον θόρυβο του αισθητήρα και στις επιδράσεις του εδάφους, οι οποίες μπορούν να συγχέουν τα σήματα της ασθένειας εάν δεν διορθωθούν σωστά. Για το λόγο αυτό συνδυάζεται συχνά με άλλους κανονικοποιημένους δείκτες σε προηγμένα αναλυτικά πλαίσια.

Τα κύρια πλεονεκτήματα του RVI είναι η υπολογιστική του απλότητα και η υψηλή ευαισθησία στις φασματικές αλλαγές που προκαλούνται από την καταπόνηση των φυτών, σχήμα 3.12. Είναι εύκολος στην εφαρμογή και την ερμηνεία, γεγονός που το καθιστά χρήσιμο για διερευνητική ανάλυση και γρήγορες εκτιμήσεις πεδίου. Επίσης, τείνει να κορεστεί σε πυκνά φυλλώματα. Ως αποτέλεσμα, τα σύγχρονα συστήματα γεωργίας ακριβείας σπάνια βασίζονται μόνο στον RVI, αλλά τον ενσωματώνουν σε άλλους δείκτες.



Σχήμα 3.12: Χάρτης δείκτη βλάστησης. [9]

Δείκτης πράσινης βλάστησης (GVI): Ο δείκτης πράσινης βλάστησης (GVI) είναι ένας δείκτης βλάστησης που έχει σχεδιαστεί για να τονίζει τη συνολική πρασινάδα και τη φωτοσυνθετικά ενεργή βιομάζα των καλλιεργειών. Σε αντίθεση με τους δείκτες που βασίζονται σε αναλογίες ή κανονικοποιημένους δείκτες, ο GVI συνήθως διατυπώνεται ως γραμμικός συνδυασμός φασματικών ζωνών, με ισχυρή συμβολή από την πράσινη ανακλαστικότητα, η οποία συνδέεται στενά με τη χλωροφύλλη και τη δύναμη του φυλλώματος.

Μαθηματικά, ο GVI εκφράζεται ως:

$$GVI = \frac{Green - Red}{Green + Red} \quad (5)$$

Ο βασικός του στόχος είναι η ποσοτικοποίηση του πρασίνου της βλάστησης ως δείκτη της φυσιολογικής κατάστασης των φυτών. Στη γεωργία ακριβείας και στην παρακολούθηση με βάση τα UAV, ο GVI χρησιμοποιείται κυρίως για την παρακολούθηση της ανάπτυξης της βιομάζας, της πυκνότητας του φυλλώματος και της υποβάθμισης που προκαλείται από την καταπόνηση, συμπεριλαμβανομένου του καταπόνησης που προκαλείται από φυτικές ασθένειες ή την έλλειψη νερού [27]. Ο GVI χρησιμοποιείται για την αξιολόγηση της σοβαρότητας των ασθενειών στις καλλιέργειες και την κατανομή τους σε ζώνες διαχείρισης. Η σταδιακή μείωση των τιμών GVI σε μια καλλιέργεια συχνά αντιστοιχεί σε αυξανόμενα επίπεδα πίεσης από ασθένειες και μειωμένη συσσώρευση βιομάζας. Όταν αναλύονται χρονικά, οι τάσεις του GVI μπορούν να αποκαλύψουν τη δυναμική της εξέλιξης των ασθενειών, καθιστώντας τον χρήσιμο για την παρακολούθηση της αποτελεσματικότητας των παρεμβάσεων.

Το κύριο πλεονέκτημα του GVI έγκειται στην άμεση ευαισθησία του στο πράσινο του φυλλώματος και στη βιομάζα, γεγονός που τον καθιστά εύκολο στην ερμηνεία. Είναι ιδιαίτερα χρήσιμος για την οπτικοποίηση της καλλιέργειας και την ανάλυση της κατάστασης της. Από την άλλη, ο GVI είναι λιγότερο συγκεκριμένος ως προς την καταπόνηση από ασθένειες, καθώς η μείωση του πρασίνου μπορεί επίσης να οφείλεται σε ανεπάρκεια θρεπτικών ουσιών, έλλειψη νερού ή γήρανση. Επιπλέον, ο GVI είναι πιο ευαίσθητος στις συνθήκες φωτισμού και στις επιδράσεις του εδάφους από τους κανονικοποιημένους δείκτες. Κατά συνέπεια, τα σύγχρονα συστήματα γεωργίας ακριβείας χρησιμοποιούν συνήθως τον GVI σε συνδυασμό με χαρακτηριστικά που βασίζονται σε NDVI, GNDVI ή NDRE και μεθόδους μηχανικής μάθησης. [21]

Δείκτης διαφοράς βλάστησης (DVI) Ο δείκτης διαφοράς βλάστησης (DVI) είναι ένας απλός φασματικός δείκτης που ποσοτικοποιεί την κατάσταση της βλάστησης χρησιμοποιώντας την απόλυτη διαφορά μεταξύ της ανακλαστικότητας στο εγγύς υπέρυθρο και στο κόκκινο. Σε αντίθεση με τους κανονικοποιημένους ή τους δείκτες που βασίζονται σε αναλογίες, ο DVI διατηρεί το μέγεθος της φασματικής αντίθεσης, καθιστώντας τον ευαίσθητο στις αλλαγές στη δύναμη του φυλλώματος και στη βιομάζα.

Μαθηματικά, ο DVI εκφράζεται ως:

$$DVI = NIR - Red \quad (6)$$

Η υγιής βλάστηση παρουσιάζει υψηλή ανακλαστικότητα στο εγγύς υπέρυθρο και χαμηλή ανακλαστικότητα στο κόκκινο λόγω της ισχυρής απορρόφησης της χλωροφύλλης, με αποτέλεσμα υψηλές τιμές DVI. Όταν οι καλλιέργειες προσβάλλονται από ασθένειες, τόσο η μειωμένη περιεκτικότητα σε χλωροφύλλη όσο και οι ζημιές στη δομή των καλλιεργειών μειώνουν την ανακλαστικότητα στο εγγύς υπέρυθρο και αυξάνουν την ανακλαστικότητα στο κόκκινο, οδηγώντας σε χαμηλότερες τιμές DVI [28]. Οι ασθένειες των φυτών επηρεάζουν αρνητικά τη φωτοσύνθεση, καθώς αποικοδομούν τις χρωστικές ουσίες της χλωροφύλλης και διαταράσσουν την εσωτερική δομή των φύλλων. Αυτές οι φυσιολογικές επιδράσεις μειώνουν άμεσα την αντίθεση εγγύς υπέρυθρου με το κόκκινο που καταγράφεται από τον DVI. Επειδή ο

DVI μετρά μια απόλυτη διαφορά και όχι μια κανονικοποιημένη αναλογία, αντιδρά έντονα στην απώλεια βιομάζας και στην αραίωση του φυλλώματος, που είναι συνήθεις συνέπειες της εξέλιξης της ασθένειας. Στα αρχικά στάδια, η μέτρια αποικοδόμηση της χλωροφύλλης μπορεί ήδη να μειώσει την απορρόφηση του κόκκινου, ενώ τα προχωρημένα στάδια της νόσου μειώνουν περαιτέρω την ανακλαστικότητα στο εγγύς υπέρυθρο λόγω της κυτταρικής κατάρρευσης. Κατά συνέπεια, η μείωση των τιμών DVI μπορεί να ερμηνευθεί ως δείκτης της αυξανόμενης σοβαρότητας της νόσου και της υποβάθμισης της βλάστησης. Ο δείκτης DVI έχει χρησιμοποιηθεί για την χαρτογράφηση της σοβαρότητας της νόσου, καθώς η προοδευτική μείωση της βιομάζας του φυλλώματος και της περιεκτικότητας σε χλωροφύλλη οδηγεί σε ανάλογη μείωση των τιμών του δείκτη DVI. Όταν αναλύεται χρονικά, η χρονοσειρά του δείκτη DVI μπορεί να αναδείξει τους ρυθμούς εξέλιξης της νόσου, βοηθώντας στην έγκαιρη. Ωστόσο, επειδή ο DVI δεν ομαλοποιείται στις επιδράσεις του φωτισμού ή του φόντου, οι τιμές του ερμηνεύονται καλύτερα σχετικά με υγιείς περιοχές αναφοράς ή προηγούμενες ημερομηνίες παρά με τη χρήση απόλυτων ορίων.

Το κύριο πλεονέκτημα του DVI είναι η απλότητα και η ευαισθησία του στις απόλυτες αλλαγές στην ανακλαστικότητα της βλάστησης, γεγονός που το καθιστά χρήσιμο για την ανίχνευση της απώλειας βιομάζας και της υποβάθμισης του φυλλώματος που προκαλείται από ασθένειες. Είναι υπολογιστικά αποδοτικός και εύκολος στην ερμηνεία σε ελεγχόμενες συνθήκες. Από την πλευρά των περιορισμών, ο DVI είναι ιδιαίτερα ευαίσθητος στη μεταβλητότητα του φωτισμού, στο υπόβαθρο του εδάφους και στη βαθμονόμηση του αισθητήρα, τα οποία μπορούν να συγχέουν τα σήματα των ασθενειών.

Δείκτης βλάστησης προσαρμοσμένος στο έδαφος (SAVI): Ο δείκτης βλάστησης προσαρμοσμένος στο έδαφος (SAVI) είναι ένας δείκτης βλάστησης που έχει αναπτυχθεί ειδικά για να ελαχιστοποιεί την επίδραση της ανακλαστικότητας του εδάφους, η οποία μπορεί να παραμορφώσει σημαντικά τα σήματα βλάστησης σε αγροτικές εκτάσεις με αραιή βλάστηση ή σε πρώιμο στάδιο ανάπτυξης. Ο SAVI επεκτείνει τον NDVI εισάγοντας έναν συντελεστή προσαρμογής στο έδαφος (L) που αντισταθμίζει τις επιδράσεις του εκτεθειμένου εδάφους.

Μαθηματικά, ο SAVI εκφράζεται ως:

$$SAVI = \frac{NIR - Red}{NIR + Red + L} \times (1 + L) \quad (7)$$

όπου L είναι ένας συντελεστής προσαρμογής του φόντου της επιφάνειας του φυλλώματος, που συνήθως ορίζεται σε 0,5 για τη μέση βλάστηση. Με τη μείωση του θορύβου που προκαλείται από το έδαφος, ο SAVI παρέχει μια πιο αξιόπιστη αναπαράσταση της κατάστασης των καλλιεργειών σε συνθήκες όπου ο NDVI τείνει να είναι ασταθές [13]. Οι ασθένειες των φυτών συχνά εκδηλώνονται σε διαφορετικά σημεία στις καλλιέργειες, ιδιαίτερα κατά τα πρώτα στάδια ανάπτυξης, όταν η κάλυψη του φυλλώματος είναι ατελής. Σε τέτοιες περιπτώσεις, η ανακλαστικότητα του εδάφους μπορεί να κυριαρχήσει στις τιμές των εικόνων, καλύπτοντας τα φασματικά σήματα που σχετίζονται με τις ασθένειες. Ο SAVI μετριάξει αυτό το πρόβλημα λαμβάνοντας ρητά υπόψη τη φωτεινότητα του εδάφους, επιτρέποντας την πιο σαφή ανίχνευση των αλλαγών που προκαλούνται από τις ασθένειες στην απορρόφηση της χλωροφύλλης και στη δομή του φυλλώματος. Από φυσιολογική άποψη, η καταπόνηση που προκαλεί η ασθένεια μειώνει τη συγκέντρωση χλωροφύλλης και διαταράσσει την κυτταρική δομή των φύλλων, οδηγώντας σε αυξημένη ανακλαστικότητα στο κόκκινο και μειωμένη ανακλαστικότητα στο εγγύς υπέρυθρο. Ο SAVI διατηρεί την

ευαισθησία σε αυτές τις αλλαγές, ενώ καταστέλλει τις επιδράσεις του εδάφους που μπορεί να αλλοιώσουν το αποτέλεσμα, καθιστώντας τον πιο ανθεκτικό από το NDVI.

Ο SAVI έχει εφαρμοστεί αποτελεσματικά για την αξιολόγηση της σοβαρότητας των ασθενειών, καταγράφοντας τα σημεία με υποβαθμισμένη βλάστηση και ελαχιστοποιώντας ταυτόχρονα την επίδραση του εδάφους. Η σταδιακή μείωση των τιμών SAVI σε ένα χωράφι συχνά αντιστοιχεί σε αύξηση της πίεσης των ασθενειών, ειδικά σε καλλιέργειες σε σειρές ή σε πρώιμα φαινολογικά στάδια. Όταν χρησιμοποιείται σε συνδυασμό με χρονική ανάλυση, ο SAVI μπορεί να αποκαλύψει τις τάσεις εξέλιξης των ασθενειών, επιτρέποντας στοχευμένη ανίχνευση και παρέμβαση σε συγκεκριμένες περιοχές. Η ανθεκτικότητά του στο υπόβαθρο του εδάφους το καθιστά ιδιαίτερα χρήσιμο για τον καθορισμό ζωνών διαχείρισης σε συστήματα γεωργίας ακριβείας.

Δείκτης υπερβάλλοντος πρασίνου (ExG): Ο δείκτης υπερβάλλοντος πρασίνου (ExG) είναι ένας χρωματικός δείκτης βλάστησης που προέρχεται από εικόνες RGB και έχει σχεδιαστεί για να τονίζει το πράσινο συστατικό της βλάστησης σε σχέση με τα κόκκινα και μπλε κανάλια. Σε αντίθεση με τους πολυφασματικούς δείκτες (π.χ. NDVI, SAVI), ο ExG δεν απαιτεί δεδομένα που ανήκουν στο εγγύς υπέρυθρο, γεγονός που τον καθιστά ιδιαίτερα χρήσιμο για πλατφόρμες UAV χαμηλού κόστους που είναι εξοπλισμένες με τυπικές κάμερες RGB.

Μαθηματικά, ο ExG εκφράζεται ως:

$$\text{ExG} = 2G - R - B \quad (8)$$

όπου R, G και B υποδηλώνουν τις τιμές ανάκλασης του κόκκινου, του πράσινου και του μπλε χρώματος, αντίστοιχα. Ενισχύοντας το πράσινο σήμα, ο ExG αναδεικνύει τα εικονοστοιχεία της βλάστησης και καταστέλλει τα χαρακτηριστικά του εδάφους και του φόντου, επιτρέποντας την αποτελεσματική τμηματοποίηση της βλάστησης και την ανάλυση της καταπόνησης χρησιμοποιώντας μόνο εικόνες RGB [29]. Οι ασθένειες των φυτών επηρεάζουν τη χρωστική ουσία των φύλλων, τη συγκέντρωση χλωροφύλλης και την ακεραιότητα της επιφάνειας, οδηγώντας συχνά σε χλώρωση, νέκρωση ή αποχρωματισμό. Αυτά τα συμπτώματα μειώνουν άμεσα τη συνιστώσα της πράσινης ανάκλασης που καταγράφεται από τους αισθητήρες RGB. Ως αποτέλεσμα, η άρρωστη βλάστηση εμφανίζει συνήθως χαμηλότερες τιμές ExG σε σύγκριση με τα υγιή φυτά.

Από φυσιολογική άποψη, οι μειώσεις στον ExG αντιστοιχούν σε αποικοδόμηση της χλωροφύλλης, απώλεια του πράσινου χρώματος των φύλλων και δομικές ζημιές που επηρεάζουν την ορατή ανακλαστικότητα. Επειδή ο ExG ανταποκρίνεται στις αλλαγές του ορατού φάσματος, είναι ιδιαίτερα ευαίσθητος στα ορατά συμπτώματα της νόσου, καθιστώντας τον συμπληρωματικό στους φασματικούς δείκτες που καταγράφουν την καταπόνηση η οποία δεν φαίνεται οπτικά. Ο ExG έχει εφαρμοστεί στην εκτίμηση της σοβαρότητας των ασθενειών, ιδιαίτερα για ασθένειες που προκαλούν ορατές αλλαγές χρώματος, όπως κιτρίνισμα ή κηλίδες στα φύλλα. Αναλύοντας την χωρική κατανομή και το μέγεθος των μειώσεων του ExG, μπορούν να εκτιμηθούν τα ποσοστά των πληγείσων περιοχών και να προσδιοριστούν οι ζώνες προχωρημένης μόλυνσης.

Το κύριο πλεονέκτημα του ExG είναι η χαμηλή απαίτηση σε αισθητήρες, επιτρέποντας έτσι την ανίχνευση


ση ασθενειών ακόμα και με φθηνά συστήματα RGB. Είναι υπολογιστικά απλός και αποτελεσματικός για τον καταμερισμό της βλάστησης και την οπτική ανίχνευση καταπόνησης. Ωστόσο, ο ExG είναι ιδιαίτερα ευαίσθητος στις συνθήκες φωτισμού, τις σκιές και το χρώμα του εδάφους και δεν μπορεί να ανιχνεύσει τη μη ορατή καταπόνηση που προηγείται των ορατών συμπτωμάτων.

3.3.3 Τεχνικές μηχανικής μάθησης

Τα τελευταία χρόνια, η μηχανική μάθηση (Machine Learning - ML) αποτελεί μια από τις σημαντικότερες τεχνικές λήψης αποφάσεων βάσει δεδομένων στη γεωργία ακριβείας, κυρίως λόγω της ικανότητάς της να επεξεργάζεται μεγάλα σύνολα δεδομένων και να αποκαλύπτει πολύπλοκα μοτίβα που δεν είναι εύκολο να καταγραφούν από τα παραδοσιακά μοντέλα ανάλυσης δεδομένων. Η αυξανόμενη χρήση UAVs, αισθητήρων και υποδομών του Διαδικτύου των Πραγμάτων σε γεωργικά περιβάλλοντα έχει οδηγήσει σε σημαντική αύξηση των χωρικών, φασματικών και χρονικών δεδομένων υψηλής ανάλυσης, δημιουργώντας έτσι μια ισχυρή ζήτηση για έξυπνες υπολογιστικές τεχνικές ικανές να μετατρέπουν τις ακατέργαστες μετρήσεις σε αξιοποιήσιμες γνώσεις σχετικά με τις καλλιέργειες. Η μηχανική μάθηση προσφέρει ένα ευέλικτο και επεκτάσιμο πλαίσιο για την αντιμετώπιση αυτής της πρόκλησης, επιτρέποντας την αυτοματοποιημένη ανάλυση σε διάφορες γεωργικές συνθήκες.

Η επιτυχία της μηχανικής μάθησης στη γεωργία ακριβείας μπορεί να αποδοθεί στην ικανότητά της να μοντελοποιεί μη γραμμικές σχέσεις μεταξύ περιβαλλοντικών μεταβλητών, χαρακτηριστικών των καλλιεργειών και πρακτικών διαχείρισης. Σε αντίθεση με τις συμβατικές στατιστικές προσεγγίσεις που συχνά βασίζονται σε προκαθορισμένες υποθέσεις και απλοποιημένα μοντέλα, οι αλγόριθμοι μηχανικής μάθησης, μαθαίνουν απευθείας από τα δεδομένα και προσαρμόζονται στις διακυμάνσεις που προκαλούνται από την μορφολογία του εδάφους, τα στάδια ανάπτυξης των καλλιεργειών, τον καιρό και τον θόρυβο των αισθητήρων. Ως αποτέλεσμα, οι προσεγγίσεις που βασίζονται στη μηχανική μάθηση εφαρμόζονται ευρέως σε βασικές γεωργικές εργασίες, όπως η αξιολόγηση της κατάστασης των καλλιεργειών, η παρακολούθηση της καταπόνησης, η αναγνώριση ασθενειών, η διαχείριση της άρδευσης και η πρόβλεψη της απόδοσης χρησιμοποιώντας δεδομένα εικόνων που προέρχονται από τα UAV.

Τα συστήματα μηχανικής μάθησης ακολουθούν συνήθως μια ροή εργασίας η οποία περιέχει τη συλλογή των δεδομένων δηλαδή εικόνες μέσω καμερών από UAV, την επεξεργασία αυτών των δεδομένων με διόρθωση και συρραφή των εικόνων, σχήμα 3.13. Στη συνέχεια αφού έχουν παραχθεί τα τελικά δεδομένα γίνεται η εξαγωγή εργαλείων όπως οι δείκτες βλάστησης και ξεκινά η διαδικασία κατασκευής του μοντέλου ακολουθώντας δύο φάσεις: τη φάση της εκπαίδευσης, κατά την οποία τα μοντέλα συνάγουν μοτίβα ή κανόνες λήψης αποφάσεων από τα σύνολα δεδομένων που έχουν λάβει, και τη φάση της αξιολόγησης, όπου τα εκπαιδευμένα μοντέλα εφαρμόζονται σε νέα δεδομένα και εξάγουν τα ανάλογα αποτελέσματα [30].



Σχήμα 3.13: Σάρωση καλλιέργειας. [10]

Οι μέθοδοι εποπτευόμενης μηχανικής μάθησης αντιπροσωπεύουν την πιο ευρέως υιοθετημένη κατηγορία στις γεωργικές εφαρμογές UAV. Αυτές οι μέθοδοι βασίζονται σε επισημασμένα σύνολα δεδομένων, όπου κάθε δείγμα δεδομένων αντιπροσωπεύει με μια γνωστή κατηγορία ή στόχο, όπως υγιής έναντι καταπονημένης βλάστησης. Αλγόριθμοι όπως οι μηχανές υποστήριξης διανυσμάτων (SVM) [31], τα δέντρα αποφάσεων (DT) [32], τα τυχαία δάση (RF) [33], οι k -πλησιέστεροι γείτονες (k -NN) [34], οι ταξινομητές Naïve Bayes και τα ρηγά τεχνητά νευρωνικά δίκτυα έχουν δείξει ισχυρή απόδοση σε μια ποικιλία εργασιών παρακολούθησης και ταξινόμησης καλλιεργειών, όπως αναφέρεται σε πρόσφατες μελέτες του MDPI [35] - [36]]. Η δημοτικότητά τους οφείλεται σε ένα συνδυασμό υψηλής ακρίβειας ταξινόμησης, σχετικά μέτρων υπολογιστικών απαιτήσεων και συμβατότητας με περιορισμένα δεδομένα εκπαίδευσης σε σύγκριση με πιο σύνθετα μοντέλα.

Ωστόσο, ένας θεμελιώδης περιορισμός της εποπτευόμενης μάθησης στη γεωργία ακριβείας έγκειται στην απαίτηση για μεγάλο όγκο επισημασμένων δεδομένων. Ο ακριβής σχολιασμός των εικόνων από UAV περιλαμβάνει την χειροκίνητη οριοθέτηση των καταπονημένων περιοχών από γεωπόνους, μια διαδικασία που είναι χρονοβόρα, δαπανηρή και ευαίσθητη σε διακυμάνσεις μεταξύ των παρατηρητών. Ως αποτέλεσμα, η επεκτασιμότητα των καθαρά εποπτευόμενων διαδικασιών είναι περιορισμένη, ιδιαίτερα σε πραγματικές γεωργικές συνθήκες όπου απαιτείται ταχεία ανάπτυξη και προσαρμογή.

Για να μετριαστούν αυτές οι προκλήσεις, οι μέθοδοι μη εποπτευόμενης μηχανικής μάθησης έχουν αρχίσει να χρησιμοποιούνται ως συμπληρωματικές ή εναλλακτικές λύσεις. Οι μη εποπτευόμενοι αλγόριθμοι λειτουργούν σε μη επισημασμένα δεδομένα και στοχεύουν στην αποκάλυψη δομών ή συστάδων αποκλειστικά με βάση την ομοιότητα των δεδομένων [37]. Στη γεωργία ακριβείας, τεχνικές ομαδοποίησης όπως το k -means [38] έχουν χρησιμοποιηθεί για να χωρίσουν τα εικονοστοιχεία των εικόνων UAV σε ομάδες που αντιστοιχούν σε υγιή και καταπονημένη βλάστηση, επιτρέποντας την ανίχνευση ασθενειών

ή ανωμαλιών χωρίς ρητές ετικέτες πραγματικών δεδομένων [39]. Τέτοιες προσεγγίσεις είναι ιδιαίτερα πολύτιμες στην ανάλυση και την παρακολούθηση σε πρώιμο στάδιο, όπου ενδέχεται να μην είναι ακόμη διαθέσιμα επισημασμένα σύνολα δεδομένων.

3.3.4 Τεχνικές βαθιάς μάθησης

Η βαθιά μάθηση (Deep Learning - DL) έχει αναδειχθεί σε μια από τις πιο χαρακτηριστικές τεχνικές ανάλυσης δεδομένων. Η υιοθέτησή της στη γεωργία ακριβείας επιταχύνθηκε ιδιαίτερα με την εξάπλωση των UAVs, τα οποία παράγουν εικόνες υψηλής ανάλυσης με μεγάλη συχνότητα λήψεων, καθιστώντας εφικτή τη συνεχή παρακολούθηση της καλλιέργειας σε μεγάλη κλίμακα. Σε αντίθεση με την παραδοσιακή μηχανική μάθηση που συχνά στηρίζεται σε ήδη κατασκευασμένα χαρακτηριστικά από τον άνθρωπο, η βαθιά μάθηση μαθαίνει ιεραρχικές αναπαραστάσεις απευθείας από τα δεδομένα, μέσω στοίβαξης πολλών επιπέδων που μετασχηματίζουν σταδιακά χαμηλού επιπέδου οπτικά μοτίβα όπως ακμές ή σημάρδια σε υψηλότερου επιπέδου σημασιολογικές έννοιες όπως συμπτώματα στο φύλλωμα και χωρικά μοτίβα καταπόνησης.

Οι σύγχρονες προσεγγίσεις βαθιάς μάθησης για εκτίμηση και ανίχνευση ασθενειών καλλιεργειών από εικόνες UAV στηρίζονται στην επιτυχία των συνελκτικών νευρωνικών δικτύων (Convolutional Neural Networks - CNN), τα οποία λειτουργούν ως βασικά δομικά στοιχεία για την εξαγωγή ιεραρχικών χαρακτηριστικών από πολυφασματικές ή RGB κάμερες. Στο πλαίσιο αυτό, μια τυπική ροή βαθιάς μάθησης, για την εκτίμηση ασθενειών ακολουθεί μια αλληλουχία σταδίων που ξεκινάει με τη συλλογή δεδομένων και την προεπεξεργασία τους, την ανάπτυξη του μοντέλου και την αξιολόγησή του, ωστόσο εμφανίζει ιδιαίτερες απαιτήσεις λόγω της φύσης των εναέριων λήψεων. Ειδικότερα, στη φάση προετοιμασίας δεδομένων είναι συχνά απαραίτητες εργασίες όπως η συρραφή ή διόρθωση των εικόνων. Τα μοντέλα βαθιάς μάθησης διακρίνονται συνήθως σε μοντέλα ταξινόμησης, τμηματοποίησης και ανίχνευσης.

Η ακρίβεια (accuracy) αποτελεί βασικό δείκτη αξιολόγησης της απόδοσης ενός αλγορίθμου ταξινόμησης και εκφράζει την ικανότητά του να πραγματοποιεί σωστές προβλέψεις. Ορίζεται ως ο λόγος του αθροίσματος των αληθώς θετικών (True Positives - TP) και αληθώς αρνητικών (True Negatives - TN) αποτελεσμάτων προς το συνολικό πλήθος των προβλέψεων του μοντέλου, το οποίο περιλαμβάνει τόσο τις σωστές όσο και τις λανθασμένες προβλέψεις, δηλαδή τα ψευδώς θετικά (False Positives - FP) και τα ψευδώς αρνητικά (False Negatives - FN). Η μετρική αυτή παρέχει μια συνολική εκτίμηση της επίδοσης του μοντέλου, εκφράζοντας το ποσοστό των περιπτώσεων στις οποίες η ταξινόμηση πραγματοποιήθηκε ορθά και υπολογίζεται σύμφωνα με την ακόλουθη σχέση [40]:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

Στα μοντέλα ταξινόμησης, ο στόχος είναι να αντιστοιχιστεί κάθε εικόνα σε προκαθορισμένες κλάσεις (π.χ. υγιές /μη υγιές). Η πρακτική αυτή ευνοεί την αξιοποίηση μεταφοράς μάθησης (transfer learning), όπου προεκπαιδευμένα CNNs χρησιμοποιούνται ως εξαγωγείς χαρακτηριστικών ή λεπτορυθμισμένοι (fine-tuned) ταξινομητές, επιτρέποντας την αποτελεσματική μάθηση ακόμη και όταν το πλήθος των δειγμάτων είναι περιορισμένο. Στη βιβλιογραφία εμφανίζονται συχνά αρχιτεκτονικές όπως VGG [41], ResNet, Inception [42], DenseNet [43], Xception και GoogLeNet, οι οποίες εφαρμόζονται σε δεδομένα

RGB ή υπερφασματικά, με αξιολόγηση σε επίπεδο συνολικής ακρίβειας ταξινόμησης.

Στα μοντέλα τμηματοποίησης, η επικρατούσα είναι η δομή κωδικοποιητή–αποκωδικοποιητή (encoder–decoder). Ο κωδικοποιητής λαμβάνει ως είσοδο την εικόνα και εφαρμόζει διαδοχικά συνελκτικά φίλτρα (convolutions) και λειτουργίες υποδειγματοληψίας, ενώ ο αποκωδικοποιητής χρησιμοποιεί λειτουργίες υπερδειγματοληψίας για να επαναφέρει τη χωρική ανάλυση και να ανακατασκευάσει τον χάρτη τμηματοποίησης. Οι πιο δημοφιλείς αρχιτεκτονικές που χρησιμοποιούνται για ασθένειες καλλιεργειών είναι οι U-Net [44], SegNet [45] και PSPNet [46].

Τέλος, τα μοντέλα ανίχνευσης είναι σχεδιασμένα ώστε να αποδίδουν ταυτόχρονα την ταυτότητα και την τοποθεσία του αντικειμένου ενδιαφέροντος. Το μοντέλο πρέπει όχι μόνο να αναγνωρίσει την κατηγορία του αντικειμένου, αλλά και να προσδιορίσει τη θέση του μέσα στην εικόνα, σχεδιάζοντας ένα ορθογώνιο πλαίσιο γύρω από το αντικείμενο ενδιαφέροντος. Αυτός ο συνδυασμός καθιστά την ανίχνευση αντικειμένων πιο σύνθετη από την απλή ταξινόμηση εικόνων. Οι μέθοδοι ανίχνευσης ομαδοποιούνται συνήθως σε ανιχνευτές δύο σταδίων (two-stage detector) όπως R-CNN [47], όπου πρώτα παράγονται οι περιοχές που μπορεί να περιέχουν αντικείμενα και κατόπιν γίνεται η ταξινόμηση ορίων, και σε ανιχνευτές ενός σταδίου (single-stage detectors), όπου η εικόνα διέρχεται από το μοντέλο μόνο μία φορά. Σε αυτή την περίπτωση, το δίκτυο προβλέπει απευθείας τόσο τις κατηγορίες των αντικειμένων όσο και τις αντίστοιχες τους θέσεις. Στις UAV εφαρμογές ανίχνευσης ασθενειών, παρατηρείται έντονη προτίμηση προς single-stage μοντέλα, όπως YOLO [48], RetinaNet και CenterNet, ενώ τα two-stage όπως Faster R-CNN εμφανίζονται λιγότερο συχνά.

Κεφάλαιο 4ο: Ταξινόμηση των τεχνικών ανίχνευσης ασθενειών μέσω UAV

4.1 Ταξινόμηση μεθόδων

Το παρόν κεφάλαιο εστιάζει στην κατηγοριοποίηση και ανάλυση των κυριότερων τεχνικών σχετικά με την έγκαιρη ανίχνευση ασθενειών και καταπόνησης που χρησιμοποιούνται στη γεωργία ακριβείας. Συγκεκριμένα, οι μέθοδοι οργανώνονται σε τρεις βασικές κατηγορίες, οι οποίες αντικατοπτρίζουν και τη σταδιακή εξέλιξη του πεδίου από απλές φασματικές προσεγγίσεις σε πιο σύνθετα μοντέλα.

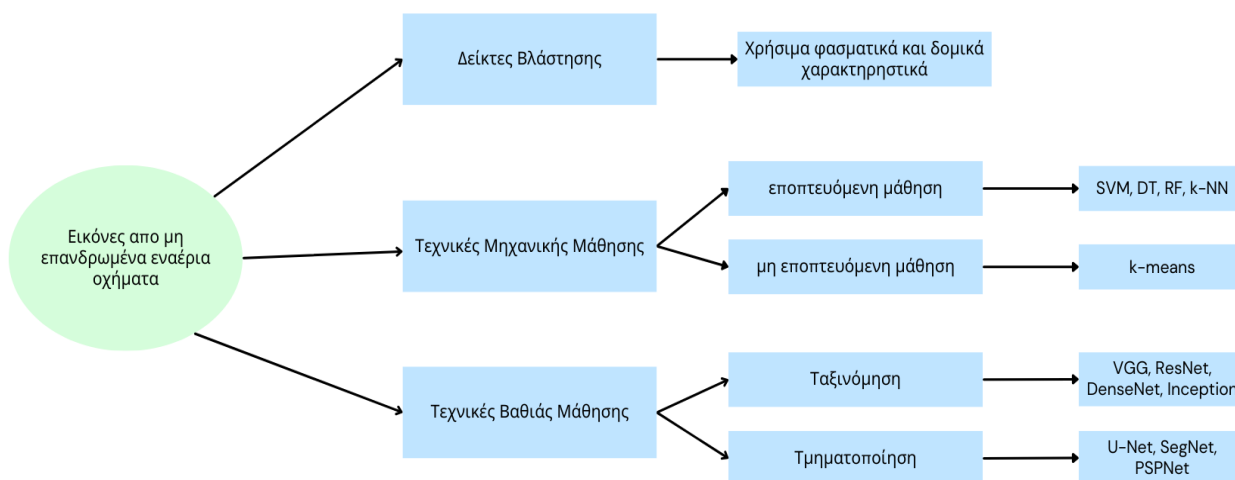
Η πρώτη κατηγορία περιλαμβάνει τις τεχνικές που βασίζονται σε δείκτες βλάστησης, οι οποίοι προκύπτουν από μαθηματικούς συνδυασμούς φασματικών ζωνών και χρησιμοποιούνται εκτενώς για την ποσοτικοποίηση της φυτικής ζωτικότητας και της καταπόνησης. Οι προσεγγίσεις αυτές αποτελούν το αρχικό και πιο ερμηνεύσιμο στάδιο της ανίχνευσης ασθενειών, προσφέροντας χαμηλό υπολογιστικό κόστος και άμεση συσχέτιση με φυσιολογικές διεργασίες των φυτών.

Η δεύτερη κατηγορία αφορά τις τεχνικές μηχανικής μάθησης, οι οποίες αξιοποιούν φασματικά χαρακτηριστικά και δείκτες βλάστησης για την εκμάθηση μοτίβων που σχετίζονται με την παρουσία και τη σοβαρότητα ασθενειών. Αυτές οι μέθοδοι επιτρέπουν τη μοντελοποίηση μη γραμμικών σχέσεων και προσφέρουν αυξημένη ακρίβεια σε σχέση με τις κλασικές φασματικές προσεγγίσεις.

Τέλος, η τρίτη κατηγορία περιλαμβάνει τις τεχνικές βαθιάς μάθησης, οι οποίες βασίζονται κυρίως σε νευρωνικά δίκτυα και επιτρέπουν την αυτόματη εξαγωγή χαρακτηριστικών απευθείας από τα δεδομένα

εικόνας από UAV. Οι προσεγγίσεις αυτές αντιπροσωπεύουν τη σύγχρονη τάση στο πεδίο, προσφέροντας υψηλή ακρίβεια σε πολύπλοκα αγροτικά περιβάλλοντα.

Μέσα από αυτή τη δομημένη ταξινόμηση, το κεφάλαιο επιδιώκει να προσφέρει μια σαφή και συγκριτική εικόνα των διαθέσιμων τεχνικών ανίχνευσης ασθενειών, αναδεικνύοντας τα πλεονεκτήματα, τους περιορισμούς και τον ρόλο κάθε κατηγορίας στο ευρύτερο πλαίσιο των συστημάτων γεωργίας ακριβείας με βάση τα UAVs.



Σχήμα 4.1: Ταξινόμηση των μεθόδων.

4.2 Δείκτες βλάστησης

Οι δείκτες βλάστησης αποτελούν μία από τις παλαιότερες και πιο διαδεδομένες προσεγγίσεις για την ανίχνευση και εκτίμηση ασθενειών στη γεωργία ακριβείας με τη χρήση UAV. Βασίζονται σε μαθηματικούς συνδυασμούς φασματικών ζωνών του ηλεκτρομαγνητικού φάσματος (ορατό, εγγύς υπέρυθρο), με στόχο την ποσοτικοποίηση φυσιολογικών και δομικών χαρακτηριστικών του φυλώματος, όπως η χλωροφύλλη, η φυτική ζωτικότητα, η γήρανση και η καταπόνηση. Οι μεταβολές αυτών των χαρακτηριστικών αποτελούν έμμεσους αλλά ισχυρούς δείκτες παρουσίας και εξέλιξης φυτικών ασθενειών.

Οι δείκτες βλάστησης χρησιμοποιούνται ευρέως σε μελέτες με βάση τα UAV για την εκτίμηση σοβαρότητας ασθενειών, είτε μέσω απλής στατιστικής παλινδρόμησης είτε ως βασικά χαρακτηριστικά εισόδου

σε πιο σύνθετα μοντέλα. Σε καλλιέργειες εσπεριδοειδών που πλήττονται από μια ασθένεια που προκαλεί το πρασίνισμα των εσπεριδοειδών, πολυφασματικά δεδομένα UAV αξιοποιήθηκαν για τον υπολογισμό δεικτών όπως NDVI, NDRE, MSAVI και CI. Τα αποτελέσματα έδειξαν ότι τα υγιή δέντρα εμφανίζουν συστηματικά υψηλότερες τιμές στους δείκτες αυτούς σε σύγκριση με τα μολυσμένα, με τους δείκτες κόκκινου άκρου να παρουσιάζουν αυξημένη διακριτική ικανότητα. Επιπλέον, η συσχέτιση φασματικών δεικτών με δομικά χαρακτηριστικά του φυλλώματος όπως ο όγκος οδήγησε σε πολύ υψηλές συσχετίσεις με επιτόπιες μετρήσεις $R^2=0.90$, όπου το R^2 αποτυπώνει το βαθμό στον οποίο οι δείκτες βλάστησης εξηγούν τη μεταβολή της σοβαρότητας της ασθένειας ενισχύοντας τη δυνατότητα πρόωμης ανίχνευσης της ασθένειας.

Μαθηματικά, το R^2 ορίζεται ως:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (10)$$

όπου y_i είναι οι πραγματικές τιμές της μεταβλητής ενδιαφέροντος, \hat{y}_i είναι οι αντίστοιχες προβλεπόμενες τιμές από το μοντέλο και \bar{y} ο μέσος όρος των πραγματικών τιμών. Η τιμή του R^2 κυμαίνεται θεωρητικά μεταξύ 0 και 1, όπου τιμές κοντά στο 0 υποδηλώνουν χαμηλή επεξηγηματική ικανότητα του μοντέλου, ενώ τιμές κοντά στο 1 θεωρούνται δείκτες ισχυρής συσχέτισης μεταξύ των φασματικών δεικτών βλάστησης και της πραγματικής σοβαρότητας της ασθένειας [49].

Αντίστοιχα, στο σιτάρι οι δείκτες βλάστησης χρησιμοποιήθηκαν εκτενώς για την εκτίμηση μυκητολογικών ασθeneιών όπως της καφέ και κίτρινης σκωρίασης. Σε μελέτες που βασίστηκαν αποκλειστικά σε RGB αισθητήρες UAV, απλοί χρωματικοί δείκτες προερχόμενοι από τις ορατές ζώνες όπως Stress Residue Index και Leaf Rust Index εμφάνισαν ισχυρές γραμμικές συσχετίσεις με επιτόπιες βαθμολογήσεις σοβαρότητας ασθένειας. Ενδεικτικά, επιτεύχθηκαν συντελεστές συσχέτισης $R^2=0.81$ [50], αποδεικνύοντας ότι ακόμη και χαμηλές σε κόστος RGB κάμερες μπορούν να υποστηρίξουν ποσοτική εκτίμηση ασθeneιών μέσω κατάλληλων δεικτών.

Πιο προηγμένες προσεγγίσεις αξιοποίησαν υπερφασματικά δεδομένα από UAV, επιτρέποντας τον υπολογισμό ευρύτερου φάσματος δεικτών όπως NDVI, SIPI, PRI και PSRI. Στην περίπτωση πάλι της σκωρίασης στο σιτάρι, οι δείκτες αυτοί, σε συνδυασμό με άλλα δομικά χαρακτηριστικά, χρησιμοποιήθηκαν σε μοντέλα παλινδρόμησης τύπου PLSR. Τα μοντέλα αυτά είχαν αποτέλεσμα έως και $R^2=0.88$ [51] της διακύμανσης του δείκτη ασθένειας σε προχωρημένα στάδια μόλυνσης, ενώ αποδείχθηκε ότι ο συνδυασμός δεικτών βλάστησης και υψής υπερέρχει σημαντικά της χρήσης δεικτών βλάστησης μόνο.

Σε ασθeneίες όπου τα συμπτώματα είναι χωρικά ανομοιογενή και η ανακλαστικότητα του φυλλώματος επηρεάζεται από πολλούς παράγοντες, οι μελέτες συχνά ξεκινούν διατηρώντας τους δείκτες βλάστησης που εμφανίζουν την υψηλότερη συσχέτιση σε έναν τύπο ασθένειας και στη συνέχεια προχωρούν σε προσαρμογή με μοντέλα παλινδρόμησης. Στην παρακολούθηση μιας μυκητολογικής ασθένειας που προκαλείται στο σιτάρι, οι συγγραφείς μέσω πολυφασματικών κάμερών εξάγουν δείκτες βλάστησης και τους χρησιμοποιούν ως μεταβλητές στον αλγόριθμο παλινδρόμησης PLSR, δίνοντας $R^2=0.72$ [52]. Στη συγκεκριμένη έρευνα χρησιμοποιήθηκαν οι δείκτες NDVI, GDVI, GVI.

Αντίστοιχη φιλοσοφία εμφανίζεται και στην εκτίμηση σοβαρότητας μιας ασθένειας για μύκητες στο βαμβάκι, όπου πολυφασματικοί δείκτες (π.χ. EVI, RENDVI, SAVI, MSAVI, RDVI) χρησιμοποιούνται ως

μεταβλητές σε μοντέλο PLSR, με αναφερόμενη απόδοση $R^2=0.78$ [53]. Ακόμη και σε σύνθετες ασθένειες όπως ο μαρασμός, όπου επηρεάζεται τόσο το εσωτερικό του φυτού όσο και το φύλλωμα, η χρήση δεικτών βλάστησης μπορεί να βοηθήσει στην εκτίμηση της έντασης της ασθένειας και στη δημιουργία χαρτών για στοχευμένες παρεμβάσεις.

Για την ποσοτικοποίηση της ιογενούς ασθένειας TSW σε φιστικιά με χρήση UAV πολυφασματικής απεικόνισης, υπολογίστηκαν πολλοί δείκτες βλάστησης και, αντί να βασιστούν απλώς στη μέση τιμή ενός δείκτη βλάστησης, οι ερευνητές αναλύουν την κατανομή των τιμών και εξάγουν χαρακτηριστικά όπως πλήθος των εικονοστοιχείων πάνω ή κάτω από δυναμικά όρια. Με γραμμική παλινδρόμηση συνδέουν αυτά τα VI χαρακτηριστικά με τις χειροκίνητες εκτιμήσεις, καταγράφοντας το όριο και την εξίσωση που μεγιστοποιεί το R^2 . Το αποτέλεσμα είναι ότι ο δείκτης NDRE ήταν ο καταλληλότερος, επιτυγχάνοντας $R^2=0.82$ [54].

Σε μια μελέτη παρουσιάζεται μια προσέγγιση για την αναγνώριση της μυκητολογικής ασθένειας που προκαλεί μαρασμό του φυλλώματος στη μπανάνα, με τη χρήση πολυφασματικών απεικονίσεων και δυαδική λογιστική παλινδρόμηση (Binary Logistic Regression, BLR). Για την περιγραφή της προσβολής χρησιμοποίησαν δείκτες βλάστησης που σχετίζονται με τη χλωροφύλλη και την ανάπτυξη (π.χ. NDVI, NDRE, CIRE). Η απόδοση αξιολογήθηκε με Overall Accuracy (OA), με τον δείκτη CIRE να επιτυγχάνει την καλύτερη επίδοση $OA=91.7\%$ [55].

Πίνακας 4.1: Σύνοψη μελετών για την ανίχνευση ασθενειών μέσω δεικτών βλάστησης. Οι συντομογραφίες που χρησιμοποιούνται είναι οι εξής: MS (Πολυφασματικός).

Βιβλ.	Φυτό	Τύπος Ασθένειας	Αισθητήρας	Δείκτης Βλάστησης	Μετρικές
[49]	Εσπεριδοειδή	Βακτηριακή	MS	NDVI, MSAVI, NDRE, CI	$R^2 = 0.90$
[50]	Σιτάρι	Μυκητολογική	RGB	SRI, LRI	$R^2 = 0.81$
[51]	Σιτάρι	Μυκητολογική	HS	SIPI, PRI, TCARI, PSRI, YRI, GI	$R^2 = 0.88$
[54]	Φιστικιά	Ιογενής	MS	NDRE, NRRE, GDVI, GNDVI	$R^2 = 0.82$
[55]	Μπανάνα	Μυκητολογική	MS	CI, NDVI, NDRE	$OA = 0.91$
[52]	Σιτάρι	Μυκητολογική	MS	NDVI, GDVI, GVI	$R^2 = 0.72$
[53]	Βαμβάκι	Μυκητολογική	MS	EVI, RENDVI, SAVI, MSAVI, RDVI	$R^2 = 0.78$

4.3 Μέθοδοι μηχανικής μάθησης

Η μετάβαση από τις προσεγγίσεις με δείκτες βλάστησης στις τεχνικές μηχανικής μάθησης αποτελεί φυσική εξέλιξη στην εκτίμηση ασθενειών μέσω UAVs, καθώς η αυξανόμενη διαθεσιμότητα απο δεδομένα υψηλής ανάλυσης μέσω RGB, πολυφασματικούς και υπερφασματικούς αισθητήρες επιτρέπει πλέον πιο ακριβή και ανθεκτική μοντελοποίηση των καλλιεργειών. Σε αντίθεση με τις γραμμικές συσχετίσεις ενός μόνο δείκτη, τα μοντέλα μηχανικής μάθησης μπορούν να ενσωματώνουν ταυτόχρονα πολλαπλές ζώνες, πολλαπλούς δείκτες βλάστησης, καθώς και άλλα χρήσιμα συμπληρωματικά χαρακτηριστικά. Όπως απεικονίζεται στο σχήμα 4.2, σε μια τυπική ροή μηχανικής μάθησης, μετά τη συλλογή των δεδομένων, οι εικόνες από τα UAV διορθώνονται και μετατρέπονται σε ορθομωσαϊκά, ακολουθεί η εξαγωγή των χαρακτηριστικών, όπως δείκτες βλάστησης και στη συνέχεια εφαρμόζονται αλγόριθμοι μηχανικής μάθησης όπως RF, SVM, k-NN είτε για ταξινόμηση (υγιές/μη υγιές) είτε για παλινδρόμηση. Η αξιολόγηση των μεθόδων μηχανικής μάθησης γίνεται συνήθως με μετρικές όπως Accuracy ή Overall Accuracy, οι οποίες

χρησιμοποιούνται για να περιγράψουν συνολικά την ικανότητα ενός μοντέλου να αποδίδει σωστά τις προβλέψεις του στο σύνολο των δεδομένων, ανεξαρτήτως της φύσης του προβλήματος ή της κλίμακας ανάλυσης. Παρακάτω παρουσιάζονται αντιπροσωπευτικές μελέτες που συνδυάζουν αλγορίθμους μηχανικής μάθησης με δείκτες βλάστησης για την ανίχνευση και εκτίμηση ασθενειών, ώστε να αναδειχθούν τόσο τα πλεονεκτήματά τους όσο και οι περιορισμοί τους.



Σχήμα 4.2: Ροή μεθόδων μηχανικής μάθησης.

Για την έγκαιρη ανίχνευση μιας μυκητολογικής ασθένειας στο ρύζι που προκαλεί κηλίδωση στα φύλλα αξιοποιώντας υπερφασματικά δεδομένα από UAV, παρουσιάζεται μια σύγχρονη προσέγγιση μηχανικής μάθησης σε συνδυασμό με δείκτες βλάστησης. Οι συγγραφείς εστιάζουν στην ευαισθησία της ασθένειας σε πρώιμα στάδια, όπου οι οπτικές αλλοιώσεις του φυλλώματος δεν είναι ακόμη έντονες, αλλά εμφανίζονται μετρήσιμες μεταβολές στη φασματική υπογραφή των φύλλων. Για τον σκοπό αυτό, υπολογίζουν έναν νέο δείκτη βλάστησης τον RBVI (Rice Blast Vegetation Index), ειδικά σχεδιασμένο για την ανίχνευση της συγκεκριμένης ασθένειας, καθώς και ένα σύνολο συμβατικών φασματικών δεικτών, οι οποίοι χρησιμοποιούνται ως είσοδοι στα μοντέλα μηχανικής μάθησης. Στο στάδιο της ταξινόμησης, αξιολογούνται διαφορετικοί αλγόριθμοι μηχανικής μάθησης, όπως SVM και AdaBoost. Τα αποτελέσματα δείχνουν ότι ο συνδυασμός RBVI + SVIs με το μοντέλο μηχανικής μάθησης υπερτερεί έναντι των επιμέρους αλγορίθμων, επιτυγχάνοντας Overall Accuracy OA=95.90% [35], γεγονός που καταδεικνύει την υψηλή διακριτική ικανότητα της προσέγγισης ακόμη και σε συνθήκες πρώιμης προσβολής.

Για την ανίχνευση ασθενειών των φύλλων του ευκαλύπτου έγινε ανάλυση σε τέσσερα επίπεδα (υγιές, ήπιο, μέτριο, σοβαρό) με τη χρήση UAV πολυφασματικών εικόνων από DJI Phantom 4. Οι συγγραφείς επέλεγον χαρακτηριστικά όπως οι ζώνες πράσινο και εγγύς υπέρυθρο, οι οποίες είναι οι πιο ευαίσθητες, ενώ από τους δείκτες βλάστησης ξεχωρίζουν ο NRI και ο GI. Στη συνέχεια συγκρίνουν Random Forest (RF) με Spectral Angle Mapper (SAM) και δείχνουν ότι ο RF με συνδυασμό με τις ζώνες και τον δείκτη NRI επιτυγχάνει την καλύτερη ταξινόμηση, με OA=90.1% [33], αποδεικνύοντας ότι η ενσωμάτωση ενός κατάλληλου δείκτη βλάστησης βελτιώνει ουσιαστικά τον διαχωρισμό των επιπέδων σοβαρότητας.

Για την αναγνώριση μιας μυκητολογικής ασθένειας που προσβάλλει τα φύλλα των δέντρων καουτσούκ χρησιμοποιήθηκαν πολυφασματικές εικόνες από UAV, με έμφαση στη συνδυαστική αξιοποίηση δεικτών βλάστησης. Οι συγγραφείς ξεκινούν από πολυφασματικό ορθομοσαϊκό υψηλής ανάλυσης (3.4 εκ) και προσομοιώνουν χαμηλότερες αναλύσεις (7 εκ, 14 εκ, 30 εκ) ώστε να εξετάσουν πώς η υποβάθμιση της ανάλυσης επηρεάζει την αναγνώριση της ασθένειας. Από τις εικόνες εξάγουν 22 δείκτες βλάστησης. Στο στάδιο της ταξινόμησης αξιολογούνται κλασικοί αλγόριθμοι τεχνητής νοημοσύνης όπως SVM, RF, KNN πάνω στους δείκτες βλάστησης. Η μέγιστη ακρίβεια επιτυγχάνεται στην υψηλότερη ανάλυση τα 3.4 εκ., όπου ο SVM φτάνει ακρίβεια A=98.16% [34], και αντίστοιχα παραμένει υψηλή στα 7 εκ. και 14 εκ., ενώ στην πιο χαμηλή ανάλυση των 30 εκ. η επίδοση μειώνεται αισθητά. Έτσι, η μελέτη αναδεικνύει ότι η επιτυχία των μοντέλων τεχνητής νοημοσύνης σε συνδυασμό με δείκτες βλάστησης δεν εξαρτάται μόνο από τον αλγόριθμο, αλλά και από τον κατάλληλο συνδυασμό ύψους, το οποίο επηρεάζει και άμεσα την ανάλυση.

Σε μια μελέτη προτείνεται ένα πρακτικό πλαίσιο ανίχνευσης ασθενειών ή εντόμων σε φοίνικες των Καναρίων Νήσων, συνδυάζοντας πολυφασματικές λήψεις από UAV με μοντέλα μηχανικής μάθησης. Οι συγγραφείς χρησιμοποίησαν κάμερα MicaSense Altum σε DJI Matrice 200 v2 και αρχικά πραγματοποίησαν τμηματοποίηση ανά δέντρο, ώστε η ανάλυση να γίνεται σε κλίμακα ενός δέντρου και όχι σε επίπεδο χάρτη ολόκληρης της καλλιέργειας. Έπειτα ενσωμάτωσαν φασματικές ζώνες και δείκτες βλάστησης σε αλγόριθμους ταξινόμησης SVM, ANN και RF. Το τελικό σύστημα βασίζεται σε Random Forest, επιτυγχάνοντας ακρίβεια A=87% [56].

Στην έρευνα που εξετάζεται η ανίχνευση του όψιμου περονόσπορου ενός παθογόνου μύκητα που προσβάλλει την πατάτα, δίνεται έμφαση σε φασματικά χαρακτηριστικά που είναι χρήσιμα όταν τα συμπτώματα δεν είναι ακόμη έντονα. Η προσέγγιση βασίζεται σε επιλεγμένες ανακλάσεις, ώστε να αναδειχθούν διαφορές στο φύλλωμα μετά από την μόλυνση. Για την τελική ταξινόμηση υγιών-προσβεβλημένων δειγμάτων χρησιμοποιείται SVM με OA=89.33% [57], επιβεβαιώνοντας την πρακτική αξία των εγγύς υπέρυθρων χαρακτηριστικών με αλγόριθμους μηχανικής μάθησης.

Για την ασθένεια που προκαλεί κιτρίνισμα φύλλων στην αρέκα, συνδυάστηκαν δείκτες βλάστησης όπως NDVI, OSAVI, LCI, GNDVI, NDRE με χαρακτηριστικά υφής, και χαμηλής ανάλυσης RGB κάμερες. Δοκιμάστηκαν τα μοντέλα DT, NB, SVM, kNN και BPNN, όπου ο BPNN αναδεικνύεται ως το πιο αποτελεσματικό με A=92% [58], δείχνοντας ότι η προσθήκη χαρακτηριστικών υφής μπορεί να ενισχύσει αισθητά την ικανότητα διάκρισης των κατηγοριών ασθένειας πέρα από τους καθαρά φασματικούς δείκτες.

Σε μια άλλη μελέτη πάλι σχετική με μύκητα που προσβάλλει τα φύλλα τα δέντρα καουτσούκ, με τη συλλογή πολυφασματικών εικόνων από DJI Phantom 4 Multispectral έγινε εξαγωγή πλούσιων χαρα-

κτηριστικών, 5 φασματικές ζώνες και 14 δείκτες βλάστησης χρησιμοποιήθηκαν σε συνδυασμό με τους αλγορίθμους RF, BPNN και SVM μοντέλα. Το καλύτερο αποτέλεσμα ήταν αυτό του SVM από τον οποίο επιτεύχθηκε OA=95.88% [32].

Πίνακας 4.2: Σύνοψη μελετών μηχανικής μάθησης (ML), για ανίχνευση ασθενειών με τη χρήση UAV. Οι συντομογραφίες που χρησιμοποιούνται είναι οι εξής: HS (Υπερφασματικός), MS (Πολυφασματικός), VIs (Δείκτες βλάστησης), ΦΖ (Φασματικές ζώνες).

Βιβλ.	Φυτό	Τύπος Ασθένειας	Αισθητήρας	Χαρακ.	Μέθοδοι ML	Μετρικές
[35]	Ρύζι	Μυκητολογική	HS	VIs	SVM, AdaBoost	OA=95.90%
[33]	Ευκάλυπτος	Μυκητολογική	MS	VIs + ΦΖ	RF	OA=90.10%
[34]	Καουτσούκ	Μυκητολογική	MS	VIs + ΦΖ	SVM, RF, KNN	A=98.16%
[59]	Καουτσούκ	Μυκητολογική	MS	VIs + ΦΖ	SVM, RF, BPNN	OA=95.88%
[56]	Φοίνικας	Εντομολογική	MS	VIs + ΦΖ	RF, SVM, ANN	A=87%
[57]	Πατάτα	Μυκητολογική	MS	ΦΖ	SVM	OA=89.33%
[58]	Αρέκα	Μυκητολογική	RGB	VIs	DT, NB, SVM, KNN, BPNN	A=92%
[32]	Καουτσούκ	Μυκητολογική	MS	VIs + ΦΖ	RF, BPNN, SVM	OA=95.88%
[60]	Βαμβάκι	Μυκητολογική	MS	ΦΖ	MLR, SVM, RF	A=79.00%
[61]	Μπανάνα	Μυκητολογική	MS	VIs	SVM, RF, BPNN	OA=97.28%
[62]	Σιτάρι	Μυκητολογική	HS	VIs + ΦΖ	BP, SA	OA=98.00%
[63]	Σιτάρι	Μυκητολογική	HS	VIs	SVM	$R^2 = 0.88$
[64]	Σιτάρι	Μυκητολογική	MS	VIs + ΦΖ	PLSR, SVR, BPNN	$R^2 = 0.83$
[31]	Σιτάρι	Μυκητολογική	HS	VIs	SVM	$R^2 = 0.63$
[65]	Ζαχαροκάλαμο	Βακτηριακή	MS	VIs	XGB, RF, DT, KNN	OA=94.00%
[38]	Βαμβάκι	Μυκητολογική	MS	ΦΖ	K-means, SVM	A=88.50%
[36]	Ελαιοφοίνικας	Μυκητολογική	MS	ΦΖ	ANN	A=72.73%

4.4 Μέθοδοι βαθιάς μάθησης

Η αξιοποίηση των τεχνικών βαθιάς μάθησης για την έγκαιρη ανίχνευση και ταξινόμηση των ασθενειών στις καλλιέργειες μέσω UAV έχει ενισχυθεί σημαντικά τα τελευταία χρόνια, καλύπτοντας ένα ευρύ φάσμα καλλιεργειών, αισθητήρων και σεναρίων εφαρμογής. Όπως παρουσιάζεται στο σχήμα 4.3, η τυπική ροή εφαρμογής μεθόδων βαθιάς μάθησης σε δεδομένα UAV περιλαμβάνει διαδοχικά στάδια συλλογής και προετοιμασίας δεδομένων, κατασκευής μοντέλου και αξιολόγησης της απόδοσης. Αρχικά πραγματοποιείται η χαρτογράφηση της καλλιέργειας και η συλλογή εικόνων υψηλής ανάλυσης, οι οποίες στη συνέχεια υποβάλλονται σε διαδικασίες διόρθωσης και διαχωρισμού σε σύνολα εκπαίδευσης και αξιολόγησης. Στο επόμενο στάδιο, τα δεδομένα εισάγονται απευθείας σε μοντέλα βαθιάς μάθησης, όπου η εξαγωγή χαρακτηριστικών και η ταξινόμηση ή τμηματοποίηση πραγματοποιούνται ενιαία μέσω της ίδιας νευρωνικής αρχιτεκτονικής. Τέλος, η απόδοση των μοντέλων αξιολογείται με κατάλληλες μετρικές, επιτρέποντας την ποσοτική αποτίμηση της ακρίβειας και της αξιοπιστίας των αποτελεσμάτων σε εφαρμογές ανίχνευσης ασθενειών ή καταπόνησης των καλλιεργειών.



Σχήμα 4.3: Ροή μεθόδων βαθιάς μάθησης.

Μοντέλα ταξινόμησης Χαρακτηριστικό παράδειγμα αποτελεί η ανίχνευση της κίτρινης σκωρίας στο σιτάρι, όπου χρησιμοποιήθηκαν υπερφασματικές εικόνες UAV και εφαρμόστηκαν τα μοντέλα Inception και ResNet για τη δυαδική ταξινόμηση υγιών και μη υγιών περιοχών. Σε πτήσεις περίπου στα 30 m, το σύστημα πέτυχε ακρίβεια $A=85\%$ [42], αποδεικνύοντας ότι τα υπερφασματικά δεδομένα σε συνδυασμό με ισχυρά CNN, μπορούν να δώσουν υψηλή ακρίβεια εντοπισμού ασθένειας ακόμη και πριν η προσβολή γίνει εμφανής στο μάτι.

Αντίστοιχα υψηλές επιδόσεις αναφέρονται σε μια μελέτη για την παρακολούθηση και τον εντοπισμό ασθενειών στο καλαμπόκι χρησιμοποιώντας υψηλής ανάλυσης RGB εικόνες σε χαμηλό ύψος πτήσης, περίπου 12 μέτρα. Οι συγγραφείς συγκρίνουν πολλαπλές CNN αρχιτεκτονικές όπως VGG, ResNet, Inception και DenseNet169, με στόχο τη σταθερή αναγνώριση ασθενών φυτών ή περιοχών. Τα αποτελέσματα έδειξαν ότι η βέλτιστη προσέγγιση μπορεί να φτάσει έως και 100% ακρίβεια [41], αναδεικνύοντας τη δυναμική των DL μοντέλων όταν τα δεδομένα είναι σωστά διαμορφωμένα και υψηλής ποιότητας.

Στο σιτάρι, η ανίχνευση μιας μυκητολογικής ασθένειας που προκαλεί κηλίδες στα φύλλα του σιταριού, εξετάστηκε με χρήση RGB δεδομένων από το UAV DJI Phantom. Για την ταξινόμηση τεσσάρων επιπέδων σοβαρότητας (κανονικό, ελαφρύ, μεσαίο, σοβαρό) εφαρμόστηκε κλασικός CNN ταξινομητής, ο οποίος πέτυχε ακρίβεια $OA=91.43\%$ [66], υπερέχοντας έναντι εναλλακτικών μεθόδων και επιβεβαιώνον-

ντας ότι ακόμη και μονοφασματικά RGB δεδομένα μπορούν να υποστηρίξουν αξιόπιστη πολυ-κλασική ταξινόμηση ασθeneιών.

Σε μια έρευνα που αφορά την έγκαιρη διάγνωση ασθeneιών στο καλαμπόκι συνδυάστηκαν δεδομένα UAV και δορυφορικής τηλεπισκόπησης, ώστε το μοντέλο να έχει πρόσβαση ταυτόχρονα στην τοπική λεπτομέρεια και το ευρύτερο χωρικό πλαίσιο. Για την ταξινόμηση αξιολογήθηκαν κλασικές DL αρχιτεκτονικές ResNet-50, VGG-16, DenseNet-121, Inception-V3, η καλύτερη συνολική επίδοση σημειώθηκε με ResNet-50 με $A=92.54\%$ [43].

Για την ανίχνευση περονόσπορου στο λάχανο όπου χρησιμοποιήθηκαν RGB εικόνες από UAV. Η μελέτη αξιολόγησε CNN αρχιτεκτονικές όπως EfficientNet, MobileNet και ViT παραλλαγές, με στόχο υψηλή ακρίβεια χωρίς μεγάλο υπολογιστικό κόστος. Τα αποτελέσματα δείχνουν ότι τα μοντέλα μπορούν να πετύχουν ακρίβεια $OA=94.8\%$ [67], ενώ σε σενάρια πρώιμης ανίχνευσης αναφέρονται ακόμη υψηλότερες επιδόσεις. Έτσι, η μελέτη τεκμηριώνει ότι η RGB χαρτογράφηση με UAV μπορεί να υποστηρίξει έγκαιρη και πρακτικά υλοποιήσιμη διάγνωση.

Η αξία των υπερφασματικών δεδομένων αναδεικνύεται ιδιαίτερα στην ανίχνευση ιολογικών ασθeneιών. Σε μια μελέτη που συλλέχθηκαν δεδομένα από υπερφασματικούς αισθητήρες UAV για τη διάγνωση ιολογικής νόσου στη γλυκοπατάτα, με το PLCNet, ενός 3D-CNN πλαισίου σε επίπεδο φυτού. Ο υπερφασματικός κύβος επιτρέπει στο δίκτυο να μαθαίνει ταυτόχρονα χωρικές και φασματικές συσχετίσεις μέσω τρισδιάστατων συνελιξιών, οδηγώντας σε ακρίβεια $A=96.55\%$ [68], ακόμη και όταν τα συμπτώματα είναι πρώιμα και μη εμφανή σε απλούς RGB αισθητήρες.

Αντίστοιχα, για την ταξινόμηση της σοβαρότητας του ωιδίου στο σιτάρι, προτείνεται ένα βελτιωμένο μοντέλο βασισμένο στο ResNet34 (QY-SE-MResNet34). Το δίκτυο ενσωματώνει μηχανισμούς προσοχής και μεταφοράς μάθησης, υπερέχοντας έναντι ResNet50, VGG16 και MobileNetV2, με ακρίβεια $A=89\%$ [69], γεγονός που δείχνει ότι οι στοχευμένες αρχιτεκτονικές μπορούν να αποδώσουν καλύτερα σε προβλήματα πολυ-επιπέδων σοβαρότητας.

Για την πρώιμη ανίχνευση μιας ασθeneίας που προκαλεί τον μαρασμό των πεύκων, χρησιμοποιήθηκαν υπερφασματικές εικόνες από UAV. Η ταξινόμηση έγινε με τρισδιάστατα CNN (3D-CNN). Το αποτέλεσμα έφτασε $OA=88.11\%$ [70], υποδεικνύοντας ότι ο συνδυασμός υπερφασματικών δεδομένων με τρισδιάστα DL είναι ικανός να εντοπίζει πρώιμα μοτίβα καταπόνησης που συνδέονται με την ασθeneία πριν αυτή γίνει εμφανής οπτικά με συμβατικές εικόνες, κάτι κρίσιμο για έγκαιρη παρέμβαση.

Πίνακας 4.3: Σύνοψη μελετών βαθιάς μάθησης (DL) με μοντέλα ταξινόμησης, για ανίχνευση ασθενειών καλλιέργειών με χρήση UAV. Οι συντομογραφίες που χρησιμοποιούνται είναι οι εξής: HS (Υπερφασματικός), MS (Πολυφασματικός), A (Ακρίβεια), OA (Ολική Ακρίβεια).

Βιβλ.	Φυτό	Τύπος Ασθένειας	Αισθητήρας	Μέθοδοι DL	Μετρικές
[42]	Σιτάρι	Μυκητολογική	HS	Inception, ResNet	A=85.00%
[41]	Καλαμπόκι	Μυκητολογική	RGB	VGG, ResNet, Inception, DenseNet169	A=100.00%
[66]	Σιτάρι	Μυκητολογική	RGB	CNN	OA=91.43%
[67]	Λάχανο	Μυκητολογική	RGB	EfficientNet, MobileNetV3	OA=94.80%
[43]	Καλαμπόκι	Μυκητολογική	RGB	ResNet-50, VGG-16, DenseNet-121, Inception-V3	A=92.54%
[68]	Γλυκοπατάτα	Ιολογική	HS	PLCNet	A=96.55%
[69]	Σιτάρι	Μυκητολογική	RGB	QY-SE-MResNet34	A=89.00%
[70]	Πεύκο	Νηματώδης	HS	3D-CNN	OA=88.11%

Μοντέλα τμηματοποίησης Οι τεχνικές βαθιάς μάθησης για μοντέλα τμηματοποίησης έχουν αποκτήσει κεντρικό ρόλο στη χαρτογράφηση φυτικών ασθενειών με UAV, καθώς επιτρέπουν τον εντοπισμό των προσβεβλημένων περιοχών σε επίπεδο εικονοστοιχείου και όχι απλώς συνολική ταξινόμηση εικόνων ή αγροτεμαχίων. Η βιβλιογραφία δείχνει ότι η επιλογή του αισθητήρα, η αρχιτεκτονική του δικτύου και το είδος της ασθένειας επηρεάζουν άμεσα την ακρίβεια και τη χρησιμότητα των παραγόμενων χαρτών.

Στα δασικά οικοσυστήματα, μια ασθένεια που προκαλεί μαρασμό των πεύκων, χρησιμοποιήθηκαν δεδομένα RGB εικόνων από UAV και εφαρμόστηκαν κλασικές αρχιτεκτονικές τμηματοποίησης όπως U-Net, SegNet και DeepLab, επιτρέποντας την παρακολούθηση της εξέλιξης της ασθένειας. Τα αποτελέσματα είναι εντυπωσιακά, με ακρίβεια A=99.7% [45], αποδεικνύοντας ότι ακόμη και απλά RGB δεδομένα μπορούν να υποστηρίξουν εξαιρετικά αξιόπιστη χαρτογράφηση όταν συνδυάζονται με κατάλληλα δίκτυα κωδικοποιητή-αποκωδικοποιητή. Αντίστοιχα, σε μελέτη για την μόλυνση των πεύκων από παράσιτα, το υβριδικό VGG - U-Net αξιοποιεί την ισχυρή εξαγωγή χαρακτηριστικών του VGG για ακριβή απομόνωση προσβεβλημένων δέντρων, πέτυχε ακρίβεια A=99.13% [71], αναδεικνύοντας την αποτελεσματικότητα των U-Net παραλλαγών σε προβλήματα τμηματοποίησης.

Σε γεωργικές καλλιέργειες, όπου τα συμπτώματα συχνά εμφανίζονται σε μικρότερη κλίμακα και με μεγαλύτερη ανομοιογένεια, η χρήση πολυφασματικών δεδομένων αποδεικνύεται ιδιαίτερα χρήσιμη. Μια μυκητολογική ασθένεια του στάχους που προκαλεί απώλειες απόδοσης και σοβαρή υποβάθμιση στο σιτάρι χαρτογραφείται με πολυφασματικές εικόνες από UAV και το μοντέλο U2Net+, το οποίο στοχεύει στη σαφή διάκριση προσβεβλημένων και υγιών περιοχών σε επίπεδο εικονοστοιχείου, όπως τα προσβεβλημένα στάχυα. Η προσέγγιση επιτυγχάνει ακρίβεια A=91.7% [44], δείχνοντας ότι η φασματική πληροφορία πέρα από το RGB ενισχύει σημαντικά την ακρίβεια της ανίχνευσης ασθενειών σε σύνθετες καλλιέργειες.

Παράλληλα, μια μελέτη που εξετάζει πάλι μια ασθένεια που συνδέεται με τον μαρασμό των πεύκων με υπερφασματικά δεδομένα από UAV, υιοθετώντας την προσέγγιση R-CNN, η οποία εστιάζει περισσότερο στον εντοπισμό και τη διάκριση μεμονωμένων αντικειμένων όπως το φύλλωμα του δέντρου. Αν και με ακρίβεια A=83.51% [72], χαμηλότερη σε σύγκριση με RGB σχήματα, η μελέτη υπογραμμίζει την αξία της υπερφασματικής πληροφορίας για πρόωμη ανίχνευση μεταβολών σε καλλιέργειες.

Στο σιτάρι, η σκωρίαση έχει μελετηθεί εκτενώς με διαφορετικούς αισθητήρες και μοντέλα τμηματοποίησης. Όταν το PSPNet εφαρμόστηκε σε RGB εικόνες από UAV, κατάφερε να επιτύχει ακρίβεια $A=94.0\%$ [46], ακόμη και με περιορισμένη επίβλεψη. Η απόδοση βελτιώνεται περαιτέρω σε μια μελέτη, όπου το Ir-UNet συνδυάζεται με UAV πολυφασματικά δεδομένα του εγγύς υπέρυθρου, εκμεταλλευόμενα τη φασματική ευαισθησία της περιοχής του κόκκινου άκρου σε μεταβολές χλωροφύλλης, οδηγώντας σε ακρίβεια $A=97.13\%$ [73].

Η αξία των υπερφασματικών δεδομένων αναδεικνύεται και στην καλλιέργεια της πατάτας. Σε μια μελέτη που προτείνεται το CropdocNet, εφαρμόζεται σε υπερφασματικές UAV εικόνες από ύψος 30 m για την τμηματοποίηση μιας φυτοπαθολογικής ασθένειας, επιτυγχάνει ακρίβεια $A=95.75\%$ [74], και επιτρέπει τον ακριβή εντοπισμό εστιών προσβολής πριν την πλήρη εξάπλωση της ασθένειας. Τέλος, σε πιο σύνθετα αγρονομικά περιβάλλοντα όπως τα αμπέλια, μια μελέτη δείχνει ότι η συγχώνευση RGB δεδομένων με το δίκτυο VddNet μπορεί να βελτιώσει την ανθεκτικότητα της τμηματοποίησης σε σκιάσεις και γεωμετρικές παραμορφώσεις, επιτυγχάνοντας ακρίβεια $A=93.72\%$. [75]

Συνολικά, οι μελέτες αυτές καταδεικνύουν ότι τα μοντέλα τμηματοποίησης αποτελούν ισχυρό εργαλείο για την παρακολούθηση των καλλιεργειών με UAV, με τις U-Net παραλλαγές να κυριαρχούν σε RGB και πολυφασματικά σενάρια και τα υπερφασματικά δίκτυα να προσφέρουν πρόσθετη αξία για την πρόωμη ανίχνευση ασθενειών, έστω και με αυξημένη υπολογιστική πολυπλοκότητα.

Πίνακας 4.4: Σύνοψη μελετών βαθιάς μάθησης (DL) με μοντέλα τμηματοποίησης, για ανίχνευση ασθενειών με τη χρήση UAV. Οι συντομογραφίες που χρησιμοποιούνται είναι οι εξής: HS (Υπερφασματικός), MS (Πολυφασματικός).

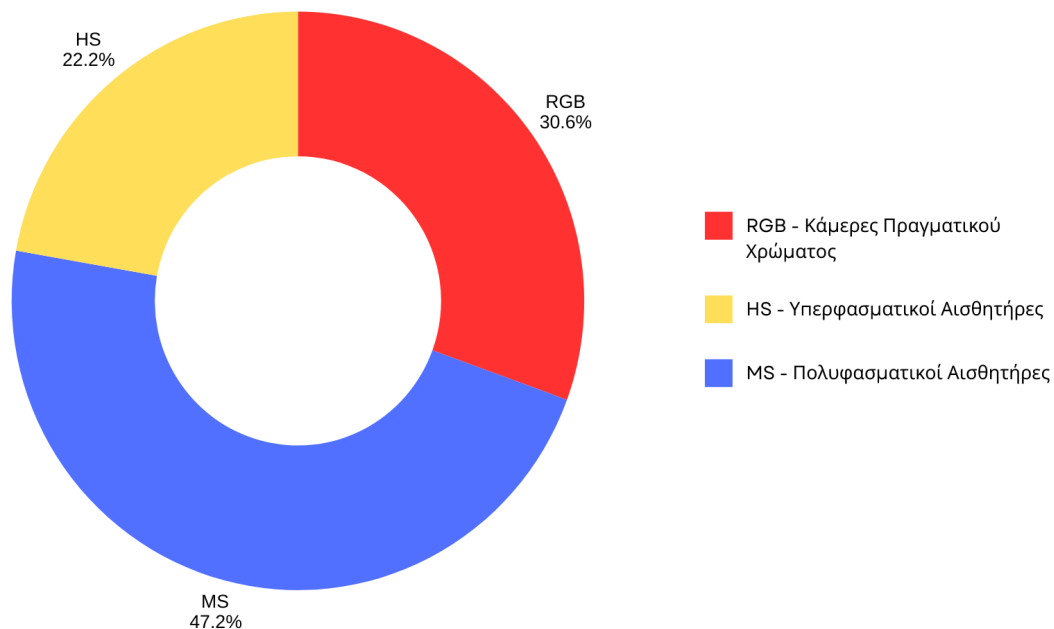
Βιβλ.	Φυτό	Τύπος Ασθένειας	Αισθητήρας	Μέθοδοι DL	Ακρίβεια (%)
[45]	Πεύκο	Μυκητολογική	RGB	U-Net, SegNet, DeepLab	99.70
[71]	Πεύκο	Νηματώδης	RGB	U-Net	99.13
[44]	Σιτάρι	Μυκητολογική	MS	U2Net+	91.70
[72]	Πεύκο	Μυκητολογική	HS	R-CNN	83.51
[46]	Σιτάρι	Μυκητολογική	RGB	PSPNet	94.00
[73]	Σιτάρι	Μυκητολογική	MS	Ir-UNet	97.13
[74]	Πατάτα	Μυκητολογική	HS	CropdocNet	95.75
[75]	Αμπέλι	Μυκητολογική	RGB	VddNet	93.72

Κεφάλαιο 5ο: Αποτελέσματα έρευνας και συμπεράσματα

Το παρόν κεφάλαιο παρουσιάζει τα αποτελέσματα που προέκυψαν από τη σύνθεση και συγκριτική ανάλυση της βιβλιογραφίας που εξετάστηκε στην εργασία, σχετικά με τη χρήση UAV και σημνών UAV στη γεωργία ακριβείας με έμφαση στην αντίληψη, την αξιοποίηση δεικτών βλάστησης και την εφαρμογή τεχνικών μηχανικής και βαθιάς μάθησης. Παρακάτω, καταγράφονται οι συχνότερα χρησιμοποιούμενοι αισθητήρες, οι πιο διαδεδομένοι και αποτελεσματικοί δείκτες βλάστησης, καθώς και τα μοντέλα μηχανικής και βαθιάς μάθησης που εμφανίζονται με τη μεγαλύτερη συχνότητα και τις υψηλότερες επιδόσεις στις αντίστοιχες εφαρμογές. Στόχος του κεφαλαίου είναι να αναδείξει τις επικρατούσες τεχνολογικές επιλογές και να τεκμηριώσει τις τάσεις που διαμορφώνουν τις σύγχρονες προσεγγίσεις UAV στη γεωργία

ακριβείας, ώστε να εξαχθούν συμπεράσματα και κατευθύνσεις που υποστηρίζουν τόσο την ερευνητική εξέλιξη όσο και την πρακτική υιοθέτηση των τεχνολογιών στο πεδίο.

Με βάση τα δεδομένα που προέκυψαν από τις μελέτες που αφορούσαν δείκτες βλάστησης, καθώς και προσεγγίσεις μηχανικής και βαθιάς μάθησης, απαντάται το πρώτο ερευνητικό ερώτημα καθώς απο το σχήμα 5.1 προκύπτει ότι οι πολυφασματικοί αισθητήρες (MS) αποτελούν την πιο δημοφιλή επιλογή, καλύπτοντας 47,2% των περιπτώσεων, καθώς προσφέρουν ισορροπία μεταξύ κόστους, επιχειρησιακής ευκολίας και επάρκειας φασματικής πληροφορίας για δείκτες βλάστησης και μοντελοποίηση της καταπόνησης και των ασθενειών. Ακολουθούν οι κάμερες RGB με 30,6%, οι οποίες προτιμώνται συχνά λόγω της χαμηλής πολυπλοκότητας, της υψηλής ανάλυσης και της ευρείας διαθεσιμότητας σε UAV πλατφόρμες, καθιστώντας τις ιδιαίτερα ελκυστικές για ταξινόμηση και τμηματοποίηση με βαθιά μάθηση. Τέλος, οι υπερφασματικοί αισθητήρες (HS) εμφανίζονται σε 22,2% των μελετών, ποσοστό χαμηλότερο αλλά ενδεικτικό της αυξημένης ερευνητικής τους αξίας, καθώς παρέχουν πλουσιότερη φασματική πληροφορία για πρόωμη ανίχνευση καταπόνησης στις καλλιέργειες, με τίμημα όμως το μεγάλο κόστος, τις αυξημένες απαιτήσεις βαθμονόμησης και επεξεργασίας των δεδομένων. Συνολικά, η κατανομή αυτή υποδηλώνει ότι η βιβλιογραφία ευνοεί τους πολυφασματικούς αισθητήρες που υποστηρίζουν αξιόπιστους δείκτες βλάστησης σε συνδυασμό με μοντέλα μηχανικής μάθησης, ενώ ταυτόχρονα διατηρούν ισχυρή παρουσία οι προσεγγίσεις RGB με βαθιά μάθηση. Οι υπερφασματικοί αισθητήρες τείνουν να αξιοποιούνται κυρίως όταν ζητείται μέγιστη φασματική ευαισθησία χωρίς τον περιορισμό του υψηλού κόστους.




Σχήμα 5.1: Κατανομή των μελετών ως προς τον τύπο αισθητήρα UAV που χρησιμοποιήθηκε για εφαρμογές με δείκτες βλάστησης και μεθόδους μηχανικής και βαθιάς μάθησης.

Στη συνέχεια, όπως φαίνεται στο σχήμα 5.2 αναλύθηκαν οι πιο δημοφιλείς δείκτες βλάστησης που χρησι-

μοποιήθηκαν στις μελέτες των πινάκων 4.1 και 4.2 της παρούσας εργασίας, δηλαδή στις εργασίες όπου οι δείκτες βλάστησης αξιοποιούνται είτε άμεσα για εκτίμηση είτε ως χαρακτηριστικά εισόδου σε μοντέλα μηχανικής μάθησης. Με την ανάλυση αυτή απαντάται το δεύτερο ερευνητικό ερώτημα, καθώς αποτυπώνονται οι δείκτες που εμφανίζονται συστηματικά στη σύγχρονη βιβλιογραφία και η αποτελεσματικότητά τους. Η κατανομή δείχνει ότι ο NDVI κυριαρχεί ως ο συχνότερα χρησιμοποιούμενος δείκτης, ενώ ακολουθεί ο NDRE, ο οποίος αξιοποιεί τη ζώνη του κόκκινου άκρου σε συνδυασμό με το εγγύς υπέρυθρο. Στη συνέχεια ακολουθούν οι δείκτες που στοχεύουν σε καλύτερη ευαισθησία σε βιοφυσικές μεταβολές όπως GDVI, OSAVI, RDVI, GNDVI, RVI. Το μοτίβο αυτό είναι αναμενόμενο, καθώς οι NDVI και NDRE αποτελούν τους βασικούς δείκτες σε πολυφασματικά δεδομένα και συχνά συνδυάζονται με μοντέλα μηχανικής μάθησης για να βελτιώσουν την ακρίβεια των αποτελεσμάτων.

Επιπλέον, ο πίνακας 4.1 αναδεικνύει σαφώς ότι η αποτελεσματικότητα των δεικτών βλάστησης διαφοροποιείται ανάλογα με το είδος του μοντέλου και την ασθένεια που εξετάζεται. Ενδεικτικά, σε μελέτη που βασίστηκε σε γραμμική παλινδρόμηση, ο NDRE προέκυψε ως ο πλέον κατάλληλος δείκτης, επιτυγχάνοντας τιμή $R^2 = 0.82$, γεγονός που αποδίδεται στην αυξημένη ευαισθησία στη ζώνη κόκκινου άκρου σε πρώιμες μεταβολές της φυτικής υγείας. Αντίστοιχα, σε μελέτη που εφάρμοσε δυαδική λογιστική παλινδρόμηση για την ανίχνευση ασθένειας στη μπανάνα, ο δείκτης CIRE/CI παρουσίασε την υψηλότερη επίδοση με ακρίβεια περίπου $OA=91.7\%$, υποδεικνύοντας ότι οι δείκτες που σχετίζονται με τη χλωροφύλλη και την ανάπτυξη της επιφάνειας του φυλλώματος μπορούν να είναι ιδιαίτερα αποτελεσματικοί σε συγκεκριμένα παθογόνα. Τέλος, στον ίδιο πίνακα καταγράφονται και περιπτώσεις όπου η χρήση συνδυασμών δεικτών όπως NDVI, MSAVI, NDRE, CI συνδέεται με ακόμη υψηλότερες επιδόσεις, έως $R^2=0.90$, στοιχείο που ενισχύει τη διαπίστωση ότι οι προσεγγίσεις που συνδυάζουν δείκτες βλάστησης υπερτερούν συχνά της μεμονωμένης χρήσης ενός δείκτη, ιδιαίτερα όταν οι δείκτες αξιοποιούνται ως χαρακτηριστικά εισόδου σε μοντέλα μηχανικής μάθησης.

Η επικράτηση του NDVI ως ο πιο διαδεδομένος δείκτης βλάστησης στη βιβλιογραφία οφείλεται κυρίως στην ευρεία αποδοχή του από την επιστημονική κοινότητα, στη σταθερή του απόδοση σε διαφορετικές καλλιέργειες και συνθήκες, καθώς και στη συμβατότητά του με το σύνολο σχεδόν των πολυφασματικών αισθητήρων που χρησιμοποιούνται σε UAV εφαρμογές. Παράλληλα, η απλότητα στην ενσωμάτωσή του σε ροές επεξεργασίας και η εκτεταμένη χρήση του σε προηγούμενες μελέτες τον καθιστούν σημείο αναφοράς για συγκριτική αξιολόγηση, γεγονός που ενισχύει περαιτέρω τη χρήση του τόσο αυτόνομα όσο και σε συνδυασμό με μοντέλα μηχανικής μάθησης.




Σχήμα 5.2: Συχνότητα εμφάνισης των δεικτών βλάστησης στις μελέτες που αξιοποιούν τους δείκτες βλάστησης είτε άμεσα είτε ως χαρακτηριστικά εισόδου σε μοντέλα μηχανικής μάθησης.

Για να είναι σαφές το πλαίσιο των επόμενων υποενοτήτων, αρχικά παρουσιάζεται στο σχήμα 5.3, η κατανομή των μελετών που χρησιμοποιήθηκαν για την παραγωγή των αποτελεσμάτων σχετικά με τις προσεγγίσεις μηχανικής και βαθιάς μάθησης.

Στο σύνολο των 33 ερευνών που χρησιμοποιήθηκαν για την εξαγωγή των αποτελεσμάτων, οι 17 αφορούσαν μοντέλα μηχανικής μάθησης (SVM, RF, DT, KNN, BPNN), ενώ οι 16 αφορούσαν μοντέλα βαθιάς μάθησης (VGG, ResNet, CNN, U-Net, SegNet), με την αναλογία αυτή να αντιστοιχεί σε 51,5% για μοντέλα μηχανικής μάθησης και 48,5% για μοντέλα βαθιάς μάθησης.

Η σχεδόν ισομερής συμμετοχή μοντέλων μηχανικής και βαθιάς μάθησης είναι κρίσιμη για την ερμηνεία των επόμενων αποτελεσμάτων, καθώς επιτρέπει μια πιο ισορροπημένη σύγκριση τόσο σε επίπεδο δημοφιλίας, όσο και σε επίπεδο αποτελεσματικότητας. Στη συνέχεια, η ανάλυση εστιάζει στα μοντέλα που εμφανίζονται πιο συχνά και με τις υψηλότερες αποδόσεις, ώστε να εξαχθούν τεκμηριωμένα συμπεράσματα για τις κυρίαρχες τεχνικές στη γεωργία ακριβείας με UAV.

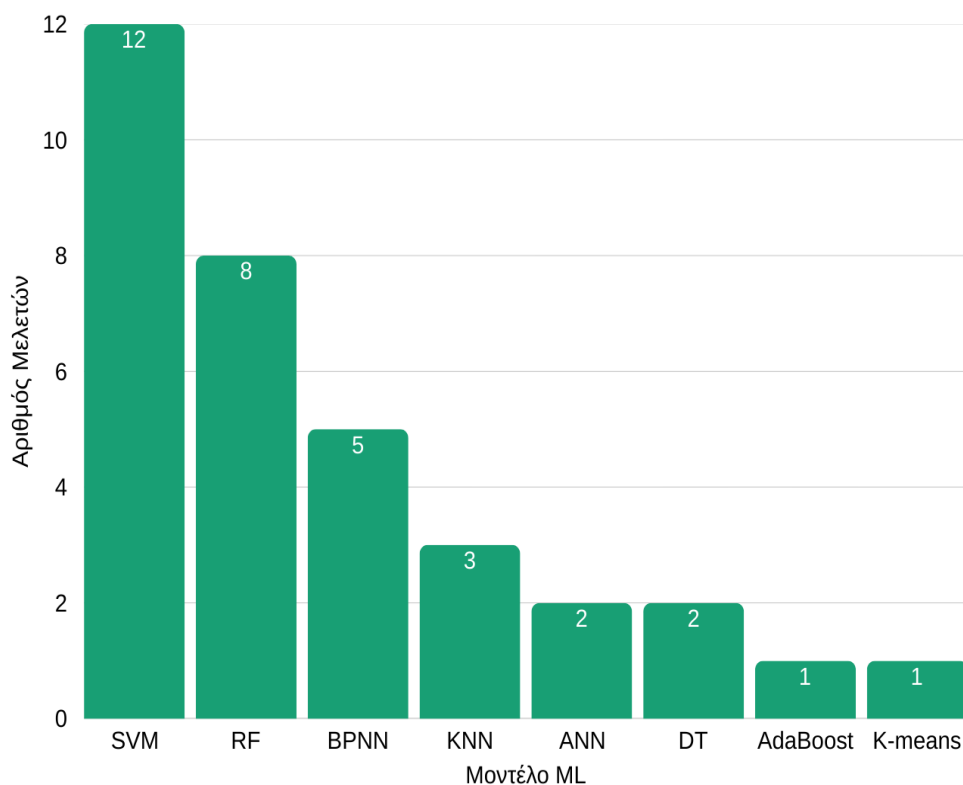


Σχήμα 5.3: Κατανομή των μελετών ως προς τις μεθόδους που χρησιμοποιήθηκαν.

Το τρίτο ερευνητικό ερώτημα απαντάται μέσω της ανάλυσης του σχήματος 5.4, εστιάζει στα μοντέλα μηχανικής μάθησης που εμφανίζονται συχνότερα στις μελέτες του πίνακα 4.2. Η κατανομή δείχνει σαφή κυριαρχία του SVM, ακολουθούμενου από το Random Forest (RF) και τα BPNN, ενώ λιγότερο συχνά συναντώνται τα KNN, ANN και DT. Οι SVM και RF εμφανίζονται κατά πολύ περισσότερο στη βιβλιογραφία, καθώς οι εποπτευόμενες μέθοδοι μηχανικής μάθησης θεωρούνται ιδιαίτερα ελκυστικές σε UAV εφαρμογές λόγω της υψηλής ακρίβειας ταξινόμησης, των μέτρων υπολογιστικών απαιτήσεων και της καλής απόδοσης ακόμη και με περιορισμένα δεδομένα εκπαίδευσης.

Ενδεικτικά, σε μελέτη για κιτρίνισμα φύλλων στην αρέκα, ο συνδυασμός δεικτών βλάστησης (π.χ. NDVI, OSAVI, LCI, GNDVI, NDRE) με χαρακτηριστικά υφής ενίσχυσε τη διακριτική ικανότητα, με το BPNN να αναδεικνύεται ως το πιο αποτελεσματικό μοντέλο με ακρίβεια $A=92\%$. Αντίστοιχα, σε περίπτωση μυκητολογικής προσβολής σε δέντρα καουτσούκ, όπου αξιοποιήθηκαν πολυφασματικά δεδομένα με πλούσια χαρακτηριστικά όπως φασματικές ζώνες και δείκτες βλάστησης, ο SVM καταγράφεται ως κορυφαία επιλογή με υψηλά επίπεδα ακρίβειας $OA=95.88\%$. Επομένως, επιβεβαιώνεται ότι η απόδοση δεν εξαρτάται μόνο από τον αλγόριθμο αλλά και από τα χαρακτηριστικά εισόδου, δηλαδή δείκτες βλάστησης, φασματικές ζώνες κ.α.

Η κυριαρχία του SVM στις μελέτες που εξετάζονται θεωρείται αναμενόμενη, καθώς αποτελεί έναν ώριμο και ευρέως αποδεκτό αλγόριθμο στη βιβλιογραφία της γεωργίας ακριβείας. Η δημοτικότητά του οφείλεται στη σταθερή του απόδοση σε σύνολα δεδομένων περιορισμένου μεγέθους, στη δυνατότητα αποτελεσματικής αξιοποίησης δεικτών βλάστησης ως χαρακτηριστικών εισόδου και στη συγκριτικά καλή γενίκευση που παρουσιάζει σε διαφορετικές καλλιέργειες και συνθήκες.




Σχήμα 5.4: Συχνότητα εμφάνισης των μοντέλων μηχανικής μάθησης στις μελέτες της ανασκόπησης.

Το τέταρτο ερευνητικό ερώτημα απαντάται μέσω της ανάλυσης του σχήματος 5.5, η ανάλυση εστιάζει στα μοντέλα βαθιάς μάθησης που εμφανίζονται συχνότερα στις μελέτες της ανασκόπησης. Η κατανομή δείχνει ως πιο δημοφιλείς επιλογές τα ResNet και U-Net, ακολουθούμενα από μοντέλα τύπου Inception, ενώ χαμηλότερη αλλά σταθερή παρουσία καταγράφουν τα VGG, DenseNet και γενικές CNN αρχιτεκτονικές. Οι υπόλοιπες αρχιτεκτονικές όπως SegNet, DeepLab, R-CNN, PSPNet, MobileNet, EfficientNet, καθώς και ειδικές προσαρμογές όπως CropdocNet και VddNet εμφανίζονται μεμονωμένα, δείχνοντας ότι παρότι υπάρχει κυρίαρχος “πυρήνας” δημοφιλών μοντέλων, παρατηρείται και συνεχής πειραματισμός με πιο εξειδικευμένες λύσεις.

Η κυριαρχία των ResNet και U-Net εξηγείται από το ότι καλύπτουν δύο θεμελιώδεις ανάγκες των UAV εφαρμογών στη γεωργία ακριβείας: αφενός, τα ResNet αξιοποιούνται ευρέως για ταξινόμηση και ισχυρή εξαγωγή χαρακτηριστικών, καθώς η δομή τους διευκολύνει τη σταθερή εκπαίδευση και τη γενίκευση σε πολύπλοκες εικόνες του πεδίου. Αφετέρου, τα U-Net προτιμώνται όταν ο στόχος είναι η τμηματοποίηση, δηλαδή ο ακριβής εντοπισμός της καταπόνησης σε επίπεδο pixel, κάτι που είναι κρίσιμο για χωρική χαρτογράφηση και στοχευμένες παρεμβάσεις. Παράλληλα, η παρουσία μοντέλων όπως DeepLab, PSPNet και SegNet επιβεβαιώνει ότι η βιβλιογραφία δίνει ιδιαίτερο βάρος σε αρχιτεκτονικές τμηματοποίησης, ενώ η μεμονωμένη χρήση μοντέλων όπως MobileNet και EfficientNet υποδηλώνει αυξανόμενο ενδιαφέρον για πιο αποδοτικές υλοποιήσεις, συμβατές με περιορισμούς υπολογιστικού κόστους και ενέργειας.

Συνολικά, επιβεβαιώνεται ότι η επιλογή τεχνικών βαθιάς μάθησης δεν καθορίζεται μόνο από τη δημοφιλία, αλλά κυρίως από τον τύπο του προβλήματος, το είδος των δεδομένων και τις απαιτήσεις των UAV εφαρμογών.



Σχήμα 5.5: Συχνότητα εμφάνισης των μοντέλων βαθιάς μάθησης στις μελέτες της ανασκόπησης.

Το πέμπτο ερευνητικό ερώτημα απαντάται μέσα από τη συνθετική ανάλυση των αποτελεσμάτων της παρούσας ανασκόπησης, η οποία καταδεικνύει ότι η απόδοση των συστημάτων UAV στη γεωργία ακριβείας δεν καθορίζεται αποκλειστικά από τον επιλεγμένο αλγόριθμο, αλλά προκύπτει από τον συνδυασμό αισθητήρων, χαρακτηριστικών εισόδου και μοντέλων ανάλυσης. Σε επίπεδο αισθητήρων, οι πολυφασματικοί κυριαρχούν λόγω της ισορροπίας που προσφέρουν μεταξύ πρακτικότητας και φασματικής πληροφορίας, ενώ οι RGB προσεγγίσεις διατηρούν ισχυρή παρουσία κυρίως όταν αξιοποιούνται σε ροές βαθιάς μάθησης. Αντίστοιχα, η ανάλυση των δεικτών βλάστησης δείχνει ότι οι κλασικοί δείκτες, όπως NDVI και NDRE, παραμένουν δημοφιλείς, λόγω της ευρείας χρήσης τους και επειδή συνδέονται αποτελεσματικά με μοντέλα μηχανικής μάθησης, ενώ παράλληλα η βιβλιογραφία επιβεβαιώνει ότι η απόδοση βελτιώνεται συχνά όταν χρησιμοποιούνται συνδυασμοί δεικτών αντί ενός μόνο δείκτη βλάστησης.

Σε επίπεδο αλγορίθμων, τα μοντέλα μηχανικής μάθησης, με κυρίαρχα τα SVM και RF, αξιοποιούνται συστηματικά λόγω της σταθερής απόδοσης και της αποτελεσματικότητας σε σενάρια με περιορισμένα δεδομένα, και αφετέρου, τα μοντέλα βαθιάς μάθησης, με έμφαση σε ResNet και U-Net, επιλέγονται όταν απαιτείται ισχυρή αναπαράσταση χαρακτηριστικών ή λεπτομερής χαρτογράφηση. Συνεπώς, προκύπτει

ότι η επιτυχία των μεθόδων εξαρτάται σε μεγάλο βαθμό από τη ποιότητα και τη φύση των εισόδων (δείκτες βλάστησης, φασματικές ζώνες, χαρακτηριστικά υψής) και από το αν το μοντέλο ταιριάζει στον τύπο του προβλήματος (ταξινόμηση, τμηματοποίηση).

Οι τεχνολογικές επιλογές στην ανάλυση δεδομένων από UAV στη γεωργία ακριβείας τείνουν να συγκλίνουν σε πολυφασματική αντίληψη με δείκτες βλάστησης και μοντέλα μηχανικής μάθησης, αλλά και σε RGB και πολυφασματικά δεδομένα με μοντέλα βαθιάς μάθησης, ανάλογα με τις απαιτήσεις ακριβείας και λεπτομέρειας. Μέσα από τη συγκριτική ανάλυση της πρόσφατης βιβλιογραφίας, χαρτογραφήθηκαν οι κυριότερες προσεγγίσεις που αφορούν τις ροές αντίληψης, τους αισθητήρες, τους δείκτες βλάστησης και τα μοντέλα μηχανικής και βαθιάς μάθησης στη γεωργία ακριβείας με UAV και σμήνη UAV. Η διαδικασία αυτή επέτρεψε την εξαγωγή συνολικών συμπερασμάτων για τις επικρατούσες τεχνολογικές τάσεις, καθώς και τον εντοπισμό περιορισμών και ερευνητικών κενών που μπορούν να καθοδηγήσουν μελλοντικές ερευνητικές και εφαρμοσμένες προσπάθειες.

Κεφάλαιο 6ο: Προκλήσεις και ερευνητικά κενά

Η υιοθέτηση UAVs στη γεωργία ακριβείας έχει επιταχυνθεί λόγω της δυνατότητας συλλογής δεδομένων υψηλής ανάλυσης και της ενσωμάτωσής τους σε μοντέλα μηχανικής και βαθιάς μάθησης για την έγκαιρη διάγνωση καταπόνησης και ασθενειών. Παρ' όλα αυτά, η βιβλιογραφία αναδεικνύει σταθερά ένα σύνολο τεχνικών και επιχειρησιακών περιορισμών, ειδικά όταν η εφαρμογή κλιμακώνεται από ένα UAV σε συστήματα πολλαπλών UAVs.

Το υψηλό αρχικό κόστος παραμένει πρωτεύων παράγοντας, κυρίως για μικρές και μεσαίες καλλιέργειες, όπου η αγορά UAV, αισθητήρων και λογισμικού επεξεργασίας συχνά δεν είναι οικονομικά εφικτή [76]. Η δυσκολία εντείνεται όταν απαιτούνται αισθητήρες υψηλού κόστους όπως πολυφασματικοί, θερμικοί, LiDAR καθώς αυξάνουν τόσο την αρχική δαπάνη όσο και το συνολικό κόστος της συντήρησης. Επιπλέον, η ανάλυση μεγάλων συνόλων από δεδομένα επιβάλλει υποδομές υψηλών υπολογιστικών απαιτήσεων, αυξάνοντας έτσι το λειτουργικό κόστος. Παρότι προτείνονται λύσεις όπως επιδοτήσεις και δάνεια, λείπουν καθολικά αποδεκτά μοντέλα κόστους-οφέλους που να αποδεικνύουν, πότε και πώς θα γίνεται η απόσβεση της επένδυσης. Στα σμήνη, το πρόβλημα κλιμακώνεται γραμμικά, επειδή πολλαπλασιάζονται ο αριθμός των UAVs, έχοντας ως αποτέλεσμα την σημαντική αύξηση του κόστους συντήρησης.

Η αυτονομία αποτελεί κύριο περιορισμό των UAVs, δημιουργώντας διακοπές της αποστολής σε μεγάλα χωράφια με συχνές στάσεις για αλλαγή των μπαταριών, άρα απώλεια συνέχειας στη συλλογή δεδομένων [77]. Το πρόβλημα επιδεινώνεται όταν το UAV κουβαλάει μεγάλο όγκο αισθητήρων, μειώνοντας περαιτέρω τον χρόνο πτήσης. Οι προτάσεις για ενεργειακά αποδοτικότερα UAV, υβριδικές λύσεις ή ηλιακή υποβοήθηση είναι σημαντικές, όμως απαιτείται ώριμη τεκμηρίωση για την αξιοπιστία τους σε πραγματικές γεωργικές συνθήκες και κυρίως στα σμήνη, όπου το ενεργειακό ζήτημα μετατρέπεται σε πρόβλημα συντονισμού στόλου, διότι η ενέργεια θα πρέπει να κατανέμεται ισόποσα σε όλα τα UAVs του σμήνους.

Η λειτουργία των UAVs και η ερμηνεία των δεδομένων συχνά απαιτούν δεξιότητες που δεν είναι δεδομένες για όλους τους αγρότες ή γεωπόνους [78]. Επιπλέον, η ενσωμάτωση σύνθετων αισθητήρων

πολυφασματικών ή θερμικών απαιτεί βαθμονόμηση, διορθώσεις και προεπεξεργασία, αυξάνοντας το τεχνικό φορτίο. Παρότι αναφέρονται διεπαφές φιλικές προς τον χρήστη και αυτοματοποιήσεις τεχνητής νοημοσύνης, παραμένει ανοιχτό το πώς επιτυγχάνεται αξιοπιστία από τη συλλογή μέχρι την εξαγωγή και τη σωστή ερμηνεία τους, χωρίς εξάρτηση από συμβούλους ή παρόχους υπηρεσιών. Για τα σμήνη, το κενό είναι μεγαλύτερο, η επιχειρησιακή πολυπλοκότητα όπως ο συντονισμός, οι επικοινωνίες απαιτούν νέα εργαλεία που μπορούν όχι μόνο να κρύβουν την πολυπλοκότητα αλλά και να διατηρούν διαφάνεια και ασφάλεια.

Παρότι τα UAV μπορούν να μειώσουν την σπατάλη λιπασμάτων και εντομοκτόνων με στοχευμένες παρεμβάσεις, οι ίδιες οι λειτουργίες τους όπως η διαχείριση μπαταριών λιθίου, ο θόρυβος, οι πιθανές ενοχλήσεις σε άγρια ζώα και οικοσυστήματα έχουν περιβαλλοντικό αποτύπωμα [79]. Σε απομακρυσμένες περιοχές, η ανάγκη για υποδομές όπως γεννήτριες ή αναμεταδότες σήματος μπορεί να επιβαρύνει επιπλέον το περιβάλλον. Υπάρχουν προτάσεις για πιο βιώσιμες τεχνολογίες ενέργειας και σχεδιασμούς φιλικούς προς το περιβάλλον, όμως λείπουν συγκρίσιμες μετρήσεις του κύκλου ζωής τους. Με βάση τους τεχνολογικούς, επιχειρησιακούς και κανονιστικούς περιορισμούς σχετικά με τη χρήση UAV στη γεωργία ακριβείας, διατυπώνονται ορισμένα ερωτήματα συζήτησης (ΕΣ) που αναδεικνύουν ανοιχτά ζητήματα και μελλοντικές προκλήσεις του πεδίου.

ΕΣ1: Πώς μπορεί να σχεδιαστεί ένα οικονομικά βιώσιμο σμήνος από UAVs (πλατφόρμες, αισθητήρες, υπολογισμός) με βελτιστοποίηση κόστους-απόδοσης, έτσι ώστε η συνεργατική ροή να παραμένει αξιόπιστη χωρίς ακριβούς αισθητήρες και βαριά cloud υποδομή;

ΕΣ2: Ποιες αποκεντρωμένες στρατηγικές ελέγχου και κατανομής αποστολών επιτρέπουν σε σμήνη να διατηρούν συνεχή κάλυψη μεγάλων αγροτεμαχίων παρά τους περιορισμούς αυτονομίας και το αυξημένο ενεργειακό κόστος από αισθητήρες;

ΕΣ3: Πώς μπορεί η συνεργατική αντίληψη να γίνεται με ελάχιστη καθυστέρηση και χωρίς διακοπές συλλογής-μετάδοσης, όταν τα UAV χρειάζονται συχνές προσγειώσεις ή λειτουργούν σε περιοχές με περιορισμένη συνδεσιμότητα;

ΕΣ4: Πώς μπορούν να σχεδιαστούν αυτοματοποιημένες, φιλικές προς τον χρήστη ροές όπως αυτόματη προεπεξεργασία και ανάλυση που να μειώνουν την ανάγκη τεχνικής εξειδίκευσης, ενώ ταυτόχρονα να παρέχουν επεξηγήσιμες αποφάσεις για εμπιστοσύνη και λήψη δράσης από μη ειδικούς;

ΕΣ5: Πώς μπορεί ο αποκεντρωμένος έλεγχος και ο σχεδιασμός διαδρομών σε σμήνη UAV να ενσωματώνει εξαρχής κανονιστικούς περιορισμούς όπως ύψος, περιοχές, ιδιωτικότητα ώστε να μεγιστοποιείται η αποτελεσματικότητα αποστολής χωρίς παραβιάσεις και χωρίς να μειώνεται υπερβολικά η ευελιξία πτήσης;

ΕΣ6: Ποια μεθοδολογία μπορεί να μειώσει το συνολικό περιβαλλοντικό αποτύπωμα της χρήσης σμηνών όπως κύκλος ζωής μπαταριών, θόρυβος, διατάραξη άγριας ζωής, πρόσθετες υποδομές και πώς αυτό επηρεάζει τον σχεδιασμό πολιτικών ελέγχου και επιχειρησιακών πρωτοκόλλων;

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] Escatec, “7 ways agricultural drones are supporting precision farming.” επίσκεψη 10 Δεκ. 2025. διεύθυν.: <https://www.escatec.com/blog/how-agricultural-drones-are-supporting-precision-farming>.
- [2] Measur, “Rgb cameras.” επίσκεψη 10 Δεκ. 2025. διεύθυν.: <https://measur.ca/collections/rgb-cameras-for-drones/products/phase-one-p3>.
- [3] GkostySky, “Ms hs cameras.” επίσκεψη 10 Δεκ. 2025. διεύθυν.: <https://www.ghostsky.com/product/aq600-pro-5-bands-multispectral-camera/>.
- [4] UAVcoach, “Thermal camera.” επίσκεψη 10 Δεκ. 2025. διεύθυν.: <https://uavcoach.com/thermal-camera-drone/>.
- [5] boom, “Lidar camera.” επίσκεψη 10 Δεκ. 2025. διεύθυν.: <https://www.xboom.in/shop/drone-shop-by-price/above-2-lakh/zenmuse-l1-a-lidarrgb-solution/?srsltid=AfmBOopehseoYpVi7oUa1CRgd-rn1W9F-p688eV5b1SMuoGXQnavgg>.
- [6] ust, “Sar camera.” επίσκεψη 10 Δεκ. 2025. διεύθυν.: <https://www.unmannedsystemstechnology.com/company/trakka-systems/trakkabeam-tlxc/>.
- [7] Esri, “Exploring digital elevation models.” επίσκεψη 15 Δεκ. 2025. διεύθυν.: <https://desktop.arcgis.com/en/arcmap/latest/tools/spatial-analyst-toolbox/exploring-digital-elevation-models.htm>.
- [8] GeoAwesome, “Understanding aerial data: Normalized difference vegetation index (ndvi).” επίσκεψη 20 Δεκ. 2025. διεύθυν.: <https://geoawesome.com/eo-hub/understanding-aerial-data-normalizeddifference-vegetation-index-ndvi/>.
- [9] pix4f, “Sar camera.” επίσκεψη 10 Δεκ. 2025. διεύθυν.: <https://www.pix4d.com/blog/pix4dfields-vegetation-indices-for-precision-agriculture/>.
- [10] greyb, “Sar camera.” επίσκεψη 10 Δεκ. 2025. διεύθυν.: <https://greyb.com/blog/precision-agriculture-drones/>.
- [11] A. Vera-Esmeraldas, S. Pizarro-Oteíza, M. Labbé, F. Rojo, and F. Salazar, “Uav-based spectral and thermal indices in precision viticulture: A review of ndvi, ndre, savi, gndvi, and cwsj,” *Agronomy*, vol. 15, no. 11, 2025.
- [12] R. Guebsi, S. Mami, and K. Chokmani, “Drones in precision agriculture: A comprehensive review of applications, technologies, and challenges,” *Drones*, vol. 8, no. 11, 2024.
- [13] S. Candiago, F. Remondino, M. De Giglio, M. Dubbini, and M. Gattelli, “Evaluating multispectral images and vegetation indices for precision farming applications from uav images,” *Remote Sensing*, vol. 7, no. 4, pp. 4026–4047, 2015.
- [14] C. Lytridis, V. G. Kaburlasos, T. Pachidis, M. Manios, E. Vrochidou, T. Kalampokas, and S. Chatzistamatis, “An overview of cooperative robotics in agriculture,” *Agronomy*, vol. 11, no. 9, 2021.

- [15] M. Raj, H. N B, S. Gupta, M. Atiquzzaman, O. Rawlley, and L. Goel, “Leveraging precision agriculture techniques using uavs and emerging disruptive technologies,” *Energy Nexus*, vol. 14, p. 100300, 2024.
- [16] Y. Song, Z. Ma, N. Chen, S. Zhou, and S. Srigrarom, “Comparative analysis of centralized and distributed multi-uav task allocation algorithms: A unified evaluation framework,” *Drones*, vol. 9, no. 8, 2025.
- [17] UNC University Libraries, “Creating a prisma flow diagram: Prisma 2020.” επίσκεψη 10 Δεκ. 2025. διεύθυν.: <https://guides.lib.unc.edu/prismas-lg-box-28341586>.
- [18] M. Yang, X. Guan, M. Shi, B. Li, C. Wei, and K.-F. C. Yiu, “Distributed model predictive formation control for uavs and cooperative capability evaluation of swarm,” *Drones*, vol. 9, no. 5, 2025.
- [19] H. Zhu and S. Wu, “Leader–follower formation reconfiguration control for fixed-wing uavs using multiplayer stackelberg–nash game,” *Drones*, vol. 9, no. 6, 2025.
- [20] W. Suo, M. Wang, D. Zhang, Z. Qu, and L. Yu, “Formation control technology of fixed-wing uav swarm based on distributed ad hoc network,” *Applied Sciences*, vol. 12, no. 2, 2022.
- [21] O. Khatib, “Real-time obstacle avoidance for manipulators and mobile robots,” *The International Journal of Robotics Research*, vol. 5, no. 1, pp. 90–98, 1986.
- [22] X. Chang, Y. Yang, Z. Zhang, J. Jiao, H. Cheng, and W. Fu, “Consensus-based formation control for heterogeneous multi-agent systems in complex environments,” *Drones*, vol. 9, no. 3, 2025.
- [23] T. Balch and R. Arkin, “Behavior-based formation control for multirobot teams,” *IEEE Transactions on Robotics and Automation*, vol. 14, no. 6, pp. 926–939, 1998.
- [24] S. I. Jiménez-Jiménez, W. Ojeda-Bustamante, M. d. J. Marcial-Pablo, and J. Enciso, “Digital terrain models generated with low-cost uav photogrammetry: Methodology and accuracy,” *ISPRS International Journal of Geo-Information*, vol. 10, no. 5, 2021.
- [25] H. Shakhathreh, A. H. Sawalmeh, A. Al-Fuqaha, Z. Dou, E. Almaita, I. Khalil, N. S. Othman, A. Khreishah, and M. Guizani, “Unmanned aerial vehicles (uavs): A survey on civil applications and key research challenges,” *IEEE Access*, vol. 7, pp. 48572–48634, 2019.
- [26] Y. Zhu, X. Yao, Y. Tian, X. Liu, and W. Cao, “Analysis of common canopy vegetation indices for indicating leaf nitrogen accumulations in wheat and rice,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 10, no. 1, pp. 1–10, 2008.
- [27] G. Kauth, R.J.; Thomas, “The tasselled cap—a graphic description of the spectral-temporal development of agricultural crops as seen by landsat.” *In Proceedings of the LARS Symposia, West Lafayette, IN, USA*, p. 159, 1976.
- [28] X. Cao, Y. Luo, Y. Zhou, J. Fan, X. Xu, J. S. West, X. Duan, and D. Cheng, “Detection of powdery mildew in two winter wheat plant densities and prediction of grain yield using canopy hyperspectral reflectance,” *PLOS ONE*, vol. 10, pp. 1–14, 03 2015.
- [29] W. Fu, Z. Chen, Q. Cheng, Y. Li, W. Zhai, F. Ding, X. Kuang, D. Chen, and F. Duan, “Maize leaf area index estimation based on machine learning algorithm and computer vision,” *Agriculture*, vol. 15, no. 12, 2025.

- [30] J. Su, X. Zhu, S. Li, and W.-H. Chen, “Ai meets uavs: A survey on ai empowered uav perception systems for precision agriculture,” *Neurocomputing*, vol. 518, pp. 242–270, 2023.
- [31] J. Zhang, W. Huang, L. Yuan, H. Ma, Y. Dong, J. Wang, and P. Chen, “In-field detection of yellow rust in wheat on the ground canopy and uav scale,” *Remote Sensing*, vol. 12, no. 10, p. 1590, 2020.
- [32] J. Zhang, W. Huang, X. Zhang, H. Ma, H. Li, L. Yang, and Y. Dong, “Monitoring the severity of rubber tree infected with powdery mildew based on uav multispectral remote sensing,” *Remote Sensing*, vol. 12, no. 6, p. 937, 2020.
- [33] K. Liao, F. Yang, H. Dang, Y. Wu, K. Luo, and G. Li, “Detection of eucalyptus leaf disease with uav multispectral imagery,” *Forests*, vol. 13, no. 8, p. 1322, 2022.
- [34] J. Zhang, W. Huang, X. Zhang, H. Ma, H. Li, L. Yang, and Y. Dong, “Recognition of rubber tree powdery mildew based on uav remote sensing with different spatial resolutions,” *Remote Sensing*, vol. 14, no. 2, p. 365, 2022.
- [35] D. Zhao, Y. Cao, J. Li, Q. Cao, J. Li, F. Guo, S. Feng, and T. Xu, “Early detection of rice leaf blast disease using unmanned aerial vehicle remote sensing: A novel approach integrating a new spectral vegetation index and machine learning,” *Agronomy*, vol. 14, no. 3, p. 602, 2024.
- [36] P. Ahmadi, S. Mansor, B. Farjad, and E. Ghaderpour, “Unmanned aerial vehicle (uav)-based remote sensing for early-stage detection of ganoderma,” *Remote Sensing*, vol. 14, no. 5, p. 1239, 2022.
- [37] L. Schmarje, M. Santarossa, S.-M. Schröder, and R. Koch, “A survey on semi-, self- and unsupervised learning for image classification,” *IEEE Access*, vol. 9, pp. 82146–82168, 2021.
- [38] T. Wang, J. A. Thomasson, C. Yang, T. Isakeit, and R. L. Nichols, “Automatic classification of cotton root rot disease based on uav remote sensing,” *Remote Sensing*, vol. 12, no. 8, p. 1310, 2020.
- [39] T. Wang, J. A. Thomasson, C. Yang, T. Isakeit, and R. L. Nichols, “Automatic classification of cotton root rot disease based on uav remote sensing,” *Remote Sensing*, vol. 12, no. 8, 2020.
- [40] I. Zualkernan, D. A. Abuhani, M. H. Hussain, J. Khan, and M. ElMohandes, “Machine learning for precision agriculture using imagery from unmanned aerial vehicles (uavs): A survey,” *Drones*, vol. 7, no. 6, 2023.
- [41] A. Maresma, M. Ariza-Sentís, J. Lloveras, and J. A. Martínez-Casasnovas, “Geodls: A deep learning-based corn disease tracking and location system using rtk geolocated uas imagery,” *Sensors*, vol. 20, no. 9, p. 2497, 2020.
- [42] X. Zhang, L. Han, Y. Dong, Y. Shi, W. Huang, L. Han, P. González-Moreno, H. Ma, H. Ye, and T. Sobeih, “A deep learning-based approach for automated yellow rust disease detection from high-resolution hyperspectral uav images,” *Remote Sensing*, vol. 11, no. 13, p. 1554, 2019.
- [43] J. Gao, K. Gujarati, M. Hegde, P. Arra, S. Gupta, and N. Buch, “Integration of uav and remote sensing data for early diagnosis and severity mapping of diseases in maize crop through deep learning and reinforcement learning,” *Remote Sensing*, vol. 17, p. 3427, 2025.

- [44] P. Dong, M. Wang, K. Li, H. Qiao, Y. Zhao, F. Bacao, L. Shi, W. Guo, and H. Si, "Research on the identification of wheat fusarium head blight based on multispectral remote sensing from uavs," *Drones*, vol. 8, no. 9, p. 445, 2024.
- [45] M.-G. Lee, H.-B. Cho, S.-K. Youm, and S.-W. Kim, "Detection of pine wilt disease using time series uav imagery and deep learning semantic segmentation," *Forests*, vol. 14, no. 8, p. 1576, 2023.
- [46] Q. Pan, M. Gao, P. Wu, J. Yan, and S. Li, "A deep-learning-based approach for wheat yellow rust disease recognition from unmanned aerial vehicle images," *Sensors*, vol. 21, no. 19, p. 6540, 2021.
- [47] Y. Li, G. Chai, Y. Wang, L. Lei, and X. Zhang, "Ace r-cnn: An attention complementary and edge detection-based instance segmentation algorithm for individual tree species identification using uav rgb images and lidar data," *Remote Sensing*, vol. 14, no. 13, 2022.
- [48] Y. Han, X. Wang, L. Niu, S. Shi, Y. Gao, K. Gong, X. Zhang, and J. Zheng, "Otb-yolo: An enhanced lightweight yolo architecture for uav-based maize tassel detection," *Plants*, vol. 14, no. 17, 2025.
- [49] A. Chang, J. Yeom, J. Jung, and J. Landivar, "Comparison of canopy shape and vegetation indices of citrus trees derived from uav multispectral images for characterization of citrus greening disease," *Remote Sensing*, vol. 12, no. 24, p. 4122, 2020.
- [50] R. Heidarian Dehkordi, M. El Jarroudi, L. Kouadio, J. Meersmans, and M. Beyer, "Monitoring wheat leaf rust and stripe rust in winter wheat using high-resolution uav-based red-green-blue imagery," *Remote Sensing*, vol. 12, no. 22, p. 3696, 2020.
- [51] W. Huang, J. Zhang, Y. Dong, H. Ma, L. Yuan, P. Chen, and J. Wang, "Wheat yellow rust detection using uav-based hyperspectral technology," *Remote Sensing*, vol. 9, no. 8, p. 815, 2017.
- [52] W. Zhu, Z. Feng, S. Dai, P. Zhang, and X. Wei, "Using uav multispectral remote sensing with appropriate spatial resolution and machine learning to monitor wheat scab," *Agriculture*, vol. 12, no. 11, p. 1785, 2022.
- [53] X. Li, Z. Liang, G. Yang, T. Lin, and B. Liu, "Assessing the severity of verticillium wilt in cotton fields and constructing pesticide application prescription maps using unmanned aerial vehicle (uav) multispectral images," *Drones*, vol. 8, no. 5, p. 176, 2024.
- [54] A. Patrick, S. Pelham, A. Culbreath, C. C. Holbrook, I. J. de Godoy, and C. Li, "High throughput phenotyping of tomato spot wilt disease in peanuts using unmanned aerial systems and multispectral imaging," *IEEE Instrumentation & Measurement Magazine*, vol. 20, no. 3, pp. 4–12, 2017.
- [55] H. Ye, W. Huang, S. Huang, B. Cui, Y. Dong, A. Guo, Y. Ren, and Y. Jin, "Recognition of banana fusarium wilt based on uav remote sensing," *Remote Sensing*, vol. 12, no. 6, p. 938, 2020.
- [56] E. Casas, M. Arbelo, J. A. Moreno-Ruiz, P. A. Hernández-Leal, and J. A. Reyes-Carlos, "Uav-based disease detection in palm groves of *Phoenix canariensis* using machine learning and multispectral imagery," *Remote Sensing*, vol. 15, no. 14, p. 3584, 2023.
- [57] C. I. Fernández, B. Leblon, A. Haddadi, K. Wang, and J. Wang, "Potato late blight detection at the leaf and canopy levels based in the red and red-edge spectral regions," *Remote Sensing*, vol. 12, no. 8, p. 1292, 2020.

- [58] Y. Chen, W. Huang, X. Zhang, H. Ma, H. Li, and Y. Dong, "Remote sensing detecting of yellow leaf disease of arecanut based on uav multisource sensors," *Remote Sensing*, vol. 12, no. 22, p. 3727, 2020.
- [59] T. Zeng, H. Zhang, Y. Li, C. Yin, Q. Liang, J. Fang, W. Fu, J. Wang, and X. Zhang, "Monitoring the severity of rubber tree infected with powdery mildew based on uav multispectral remote sensing," *Forests*, vol. 14, no. 4, p. 717, 2023.
- [60] T. W. F. Xavier, R. N. V. Souto, T. Statella, R. Galbieri, E. S. Santos, G. S. Suli, and P. Zeilhofer, "Identification of ramularia leaf blight cotton disease infection levels by multispectral, multiscale uav imagery," *Drones*, vol. 3, no. 2, p. 33, 2019.
- [61] M. Zhang, W. Li, Q. Wang, W. Huang, Y. Dong, and H. Ma, "Banana fusarium wilt disease detection by supervised and unsupervised methods from uav-based multispectral imagery," *Remote Sensing*, vol. 11, no. 11, p. 1321, 2019.
- [62] L. Liu, Y. Dong, W. Huang, X. Du, and H. Ma, "Monitoring wheat fusarium head blight using unmanned aerial vehicle hyperspectral imagery," *Remote Sensing*, vol. 12, no. 22, p. 3811, 2020.
- [63] J. Zhang, W. Huang, H. Ma, Y. Dong, L. Yuan, J. Wang, P. Chen, and D. Zhang, "Using uav-based hyperspectral imagery to detect winter wheat fusarium head blight," *Remote Sensing*, vol. 10, no. 3, p. 431, 2018.
- [64] W. Zhu, Z. Feng, S. Dai, P. Zhang, and X. Wei, "Using uav multispectral remote sensing with appropriate spatial resolution and machine learning to monitor wheat scab," *Agriculture*, vol. 12, no. 11, p. 1785, 2022.
- [65] S. Sankaran, A. Mishra, J. M. Maja, and R. Ehsani, "Detection of white leaf disease in sugarcane using machine learning techniques over uav multispectral images," *Remote Sensing*, vol. 12, no. 2, p. 353, 2020.
- [66] H. Huang, J. Deng, Y. Lan, A. Yang, L. Zhang, S. Wen, H. Zhang, Y. Zhang, and Y. Deng, "Detection of helminthosporium leaf blotch disease based on uav imagery," *Applied Sciences*, vol. 9, no. 3, p. 558, 2019.
- [67] D.-H. Kim, S. Lee, J.-W. Park, Y.-J. Choi, and H.-S. Kim, "Unmanned aerial vehicle-based rgb imaging and lightweight deep learning for downy mildew detection in kimchi cabbage," *Sensors*, vol. 23, no. 6, p. 3187, 2023.
- [68] Q. Zhang, W. Wang, H. Su, G. Yang, J. Xue, H. Hou, X. Geng, Q. Cao, and Z. Xu, "Plcnet: A 3d-cnn-based plant-level classification network hyperspectral framework for sweetpotato virus disease detection," *Remote Sensing*, vol. 17, no. 16, p. 2882, 2025.
- [69] M. Li, Y. Guo, W. Guo, H. Qiao, L. Shi, Y. Liu, G. Zheng, H. Zhang, and Q. Wang, "Wheat powdery mildew severity classification based on an improved resnet34 model," *Agriculture*, vol. 15, no. 15, p. 1580, 2025.
- [70] R. Yu, Y. Luo, H. Li, L. Yang, H. Huang, L. Yu, and L. Ren, "Three-dimensional convolutional neural network model for early detection of pine wilt disease using uav-based hyperspectral images," *Remote Sensing*, vol. 13, no. 20, p. 4065, 2021.

- [71] J. Shen, Q. Xu, M. Gao, J. Ning, X. Jiang, and M. Gao, "Aerial image segmentation of nematode-affected pine trees with u-net convolutional neural network," *Applied Sciences*, vol. 14, no. 12, p. 5087, 2024.
- [72] J. Zhang, X. Zhang, Y. Sun, L. Wang, M. Li, and W. Huang, "Intelligent identification of pine wilt disease infected individual trees using uav-based hyperspectral imagery," *Remote Sensing*, vol. 12, no. 8, p. 1291, 2020.
- [73] T. Zhang, Z. Xu, J. Su, Z. Yang, C. Liu, W.-H. Chen, and J. Li, "Ir-unet: Irregular segmentation u-shape network for wheat yellow rust detection by uav multispectral imagery," *Remote Sensing*, vol. 13, no. 19, p. 3892, 2021.
- [74] M. Kerkech, A. Hafiane, and R. Canals, "Novel cropdocnet model for automated potato late blight disease detection from unmanned aerial vehicle-based hyperspectral imagery," *Remote Sensing*, vol. 13, no. 4, p. 709, 2021.
- [75] M. Kerkech, A. Hafiane, and R. Canals, "Vddnet: Vine disease detection network based on multispectral images and depth map," *Remote Sensing*, vol. 12, no. 20, p. 3305, 2020.
- [76] M. Abdelghani, A. Belabed, and H. Boudjella, "A review on uav-based applications for plant disease detection and monitoring," *Drones*, vol. 5, no. 4, p. 113, 2021.
- [77] A. L. P. De Ocampo and F. J. P. Montalbo, "A multi-vision monitoring framework for simultaneous real-time unmanned aerial monitoring of farmer activity and crop health," *Smart Agricultural Technology*, vol. 8, p. 100466, 2024.
- [78] H. Puppala, P. R. Peddinti, J. P. Tamvada, J. Ahuja, and B. Kim, "Barriers to the adoption of new technologies in rural areas: The case of unmanned aerial vehicles for precision agriculture in india," *Technology in Society*, vol. 74, p. 102335, 2023.
- [79] C. Song, Z. Zhou, Y. Zang, L. Zhao, W. Yang, X. Luo, R. Jiang, R. Ming, Y. Zang, L. Zi, and Q. Zhu, "Variable-rate control system for uav-based granular fertilizer spreader," *Computers and Electronics in Agriculture*, vol. 180, p. 105832, 2021.