

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ
ΚΑΙ ΗΛΕΚΤΡΟΝΙΚΩΝ ΣΥΣΤΗΜΑΤΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

«Ανίχνευση Ασθενειών Καλλιεργείων με
Πολυφασματικά Δεδομένα Sentinel-2 και Τεχνικές
Βαθιάς Μάθησης»



Του φοιτητή ΚΑΖΑΚΗΣ ΠΑΝΑΓΙΩΤΗΣ Αρ. Μητρώου: 11/2024	Επιβλέπων ΔΙΑΜΑΝΤΑΡΑΣ ΚΩΝΣΤΑΝΤΙΝΟΣ ΚΑΘΗΓΗΤΗΣ
---	---

Ημερομηνία

Τίτλος Δ.Ε. Ανίχνευση Ασθενειών Καλλιιεργειών με Πολυφασματικά Δεδομένα Sentinel-2 και
Τεχνικές Βαθιάς Μάθησης

Κωδικός Δ.Ε. ...

Ονοματεπώνυμο φοιτητή/τών ΚΑΖΑΚΗΣ ΠΑΝΑΓΙΩΤΗΣ

Ονοματεπώνυμο εισηγητή ΔΙΑΜΑΝΤΑΡΑΣ ΚΩΝΣΤΑΝΤΙΝΟΣ

Ημερομηνία ανάληψης Δ.Ε. ...

Ημερομηνία περάτωσης Δ.Ε. ...

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 διπλωματική εργασία, στο Τμήμα Μηχανικών Πληροφορικής και Ηλεκτρονικών Συστημάτων του ΔΙ.ΠΑ.Ε.

Η παρούσα εργασία αποτελεί πνευματική ιδιοκτησία του φοιτητή ΚΑΖΑΚΗ ΠΑΝΑΓΙΩΤΗ 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 διπλωματικής 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 παρούσα διπλωματική εργασία εκπονήθηκε στο πλαίσιο του ιδιαίτερου επιστημονικού ενδιαφέροντος που παρουσιάζει η εφαρμογή σύγχρονων μεθόδων τηλεπισκόπησης και τεχνητής νοημοσύνης στη γεωργική παρακολούθηση. Η επιλογή του συγκεκριμένου θέματος βασίστηκε στη διαπίστωση ότι η έγκαιρη και αξιόπιστη ανίχνευση ασθενειών των καλλιεργειών αποτελεί σημαντική πρόκληση για τη βιώσιμη γεωργική παραγωγή, με άμεσες επιπτώσεις στην αποδοτικότητα των καλλιεργειών, στη διαχείριση των γεωργικών εισροών και στην αγροτική οικονομία ευρύτερα.

Η ενασχόληση με το παρόν αντικείμενο παρείχε τη δυνατότητα συστηματικής μελέτης ζητημάτων που αφορούν την επεξεργασία πολυφασματικών δορυφορικών δεδομένων, τις δυνατότητες του δορυφόρου Sentinel-2, καθώς και την αξιοποίηση τεχνικών βαθιάς μάθησης, αυτοεπιβλεπόμενης μάθησης και μεταφοράς μάθησης σε εφαρμογές γεωργίας ακριβείας. Παράλληλα, η εκπόνηση της εργασίας συνέβαλε ουσιαστικά στην εμβάθυνση σε σύγχρονες ερευνητικές προσεγγίσεις, στην κατανόηση της πειραματικής διαδικασίας και στην ανάπτυξη δεξιοτήτων που σχετίζονται με την ανάλυση, την αξιολόγηση και την ερμηνεία σύνθετων δεδομένων.

Περίληψη

Η έγκαιρη ανίχνευση ασθενειών στις καλλιέργειες αποτελεί κρίσιμο ζήτημα για τη βιώσιμη γεωργική παραγωγή, καθώς οι φυτοπαθολογικές προσβολές μπορούν να προκαλέσουν σημαντικές απώλειες στην απόδοση των καλλιεργειών και να επηρεάσουν αρνητικά την αγροτική οικονομία. Τα τελευταία χρόνια, η τηλεπισκόπηση και ειδικότερα τα πολυφασματικά δεδομένα δορυφορικών αισθητήρων έχουν αναδειχθεί σε σημαντικό εργαλείο για την παρακολούθηση της κατάστασης της βλάστησης σε μεγάλη χωρική κλίμακα. Η αξιοποίηση των δεδομένων αυτών, σε συνδυασμό με τεχνικές βαθιάς μάθησης, επιτρέπει την ανάπτυξη αυτοματοποιημένων συστημάτων ανάλυσης γεωργικών εκτάσεων.

Στην παρούσα εργασία προτείνεται και αξιολογείται ένα πολυσταδιακό πλαίσιο βαθιάς μάθησης για την ανίχνευση ασθενειών καλλιεργειών με χρήση πολυφασματικών δεδομένων Sentinel-2. Η μεθοδολογία βασίζεται αρχικά σε αυτοεπιβλεπόμενη προεκπαίδευση ενός πολυφασματικού encoder σε μη επισημασμένα δορυφορικά δεδομένα, με στόχο την εκμάθηση γενικευμένων φασματικών και χωρικών αναπαραστάσεων. Στη συνέχεια, οι αναπαραστάσεις αυτές μεταφέρονται σε ενδιάμεσο στάδιο ταξινόμησης καλλιεργειών και τελικά προσαρμόζονται στο πρόβλημα ταξινόμησης ασθενειών. Η διαδοχική αυτή στρατηγική επιδιώκει να αξιοποιήσει τόσο τη διαθέσιμη μη επισημασμένη πληροφορία όσο και τη γεωργική γνώση που αποκτάται από το ενδιάμεσο crop classification task.

Ιδιαίτερη έμφαση δίνεται στη φασματική αξιολόγηση των δεδομένων εισόδου. Για τον σκοπό αυτό εξετάζονται διαφορετικοί συνδυασμοί ζωνών Sentinel-2, οι οποίοι καλύπτουν το ορατό φάσμα, το εγγύς υπέρυθρο, την περιοχή red-edge και το βραχύ υπέρυθρο. Η αξιολόγηση πραγματοποιείται με επαναλαμβανόμενη διασταυρούμενη επικύρωση, ενώ εφαρμόζονται και στατιστικοί έλεγχοι για την πιο αξιόπιστη σύγκριση των φασματικών σχημάτων. Επιπλέον, εφαρμόζεται ανάλυση ερμηνευσιμότητας μέσω band occlusion στο πλήρες πολυφασματικό μοντέλο, με στόχο την εκτίμηση της συμβολής κάθε φασματικής ζώνης στην τελική ταξινόμηση.

Τα αποτελέσματα δείχνουν ότι το RGB σχήμα εισόδου πέτυχε την υψηλότερη μέση απόδοση, γεγονός που υποδηλώνει ότι οι ορατές ζώνες ευθυγραμμίζονται ισχυρά με τη φύση των διαθέσιμων labels του προβλήματος. Παράλληλα, η ανάλυση band occlusion ανέδειξε ως σημαντικότερες τις ζώνες B8A, B3, B4, B7 και B8. Με βάση τα ευρήματα αυτά σχεδιάστηκε και αξιολογήθηκε ένα πρόσθετο XAI-guided Top-5 φασματικό σχήμα, το οποίο πέτυχε απόδοση συγκρίσιμη με το πλήρες πολυφασματικό σχήμα, χρησιμοποιώντας μόνο τις μισές φασματικές ζώνες. Τα ευρήματα αναδεικνύουν ότι η προσθήκη περισσότερων ζωνών δεν οδηγεί απαραίτητα σε καλύτερη γενίκευση και ότι η στοχευμένη επιλογή φασματικής πληροφορίας μπορεί να είναι εξίσου σημαντική με την αρχιτεκτονική του μοντέλου.

Συνολικά, η εργασία συμβάλλει στην ανάπτυξη και αξιολόγηση μεθόδων βαθιάς μάθησης για την ανίχνευση ασθενειών από δορυφορικά δεδομένα Sentinel-2, ενώ παράλληλα προσφέρει ερμηνευτική ανάλυση της συμβολής των επιμέρους φασματικών ζωνών. Η προτεινόμενη προσέγγιση αναδεικνύει τις δυνατότητες του συνδυασμού τηλεπισκόπησης, αυτοεπιβλεπόμενης μάθησης και XAI για εφαρμογές γεωργίας ακριβείας, επισημαίνοντας ταυτόχρονα την ανάγκη περαιτέρω διερεύνησης σε μεγαλύτερα, πιο ισορροπημένα και ανεξάρτητα σύνολα δεδομένων.

Λέξεις-κλειδιά: τηλεπισκόπηση, Sentinel-2, πολυφασματικά δεδομένα, γεωργία ακριβείας, ανίχνευση ασθενειών, αυτοεπιβλεπόμενη μάθηση, βαθιά μάθηση, φασματική αξιολόγηση, ερμηνευσιμότητα, XAI

Crop Disease Detection Using Sentinel-2 Multispectral Imagery and Deep Learning

Panagiotis Kazakis

Abstract

Early detection of crop diseases is a critical issue for sustainable agricultural production, as phytopathological infestations may cause substantial yield losses and significant economic impacts. In recent years, remote sensing and, in particular, multispectral satellite imagery have emerged as valuable tools for large-scale vegetation monitoring. When combined with deep learning methods, such data can support the development of automated systems for crop health assessment.

This thesis proposes and evaluates a multi-stage deep learning framework for crop disease detection using Sentinel-2 multispectral imagery. The methodology begins with self-supervised pretraining of a multispectral encoder on unlabeled satellite data, aiming to learn generalized spectral and spatial representations. The learned encoder is subsequently transferred to an intermediate crop classification task and finally fine-tuned for crop disease classification. This progressive learning strategy aims to exploit both the abundance of unlabeled remote sensing data and the agricultural domain knowledge introduced through crop classification.

A central focus of this work is the spectral evaluation of Sentinel-2 input bands. Several spectral band combinations are examined, covering visible, near-infrared, red-edge and shortwave infrared regions. The experimental evaluation is based on repeated cross-validation and statistical testing, in order to provide a more robust comparison of the examined spectral configurations. In addition, an explainability analysis based on band occlusion is applied to the full multispectral model, aiming to quantify the contribution of each Sentinel-2 band to the final classification performance.

The results show that the RGB input configuration achieved the highest mean performance, suggesting that the visible bands are strongly aligned with the available disease labels. At the same time, the band occlusion analysis identified B8A, B3, B4, B7 and B8 as the most influential bands within the full multispectral model. Based on these findings, an additional XAI-guided Top-5 spectral subset was designed and evaluated. This subset achieved performance comparable to the full multispectral configuration while using only half of the available input bands. These findings indicate that adding more spectral bands does not necessarily improve generalization and that targeted spectral band selection can be as important as model design.

Overall, this thesis contributes to the development and evaluation of deep learning methods for crop disease detection from Sentinel-2 imagery, while also providing an interpretability-driven analysis of spectral band contribution. The proposed framework highlights the potential of combining remote

sensing, self-supervised learning and explainable AI for precision agriculture applications, while underlining the need for further validation on larger, more balanced and independent datasets.

Keywords: remote sensing, Sentinel-2, multispectral data, precision agriculture, crop disease detection, self-supervised learning, deep learning, spectral evaluation, explainable AI, band occlusion.

Περιεχόμενα

Πρόλογος.....	ii
Περίληψη.....	iii
Abstract.....	iv
Περιεχόμενα.....	vi
Κατάλογος Σχημάτων.....	xi
Κατάλογος Πινάκων.....	xii
Κεφάλαιο 1ο: ΕΙΣΑΓΩΓΗ.....	1
1.1 Η σημασία της παρακολούθησης καλλιεργειών.....	1
1.2 Τηλεπισκόπηση και γεωργία ακριβείας.....	1
1.3 Ανίχνευση ασθενειών καλλιεργειών με δορυφορικά δεδομένα.....	2
1.4 Περιορισμοί των υφιστάμενων προσεγγίσεων.....	3
1.5 Διατύπωση του ερευνητικού προβλήματος.....	4
1.6 Στόχοι της εργασίας.....	4
1.7 Ερευνητικές συνεισφορές.....	5
1.8 Δομή της διπλωματικής εργασίας.....	5
Κεφάλαιο 2ο: ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ.....	8
2.1 Εισαγωγή.....	8
2.2 Τηλεπισκόπηση και φασματική συμπεριφορά της βλάστησης.....	8
2.2.1 Φασματική υπογραφή της βλάστησης.....	8
2.2.2 Φασματικές περιοχές ορατού, red-edge, εγγύς υπερύθρου και βραχέος υπερύθρου.....	9
2.2.3 Επίδραση των ασθενειών στη φασματική συμπεριφορά των φυτών.....	10
2.2.4 Φαινολογία καλλιεργειών και χρονική μεταβολή της φασματικής απόκρισης.....	10
2.2.5 Σχέση καλλιέργειας και ασθένειας.....	11
2.3 Παραδοσιακές μέθοδοι ανάλυσης τηλεπισκοπικών δεδομένων.....	11
2.3.1 Δείκτες βλάστησης.....	11
2.3.2 NDVI και συναφείς φασματικοί δείκτες.....	11
2.3.3 Μέθοδοι ανίχνευσης ανωμαλιών.....	12
2.3.4 Περιορισμοί των παραδοσιακών προσεγγίσεων.....	12
2.4 Μηχανική μάθηση στην τηλεπισκόπηση.....	12
2.4.1 Κλασικές μέθοδοι μηχανικής μάθησης.....	12
2.4.2 Βαθιά μάθηση σε δορυφορικές εικόνες.....	13
2.4.3 Συνελικτικά νευρωνικά δίκτυα στην τηλεπισκόπηση.....	13

2.4.4 Μεταφορά μάθησης.....	14
2.4.5 Αυτοεπιβλεπόμενη μάθηση.....	14
2.4.6 Αναπαράσταση πολυφασματικών δεδομένων για μοντέλα βαθιάς μάθησης.....	15
2.4.7 Προκλήσεις των δορυφορικών δεδομένων για εφαρμογές μηχανικής μάθησης.....	15
2.4.8 Ερμηνευσιμότητα μοντέλων βαθιάς μάθησης σε πολυφασματικά δεδομένα.....	15
Κεφάλαιο 3ο: ΤΟ ΠΡΟΓΡΑΜΜΑ COPERNICUS ΚΑΙ Ο ΔΟΡΥΦΟΡΟΣ SENTINEL-2.....	17
3.1 Εισαγωγή.....	17
3.2 Το πρόγραμμα Copernicus.....	17
3.3 Οι αποστολές Sentinel.....	18
3.3.1 Sentinel-1.....	18
3.3.2 Sentinel-2.....	18
3.3.3 Sentinel-3.....	19
3.4 Ο δορυφόρος Sentinel-2.....	19
3.4.1 Τεχνικά χαρακτηριστικά της αποστολής.....	19
3.4.2 Το όργανο MultiSpectral Instrument (MSI).....	19
3.4.3 Φασματικές μπάντες του Sentinel-2.....	20
3.4.4 Χωρική και χρονική ανάλυση.....	20
3.4.5 Επιλεγμένες φασματικές μπάντες στην παρούσα εργασία.....	21
3.5 Εφαρμογές του Sentinel-2 στη γεωργία.....	22
3.5.1 Παρακολούθηση καλλιεργειών.....	22
3.5.2 Ανίχνευση στρες και ασθενειών.....	22
Κεφάλαιο 4ο: ΔΕΔΟΜΕΝΑ.....	23
4.1 Εισαγωγή.....	23
4.2 Περιγραφή των συνόλων δεδομένων.....	23
4.2.1 Σύνολο δεδομένων καλλιεργειών.....	23
4.2.2 Σύνολο δεδομένων ασθενειών.....	24
4.2.3 Ανισορροπία κλάσεων στο σύνολο δεδομένων.....	26
4.2.4 Μη επισημασμένα δεδομένα Sentinel-2.....	26
4.2.5 Φαινολογία καλλιεργειών και χρονική δυναμική της βλάστησης.....	26
4.3 Φασματικές μπάντες που χρησιμοποιούνται.....	27
4.3.1 Μπάντες ορατού φάσματος.....	27
4.3.2 Μπάντες red-edge.....	27
4.3.3 Εγγύς υπέρυθρο.....	28
4.3.4 Βραχύ υπέρυθρο.....	28
4.4 Προεπεξεργασία δεδομένων.....	28

4.4.1 Χωρική επαναδειγματοληψία φασματικών μπαντών.....	28
4.4.2 Έλεγχος καθαρότητας patches και πρόβλημα μικτών εικονοστοιχείων.....	29
4.4.3 Δημιουργία patches.....	29
4.4.4 Κανονικοποίηση δεδομένων.....	30
Κεφάλαιο 5ο: ΜΕΘΟΔΟΛΟΓΙΑ.....	31
5.1 Εισαγωγή.....	31
5.2 Συνολική αρχιτεκτονική του προτεινόμενου συστήματος.....	31
5.3 Αυτοεπιβλεπόμενη μάθηση.....	32
5.3.1 Προεκπαίδευση του encoder.....	33
5.3.2 Αρχιτεκτονική του SSL μοντέλου.....	33
5.3.3 Αντιθετική μάθηση.....	34
5.3.4 Στρατηγική επαυξήσεων δεδομένων.....	35
5.4 Εκπαίδευση μοντέλου ταξινόμησης καλλιέργειας.....	35
5.4.1 Μεταφορά μάθησης από το SSL στάδιο.....	36
5.4.2 Χρονική μοντελοποίηση και temporal mean pooling.....	36
5.4.3 Προσαρμογή στο γεωργικό domain.....	37
5.5 Εκπαίδευση μοντέλου ανίχνευσης ασθενειών.....	37
5.5.1 Λεπτομερής προσαρμογή του encoder.....	37
5.5.2 Αντιμέτωπιση ανισορροπίας κλάσεων.....	38
5.5.3 Συνάρτηση απώλειας και κριτήριο επιλογής μοντέλου.....	38
5.6 Αρχιτεκτονική του τελικού μοντέλου.....	39
5.7 Φασματική αξιολόγηση και XAI-guided επιλογή ζωνών.....	40
5.8 Σύνοψη της προτεινόμενης μεθοδολογίας.....	42
Κεφάλαιο 6ο: ΠΕΙΡΑΜΑΤΙΚΗ ΔΙΑΔΙΚΑΣΙΑ.....	43
6.1 Εισαγωγή.....	43
6.2 Πειραματικό πλαίσιο.....	43
6.2.1 Υπολογιστικό περιβάλλον.....	43
6.2.2 Λογισμικό και βιβλιοθήκες.....	44
6.3 Ρυθμίσεις εκπαίδευσης ανά στάδιο.....	45
6.3.1 Στάδιο αυτοεπιβλεπόμενης προεκπαίδευσης.....	45
6.3.2 Στάδιο ταξινόμησης καλλιέργειας.....	45
6.3.3 Στάδιο ταξινόμησης ασθενειών.....	46
6.3.4 Πειράματα φασματικών συνδυασμών εισόδου.....	46
6.4 Πρωτόκολλο αξιολόγησης.....	48
6.5 Μετρικές αξιολόγησης.....	49

6.5.1 Accuracy.....	49
6.5.2 Precision και Recall.....	49
6.5.3 F1-score.....	50
6.5.4 Macro-F1.....	50
6.5.5 Στατιστική αξιολόγηση φασματικών σχημάτων.....	51
6.6 Πρωτόκολλο ερμηνευσιμότητας μέσω band occlusion.....	52
6.7 Καταγραφή και αποθήκευση αποτελεσμάτων.....	53
6.8 Σύνοψη της πειραματικής διαδικασίας.....	53
Κεφάλαιο 7ο: ΑΠΟΤΕΛΕΣΜΑΤΑ.....	55
7.1 Εισαγωγή.....	55
7.2 Μετρικές αξιολόγησης.....	55
7.3 Αποτελέσματα αυτοεπιβλεπόμενης προεκπαίδευσης.....	56
7.4 Αποτελέσματα ενδιάμεσης εκπαίδευσης ταξινόμησης καλλιέργειας.....	57
7.5 Αποτελέσματα τελικής ανίχνευσης ασθενειών.....	59
7.5.1 Ανάλυση πινάκων σύγχυσης και ανά κλάση συμπεριφοράς.....	61
7.5.2 Συγκριτική αξιολόγηση εναλλακτικών σχημάτων μεταφοράς γνώσης.....	64
7.5.3 Συγκριτική αξιολόγηση διαφορετικών φασματικών συνδυασμών εισόδου.....	67
7.6 Επαναλαμβανόμενη διασταυρούμενη επικύρωση και στατιστική αξιολόγηση.....	69
7.6.1 Κίνητρο και μεθοδολογία.....	69
7.6.2 Αποτελέσματα επαναλαμβανόμενης διασταυρούμενης επικύρωσης.....	70
7.6.3 Έλεγχος Friedman.....	72
7.6.4 Pairwise συγκρίσεις με διόρθωση Holm.....	72
7.7 Ανάλυση σημαντικότητας φασματικών ζωνών μέσω band occlusion.....	73
7.7.1 Συνολική σημαντικότητα φασματικών ζωνών.....	73
7.7.2 Ανάλυση σημαντικότητας φασματικών ζωνών ανά κλάση ασθένειας.....	75
7.8 Αξιολόγηση XAI-guided Top-5 φασματικού σχήματος.....	78
7.9 Ερμηνεία φασματικών αποτελεσμάτων.....	79
Κεφάλαιο 8ο: ΣΥΖΗΤΗΣΗ.....	81
8.1 Εισαγωγή.....	81
8.2 Συνολική αποτίμηση των αποτελεσμάτων.....	81
8.3 Αξιοπιστία της αξιολόγησης και σημασία της επαναλαμβανόμενης διασταυρούμενης επικύρωσης.....	81
8.4 Συμβολή των επιμέρους σταδίων της μεθοδολογίας.....	82
8.5 Ερμηνεία της απόδοσης ανά κλάση.....	82
8.6 Ερμηνεία των φασματικών αποτελεσμάτων.....	83

8.7 Ερμηνευσιμότητα μοντέλου και σημασία της band occlusion analysis.....	83
8.7.1 Ανά κλάση φασματική ευαισθησία.....	84
8.8 Αξιολόγηση του XAI-guided Top-5 σχήματος.....	85
8.9 Πλεονεκτήματα της προτεινόμενης προσέγγισης.....	85
8.10 Σύγκριση με παραδοσιακές και απλούστερες προσεγγίσεις.....	86
8.11 Πρακτική σημασία για τη γεωργία ακριβείας.....	86
8.12 Περιορισμοί της μελέτης.....	87
8.13 Κατευθύνσεις βελτίωσης της μεθοδολογίας.....	87
8.14 Σύνοψη της συζήτησης.....	88
Κεφάλαιο 9ο: ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΜΕΛΛΟΝΤΙΚΗ ΕΡΕΥΝΑ.....	91
9.1 Εισαγωγή.....	91
9.2 Συμπεράσματα.....	91
9.3 Επιστημονική συνεισφορά της εργασίας.....	92
9.4 Περιορισμοί και προσεκτική ερμηνεία των αποτελεσμάτων.....	93
9.5 Προτάσεις για μελλοντική έρευνα.....	94
9.6 Τελική αποτίμηση.....	95
BIBΛΙΟΓΡΑΦΙΑ.....	96
Βιβλία.....	96
Άρθρα σε επιστημονικά περιοδικά.....	96
Εργασίες σε πρακτικά συνεδρίων.....	97
Τεχνικές αναφορές / Handbooks / Product Specifications.....	97
Διαδικτυακές πηγές.....	97
Σύνολα δεδομένων / Πλατφόρμες δεδομένων.....	97
ΠΑΡΑΡΤΗΜΑ Α.....	99

Κατάλογος Σχημάτων

Σχήμα 1.1. Ενδεικτική απεικόνιση της αξιοποίησης δορυφορικών δεδομένων και τεχνικών τεχνητής νοημοσύνης σε εφαρμογές γεωργίας ακριβείας και υποστήριξης λήψης αποφάσεων.....	3
Σχήμα 2.1. Φασματική συμπεριφορά της βλάστησης στις περιοχές του ορατού, red-edge, εγγύς υπερύθρου και βραχέος υπερύθρου, με έμφαση στις μπάντες του Sentinel-2 που αξιοποιούνται στην παρούσα εργασία.....	10
Σχήμα 2.2. Διάγραμμα Αρχιτεκτονικής ResNet-18 και Υπολειμματικών Συνδέσεων.....	14
Σχήμα 3.1. Κατανομή των φασματικών μπαντών του Sentinel-2 στις περιοχές του ορατού, red-edge, NIR και SWIR, καθώς και η αντίστοιχη χωρική ανάλυσή τους.....	21
Σχήμα 4.1. Αντιπροσωπευτικά δείγματα πολυφασματικών patches σε φυσικό χρώμα (RGB σύνθεση των μπαντών B4-B3-B2) για τις τέσσερις υπό μελέτη κατηγορίες ασθενειών: Aphid, Blast, Rust και RPH.....	25
Σχήμα 4.2. Παράδειγμα μικτού εικονοστοιχείου σε εικόνα Sentinel-2 και της αντίστοιχης μικτής φασματικής υπογραφής.....	29
Σχήμα 5.1. Συνολική αρχιτεκτονική της προτεινόμενης πολυσταδιακής μεθοδολογίας.....	32
Σχήμα 5.2. Σχηματική απεικόνιση της αυτοεπιβλεπόμενης contrastive εκπαίδευσης με χρήση SupConLoss.....	35
Σχήμα 5.3. Σχηματική απεικόνιση της συνολικής αρχιτεκτονικής.....	40
Σχήμα 5.4. Μεθοδολογική ροή της φασματικής αξιολόγησης και της XAI-guided επιλογής ζωνών. Η ανάλυση band occlusion εφαρμόζεται στο πλήρες πολυφασματικό μοντέλο και χρησιμοποιείται για τον σχεδιασμό πρόσθετου Top-5 φασματικού σχήματος.....	42
Σχήμα 6.1. Πίνακας σύγχυσης.....	51
Σχήμα 7.1. Εξέλιξη της συνάρτησης απώλειας (SSL loss) κατά την αυτοεπιβλεπόμενη προεκπαίδευση για 25 εποχές.....	57
Σχήμα 7.2. Κοινό διάγραμμα της εξέλιξης της training loss και της validation accuracy στο στάδιο ταξινόμησης καλλιέργειας για 25 εποχές.....	59
Σχήμα 7.3. Βέλτιστη επίδοση του μοντέλου ανά fold στο στάδιο ανίχνευσης ασθενειών, με βάση τη μετρική Validation Macro-F1.....	61
Σχήμα 7.4. Πίνακας σύγχυσης του καλύτερου fold (Fold 1, Epoch 39) για τις κλάσεις Aphid, Blast, RPH και Rust.....	62
Σχήμα 7.5. Συγκριτική επίδοση των τριών πειραματικών σχημάτων εκπαίδευσης με βάση τη μέση τιμή της best validation macro-F1.....	65
Σχήμα 7.6. Συγκριτική επίδοση Macro-F1 ανά φασματικό συνδυασμό.....	69
Σχήμα 7.7. Συγκριτική επίδοση macro-F1 ανά φασματικό συνδυασμό μετά την επαναλαμβανόμενη διασταυρούμενη επικύρωση. Οι ράβδοι σφάλματος αντιστοιχούν στην τυπική απόκλιση των επαναλαμβανόμενων folds.....	71
Σχήμα 7.8. Μέση πτώση της macro-F1 μετά από απόκρυψη κάθε φασματικής ζώνης Sentinel-2 στο πλήρες πολυφασματικό μοντέλο. Οι ράβδοι σφάλματος αντιστοιχούν στην τυπική απόκλιση σε 25 repeat-fold runs.....	74

Σχήμα 7.9. Ανά κλάση επίδραση της απόκρυψης φασματικών ζωνών στο F1-score. Οι τιμές αντιστοιχούν στη μέση πτώση F1-score ανά κλάση και ανά ζώνη Sentinel-2 στα 25 repeat-fold runs του πλήρους πολυφασματικού μοντέλου.....	77
Σχήμα 7.10. XAI-guided επιλογή των πέντε σημαντικότερων φασματικών ζωνών Sentinel-2 με βάση την band occlusion analysis του πλήρους πολυφασματικού μοντέλου.....	79
Σχήμα 8.1. Συνοπτική ερμηνεία των φασματικών ευρημάτων και της XAI-guided επιλογής ζωνών...	90

Κατάλογος Πινάκων

Πίνακας 6.1. Φασματικοί συνδυασμοί εισόδου που αξιολογήθηκαν στο disease stage.....	47
Πίνακας 6.2. Πρωτόκολλο band occlusion analysis.....	52
Πίνακας 7.1. Εξέλιξη της απώλειας κατά την αυτοεπιβλεπόμενη προεκπαίδευση.....	57
Πίνακας 7.2. Εξέλιξη της απόδοσης κατά την εκπαίδευση ταξινόμησης καλλιέργειας.....	58
Πίνακας 7.3. Βέλτιστη επίδοση ανά fold στο στάδιο ανίχνευσης ασθενειών.....	60
Πίνακας 7.4. Συνοπτική αποτίμηση 5-fold αξιολόγησης.....	61
Πίνακας 7.5. Συγκριτική αξιολόγηση των τριών πειραματικών σχημάτων εκπαίδευσης.....	65
Πίνακας 7.6. Ερμηνευτική σημασία των επιμέρους πειραματικών σχημάτων.....	66
Πίνακας 7.7. Αναλυτικά αποτελέσματα του πειράματος Crop → Disease ανά fold.....	66
Πίνακας 7.8. Φασματικά σχήματα εισόδου που αξιολογήθηκαν.....	68
Πίνακας 7.9. Συγκριτικά αποτελέσματα διαφορετικών φασματικών συνδυασμών.....	68
Πίνακας 7.10. Αποτελέσματα repeated 5-fold cross-validation για τους διαφορετικούς φασματικούς συνδυασμούς.....	70
Πίνακας 7.11. Αποτέλεσμα ελέγχου Friedman.....	72
Πίνακας 7.12. Στατιστικά σημαντικές pairwise συγκρίσεις μετά από Holm correction.....	72
Πίνακας 7.13. Σημαντικότητα φασματικών ζωνών Sentinel-2 με βάση band occlusion analysis στο πλήρες πολυφασματικό σχήμα.....	73
Πίνακας 7.14. Μέση πτώση F1-score ανά κλάση μετά από απόκρυψη κάθε φασματικής ζώνης στο πλήρες πολυφασματικό μοντέλο.....	75
Πίνακας 7.15. Πέντε σημαντικότερες φασματικές ζώνες ανά κλάση με βάση την ανά κλάση band occlusion analysis.....	76
Πίνακας 7.16. Απόδοση του XAI-guided Top-5 φασματικού σχήματος σε repeated 5-fold cross-validation.....	78
Πίνακας 8.1. Συνοπτική ερμηνεία των βασικών ευρημάτων της εργασίας.....	88
Πίνακας 9.1. Κύριες επιστημονικές συνεισφορές της εργασίας.....	93
Πίνακας 9.2. Τελική σύνδεση ερευνητικών ερωτημάτων και συμπερασμάτων.....	95

Κεφάλαιο 1ο: ΕΙΣΑΓΩΓΗ

1.1 Η σημασία της παρακολούθησης καλλιεργειών

Η γεωργία αποτελεί έναν από τους σημαντικότερους τομείς της ανθρώπινης δραστηριότητας, καθώς συνδέεται άμεσα με τη διασφάλιση της επισιτιστικής επάρκειας, τη στήριξη της αγροτικής οικονομίας και τη βιώσιμη διαχείριση των φυσικών πόρων [2]. Η συνεχώς αυξανόμενη ζήτηση για τρόφιμα, σε συνδυασμό με τις επιπτώσεις της κλιματικής αλλαγής, την υποβάθμιση των εδαφών και την αυξημένη πίεση στα γεωργικά συστήματα παραγωγής, καθιστούν αναγκαία την ανάπτυξη αποτελεσματικότερων μεθόδων παρακολούθησης και διαχείρισης των καλλιεργειών [2].

Η κατάσταση υγείας των φυτών επηρεάζει καθοριστικά τόσο την ποσότητα όσο και την ποιότητα της γεωργικής παραγωγής. Μεταξύ των παραγόντων που συμβάλλουν στη μείωση της παραγωγικότητας, οι φυτοπαθολογικές ασθένειες κατέχουν ιδιαίτερα σημαντική θέση, καθώς μπορούν να προκαλέσουν σοβαρές απώλειες στην απόδοση των καλλιεργειών, να επιβαρύνουν σημαντικά το κόστος παραγωγής και να επηρεάσουν ευρύτερα την παγκόσμια επισιτιστική ασφάλεια [11]. Η έγκαιρη ανίχνευσή τους είναι κρίσιμη, διότι επιτρέπει την εφαρμογή στοχευμένων παρεμβάσεων φυτοπροστασίας, τον περιορισμό της εξάπλωσης των προσβολών και τη βελτίωση της αποδοτικότητας της γεωργικής πρακτικής [11].

Παραδοσιακά, η παρακολούθηση της κατάστασης των καλλιεργειών και η διάγνωση ασθενειών βασίζονται σε επιτόπιες παρατηρήσεις από γεωπόνους ή άλλους ειδικούς. Παρότι οι μέθοδοι αυτές μπορούν να προσφέρουν υψηλή αξιοπιστία σε τοπικό επίπεδο, είναι χρονοβόρες, κοστοβόρες και δύσκολα κλιμακώσιμες όταν πρόκειται για μεγάλες γεωγραφικές εκτάσεις. Για τον λόγο αυτό, η σύγχρονη γεωργική παρακολούθηση στρέφεται όλο και περισσότερο προς αυτοματοποιημένες και κλιμακούμενες προσεγγίσεις, οι οποίες αξιοποιούν δεδομένα παρατήρησης της Γης και προηγμένες μεθόδους ανάλυσης [15].

1.2 Τηλεπισκόπηση και γεωργία ακριβείας

Η τηλεπισκόπηση προσφέρει τη δυνατότητα συστηματικής παρακολούθησης της επιφάνειας της Γης μέσω αισθητήρων εγκατεστημένων σε δορυφόρους ή αερομεταφερόμενες πλατφόρμες. Οι αισθητήρες αυτοί καταγράφουν την ανακλώμενη ή εκπεμπόμενη ηλεκτρομαγνητική ακτινοβολία από την επιφάνεια της Γης σε διαφορετικά μήκη κύματος, παρέχοντας πολύτιμες πληροφορίες για τα φυσικά και βιολογικά χαρακτηριστικά των επιφανειακών καλύψεων [19], [21].

Στο πεδίο της γεωργίας ακριβείας, η τηλεπισκόπηση έχει αναδειχθεί σε βασικό εργαλείο υποστήριξης αποφάσεων. Μέσω της ανάλυσης δορυφορικών δεδομένων είναι δυνατή η εκτίμηση της βιομάζας, η παρακολούθηση της ανάπτυξης των καλλιεργειών, η ανίχνευση υδατικού ή θρεπτικού στρες, καθώς και ο εντοπισμός χωρικών ή χρονικών αποκλίσεων στη φυσιολογική κατάσταση των φυτών [19], [21]. Η αξία των δεδομένων αυτών έγκειται κυρίως στη δυνατότητα συχνής, μη παρεμβατικής και μεγάλης κλίμακας παρατήρησης των αγροτικών εκτάσεων.

Ιδιαίτερη σημασία έχει τα τελευταία χρόνια η αξιοποίηση των δορυφορικών δεδομένων του ευρωπαϊκού προγράμματος Copernicus. Οι αποστολές Sentinel παρέχουν ανοικτά και δωρεάν δεδομένα υψηλής ποιότητας, τα οποία υποστηρίζουν πλήθος εφαρμογών περιβαλλοντικής και γεωργικής παρακολούθησης [21], [22]. Μεταξύ αυτών, ο δορυφόρος Sentinel-2 κατέχει κεντρική θέση σε

γεωργικές εφαρμογές, καθώς διαθέτει πολυφασματικό αισθητήρα με δεκατρείς φασματικές μπάντες, που καλύπτουν το ορατό, το εγγύς υπέρυθρο και το βραχύ υπέρυθρο τμήμα του φάσματος [19], [20]. Η φασματική αυτή πληροφορία επιτρέπει την αποτύπωση κρίσιμων πτυχών της φυσιολογικής κατάστασης της βλάστησης, όπως η συγκέντρωση χλωροφύλλης, η δομή του φυλλώματος και η υδατική κατάσταση των φυτικών ιστών [19].


1.3 Ανίχνευση ασθενειών καλλιεργειών με δορυφορικά δεδομένα

Οι φυτικές ασθένειες προκαλούν μεταβολές στη φυσιολογία των φυτών, οι οποίες επηρεάζουν τη φασματική τους συμπεριφορά [13]. Μεταβολές στη συγκέντρωση χλωροφύλλης, στη δομή των φύλλων, στην περιεκτικότητα σε νερό και γενικότερα στην υγεία του φυτικού ιστού μπορούν να αποτυπωθούν στη φασματική απόκριση της βλάστησης και, κατά συνέπεια, να καταγραφούν από πολυφασματικούς δορυφορικούς αισθητήρες [13].

Στο ορατό τμήμα του φάσματος, οι αλλαγές αυτές συνδέονται κυρίως με την απορρόφηση της ακτινοβολίας από τη χλωροφύλλη. Στο εγγύς υπέρυθρο, σχετίζονται περισσότερο με τη δομή του φυλλώματος και των εσωτερικών ιστών των φύλλων, ενώ στις ζώνες του βραχείου υπέρυθρου αποτυπώνονται συχνά μεταβολές που σχετίζονται με την περιεκτικότητα των φυτών σε νερό [6], [13]. Η δυνατότητα παρατήρησης αυτών των διαφοροποιήσεων καθιστά τα πολυφασματικά δεδομένα ιδιαίτερα χρήσιμα για την έμμεση ανίχνευση φυτοπαθολογικών ανωμαλιών [13].

Ο Sentinel-2 παρουσιάζει ιδιαίτερο ενδιαφέρον για τέτοιου είδους εφαρμογές, καθώς διαθέτει όχι μόνο τις συμβατικές ζώνες του ορατού και του εγγύς υπέρυθρου, αλλά και εξειδικευμένες μπάντες red-edge, οι οποίες είναι ιδιαίτερα ευαίσθητες σε πρώιμες μεταβολές της βλάστησης [19], [20]. Η πληροφορία αυτή μπορεί να αξιοποιηθεί για την ανάπτυξη μεθόδων που ανιχνεύουν πρότυπα φυτικού στρες και αποκλίσεις από τη φυσιολογική ανάπτυξη των καλλιεργειών [13].

Ωστόσο, η αξιοποίηση δορυφορικών δεδομένων για την ανίχνευση ασθενειών δεν είναι απλή διαδικασία. Οι δορυφορικοί αισθητήρες δεν καταγράφουν άμεσα την ασθένεια ως ορατό αντικείμενο, αλλά τη φασματική έκφραση φυσιολογικών μεταβολών που ενδέχεται να σχετίζονται με φυτοπαθολογικές καταστάσεις [13]. Επομένως, η επιτυχής ανάλυση απαιτεί μεθόδους ικανές να εντοπίζουν σύνθετα και συχνά έμμεσα μοτίβα στα δεδομένα [13], [15].



Σχήμα 1.1. Ενδεικτική απεικόνιση της αξιοποίησης δορυφορικών δεδομένων και τεχνικών τεχνητής νοημοσύνης σε εφαρμογές γεωργίας ακριβείας και υποστήριξης λήψης αποφάσεων.

1.4 Περιορισμοί των υφιστάμενων προσεγγίσεων

Παρά τη σημαντική πρόοδο που έχει σημειωθεί στην αξιοποίηση δορυφορικών δεδομένων για γεωργικές εφαρμογές, η ανίχνευση ασθενειών καλλιεργειών παραμένει ένα ιδιαίτερα απαιτητικό πρόβλημα [13], [15]. Ένας από τους σημαντικότερους περιορισμούς αφορά τη διαθεσιμότητα αξιόπιστων επισημασμένων δεδομένων. Η δημιουργία συνόλων δεδομένων που συνδέουν δορυφορικές παρατηρήσεις με επιβεβαιωμένες φυτοπαθολογικές καταστάσεις απαιτεί εξειδικευμένη γνώση, επιτόπιες παρατηρήσεις και σημαντικό χρόνο, με αποτέλεσμα τα διαθέσιμα δεδομένα να είναι συχνά περιορισμένα σε μέγεθος και ανισόρροπα ως προς την κατανομή των κλάσεων [4], [9], [14].

Επιπλέον, η φασματική έκφραση μιας ασθένειας δεν εξαρτάται αποκλειστικά από το παθογόνο ή το είδος της προσβολής, αλλά επηρεάζεται και από άλλους παράγοντες, όπως ο τύπος της καλλιέργειας, το φαινολογικό στάδιο ανάπτυξης, οι εδαφοκλιματικές συνθήκες και η παρουσία άλλων μορφών στρες [5], [13]. Οι παράγοντες αυτοί μπορούν να προκαλέσουν αλληλοεπικάλυψη στη φασματική υπογραφή διαφορετικών κατηγοριών, καθιστώντας δύσκολη τη σαφή διάκριση μεταξύ ασθένειας, φυσιολογικής μεταβολής και άλλων περιβαλλοντικών πιέσεων [13].

Περαιτέρω δυσκολία προκύπτει από τη χωρική ανάλυση των δορυφορικών δεδομένων. Αν και ο Sentinel-2 παρέχει δεδομένα υψηλής ποιότητας, η ανάλυσή του εξακολουθεί να είναι μέσης κλίμακας σε σχέση με τα λεπτά χωρικά πρότυπα στα οποία συχνά εκδηλώνονται τα πρώιμα συμπτώματα ασθενειών [19], [20]. Ως αποτέλεσμα, ένα εικονοστοιχείο ή ένα patch μπορεί να περιέχει μικτή πληροφορία από διαφορετικές επιφάνειες, καλλιέργειες ή καταστάσεις υγείας, εισάγοντας θόρυβο στη διαδικασία ανάλυσης [1].

Οι παραπάνω περιορισμοί καταδεικνύουν ότι οι απλούστερες προσεγγίσεις, όπως η χρήση μεμονωμένων φασματικών δεικτών ή η άμεση εκπαίδευση μοντέλων σε μικρά και ανισόρροπα σύνολα δεδομένων, συχνά δεν επαρκούν για την αξιόπιστη διάκριση φυτοπαθολογικών κατηγοριών [3], [15]. Καθίσταται, συνεπώς, αναγκαία η ανάπτυξη μεθοδολογιών που μπορούν να αξιοποιήσουν πιο αποτελεσματικά τόσο τα επισημασμένα όσο και τα μη επισημασμένα δεδομένα [10], [14].

1.5 Διατύπωση του ερευνητικού προβλήματος

Με βάση τα παραπάνω, το βασικό ερευνητικό πρόβλημα της παρούσας εργασίας αφορά την ανάπτυξη μιας αποτελεσματικής μεθοδολογίας για την ανίχνευση ασθενειών καλλιεργειών από πολυφασματικά δορυφορικά δεδομένα Sentinel-2, υπό συνθήκες περιορισμένης διαθεσιμότητας επισημασμένων δεδομένων και έντονης ανισορροπίας μεταξύ των κατηγοριών [4], [9], [14].

Η επίλυση του προβλήματος αυτού προϋποθέτει την εκμάθηση διακριτικών αναπαραστάσεων από δεδομένα υψηλής φασματικής πολυπλοκότητας, καθώς και τη δυνατότητα γενίκευσης του μοντέλου σε διαφορετικές κατηγορίες καλλιεργειών και φυτοπαθολογικών καταστάσεων [10], [14], [15]. Παράλληλα, απαιτείται η αξιοποίηση της πλούσιας πληροφορίας που παρέχουν τα μη επισημασμένα δορυφορικά δεδομένα, ώστε να περιοριστεί η εξάρτηση της εκπαίδευσης από μικρά σύνολα επισημασμένων παραδειγμάτων [14].

Στο πλαίσιο αυτό, η παρούσα εργασία διερευνά κατά πόσο μια πολυσταδιακή στρατηγική μάθησης, η οποία συνδυάζει αυτοεπιβλεπόμενη προεκπαίδευση, ενδιάμεση προσαρμογή σε πρόβλημα ταξινόμησης καλλιεργειών και τελικό fine-tuning σε πρόβλημα ταξινόμησης ασθενειών, μπορεί να βελτιώσει ουσιαστικά την απόδοση ενός μοντέλου βαθιάς μάθησης στην αναγνώριση φυτοπαθολογικών κατηγοριών από δεδομένα Sentinel-2 [10], [14].

Πέρα από την επίτευξη υψηλής ταξινομητικής απόδοσης, ένα επιπλέον ερευνητικό ζήτημα αφορά την κατανόηση της φασματικής πληροφορίας που αξιοποιεί το μοντέλο. Στα πολυφασματικά δεδομένα Sentinel-2, κάθε ζώνη αποτυπώνει διαφορετικές φυσικές και βιοφυσικές ιδιότητες της βλάστησης [19], [20]. Ωστόσο, η χρήση περισσότερων ζωνών δεν συνεπάγεται απαραίτητα καλύτερη γενίκευση, ιδίως όταν το διαθέσιμο σύνολο δεδομένων είναι μικρό, ανισόρροπο και ενδέχεται να περιέχει θόρυβο [4], [9], [15]. Συνεπώς, το ερευνητικό πρόβλημα της παρούσας εργασίας δεν περιορίζεται μόνο στο ερώτημα αν ένα μοντέλο βαθιάς μάθησης μπορεί να ταξινομήσει ασθένειες καλλιεργειών, αλλά επεκτείνεται και στο ερώτημα ποιες φασματικές ζώνες συμβάλλουν ουσιαστικά στη διαδικασία αυτή.

1.6 Στόχοι της εργασίας

Κύριος στόχος της παρούσας εργασίας είναι η ανάπτυξη και αξιολόγηση ενός ολοκληρωμένου πλαισίου βαθιάς μάθησης για την ανίχνευση ασθενειών καλλιεργειών με αξιοποίηση πολυφασματικών δορυφορικών δεδομένων Sentinel-2 [13], [15], [19], [24].

Ειδικότερα, οι επιμέρους στόχοι της μελέτης είναι οι ακόλουθοι:

- η διερεύνηση της καταλληλότητας των φασματικών ζωνών του Sentinel-2 για την αποτύπωση μεταβολών που σχετίζονται με τη φυσιολογική κατάσταση και την υγεία της βλάστησης,
- η ανάπτυξη πολυφασματικού encoder βασισμένου σε αρχιτεκτονική βαθιάς μάθησης, προσαρμοσμένου για είσοδο πολλαπλών φασματικών ζωνών,

- η αξιοποίηση μη επισημασμένων δεδομένων Sentinel-2 μέσω αυτοεπιβλεπόμενης μάθησης για την εκμάθηση γενικευμένων φασματικών και χωρικών αναπαραστάσεων,
- η ενδιάμεση προσαρμογή του encoder σε πρόβλημα ταξινόμησης καλλιεργειών, με στόχο τη γεωργική εξειδίκευση των learned representations,
- η τελική αξιολόγηση του συστήματος στην ταξινόμηση ασθενειών καλλιεργειών υπό συνθήκες περιορισμένων και ανισόρροπων δεδομένων,
- η συστηματική σύγκριση διαφορετικών φασματικών συνδυασμών εισόδου, ώστε να διερευνηθεί η συμβολή των ορατών, NIR, red-edge και SWIR ζωνών,
- η εφαρμογή τεχνικής ερμηνευσιμότητας μέσω band occlusion για την εκτίμηση της σημαντικότητας κάθε φασματικής ζώνης,
- ο σχεδιασμός και η αξιολόγηση ενός XAI-guided φασματικού subset, βασισμένου στις ζώνες που αναδείχθηκαν ως σημαντικότερες από την ερμηνευτική ανάλυση.

1.7 Ερευνητικές συνεισφορές

Η παρούσα εργασία συμβάλλει στη διερεύνηση του συνδυασμού πολυφασματικής τηλεπισκόπησης, αυτοεπιβλεπόμενης μάθησης και ερμηνεύσιμης βαθιάς μάθησης για εφαρμογές γεωργικής παρακολούθησης και ειδικότερα για την ανίχνευση ασθενειών καλλιεργειών [13]–[15], [24], [28].

Οι βασικές συνεισφορές της συνοψίζονται ως εξής:

- προτείνεται ένα πολυσταδιακό πλαίσιο μάθησης για δεδομένα Sentinel-2, το οποίο συνδυάζει αυτοεπιβλεπόμενη προεκπαίδευση, ενδιάμεση προσαρμογή σε ταξινόμηση καλλιεργειών και τελικό fine-tuning σε ταξινόμηση ασθενειών [10], [14],
- αξιοποιείται πολυφασματικός encoder βασισμένος στην αρχιτεκτονική ResNet, προσαρμοσμένος ώστε να δέχεται ως είσοδο δέκα φασματικές μπάντες του Sentinel-2 [16], [19],
- διερευνάται η χρήση contrastive αυτοεπιβλεπόμενης μάθησης για την εκμάθηση μεταφέρσιμων αναπαραστάσεων από μεγάλο όγκο μη επισημασμένων δορυφορικών δεδομένων [14], [17],
- τεκμηριώνεται πειραματικά η συμβολή της διαδοχικής μεταφοράς γνώσης από γενικές φασματικές αναπαραστάσεις προς πιο εξειδικευμένα γεωργικά και φυτοπαθολογικά tasks [10],
- αναδεικνύονται οι δυνατότητες, αλλά και οι περιορισμοί, της χρήσης δεδομένων Sentinel-2 για την έμμεση αναγνώριση κατηγοριών ασθενειών σε πραγματικά πολυφασματικά σύνολα δεδομένων [13], [19], [20].

1.8 Δομή της διπλωματικής εργασίας

Η παρούσα διπλωματική εργασία οργανώνεται σε εννέα κεφάλαια.

Στο Κεφάλαιο 1 παρουσιάζεται η εισαγωγή στο πρόβλημα της ανίχνευσης ασθενειών καλλιεργειών, καθώς και οι στόχοι και οι βασικές συνεισφορές της μελέτης.

Κεφάλαιο 1ο

Στο Κεφάλαιο 2 αναπτύσσεται το θεωρητικό υπόβαθρο της εργασίας, με έμφαση στη φασματική συμπεριφορά της βλάστησης, στις παραδοσιακές μεθόδους ανάλυσης τηλεπισκοπικών δεδομένων και στις τεχνικές μηχανικής μάθησης και βαθιάς μάθησης στην τηλεπισκόπηση.

Στο Κεφάλαιο 3 παρουσιάζεται το πρόγραμμα Copernicus και ο δορυφόρος Sentinel-2, με ιδιαίτερη έμφαση στα τεχνικά χαρακτηριστικά του αισθητήρα, στις φασματικές ζώνες και στη σημασία τους για γεωργικές εφαρμογές.

Στο Κεφάλαιο 4 περιγράφονται τα δεδομένα που χρησιμοποιούνται στην παρούσα μελέτη, καθώς και τα βασικά στάδια προεπεξεργασίας τους.

Στο Κεφάλαιο 5 παρουσιάζεται αναλυτικά η προτεινόμενη μεθοδολογία και η αρχιτεκτονική του συστήματος.

Στο Κεφάλαιο 6 περιγράφεται η πειραματική διαδικασία, το υπολογιστικό περιβάλλον και το πρωτόκολλο αξιολόγησης.

Στο Κεφάλαιο 7 παρουσιάζονται και αναλύονται τα πειραματικά αποτελέσματα των επιμέρους σταδίων της μεθοδολογίας. Ιδιαίτερη έμφαση δίνεται στη συγκριτική αξιολόγηση των διαφορετικών φασματικών συνδυασμών εισόδου, στην επαναλαμβανόμενη διασταυρούμενη επικύρωση, στη στατιστική σύγκριση των αποτελεσμάτων και στην ερμηνευτική ανάλυση της συμβολής των φασματικών ζωνών μέσω band occlusion.

Στο Κεφάλαιο 8 συζητούνται τα ευρήματα της εργασίας, με έμφαση στη συμβολή των επιμέρους σταδίων της μεθοδολογίας, στην ερμηνεία της απόδοσης των φασματικών σχημάτων, στη σημασία του RGB αποτελέσματος, καθώς και στη χρησιμότητα της XAI-guided επιλογής ζωνών. Παράλληλα, αναλύονται οι περιορισμοί της μελέτης και οι παράγοντες που επηρεάζουν τη γενίκευση των μοντέλων.

Τέλος, στο Κεφάλαιο 9 συνοψίζονται τα βασικά συμπεράσματα της εργασίας, παρουσιάζεται η επιστημονική της συνεισφορά και προτείνονται κατευθύνσεις για μελλοντική έρευνα, με έμφαση σε μεγαλύτερα datasets, ανεξάρτητη επικύρωση, πιο σύνθετη χρονική μοντελοποίηση και συστηματικότερες μεθόδους επιλογής φασματικών ζωνών.

Κεφάλαιο 2ο: ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ

2.1 Εισαγωγή

Η τηλεπισκόπηση αποτελεί μία από τις σημαντικότερες τεχνολογικές υποδομές για τη συστηματική παρακολούθηση της γήινης επιφάνειας. Μέσω δορυφορικών αισθητήρων είναι δυνατή η συλλογή δεδομένων σε μεγάλη χωρική έκταση και με επαναληπτικό χρονικό ρυθμό, γεγονός που επιτρέπει την ανάλυση φυσικών, περιβαλλοντικών και γεωργικών διεργασιών με αντικειμενικό και αυτοματοποιημένο τρόπο [19], [21]. Στον γεωργικό τομέα, η αξιοποίηση τηλεπισκοπικών δεδομένων έχει συμβάλει ουσιαστικά στην παρακολούθηση της ανάπτυξης των καλλιεργειών, στην εκτίμηση της βιομάζας, στην αναγνώριση φυτικού στρες και στη διαχείριση γεωργικών εισροών [19], [21].

Η πληροφορία που παρέχουν οι δορυφορικοί αισθητήρες βασίζεται στη φασματική συμπεριφορά των επιφανειών, δηλαδή στον τρόπο με τον οποίο τα αντικείμενα απορροφούν, ανακλούν ή εκπέμπουν ηλεκτρομαγνητική ακτινοβολία σε διαφορετικά μήκη κύματος [19]. Στην περίπτωση της βλάστησης, η φασματική απόκριση συνδέεται άμεσα με φυσιολογικά χαρακτηριστικά των φυτών, όπως η συγκέντρωση χλωροφύλλης, η δομή των φύλλων και η περιεκτικότητα σε νερό [6], [19]. Η κατανόηση αυτής της συμπεριφοράς αποτελεί θεμελιώδη προϋπόθεση για την αξιοποίηση πολυφασματικών δορυφορικών δεδομένων σε εφαρμογές γεωργικής παρακολούθησης και ειδικότερα στην ανίχνευση φυτοπαθολογικών προβλημάτων [13].

Παράλληλα, η εξέλιξη της μηχανικής μάθησης και ιδιαίτερα της βαθιάς μάθησης έχει διευρύνει σημαντικά τις δυνατότητες ανάλυσης δορυφορικών δεδομένων [15]. Τα σύγχρονα υπολογιστικά μοντέλα είναι σε θέση να επεξεργάζονται μεγάλους όγκους πολυφασματικής πληροφορίας και να εξάγουν σύνθετες αναπαραστάσεις που δεν αποτυπώνονται επαρκώς με απλούς φασματικούς δείκτες ή κλασικές στατιστικές προσεγγίσεις [3], [15]. Στο παρόν κεφάλαιο παρουσιάζονται οι βασικές θεωρητικές έννοιες που υποστηρίζουν την παρούσα εργασία: η φασματική συμπεριφορά της βλάστησης, οι παραδοσιακές μέθοδοι ανάλυσης τηλεπισκοπικών δεδομένων και οι σύγχρονες προσεγγίσεις μηχανικής μάθησης στην τηλεπισκόπηση.

2.2 Τηλεπισκόπηση και φασματική συμπεριφορά της βλάστησης

Η τηλεπισκόπηση είναι η επιστήμη και τεχνολογία που επιτρέπει τη συλλογή πληροφοριών για αντικείμενα ή φαινόμενα χωρίς άμεση φυσική επαφή με αυτά, μέσω της καταγραφής της ηλεκτρομαγνητικής ακτινοβολίας που ανακλάται ή εκπέμπεται από την επιφάνεια της Γης [19], [21]. Οι δορυφορικοί αισθητήρες καταγράφουν τη φασματική απόκριση των επιφανειών σε διαφορετικά μήκη κύματος, καθιστώντας δυνατή τη διάκριση τύπων κάλυψης γης, την παρακολούθηση φυσικών διεργασιών και την ανάλυση βιολογικών καταστάσεων [19].

Στην περίπτωση της βλάστησης, η αλληλεπίδραση της ηλιακής ακτινοβολίας με τα φύλλα και το φυτικό κάλυμμα εξαρτάται από παράγοντες όπως η περιεκτικότητα σε χλωροφύλλη, η εσωτερική δομή των ιστών, η υδατική κατάσταση των φυτών και η γεωμετρία της φυτικής κόμης [19]. Οι παράγοντες αυτοί επηρεάζουν άμεσα το ποσοστό της ακτινοβολίας που απορροφάται ή ανακλάται σε κάθε φασματική περιοχή. Επομένως, η φασματική συμπεριφορά της βλάστησης μπορεί να αξιοποιηθεί ως έμμεσος δείκτης της φυσιολογικής της κατάστασης [19], [13].

2.2.1 Φασματική υπογραφή της βλάστησης

Η φασματική υπογραφή περιγράφει το πρότυπο ανάκλασης ή απορρόφησης της ηλεκτρομαγνητικής ακτινοβολίας από ένα αντικείμενο ως συνάρτηση του μήκους κύματος [19]. Στη βλάστηση, η φασματική υπογραφή χαρακτηρίζεται από ιδιαίτερα πρότυπα που σχετίζονται με τα φυσιολογικά και βιοχημικά χαρακτηριστικά των φυτών [19], [21].

Στο ορατό τμήμα του φάσματος, και ειδικότερα στην περιοχή του κόκκινου φωτός, η χλωροφύλλη απορροφά σημαντικό μέρος της ακτινοβολίας για τη διαδικασία της φωτοσύνθεσης, με αποτέλεσμα η ανάκλαση να είναι σχετικά χαμηλή [19]. Αντίθετα, στην περιοχή του πράσινου η απορρόφηση είναι μικρότερη και η ανάκλαση υψηλότερη, γεγονός που εξηγεί γιατί η βλάστηση εμφανίζεται πράσινη στο ανθρώπινο μάτι [19].

Στην περιοχή του εγγύς υπερύθρου, η ανάκλαση αυξάνεται σημαντικά λόγω της εσωτερικής δομής των φύλλων και της παρουσίας αεροχώρων στο μεσοφύλλιο [19]. Η υψηλή ανάκλαση σε αυτή τη φασματική περιοχή αποτελεί χαρακτηριστικό γνώρισμα της υγιούς βλάστησης. Αντίστοιχα, στις ζώνες του βραχέος υπερύθρου, η φασματική απόκριση επηρεάζεται κυρίως από την περιεκτικότητα των φυτικών ιστών σε νερό [6], [19]. Κατά συνέπεια, η φασματική υπογραφή της βλάστησης αντανακλά άμεσα τη φυσιολογική κατάσταση των φυτών και μπορεί να αξιοποιηθεί για την ανάλυση μεταβολών ή αποκλίσεων από τη φυσιολογική ανάπτυξη [13].

2.2.2 Φασματικές περιοχές ορατού, red-edge, εγγύς υπερύθρου και βραχέος υπερύθρου


Για την τηλεπισκοπική μελέτη της βλάστησης ιδιαίτερο ενδιαφέρον παρουσιάζουν τέσσερις βασικές φασματικές περιοχές: το ορατό φάσμα, η περιοχή red-edge, το εγγύς υπέρυθρο και το βραχύ υπέρυθρο [19], [20].

Το ορατό φάσμα καλύπτει περίπου το εύρος 400–700 nm και περιλαμβάνει τις μπάντες που σχετίζονται περισσότερο με τη χρωματική πληροφορία και τη φωτοσυνθετική δραστηριότητα των φυτών [19]. Οι διαφοροποιήσεις στην ανάκλαση του μπλε, του πράσινου και του κόκκινου τμήματος του φάσματος σχετίζονται άμεσα με τη συγκέντρωση χλωροφύλλης και τη γενικότερη φυσιολογική κατάσταση της βλάστησης [19].

Η περιοχή red-edge βρίσκεται μεταξύ του κόκκινου και του εγγύς υπερύθρου και χαρακτηρίζεται από την απότομη μετάβαση από χαμηλή σε υψηλή ανακλαστικότητα [19], [20]. Η περιοχή αυτή είναι ιδιαίτερα ευαίσθητη σε αλλαγές της χλωροφυλλικής συγκέντρωσης και αποτελεί κρίσιμο πεδίο για την ανίχνευση πρώιμων μορφών φυτικού στρες [19], [20].

Το εγγύς υπέρυθρο συνδέεται κυρίως με τη δομή των φύλλων, τη βιομάζα και τη συνολική κατάσταση του φυλλώματος [19]. Υγιή φυτά τείνουν να εμφανίζουν υψηλή ανάκλαση στη ζώνη αυτή, ενώ η παρουσία στρες ή ασθενειών μπορεί να οδηγήσει σε μείωση της απόκρισης [13], [19].

Το βραχύ υπέρυθρο είναι ιδιαίτερα ευαίσθητο στην περιεκτικότητα των φυτών σε νερό και στις δομικές μεταβολές των ιστών [6], [19]. Η πληροφορία αυτή είναι εξαιρετικά χρήσιμη σε εφαρμογές όπου ζητείται η διάκριση μεταξύ φυσιολογικής ανάπτυξης, υδατικού στρες και άλλων ανωμαλιών της βλάστησης [6].



Σχήμα 2.1. Φασματική συμπεριφορά της βλάστησης στις περιοχές του ορατού, red-edge, εγγύς υπέρυθρου και βραχέος υπέρυθρου, με έμφαση στις μπάντες του Sentinel-2 που αξιοποιούνται στην παρούσα εργασία.

2.2.3 Επίδραση των ασθενειών στη φασματική συμπεριφορά των φυτών

Οι φυτικές ασθένειες μεταβάλλουν τη φυσιολογική λειτουργία των φυτών και επηρεάζουν άμεσα τη φασματική τους απόκριση [13]. Η μείωση της φωτοσυνθετικής δραστηριότητας, η αλλοίωση της δομής των φύλλων, η νέκρωση φυτικών ιστών και η μεταβολή της υδατικής ισορροπίας αποτελούν ορισμένους από τους βασικούς μηχανισμούς μέσω των οποίων μια ασθένεια μπορεί να αποτυπωθεί φασματικά [13].

Η μείωση της χλωροφύλλης οδηγεί συνήθως σε αύξηση της ανάκλασης στο κόκκινο τμήμα του φάσματος, ενώ η διαταραχή της εσωτερικής δομής των φύλλων επηρεάζει την απόκριση στο εγγύς υπέρυθρο. Παράλληλα, η μεταβολή της περιεκτικότητας σε νερό μπορεί να επηρεάσει αισθητά τις ζώνες του βραχέος υπέρυθρου [6], [13]. Οι μεταβολές αυτές δεν είναι πάντοτε έντονες ή απόλυτα διακριτές, αλλά μπορούν να λειτουργήσουν ως έμμεσες ενδείξεις φυτοπαθολογικής κατάστασης όταν αναλυθούν κατάλληλα [13].

Στην πράξη, αυτό σημαίνει ότι η ανίχνευση ασθενειών από δορυφορικά δεδομένα δεν βασίζεται στην άμεση «οπτική» αναγνώριση της ασθένειας, αλλά στην αναγνώριση φασματικών μοτίβων που υποδηλώνουν αποκλίσεις από τη φυσιολογική κατάσταση της βλάστησης [13].

2.2.4 Φαινολογία καλλιεργειών και χρονική μεταβολή της φασματικής απόκρισης

Η φασματική συμπεριφορά των καλλιεργειών δεν παραμένει σταθερή στον χρόνο, αλλά μεταβάλλεται δυναμικά κατά τη διάρκεια του καλλιεργητικού κύκλου [5]. Η φαινολογία αναφέρεται στα διαδοχικά στάδια ανάπτυξης των φυτών, όπως η βλάστηση, η ανάπτυξη του φυλλώματος, η άνθηση, η ωρίμανση και η γήρανση. Κάθε στάδιο συνοδεύεται από συγκεκριμένες φυσιολογικές και μορφολογικές μεταβολές, οι οποίες επηρεάζουν άμεσα τη φασματική απόκριση της βλάστησης [5].

Κατά την ενεργό ανάπτυξη, η αύξηση της χλωροφύλλης και της φυλλικής επιφάνειας οδηγεί συνήθως σε ισχυρότερη απορρόφηση στο κόκκινο και σε υψηλή ανάκλαση στο εγγύς υπέρυθρο [5], [19]. Αντίθετα, κατά τη γήρανση των φυτών ή σε συνθήκες στρες, η μείωση της φωτοσυνθετικής

δραστηριότητας και οι μεταβολές στους ιστούς προκαλούν διαφοροποιήσεις στη φασματική υπογραφή [5].

Η παρατήρηση αυτή είναι ιδιαίτερα σημαντική για την ανίχνευση ασθενειών, καθώς οι φασματικές αποκλίσεις που οφείλονται σε φυτοπαθολογικά αίτια πρέπει να διαχωρίζονται από τις φυσιολογικές χρονικές μεταβολές της καλλιέργειας [5], [13]. Για τον λόγο αυτό, η αξιοποίηση πολυχρονικών δεδομένων μπορεί να ενισχύσει σημαντικά την αξιοπιστία της ανάλυσης [5].

2.2.5 Σχέση καλλιέργειας και ασθένειας

Η εκδήλωση και η φασματική έκφραση μιας ασθένειας δεν είναι ανεξάρτητες από το φυτικό υπόβαθρο στο οποίο αυτή εμφανίζεται [13]. Κάθε καλλιέργεια χαρακτηρίζεται από διαφορετική μορφολογία, δομή φυλλώματος, φαινολογικό κύκλο, συγκέντρωση χλωροφύλλης και υδατική συμπεριφορά [5]. Οι ιδιαιτερότητες αυτές επηρεάζουν τόσο την εμφάνιση της ασθένειας όσο και τον τρόπο με τον οποίο αυτή αποτυπώνεται στα τηλεπισκοπικά δεδομένα [13].

Ως αποτέλεσμα, η ίδια ασθένεια μπορεί να εμφανίζει διαφορετική φασματική έκφραση σε διαφορετικά είδη καλλιέργειας, ενώ αντίστροφα διαφορετικές ασθένειες μπορεί να προκαλούν φαινομενικά παρόμοιες αποκλίσεις στη φασματική συμπεριφορά [13]. Η σχέση μεταξύ καλλιέργειας και ασθένειας αποτελεί, συνεπώς, κρίσιμο παράγοντα για τη σωστή ερμηνεία των δεδομένων και για την ανάπτυξη αποτελεσματικών υπολογιστικών μοντέλων [10], [13].

2.3 Παραδοσιακές μέθοδοι ανάλυσης τηλεπισκοπικών δεδομένων

Οι παραδοσιακές μέθοδοι ανάλυσης τηλεπισκοπικών δεδομένων βασίζονται κυρίως σε φασματικούς δείκτες, εμπειρικά κατώφλια και στατιστικές συγκρίσεις των τιμών ανάκλασης. Οι προσεγγίσεις αυτές είναι απλές, ερμηνεύσιμες και ιδιαίτερα χρήσιμες για τη γενική παρακολούθηση της βλάστησης, όμως συχνά δυσκολεύονται να διακρίνουν σύνθετες ή έμμεσες φυτοπαθολογικές αποκλίσεις [13], [15].

2.3.1 Δείκτες βλάστησης

Οι δείκτες βλάστησης αποτελούν μαθηματικούς συνδυασμούς δύο ή περισσότερων φασματικών ζωνών, με στόχο τη συνοπτική αποτύπωση της κατάστασης της βλάστησης [18]. Οι δείκτες αυτοί βασίζονται κυρίως στη διαφορά ανάμεσα στην ισχυρή απορρόφηση της ακτινοβολίας στο κόκκινο και στην υψηλή ανάκλαση στο εγγύς υπέρυθρο, που χαρακτηρίζει τη υγιή βλάστηση [18].

Η μεγάλη διάδοσή τους οφείλεται στην απλότητα υπολογισμού τους και στην ικανότητά τους να παρέχουν γρήγορες εκτιμήσεις για τη φυτική κάλυψη, τη βιομάζα και τη γενικότερη φυσιολογική κατάσταση των φυτών [18]. Ωστόσο, επειδή συμπυκνώνουν την πληροφορία σε λίγες μόνο αριθμητικές ποσότητες, δεν μπορούν πάντοτε να αποτυπώσουν τη σύνθετη φασματική δυναμική της βλάστησης [15].

2.3.2 NDVI και συναφείς φασματικοί δείκτες

Ο πιο γνωστός δείκτης βλάστησης είναι ο Normalized Difference Vegetation Index (NDVI), ο οποίος υπολογίζεται από την κανονικοποιημένη διαφορά μεταξύ της ανάκλασης στο εγγύς υπέρυθρο και στο κόκκινο [18]. Ο δείκτης αυτός χρησιμοποιείται ευρέως για την παρακολούθηση της υγείας των φυτών, την εκτίμηση της βιομάζας και τη μελέτη της δυναμικής της βλάστησης σε διαφορετικές χρονικές στιγμές [18].

Εκτός από τον NDVI, έχουν αναπτυχθεί και άλλοι δείκτες, όπως ο Enhanced Vegetation Index (EVI), ο Soil Adjusted Vegetation Index (SAVI) και ο Normalized Difference Water Index (NDWI), οι οποίοι στοχεύουν στην ανάδειξη διαφορετικών πτυχών της φυτικής κατάστασης ή στην αντιμετώπιση συγκεκριμένων περιορισμών [6], [7], [8]. Για παράδειγμα, ορισμένοι δείκτες επιχειρούν να περιορίσουν την επίδραση του εδάφους, ενώ άλλοι να καταγράψουν καλύτερα την υδατική κατάσταση της βλάστησης [6], [7], [8].

Παρότι οι δείκτες αυτοί είναι ιδιαίτερα χρήσιμοι για γενική παρακολούθηση της βλάστησης, η ικανότητά τους να διακρίνουν διαφορετικές αιτίες στρες ή να εντοπίζουν συγκεκριμένες φυτοπαθολογικές κατηγορίες παραμένει περιορισμένη [13], [15].

2.3.3 Μέθοδοι ανίχνευσης ανωμαλιών

Η παραδοσιακή ανίχνευση ανωμαλιών στη βλάστηση βασίζεται συνήθως στη σύγκριση των φασματικών δεικτών ή των ανακλαστικών τιμών με ιστορικά δεδομένα, με εποχικά πρότυπα ή με τιμές αναφοράς [13]. Μία συχνά χρησιμοποιούμενη προσέγγιση είναι η ανάλυση χρονικών σειρών, κατά την οποία εντοπίζονται αποκλίσεις από το αναμενόμενο μοτίβο ανάπτυξης μιας καλλιέργειας [5].

Οι αποκλίσεις αυτές μπορεί να υποδηλώνουν την παρουσία στρες, έλλειψης νερού, θρεπτικών προβλημάτων ή ασθενειών. Ωστόσο, η ανίχνευση της ύπαρξης ανωμαλίας δεν ισοδυναμεί με αξιόπιστη διάγνωση της αιτίας της. Πολλαπλοί παράγοντες μπορούν να οδηγήσουν σε παρόμοια φασματικά μοτίβα, γεγονός που καθιστά δύσκολη τη σαφή ερμηνεία μόνο με βάση απλές συγκρίσεις ή κατώφλια [13], [15].

2.3.4 Περιορισμοί των παραδοσιακών προσεγγίσεων

Οι παραδοσιακές μέθοδοι ανάλυσης τηλεπισκοπικών δεδομένων προσφέρουν χρήσιμα εργαλεία συνοπτικής περιγραφής της βλάστησης, αλλά εμφανίζουν σημαντικούς περιορισμούς σε πιο σύνθετα προβλήματα [15]. Η κύρια αδυναμία τους έγκειται στο ότι βασίζονται σε περιορισμένο αριθμό χειροποίητων χαρακτηριστικών, τα οποία δεν αξιοποιούν το πλήρες εύρος της πολυφασματικής πληροφορίας [3], [15].

Επιπλέον, οι δείκτες βλάστησης είναι συχνά ευαίσθητοι σε παράγοντες όπως η παρουσία γυμνού εδάφους, οι ατμοσφαιρικές συνθήκες, οι σκιές, η γεωμετρία παρατήρησης και η φαινολογική μεταβλητότητα της καλλιέργειας [7], [8]. Σε προβλήματα ανίχνευσης ασθενειών, όπου οι αποκλίσεις μπορεί να είναι λεπτές, έμμεσες και ενίοτε αλληλεπικαλυπτόμενες, οι απλούστερες προσεγγίσεις δεν επαρκούν συνήθως για αξιόπιστη διάκριση μεταξύ διαφορετικών κατηγοριών [13], [15].

2.4 Μηχανική μάθηση στην τηλεπισκόπηση

Η μηχανική μάθηση αποτελεί έναν από τους πλέον δυναμικούς τομείς στην ανάλυση δορυφορικών δεδομένων [3], [15]. Μέσω της χρήσης αλγορίθμων που μαθαίνουν πρότυπα από δεδομένα, είναι δυνατή η ανάπτυξη συστημάτων ικανών να εκτελούν ταξινόμηση, πρόβλεψη ή αναγνώριση σύνθετων σχέσεων χωρίς την ανάγκη ρητού προγραμματισμού όλων των κανόνων [15].

Στην τηλεπισκόπηση, οι τεχνικές μηχανικής μάθησης έχουν αξιοποιηθεί σε ευρύ φάσμα εφαρμογών, όπως η ταξινόμηση χρήσεων γης, η ανίχνευση αλλαγών, η εκτίμηση γεωργικών παραμέτρων και η παρακολούθηση της κατάστασης της βλάστησης [3], [15].

2.4.1 Κλασικές μέθοδοι μηχανικής μάθησης

Οι κλασικές μέθοδοι μηχανικής μάθησης περιλαμβάνουν αλγορίθμους όπως τα Support Vector Machines, τα Random Forests και οι μέθοδοι k-Nearest Neighbors [3], [15]. Οι αλγόριθμοι αυτοί έχουν χρησιμοποιηθεί ευρέως στην τηλεπισκόπηση, ιδιαίτερα σε προβλήματα όπου τα διαθέσιμα δεδομένα είναι σχετικά περιορισμένα και η εξαγωγή χαρακτηριστικών γίνεται χειροκίνητα ή ημιαυτόματα [15].

2.4.2 Βαθιά μάθηση σε δορυφορικές εικόνες


Η βαθιά μάθηση αποτελεί εξέλιξη της μηχανικής μάθησης που βασίζεται σε νευρωνικά δίκτυα πολλών επιπέδων, ικανά να μαθαίνουν αυτόματα ιεραρχικές αναπαραστάσεις από τα ίδια τα δεδομένα [3], [15]. Σε αντίθεση με τις κλασικές προσεγγίσεις, δεν απαιτείται εκτεταμένη χειροκίνητη εξαγωγή χαρακτηριστικών, καθώς το μοντέλο μαθαίνει σταδιακά από απλούστερα σε πιο σύνθετα επίπεδα αναπαράστασης [15].

Στις δορυφορικές εικόνες, η βαθιά μάθηση προσφέρει τη δυνατότητα συνδυασμένης αξιοποίησης χωρικής, φασματικής και, σε ορισμένες περιπτώσεις, χρονικής πληροφορίας [3], [15]. Το πλεονέκτημα αυτό είναι ιδιαίτερα σημαντικό σε εφαρμογές γεωργικής παρακολούθησης, όπου οι διαφοροποιήσεις μπορεί να είναι λεπτές και να μην αποτυπώνονται επαρκώς μέσω περιορισμένου αριθμού χειροποίητων δεικτών [15].

2.4.3 Συνελικτικά νευρωνικά δίκτυα στην τηλεπισκόπηση

Τα συνελικτικά νευρωνικά δίκτυα αποτελούν μία από τις πιο διαδεδομένες αρχιτεκτονικές βαθιάς μάθησης για την ανάλυση εικόνων [3], [15]. Η βασική τους λειτουργία στηρίζεται στην εφαρμογή συνελικτικών φίλτρων, τα οποία επιτρέπουν την εξαγωγή τοπικών χωρικών προτύπων, όπως ακμές, υφές και πιο σύνθετες δομές [15].

Στην τηλεπισκόπηση, τα συνελικτικά δίκτυα έχουν χρησιμοποιηθεί εκτενώς για την επεξεργασία πολυφασματικών και υπερφασματικών εικόνων, καθώς μπορούν να επεξεργάζονται ταυτόχρονα πολλαπλά φασματικά κανάλια και να μαθαίνουν σύνθετες αναπαραστάσεις της επιφάνειας της Γης [3], [15]. Η αρχιτεκτονική ResNet, ειδικότερα, συνέβαλε σημαντικά στην επιτυχή εκπαίδευση βαθύτερων μοντέλων μέσω των residual συνδέσεων [16].



Σχήμα 2.2. Διάγραμμα Αρχιτεκτονικής ResNet-18 και Υπολειμματικών Συνδέσεων.

2.4.4 Μεταφορά μάθησης

Η μεταφορά μάθησης αναφέρεται στην επαναχρησιμοποίηση γνώσης που έχει αποκτηθεί σε ένα πρόβλημα ή ένα σύνολο δεδομένων, με σκοπό τη βελτίωση της απόδοσης σε ένα άλλο, σχετικό πρόβλημα [10]. Στα νευρωνικά δίκτυα, η διαδικασία αυτή υλοποιείται συνήθως μέσω της αξιοποίησης προεκπαιδευμένων βαρών, ιδιαίτερα στα αρχικά επίπεδα του μοντέλου, τα οποία μαθαίνουν γενικότερα χαρακτηριστικά των δεδομένων [10].

Στην τηλεπισκόπηση, η μεταφορά μάθησης έχει ιδιαίτερη αξία επειδή η συλλογή επισημασμένων δεδομένων είναι συχνά δύσκολη και δαπανηρή [10], [15]. Ένα μοντέλο που έχει ήδη μάθει να εξάγει χρήσιμες φασματικές και χωρικές αναπαραστάσεις μπορεί να προσαρμοστεί αποτελεσματικότερα σε ένα νέο πρόβλημα, ιδίως όταν το διαθέσιμο σύνολο εκπαίδευσης είναι περιορισμένο [10].

2.4.5 Αυτοεπιβλεπόμενη μάθηση

Η αυτοεπιβλεπόμενη μάθηση αποτελεί μια σύγχρονη προσέγγιση που επιτρέπει την εκπαίδευση μοντέλων σε μη επισημασμένα δεδομένα μέσω της διαμόρφωσης τεχνητών στόχων μάθησης [14]. Αντί να βασίζεται σε εξωτερικά labels, το μοντέλο εξάγει την εποπτεία από τα ίδια τα δεδομένα και μαθαίνει γενικές αναπαραστάσεις, οι οποίες μπορούν στη συνέχεια να μεταφερθούν σε επιβλεπόμενες εργασίες [14], [24].

Η σημασία της αυτοεπιβλεπόμενης μάθησης στην τηλεπισκόπηση είναι ιδιαίτερα μεγάλη, καθώς ο όγκος των διαθέσιμων μη επισημασμένων δορυφορικών δεδομένων είναι πολύ μεγαλύτερος από τον όγκο των αξιόπιστα επισημασμένων παραδειγμάτων [14]. Ιδιαίτερα σημαντική κατηγορία μεθόδων αυτοεπιβλεπόμενης μάθησης είναι η αντιθετική μάθηση, στην οποία το μοντέλο μαθαίνει να φέρνει κοντά στον χώρο αναπαράστασης διαφορετικές όψεις του ίδιου δείγματος και να απομακρύνει όψεις διαφορετικών δειγμάτων [17].

2.4.6 Αναπαράσταση πολυφασματικών δεδομένων για μοντέλα βαθιάς μάθησης

Σε αντίθεση με τις συμβατικές εικόνες RGB, οι πολυφασματικές δορυφορικές εικόνες αποτελούνται από μεγαλύτερο αριθμό φασματικών ζωνών, καθεμία από τις οποίες αποτυπώνει διαφορετική πτυχή της φυσικής ή βιολογικής κατάστασης της επιφάνειας [15], [19]. Στα δεδομένα Sentinel-2, ένα δείγμα μπορεί να αναπαρασταθεί ως πολυδιάστατος πίνακας της μορφής

$$X \in \mathbb{R}^{N \times C \times H \times W}$$

όπου C είναι ο αριθμός των φασματικών καναλιών, ενώ H και W αντιστοιχούν στις χωρικές διαστάσεις της εικόνας ή του patch.

Η μορφή αυτή απαιτεί προσαρμογή των αρχιτεκτονικών βαθιάς μάθησης, καθώς το πρώτο συνελικτικό επίπεδο ενός μοντέλου πρέπει να είναι σε θέση να επεξεργάζεται αριθμό καναλιών εισόδου μεγαλύτερο από τρία [16]. Με τον τρόπο αυτό, το δίκτυο μπορεί να αξιοποιεί τα πολυφασματικά δεδομένα ως ενιαία πολυκαναλική είσοδο και να εξάγει τόσο χωρικά όσο και φασματικά χαρακτηριστικά [15], [16].

2.4.7 Προκλήσεις των δορυφορικών δεδομένων για εφαρμογές μηχανικής μάθησης

Παρά τις σημαντικές δυνατότητες που προσφέρουν οι τεχνικές μηχανικής μάθησης στην τηλεπισκόπηση, η εφαρμογή τους συνοδεύεται από μια σειρά ουσιωδών προκλήσεων [3], [15]. Μία από τις σημαντικότερες είναι η περιορισμένη διαθεσιμότητα επισημασμένων δεδομένων [14], [15]. Εξίσου κρίσιμο ζήτημα αποτελεί η φασματική και χωρική ετερογένεια των δορυφορικών δεδομένων, ενώ πρόσθετη πρόκληση συνιστά η ύπαρξη διαφορετικών χωρικών αναλύσεων μεταξύ των επιμέρους φασματικών ζωνών [19], [20]. Τέλος, η παρουσία μικτών εικονοστοιχείων και τα ζητήματα γενίκευσης σε διαφορετικά γεωργικά περιβάλλοντα καθιστούν ακόμη πιο απαιτητική την ανάπτυξη αξιόπιστων μοντέλων [1], [15].

2.4.8 Ερμηνευσιμότητα μοντέλων βαθιάς μάθησης σε πολυφασματικά δεδομένα

Η αυξανόμενη χρήση μοντέλων βαθιάς μάθησης στην τηλεπισκόπηση συνοδεύεται από την ανάγκη καλύτερης ερμηνείας των αποφάσεών τους. Παρότι τα συνελικτικά νευρωνικά δίκτυα μπορούν να επιτύχουν υψηλή απόδοση σε προβλήματα ταξινόμησης εικόνων, συχνά λειτουργούν ως πολύπλοκα μη γραμμικά μοντέλα, των οποίων η εσωτερική διαδικασία λήψης απόφασης δεν είναι άμεσα κατανοητή [3], [15], [29]. Το ζήτημα αυτό είναι ιδιαίτερα σημαντικό σε εφαρμογές γεωργικής παρακολούθησης, όπου η αξιοπιστία και η ερμηνευσιμότητα των προβλέψεων επηρεάζουν την πρακτική αξιοποίησή τους [13], [24].

Στα πολυφασματικά δεδομένα, η ανάγκη ερμηνευσιμότητας αποκτά επιπλέον σημασία, καθώς κάθε φασματική ζώνη αντιστοιχεί σε συγκεκριμένο τμήμα του ηλεκτρομαγνητικού φάσματος και συνδέεται με διαφορετικές βιοφυσικές ιδιότητες της βλάστησης [1], [19], [20]. Για παράδειγμα, οι ορατές ζώνες σχετίζονται κυρίως με τη χρωματική πληροφορία και τη χλωροφύλλη, οι red-edge και NIR ζώνες με τη φυτική δομή και τη φυσιολογική κατάσταση, ενώ οι SWIR ζώνες με την υδατική κατάσταση των φυτικών ιστών [6], [8], [13]. Επομένως, η κατανόηση του βαθμού στον οποίο ένα μοντέλο αξιοποιεί κάθε ζώνη μπορεί να προσφέρει χρήσιμες πληροφορίες τόσο για τη λειτουργία του μοντέλου όσο και για τη φύση του προβλήματος.

Μία απλή αλλά αποτελεσματική προσέγγιση ερμηνευσιμότητας είναι η ανάλυση απόκρυψης χαρακτηριστικών, γνωστή ως occlusion ή ablation analysis [28]. Στην περίπτωση των πολυφασματικών δεδομένων, η μέθοδος μπορεί να εφαρμοστεί αποκρύπτοντας κάθε φασματική ζώνη ξεχωριστά και μετρώντας την αντίστοιχη πτώση της απόδοσης του μοντέλου. Εάν η απόκρυψη μιας ζώνης προκαλεί μεγάλη μείωση στη μετρική αξιολόγησης, τότε η ζώνη αυτή θεωρείται σημαντική για τη συγκεκριμένη ταξινομητική απόφαση ή για τη συνολική συμπεριφορά του μοντέλου.

Η προσέγγιση αυτή δεν αποδεικνύει αιτιώδη σχέση μεταξύ μιας φασματικής ζώνης και μιας ασθένειας, αλλά παρέχει μια πρακτική εκτίμηση της εξάρτησης του εκπαιδευμένου μοντέλου από τη συγκεκριμένη πληροφορία εισόδου [28], [30], [31]. Για τον λόγο αυτό, η band occlusion analysis μπορεί να λειτουργήσει συμπληρωματικά προς τη συγκριτική αξιολόγηση φασματικών συνδυασμών, βοηθώντας στην κατανόηση του γιατί ορισμένες ζώνες ή ομάδες ζωνών είναι περισσότερο χρήσιμες από άλλες.

Κεφάλαιο 3ο: ΤΟ ΠΡΟΓΡΑΜΜΑ COPERNICUS ΚΑΙ Ο ΔΟΡΥΦΟΡΟΣ SENTINEL-2

3.1 Εισαγωγή

Η συστηματική παρακολούθηση της γήινης επιφάνειας αποτελεί θεμελιώδη προϋπόθεση για την κατανόηση περιβαλλοντικών, γεωργικών και κλιματικών διεργασιών. Στο πλαίσιο αυτό, τα δορυφορικά προγράμματα παρατήρησης της Γης έχουν αποκτήσει ιδιαίτερη σημασία, καθώς προσφέρουν δεδομένα μεγάλης χωρικής κάλυψης, συστηματικής επαναληψιμότητας και υψηλής επιστημονικής αξίας [21], [22]. Μεταξύ αυτών, το ευρωπαϊκό πρόγραμμα Copernicus αποτελεί μία από τις σημαντικότερες παγκόσμιες πρωτοβουλίες για την παροχή ανοικτών γεωχωρικών δεδομένων, υποστηρίζοντας τόσο την επιστημονική έρευνα όσο και ένα ευρύ φάσμα επιχειρησιακών εφαρμογών [21], [22].

Στο παρόν κεφάλαιο παρουσιάζεται το πρόγραμμα Copernicus και οι βασικές αποστολές της σειράς Sentinel, με ιδιαίτερη έμφαση στον δορυφόρο Sentinel-2, ο οποίος αποτελεί την κύρια πηγή δεδομένων της παρούσας εργασίας [19], [21]. Εξετάζονται τα τεχνικά χαρακτηριστικά της αποστολής, το όργανο MultiSpectral Instrument (MSI), οι φασματικές ζώνες του αισθητήρα και η σημασία τους για εφαρμογές γεωργικής παρακολούθησης και ανίχνευσης ασθενειών καλλιεργειών [19], [20].

3.2 Το πρόγραμμα Copernicus

Το Copernicus είναι το ευρωπαϊκό πρόγραμμα παρατήρησης της Γης, το οποίο αναπτύχθηκε από την Ευρωπαϊκή Ένωση σε συνεργασία με τον Ευρωπαϊκό Οργανισμό Διαστήματος (European Space Agency – ESA) [21], [22]. Βασικός του στόχος είναι η συστηματική συλλογή, επεξεργασία και διάθεση δεδομένων που αφορούν την ξηρά, τη θάλασσα, την ατμόσφαιρα, το κλίμα και την ασφάλεια, με σκοπό την υποστήριξη της επιστημονικής γνώσης, της δημόσιας πολιτικής και των επιχειρησιακών εφαρμογών [21].

Η σημασία του Copernicus έγκειται όχι μόνο στην ποιότητα των δεδομένων του, αλλά και στην πολιτική ανοικτής πρόσβασης που το χαρακτηρίζει [21], [22]. Η δυνατότητα ελεύθερης χρήσης δορυφορικών δεδομένων υψηλής ποιότητας έχει ενισχύσει σημαντικά την ανάπτυξη εφαρμογών τηλεπισκόπησης σε ερευνητικό, διοικητικό και παραγωγικό επίπεδο. Ειδικότερα στον γεωργικό τομέα, η διάθεση αυτών των δεδομένων επιτρέπει την ανάπτυξη μεθοδολογιών για την παρακολούθηση της βλάστησης, την εκτίμηση της κατάστασης των καλλιεργειών, τον εντοπισμό χωρικών ανωμαλιών και την υποστήριξη πρακτικών γεωργίας ακριβείας [19], [21].

Το πρόγραμμα βασίζεται σε δύο κύριους πυλώνες: αφενός στις δορυφορικές αποστολές της σειράς Sentinel και αφετέρου σε επίγειες, αερομεταφερόμενες ή θαλάσσιες μετρήσεις αναφοράς (in situ observations), οι οποίες συμπληρώνουν και επικυρώνουν τη δορυφορική πληροφορία [21], [22]. Οι υπηρεσίες του Copernicus καλύπτουν πολλούς θεματικούς τομείς, όπως η παρακολούθηση ξηράς, η παρακολούθηση θαλάσσιου περιβάλλοντος, η παρακολούθηση ατμόσφαιρας, η κλιματική αλλαγή, η διαχείριση εκτάκτων αναγκών και η ασφάλεια [21].

3.3 Οι αποστολές Sentinel

Οι αποστολές Sentinel αποτελούν τη βασική δορυφορική υποδομή του προγράμματος Copernicus [21], [22]. Κάθε αποστολή έχει σχεδιαστεί ώστε να καλύπτει διαφορετικές ανάγκες παρατήρησης της Γης, χρησιμοποιώντας διαφορετικού τύπου αισθητήρες και προσφέροντας εξειδικευμένα προϊόντα δεδομένων [21].

Η σειρά Sentinel περιλαμβάνει αποστολές που παρέχουν δεδομένα ραντάρ, οπτικά πολυφασματικά δεδομένα, θερμική πληροφορία και παρατηρήσεις σχετικές με ατμοσφαιρικές και θαλάσσιες παραμέτρους. Η πολυμορφία αυτή επιτρέπει την ολοκληρωμένη παρακολούθηση ενός μεγάλου εύρους φυσικών και ανθρωπογενών διεργασιών [21], [22]. Στο πλαίσιο της παρούσας εργασίας, το κύριο ενδιαφέρον εστιάζει στον Sentinel-2, ωστόσο κρίνεται σκόπιμη η σύντομη παρουσίαση και άλλων βασικών αποστολών, ώστε να αποτυπωθεί το ευρύτερο πλαίσιο της ευρωπαϊκής δορυφορικής υποδομής.

3.3.1 Sentinel-1

Η αποστολή Sentinel-1 αποτελείται από δορυφόρους εξοπλισμένους με αισθητήρες ραντάρ συνθετικού ανοίγματος (Synthetic Aperture Radar – SAR), οι οποίοι λειτουργούν στη ζώνη C του μικροκυματικού φάσματος [21]. Σε αντίθεση με τους οπτικούς αισθητήρες, τα δεδομένα SAR μπορούν να συλλέγονται ανεξάρτητα από την παρουσία νεφών και από τις συνθήκες φωτισμού, γεγονός που τα καθιστά ιδιαίτερα χρήσιμα για επιχειρησιακές εφαρμογές συνεχούς παρακολούθησης [21].

Τα δεδομένα του Sentinel-1 χρησιμοποιούνται σε εφαρμογές όπως η παρακολούθηση πλημμυρών, η ανίχνευση μετακινήσεων της επιφάνειας, η χαρτογράφηση χρήσεων γης και η εκτίμηση της υγρασίας του εδάφους [21]. Στον γεωργικό τομέα, το ραντάρ μπορεί να λειτουργήσει συμπληρωματικά προς τα οπτικά δεδομένα, προσφέροντας πληροφορίες για τη δομή της βλάστησης και τις επιφανειακές συνθήκες του εδάφους, ιδίως όταν οι οπτικές λήψεις περιορίζονται από νέφη [21].

3.3.2 Sentinel-2

Η αποστολή Sentinel-2 αποτελείται από δύο δορυφόρους, τους Sentinel-2A και Sentinel-2B, οι οποίοι φέρουν πολυφασματικό οπτικό αισθητήρα και έχουν σχεδιαστεί κυρίως για την παρακολούθηση της ξηράς, της βλάστησης, των εσωτερικών υδάτων και των παράκτιων περιοχών [19], [21]. Η αποστολή παρέχει δεδομένα υψηλής χωρικής ανάλυσης, πλούσιας φασματικής πληροφορίας και συχνής επαναληψιμότητας λήψεων [19], [20], [25].

Ο Sentinel-2 είναι ιδιαίτερα σημαντικός για γεωργικές εφαρμογές, διότι συνδυάζει επαρκή χωρική ανάλυση για παρακολούθηση σε επίπεδο αγροτεμαχίου με φασματικές ζώνες ειδικά κατάλληλες για τη μελέτη της φυσιολογίας της βλάστησης [19]. Η ύπαρξη red-edge, εγγύς υπερύθρων και βραχέος υπερύθρου ζωνών επιτρέπει την αποτύπωση μεταβολών που σχετίζονται με τη συγκέντρωση χλωροφύλλης, τη δομή των φύλλων και την υδατική κατάσταση των φυτών [6], [19], [20]. Για τον λόγο αυτό, ο Sentinel-2 έχει εξελιχθεί σε βασικό εργαλείο για εφαρμογές γεωργίας ακριβείας, ταξινόμησης καλλιεργειών, ανίχνευσης φυτικού στρες και παρακολούθησης της υγείας των φυτών [19], [21].

3.3.3 Sentinel-3

Η αποστολή Sentinel-3 έχει σχεδιαστεί κυρίως για την παρακολούθηση των ωκεανών, της επιφανειακής θερμοκρασίας ξηράς και θάλασσας, του χρώματος των υδάτων και άλλων περιβαλλοντικών παραμέτρων μεγάλης κλίμακας [21]. Τα δεδομένα της είναι ιδιαίτερα χρήσιμα για κλιματικές και ωκεανογραφικές εφαρμογές, καθώς και για τη μελέτη θερμικών και βιοφυσικών διεργασιών σε περιφερειακό και παγκόσμιο επίπεδο [21].

Παρότι ο Sentinel-3 δεν αποτελεί την κύρια αποστολή για λεπτομερή παρακολούθηση καλλιεργειών σε επίπεδο αγροτεμαχίου, μπορεί να λειτουργήσει υποστηρικτικά σε εφαρμογές που σχετίζονται με θερμική καταπόνηση, περιβαλλοντικές συνθήκες και ευρύτερη παρακολούθηση της χερσαίας επιφάνειας [21].

3.4 Ο δορυφόρος Sentinel-2

Ο Sentinel-2 αποτελεί μία από τις σημαντικότερες αποστολές οπτικής τηλεπισκόπησης για εφαρμογές που σχετίζονται με τη βλάστηση, τη χρήση γης και τη γεωργική παρακολούθηση [19], [21]. Η αξία του για τη γεωργία δεν οφείλεται μόνο στη χωρική του ανάλυση, αλλά κυρίως στον συνδυασμό των φασματικών του ζωνών, οι οποίες επιτρέπουν την καταγραφή κρίσιμων φυσιολογικών χαρακτηριστικών των φυτών [19], [20].

Η καταλληλότητά του για την παρούσα εργασία είναι ιδιαίτερα εμφανής, καθώς οι φασματικές ζώνες του καλύπτουν το ορατό, το εγγύς υπέρυθρο και το βραχύ υπέρυθρο φάσμα, ενώ περιλαμβάνουν και εξειδικευμένες ζώνες red-edge [19], [20]. Ο συνδυασμός αυτός καθιστά εφικτή την ανίχνευση έμμεσων φασματικών ενδείξεων που σχετίζονται με φυτοπαθολογικές μεταβολές και γενικότερα με αποκλίσεις από τη φυσιολογική κατάσταση της βλάστησης [13], [19].

3.4.1 Τεχνικά χαρακτηριστικά της αποστολής

Η αποστολή Sentinel-2 αποτελείται από δύο δορυφόρους σε πολική, ηλιοσύγχρονη τροχιά, οι οποίοι λειτουργούν συνδυαστικά ώστε να προσφέρουν υψηλή συχνότητα επανάληψης λήψεων [19], [21]. Η επαναληψιμότητα αυτή είναι ιδιαίτερα σημαντική για γεωργικές εφαρμογές, στις οποίες η χρονική εξέλιξη της βλάστησης παίζει καθοριστικό ρόλο [5], [19].

Τα δεδομένα του Sentinel-2 παρέχονται με χωρική ανάλυση που φθάνει έως τα 10 m, επιτρέποντας την ανάλυση σε επίπεδο αγροτεμαχίου για πολλές εφαρμογές [19], [20]. Παράλληλα, η διαθεσιμότητα πολλών φασματικών ζωνών ενισχύει σημαντικά την ικανότητα εξαγωγής βιοφυσικής και γεωργικής πληροφορίας [19]. Η αποστολή έχει σχεδιαστεί με τρόπο ώστε να υποστηρίζει τόσο επιχειρησιακές όσο και ερευνητικές εφαρμογές, παρέχοντας συστηματικά και αναπαραγώγιμα δεδομένα σε παγκόσμια κλίμακα [21].

3.4.2 Το όργανο MultiSpectral Instrument (MSI)

Ο βασικός αισθητήρας του Sentinel-2 είναι το MultiSpectral Instrument (MSI), ένας πολυφασματικός αισθητήρας που καταγράφει την ανακλώμενη ηλιακή ακτινοβολία σε δεκατρείς φασματικές ζώνες [19], [20]. Οι ζώνες αυτές καλύπτουν το ορατό, το εγγύς υπέρυθρο και το βραχύ υπέρυθρο φάσμα και επιτρέπουν την παρατήρηση διαφορετικών φυσικών και βιολογικών ιδιοτήτων της επιφάνειας της Γης [19].

Το MSI έχει σχεδιαστεί με ιδιαίτερη έμφαση στην παρακολούθηση της ξηράς και της βλάστησης. Ένα από τα πιο σημαντικά χαρακτηριστικά του είναι η παρουσία εξειδικευμένων ζωνών red-edge, οι οποίες επιτρέπουν ακριβέστερη καταγραφή μεταβολών που σχετίζονται με τη συγκέντρωση χλωροφύλλης και με πρώιμα στάδια φυτικού στρες [19], [20]. Η φασματική ποικιλία του MSI προσφέρει σαφές πλεονέκτημα σε σχέση με αισθητήρες πιο περιορισμένου φασματικού εύρους, ιδιαίτερα σε εφαρμογές γεωργικής παρακολούθησης [19].

3.4.3 Φασματικές μπάντες του Sentinel-2

Ο Sentinel-2 διαθέτει συνολικά δεκατρείς φασματικές μπάντες, οι οποίες διαφοροποιούνται τόσο ως προς το φασματικό εύρος όσο και ως προς τη χωρική ανάλυση [19], [20]. Η πολυφασματική αυτή διάρθρωση επιτρέπει την εξαγωγή πληροφορίας σχετικής με διαφορετικά χαρακτηριστικά της επιφάνειας και ειδικότερα της βλάστησης [19].

Οι μπάντες του ορατού φάσματος σχετίζονται κυρίως με τη χρωματική πληροφορία και την απορρόφηση της ακτινοβολίας από τη χλωροφύλλη. Οι μπάντες της περιοχής red-edge είναι ιδιαίτερα χρήσιμες για την καταγραφή μεταβολών στη φυσιολογική κατάσταση των φυτών. Η περιοχή του εγγύς υπερύθρου συνδέεται περισσότερο με τη δομή του φυλλώματος και τη βιομάζα, ενώ οι μπάντες του βραχέος υπερύθρου παρέχουν πληροφορίες που σχετίζονται κυρίως με την υδατική κατάσταση των φυτικών ιστών και με δομικές μεταβολές [6], [19], [20].


Η συνδυαστική αξιοποίηση αυτών των φασματικών περιοχών είναι καθοριστικής σημασίας για εφαρμογές όπου επιδιώκεται όχι μόνο η γενική παρακολούθηση της βλάστησης αλλά και η ανίχνευση πιο λεπτών αποκλίσεων, όπως αυτές που σχετίζονται με φυτικό στρες ή ασθένειες [13], [19].

3.4.4 Χωρική και χρονική ανάλυση

Οι φασματικές ζώνες του Sentinel-2 δεν παρέχονται όλες στην ίδια χωρική ανάλυση. Ορισμένες διατίθενται στα 10 m, άλλες στα 20 m και ορισμένες στα 60 m [19], [20]. Η διαφοροποίηση αυτή αντικατοπτρίζει τη λειτουργική εξειδίκευση κάθε ζώνης και τον σχεδιασμό του αισθητήρα [19].

Για γεωργικές εφαρμογές, οι ζώνες των 10 m και 20 m είναι οι πιο χρήσιμες, καθώς παρέχουν συνδυασμό ικανοποιητικής χωρικής λεπτομέρειας και υψηλής βιοφυσικής αξίας [19], [20]. Η χρονική επαναληψιμότητα της αποστολής επιτρέπει τη συχνή παρακολούθηση των ίδιων περιοχών, γεγονός ιδιαίτερα σημαντικό για τη μελέτη της φαινολογίας των καλλιεργειών, της εξέλιξης του φυτικού στρες και της εμφάνισης ανωμαλιών στον χρόνο [5], [19].

Η χρονική διάσταση είναι κρίσιμη σε γεωργικές εφαρμογές, καθώς πολλές διαφοροποιήσεις δεν ερμηνεύονται επαρκώς από μία μόνο λήψη αλλά γίνονται σαφέστερες όταν εντάσσονται στο πλαίσιο της εξέλιξης της καλλιέργειας [5].



Σχήμα 3.1. Κατανομή των φασματικών μπαντών του Sentinel-2 στις περιοχές του ορατού, red-edge, NIR και SWIR, καθώς και η αντίστοιχη χωρική ανάλυσή τους.

3.4.5 Επιλεγμένες φασματικές μπάντες στην παρούσα εργασία

Στην παρούσα εργασία χρησιμοποιείται υποσύνολο των φασματικών μπαντών του Sentinel-2, το οποίο περιλαμβάνει τις B2, B3, B4, B5, B6, B7, B8, B8A, B11 και B12. Η επιλογή αυτή δεν είναι τυχαία, αλλά βασίζεται στη βιοφυσική σημασία των συγκεκριμένων ζωνών για την ανάλυση της βλάστησης και ειδικότερα για την αναγνώριση έμμεσων ενδείξεων φυτικού στρες και ασθενειών [19], [20].

Οι μπάντες B2, B3 και B4 αντιστοιχούν στο ορατό φάσμα και σχετίζονται κυρίως με τη χρωματική πληροφορία και τη συμπεριφορά της χλωροφύλλης. Η μπάντα B8 ανήκει στο εγγύς υπέρυθρο και είναι ιδιαίτερα χρήσιμη για την αποτύπωση της βιομάζας και της δομής του φυλλώματος. Οι μπάντες B5, B6, B7 και B8A καλύπτουν την περιοχή red-edge και είναι ιδιαίτερα ευαίσθητες σε μεταβολές της φυσιολογικής κατάστασης των φυτών, ενώ οι μπάντες B11 και B12, που ανήκουν στο βραχύ υπέρυθρο, παρέχουν κρίσιμη πληροφορία για την υδατική κατάσταση και τις δομικές μεταβολές των ιστών [6], [19], [20].

Αντίθετα, οι μπάντες B1, B9 και B10 δεν εντάσσονται στο τελικό σύνολο εισόδου του προτεινόμενου μοντέλου, είτε λόγω χαμηλότερης χωρικής ανάλυσης είτε επειδή σχετίζονται κυρίως με ατμοσφαιρικές εφαρμογές και όχι με λεπτομερή ανάλυση βλάστησης σε επίπεδο καλλιέργειας [19], [20].

Πέρα από τη χρήση του πλήρους αυτού συνόλου ζωνών, στην παρούσα εργασία εξετάζονται και επιμέρους φασματικοί συνδυασμοί, με στόχο να διερευνηθεί πειραματικά ποια τμήματα του φάσματος συμβάλλουν περισσότερο στην ταξινόμηση ασθενειών. Η ανάλυση αυτή δεν περιορίζεται στη

θεωρητική βιοφυσική σημασία των ζωνών, αλλά συνδυάζεται με επαναλαμβανόμενη πειραματική αξιολόγηση και ερμηνευτική ανάλυση μέσω band occlusion.

3.5 Εφαρμογές του Sentinel-2 στη γεωργία

Η συμβολή του Sentinel-2 στη γεωργία είναι ιδιαίτερα σημαντική, καθώς επιτρέπει τη συστηματική, επαναλαμβανόμενη και μεγάλης κλίμακας παρακολούθηση αγροτικών εκτάσεων με υψηλή φασματική πληροφόρηση [19], [21]. Η αξία του δεν περιορίζεται μόνο στη χαρτογράφηση των καλλιεργειών, αλλά επεκτείνεται στην παρακολούθηση της φυσιολογικής τους κατάστασης και στην υποστήριξη διαδικασιών λήψης αποφάσεων [19].

3.5.1 Παρακολούθηση καλλιεργειών

Μία από τις βασικότερες εφαρμογές του Sentinel-2 είναι η παρακολούθηση της ανάπτυξης των καλλιεργειών και η χαρτογράφηση διαφορετικών τύπων φυτικής κάλυψης [19], [21]. Μέσω της ανάλυσης της φασματικής υπογραφής και της χρονικής εξέλιξης των καλλιεργειών, είναι δυνατή η αναγνώριση τύπων καλλιέργειας, η εκτίμηση της φαινολογικής εξέλιξης και η ανάλυση διαφοροποιήσεων στη φυσιολογική τους κατάσταση [5], [19].

Η πληροφορία αυτή μπορεί να αξιοποιηθεί τόσο σε ερευνητικό όσο και σε επιχειρησιακό επίπεδο, για παράδειγμα σε εφαρμογές χαρτογράφησης αγροτεμαχίων, εκτίμησης παραγωγικού δυναμικού και υποστήριξης συστημάτων γεωργίας ακριβείας [19], [21].

3.5.2 Ανίχνευση στρες και ασθενειών

Η ανίχνευση φυτικού στρες και ασθενειών αποτελεί μία από τις πιο απαιτητικές αλλά και πιο σημαντικές γεωργικές εφαρμογές του Sentinel-2 [13], [19]. Οι μεταβολές που προκαλούνται από ασθένειες, υδατικό στρες ή θρεπτικές ανεπάρκειες επηρεάζουν τη φυσιολογία των φυτών και, κατά συνέπεια, τη φασματική τους απόκριση [6], [13]. Η πληροφορία αυτή αποτυπώνεται κυρίως στις ζώνες του κόκκινου, του red-edge, του εγγύς υπερύθρου και του βραχέος υπερύθρου [6], [19], [20].

Ιδιαίτερα χρήσιμες για τέτοιες εφαρμογές είναι οι μπάντες red-edge και SWIR, καθώς μπορούν να αναδείξουν αλλαγές στη συγκέντρωση χλωροφύλλης, στη δομή των φύλλων και στην περιεκτικότητα των φυτών σε νερό [6], [19], [20]. Ωστόσο, η αξιοποίηση αυτής της πληροφορίας απαιτεί κατάλληλες υπολογιστικές μεθόδους, καθώς οι μεταβολές που σχετίζονται με ασθένειες είναι συχνά έμμεσες, λεπτές και επηρεάζονται από πολλαπλούς παράγοντες [13], [15].

Συνεπώς, ο Sentinel-2 δεν προσφέρει απλώς εικόνες βλάστησης, αλλά ένα πλούσιο πολυφασματικό πεδίο πληροφορίας, το οποίο μπορεί να αποτελέσει τη βάση για την ανάπτυξη προηγμένων μοντέλων ανάλυσης και έγκαιρης ανίχνευσης γεωργικών ανωμαλιών [13], [19].

Κεφάλαιο 4ο: ΔΕΔΟΜΕΝΑ

4.1 Εισαγωγή

Η ανάπτυξη και η αξιολόγηση του προτεινόμενου συστήματος ανίχνευσης ασθενειών βασίστηκαν στη χρήση πολυφασματικών δορυφορικών δεδομένων Sentinel-2 [19], [20]. Τα δεδομένα αυτά παρέχουν πληροφορία υψηλής βιοφυσικής αξίας για τη φυσιολογική κατάσταση της βλάστησης και είναι κατάλληλα για εφαρμογές γεωργικής παρακολούθησης, ταξινόμησης καλλιεργειών και ανίχνευσης φυτικού στρες [19], [21].

Στο πλαίσιο της παρούσας εργασίας αξιοποιήθηκαν τρεις διακριτές κατηγορίες δεδομένων: ένα επισημασμένο σύνολο δεδομένων καλλιεργειών, ένα επισημασμένο σύνολο δεδομένων ασθενειών και ένα μεγάλο σύνολο μη επισημασμένων πολυφασματικών δεδομένων Sentinel-2. Η διάκριση αυτή είναι θεμελιώδης για την προτεινόμενη πολυσταδιακή μεθοδολογία, καθώς κάθε σύνολο δεδομένων επιτελεί διαφορετικό ρόλο στο pipeline εκπαίδευσης: τα μη επισημασμένα δεδομένα χρησιμοποιούνται για την αυτοεπιβλεπόμενη προεκπαίδευση, ενώ τα επισημασμένα σύνολα χρησιμοποιούνται για τη διαδοχική εξειδίκευση του μοντέλου σε καλλιέργειες και ασθένειες [10], [14].

Τα δεδομένα που χρησιμοποιήθηκαν στην παρούσα μελέτη προέρχονται από τον διαγωνισμό Beyond Visible Spectrum: AI for Agriculture 2026, ο οποίος φιλοξενείται στην πλατφόρμα Kaggle και εντάσσεται στο ευρύτερο πλαίσιο ερευνητικών προκλήσεων σχετικών με την αξιοποίηση τεχνητής νοημοσύνης και δεδομένων παρατήρησης της Γης για γεωργικές εφαρμογές [23]. Το συγκεκριμένο περιβάλλον παρείχε ένα ρεαλιστικό και απαιτητικό πλαίσιο αξιολόγησης, με δεδομένα πολυφασματικής τηλεπισκόπησης και προβλήματα ταξινόμησης που χαρακτηρίζονται από περιορισμένη διαθεσιμότητα labels και ανισορροπία κλάσεων [23].

4.2 Περιγραφή των συνόλων δεδομένων

Η παρούσα εργασία αξιοποιεί τρία κύρια σύνολα δεδομένων, τα οποία αντιστοιχούν στις τρεις βασικές λειτουργικές βαθμίδες της προτεινόμενης μεθοδολογίας. Το πρώτο αφορά την ταξινόμηση καλλιεργειών και χρησιμοποιείται ως ενδιάμεσο στάδιο γεωργικής εξειδίκευσης. Το δεύτερο αφορά την τελική ταξινόμηση ασθενειών και αποτελεί το βασικό supervised task της μελέτης. Το τρίτο περιλαμβάνει μη επισημασμένα πολυφασματικά δεδομένα και χρησιμοποιείται στο στάδιο της αυτοεπιβλεπόμενης προεκπαίδευσης [10], [14].

Η χρήση πολλαπλών συνόλων δεδομένων δεν αποτελεί απλώς τεχνική επιλογή, αλλά συνδέεται άμεσα με τη βασική ερευνητική υπόθεση της εργασίας: ότι η αποτελεσματική ανίχνευση ασθενειών σε πολυφασματικά δεδομένα μπορεί να ενισχυθεί όταν προηγείται εκμάθηση γενικών αναπαραστάσεων από μη επισημασμένα δεδομένα και στη συνέχεια γεωργική εξειδίκευση μέσω σχετικού supervised task [10], [14].

4.2.1 Σύνολο δεδομένων καλλιεργειών

Το σύνολο δεδομένων καλλιεργειών χρησιμοποιήθηκε στο δεύτερο στάδιο του pipeline, δηλαδή στην εποπτευόμενη εκπαίδευση για την ταξινόμηση τύπου καλλιέργειας. Ο ρόλος του συνόλου αυτού δεν περιορίζεται στην επίλυση ενός επιμέρους προβλήματος ταξινόμησης, αλλά λειτουργεί ως ενδιάμεσο βήμα προσαρμογής του προεκπαιδευμένου encoder σε γεωργικά χαρακτηριστικά [10].

Το σύνολο περιλαμβάνει πολυφασματικά δεδομένα Sentinel-2 από διαφορετικές γεωργικές περιοχές και καλύπτει τέσσερις βασικούς τύπους καλλιέργειας:

- Rice
- Maize
- Wheat
- Soybean

Κάθε δείγμα οργανώνεται σε μορφή πολυφασματικών patches και περιλαμβάνει πολλαπλές χρονικές λήψεις της ίδιας περιοχής. Με τον τρόπο αυτό, το σύνολο δεν αποτυπώνει μόνο τη στιγμιαία φασματική κατάσταση μιας καλλιέργειας, αλλά και τη χρονική της εξέλιξη κατά τη διάρκεια της καλλιεργητικής περιόδου [5]. Η χρονική αυτή πληροφορία είναι ιδιαίτερα σημαντική, καθώς διαφορετικές καλλιέργειες διακρίνονται όχι μόνο από τη φασματική τους υπογραφή σε μία χρονική στιγμή, αλλά και από τη φαινολογική δυναμική που εμφανίζουν στον χρόνο [5].


Η αξία του συνόλου καλλιεργειών έγκειται επομένως στο ότι επιτρέπει στο μοντέλο να μάθει χαρακτηριστικά σχετικά με τη μορφολογία, τη φυσιολογία και τη χρονική συμπεριφορά διαφορετικών φυτικών τύπων. Αυτή η γνώση θεωρείται κρίσιμη για το επόμενο στάδιο ανίχνευσης ασθενειών, όπου η φασματική έκφραση μιας προσβολής εξαρτάται σε σημαντικό βαθμό από την ίδια την καλλιέργεια στην οποία εκδηλώνεται [5], [10], [13].

4.2.2 Σύνολο δεδομένων ασθενειών

Το σύνολο δεδομένων ασθενειών αποτελεί το βασικό supervised σύνολο της εργασίας και χρησιμοποιείται στο τελικό στάδιο ταξινόμησης φυτοπαθολογικών κατηγοριών [23]. Περιλαμβάνει πολυφασματικά patches Sentinel-2 που αντιστοιχούν σε περιοχές όπου έχουν καταγραφεί συγκεκριμένες κατηγορίες προσβολών ή ασθενειών.

Οι τέσσερις κατηγορίες που εξετάζονται στην παρούσα εργασία είναι οι εξής:

- Aphid
- Blast
- RPH
- Rust



Σχήμα 4.1. Αντιπροσωπευτικά δείγματα πολυφασματικών patches σε φυσικό χρώμα (RGB σύνθεση των μπαντών B4-B3-B2) για τις τέσσερις υπό μελέτη κατηγορίες ασθενειών: Aphid, Blast, Rust και RPH.

Οι κατηγορίες αυτές επιλέγονται από το διαθέσιμο διαγνωστικό πλαίσιο και αντιπροσωπεύουν διαφορετικού τύπου προσβολές, οι οποίες επηρεάζουν με διαφορετικό τρόπο τη φυσιολογική κατάσταση των φυτών [13]. Η σημασία του συνόλου αυτού έγκειται στο ότι επιτρέπει την αξιολόγηση της ικανότητας του μοντέλου να διακρίνει φασματικές αποκλίσεις που σχετίζονται με διαφορετικές φυτοπαθολογικές καταστάσεις [13].

Πρέπει, ωστόσο, να υπογραμμιστεί ότι η ανίχνευση των κατηγοριών αυτών μέσω δεδομένων Sentinel-2 είναι έμμεση. Το μοντέλο δεν αναγνωρίζει άμεσα οπτικά συμπτώματα υψηλής χωρικής λεπτομέρειας, αλλά μαθαίνει να συσχετίζει πολυφασματικά πρότυπα με φυτοπαθολογικές κατηγορίες [13]. Συνεπώς, η ποιότητα και η ερμηνεία του συγκεκριμένου συνόλου δεδομένων είναι ιδιαίτερα κρίσιμες για τη συνολική αξιοπιστία της μελέτης.

Όπως φαίνεται στο Σχήμα 4.2, η οπτική διάκριση των ασθενειών από τις δορυφορικές εικόνες φυσικού χρώματος είναι εξαιρετικά δύσκολη για το ανθρώπινο μάτι, λόγω της μέσης χωρικής ανάλυσης και των παρόμοιων φασματικών αποκρίσεων των προσβεβλημένων ιστών. Αυτό υπογραμμίζει την ανάγκη

χρήσης τεχνικών βαθιάς μάθησης που αξιοποιούν ολόκληρο το πολυφασματικό εύρος, συμπεριλαμβανομένων των περιοχών red-edge και SWIR.

4.2.3 Ανισορροπία κλάσεων στο σύνολο δεδομένων

Ένα από τα βασικότερα χαρακτηριστικά του συνόλου ασθενειών είναι η έντονη ανισορροπία μεταξύ των κλάσεων. Οι διαθέσιμες κατηγορίες δεν εκπροσωπούνται από ισοδύναμο αριθμό δειγμάτων, με αποτέλεσμα ορισμένες να είναι σημαντικά πιο πολυπληθείς από άλλες [4], [9]. Το πρόβλημα αυτό είναι ιδιαίτερα συνηθισμένο σε πραγματικά γεωργικά datasets, όπου ορισμένες κατηγορίες προσβολής εμφανίζονται συχνότερα ή είναι ευκολότερο να καταγραφούν από άλλες [4].

Η ανισορροπία κλάσεων επηρεάζει άμεσα τη διαδικασία εκπαίδευσης, καθώς ένα μοντέλο τείνει να ευνοεί τις πολυπληθέστερες κατηγορίες και να υποεκπαιδεύεται στις σπανιότερες [4], [9], [24]. Ως αποτέλεσμα, η συνολική accuracy μπορεί να εμφανίζεται σχετικά υψηλή, ακόμη και όταν η απόδοση σε υποεκπροσωπούμενες κλάσεις είναι χαμηλή [9], [12]. Στην παρούσα εργασία, η παρατήρηση αυτή έχει ιδιαίτερη σημασία, διότι ο στόχος δεν είναι μόνο η επίτευξη υψηλής συνολικής ακρίβειας, αλλά η όσο το δυνατόν πιο ισορροπημένη αναγνώριση όλων των κατηγοριών.

Η έντονη ανισορροπία των κλάσεων αποτελεί, συνεπώς, μία από τις βασικές πειραματικές προκλήσεις της μελέτης και επηρεάζει τόσο τον σχεδιασμό της εκπαιδευτικής διαδικασίας όσο και την επιλογή των κατάλληλων μετρικών αξιολόγησης [4], [9], [12]. Για τον λόγο αυτό, δίνεται ιδιαίτερη έμφαση στη macro-F1 και εφαρμόζονται τεχνικές που αποσκοπούν στη μερική εξισορρόπηση της εκπαίδευσης [4], [9], [12].

4.2.4 Μη επισημασμένα δεδομένα Sentinel-2

Το τρίτο σύνολο δεδομένων αποτελείται από μεγάλο αριθμό μη επισημασμένων πολυφασματικών παρατηρήσεων Sentinel-2 και χρησιμοποιείται στο στάδιο της αυτοεπιβλεπόμενης προεκπαίδευσης [14]. Η αξιοποίησή του είναι καθοριστικής σημασίας για την παρούσα εργασία, καθώς επιτρέπει την εκμάθηση γενικών φασματικών και χωρικών αναπαραστάσεων χωρίς την ανάγκη ανθρώπινης επισημείωσης [14].

Η σημασία των μη επισημασμένων δεδομένων στην τηλεπισκόπηση είναι ιδιαίτερα μεγάλη, δεδομένου ότι η συλλογή αξιόπιστων labels είναι συνήθως χρονοβόρα, δαπανηρή και δύσκολη σε μεγάλη κλίμακα. Αντίθετα, η διαθεσιμότητα μη επισημασμένων δορυφορικών εικόνων είναι πολύ μεγαλύτερη [14]. Μέσω της αυτοεπιβλεπόμενης μάθησης, το μοντέλο μπορεί να αξιοποιήσει την αφθονία αυτών των δεδομένων για να μάθει πιο σταθερές και πιο μεταφέρσιμες αναπαραστάσεις, οι οποίες στη συνέχεια μπορούν να χρησιμοποιηθούν αποτελεσματικά σε downstream γεωργικά tasks [10], [14].

Στο πλαίσιο της παρούσας εργασίας, το μη επισημασμένο σύνολο δεδομένων δεν υποκαθιστά τα επισημασμένα δεδομένα, αλλά λειτουργεί συμπληρωματικά, ενισχύοντας τη δυνατότητα του μοντέλου να ξεκινά τη supervised εκπαίδευση από ένα πιο κατάλληλο και πληροφοριακά πλουσιότερο σημείο εκκίνησης [10], [14].

4.2.5 Φαινολογία καλλιιεργειών και χρονική δυναμική της βλάστησης

Η χρονική διάσταση των δεδομένων αποτελεί κρίσιμο στοιχείο της γεωργικής τηλεπισκόπησης. Η φαινολογία των καλλιιεργειών, δηλαδή η διαδοχή των αναπτυξιακών τους σταδίων, επηρεάζει άμεσα τη

φασματική τους συμπεριφορά [5]. Κατά συνέπεια, δύο δείγματα της ίδιας καλλιέργειας μπορεί να εμφανίζουν διαφορετική φασματική υπογραφή σε διαφορετικές χρονικές στιγμές, ακόμη και όταν βρίσκονται σε φυσιολογική κατάσταση [5].

Η αξιοποίηση πολλαπλών χρονικών λήψεων επιτρέπει την αποτύπωση αυτής της δυναμικής και διευκολύνει τη διάκριση μεταξύ φυσιολογικών μεταβολών ανάπτυξης και παθολογικών αποκλίσεων [5], [13]. Η πληροφορία αυτή είναι ιδιαίτερα χρήσιμη τόσο στο στάδιο ταξινόμησης καλλιεργειών όσο και στην ερμηνεία των δυσκολιών του τελικού task ανίχνευσης ασθενειών. Ειδικότερα, η χρονική εξέλιξη της βλάστησης μπορεί να λειτουργήσει ως πρόσθετο σήμα διαφοροποίησης μεταξύ κατηγοριών που εμφανίζουν παρόμοια στιγμιαία φασματικά χαρακτηριστικά [5].

Η ενσωμάτωση της χρονικής πληροφορίας αντανακλά τη βασική παραδοχή ότι η γεωργική κατάσταση μιας περιοχής δεν μπορεί να αποτιμηθεί πλήρως από μία μόνο δορυφορική λήψη, αλλά πρέπει να εντάσσεται στο ευρύτερο πλαίσιο της φαινολογικής εξέλιξης της καλλιέργειας [5].

4.3 Φασματικές μπάντες που χρησιμοποιούνται

Στην παρούσα εργασία αξιοποιείται υποσύνολο φασματικών ζωνών του Sentinel-2 που καλύπτουν διαφορετικές περιοχές του ηλεκτρομαγνητικού φάσματος και αποτυπώνουν συμπληρωματικές όψεις της φυσιολογίας της βλάστησης [19], [20]. Οι μπάντες αυτές οργανώνονται σε τέσσερις βασικές κατηγορίες: ορατό φάσμα, red-edge, εγγύς υπέρυθρο και βραχύ υπέρυθρο.

Η επιλογή των συγκεκριμένων φασματικών ζωνών βασίζεται στην τεκμηριωμένη χρησιμότητά τους για τη μελέτη της φυτικής υγείας, της δομής του φυλλώματος, της περιεκτικότητας σε νερό και γενικότερα των μεταβολών που σχετίζονται με στρες ή ασθένεια [6], [19], [20].

4.3.1 Μπάντες ορατού φάσματος

Οι μπάντες του ορατού φάσματος που χρησιμοποιούνται είναι οι B2 (Blue), B3 (Green) και B4 (Red). Οι ζώνες αυτές συνδέονται άμεσα με τη χρωματική πληροφορία και με τη συμπεριφορά της χλωροφύλλης, η οποία απορροφά έντονα την ακτινοβολία στο μπλε και στο κόκκινο και εμφανίζει αυξημένη ανάκλαση στο πράσινο [19], [20].

Οι μεταβολές στις συγκεκριμένες μπάντες είναι ιδιαίτερα σημαντικές για την αναγνώριση αλλαγών στη φωτοσυνθετική δραστηριότητα και στη γενικότερη φυσιολογική κατάσταση των φυτών [19]. Αν και από μόνες τους δεν επαρκούν για λεπτομερή διάκριση σύνθετων φυτοπαθολογικών κατηγοριών, αποτελούν βασικό τμήμα της συνολικής πολυφασματικής αναπαράστασης.

4.3.2 Μπάντες red-edge

Οι μπάντες B5, B6, B7 και B8A ανήκουν στην περιοχή red-edge και έχουν ιδιαίτερη σημασία για τη γεωργική τηλεπισκόπηση [19], [20]. Η περιοχή αυτή χαρακτηρίζεται από την απότομη μετάβαση της ανακλαστικότητας από το κόκκινο προς το εγγύς υπέρυθρο και είναι εξαιρετικά ευαίσθητη σε αλλαγές που σχετίζονται με τη συγκέντρωση χλωροφύλλης και τη φυσιολογική κατάσταση των φυτών [19], [20].

Η αξιοποίηση των μπαντών red-edge είναι ιδιαίτερα χρήσιμη για τον εντοπισμό λεπτών ή πρώιμων αποκλίσεων στη βλάστηση, οι οποίες ενδέχεται να μην είναι ακόμη εμφανείς στις συμβατικές μπάντες

του ορατού [19], [20]. Για τον λόγο αυτό, οι ζώνες αυτές έχουν κεντρικό ρόλο σε εφαρμογές ανίχνευσης στρες και θεωρούνται κρίσιμες και στην παρούσα εργασία [13], [19].

4.3.3 Εγγύς υπέρυθρο

Η μπάντα B8 αντιστοιχεί στο εγγύς υπέρυθρο και αποτελεί μία από τις σημαντικότερες ζώνες για την ανάλυση της βλάστησης [19]. Η υψηλή ανάκλαση της υγιούς βλάστησης σε αυτή την περιοχή σχετίζεται κυρίως με τη δομή των φύλλων και με την εσωτερική αρχιτεκτονική των φυτικών ιστών [19].

Μεταβολές στο εγγύς υπέρυθρο μπορούν να αντανακλούν αλλαγές στη βιομάζα, στη φυλλική δομή και στη συνολική κατάσταση του φυλλώματος [13], [19]. Κατά συνέπεια, η ζώνη αυτή παρέχει κρίσιμη πληροφορία τόσο για τη διάκριση καλλιεργειών όσο και για την αναγνώριση έμμεσων ενδείξεων φυτικού στρες.

4.3.4 Βραχύ υπέρυθρο

Οι μπάντες B11 και B12 ανήκουν στο βραχύ υπέρυθρο και σχετίζονται κυρίως με την περιεκτικότητα των φυτών σε νερό, αλλά και με ορισμένες δομικές μεταβολές των ιστών [6], [19], [20]. Η πληροφορία αυτή είναι ιδιαίτερα πολύτιμη σε εφαρμογές όπου ζητείται διάκριση μεταξύ φυσιολογικής κατάστασης και καταστάσεων στρες ή ασθένειας [6].

Σε αρκετές περιπτώσεις, οι μεταβολές που σχετίζονται με ασθένεια δεν αποτυπώνονται μόνο στη χλωροφύλλη ή στη δομή του φυλλώματος, αλλά και στην υδατική ισορροπία του φυτού [6], [13]. Επομένως, οι μπάντες του βραχέος υπέρυθρου ενισχύουν ουσιαστικά τη συνολική ικανότητα του μοντέλου να συλλαμβάνει σύνθετες φυσιολογικές αποκλίσεις.

4.4 Προεπεξεργασία δεδομένων

Η προεπεξεργασία των δορυφορικών δεδομένων αποτελεί ιδιαίτερα κρίσιμο στάδιο πριν από την εισαγωγή τους σε μοντέλα μηχανικής μάθησης. Στην περίπτωση των δεδομένων Sentinel-2, η προεπεξεργασία δεν περιορίζεται σε μία απλή διαδικασία μετασχηματισμού, αλλά αποσκοπεί στην ενοποίηση φασματικών ζωνών διαφορετικής χωρικής ανάλυσης, στη βελτίωση της συμβατότητας των δεδομένων με το μοντέλο και στη μείωση παραγόντων που μπορούν να εισαγάγουν αβεβαιότητα στη μάθηση [19], [20].

Στην παρούσα εργασία, η προεπεξεργασία περιλαμβάνει τρία βασικά στάδια: τη χωρική επαναδειγματοληψία των φασματικών ζωνών, τη δημιουργία patches και την κανονικοποίηση των τιμών εισόδου.

4.4.1 Χωρική επαναδειγματοληψία φασματικών μπαντών

Οι φασματικές μπάντες του Sentinel-2 δεν διατίθενται όλες στην ίδια χωρική ανάλυση. Οι μπάντες B2, B3, B4 και B8 παρέχονται στα 10 m, ενώ οι μπάντες B5, B6, B7, B8A, B11 και B12 στα 20 m [19], [20]. Για να χρησιμοποιηθούν οι ζώνες αυτές ως ενιαία πολυκαναλική είσοδος σε ένα συνελκτικό μοντέλο, είναι απαραίτητο να ευθυγραμμιστούν χωρικά και να αποκτήσουν κοινές διαστάσεις [19].

Στο πλαίσιο της παρούσας εργασίας, οι μπάντες των 20 m επαναδειγματοληπτήθηκαν στο χωρικό πλέγμα αναφοράς των 10 m, ώστε όλες οι χρησιμοποιούμενες ζώνες να έχουν κοινό σχήμα εισόδου. Η διαδικασία πραγματοποιήθηκε με bilinear interpolation. Πρέπει να τονιστεί ότι η επαναδειγματοληψία αυτή δεν αυξάνει την πραγματική χωρική πληροφορία των δεδομένων. Αντίθετα, παράγει παρεμβλλόμενες τιμές που επιτρέπουν τη χωρική ενοποίηση των επιμέρους ζωνών και τη συνδυαστική αξιοποίησή τους από το μοντέλο [19], [20].


Η συγκεκριμένη διαδικασία είναι αναγκαία για την κατασκευή πολυφασματικών tensors εισόδου και αποτελεί συνήθη πρακτική σε εφαρμογές βαθιάς μάθησης με δεδομένα Sentinel-2 [15], [19].

4.4.2 Έλεγχος καθαρότητας patches και πρόβλημα μικτών εικονοστοιχείων

Ένα από τα βασικά ζητήματα στη χρήση δορυφορικών δεδομένων μέσης χωρικής ανάλυσης είναι η παρουσία μικτών εικονοστοιχείων [1]. Ένα εικονοστοιχείο θεωρείται μικτό όταν η φασματική του υπογραφή προέρχεται από περισσότερους του ενός τύπους επιφάνειας, όπως για παράδειγμα καλλιέργεια, γυμνό έδαφος, δρόμο ή γειτονικό αγροτεμάχιο [1].

Το πρόβλημα αυτό αποκτά ιδιαίτερη σημασία σε γεωργικές εφαρμογές, όπου τα αγροτεμάχια μπορεί να είναι μικρού μεγέθους, ακανόνιστα ή ετερογενή. Ως αποτέλεσμα, ακόμη και όταν ένα patch αντιστοιχεί κυρίως σε μια συγκεκριμένη καλλιέργεια, είναι πιθανό να περιέχει πληροφορία από γειτονικές επιφάνειες ή από τμήματα με διαφορετική κατάσταση υγείας [1].

Η παρουσία μικτών εικονοστοιχείων εισάγει αναπόφευκτη αβεβαιότητα στη σχέση μεταξύ του φασματικού σήματος και της πραγματικής κατάστασης της καλλιέργειας. Αυτό μπορεί να οδηγήσει σε μείωση της καθαρότητας των φασματικών χαρακτηριστικών, σε αύξηση της ενδοκλασικής διακύμανσης και σε δυσκολία διάκρισης μεταξύ υγιών και προσβεβλημένων καταστάσεων [1]. Στην παρούσα εργασία, το ζήτημα αυτό αντιμετωπίζεται όχι με πλήρη εξάλειψη, η οποία δεν είναι πάντοτε εφικτή, αλλά με την αποδοχή του ως εγγενούς περιορισμού των δεδομένων και με την ανάπτυξη μοντέλου ικανού να μάθει ανθεκτικές αναπαραστάσεις υπό συνθήκες μερικής φασματικής ανάμειξης [1], [15].



Σχήμα 4.2. Παράδειγμα μικτού εικονοστοιχείου σε εικόνα Sentinel-2 και της αντίστοιχης μικτής φασματικής υπογραφής.

4.4.3 Δημιουργία patches

Οι δορυφορικές εικόνες αναλύονται σε μικρότερες χωρικές μονάδες, δηλαδή σε patches, τα οποία χρησιμοποιούνται ως είσοδος στα μοντέλα βαθιάς μάθησης [15]. Η πρακτική αυτή είναι ιδιαίτερα

διαδεδομένη στην επεξεργασία δορυφορικών δεδομένων, καθώς επιτρέπει τη μετατροπή μεγάλων και ετερογενών εικόνων σε τυποποιημένα δείγματα κατάλληλα για εκπαίδευση [3], [15].

Η χρήση patches προσφέρει πολλαπλά πλεονεκτήματα. Πρώτον, μειώνει την υπολογιστική πολυπλοκότητα, καθώς το μοντέλο επεξεργάζεται μικρότερες μονάδες δεδομένων αντί για ολόκληρες εικόνες. Δεύτερον, επιτρέπει την αύξηση του αριθμού των διαθέσιμων δειγμάτων εκπαίδευσης. Τρίτον, διευκολύνει την εκμάθηση τοπικών χωρικών και φασματικών προτύπων, τα οποία είναι ιδιαίτερα σημαντικά σε προβλήματα ανίχνευσης ανωμαλιών ή διαφοροποίησης μεταξύ κατηγοριών [3], [15].

Στην παρούσα εργασία, κάθε patch αντιμετωπίζεται ως βασική μονάδα μάθησης, στην οποία ενσωματώνεται τόσο η χωρική όσο και η φασματική πληροφορία της περιοχής ενδιαφέροντος.

4.4.4 Κανονικοποίηση δεδομένων

Πριν από την εισαγωγή των δεδομένων στο νευρωνικό δίκτυο εφαρμόζεται κανονικοποίηση των φασματικών τιμών. Η διαδικασία αυτή είναι ιδιαίτερα σημαντική στα πολυφασματικά δεδομένα, καθώς κάθε φασματική ζώνη ενδέχεται να έχει διαφορετικό εύρος τιμών, διαφορετική κατανομή και διαφορετική φυσική σημασία [19], [20].

Η κανονικοποίηση συμβάλλει στη σταθεροποίηση της εκπαίδευσης, στη βελτίωση της σύγκλισης του μοντέλου και στη μείωση της επίδρασης ακραίων τιμών ή ανισοτήτων κλίμακας μεταξύ των φασματικών καναλιών. Παράλληλα, επιτρέπει στο μοντέλο να μάθει πιο αποτελεσματικά σχέσεις μεταξύ καναλιών χωρίς να επηρεάζεται δυσανάλογα από απόλυτες διαφορές στις τιμές των ζωνών [15]. Για τον λόγο αυτό, η κανονικοποίηση αποτελεί αναπόσπαστο στάδιο της προεπεξεργασίας και κρίσιμο παράγοντα για την επιτυχή εκπαίδευση μοντέλων βαθιάς μάθησης σε πολυφασματικά δεδομένα Sentinel-2 [15], [19].

Κεφάλαιο 5ο: ΜΕΘΟΔΟΛΟΓΙΑ

5.1 Εισαγωγή

Η παρούσα εργασία προτείνει ένα πολυσταδιακό πλαίσιο βαθιάς μάθησης για την ανίχνευση ασθενειών καλλιεργειών με αξιοποίηση πολυφασματικών δορυφορικών δεδομένων Sentinel-2. Η βασική υπόθεση στην οποία στηρίζεται η προτεινόμενη μεθοδολογία είναι ότι η αποτελεσματική διάκριση φυτοπαθολογικών κατηγοριών σε ένα απαιτητικό και ανισόρροπο περιβάλλον δεδομένων μπορεί να βελτιωθεί όταν η εκπαίδευση του μοντέλου δεν ξεκινά απευθείας από το τελικό task, αλλά προηγείται σταδιακή εκμάθηση σε ευρύτερα και συναφή επίπεδα πληροφορίας [10], [14].

Συγκεκριμένα, η μεθοδολογία οργανώνεται σε τρία διαδοχικά στάδια. Στο πρώτο στάδιο πραγματοποιείται αυτοεπιβλεπόμενη προεκπαίδευση ενός πολυφασματικού encoder σε μεγάλο όγκο μη επισημασμένων δεδομένων Sentinel-2, με στόχο την εκμάθηση γενικών φασματικών και χωρικών αναπαραστάσεων της βλάστησης [14]. Στο δεύτερο στάδιο, ο προεκπαιδευμένος encoder μεταφέρεται σε πρόβλημα ταξινόμησης καλλιεργειών, ώστε να εξειδικευτεί σε χαρακτηριστικά που σχετίζονται με τη γεωργική φυσιολογία και τη φαινολογική εξέλιξη των φυτών [5], [10]. Στο τρίτο και τελικό στάδιο, το μοντέλο προσαρμόζεται περαιτέρω στο πρόβλημα ταξινόμησης ασθενειών, όπου καλείται να διακρίνει λεπτές και έμμεσες φασματικές αποκλίσεις που σχετίζονται με φυτοπαθολογικές κατηγορίες [10], [13].

Η διαδοχική αυτή στρατηγική επιτρέπει τη συνδυαστική αξιοποίηση μη επισημασμένων και επισημασμένων δεδομένων και επιδιώκει να ενισχύσει τη γενικευτική ικανότητα του συστήματος υπό συνθήκες περιορισμένης διαθεσιμότητας ground truth [10], [14]. Παράλληλα, αντανακλά την παραδοχή ότι η ανίχνευση ασθενειών από δορυφορικά δεδομένα δεν πρέπει να αντιμετωπίζεται ως απομονωμένο πρόβλημα, αλλά ως ανώτερο επίπεδο μιας ιεραρχικής διαδικασίας μάθησης που ξεκινά από τη γενική φασματική συμπεριφορά της βλάστησης, περνά από τη γεωργική εξειδίκευση και καταλήγει στη φυτοπαθολογική διάκριση [10], [14].

5.2 Συνολική αρχιτεκτονική του προτεινόμενου συστήματος

Η συνολική αρχιτεκτονική του συστήματος βασίζεται σε έναν κοινό πολυφασματικό encoder, ο οποίος επαναχρησιμοποιείται και εξειδικεύεται προοδευτικά σε όλα τα στάδια της μεθοδολογίας [10], [16]. Η κεντρική ιδέα είναι ότι ένα μοντέλο που έχει πρώτα μάθει να αναπαριστά γενικές φασματικές και χωρικές δομές από μεγάλο όγκο μη επισημασμένων δεδομένων μπορεί στη συνέχεια να αξιοποιήσει αποτελεσματικότερα τα περιορισμένα επισημασμένα δεδομένα των downstream εργασιών [10], [14].

Η συνολική ροή του συστήματος μπορεί να συνοψιστεί ως εξής:


Sentinel-2 data → preprocessing → self-supervised pretraining → crop classification training → disease classification fine-tuning

Στο πρώτο στάδιο, ο encoder εκπαιδεύεται μέσω αυτοεπιβλεπόμενης αντιθετικής μάθησης σε μη επισημασμένα πολυφασματικά δεδομένα [14], [17]. Στο δεύτερο στάδιο, τα βάρη του χρησιμοποιούνται ως αρχικοποίηση για ένα εποπτευόμενο μοντέλο ταξινόμησης καλλιεργειών με πολυχρονική είσοδο [10]. Στο τρίτο στάδιο, ο ήδη γεωργικά εξειδικευμένος encoder μεταφέρεται σε μοντέλο ταξινόμησης ασθενειών, όπου πραγματοποιείται τελική λεπτομερής προσαρμογή [10].

Η σχεδίαση αυτή παρουσιάζει τρία βασικά πλεονεκτήματα. Πρώτον, επιτρέπει την αξιοποίηση μεγάλου όγκου μη επισημασμένων δορυφορικών δεδομένων [14]. Δεύτερον, ενισχύει τη σταθερότητα της εκπαίδευσης και τη δυνατότητα γενίκευσης μέσω μεταφοράς γνώσης [10]. Τρίτον, υποστηρίζει τη σταδιακή εξειδίκευση των αναπαραστάσεων από γενικά χαρακτηριστικά της βλάστησης προς πιο εξειδικευμένα γεωργικά και φυτοπαθολογικά μοτίβα [10], [14].

Στο πλαίσιο αυτό, ο encoder λειτουργεί ως κοινός μηχανισμός εξαγωγής χαρακτηριστικών σε όλο το pipeline. Η λογική της διαδοχικής επαναχρησιμοποίησης του ίδιου πυρήνα μοντελοποίησης δεν είναι απλώς μια τεχνική ευκολία, αλλά ενσωματώνει τη βασική θεωρητική θέση της εργασίας: ότι η γνώση για τη βλάστηση, τις καλλιέργειες και τις ασθένειες πρέπει να οικοδομείται σταδιακά και όχι αποσπασματικά [10], [14].

Πέρα από την τελική ταξινομητική απόδοση, η παρούσα μεθοδολογία σχεδιάστηκε έτσι ώστε να επιτρέπει και τη φασματική ερμηνεία της συμπεριφοράς του μοντέλου. Για τον λόγο αυτό, το ίδιο πολυσταδιακό pipeline εφαρμόζεται σε διαφορετικούς συνδυασμούς φασματικών ζωνών Sentinel-2 [19], [20], ενώ στο πλήρες πολυφασματικό σχήμα πραγματοποιείται επιπλέον ανάλυση σημαντικότητας ζωνών μέσω band occlusion [28]. Με τον τρόπο αυτό, η μεθοδολογία δεν περιορίζεται στην πρόβλεψη της κατηγορίας ασθένειας, αλλά επιχειρεί να διερευνήσει ποια τμήματα της φασματικής πληροφορίας συμβάλλουν ουσιαστικά στη λήψη απόφασης του μοντέλου.



Σχήμα 5.1. Συνολική αρχιτεκτονική της προτεινόμενης πολυσταδιακής μεθοδολογίας.

5.3 Αυτοεπιβλεπόμενη μάθηση

Η αυτοεπιβλεπόμενη μάθηση αποτελεί το θεμελιώδες πρώτο στάδιο της προτεινόμενης μεθοδολογίας. Στην παρούσα εργασία, ο ρόλος της δεν είναι η άμεση πρόβλεψη κατηγοριών, αλλά η εκμάθηση

αναπαραστάσεων με υψηλή μεταφερσιμότητα, οι οποίες μπορούν στη συνέχεια να αξιοποιηθούν σε επιβλεπόμενα γεωργικά tasks [14].

Η επιλογή της αυτοεπιβλεπόμενης μάθησης είναι ιδιαίτερα κατάλληλη για την τηλεπισκόπηση, καθώς ο όγκος των διαθέσιμων μη επισημασμένων δορυφορικών δεδομένων είναι πολύ μεγαλύτερος από τον όγκο των δεδομένων με αξιόπιστες ετικέτες [14]. Επομένως, η προεκπαίδευση σε μη επισημασμένα δεδομένα λειτουργεί ως μηχανισμός εκμάθησης γενικών φασματικών και χωρικών δομών της βλάστησης, περιορίζοντας την εξάρτηση της συνολικής μεθοδολογίας από μικρά και ανισόρροπα σύνολα labels [14].

5.3.1 Προεκπαίδευση του encoder

Η διαδικασία προεκπαίδευσης βασίζεται στη χρήση μη επισημασμένων πολυφασματικών patches Sentinel-2. Για κάθε δείγμα είναι διαθέσιμες πολλαπλές χρονικές λήψεις από διαφορετικές ημερομηνίες, γεγονός που επιτρέπει στο μοντέλο να εκτεθεί όχι μόνο σε χωρική και φασματική πληροφορία, αλλά και σε στοιχεία χρονικής μεταβλητότητας της βλάστησης [5], [14].

Σε κάθε βήμα εκπαίδευσης επιλέγονται έως τέσσερις χρονικές παρατηρήσεις ανά δείγμα. Από κάθε παρατήρηση παράγονται δύο διαφορετικές επαυξημένες όψεις, οι οποίες χρησιμοποιούνται ως είσοδοι στην αντιθετική εκπαίδευση [14], [17]. Με τον τρόπο αυτό, το μοντέλο μαθαίνει να θεωρεί παρόμοιες τις αναπαραστάσεις που αντιστοιχούν στο ίδιο υποκείμενο δείγμα, παρότι έχουν υποστεί διαφορετικούς μετασχηματισμούς, ενώ παράλληλα διαχωρίζει δείγματα διαφορετικής προέλευσης [17].

Πριν από την έναρξη της εκπαίδευσης εφαρμόζεται κανονικοποίηση ανά φασματική ζώνη, με βάση εκτιμήσεις μέσου και τυπικής απόκλισης από τα δεδομένα εισόδου. Η διαδικασία αυτή είναι κρίσιμη, καθώς οι φασματικές ζώνες του Sentinel-2 εμφανίζουν διαφορετικές κατανομές και διαφορετικά εύρη τιμών [19], [20]. Χωρίς τέτοια κανονικοποίηση, το μοντέλο θα μπορούσε να επηρεάζεται δυσανάλογα από ζώνες με μεγαλύτερη αριθμητική κλίμακα, γεγονός που θα υποβάθμιζε την ποιότητα της μαθησιακής διαδικασίας.

Επιπλέον, η ύπαρξη πολλαπλών χρονικών λήψεων επιτρέπει στο SSL στάδιο να αξιοποιεί όχι μόνο στατικές πολυφασματικές δομές, αλλά και μεταβολές που παρατηρούνται φυσιολογικά στην καλλιέργεια μέσα στον χρόνο [5]. Με τον τρόπο αυτό, ο encoder αποκτά από πολύ νωρίς επαφή με τη δυναμική φύση των γεωργικών δεδομένων, κάτι που είναι ιδιαίτερα σημαντικό για downstream tasks που σχετίζονται με καλλιέργειες και ασθένειες.

5.3.2 Αρχιτεκτονική του SSL μοντέλου

Η αρχιτεκτονική του πρώτου σταδίου αποτελείται από δύο βασικά μέρη: τον πολυφασματικό encoder και μία κεφαλή προβολής. Ο encoder είναι προσαρμοσμένος ώστε να δέχεται ως είσοδο δέκα φασματικές ζώνες του Sentinel-2, αντί των τριών καναλιών RGB που χρησιμοποιούνται συνήθως σε εφαρμογές υπολογιστικής όρασης [16]. Με τον τρόπο αυτό, το μοντέλο έχει άμεση πρόσβαση στην πλήρη πολυφασματική πληροφορία που σχετίζεται με τη φυσιολογία της βλάστησης [19], [20].

Ο encoder λειτουργεί ως βασικός μηχανισμός εξαγωγής χαρακτηριστικών, μετατρέποντας κάθε πολυφασματικό patch σε λανθάνουσα αναπαράσταση. Στο στάδιο της αυτοεπιβλεπόμενης μάθησης, η αναπαράσταση αυτή μετασχηματίζεται περαιτέρω μέσω της κεφαλής προβολής σε χώρο ενσωματώσεων κατάλληλο για αντιθετική βελτιστοποίηση [17]. Η διάκριση αυτή είναι σημαντική, διότι

επιτρέπει την εκπαίδευση του contrastive objective στον χώρο προβολής, διατηρώντας παράλληλα τον encoder προσανατολισμένο στην εκμάθηση πιο γενικών και επαναχρησιμοποιήσιμων χαρακτηριστικών [14], [17].

Στην πράξη, η κεφαλή προβολής λειτουργεί ως ενδιάμεσος μετασχηματισμός που επιτρέπει στο μοντέλο να προσαρμόζει τον χώρο ενσωματώσεων στις ανάγκες του contrastive objective, χωρίς να «φορτώνει» όλη αυτή τη βελτιστοποίηση απευθείας στον χώρο χαρακτηριστικών του encoder. Αυτό είναι ιδιαίτερα χρήσιμο όταν ο τελικός στόχος είναι η μεταφορά των learned representations σε επόμενα επιβλεπόμενα στάδια [14], [17].


5.3.3 Αντιθετική μάθηση

Η εκπαίδευση στο στάδιο της αυτοεπιβλεπόμενης μάθησης πραγματοποιείται μέσω αντιθετικής μάθησης. Στόχος της διαδικασίας είναι να μειώνεται η απόσταση μεταξύ αναπαραστάσεων που προέρχονται από διαφορετικές όψεις του ίδιου δείγματος και να αυξάνεται η απόσταση μεταξύ αναπαραστάσεων που αντιστοιχούν σε διαφορετικά δείγματα [17].

Στην παρούσα εργασία χρησιμοποιείται η συνάρτηση απώλειας **SupConLoss** σε αυτοεπιβλεπόμενη διάταξη [17]. Στην πράξη, διαφορετικές επανημιμένες όψεις του ίδιου δείγματος λειτουργούν ως θετικά ζεύγη, ενώ όψεις διαφορετικών δειγμάτων λειτουργούν ως αρνητικά παραδείγματα [17]. Το αποτέλεσμα είναι η εκμάθηση αναπαραστάσεων που είναι ταυτόχρονα σταθερές απέναντι σε γεωμετρικές μεταβολές και επαρκώς διακριτές ώστε να διαφοροποιούν διαφορετικά παραδείγματα [17].

Η αντιθετική μάθηση θεωρείται ιδιαίτερα κατάλληλη για πολυφασματικά δεδομένα τηλεπισκόπησης, καθώς επιτρέπει την εκμάθηση γενικών πολυκαναλικών δομών χωρίς την ανάγκη labels και δημιουργεί ισχυρή βάση για μεταφορά γνώσης στα επόμενα στάδια [14]. Ειδικά σε περιβάλλοντα όπου το κόστος επισημείωσης είναι υψηλό και ο όγκος των μη επισημασμένων δεδομένων μεγάλος, η αντιθετική προσέγγιση καθίσταται ιδιαίτερα ελκυστική [14].

Πέρα από το τεχνικό της πλεονέκτημα, η αντιθετική μάθηση εισάγει και μια ουσιαστική μεθοδολογική μετατόπιση: αντί το μοντέλο να μαθαίνει απευθείας να προβλέπει κλάσεις από την αρχή, μαθαίνει πρώτα να οργανώνει τον χώρο αναπαράστασης με τρόπο που αποτυπώνει εσωτερικές ομοιότητες και διαφορές στα δεδομένα. Η οργάνωση αυτή είναι ακριβώς που καθιστά εφικτή την αποτελεσματική μεταφορά γνώσης στα επόμενα στάδια [10], [14], [17].



Σχήμα 5.2. Σχηματική απεικόνιση της αυτοεπιβλεπόμενης contrastive εκπαίδευσης με χρήση SupConLoss.

5.3.4 Στρατηγική επαυξήσεων δεδομένων

Η δημιουργία πολλαπλών όψεων του ίδιου δείγματος αποτελεί κρίσιμο στοιχείο της αντιθετικής μάθησης [17]. Στην παρούσα εργασία εφαρμόζονται κυρίως γεωμετρικές επαυξήσεις που διατηρούν τη φασματική συνέπεια των δεδομένων και δεν αλλοιώνουν την ερμηνευσιμότητα των πολυφασματικών τιμών [14].

Οι βασικοί μετασχηματισμοί που χρησιμοποιούνται είναι:

- τυχαία περικοπή με αλλαγή κλίμακας,
- οριζόντια αναστροφή,
- κατακόρυφη αναστροφή,
- περιστροφή κατά πολλαπλάσια των 90° .

Η επιλογή αυτών των επαυξήσεων βασίζεται στην ανάγκη να ενισχυθεί η χωρική ανθεκτικότητα του μοντέλου χωρίς να εισαχθούν τεχνητές φασματικές παραμορφώσεις [14]. Σε αντίθεση με τις τυπικές RGB εφαρμογές, όπου χρησιμοποιούνται συχνά έντονοι χρωματικοί μετασχηματισμοί, στα πολυφασματικά δεδομένα τέτοιοι χειρισμοί ενδέχεται να αλλοιώσουν το φυσικό νόημα των καναλιών [14], [19].

Η απόφαση αυτή είναι ιδιαίτερα σημαντική για την αξιοπιστία της μεθοδολογίας. Επειδή κάθε φασματική μπάντα του Sentinel-2 αντιστοιχεί σε συγκεκριμένη φυσική ιδιότητα της επιφάνειας, τυχόν ακατάλληλοι μετασχηματισμοί θα μπορούσαν να εισαγάγουν τεχνητά πρότυπα που δεν αντανακλούν πραγματικές καταστάσεις βλάστησης [19], [20]. Κατά συνέπεια, οι επαυξήσεις πρέπει να επιλέγονται με πολύ μεγαλύτερη προσοχή σε σχέση με τις κλασικές εφαρμογές υπολογιστικής όρασης.

5.4 Εκπαίδευση μοντέλου ταξινόμησης καλλιέργειας

Μετά την ολοκλήρωση της αυτοεπιβλεπόμενης προεκπαίδευσης, ο encoder μεταφέρεται σε ένα εποπτευόμενο πρόβλημα ταξινόμησης καλλιεργειών. Το στάδιο αυτό λειτουργεί ως ενδιάμεσο επίπεδο γεωργικής εξειδίκευσης και γεφυρώνει τη γενική φασματική γνώση που αποκτήθηκε από τα μη επισημασμένα δεδομένα με το τελικό πρόβλημα της ανίχνευσης ασθενειών [10], [14].

Η επιλογή αυτού του ενδιάμεσου βήματος βασίζεται στην παραδοχή ότι η διάκριση φυτοπαθολογικών κατηγοριών είναι ευκολότερη όταν το μοντέλο έχει ήδη μάθει να αναγνωρίζει τις βασικές φασματικές και χρονικές ιδιότητες διαφορετικών καλλιεργειών [5], [10]. Με άλλα λόγια, η γνώση του φυτικού υποβάθρου θεωρείται προϋπόθεση για την πιο αξιόπιστη ερμηνεία των παθολογικών αποκλίσεων [13].

5.4.1 Μεταφορά μάθησης από το SSL στάδιο

Στο στάδιο ταξινόμησης καλλιέργειας, τα βάρη του encoder που προέκυψαν από την αυτοεπιβλεπόμενη προεκπαίδευση χρησιμοποιούνται ως αρχική κατάσταση του νέου μοντέλου. Η στρατηγική αυτή αποτελεί εφαρμογή μεταφοράς μάθησης, καθώς η γνώση που αποκτήθηκε από μη επισημασμένα πολυφασματικά δεδομένα μεταφέρεται σε ένα σχετικό αλλά εποπτευόμενο γεωργικό πρόβλημα [10], [14].

Η χρήση προεκπαιδευμένων βαρών παρέχει πολλαπλά οφέλη. Επιταχύνει τη σύγκλιση, βελτιώνει τη σταθερότητα της εκπαίδευσης και αυξάνει την πιθανότητα το μοντέλο να μάθει ουσιαστικές γεωργικές αναπαραστάσεις αντί να ξεκινήσει από τυχαία αρχικοποίηση [10]. Στην παρούσα εργασία, η μεταφορά μάθησης δεν λειτουργεί απλώς ως τεχνική βελτιστοποίησης, αλλά ως βασικός μηχανισμός διαδοχικής εξειδίκευσης των χαρακτηριστικών [10].

Επιπλέον, η μετάβαση από το SSL στο crop stage επιτρέπει στον encoder να μετασχηματίσει τις γενικές πολυφασματικές αναπαραστάσεις σε περισσότερο «γεωργικά» χαρακτηριστικά. Δηλαδή, το μοντέλο παύει να οργανώνει τον χώρο χαρακτηριστικών μόνο βάσει γενικών ομοιοτήτων και αρχίζει να τον οργανώνει και με όρους σχετικούς με τύπους καλλιεργειών [5], [10].

5.4.2 Χρονική μοντελοποίηση και temporal mean pooling

Το στάδιο ταξινόμησης καλλιεργειών αξιοποιεί πολυχρονικά δεδομένα. Για κάθε δείγμα χρησιμοποιούνται τέσσερις χρονικές λήψεις, οι οποίες αντιστοιχούν σε διαφορετικές ημερομηνίες παρατήρησης της ίδιας περιοχής [5], [27]. Ο encoder εφαρμόζεται ανεξάρτητα σε κάθε χρονική λήψη, παράγοντας ξεχωριστή αναπαράσταση χαρακτηριστικών για καθεμία.

Στη συνέχεια, οι επιμέρους αναπαραστάσεις συνδυάζονται μέσω μέσου όρου στον χρονικό άξονα (**temporal mean pooling**), ώστε να προκύψει μία ενιαία αναπαράσταση του δείγματος. Η τελική αυτή αναπαράσταση τροφοδοτεί μία κεφαλή ταξινόμησης, η οποία προβλέπει την κατηγορία καλλιέργειας.

Η επιλογή του temporal mean pooling αποτελεί σχετικά απλή αλλά λειτουργική στρατηγική χρονικής ενοποίησης. Επιτρέπει στο μοντέλο να ενσωματώνει πληροφορία από πολλαπλές χρονικές στιγμές χωρίς την προσθήκη πιο σύνθετων ακολουθιακών ή attention-based μηχανισμών. Με τον τρόπο αυτό αξιοποιείται η φαινολογική εξέλιξη των καλλιεργειών, η οποία λειτουργεί ως σημαντικό διακριτικό χαρακτηριστικό μεταξύ διαφορετικών crop classes [5].

Παρότι η προσέγγιση αυτή δεν αποτυπώνει ρητά σύνθετες χρονικές εξαρτήσεις, είναι υπολογιστικά αποδοτική, απλή στην υλοποίηση και επαρκώς εκφραστική για το συγκεκριμένο πρόβλημα. Επιπλέον,

λειτουργεί ως σταθερό ενδιάμεσο βήμα πριν από το πολύ πιο απαιτητικό disease stage, στο οποίο η έμφαση μετατοπίζεται από τη χρονική διαφοροποίηση των καλλιεργειών στη διάκριση φυτοπαθολογικών αποκλίσεων [10], [13].

5.4.3 Προσαρμογή στο γεωργικό domain

Το στάδιο ταξινόμησης καλλιεργειών λειτουργεί ως ενδιάμεσο επίπεδο domain adaptation [10]. Μέσω της εκπαίδευσης αυτής, ο encoder παύει να αναπαριστά απλώς γενικές πολυφασματικές δομές και αρχίζει να εστιάζει σε χαρακτηριστικά που σχετίζονται ειδικότερα με τη γεωργική πραγματικότητα, όπως:

- η συγκέντρωση χλωροφύλλης,
- η δομή της φυτικής κόμης,
- η φαινολογική εξέλιξη,
- η χρονική μεταβολή της φασματικής απόκρισης [5], [19].

Η πληροφορία αυτή είναι κρίσιμη για το επόμενο στάδιο, καθώς η φασματική έκφραση μιας ασθένειας εξαρτάται από την καλλιέργεια στην οποία εκδηλώνεται [13]. Συνεπώς, η προηγούμενη εκμάθηση γεωργικών χαρακτηριστικών συμβάλλει στη δημιουργία ενός πιο κατάλληλου feature space για την τελική φυτοπαθολογική διάκριση [10].

Η επιλογή ενός τέτοιου ενδιάμεσου σταδίου είναι θεωρητικά και πρακτικά ισχυρή. Θεωρητικά, επειδή γεφυρώνει τη μετάβαση από γενικές representations σε problem-specific knowledge. Πρακτικά, επειδή περιορίζει το βάρος που θα έπρεπε να σηκώνει το τελικό disease stage μόνο του, αν ξεκινούσε από πολύ γενικά ή και τυχαία χαρακτηριστικά [10], [14].

5.5 Εκπαίδευση μοντέλου ανίχνευσης ασθενειών

Το τρίτο και τελικό στάδιο της προτεινόμενης μεθοδολογίας αφορά την ταξινόμηση ασθενειών. Στο σημείο αυτό, ο encoder έχει ήδη αποκτήσει δύο επίπεδα γνώσης: γενική πολυφασματική γνώση από το SSL στάδιο και γεωργικά εξειδικευμένη γνώση από το crop stage [10], [14]. Η τελική εκπαίδευση στο disease task αξιοποιεί αυτή τη συσσωρευμένη γνώση για την αναγνώριση κατηγοριών προσβολής [10].

Το συγκεκριμένο πρόβλημα είναι το πιο απαιτητικό από τα τρία στάδια, καθώς το μοντέλο καλείται να διακρίνει λεπτές και συχνά επικαλυπτόμενες φασματικές αποκλίσεις που σχετίζονται με διαφορετικές φυτοπαθολογικές καταστάσεις [13]. Επιπλέον, το διαθέσιμο σύνολο δεδομένων είναι μικρότερο και εμφανίζει έντονη ανισορροπία μεταξύ των κλάσεων [4], [9].

5.5.1 Λεπτομερής προσαρμογή του encoder

Στο disease stage, τα βάρη του encoder δεν διατηρούνται παγωμένα, αλλά προσαρμόζονται περαιτέρω μέσω λεπτομερούς προσαρμογής. Με τον τρόπο αυτό, οι γενικές και γεωργικά εξειδικευμένες αναπαραστάσεις που έχουν μάθει τα προηγούμενα στάδια εξειδικεύονται επιπλέον ώστε να ανταποκρίνονται στις απαιτήσεις του τελικού προβλήματος [10].

Η λεπτομερής προσαρμογή επιτρέπει στο μοντέλο να εστιάζει σε πιο σύνθετα πρότυπα που σχετίζονται με μεταβολές στη χλωροφύλλη, στη δομή του φυλλώματος και στην υδατική κατάσταση των φυτών [6], [13]. Πρέπει να σημειωθεί ότι το μοντέλο δεν αναγνωρίζει την ασθένεια ως άμεσο οπτικό αντικείμενο,

αλλά μαθαίνει να διακρίνει φασματικά αποτυπώματα φυσιολογικών αποκλίσεων που συσχετίζονται με συγκεκριμένες κατηγορίες προσβολής [13].

Αυτό σημαίνει ότι το disease fine-tuning λειτουργεί σε ένα πολύ πιο λεπτό επίπεδο διαφοροποίησης σε σχέση με τα προηγούμενα στάδια. Το ζητούμενο δεν είναι πλέον να αναγνωριστεί γενικά «τι είδους βλάβηση» ή «ποια καλλιέργεια» υπάρχει, αλλά να απομονωθούν μικρές φασματικές αποκλίσεις που ενδέχεται να αντιστοιχούν σε διαφορετικά φυτοπαθολογικά μοτίβα [13]. Η επιτυχία αυτού του σταδίου εξαρτάται, επομένως, σε μεγάλο βαθμό από την ποιότητα της γνώσης που έχει ήδη αποκτηθεί στα δύο προηγούμενα στάδια [10], [14].

5.5.2 Αντιμετώπιση ανισορροπίας κλάσεων

Ένα από τα σημαντικότερα προβλήματα του συνόλου δεδομένων ασθενειών είναι η έντονη ανισορροπία μεταξύ των διαθέσιμων κατηγοριών. Ορισμένες κλάσεις περιλαμβάνουν σαφώς περισσότερα δείγματα από άλλες, γεγονός που μπορεί να οδηγήσει το μοντέλο σε μεροληψία υπέρ των πολυπληθέστερων κατηγοριών [4], [9].

Για την αντιμετώπιση του ζητήματος χρησιμοποιείται **Weighted Random Sampler**, ο οποίος αυξάνει τη συχνότητα δειγματοληψίας των υποεκπροσωπούμενων κλάσεων κατά τη διάρκεια της εκπαίδευσης. Η στρατηγική αυτή επιτρέπει στο μοντέλο να εκτεθεί πιο συχνά σε σπάνιες κατηγορίες και να μάθει καλύτερα τα χαρακτηριστικά τους, χωρίς να απαιτείται τεχνητή αύξηση του όγκου των δεδομένων [4], [9].

Η επιλογή της συγκεκριμένης μεθόδου είναι πρακτική και αποτελεσματική, καθώς επιτυγχάνει μερική εξισορρόπηση της εκπαίδευσης διατηρώντας ταυτόχρονα ανέπαφη τη βασική δομή του dataset. Παρά το γεγονός ότι δεν εξαλείφει πλήρως το πρόβλημα της ανισορροπίας, περιορίζει σε σημαντικό βαθμό τη δυσανάλογη επίδραση των πολυπληθέστερων κατηγοριών στη διαδικασία βελτιστοποίησης [4], [9].

5.5.3 Συνάρτηση απώλειας και κριτήριο επιλογής μοντέλου

Στο τελικό στάδιο ταξινόμησης ασθενειών χρησιμοποιείται η συνάρτηση απώλειας **CrossEntropyLoss**, η οποία αποτελεί τυπική επιλογή για προβλήματα πολυκλασικής ταξινόμησης. Παρότι η βελτιστοποίηση βασίζεται στην cross-entropy, η αξιολόγηση της απόδοσης δεν περιορίζεται στην accuracy, αλλά δίνει έμφαση κυρίως στη **macro-F1** [12].

Η επιλογή αυτή είναι κρίσιμη λόγω της ανισορροπίας κλάσεων. Η accuracy μπορεί να επηρεάζεται δυσανάλογα από τις πολυπληθέστερες κατηγορίες και συνεπώς δεν αποτυπώνει πάντοτε την πραγματική ισορροπία της επίδοσης [4], [9], [12]. Αντίθετα, η macro-F1 αποδίδει ίσο βάρος σε όλες τις κατηγορίες και παρέχει πιο δίκαιη εικόνα της ικανότητας του μοντέλου να αναγνωρίζει και τις σπάνιες κλάσεις [9], [12].

Για τον λόγο αυτό, το βέλτιστο checkpoint του disease stage επιλέγεται με βάση τη μέγιστη τιμή validation macro-F1 και όχι αποκλειστικά με βάση τη μικρότερη loss ή τη μέγιστη accuracy. Η απόφαση αυτή είναι μεθοδολογικά σημαντική, διότι ευθυγραμμίζει το κριτήριο επιλογής μοντέλου με τον πραγματικό στόχο της εργασίας, που είναι η ισορροπημένη αναγνώριση όλων των κατηγοριών ασθένειας και όχι απλώς η βελτιστοποίηση μιας συνολικής μετρικής που ευνοεί τις μεγάλες κλάσεις [4], [9], [12].

5.6 Αρχιτεκτονική του τελικού μοντέλου

Η τελική αρχιτεκτονική του συστήματος μπορεί να θεωρηθεί ως συνδυασμός ενός πολυφασματικού encoder και μιας κεφαλής ταξινόμησης, με μικρές διαφοροποιήσεις ανάλογα με το στάδιο της μεθοδολογίας. Ο encoder αποτελεί το κοινό, επαναχρησιμοποιήσιμο τμήμα εκμάθησης αναπαραστάσεων και διατηρείται ως βασικός κορμός του συστήματος σε όλα τα στάδια [10], [16].


Στο SSL stage, η κεφαλή ταξινόμησης αντικαθίσταται από κεφαλή προβολής για την υποστήριξη της αντιθετικής μάθησης [17]. Στο crop stage, οι επιμέρους χρονικές αναπαραστάσεις συνδυάζονται μέσω temporal mean pooling και ακολουθεί κεφαλή ταξινόμησης για την πρόβλεψη της κατηγορίας καλλιέργειας. Στο disease stage, ο encoder συνδέεται με τελική κεφαλή πολυκλασικής ταξινόμησης για την πρόβλεψη φυτοπαθολογικών κατηγοριών.

Η λογική της σχεδίασης αυτής βασίζεται στη σταδιακή μεταφορά γνώσης από ένα κοινό σώμα αναπαραστάσεων προς διαφορετικά επίπεδα εξειδίκευσης [10]. Με τον τρόπο αυτό επιτυγχάνεται μεγαλύτερη συνέπεια στη συνολική μαθησιακή διαδικασία και ενισχύεται η αποτελεσματικότητα της μεταφοράς γνώσης μεταξύ των σταδίων [10], [14].

Επιπλέον, η χρήση μίας κοινής βασικής αρχιτεκτονικής καθιστά πιο καθαρή και την πειραματική αποτίμηση της μεθοδολογίας. Εφόσον ο ίδιος encoder μεταφέρεται και επαναχρησιμοποιείται, είναι ευκολότερο να αποδοθεί η βελτίωση της απόδοσης στα ίδια τα στάδια μάθησης και όχι σε ριζικές αλλαγές αρχιτεκτονικού σχεδιασμού. Αυτό ενισχύει τη μεθοδολογική καθαρότητα των πειραμάτων [10].

Το τελικό μοντέλο αποτελείται από τρία βασικά τμήματα:

multispectral encoder
feature representation
classification head



Σχήμα 5.3. Σχηματική απεικόνιση της συνολικής αρχιτεκτονικής.

5.7 Φασματική αξιολόγηση και XAI-guided επιλογή ζωνών

Εκτός από την ανάπτυξη του πολυσταδιακού pipeline μάθησης, η παρούσα εργασία δίνει ιδιαίτερη έμφαση στη φασματική αξιολόγηση των δεδομένων εισόδου. Η επιλογή αυτή είναι κρίσιμη, καθώς τα πολυφασματικά δεδομένα Sentinel-2 περιλαμβάνουν ζώνες που αποτυπώνουν διαφορετικές βιοφυσικές ιδιότητες της βλάστησης, όπως χρωματική πληροφορία, χλωροφύλλη, φυλλική δομή και υδατική κατάσταση. Ωστόσο, η χρήση μεγαλύτερου αριθμού φασματικών ζωνών δεν συνεπάγεται απαραίτητα βελτιωμένη γενίκευση, ιδίως όταν το διαθέσιμο σύνολο δεδομένων είναι μικρό, ανισόρροπο και περιέχει θόρυβο.

Για τον λόγο αυτό, η αξιολόγηση της μεθοδολογίας περιλαμβάνει σύγκριση διαφορετικών φασματικών συνδυασμών εισόδου. Κάθε φασματικό σχήμα εκπαιδεύεται με την ίδια συνολική λογική SSL → Crop → Disease, ώστε η σύγκριση να παραμένει μεθοδολογικά συνεπής. Με άλλα λόγια, όταν αξιολογείται ένα συγκεκριμένο σύνολο ζωνών, η αυτοεπιβλεπόμενη προεκπαίδευση, η ενδιάμεση εκπαίδευση καλλιέργειας και η τελική εκπαίδευση ασθενειών πραγματοποιούνται με το ίδιο φασματικό σύνολο. Η επιλογή αυτή αποτρέπει ασυνέπειες μεταξύ των σταδίων και επιτρέπει πιο καθαρή αποτίμηση της πραγματικής συμβολής κάθε φασματικού συνδυασμού.

Πέρα από τη συγκριτική αξιολόγηση προκαθορισμένων φασματικών σχημάτων, εφαρμόζεται επιπλέον ανάλυση ερμηνευσιμότητας στο πλήρες πολυφασματικό μοντέλο. Συγκεκριμένα, χρησιμοποιείται band occlusion analysis, κατά την οποία κάθε φασματική ζώνη αποκρύπτεται προσωρινά και μετράται η αντίστοιχη μεταβολή στην απόδοση του μοντέλου. Η βασική υπόθεση είναι ότι, εάν η απόκρυψη μιας ζώνης προκαλεί μεγάλη πτώση στη macro-F1, τότε η ζώνη αυτή συμβάλλει σημαντικά στη λειτουργία του εκπαιδευμένου μοντέλου.

Η διαδικασία εφαρμόζεται στο πλήρες πολυφασματικό σχήμα, το οποίο περιλαμβάνει τις ζώνες B2, B3, B4, B5, B6, B7, B8, B8A, B11 και B12. Για κάθε εκπαιδευμένο μοντέλο υπολογίζεται αρχικά η baseline macro-F1 στο αντίστοιχο validation set. Στη συνέχεια, κάθε ζώνη αντικαθίσταται με τη μέση κανονικοποιημένη τιμή της, ενώ οι υπόλοιπες ζώνες παραμένουν αμετάβλητες. Η macro-F1 υπολογίζεται εκ νέου και η διαφορά σε σχέση με την αρχική τιμή χρησιμοποιείται ως μέτρο σημαντικότητας της ζώνης.

Η ανάλυση αυτή δεν αποδεικνύει αιτιώδη σχέση μεταξύ μιας φασματικής ζώνης και μιας συγκεκριμένης ασθένειας. Παρέχει όμως μια πρακτική εκτίμηση της εξάρτησης του εκπαιδευμένου μοντέλου από κάθε κανάλι εισόδου. Συνεπώς, λειτουργεί συμπληρωματικά προς τη συγκριτική αξιολόγηση των φασματικών συνδυασμών, προσφέροντας ένα δεύτερο επίπεδο ερμηνείας της συμπεριφοράς του μοντέλου.

Με βάση τα αποτελέσματα της band occlusion analysis σχεδιάζεται επιπλέον ένα XAI-guided φασματικό σχήμα. Το σχήμα αυτό περιλαμβάνει τις πέντε ζώνες με τη μεγαλύτερη μέση επίδραση στη macro-F1 και αξιολογείται ως πρόσθετο διερευνητικό πείραμα. Στόχος του δεν είναι να αντικαταστήσει τα αρχικά φασματικά σχήματα, αλλά να εξετάσει αν η ερμηνευτική σημαντικότητα των ζωνών μπορεί να οδηγήσει σε ένα μικρότερο, στοχευμένο και ανταγωνιστικό υποσύνολο εισόδου.



Σχήμα 5.4. Μεθοδολογική ροή της φασματικής αξιολόγησης και της XAI-guided επιλογής ζωνών. Η ανάλυση band occlusion εφαρμόζεται στο πλήρες πολυφασματικό μοντέλο και χρησιμοποιείται για τον σχεδιασμό πρόσθετου Top-5 φασματικού σχήματος.

5.8 Σύνοψη της προτεινόμενης μεθοδολογίας

Συνοψίζοντας, η προτεινόμενη μεθοδολογία βασίζεται σε ένα πολυσταδιακό pipeline μάθησης, το οποίο επιδιώκει να μεταφέρει γνώση από γενικά μη επισημασμένα δεδομένα σε ολόένα πιο εξειδικευμένα γεωργικά προβλήματα [10], [14]. Στο πρώτο στάδιο, η αυτοεπιβλεπόμενη μάθηση επιτρέπει την εκμάθηση γενικών πολυφασματικών αναπαραστάσεων [14]. Στο δεύτερο στάδιο, το μοντέλο εξειδικεύεται στη διάκριση καλλιεργειών με αξιοποίηση πολυχρονικής πληροφορίας [5], [10]. Στο τρίτο στάδιο, η ήδη αποκτημένη γνώση προσαρμόζεται περαιτέρω για το τελικό πρόβλημα της ανίχνευσης ασθενειών [10], [13].

Η προσέγγιση αυτή ενσωματώνει τη βασική θεωρητική παραδοχή της εργασίας: ότι η αναγνώριση ασθενειών σε δεδομένα Sentinel-2 δεν πρέπει να αντιμετωπίζεται ως μεμονωμένο task, αλλά ως κορύφωση μιας ιεραρχικής διαδικασίας μάθησης. Πρώτα μαθαίνονται γενικές φασματικές δομές της βλάστησης, στη συνέχεια πιο εξειδικευμένα γεωργικά χαρακτηριστικά και τέλος οι φασματικές αποκλίσεις που σχετίζονται με φυτοπαθολογικές καταστάσεις [10], [14].

Επιπλέον, η μεθοδολογία επεκτείνεται πέρα από την απλή ταξινομητική αξιολόγηση, ενσωματώνοντας συστηματική φασματική ανάλυση και ερμηνευσιμότητα. Η σύγκριση διαφορετικών φασματικών σχημάτων επιτρέπει την εκτίμηση της συμβολής των ορατών, NIR, red-edge και SWIR ζωνών, ενώ η band occlusion analysis παρέχει πρακτική εκτίμηση της εξάρτησης του πλήρους μοντέλου από κάθε ζώνη. Με βάση αυτή την ερμηνευτική ανάλυση σχεδιάζεται και αξιολογείται πρόσθετο XAI-guided Top-5 σχήμα, ώστε να διερευνηθεί αν ένα μικρότερο και στοχευμένο φασματικό υποσύνολο μπορεί να διατηρήσει ανταγωνιστική απόδοση.

Η αποτελεσματικότητα της μεθοδολογίας αυτής εξετάζεται πειραματικά στα επόμενα κεφάλαια, όπου αξιολογείται τόσο η συμβολή κάθε επιμέρους σταδίου όσο και η συνολική απόδοση του συστήματος στο τελικό πρόβλημα ταξινόμησης ασθενειών.

Κεφάλαιο 6ο: ΠΕΙΡΑΜΑΤΙΚΗ ΔΙΑΔΙΚΑΣΙΑ

6.1 Εισαγωγή

Στο παρόν κεφάλαιο παρουσιάζεται αναλυτικά η πειραματική διαδικασία που ακολουθήθηκε για την αξιολόγηση του προτεινόμενου συστήματος ανίχνευσης ασθενειών καλλιεργείων. Περιγράφονται το υπολογιστικό περιβάλλον στο οποίο πραγματοποιήθηκαν τα πειράματα, τα εργαλεία λογισμικού που χρησιμοποιήθηκαν, οι βασικές ρυθμίσεις εκπαίδευσης των επιμέρους σταδίων, το πρωτόκολλο αξιολόγησης και οι μετρικές που εφαρμόστηκαν για την αποτίμηση της απόδοσης του συστήματος [12].

Η πειραματική διαδικασία σχεδιάστηκε με τρόπο που να επιτρέπει όχι μόνο την τελική αξιολόγηση του μοντέλου στο πρόβλημα ταξινόμησης ασθενειών, αλλά και τη σταδιακή αποτίμηση της συμβολής κάθε φάσης του προτεινόμενου pipeline [10], [14]. Για τον λόγο αυτό, τα πειράματα οργανώθηκαν σε τρία διαδοχικά στάδια: αυτοεπιβλεπόμενη προεκπαίδευση σε μη επισημασμένα δεδομένα Sentinel-2, εποπτευόμενη εκπαίδευση σε πρόβλημα ταξινόμησης καλλιεργείων και τελικό fine-tuning σε πρόβλημα ταξινόμησης ασθενειών [10], [14]. Η διαδοχική αυτή αξιολόγηση επιτρέπει την ερμηνεία όχι μόνο της τελικής απόδοσης, αλλά και του ρόλου κάθε επιμέρους σταδίου στη διαμόρφωση χρήσιμων πολυφασματικών αναπαραστάσεων [10], [14].

6.2 Πειραματικό πλαίσιο

Το πειραματικό πλαίσιο της παρούσας μελέτης βασίστηκε στην εκπαίδευση και αξιολόγηση μοντέλων βαθιάς μάθησης που επεξεργάζονται πολυφασματικά δεδομένα Sentinel-2 [15], [19]. Ο συνολικός σχεδιασμός είχε ως στόχο να διερευνηθεί η αποτελεσματικότητα της προτεινόμενης πολυσταδιακής στρατηγικής μάθησης, η οποία συνδυάζει αξιοποίηση μη επισημασμένων δεδομένων, μεταφορά γνώσης και σταδιακή προσαρμογή σε ολοένα πιο εξειδικευμένα γεωργικά tasks [10], [14].

Στο πρώτο στάδιο εφαρμόστηκε αντιθετική αυτοεπιβλεπόμενη μάθηση σε μεγάλο σύνολο μη επισημασμένων χρονικών δεδομένων Sentinel-2, ώστε να εκπαιδευτεί ένας πολυφασματικός encoder σε γενικές φασματικές και χωρικές αναπαραστάσεις [14], [17]. Στο δεύτερο στάδιο, ο encoder χρησιμοποιήθηκε ως αρχικοποίηση σε πρόβλημα ταξινόμησης καλλιεργείων με πολυχρονική είσοδο, με στόχο τη γεωργική εξειδίκευση των χαρακτηριστικών [5], [10]. Στο τρίτο στάδιο, το μοντέλο προσαρμόστηκε περαιτέρω στο πρόβλημα ταξινόμησης ασθενειών, το οποίο αποτελεί και το τελικό αντικείμενο της παρούσας εργασίας [10], [13].

Για κάθε στάδιο καταγράφονταν οι κατάλληλες μετρικές εκπαίδευσης και αξιολόγησης, ανάλογα με τη φύση του εκάστοτε προβλήματος. Στο αυτοεπιβλεπόμενο στάδιο δόθηκε έμφαση στην εξέλιξη της συνάρτησης απώλειας, ενώ στα επιβλεπόμενα στάδια χρησιμοποιήθηκαν μετρικές ταξινόμησης όπως η accuracy, η macro-F1 και οι πίνακες σύγχυσης [9], [12]. Με τον τρόπο αυτό, η πειραματική διαδικασία δεν περιορίστηκε σε μία συνολική αποτίμηση του τελικού αποτελέσματος, αλλά παρείχε τη δυνατότητα πιο λεπτομερούς παρακολούθησης της συμπεριφοράς του συστήματος σε κάθε επιμέρους φάση [12].

6.2.1 Υπολογιστικό περιβάλλον

Η εκπαίδευση των μοντέλων πραγματοποιήθηκε σε υπολογιστικό σύστημα με δυνατότητα επιτάχυνσης μέσω μονάδας γραφικών (GPU), καθώς η επεξεργασία πολυφασματικών δορυφορικών δεδομένων και η εκπαίδευση μοντέλων βαθιάς μάθησης απαιτούν αυξημένους υπολογιστικούς πόρους [15].

Το υπολογιστικό περιβάλλον περιλάμβανε:

- επεξεργαστή υψηλής απόδοσης Intel i9,
- μνήμη RAM 64 GB,
- κάρτα γραφικών NVIDIA RTX 2070 με 8 GB μνήμης.

Η χρήση GPU ήταν ιδιαίτερα σημαντική, κυρίως στο στάδιο της αυτοεπιβλεπόμενης προεκπαίδευσης και στα επαναλαμβανόμενα πειράματα του τελικού disease stage. Η επιταχυνόμενη εκτέλεση επέτρεψε την ολοκλήρωση πολλαπλών πειραμάτων σε αποδεκτό χρονικό διάστημα και την εξερεύνηση εναλλακτικών ρυθμίσεων εκπαίδευσης. Ειδικά στην περίπτωση της αντιθετικής μάθησης, όπου κάθε batch περιλαμβάνει πολλαπλές όψεις ανά δείγμα και ο αριθμός των συγκρίσεων στον χώρο αναπαράστασης αυξάνεται σημαντικά, η υπολογιστική απαίτηση είναι αυξημένη [14], [17].

Πέρα από το καθαρά τεχνικό σκέλος, το υπολογιστικό περιβάλλον επηρεάζει και τον πειραματικό σχεδιασμό. Περιορισμοί όπως η διαθέσιμη μνήμη GPU, ο χρόνος εκπαίδευσης ανά εποχή και ο αριθμός των ταυτόχρονων διεργασιών επηρεάζουν παραμέτρους όπως το batch size, τον αριθμό των workers και το εύρος των πειραμάτων που μπορούν να υλοποιηθούν [15]. Κατά συνέπεια, η τελική πειραματική διαδικασία διαμορφώθηκε όχι μόνο με βάση θεωρητικά κριτήρια, αλλά και με βάση τις πρακτικές δυνατότητες του διαθέσιμου εξοπλισμού.

6.2.2 Λογισμικό και βιβλιοθήκες

Η υλοποίηση της πειραματικής διαδικασίας πραγματοποιήθηκε στη γλώσσα προγραμματισμού Python, η οποία αποτελεί ένα από τα πλέον διαδεδομένα περιβάλλοντα για εφαρμογές μηχανικής μάθησης, επεξεργασίας εικόνων και ανάλυσης γεωχωρικών δεδομένων. Η επιλογή της Python είναι ιδιαίτερα συνηθισμένη στη σχετική βιβλιογραφία, καθώς προσφέρει πλούσιο οικοσύστημα βιβλιοθηκών και υψηλό βαθμό αναπαραγωγιμότητας [15].

Οι βασικές βιβλιοθήκες που αξιοποιήθηκαν ήταν οι ακόλουθες:

- **PyTorch**, για την υλοποίηση και εκπαίδευση των νευρωνικών δικτύων,
- **NumPy**, για αριθμητικούς υπολογισμούς και διαχείριση πολυδιάστατων πινάκων,
- **Pandas**, για τη διαχείριση πινάκων μεταδεδομένων και αποτελεσμάτων,
- **Scikit-learn**, για stratified splitting, k-fold cross-validation και υπολογισμό μετρικών αξιολόγησης,
- **Rasterio**, για τη φόρτωση και επεξεργασία πολυφασματικών εικόνων,
- βοηθητικές βιβλιοθήκες Python για την οργάνωση αρχείων, την αποθήκευση checkpoints και την καταγραφή πειραματικών αποτελεσμάτων.

Η επιλογή αυτού του λογισμικού επέτρεψε τη διαμόρφωση ενός πειραματικού πλαισίου επαρκώς ευέλικτου, αναπαραγωγίμου και κατάλληλου για εφαρμογές πολυφασματικής βαθιάς μάθησης [12], [15]. Ιδιαίτερα σημαντική ήταν η δυνατότητα του PyTorch να υποστηρίζει προσαρμοσμένες αρχιτεκτονικές, διαφορετικά training loops και εύκολη ενσωμάτωση μηχανισμών μεταφοράς μάθησης, γεγονός που ήταν απαραίτητο για τη δομή της παρούσας μελέτης [10], [16].

6.3 Ρυθμίσεις εκπαίδευσης ανά στάδιο

Η εκπαίδευση του προτεινόμενου συστήματος πραγματοποιήθηκε σε τρία διαδοχικά στάδια, καθένα από τα οποία υπηρετούσε διαφορετικό λειτουργικό ρόλο και συνοδευόταν από διαφορετικές ρυθμίσεις και πρωτόκολλο αξιολόγησης [10], [14]. Η διακριτή καταγραφή των υπερπαραμέτρων και των επιλογών εκπαίδευσης ανά στάδιο είναι σημαντική, διότι οι απαιτήσεις της αυτοεπιβλεπόμενης μάθησης διαφέρουν ουσιαστικά από εκείνες ενός επιβλεπόμενου task ταξινόμησης [14], [17].

6.3.1 Στάδιο αυτοεπιβλεπόμενης προεκπαίδευσης

Στο πρώτο στάδιο πραγματοποιήθηκε αυτοεπιβλεπόμενη προεκπαίδευση σε μη επισημασμένα δεδομένα Sentinel-2. Ως είσοδος χρησιμοποιήθηκαν δέκα φασματικές ζώνες:

B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12 [19], [20]

Για κάθε δείγμα επιλέγονταν έως τέσσερις χρονικές παρατηρήσεις, ενώ από κάθε παρατήρηση παράγονταν δύο επαυξημένες όψεις για τις ανάγκες της αντιθετικής μάθησης [14], [17]. Η εκπαίδευση πραγματοποιήθηκε για 25 εποχές με τις ακόλουθες βασικές ρυθμίσεις:

- batch size = 8,
- learning rate = 2×10^{-4} ,
- temperature = 0.1,
- num_workers = 4.

Πριν από την έναρξη της εκπαίδευσης εκτιμήθηκαν οι τιμές μέσου και τυπικής απόκλισης για τις φασματικές ζώνες, ώστε να εφαρμοστεί κανονικοποίηση στα δεδομένα εισόδου [19], [20]. Η βελτιστοποίηση βασίστηκε στη συνάρτηση απώλειας **SupConLoss**, ενώ το βέλτιστο checkpoint αποθηκευόταν με βάση τη μικρότερη τιμή της αυτοεπιβλεπόμενης απώλειας [17].

Η επιλογή σχετικά μικρού batch size συνδέεται με τις αυξημένες απαιτήσεις μνήμης που συνεπάγεται η αντιθετική μάθηση, ιδιαίτερα όταν κάθε δείγμα συνοδεύεται από πολλαπλές χρονικές λήψεις και δύο επαυξημένες όψεις [14], [17]. Παράλληλα, ο επιλεγμένος ρυθμός μάθησης κρίθηκε επαρκής ώστε να επιτρέπει σταθερή σύγκλιση χωρίς έντονες ταλαντώσεις στη loss. Η θερμοκρασία 0.1 επιλέχθηκε σύμφωνα με τη συνήθη πρακτική σε contrastive frameworks, όπου η συγκεκριμένη παράμετρος επηρεάζει την «οξύτητα» με την οποία διαχωρίζονται θετικά και αρνητικά παραδείγματα στον χώρο ενσωματώσεων [17].

6.3.2 Στάδιο ταξινόμησης καλλιέργειας

Στο δεύτερο στάδιο, ο encoder αρχικοποιήθηκε από το καλύτερο checkpoint του SSL σταδίου και εκπαιδεύτηκε σε πρόβλημα ταξινόμησης καλλιεργειών [10], [14]. Στο crop stage χρησιμοποιήθηκαν:

- οι ίδιες δέκα φασματικές ζώνες Sentinel-2,
- τέσσερις χρονικές λήψεις ανά δείγμα,
- 25 εποχές εκπαίδευσης,
- batch size = 16,
- num_workers = 0,
- seed = 42.

Στο συγκεκριμένο στάδιο εφαρμόστηκε διαχωρισμός του ρυθμού μάθησης μεταξύ του βασικού κορμού του μοντέλου και της κεφαλής ταξινόμησης, ώστε ο encoder να ενημερώνεται πιο συντηρητικά σε σχέση με το ανώτερο εποπτευόμενο τμήμα [10]. Η βελτιστοποίηση πραγματοποιήθηκε με **AdamW**, ενώ κατά την εκπαίδευση εφαρμόστηκαν βασικές γεωμετρικές επαυξήσεις στα training δεδομένα. Αντίθετα, στο validation χρησιμοποιήθηκε ντετερμινιστική επιλογή χρονικών στιγμών χωρίς επαυξήσεις, ώστε η αξιολόγηση να παραμένει σταθερή και συγκρίσιμη [12].

Η επιλογή μεγαλύτερου batch size σε σχέση με το SSL στάδιο σχετίζεται με το γεγονός ότι η εποπτευόμενη εκπαίδευση καλλιιεργειών είναι λιγότερο απαιτητική σε μνήμη από την contrastive learning διάταξη. Ο διαχωρισμός learning rate μεταξύ backbone και classifier head είναι ιδιαίτερα σημαντικός, καθώς επιτρέπει την προσεκτική προσαρμογή των προεκπαιδευμένων χαρακτηριστικών χωρίς να διαταράσσεται απότομα η γνώση που έχει ήδη αποκτηθεί στο SSL stage [10].

Η χρήση συγκεκριμένου seed ενισχύει την αναπαραγωγικότητα της διαδικασίας και επιτρέπει πιο αξιόπιστες συγκρίσεις μεταξύ εναλλακτικών πειραμάτων. Αυτό είναι κρίσιμο σε προβλήματα όπου ακόμη και μικρές διαφορές στην αρχικοποίηση ή στο split μπορούν να επηρεάσουν αισθητά τη συμπεριφορά του μοντέλου [12].

6.3.3 Στάδιο ταξινόμησης ασθενειών

Στο τρίτο και τελικό στάδιο, το μοντέλο αρχικοποιήθηκε από το checkpoint του crop stage που περιλάμβανε μόνο τα βάρη του encoder [10]. Η τελική εκπαίδευση πραγματοποιήθηκε στο πρόβλημα ταξινόμησης ασθενειών με τις ακόλουθες βασικές ρυθμίσεις:

- οι ίδιες δέκα φασματικές ζώνες Sentinel-2,
- 45 εποχές εκπαίδευσης,
- batch size = 32,
- learning rate = 2×10^{-4} ,
- weight decay = 10^{-4} ,
- num_workers = 0,
- seed = 42.

Για την αντιμετώπιση της ανισορροπίας κλάσεων εφαρμόστηκε **Weighted Random Sampler**, ώστε οι υποεκπροσωπούμενες κατηγορίες να εμφανίζονται συχνότερα κατά την εκπαίδευση [4], [9]. Η συνάρτηση απώλειας ήταν η κλασική **CrossEntropyLoss**, ενώ το βέλτιστο checkpoint επιλεγόταν με βάση τη μέγιστη τιμή της validation macro-F1 [9], [12].

Η επιλογή μεγαλύτερου αριθμού εποχών στο disease stage αιτιολογείται από τη δυσκολία του προβλήματος και από την ανάγκη το μοντέλο να προσαρμόσει με μεγαλύτερη ακρίβεια τις ήδη μαθημένες αναπαραστάσεις σε λεπτότερες φυτοπαθολογικές διαφοροποιήσεις [10], [13]. Παράλληλα, η χρήση weight decay λειτουργεί ως στοιχείο κανονικοποίησης της εκπαίδευσης, περιορίζοντας σε έναν βαθμό τον κίνδυνο υπερπροσαρμογής σε ένα σχετικά μικρό και ανισόρροπο σύνολο δεδομένων [4], [9].

6.3.4 Πειράματα φασματικών συνδυασμών εισόδου

Πέρα από την αξιολόγηση του πλήρους πολυφασματικού σχήματος, πραγματοποιήθηκαν επιπλέον πειράματα με διαφορετικούς φασματικούς συνδυασμούς εισόδου, με στόχο να διερευνηθεί η συμβολή επιμέρους περιοχών του φάσματος στην τελική ταξινόμηση ασθενειών. Η επιλογή αυτή κρίθηκε απαραίτητη, καθώς οι διαφορετικές ζώνες του Sentinel-2 αποτυπώνουν διαφορετικές ιδιότητες της βλάστησης, όπως ορατά συμπτώματα, φυλλική δομή, χλωροφύλλη και υδατική κατάσταση [6], [8], [13], [19], [20].

Για κάθε φασματικό σχήμα διατηρήθηκε σταθερή η ίδια βασική αρχιτεκτονική και το ίδιο πολυσταδιακό πρωτόκολλο $SSL \rightarrow Crop \rightarrow Disease$. Ειδικότερα, κάθε φασματικός συνδυασμός χρησιμοποιήθηκε με συνέπεια σε όλα τα στάδια της εκπαίδευσης, από την αυτοεπιβλεπόμενη προεκπαίδευση έως την τελική ταξινόμηση ασθενειών. Με τον τρόπο αυτό, οι διαφορές στην απόδοση μπορούν να αποδοθούν με μεγαλύτερη ασφάλεια στη διαθέσιμη φασματική πληροφορία και όχι σε ασυνέπειες μεταξύ των σταδίων του pipeline.

Επιπλέον των αρχικά ορισμένων φασματικών συνδυασμών, αξιολογήθηκε ένα πρόσθετο XAI-guided Top-5 σχήμα. Το σχήμα αυτό δεν ορίστηκε a priori, αλλά προέκυψε μετά την band occlusion analysis του πλήρους πολυφασματικού μοντέλου και περιλαμβάνει τις πέντε ζώνες με τη μεγαλύτερη μέση επίδραση στη macro-F1. Επομένως, αντιμετωπίζεται ως διερευνητικό πείραμα ερμηνευτικά καθοδηγούμενης επιλογής ζωνών.

Τα φασματικά σχήματα που εξετάστηκαν ήταν τα εξής:

Πίνακας 6.1. Φασματικοί συνδυασμοί εισόδου που αξιολογήθηκαν στο disease stage.

Φασματικός συνδυασμός	Ζώνες Sentinel-2	Λογική επιλογής
RGB	B2, B3, B4	Ορατό φάσμα και χρωματική πληροφορία
RGB + NIR	B2, B3, B4, B8	Ορατό φάσμα και φυλλική δομή
NIR + Red-edge	B5, B6, B7, B8, B8A	Φυσιολογική κατάσταση, χλωροφύλλη και φυτική δομή
RGB + Red-edge χωρίς NIR	B2, B3, B4, B5, B6, B7	Ορατό φάσμα και red-edge πληροφορία
RGB + NIR + Red-edge	B2, B3, B4, B5, B6, B7, B8, B8A	Ορατό, red-edge και NIR χωρίς SWIR
Red-edge + NIR + SWIR	B5, B6, B7, B8, B8A, B11, B12	Φυσιολογική και υδατική κατάσταση
Full multispectral	B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12	Πλήρες διαθέσιμο πολυφασματικό σχήμα
XAI-guided Top-5	B3, B4, B7, B8, B8A	Επιλογή βάσει band occlusion σημαντικότητας

Το RGB σχήμα χρησιμοποιήθηκε ως βασική αναφορά ορατού φάσματος, ενώ τα υπόλοιπα σχήματα σχεδιάστηκαν ώστε να απομονώνουν ή να συνδυάζουν διαφορετικές φασματικές περιοχές. Ιδιαίτερο ενδιαφέρον παρουσιάζει η σύγκριση μεταξύ RGB, RGB + NIR, RGB + NIR + red-edge και Full multispectral, καθώς επιτρέπει να εξεταστεί αν η σταδιακή προσθήκη μη ορατής φασματικής πληροφορίας οδηγεί σε συστηματική βελτίωση της απόδοσης. Το XAI-guided Top-5 σχήμα αξιολογείται συμπληρωματικά, με στόχο να ελεγχθεί αν οι ζώνες που αναδείχθηκαν ως σημαντικότερες μέσα στο πλήρες μοντέλο μπορούν να συγκροτήσουν ένα μικρότερο αλλά ανταγωνιστικό φασματικό subset.

Για κάθε φασματικό σχήμα διατηρήθηκε σταθερή η ίδια βασική αρχιτεκτονική και το ίδιο πειραματικό πρωτόκολλο, ώστε οι διαφορές στην απόδοση να αποδίδονται κατά το δυνατόν στη διαφορετική φασματική πληροφορία και όχι σε μεταβολές της διαδικασίας εκπαίδευσης. Με τον τρόπο αυτό κατέστη δυνατή η συγκριτική αξιολόγηση της συμβολής των ορατών, NIR, red-edge και SWIR ζωνών στην τελική ταξινόμηση.

6.4 Πρωτόκολλο αξιολόγησης

Η αξιολόγηση των επιμέρους σταδίων δεν βασίστηκε σε ενιαίο πρωτόκολλο, αλλά προσαρμόστηκε στη φύση του κάθε προβλήματος και στη διαθεσιμότητα δεδομένων [12]. Η επιλογή αυτή ήταν αναγκαία, καθώς τα τρία στάδια της μεθοδολογίας διαφέρουν ουσιαστικά ως προς τον τύπο των δεδομένων, τον όγκο των labels και τον ερευνητικό ρόλο που επιτελούν [10], [14].

Στο στάδιο ταξινόμησης καλλιεργειών, όπου υπήρχε επαρκής αριθμός επισημασμένων δειγμάτων, χρησιμοποιήθηκε stratified hold-out split με αναλογία 80/20 μεταξύ συνόλου εκπαίδευσης και συνόλου επικύρωσης. Ο διαχωρισμός πραγματοποιήθηκε με τρόπο ώστε όλες οι κατηγορίες καλλιεργειών να εκπροσωπούνται τόσο στο training όσο και στο validation set.

Στο στάδιο ταξινόμησης ασθενειών, λόγω του μικρότερου μεγέθους του συνόλου δεδομένων και της έντονης ανισορροπίας μεταξύ των κλάσεων, επιλέχθηκε 5-fold stratified cross-validation [4], [9], [12]. Η επιλογή αυτή προσφέρει πιο αξιόπιστη εκτίμηση της γενικευτικής ικανότητας του μοντέλου σε σχέση με ένα μεμονωμένο hold-out split, καθώς κάθε δείγμα συμμετέχει εναλλάξ σε training και validation. Παράλληλα, η stratified διάταξη διασφαλίζει, στον βαθμό που είναι εφικτό, την αναλογική εκπροσώπηση όλων των κλάσεων σε κάθε fold [12].

Επιπλέον, για την πιο αξιόπιστη σύγκριση των διαφορετικών φασματικών σχημάτων, εφαρμόστηκε επαναλαμβανόμενη διασταυρούμενη επικύρωση πέντε πτυχών (repeated 5-fold cross-validation). Η διαδικασία αυτή επαναλήφθηκε με διαφορετικές τιμές αρχικοποίησης (random seeds), ώστε να εκτιμηθεί η ευαισθησία των αποτελεσμάτων στην τυχαιότητα του διαχωρισμού των δεδομένων, της αρχικοποίησης των βαρών και της σειράς παρουσίασης των δειγμάτων κατά την εκπαίδευση [12].

Η χρήση repeated cross-validation κρίθηκε απαραίτητη, καθώς κατά τη διάρκεια των πειραμάτων παρατηρήθηκε μεταβλητότητα της απόδοσης μεταξύ διαφορετικών εκτελέσεων. Σε μικρά και ανισόρροπα σύνολα δεδομένων, όπως το σύνολο ασθενειών της παρούσας εργασίας, μία μεμονωμένη εκτέλεση μπορεί να οδηγήσει σε μη ασφαλή συμπεράσματα. Για τον λόγο αυτό, η τελική σύγκριση των φασματικών σχημάτων βασίστηκε στη μέση τιμή και στην τυπική απόκλιση της macro-F1 σε πολλαπλές επαναλήψεις.

Στο αυτοεπιβλεπόμενο στάδιο δεν χρησιμοποιήθηκε χωριστό validation set με labels, καθώς το πρόβλημα δεν ήταν εποπτευόμενο. Η αξιολόγηση του συγκεκριμένου σταδίου βασίστηκε κυρίως στην εξέλιξη της contrastive απώλειας και, σημαντικότερα, στη χρησιμότητα των παραγόμενων αναπαραστάσεων στα επόμενα downstream tasks [14], [17].

Το συγκεκριμένο πρωτόκολλο αξιολόγησης επιτρέπει μια πιο ισορροπημένη και ρεαλιστική αποτίμηση της μεθοδολογίας. Το crop stage λειτουργεί ως ενδιάμεσο supervised βήμα με hold-out design, ενώ το disease stage, ως τελικό και πιο κρίσιμο πείραμα, αξιολογείται με αυστηρότερο σχήμα διασταυρωμένης

επικύρωσης και επαναλαμβανόμενων εκτελέσεων [12]. Η επιλογή αυτή ενισχύει τη μεθοδολογική αξιοπιστία των αποτελεσμάτων της εργασίας.

Για τα πειράματα φασματικών συνδυασμών, η repeated cross-validation εφαρμόστηκε με στόχο τη μείωση της εξάρτησης των συμπερασμάτων από ένα συγκεκριμένο split. Κάθε φασματικό σχήμα αξιολογήθηκε με βάση τη μέση macro-F1 και την τυπική απόκλιση σε πολλαπλές επαναλήψεις και folds. Η επιλογή της macro-F1 είναι ιδιαίτερα σημαντική σε προβλήματα ανισορροπίας κλάσεων, καθώς αποδίδει ίσο βάρος στην απόδοση κάθε κατηγορίας [9], [12].

Σημειώνεται ότι το XAI-guided Top-5 σχήμα δεν χρησιμοποιείται για να αναθεωρήσει εκ των υστέρων τα αρχικά πειράματα, αλλά για να εξετάσει εάν ένα ερμηνευτικά καθοδηγούμενο subset μπορεί να διατηρήσει ανταγωνιστική απόδοση. Για τον λόγο αυτό, τα αποτελέσματά του παρουσιάζονται ως πρόσθετη διερευνητική αξιολόγηση και ερμηνεύονται σε συνδυασμό με τα αποτελέσματα του πλήρους πολυφασματικού μοντέλου.

6.5 Μετρικές αξιολόγησης

Για την αξιολόγηση των μοντέλων χρησιμοποιήθηκαν μετρικές πολυκλασικής ταξινόμησης που επιτρέπουν τόσο συνολική όσο και αναλυτική αποτίμηση της συμπεριφοράς του συστήματος [12]. Οι βασικές μετρικές που αξιοποιήθηκαν ήταν:

- Accuracy,
- Precision,
- Recall,
- F1-score,
- Macro-F1,
- πίνακας σύγχυσης.

Η χρήση πολλαπλών μετρικών είναι ιδιαίτερα σημαντική σε προβλήματα ανισορροπίας ταξινόμησης, όπου μία μόνο συνολική μετρική, όπως η accuracy, μπορεί να δώσει παραπλανητική εικόνα της πραγματικής απόδοσης του μοντέλου [4], [9], [12].

6.5.1 Accuracy

Η ακρίβεια (**Accuracy**) εκφράζει το ποσοστό των σωστών προβλέψεων ως προς το συνολικό πλήθος δειγμάτων [12]. Αποτελεί μια συνολική ένδειξη της απόδοσης του μοντέλου και είναι εύκολα ερμηνεύσιμη, ιδιαίτερα όταν οι κατηγορίες είναι σχετικά ισορροπημένες [12].

Ωστόσο, σε προβλήματα με έντονη ανισορροπία κλάσεων, η accuracy δεν επαρκεί από μόνη της για αξιόπιστη αξιολόγηση, καθώς μπορεί να επηρεάζεται δυσανάλογα από τις πολυπληθέστερες κατηγορίες [4], [9]. Για τον λόγο αυτό, στην παρούσα εργασία η accuracy χρησιμοποιείται ως συμπληρωματική μετρική και όχι ως αποκλειστικό κριτήριο αποτίμησης.

6.5.2 Precision και Recall

Η **precision** εκφράζει το ποσοστό των σωστών θετικών προβλέψεων σε σχέση με το σύνολο των θετικών προβλέψεων του μοντέλου, ενώ η **recall** εκφράζει το ποσοστό των πραγματικών θετικών δειγμάτων που αναγνωρίστηκαν σωστά [12].

Οι δύο αυτές μετρικές είναι ιδιαίτερα σημαντικές σε προβλήματα ανίχνευσης ασθενειών, όπου τόσο οι ψευδώς θετικές όσο και οι ψευδώς αρνητικές προβλέψεις έχουν πρακτική σημασία. Η precision αποτυπώνει κατά πόσο οι θετικές προβλέψεις του συστήματος είναι αξιόπιστες, ενώ η recall εκφράζει την ικανότητα του μοντέλου να μην παραλείπει πραγματικά προβληματικά δείγματα [12].

6.5.3 F1-score

Το **F1-score** αποτελεί τον αρμονικό μέσο της precision και της recall και παρέχει πιο ισορροπημένη εικόνα της απόδοσης του μοντέλου, ιδίως όταν υπάρχει ανάγκη ταυτόχρονης αξιολόγησης της ικανότητας εντοπισμού θετικών δειγμάτων και της αξιοπιστίας των αντίστοιχων προβλέψεων [12].

Στην παρούσα εργασία, ιδιαίτερο ενδιαφέρον είχαν τα F1-scores ανά κλάση, καθώς αυτά προσφέρουν λεπτομερή εικόνα για το πόσο καλά το μοντέλο αναγνωρίζει κάθε κατηγορία ασθένειας ξεχωριστά. Η ανάλυση αυτή είναι ουσιαστική, επειδή ένα συνολικό μέσο αποτέλεσμα μπορεί να αποκρύπτει σημαντικές διαφορές ανάμεσα σε πολυπληθείς και σπάνιες κλάσεις [4], [9], [12].

6.5.4 Macro-F1

Η **macro-F1** υπολογίζεται ως ο αριθμητικός μέσος των F1-scores όλων των κλάσεων [12]. Σε αντίθεση με μετρικές που επηρεάζονται περισσότερο από τις πολυπληθέστερες κατηγορίες, η macro-F1 αποδίδει ίσο βάρος σε κάθε κλάση ανεξαρτήτως μεγέθους [9], [12].

Η συγκεκριμένη μετρική ήταν η σημαντικότερη για την τελική αξιολόγηση του disease stage, καθώς το σύνολο δεδομένων ασθενειών παρουσιάζει έντονη ανισορροπία [4], [9]. Για τον λόγο αυτό, το βέλτιστο checkpoint κάθε fold επιλεγόταν με βάση τη μέγιστη τιμή της validation macro-F1 και όχι με βάση τη μικρότερη loss ή τη μέγιστη accuracy [9], [12].

Η επιλογή της macro-F1 συνδέεται άμεσα με τον στόχο της εργασίας. Εφόσον ζητούμενο είναι η αξιόπιστη αναγνώριση όλων των κατηγοριών ασθένειας και όχι μόνο των συχνότερων, η συγκεκριμένη μετρική αποτελεί το καταλληλότερο συνολικό μέτρο απόδοσης [4], [9], [12].

Προβλεπόμενη κλάση

		Κλάση 1	Κλάση 2	...
Πραγματική κλάση	Κλάση 1	Σωστές ταξινομήσεις	Σύγχυση 1→2	...
	Κλάση 2	Σύγχυση 2→1	Σωστές ταξινομήσεις	...

Οι διαγώνιες τιμές αντιστοιχούν σε σωστές προβλέψεις, ενώ οι εκτός διαγωνίου τιμές σε σφάλματα ταξινόμησης.

Σχήμα 6.1. Ενδεικτική δομή πίνακα σύγχυσης για πρόβλημα πολυκλασικής ταξινόμησης.

Ο πίνακας σύγχυσης (**confusion matrix**) παρέχει αναλυτική αποτύπωση των σωστών και λανθασμένων ταξινομήσεων ανά κατηγορία [12]. Κάθε γραμμή του πίνακα αντιστοιχεί στην πραγματική κλάση και κάθε στήλη στην προβλεπόμενη κλάση.

Η χρήση πίνακα σύγχυσης είναι ιδιαίτερα σημαντική στην παρούσα μελέτη, καθώς επιτρέπει την αναγνώριση συστηματικών συγχύσεων μεταξύ κατηγοριών ασθενειών. Με τον τρόπο αυτό καθίσταται δυνατή όχι μόνο η ποσοτική αλλά και η ποιοτική ερμηνεία της συμπεριφοράς του μοντέλου [12]. Η πληροφορία αυτή είναι ιδιαίτερα πολύτιμη, επειδή σε ένα πολύπλοκο πρόβλημα ταξινόμησης οι συνολικές μετρικές δεν αρκούν για να εξηγήσουν πού ακριβώς αποτυγχάνει ή υπερέχει το σύστημα [12].

6.5.5 Στατιστική αξιολόγηση φασματικών σχημάτων

Για τη σύγκριση των διαφορετικών φασματικών σχημάτων δεν χρησιμοποιήθηκαν μόνο περιγραφικές μετρικές, όπως η μέση macro-F1 και η τυπική απόκλιση, αλλά εφαρμόστηκαν και στατιστικοί έλεγχοι. Η επιλογή αυτή κρίθηκε αναγκαία, καθώς οι αριθμητικές διαφορές μεταξύ ορισμένων φασματικών συνδυασμών ήταν μικρές και θα μπορούσαν να οφείλονται στην τυχαιότητα των πειραμάτων.

Αρχικά εφαρμόστηκε ο μη παραμετρικός έλεγχος Friedman, ο οποίος είναι κατάλληλος για τη σύγκριση περισσότερων από δύο μεθόδων σε επαναλαμβανόμενα πειραματικά σενάρια. Ο έλεγχος αυτός δεν προϋποθέτει κανονικότητα των επιδόσεων και χρησιμοποιείται για να διερευνηθεί εάν υπάρχει συνολική στατιστικά σημαντική διαφορά μεταξύ των εξεταζόμενων μεθόδων.

Στη συνέχεια, επειδή ο έλεγχος Friedman δείχνει μόνο αν υπάρχει συνολική διαφορά και όχι ποια συγκεκριμένα ζεύγη μεθόδων διαφέρουν μεταξύ τους, πραγματοποιήθηκαν pairwise συγκρίσεις. Για τον έλεγχο του σφάλματος πολλαπλών συγκρίσεων εφαρμόστηκε διόρθωση Holm. Η διόρθωση αυτή επιτρέπει πιο αυστηρή και αξιόπιστη αξιολόγηση των επιμέρους διαφορών μεταξύ φασματικών σχημάτων.

Η συνδυαστική χρήση repeated cross-validation, Friedman test και Holm correction επιτρέπει πιο ασφαλή ερμηνεία των αποτελεσμάτων. Με τον τρόπο αυτό αποφεύγεται η υπερερμηνεία μικρών αριθμητικών διαφορών και ενισχύεται η στατιστική τεκμηρίωση των συμπερασμάτων του Κεφαλαίου 7.

6.6 Πρωτόκολλο ερμηνευσιμότητας μέσω band occlusion

Για την ερμηνευτική ανάλυση της συμβολής των επιμέρους φασματικών ζωνών εφαρμόστηκε band occlusion analysis στο πλήρες πολυφασματικό σχήμα εισόδου [28]. Η μέθοδος αυτή επιτρέπει την εκτίμηση της σημαντικότητας κάθε ζώνης με βάση τη μεταβολή της απόδοσης του μοντέλου όταν η συγκεκριμένη ζώνη αποκρύπτεται από την είσοδο.

Η διαδικασία εφαρμόστηκε στα μοντέλα που προέκυψαν από την επαναλαμβανόμενη 5-fold διασταυρούμενη επικύρωση του πλήρους πολυφασματικού σχήματος. Συνολικά αξιοποιήθηκαν 25 εκπαιδευμένα μοντέλα, τα οποία αντιστοιχούν σε πέντε επαναλήψεις των πέντε folds. Για κάθε μοντέλο υπολογίστηκε αρχικά η baseline macro-F1 στο αντίστοιχο validation set. Στη συνέχεια, για κάθε φασματική ζώνη δημιουργήθηκε μία occluded εκδοχή του validation input, στην οποία οι τιμές της συγκεκριμένης ζώνης αντικαταστάθηκαν από τη μέση κανονικοποιημένη τιμή της.

Η επιλογή της μέσης κανονικοποιημένης τιμής ως τιμής αντικατάστασης έγινε ώστε η απόκρυψη της ζώνης να μην εισάγει ακραίες ή μη ρεαλιστικές τιμές στην είσοδο. Εφόσον τα δεδομένα έχουν κανονικοποιηθεί ανά φασματική ζώνη, η αντικατάσταση με τη μέση τιμή αντιστοιχεί πρακτικά σε ουδέτερη πληροφορία για το συγκεκριμένο κανάλι. Με τον τρόπο αυτό, η υπόλοιπη πολυφασματική πληροφορία παραμένει αμετάβλητη και η μεταβολή της απόδοσης μπορεί να αποδοθεί στην απουσία της συγκεκριμένης ζώνης.

Για κάθε ζώνη υπολογίστηκε η διαφορά μεταξύ της baseline macro-F1 και της macro-F1 μετά την απόκρυψη. Η χρήση της macro-F1 ως βασικής μετρικής είναι κατάλληλη για το συγκεκριμένο πρόβλημα, επειδή το σύνολο δεδομένων εμφανίζει ανισορροπία μεταξύ των κατηγοριών ασθενειών [4], [9], [12].

Επιπλέον, υπολογίστηκαν οι μεταβολές F1-score ανά κλάση, ώστε να διερευνηθεί αν ορισμένες ζώνες επηρεάζουν περισσότερο συγκεκριμένες κατηγορίες ασθενειών. Η ανάλυση αυτή αξιοποιήθηκε κυρίως ερμηνευτικά και όχι ως κριτήριο επιλογής του τελικού μοντέλου.

Τα αποτελέσματα της band occlusion analysis χρησιμοποιήθηκαν για τον σχεδιασμό του XAI-guided Top-5 φασματικού σχήματος. Οι πέντε ζώνες με τη μεγαλύτερη μέση πτώση macro-F1 επιλέχθηκαν ως υποσύνολο εισόδου και αξιολογήθηκαν εκ νέου μέσω του ίδιου πολυσταδιακού pipeline. Με τον τρόπο αυτό, η ερμηνευτική ανάλυση δεν περιορίστηκε στην απλή περιγραφή της συμπεριφοράς του πλήρους μοντέλου, αλλά αξιοποιήθηκε για τη διαμόρφωση ενός πρόσθετου πειραματικού σχήματος.

Η συνολική διαδικασία της band occlusion analysis συνοψίζεται στον Πίνακα 6.2.

Πίνακας 6.2. Πρωτόκολλο band occlusion analysis.

Βήμα	Περιγραφή
1	Επιλογή των εκπαιδευμένων full multispectral μοντέλων από repeated 5-fold cross-validation
2	Υπολογισμός baseline macro-F1 στο validation set κάθε fold
3	Μεμονωμένη απόκρυψη κάθε φασματικής ζώνης
4	Αντικατάσταση της αποκρυπτόμενης ζώνης με τη μέση κανονικοποιημένη τιμή
5	Επανυπολογισμός macro-F1 μετά την απόκρυψη
6	Υπολογισμός ΔMacro-F1 για κάθε ζώνη
7	Μέσος όρος και τυπική απόκλιση της ΔMacro-F1 σε 25 runs

Βήμα	Περιγραφή
8	Επιλογή Top-5 ζωνών για το XAI-guided φασματικό σχήμα

6.7 Καταγραφή και αποθήκευση αποτελεσμάτων

Κατά τη διάρκεια των πειραμάτων, για κάθε στάδιο εκπαίδευσης αποθηκεύονταν τα βασικά αρχεία ρυθμίσεων, οι μετρικές ανά εποχή και τα checkpoints των καλύτερων μοντέλων, ώστε να διασφαλίζεται η αναπαραγωγικότητα των αποτελεσμάτων και η δυνατότητα συγκριτικής αξιολόγησης μεταξύ διαφορετικών runs [12].

Στο crop stage αποθηκευόταν τόσο το πλήρες checkpoint του καλύτερου μοντέλου όσο και έκδοση που περιλάμβανε μόνο τα βάρη του encoder, ώστε να χρησιμοποιηθεί ως αρχικοποίηση στο επόμενο στάδιο. Στο disease stage αποθηκεύονταν αναλυτικά τα logs των μετρικών, οι πίνακες σύγχυσης ανά εποχή και τα βέλτιστα checkpoints για κάθε fold της διασταυρωμένης επικύρωσης.

Η συστηματική καταγραφή των αποτελεσμάτων επέτρεψε την παρακολούθηση της πορείας της εκπαίδευσης, τη σύγκριση μεταξύ διαφορετικών σταδίων και folds και τη σαφέστερη ερμηνεία της συνολικής συμπεριφοράς του συστήματος [12]. Παράλληλα, συνέβαλε στην αναπαραγωγικότητα της μελέτης, καθώς κατέστη δυνατή η αναδρομή στα επιμέρους πειράματα και η ακριβής ταυτοποίηση των ρυθμίσεων που οδήγησαν στα καλύτερα αποτελέσματα.

Επιπλέον, για τα πειράματα φασματικών συνδυασμών καταγράφηκαν ξεχωριστά τα αποτελέσματα κάθε επανάληψης και κάθε fold, ώστε να είναι δυνατός ο υπολογισμός της μέσης macro-F1, της τυπικής απόκλισης και των στατιστικών ελέγχων. Η συστηματική αυτή καταγραφή ήταν απαραίτητη για την εφαρμογή του repeated cross-validation και της στατιστικής σύγκρισης των φασματικών σχημάτων. Με τον τρόπο αυτό, τα τελικά συμπεράσματα δεν βασίστηκαν σε μεμονωμένες τιμές απόδοσης, αλλά σε συνολική και επαναλαμβανόμενη πειραματική εικόνα.

Για την ανάλυση band occlusion αποθηκεύτηκαν ξεχωριστά τα αποτελέσματα κάθε repeat-fold run και κάθε φασματικής ζώνης. Συγκεκριμένα, καταγράφηκαν η baseline macro-F1, η macro-F1 μετά την απόκρυψη κάθε ζώνης, η αντίστοιχη πτώση ΔMacro-F1 και οι ανά κλάση μεταβολές F1-score. Από τα αναλυτικά αυτά αρχεία προέκυψαν οι συνοπτικοί πίνακες σημαντικότητας ζωνών και τα αντίστοιχα διαγράμματα που παρουσιάζονται στο Κεφάλαιο 7.

6.8 Σύνοψη της πειραματικής διαδικασίας

Συνολικά, η πειραματική διαδικασία της παρούσας εργασίας σχεδιάστηκε έτσι ώστε να αξιολογεί με συστηματικό, αναπαραγωγίμο και στατιστικά τεκμηριωμένο τρόπο την αποτελεσματικότητα ενός πολυσταδιακού πλαισίου μάθησης για την ανίχνευση ασθενειών καλλιεργείων από πολυφασματικά δεδομένα Sentinel-2 [10], [12], [14].

Η διαδικασία περιλάμβανε αυτοεπιβλεπόμενη προεκπαίδευση σε μη επισημασμένα δεδομένα, ενδιάμεση εποπτευόμενη εκπαίδευση σε ταξινομηση καλλιεργείων και τελικό fine-tuning σε ταξινόμηση ασθενειών με 5-fold stratified cross-validation. Για την ενίσχυση της αξιοπιστίας των

συμπερασμάτων εφαρμόστηκε επαναλαμβανόμενη 5-fold cross-validation με διαφορετικά random seeds. Επιπλέον, πραγματοποιήθηκε συγκριτική αξιολόγηση διαφορετικών φασματικών συνδυασμών εισόδου, ώστε να διερευνηθεί η συμβολή των RGB, NIR, red-edge και SWIR ζωνών στην τελική απόδοση του μοντέλου [19], [20].

Για την ενίσχυση της αξιοπιστίας των συμπερασμάτων εφαρμόστηκε επαναλαμβανόμενη 5-fold cross-validation με διαφορετικά random seeds. Τα αποτελέσματα των φασματικών σχημάτων αξιολογήθηκαν όχι μόνο με βάση τη μέση macro-F1 και την τυπική απόκλιση, αλλά και με στατιστικούς ελέγχους. Συγκεκριμένα, χρησιμοποιήθηκε ο έλεγχος Friedman για τη συνολική σύγκριση των σχημάτων και post-hoc pairwise συγκρίσεις με διόρθωση Holm για τον εντοπισμό στατιστικά σημαντικών διαφορών.

Η αξιολόγηση βασίστηκε σε κατάλληλες μετρικές πολυκλασικής ταξινόμησης, με ιδιαίτερη έμφαση στη macro-F1 για το τελικό στάδιο, λόγω της έντονης ανισορροπίας των κλάσεων [4], [9], [12]. Παράλληλα, η χρήση πινάκων σύγχυσης επέτρεψε την αναλυτική ερμηνεία των σφαλμάτων και τη διερεύνηση συστηματικών συγχύσεων μεταξύ κατηγοριών ασθενειών.

Πέρα από την ταξινομητική αξιολόγηση, εφαρμόστηκε band occlusion analysis στο πλήρες πολυφασματικό μοντέλο, με στόχο την εκτίμηση της σημαντικότητας κάθε φασματικής ζώνης Sentinel-2. Η ανάλυση αυτή επέτρεψε την ερμηνεία της συμπεριφοράς του μοντέλου και οδήγησε στον σχεδιασμό ενός πρόσθετου XAI-guided Top-5 φασματικού σχήματος. Με τον τρόπο αυτό, η πειραματική διαδικασία συνδύασε την αξιολόγηση απόδοσης με την ερμηνευτική ανάλυση της φασματικής πληροφορίας.

Το κεφάλαιο αυτό θέτει τη μεθοδολογική βάση για την παρουσίαση και ερμηνεία των πειραματικών αποτελεσμάτων που ακολουθούν. Η ενσωμάτωση repeated cross-validation, στατιστικής αξιολόγησης και XAI-based band importance analysis είναι ιδιαίτερα σημαντική, καθώς επιτρέπει την εξαγωγή πιο ασφαλών συμπερασμάτων και αποτρέπει την υπερερμηνεία μικρών αριθμητικών διαφορών μεταξύ φασματικών σχημάτων.

Κεφάλαιο 7ο: ΑΠΟΤΕΛΕΣΜΑΤΑ

7.1 Εισαγωγή

Στο παρόν κεφάλαιο παρουσιάζονται και αναλύονται τα αποτελέσματα που προέκυψαν από την εφαρμογή της προτεινόμενης πολυσταδιακής μεθοδολογίας για την ανίχνευση ασθενειών καλλιεργείων με αξιοποίηση πολυφασματικών δεδομένων Sentinel-2 και τεχνικών βαθιάς μάθησης [10], [14], [15]. Η αξιολόγηση οργανώθηκε έτσι ώστε να αποτιμάται σταδιακά η συμβολή κάθε φάσης του pipeline, από την αυτοεπιβλεπόμενη προεκπαίδευση έως την τελική ταξινόμηση ασθενειών [10], [14].

Αρχικά παρουσιάζονται τα αποτελέσματα του σταδίου αυτοεπιβλεπόμενης προεκπαίδευσης, όπου ο encoder εκπαιδεύεται σε μη επισημασμένα χρονικά δεδομένα Sentinel-2 [14]. Στη συνέχεια αναλύονται τα αποτελέσματα του ενδιάμεσου σταδίου ταξινόμησης καλλιεργείων, το οποίο λειτουργεί ως βήμα γεωργικής εξειδίκευσης του encoder [5], [10]. Τέλος, εξετάζονται τα αποτελέσματα της τελικής φάσης ταξινόμησης ασθενειών, με ιδιαίτερη έμφαση στη 5-fold διασταυρωμένη επικύρωση, στη macro-F1 και στην ανάλυση των πινάκων σύγχυσης [4], [9], [12].

Κατά τη διάρκεια των πειραμάτων παρατηρήθηκε σημαντική διακύμανση της απόδοσης μεταξύ διαφορετικών εκτελέσεων. Επομένως, μικρές αριθμητικές διαφορές μεταξύ φασματικών σχημάτων δεν μπορούν να ερμηνευθούν με ασφάλεια χωρίς επαναλαμβανόμενη αξιολόγηση και στατιστικό έλεγχο. Για το λόγο αυτό πραγματοποιήθηκαν επιπλέον πειράματα επαναλαμβανόμενης διασταυρούμενης επικύρωσης και στατιστική αξιολόγηση των φασματικών συνδυασμών.

Η παρουσίαση των αποτελεσμάτων ακολουθεί τη λογική της προοδευτικής εξειδίκευσης του μοντέλου. Με τον τρόπο αυτό καθίσταται σαφές όχι μόνο το τελικό επίπεδο απόδοσης του συστήματος, αλλά και η συμβολή των επιμέρους σταδίων στη διαμόρφωση ισχυρών πολυφασματικών αναπαραστάσεων για τη διάκριση καλλιεργείων και ασθενειών [10], [14]. Η σταδιακή αυτή αποτίμηση είναι σημαντική, διότι επιτρέπει την ερμηνεία της συνολικής μεθοδολογίας όχι απλώς ως τελικό classifier, αλλά ως σύνθετη διαδικασία μάθησης που βασίζεται στη μεταφορά γνώσης μεταξύ διαφορετικών επιπέδων γεωργικής πληροφορίας [10].

7.2 Μετρικές αξιολόγησης

Η αξιολόγηση των επιμέρους πειραμάτων βασίστηκε σε κατάλληλες μετρικές ταξινόμησης, ανάλογα με τη φύση του κάθε προβλήματος [12]. Στο στάδιο της αυτοεπιβλεπόμενης μάθησης, κύριο κριτήριο ήταν η πορεία της contrastive συνάρτησης απώλειας, καθώς δεν υπήρχαν ετικέτες για άμεση εποπτευόμενη αξιολόγηση [14], [17]. Στο στάδιο ταξινόμησης καλλιεργείων χρησιμοποιήθηκε ως βασική μετρική η accuracy στο validation set, ενώ στο τελικό στάδιο ταξινόμησης ασθενειών δόθηκε έμφαση τόσο στην accuracy όσο και στη macro-F1, στα επιμέρους F1-scores ανά κλάση και στους πίνακες σύγχυσης [4], [9], [12].

Ιδιαίτερη σημασία αποδόθηκε στη macro-F1 κατά την τελική αξιολόγηση του disease stage, λόγω της σημαντικής ανισορροπίας των διαθέσιμων δειγμάτων μεταξύ των τεσσάρων κατηγοριών [4], [9]. Σε αντίθεση με την accuracy, η macro-F1 αποδίδει ίσο βάρος σε κάθε κλάση και προσφέρει πιο αντιπροσωπευτική εικόνα της πραγματικής συμπεριφοράς του μοντέλου στις υποεκπροσωπούμενες

κατηγορίες [9], [12]. Για τον λόγο αυτό, το βέλτιστο checkpoint κάθε fold επιλέχθηκε με βάση τη μέγιστη τιμή της validation macro-F1 και όχι με βάση τη μικρότερη loss ή τη μέγιστη accuracy [9], [12].

Η επιλογή των μετρικών δεν ήταν απλώς τεχνικό ζήτημα, αλλά ουσιαστικό στοιχείο της πειραματικής μεθοδολογίας. Σε ένα πρόβλημα όπως η ανίχνευση ασθενειών, όπου οι κατηγορίες είναι άνισα κατανομημένες και η πρακτική σημασία των λαθών διαφέρει ανά περίπτωση, η χρήση μόνο μίας συνολικής μετρικής θα μπορούσε να οδηγήσει σε παραπλανητικά συμπεράσματα [4], [9], [12]. Επομένως, η αξιολόγηση οργανώθηκε έτσι ώστε να επιτρέπει τόσο συνολική όσο και αναλυτική κατανόηση της συμπεριφοράς του μοντέλου.

Για τη σύγκριση πολλαπλών φασματικών σχημάτων χρησιμοποιήθηκε επιπλέον επαναλαμβανόμενη διασταυρούμενη επικύρωση και στατιστικοί έλεγχοι. Ο έλεγχος Friedman χρησιμοποιήθηκε για τη διερεύνηση συνολικής στατιστικά σημαντικής διαφοράς μεταξύ των φασματικών σχημάτων, ενώ οι pairwise συγκρίσεις με διόρθωση Holm χρησιμοποιήθηκαν για τον εντοπισμό των επιμέρους ζευγών που διαφέρουν σημαντικά.

7.3 Αποτελέσματα αυτοεπιβλεπόμενης προεκπαίδευσης

Στο πρώτο στάδιο του προτεινόμενου pipeline πραγματοποιήθηκε αυτοεπιβλεπόμενη προεκπαίδευση του πολυφασματικού encoder σε μη επισημασμένα δεδομένα Sentinel-2 [14]. Η διαδικασία βασίστηκε σε αντιθετική μάθηση με χρήση της συνάρτησης απώλειας SupConLoss [17]. Το μοντέλο δέχθηκε ως είσοδο δέκα φασματικές ζώνες του Sentinel-2, δηλαδή τις B2, B3, B4, B5, B6, B7, B8, B8A, B11 και B12 [19], [20]. Για κάθε δείγμα επιλέγονταν έως τέσσερις διαφορετικές χρονικές παρατηρήσεις, ενώ από κάθε παρατήρηση παράγονταν δύο επαυξημένες όψεις μέσω γεωμετρικών μετασχηματισμών, όπως τυχαία περικοπή με αλλαγή κλίμακας, οριζόντια και κατακόρυφη αναστροφή και περιστροφή κατά πολλαπλάσια των 90° [14], [17].

Πριν από την έναρξη της εκπαίδευσης υπολογίστηκαν οι τιμές μέσου και τυπικής απόκλισης των δέκα φασματικών ζωνών, ώστε να εφαρμοστεί κανονικοποίηση στα δεδομένα εισόδου. Η διαδικασία αυτή είναι ιδιαίτερα σημαντική στα πολυφασματικά δεδομένα, καθώς οι επιμέρους ζώνες εμφανίζουν διαφορετικές κατανομές τιμών και διαφορετική στατιστική συμπεριφορά [19], [20]. Οι εκτιμημένες τιμές επιβεβαίωσαν την ανάγκη κατάλληλης κανονικοποίησης πριν από την προεκπαίδευση του encoder.


Η πορεία της συνάρτησης απώλειας έδειξε σταθερή και ομαλή σύγκλιση. Συγκεκριμένα, η τιμή της ssl_loss μειώθηκε από 3.3990 στην πρώτη εποχή σε 2.1512 στην εικοστή πέμπτη, παρουσιάζοντας συνολική μείωση περίπου 36.7%. Η μείωση αυτή ήταν συνεχής σε όλη τη διάρκεια της εκπαίδευσης, χωρίς έντονες ταλαντώσεις ή σημάδια αποσταθεροποίησης. Η συμπεριφορά αυτή υποδηλώνει ότι τόσο η αρχιτεκτονική όσο και οι επιλεγμένες υπερπαραμέτροι ήταν κατάλληλες για το συγκεκριμένο σύνολο μη επισημασμένων δεδομένων [14], [17].

Ιδιαίτερο ενδιαφέρον παρουσιάζει το γεγονός ότι η μεγαλύτερη μείωση της απώλειας σημειώθηκε στις πρώτες εποχές της εκπαίδευσης, ενώ στη συνέχεια ο ρυθμός βελτίωσης επιβραδύνθηκε προοδευτικά. Το εύρημα αυτό είναι συμβατό με τη φύση της αντιθετικής μάθησης, όπου το μοντέλο αρχικά μαθαίνει βασικούς μηχανισμούς ομαδοποίησης των όψεων του ίδιου δείγματος και στη συνέχεια βελτιώνει λεπτότερες διακρίσεις στον χώρο αναπαράστασης [17].

Συνολικά, τα αποτελέσματα του πρώτου σταδίου κρίνονται ιδιαίτερα ικανοποιητικά. Παρότι πρόκειται για στάδιο χωρίς άμεση εποπτευόμενη αξιολόγηση, η ομαλή πτώση της *ssl_loss* αποτελεί ισχυρή ένδειξη ότι ο *encoder* κατόρθωσε να μάθει σταθερές και χρήσιμες πολυφασματικές αναπαραστάσεις από μη επισημασμένα χρονικά δεδομένα Sentinel-2 [14]. Η πραγματική αξία αυτής της προεκπαίδευσης γίνεται εμφανής στα επόμενα στάδια, όπου οι αναπαραστάσεις αυτές επαναχρησιμοποιούνται μέσω μεταφοράς γνώσης για την ταξινόμηση καλλιεργειών και την τελική ανίχνευση ασθενειών [10], [14].

Πίνακας 7.1. Εξέλιξη της απώλειας κατά την αυτοεπιβλεπόμενη προεκπαίδευση.

Εποχή	SSL Loss
1	3.3990
5	2.4179
10	2.2611
15	2.2032
20	2.1682
25	2.1512



Σχήμα 7.1. Εξέλιξη της συνάρτησης απώλειας (SSL loss) κατά την αυτοεπιβλεπόμενη προεκπαίδευση για 25 εποχές.

7.4 Αποτελέσματα ενδιάμεσης εκπαίδευσης ταξινόμησης καλλιεργείας

Στο δεύτερο στάδιο του προτεινόμενου pipeline πραγματοποιήθηκε εποπτευόμενη εκπαίδευση για την ταξινόμηση τύπου καλλιεργείας, με σκοπό την περαιτέρω προσαρμογή του προεκπαιδευμένου *encoder* σε γεωργικά πολυφασματικά δεδομένα [10]. Για τη φάση αυτή χρησιμοποιήθηκε το μοντέλο που αρχικοποιήθηκε από το καλύτερο checkpoint της προηγούμενης αυτοεπιβλεπόμενης προεκπαίδευσης [10], [14]. Το μοντέλο δέχθηκε ως είσοδο τις ίδιες δέκα φασματικές ζώνες και τέσσερις χρονικές παρατηρήσεις ανά δείγμα [19], [20]. Η εκπαίδευση πραγματοποιήθηκε για 25 εποχές με batch size 16, stratified hold-out split 80/20 και seed ίσο με 42 [12].

Το στάδιο αυτό δεν είχε ως μοναδικό σκοπό την επίτευξη υψηλής ακρίβειας στην ταξινόμηση καλλιιεργειών, αλλά κυρίως τη γεωργική εξειδίκευση του encoder σε χαρακτηριστικά που σχετίζονται με τη φασματική και χρονική διαφοροποίηση των καλλιιεργειών [5], [10]. Το μοντέλο αξιοποίησε temporal mean pooling, στο οποίο ο encoder εφαρμόζεται ανεξάρτητα σε κάθε μία από τις τέσσερις χρονικές λήψεις και οι παραγόμενες αναπαραστάσεις συνδυάζονται μέσω μέσου όρου στον χρονικό άξονα πριν από την τελική ταξινόμηση [5].

Η πορεία της εκπαίδευσης έδειξε ουσιαστική μείωση της training loss, από 1.0902 στην πρώτη εποχή σε 0.1535 στην εικοστή πέμπτη. Η εξέλιξη αυτή τεκμηριώνει ότι το μοντέλο προσαρμόστηκε αποτελεσματικά στο πρόβλημα διάκρισης μεταξύ των τεσσάρων τύπων καλλιιεργείας. Παράλληλα, η accuracy στο validation set κινήθηκε σε ικανοποιητικά επίπεδα, με μέγιστη τιμή 0.8163 στην έκτη εποχή. Υψηλές επιδόσεις παρατηρήθηκαν επίσης στις επόμενες εποχές, αν και όχι με απόλυτα μονοτονική πορεία.


Αξίζει να σημειωθεί ότι, ενώ η training loss συνέχισε να μειώνεται σταθερά μέχρι το τέλος της εκπαίδευσης, η validation accuracy δεν παρουσίασε αντίστοιχα σταθερή ανοδική συμπεριφορά. Μετά την επίτευξη της μέγιστης τιμής στην έκτη εποχή, παρατηρήθηκαν διακυμάνσεις, ενώ στην τελευταία εποχή η validation accuracy υποχώρησε σε 0.7075. Η συμπεριφορά αυτή υποδηλώνει ότι μετά από ένα σημείο το μοντέλο άρχισε να προσαρμόζεται υπερβολικά στα δεδομένα εκπαίδευσης, εμφανίζοντας ενδείξεις υπερπροσαρμογής [12].

Το εύρημα αυτό αναδεικνύει τη σημασία της επιλογής του καλύτερου checkpoint με βάση το validation set και όχι της τελευταίας εποχής εκπαίδευσης. Στο συγκεκριμένο πείραμα, το βέλτιστο crop model αντιστοιχεί στην εποχή 6, όπου καταγράφηκε η μέγιστη τιμή val_acc. Το γεγονός αυτό είναι ιδιαίτερα σημαντικό για την επόμενη φάση της μεθοδολογίας, καθώς τα βάρη του encoder από το συγκεκριμένο checkpoint χρησιμοποιούνται ως αρχικοποίηση στο τελικό στάδιο ανίχνευσης ασθενειών [10].

Συνολικά, τα αποτελέσματα του δεύτερου σταδίου δείχνουν ότι η ενδιάμεση εκπαίδευση σε πρόβλημα ταξινόμησης καλλιιεργείας λειτούργησε αποτελεσματικά ως βήμα γεωργικής εξειδίκευσης του encoder [10]. Η επίτευξη validation accuracy άνω του 81% υποδηλώνει ότι το μοντέλο κατάφερε να μάθει διακριτές χρονικές και φασματικές αναπαραστάσεις για διαφορετικούς τύπους καλλιιεργείας [5], [10]. Η εξειδίκευση αυτή θεωρείται κρίσιμη, καθώς ένας encoder που έχει ήδη αποκτήσει γνώση σχετική με τον τύπο καλλιιεργείας είναι ευλογότερο να ανταποκρίνεται καλύτερα στην πιο σύνθετη εργασία της ανίχνευσης ασθενειών [5], [10], [13].

Πίνακας 7.2. Εξέλιξη της απόδοσης κατά την εκπαίδευση ταξινόμησης καλλιιεργείας.

Εποχή	Train Loss	Validation Accuracy
1	1.0902	0.7007
5	0.6841	0.7687
6	0.5919	0.8163
10	0.4727	0.7551
15	0.3241	0.7347
20	0.2833	0.7211
25	0.1535	0.7075



Σχήμα 7.2. Κοινό διάγραμμα της εξέλιξης της training loss και της validation accuracy στο στάδιο ταξινόμησης καλλιέργειας για 25 εποχές.

7.5 Αποτελέσματα τελικής ανίχνευσης ασθενειών

Στο τρίτο και τελικό στάδιο του προτεινόμενου pipeline πραγματοποιήθηκε η ταξινόμηση των τεσσάρων κατηγοριών ασθενειών Aphid, Blast, RPH και Rust. Το μοντέλο αρχικοποιήθηκε από το checkpoint του προηγούμενου crop stage, γεγονός που επέτρεψε τη μεταφορά γνώσης από έναν ήδη γεωργικά εξειδικευμένο encoder προς την τελική εργασία αναγνώρισης ασθενειών [10]. Στην εκπαίδευση χρησιμοποιήθηκαν οι ίδιες δέκα φασματικές ζώνες Sentinel-2, για συνολικά 45 εποχές, με batch size 32, learning rate 2×10^{-4} , weight decay 10^{-4} , seed 42 και στρατηγική 5-fold stratified cross-validation. Παράλληλα, λόγω της σημαντικής ανισορροπίας μεταξύ των κλάσεων, εφαρμόστηκε Weighted Random Sampler ώστε οι υποεκπροσωπούμενες κατηγορίες να συμμετέχουν συχνότερα στην εκπαίδευση [4], [9], [12].

Η χρήση 5-fold διασταυρωμένης επικύρωσης στο τελικό στάδιο είναι ιδιαίτερα σημαντική, καθώς επιτρέπει πιο αξιόπιστη εκτίμηση της γενικευτικής ικανότητας του μοντέλου σε σχέση με ένα μόνο hold-out split [12]. Σε κάθε fold, το μοντέλο εκπαιδεύτηκε εκ νέου από την ίδια αρχικοποίηση encoder, ενώ η επιλογή του βέλτιστου checkpoint γινόταν με βάση τη μέγιστη τιμή της validation macro-F1 [9], [12]. Η επιλογή αυτή είναι πλήρως αιτιολογημένη, καθώς το σύνολο δεδομένων ασθενειών παρουσιάζει έντονη ανισοκατανομή δειγμάτων μεταξύ των κλάσεων και η macro-F1 αποτελεί καταλληλότερη μετρική από την accuracy για την αποτίμηση της πραγματικής ισορροπίας στην επίδοση του μοντέλου [4], [9].

Τα αποτελέσματα των πέντε folds έδειξαν ότι το προτεινόμενο σύστημα πέτυχε υψηλή και σχετικά σταθερή απόδοση. Οι βέλτιστες τιμές validation macro-F1 ανά fold ήταν 0.7248 για το Fold 0, 0.7844

για το Fold 1, 0.6921 για το Fold 2, 0.7476 για το Fold 3 και 0.7549 για το Fold 4. Συνολικά, ο μέσος όρος της βέλτιστης macro-F1 στα πέντε folds ήταν 0.7408, με τυπική απόκλιση 0.0345. Το αποτέλεσμα αυτό υποδηλώνει ότι το μοντέλο όχι μόνο επιτυγχάνει ισχυρή απόδοση, αλλά και διατηρεί ικανοποιητική σταθερότητα απέναντι σε διαφορετικούς διαχωρισμούς των δεδομένων.


Εξίσου σημαντικό είναι το γεγονός ότι τα βέλτιστα checkpoints δεν εντοπίστηκαν στην ίδια εποχή για όλα τα folds, αλλά εμφανίστηκαν συνήθως μεταξύ των εποχών 29 και 42. Πιο συγκεκριμένα, το καλύτερο checkpoint αντιστοιχούσε στην εποχή 34 για το Fold 0, στην εποχή 39 για το Fold 1, στην εποχή 42 για το Fold 2, στην εποχή 29 για το Fold 3 και στην εποχή 40 για το Fold 4. Η παρατήρηση αυτή δείχνει ότι το disease fine-tuning επωφελήθηκε από εκτεταμένη εκπαίδευση, χωρίς όμως να υπάρχει μία ενιαία «ιδανική» εποχή για όλα τα folds. Επομένως, η επιλογή του βέλτιστου checkpoint με βάση τη validation macro-F1 ήταν απαραίτητη για αξιόπιστη αξιολόγηση [9], [12].

Τα αναλυτικά αποτελέσματα δείχνουν επίσης ότι το μοντέλο δεν συμπεριφέρεται ομοιόμορφα σε όλες τις κλάσεις. Η κατηγορία RPH παρουσίασε σταθερά υψηλές επιδόσεις στα περισσότερα folds, γεγονός που είναι αναμενόμενο καθώς αποτελεί και την πολυπληθέστερη κλάση. Πολύ καλή απόδοση εμφάνισε επίσης η κατηγορία Aphid, η οποία σε αρκετά folds πέτυχε F1-score άνω του 0.90. Αντίθετα, η κατηγορία Blast αποδείχθηκε η δυσκολότερη, καθώς το F1-score της παρέμεινε αισθητά χαμηλότερο σε σχέση με τις υπόλοιπες κατηγορίες. Τέλος, η κατηγορία Rust, παρότι υποεκπροσωπούμενη, παρουσίασε σε αρκετές περιπτώσεις αξιοσημείωτη επίδοση, γεγονός που δείχνει ότι η χρήση κατάλληλης δειγματοληψίας κατά την εκπαίδευση βοήθησε το μοντέλο να μάθει βασικά διακριτικά μοτίβα ακόμη και για σπάνιες κατηγορίες [4], [9], [13].

Συνολικά, η τελική επίδοση **Macro-F1 = 0.7408 ± 0.0345** σε 5-fold cross-validation κρίνεται ιδιαίτερα ενθαρρυντική, ιδίως αν ληφθούν υπόψη η δυσκολία του προβλήματος, η περιορισμένη διαθεσιμότητα επισημασμένων δειγμάτων και η έντονη ανισορροπία κλάσεων [4], [9], [12]. Το αποτέλεσμα αυτό ενισχύει την κεντρική υπόθεση της εργασίας, ότι η αυτοεπιβλεπόμενη προεκπαίδευση και η ενδιάμεση γεωργική εξειδίκευση μέσω crop classification προσφέρουν ουσιαστικό πλεονέκτημα στο τελικό disease model [10], [14].

Πίνακας 7.3. Βέλτιστη επίδοση ανά fold στο στάδιο ανίχνευσης ασθενειών.

Fold	Best Epoch	Best Validation Macro-F1
Fold 0	34	0.7248
Fold 1	39	0.7844
Fold 2	42	0.6921
Fold 3	29	0.7476
Fold 4	40	0.7549



Σχήμα 7.3. Βέλτιστη επίδοση του μοντέλου ανά fold στο στάδιο ανίχνευσης ασθενειών, με βάση τη μετρική Validation Macro-F1.


Πίνακας 7.4. Συνοπτική αποτίμηση 5-fold αξιολόγησης.

Μετρική	Τιμή
Μέση καλύτερη Macro-F1	0.7408
Τυπική απόκλιση Macro-F1	0.0345
Καλύτερο fold	0.7844
Χαμηλότερο fold	0.6921

7.5.1 Ανάλυση πινάκων σύγχυσης και ανά κλάση συμπεριφοράς

Η ανάλυση των πινάκων σύγχυσης προσφέρει πιο λεπτομερή εικόνα της συμπεριφοράς του μοντέλου από ό,τι οι συνολικές μετρικές accuracy και macro-F1, καθώς επιτρέπει την αποτύπωση των σωστών και λανθασμένων ταξινομήσεων ανά κατηγορία ασθένειας [12]. Μέσω της εξέτασης των πινάκων σύγχυσης στα πέντε folds καθίσταται δυνατή η διερεύνηση των συστηματικών συγχύσεων μεταξύ των κλάσεων και η ερμηνεία των διαφορών που παρατηρούνται στα επιμέρους F1-scores [12].

Συνολικά, οι πίνακες σύγχυσης έδειξαν ότι το μοντέλο διακρίνει με ιδιαίτερα υψηλή αξιοπιστία τις κατηγορίες Aphid και RPH, ενώ μεγαλύτερη δυσκολία παρουσιάζεται στην αναγνώριση της Blast και, σε μικρότερο βαθμό, της Rust. Η εικόνα αυτή είναι συνεπής με τα επιμέρους αποτελέσματα των F1-scores και αντανακλά τόσο την ανισορροπία του συνόλου δεδομένων όσο και τη διαφορετική φασματική διακριτικότητα των τεσσάρων κατηγοριών [4], [9], [13].



Σχήμα 7.4. Πίνακας σύγχυσης του καλύτερου fold (Fold 1, Epoch 39) για τις κλάσεις Aphid, Blast, RPH και Rust.

7.5.1.1 Συμπεριφορά της κλάσης Aphid

Η κλάση Aphid εμφάνισε σταθερά πολύ υψηλές επιδόσεις στα περισσότερα folds. Στους περισσότερους πίνακες σύγχυσης, η πλειονότητα των δειγμάτων Aphid ταξινομήθηκε σωστά, με περιορισμένο αριθμό σφαλμάτων προς άλλες κατηγορίες. Οι λανθασμένες ταξινομήσεις της Aphid παρατηρούνται κυρίως προς τη Rust, ενώ σε ορισμένες περιπτώσεις εμφανίζονται και μικρότερες συγχύσεις προς άλλες κατηγορίες.

Η συμπεριφορά αυτή υποδηλώνει ότι η Aphid διαθέτει σχετικά ευδιάκριτη φασματική έκφραση για το μοντέλο, πιθανότατα επειδή οι επιπτώσεις της στη φυσιολογία του φυτού αποτυπώνονται με αρκετά συνεπή τρόπο στις χρησιμοποιούμενες φασματικές ζώνες [13]. Η υψηλή επίδοση της κλάσης αυτής δείχνει επίσης ότι το προτεινόμενο pipeline κατάφερε να αξιοποιήσει αποτελεσματικά τόσο τη γενική γνώση της βλάστησης όσο και την ειδική προσαρμογή στο disease task [10], [14].

7.5.1.2 Συμπεριφορά της κλάσης RPH

Η κλάση RPH ήταν μία από τις ευκολότερα αναγνωρίσιμες κατηγορίες. Σε πολλά folds καταγράφηκαν υψηλές τιμές F1-score για τη συγκεκριμένη κλάση, ενώ στους πίνακες σύγχυσης το μεγαλύτερο μέρος των δειγμάτων της εντοπιζόταν σωστά στη διαγώνιο. Το αποτέλεσμα αυτό σχετίζεται αφενός με τον μεγαλύτερο αριθμό διαθέσιμων δειγμάτων της κλάσης στο training set και αφετέρου με το γεγονός ότι η φασματική της συμπεριφορά φαίνεται να διαχωρίζεται επαρκώς από άλλες κατηγορίες [4], [9], [13].

Οι κυριότερες συγχύσεις της RPH εντοπίζονται προς τη Blast, στοιχείο που υποδηλώνει ότι οι δύο αυτές κατηγορίες μοιράζονται, σε ορισμένες περιπτώσεις, κοινά μοτίβα φασματικής απόκρισης [13]. Παρά ταύτα, η συνολική συμπεριφορά της RPH υποδεικνύει ότι η προτεινόμενη μεθοδολογία ανταποκρίθηκε ικανοποιητικά στην αναγνώριση της συγκεκριμένης κλάσης.

7.5.1.3 Συμπεριφορά της κλάσης Blast

Η κλάση Blast αποδείχθηκε η δυσκολότερη κατηγορία για το μοντέλο. Σε όλα τα folds, τα F1-scores της ήταν αισθητά χαμηλότερα σε σχέση με τις υπόλοιπες κλάσεις, ενώ οι πίνακες σύγχυσης έδειξαν ότι σημαντικός αριθμός δειγμάτων Blast ταξινομήθηκε λανθασμένα ως RPH. Πρόκειται για το πιο σταθερό και χαρακτηριστικό μοτίβο σφάλματος της συνολικής διαδικασίας αξιολόγησης.

Η συμπεριφορά αυτή μπορεί να αποδοθεί σε δύο βασικούς παράγοντες: πρώτον, στη σαφή υποεκπροσώπηση της Blast σε σχέση με την RPH και, δεύτερον, στη μερική φασματική ομοιότητα των μεταβολών που προκαλούν οι δύο κατηγορίες στη βλάστηση [4], [9], [13]. Παρότι η χρήση Weighted Random Sampling βελτίωσε την ισορροπία της εκπαίδευσης, δεν εξάλειψε πλήρως τη δυσκολία διάκρισης της συγκεκριμένης κλάσης [4], [9].

Το εύρημα αυτό είναι ιδιαίτερα σημαντικό, διότι αποκαλύπτει το κύριο όριο της τρέχουσας προσέγγισης. Παρά τη συνολικά υψηλή macro-F1, εξακολουθεί να υπάρχει συγκεκριμένο ζεύγος κλάσεων για το οποίο το μοντέλο παρουσιάζει συστηματική αβεβαιότητα. Αυτό προσφέρει πολύτιμη πληροφορία για μελλοντική βελτίωση της μεθοδολογίας, είτε μέσω εμπλουτισμού των δεδομένων είτε μέσω διαφορετικών στρατηγικών μάθησης για δύσκολες και υποεκπροσωπούμενες κατηγορίες [4], [9].

7.5.1.4 Συμπεριφορά της κλάσης Rust

Η κλάση Rust παρουσίασε μεταβλητή αλλά συχνά ικανοποιητική συμπεριφορά, παρά τον πολύ μικρό αριθμό διαθέσιμων δειγμάτων. Σε αρκετά folds το μοντέλο πέτυχε αξιοσημείωτα F1-scores για τη Rust, γεγονός που δείχνει ότι ορισμένα από τα παραδείγματα της κατηγορίας αυτής ήταν αρκετά αντιπροσωπευτικά ώστε να μάθει βασικά διακριτικά μοτίβα [13].

Ωστόσο, η απόδοσή της δεν ήταν σταθερή σε όλα τα folds. Σε ορισμένες περιπτώσεις παρατηρήθηκαν συγχύσεις κυρίως με την Aphid, ενώ σε άλλες η κατηγορία εμφάνισε πιο ασταθή συμπεριφορά. Η μεταβλητότητα αυτή είναι αναμενόμενη σε κλάσεις με πολύ περιορισμένο πλήθος δειγμάτων, όπου ακόμη και μικρές αλλαγές στη σύνθεση του train/validation split μπορούν να επηρεάσουν αισθητά την τελική επίδοση [4], [9].

Η συμπεριφορά της Rust έχει ιδιαίτερο ενδιαφέρον, καθώς δείχνει ότι ακόμη και σε ιδιαίτερα άνισες συνθήκες, η προτεινόμενη διαδικασία fine-tuning δεν καταρρέει εντελώς για τις σπάνιες κλάσεις. Αυτό αποτελεί θετική ένδειξη για την αποτελεσματικότητα της μεθοδολογίας, αλλά ταυτόχρονα υπενθυμίζει

την ανάγκη προσεκτικής ερμηνείας των αποτελεσμάτων σε υποεκπροσωπούμενες κατηγορίες [4], [9], [12].

7.5.1.5 Συνολικά μοτίβα σφαλμάτων

Ένα από τα σημαντικότερα συμπεράσματα από την ανάλυση των πινάκων σύγχυσης είναι ότι τα σφάλματα του μοντέλου δεν κατανέμονται τυχαία, αλλά ακολουθούν επαναλαμβανόμενα μοτίβα [12]. Το σημαντικότερο από αυτά είναι η σύγχυση μεταξύ Blast και RPH, η οποία εμφανίζεται σχεδόν συστηματικά σε πολλά folds και σε πολλές εποχές. Αντίθετα, οι συγχύσεις που αφορούν την Aphid και τη Rust είναι γενικά πιο περιορισμένες.

Το γεγονός αυτό υποδηλώνει ότι το μοντέλο έχει κατακτήσει σε ικανοποιητικό βαθμό τον συνολικό διαχωρισμό του προβλήματος, αλλά εξακολουθεί να δυσκολεύεται σε εκείνα τα ζεύγη κλάσεων που βρίσκονται πιο κοντά μεταξύ τους από φασματική και στατιστική άποψη [13]. Επομένως, η macro-F1 δεν πρέπει να ερμηνεύεται απομονωμένα, αλλά σε συνδυασμό με την επιμέρους συμπεριφορά κάθε κλάσης και με την ποιοτική ανάλυση των λαθών [12].

7.5.2 Συγκριτική αξιολόγηση εναλλακτικών σχημάτων μεταφοράς γνώσης

Στην παρούσα υποενότητα παρουσιάζεται η συγκριτική αξιολόγηση τριών εναλλακτικών σχημάτων εκπαίδευσης για το πρόβλημα της ανίχνευσης ασθενειών από πολυφασματικά δεδομένα Sentinel-2. Στόχος των πειραμάτων ήταν να αποτιμηθεί ποσοτικά η συμβολή της ενδιάμεσης εκπαίδευσης στο task ταξινόμησης καλλιεργειών, καθώς και η συμβολή της αυτοεπιβλεπόμενης προεκπαίδευσης στην τελική απόδοση του disease classification stage [10], [14].


Η αξιολόγηση πραγματοποιήθηκε με χρήση 5-fold stratified cross-validation, ώστε τα αποτελέσματα να μην εξαρτώνται από έναν μόνο τυχαίο διαχωρισμό των δεδομένων [12]. Ως βασική μετρική χρησιμοποιήθηκε η best validation macro-F1, καθώς η macro-F1 θεωρείται καταλληλότερη σε προβλήματα πολυκλασικής ταξινόμησης με ανισόρροπη κατανομή κλάσεων [4], [9], [12].

Τα τρία πειραματικά σχήματα που εξετάστηκαν ήταν τα ακόλουθα:

- **Disease from scratch**, όπου το disease model εκπαιδεύτηκε από τυχαία αρχικοποίηση, χωρίς κανενός είδους προεκπαίδευση.
- **Crop → Disease**, όπου ο encoder εκπαιδεύτηκε αρχικά στο task ταξινόμησης καλλιεργειών και στη συνέχεια μεταφέρθηκε στο task ανίχνευσης ασθενειών.
- **SSL → Crop → Disease**, όπου εφαρμόστηκε αρχικά αυτοεπιβλεπόμενη προεκπαίδευση σε μη επισημασμένα δεδομένα, ακολούθησε εκπαίδευση στο crop task και στη συνέχεια μεταφορά του encoder στο disease task.

Πίνακας 7.5. Συγκριτική αξιολόγηση των τριών πειραματικών σχημάτων εκπαίδευσης.

Πειραματικό σχήμα	Μέση τιμή best validation macro-F1	Τυπική απόκλιση
Disease from scratch	0.5448	0.0165
Crop → Disease	0.5682	0.0258
SSL → Crop → Disease	0.7408	0.0345



Σχήμα 7.5. Συγκριτική επίδοση των τριών πειραματικών σχημάτων εκπαίδευσης με βάση τη μέση τιμή της best validation macro-F1.

Το διάγραμμα παρουσιάζει τη μέση καλύτερη τιμή macro-F1 για τα τρία πειραματικά σχήματα εκπαίδευσης, καθώς και τη διακύμανση της απόδοσης μέσω της τυπικής απόκλισης. Παρατηρείται σαφής υπεροχή του πλήρους πολυσταδιακού σχήματος $SSL \rightarrow Crop \rightarrow Disease$, γεγονός που επιβεβαιώνει τη σημαντική συμβολή της αυτοεπιβλεπόμενης προεκπαίδευσης και της ενδιάμεσης γεωργικής εξειδίκευσης στη βελτίωση της τελικής απόδοσης του μοντέλου.

Από τον Πίνακα 7.5 προκύπτει ότι το σχήμα *Disease from scratch* εμφανίζει τη χαμηλότερη μέση επίδοση, με τιμή 0.5448. Το αποτέλεσμα αυτό αποτελεί το βασικό σημείο αναφοράς της μελέτης και αποτυπώνει την απόδοση ενός *disease classifier* που εκπαιδεύεται αποκλειστικά από τυχαία αρχικοποίηση, χωρίς προηγούμενη γνώση από άλλο task. Η επίδοση αυτή δείχνει ότι, αν και το σύνολο δεδομένων ασθενειών επιτρέπει την εκπαίδευση ενός λειτουργικού ταξινομητή, η γενίκευση παραμένει περιορισμένη όταν η μάθηση ξεκινά από τυχαία αρχικοποίηση [4], [9].

Το σχήμα $Crop \rightarrow Disease$ οδήγησε σε μέση τιμή 0.5682, δηλαδή σε βελτίωση περίπου 0.0234 μονάδων macro-F1 σε σχέση με το baseline. Το εύρημα αυτό δείχνει ότι η εκπαίδευση στο task ταξινόμησης καλλιιεργειών προσφέρει έναν βαθμό μεταφοράς γνώσης προς το *disease task* [5], [10]. Πιο συγκεκριμένα, ο encoder φαίνεται να μαθαίνει βασικά φασματικά και μορφολογικά χαρακτηριστικά της βλάστησης, τα οποία μπορούν να αξιοποιηθούν σε περιορισμένο βαθμό και για την αναγνώριση ασθενειών [10]. Ωστόσο, η βελτίωση αυτή παραμένει σχετικά μικρή, γεγονός που υποδεικνύει ότι η γνώση που αποκτάται μόνο από το *crop task* δεν αρκεί από μόνη της για ουσιαστική αναβάθμιση της τελικής επίδοσης.

Αντίθετα, το πλήρες σχήμα $SSL \rightarrow Crop \rightarrow Disease$ πέτυχε σαφώς υψηλότερη επίδοση, με μέση τιμή 0.7408. Η διαφορά αυτή είναι ιδιαίτερα σημαντική, καθώς αντιστοιχεί σε βελτίωση περίπου 0.1960 μονάδων macro-F1 σε σχέση με το Disease from scratch και περίπου 0.1726 μονάδων σε σχέση με το $Crop \rightarrow Disease$. Το αποτέλεσμα αυτό δείχνει ξεκάθαρα ότι η μεγαλύτερη συνεισφορά στην τελική απόδοση προέρχεται από την αυτοεπιβλεπόμενη προεκπαίδευση, η οποία επιτρέπει στο μοντέλο να μάθει πιο γενικευμένες και πιο μεταφέρσιμες πολυφασματικές αναπαραστάσεις πριν από την έκθεσή του στα disease labels [10], [14].

Πίνακας 7.6. Ερμηνευτική σημασία των επιμέρους πειραματικών σχημάτων.

Disease from scratch	Αποτελεί το βασικό σημείο αναφοράς της μελέτης και αποτυπώνει την επίδοση ενός disease classifier που εκπαιδεύεται αποκλειστικά από τυχαία αρχικοποίηση, χωρίς προηγούμενη προεκπαίδευση.
$Crop \rightarrow Disease$	Εξετάζει κατά πόσο η ενδιάμεση εκπαίδευση στο task ταξινόμησης καλλιεργειών προσφέρει χρήσιμη μεταφερόμενη γνώση για το τελικό task ανίχνευσης ασθενειών.
$SSL \rightarrow Crop \rightarrow Disease$	Αξιολογεί την πλήρη προτεινόμενη μεθοδολογία και αποτυπώνει τη συνδυαστική επίδραση της αυτοεπιβλεπόμενης προεκπαίδευσης και της ενδιάμεσης προσαρμογής στο crop task.

Πίνακας 7.7. Αναλυτικά αποτελέσματα του πειράματος $Crop \rightarrow Disease$ ανά fold.

Fold	Καλύτερη εποχή (Best Epoch)	Best Validation Macro-F1
Fold 0	27	0.5416
Fold 1	28	0.5627
Fold 2	8	0.5481
Fold 3	39	0.5848
Fold 4	45	0.6036
Μέσος όρος	—	0.5682
Τυπική απόκλιση	—	0.0258

Τα αναλυτικά αποτελέσματα του Πίνακα 7.7 δείχνουν ότι το σχήμα $Crop \rightarrow Disease$ εμφανίζει σταθερή αλλά περιορισμένη βελτίωση σε σχέση με το from-scratch baseline. Η καλύτερη επίδοση καταγράφηκε στο Fold 4 με τιμή 0.6036, ενώ η χαμηλότερη στο Fold 0 με τιμή 0.5416. Η συνολική εικόνα δείχνει ότι το crop pretraining προσφέρει ένα μικρό αλλά συνεπές όφελος, χωρίς όμως να πλησιάζει την απόδοση του πλήρους σχήματος με SSL [10].

Η σύγκριση των τριών πειραματικών σχημάτων οδηγεί σε σαφές συμπέρασμα ως προς τον ρόλο κάθε σταδίου της προτεινόμενης μεθοδολογίας. Το Disease from scratch δείχνει ότι η άμεση εκπαίδευση ενός μοντέλου ανίχνευσης ασθενειών από τυχαία αρχικοποίηση δεν είναι επαρκής για υψηλή απόδοση. Το disease dataset είναι σχετικά περιορισμένο και έντονα ανισόρροπο, με αποτέλεσμα το μοντέλο να δυσκολεύεται να μάθει σταθερές και γενικεύσιμες αναπαραστάσεις μόνο από τα διαθέσιμα labels [4], [9].

Το σχήμα Crop → Disease δείχνει ότι η ταξινόμηση καλλιεργειών μπορεί να λειτουργήσει ως ένα χρήσιμο ενδιάμεσο βήμα προσαρμογής. Μέσω αυτού, ο encoder αποκτά βασική γνώση σχετική με τη φασματική δομή και τη μορφολογία της βλάστησης, η οποία μεταφέρεται στη συνέχεια στο disease task [5], [10]. Παρ' όλα αυτά, το μέγεθος του κέρδους παραμένει μικρό, γεγονός που δείχνει ότι η γνώση από το crop task δεν επαρκεί για ουσιαστική αναβάθμιση της συνολικής επίδοσης.

Το πλήρες σχήμα SSL → Crop → Disease παρουσιάζει σαφώς ανώτερη απόδοση από τα δύο προηγούμενα. Το εύρημα αυτό υποδηλώνει ότι το σημαντικότερο δομικό στοιχείο της προτεινόμενης pipeline είναι η αυτοεπιβλεπόμενη προεκπαίδευση. Μέσω αυτής, το μοντέλο αξιοποιεί μεγάλο όγκο μη επισημασμένων πολυφασματικών δεδομένων και μαθαίνει γενικές φασματικές αναπαραστάσεις, πριν ακόμη εκτεθεί στα disease labels [14]. Όταν αυτή η γνώση ακολουθείται από το στάδιο crop adaptation και τελικά από το disease fine-tuning, το μοντέλο εμφανίζει σημαντικά υψηλότερη ικανότητα γενίκευσης [10], [14].

Η παρουσία του ενδιάμεσου πειράματος Crop → Disease είναι κρίσιμη, καθώς επιτρέπει την απομόνωση της συνεισφοράς του σταδίου γεωργικής εξειδίκευσης από εκείνη της αυτοεπιβλεπόμενης προεκπαίδευσης. Αν είχε συγκριθεί μόνο το baseline με το πλήρες μοντέλο, δεν θα ήταν δυνατό να προσδιοριστεί με σαφήνεια αν το όφελος προέρχεται κυρίως από το crop stage ή από το SSL. Η ύπαρξη του ενδιάμεσου πειράματος ενισχύει σημαντικά την πειραματική τεκμηρίωση της εργασίας [10].

Συνοψίζοντας, η συγκριτική αξιολόγηση των τριών πειραματικών σχημάτων δείχνει ότι η απλή μεταφορά γνώσης από την ταξινόμηση καλλιεργειών προς την ανίχνευση ασθενειών οδηγεί μόνο σε περιορισμένη βελτίωση. Αντίθετα, η ενσωμάτωση αυτοεπιβλεπόμενης προεκπαίδευσης μεταβάλλει ουσιαστικά την απόδοση του συστήματος. Το πλήρες σχήμα SSL → Crop → Disease υπερέχει καθαρά τόσο του baseline Disease from scratch όσο και του ενδιάμεσου σχήματος Crop → Disease, γεγονός που επιβεβαιώνει ότι η αυτοεπιβλεπόμενη εκμάθηση αποτελεί το σημαντικότερο δομικό στοιχείο της προτεινόμενης μεθοδολογίας [10], [14].

7.5.3 Συγκριτική αξιολόγηση διαφορετικών φασματικών συνδυασμών εισόδου

Στην παρούσα υποενότητα παρουσιάζεται η συγκριτική αξιολόγηση διαφορετικών φασματικών συνδυασμών εισόδου στο τελικό στάδιο ανίχνευσης ασθενειών. Στόχος των πειραμάτων ήταν να διερευνηθεί κατά πόσο η χρήση μεγαλύτερου αριθμού φασματικών ζωνών Sentinel-2 οδηγεί πράγματι σε βελτιωμένη απόδοση, καθώς και να εντοπιστούν οι φασματικές περιοχές που συνεισφέρουν ουσιαστικότερα στη διάκριση των τεσσάρων κατηγοριών ασθενειών.

Η αξιολόγηση πραγματοποιήθηκε στο ίδιο πολυσταδιακό pipeline **SSL** → **Crop** → **Disease**, διατηρώντας σταθερό το γενικό πειραματικό πρωτόκολλο. Για κάθε φασματικό σχήμα εφαρμόστηκε η ίδια λογική εκπαίδευσης και αξιολόγησης με **5-fold cross-validation**, ενώ ως βασική μετρική χρησιμοποιήθηκε η μέση τιμή της καλύτερης validation macro-F1. Η χρήση της macro-F1 είναι ιδιαίτερα σημαντική, καθώς το σύνολο δεδομένων ασθενειών παρουσιάζει έντονη ανισορροπία μεταξύ των κλάσεων.

Τα φασματικά σχήματα που αξιολογήθηκαν παρουσιάζονται στον Πίνακα 7.8.

Πίνακας 7.8. Φασματικά σχήματα εισόδου που αξιολογήθηκαν.

Φασματικός συνδυασμός	Ζώνες Sentinel-2
RGB	B2, B3, B4
RGB + NIR	B2, B3, B4, B8
NIR + Red-edge	B5, B6, B7, B8, B8A
RGB + Red-edge χωρίς NIR	B2, B3, B4, B5, B6, B7
RGB + NIR + Red-edge	B2, B3, B4, B5, B6, B7, B8, B8A
Red-edge + NIR + SWIR	B5, B6, B7, B8, B8A, B11, B12
Full multispectral	B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12

Τα συγκριτικά αποτελέσματα των διαφορετικών φασματικών συνδυασμών παρουσιάζονται στον Πίνακα 7.9.

Πίνακας 7.9. Συγκριτικά αποτελέσματα διαφορετικών φασματικών συνδυασμών.

Φασματικός συνδυασμός	Πλήθος ζωνών	Mean Best Validation Macro-F1	Std
RGB	3	0.7706	0.0422
RGB + NIR	4	0.7912	0.0464
NIR + Red-edge	5	0.7784	0.0357
RGB + Red-edge χωρίς NIR	6	0.7578	0.0191
Red-edge + NIR + SWIR	7	0.7180	0.0122
RGB + NIR + Red-edge	8	0.7617	0.0187
Full multispectral	10	0.7408	0.0345

RGB		0.7706
RGB + NIR		0.7912
NIR + red-edge		0.7784
RGB + NIR + red-edge		0.7617
RGB + red-edge χωρίς NIR		0.7578
Full multispectral		0.7408

red-edge + NIR + SWIR  0.7180

Σχήμα 7.6. Συγκριτική επίδοση Macro-F1 ανά φασματικό συνδυασμό.

7.5.3.1 Ανάλυση αποτελεσμάτων

Από τα αποτελέσματα του Πίνακα 7.9 προκύπτει ότι ο αποδοτικότερος φασματικός συνδυασμός ήταν το σχήμα **RGB + NIR**, το οποίο πέτυχε μέση τιμή **best validation macro-F1 ίση με 0.7912**. Η επίδοση αυτή είναι υψηλότερη από όλα τα υπόλοιπα σχήματα, γεγονός που υποδηλώνει ότι η προσθήκη της ζώνης NIR στο ορατό φάσμα παρέχει ιδιαίτερα χρήσιμη συμπληρωματική πληροφορία για την ανίχνευση των εξεταζόμενων ασθενειών.

Ιδιαίτερα σημαντικό εύρημα αποτελεί και η υψηλή επίδοση του σχήματος NIR + red-edge, το οποίο κατέγραψε μέση macro-F1 ίση με 0.7784, αποτελώντας το δεύτερο καλύτερο αποτέλεσμα. Η επίδοση αυτή δείχνει ότι οι ζώνες red-edge μπορούν να αξιοποιηθούν αποτελεσματικά όταν συνδυάζονται με τη ζώνη NIR, ακόμη και χωρίς τη συμμετοχή των κλασικών RGB ζωνών.

Το σχήμα **RGB** παρουσίασε επίσης ισχυρή απόδοση, με μέση macro-F1 ίση με **0.7706**. Το αποτέλεσμα αυτό δείχνει ότι σημαντικό μέρος της πληροφορίας των ασθενειών αποτυπώνεται ήδη στις ορατές ζώνες. Συμπτώματα όπως αποχρωματισμοί, κιτρίνισμα, νεκρωτικές κηλίδες και διαφοροποιήσεις στην υφή της φυτοκάλυψης φαίνεται ότι αξιοποιούνται αποτελεσματικά από το μοντέλο.

Ωστόσο, επειδή οι διαφορές μεταξύ των κορυφαίων σχημάτων ήταν σχετικά μικρές και επειδή παρατηρήθηκε μεταβλητότητα μεταξύ διαφορετικών εκτελέσεων, κρίθηκε απαραίτητη η επανάληψη της αξιολόγησης με διαφορετικές αρχικοποιήσεις. Τα αποτελέσματα της επαναλαμβανόμενης διασταυρούμενης επικύρωσης παρουσιάζονται στην επόμενη ενότητα και οδηγούν σε πιο ασφαλή και στατιστικά τεκμηριωμένη ερμηνεία.

7.6 Επαναλαμβανόμενη διασταυρούμενη επικύρωση και στατιστική αξιολόγηση

7.6.1 Κίνητρο και μεθοδολογία

Για την αξιόπιστη αξιολόγηση των διαφορετικών φασματικών συνδυασμών εφαρμόστηκε επαναλαμβανόμενη διασταυρούμενη επικύρωση πέντε πτυχών (Repeated 5-fold Cross-Validation) με διαφορετικές τιμές αρχικοποίησης seed. Η επιλογή αυτής της διαδικασίας κρίθηκε απαραίτητη, καθώς κατά τη διάρκεια των πειραμάτων παρατηρήθηκε σημαντική διακύμανση της απόδοσης μεταξύ διαφορετικών εκτελέσεων. Το γεγονός αυτό υποδηλώνει ότι η αξιολόγηση ενός μοντέλου με βάση μία μόνο εκτέλεση μπορεί να οδηγήσει σε μη ασφαλή συμπεράσματα, ιδιαίτερα όταν το διαθέσιμο σύνολο δεδομένων είναι σχετικά μικρό και παρουσιάζει ανισορροπία μεταξύ των κλάσεων.

Η χρήση διαφορετικών seeds επηρεάζει παράγοντες όπως η αρχικοποίηση των βαρών του μοντέλου, ο διαχωρισμός των δεδομένων σε σύνολα εκπαίδευσης και επικύρωσης, καθώς και η σειρά

παρουσίασης των δειγμάτων κατά την εκπαίδευση. Σε προβλήματα με περιορισμένο αριθμό δειγμάτων, οι παράγοντες αυτοί μπορούν να έχουν αισθητή επίδραση στην τελική απόδοση.

Στην παρούσα εργασία διαπιστώθηκε ότι η μεταβολή της τιμής macro-F1 μεταξύ διαφορετικών εκτελέσεων ήταν της ίδιας τάξης μεγέθους με τις διαφορές μεταξύ ορισμένων από τους εξεταζόμενους φασματικούς συνδυασμούς. Επομένως, μικρές αριθμητικές διαφορές μεταξύ δύο σχημάτων δεν μπορούν να θεωρηθούν αυτόματα ένδειξη πραγματικής υπεροχής του ενός έναντι του άλλου.


Για τον λόγο αυτό, τα τελικά συμπεράσματα δεν βασίστηκαν στην καλύτερη μεμονωμένη εκτέλεση, αλλά στη μέση τιμή και την τυπική απόκλιση της macro-F1 σε πολλαπλές επαναλήψεις. Με τον τρόπο αυτό μειώνεται η επίδραση της τυχαιότητας και παρέχεται πιο αξιόπιστη εικόνα για τη γενικευτική ικανότητα κάθε φασματικού σχήματος.

7.6.2 Αποτελέσματα επαναλαμβανόμενης διασταυρούμενης επικύρωσης

Πίνακας 7.10. Αποτελέσματα repeated 5-fold cross-validation για τους διαφορετικούς φασματικούς συνδυασμούς.

Φασματικός συνδυασμός	Ζώνες Sentinel-2	Mean Macro-F1	Std
RGB	B2, B3, B4	0.7732	0.0381
RGB + NIR	B2, B3, B4, B8	0.7695	0.0435
RGB + NIR + Red-edge	B2, B3, B4, B5, B6, B7, B8, B8A	0.7675	0.0305
NIR + Red-edge	B5, B6, B7, B8, B8A	0.7619	0.0434
RGB + Red-edge χωρίς NIR	B2, B3, B4, B5, B6, B7	0.7564	0.0238
XAI-guided Top-5	B3, B4, B7, B8, B8A	0.7558	0.0471
Full multispectral	B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12	0.7553	0.0352
Red-edge + NIR + SWIR	B5, B6, B7, B8, B8A, B11, B12	0.7256	0.0434

Το XAI-guided Top-5 σχήμα αποτελεί πρόσθετο διερευνητικό φασματικό πείραμα, το οποίο σχεδιάστηκε μετά την band occlusion analysis του πλήρους πολυφασματικού μοντέλου.



Σχήμα 7.7. Συγκριτική επίδοση macro-F1 ανά φασματικό συνδυασμό μετά την επαναλαμβανόμενη διασταυρούμενη επικύρωση. Οι ράβδοι σφάλματος αντιστοιχούν στην τυπική απόκλιση των επαναλαμβανόμενων folds.

Από τα αποτελέσματα προκύπτει ότι το RGB σχήμα πέτυχε την υψηλότερη μέση τιμή macro-F1, με επίδοση 0.7732 και τυπική απόκλιση 0.0381. Πολύ κοντινές επιδόσεις εμφάνισαν επίσης τα σχήματα RGB + NIR και RGB + NIR + red-edge, με τιμές 0.7695 και 0.7675 αντίστοιχα. Το αποτέλεσμα αυτό δείχνει ότι οι ορατές ζώνες αποτελούν ιδιαίτερα ισχυρή πηγή πληροφορίας για το συγκεκριμένο πρόβλημα ταξινόμησης ασθενειών.

Το πλήρες πολυφασματικό σχήμα, παρότι περιλαμβάνει το σύνολο των διαθέσιμων ζωνών B2, B3, B4, B5, B6, B7, B8, B8A, B11 και B12, δεν οδήγησε σε βελτίωση έναντι των πιο περιορισμένων φασματικών σχημάτων. Η μέση macro-F1 του Full multispectral ήταν 0.7553, δηλαδή χαμηλότερη από τα σχήματα RGB, RGB + NIR και RGB + NIR + red-edge. Η παρατήρηση αυτή υποδηλώνει ότι η αύξηση της φασματικής διαστατικότητας δεν συνεπάγεται απαραίτητα καλύτερη γενίκευση, ιδίως σε μικρά και ανισόρροπα σύνολα δεδομένων.

Ιδιαίτερο ενδιαφέρον παρουσιάζει το XAI-guided Top-5 σχήμα, το οποίο βασίστηκε στις ζώνες που αναδείχθηκαν ως σημαντικότερες από την band occlusion analysis. Το σχήμα αυτό πέτυχε mean macro-F1 ίση με 0.7558, δηλαδή πρακτικά συγκρίσιμη με το Full multispectral σχήμα, χρησιμοποιώντας όμως μόνο πέντε από τις δέκα διαθέσιμες ζώνες. Το αποτέλεσμα αυτό δείχνει ότι ένα μικρότερο και ερμηνευτικά καθοδηγούμενο φασματικό subset μπορεί να διατηρήσει μεγάλο μέρος της πληροφορίας του πλήρους πολυφασματικού μοντέλου.

7.6.3 Έλεγχος Friedman

Προκειμένου να εξεταστεί εάν οι παρατηρούμενες διαφορές μεταξύ των φασματικών σχημάτων είναι στατιστικά σημαντικές, εφαρμόστηκε αρχικά ο μη παραμετρικός έλεγχος Friedman. Ο έλεγχος αυτός είναι κατάλληλος για τη σύγκριση περισσότερων από δύο μεθόδων σε επαναλαμβανόμενα πειραματικά σενάρια, καθώς δεν προϋποθέτει κανονικότητα των επιδόσεων.

Πίνακας 7.11. Αποτέλεσμα ελέγχου Friedman.

Έλεγχος	Αποτέλεσμα	Ερμηνεία
Friedman test	$\chi^2 = 31.6629$, $p = 0.000019$	Υπάρχει ισχυρή συνολική στατιστικά σημαντική διαφορά μεταξύ των φασματικών σχημάτων

Το αποτέλεσμα του ελέγχου ήταν $\chi^2 = 31.6629$ με $p = 0.000019$, γεγονός που υποδηλώνει την ύπαρξη συνολικής στατιστικά σημαντικής διαφοράς μεταξύ των εξεταζόμενων φασματικών συνδυασμών. Ωστόσο, ο έλεγχος Friedman δεν προσδιορίζει ποια συγκεκριμένα ζεύγη φασματικών σχημάτων διαφέρουν μεταξύ τους. Για τον λόγο αυτό ακολούθησαν pairwise συγκρίσεις με διόρθωση Holm.

Το XAI-guided Top-5 σχήμα παρουσιάζεται ως πρόσθετο διερευνητικό αποτέλεσμα, καθώς προέκυψε μετά την ερμηνευτική ανάλυση του πλήρους πολυφασματικού μοντέλου. Επομένως, η στατιστική σύγκριση των αρχικά ορισμένων φασματικών σχημάτων παραμένει η βασική βάση αξιολόγησης, ενώ το Top-5 χρησιμοποιείται κυρίως για την ερμηνευτική διερεύνηση της δυνατότητας μείωσης των φασματικών καναλιών.

7.6.4 Pairwise συγκρίσεις με διόρθωση Holm

Στη συνέχεια πραγματοποιήθηκαν pairwise συγκρίσεις με διόρθωση Holm, ώστε να εντοπιστούν τα ζεύγη φασματικών σχημάτων που διαφέρουν στατιστικά σημαντικά μεταξύ τους. Τα αποτελέσματα έδειξαν ότι οι στατιστικά σημαντικές διαφορές αφορούν κυρίως συγκρίσεις των υπόλοιπων σχημάτων με το χαμηλότερης απόδοσης σχήμα red-edge + NIR + SWIR.

Πίνακας 7.12. Στατιστικά σημαντικές pairwise συγκρίσεις μετά από Holm correction.

Σύγκριση	Διαφορά μέσων	Holm p-adj	Σημαντική;
RGB + NIR + Red-edge vs Red-edge + NIR + SWIR	+0.0419	0.0011	Ναι

Σύγκριση	Διαφορά μέσων	Holm p-adj	Σημαντική;
RGB vs Red-edge + NIR + SWIR	+0.0476	0.0043	Ναι
Full multispectral vs Red-edge + NIR + SWIR	+0.0298	0.0082	Ναι
RGB + NIR vs Red-edge + NIR + SWIR	+0.0439	0.0088	Ναι
NIR + Red-edge vs Red-edge + NIR + SWIR	+0.0363	0.0095	Ναι
RGB + Red-edge χωρίς NIR vs Red-edge + NIR + SWIR	+0.0308	0.0260	Ναι

Τα αποτελέσματα των pairwise συγκρίσεων δείχνουν ότι το σχήμα red-edge + NIR + SWIR είναι στατιστικά χειρότερο από τα περισσότερα υπόλοιπα φασματικά σχήματα. Αντίθετα, οι διαφορές μεταξύ των κορυφαίων σχημάτων, δηλαδή RGB, RGB + NIR, RGB + NIR + red-edge και NIR + red-edge, δεν αποδείχθηκαν στατιστικά σημαντικές μεταξύ τους.

Επομένως, παρότι το RGB εμφανίζει την υψηλότερη αριθμητική επίδοση, δεν μπορεί να υποστηριχθεί ότι υπερέχει στατιστικά έναντι των υπόλοιπων κορυφαίων σχημάτων. Το ορθότερο συμπέρασμα είναι ότι τα καλύτερα φασματικά σχήματα είναι πρακτικά ισοδύναμα, με μικρή αριθμητική υπεροχή του RGB.

7.7 Ανάλυση σημαντικότητας φασματικών ζωνών μέσω band occlusion

7.7.1 Συνολική σημαντικότητα φασματικών ζωνών

Για την περαιτέρω ερμηνεία της συμβολής των επιμέρους φασματικών ζωνών πραγματοποιήθηκε band occlusion analysis στο πλήρες πολυφασματικό σχήμα εισόδου [28]. Η ανάλυση εφαρμόστηκε στα μοντέλα που προέκυψαν από την επαναλαμβανόμενη 5-fold διασταυρούμενη επικύρωση, δηλαδή σε 25 συνολικά repeat-fold runs.


Για κάθε μοντέλο υπολογίστηκε αρχικά η baseline macro-F1 στο αντίστοιχο validation set. Στη συνέχεια, κάθε φασματική ζώνη αποκρύφθηκε μεμονωμένα, αντικαθιστώντας τις τιμές της με τη μέση κανονικοποιημένη τιμή, και υπολογίστηκε εκ νέου η macro-F1.

Η σημαντικότητα κάθε ζώνης εκφράστηκε ως η μέση πτώση της macro-F1 σε σχέση με την αρχική επίδοση του ίδιου μοντέλου. Υψηλότερη τιμή πτώσης υποδηλώνει ότι η αντίστοιχη ζώνη είχε μεγαλύτερη επίδραση στην ταξινόμηση. Με τον τρόπο αυτό, η ανάλυση προσφέρει μια πρακτική εκτίμηση του βαθμού στον οποίο το εκπαιδευμένο full multispectral μοντέλο εξαρτάται από κάθε φασματικό κανάλι.

Πίνακας 7.13. Σημαντικότητα φασματικών ζωνών Sentinel-2 με βάση band occlusion analysis στο πλήρες πολυφασματικό σχήμα.

Κατάταξη	Φασματική ζώνη	Φασματική περιοχή	Μέση πτώση Macro-F1	Τυπική απόκλιση	Runs
1	B8A	Red-edge / NIR	0.3497	0.0730	25
2	B3	Ορατό – Πράσινο	0.3177	0.0870	25

Κατάταξη	Φασματική ζώνη	Φασματική περιοχή	Μέση πτώση Macro-F1	Τυπική απόκλιση	Runs
3	B4	Ορατό – Κόκκινο	0.3100	0.0709	25
4	B7	Red-edge	0.2475	0.0767	25
5	B8	NIR	0.2409	0.0535	25
6	B12	SWIR	0.2199	0.0591	25
7	B6	Red-edge	0.2109	0.1037	25
8	B11	SWIR	0.2050	0.0559	25
9	B2	Ορατό – Μπλε	0.1611	0.0533	25
10	B5	Red-edge	0.1570	0.0687	25



Σχήμα 7.8. Μέση πτώση της macro-F1 μετά από απόκρυψη κάθε φασματικής ζώνης Sentinel-2 στο πλήρες πολυφασματικό μοντέλο. Οι ράβδοι σφάλματος αντιστοιχούν στην τυπική απόκλιση σε 25 repeat-fold runs.

Η κατάταξη των ζωνών δείχνει ότι η σημαντικότερη πληροφορία του πλήρους μοντέλου δεν προέρχεται αποκλειστικά από μία φασματική περιοχή, αλλά από συνδυασμό ορατού, red-edge και NIR φάσματος. Η παρατήρηση αυτή υποστηρίζει την ανάγκη ερμηνευτικής ανάλυσης πέρα από την απλή σύγκριση συνολικών φασματικών σχημάτων.

Τα αποτελέσματα δείχνουν ότι η ζώνη B8A παρουσίασε τη μεγαλύτερη επίδραση στην απόδοση του πλήρους πολυφασματικού μοντέλου, με μέση πτώση macro-F1 ίση με 0.3497. Η ζώνη αυτή βρίσκεται στη μετάβαση μεταξύ red-edge και εγγύς υπερόυθρου και συνδέεται με τη φυσιολογική κατάσταση και τη δομή της βλάστησης [13], [19], [20]. Η υψηλή σημαντικότητά της υποδηλώνει ότι το μοντέλο

αξιοποιεί έντονα πληροφορία που σχετίζεται με αλλαγές στη φυτική δομή και στη φυσιολογική κατάσταση.

Ιδιαίτερα σημαντικές εμφανίστηκαν επίσης οι ορατές ζώνες B3 και B4, με μέση πτώση 0.3177 και 0.3100 αντίστοιχα. Το εύρημα αυτό είναι ιδιαίτερα σημαντικό, καθώς συνδέεται με την υψηλή απόδοση του RGB σχήματος στη συγκριτική αξιολόγηση των φασματικών συνδυασμών. Η συμβολή των B3 και B4 δείχνει ότι το μοντέλο αξιοποιεί έντονα πληροφορία σχετική με χρωματικές διαφοροποιήσεις, χλωροφύλλη και ορατά συμπτώματα, κάτι που είναι συμβατό με τη βιβλιογραφία για την τηλεπισκοπική ανίχνευση φυτικής κατάστασης και ασθενειών [8], [13], [24].

Οι ζώνες B7 και B8 συμπληρώνουν την ομάδα των πέντε σημαντικότερων καναλιών, αναδεικνύοντας τον ρόλο της red-edge και NIR πληροφορίας στην αποτύπωση φυτικής δομής και φυσιολογικού στρες. Αντίθετα, οι ζώνες B2 και B5 εμφάνισαν τη χαμηλότερη μέση επίδραση στη macro-F1. Οι SWIR ζώνες B11 και B12 παρουσίασαν μέτρια συμβολή, γεγονός που δείχνει ότι παρέχουν χρήσιμη αλλά όχι κυρίαρχη πληροφορία για το συγκεκριμένο task.

Είναι σημαντικό να τονιστεί ότι η band occlusion analysis δεν αποδεικνύει αιτιώδη σχέση μεταξύ μιας ζώνης και μιας συγκεκριμένης ασθένειας. Αντίθετα, αποτυπώνει την εξάρτηση του εκπαιδευμένου μοντέλου από κάθε κανάλι εισόδου. Για τον λόγο αυτό, τα αποτελέσματα ερμηνεύονται συμπληρωματικά προς τη συγκριτική αξιολόγηση των φασματικών σχημάτων.

7.7.2 Ανάλυση σημαντικότητας φασματικών ζωνών ανά κλάση ασθένειας

Πέρα από τη συνολική εκτίμηση της σημαντικότητας των φασματικών ζωνών, πραγματοποιήθηκε επιπλέον ανάλυση band occlusion σε επίπεδο επιμέρους κλάσεων [28]. Η ανάλυση αυτή κρίθηκε απαραίτητη, καθώς η συνολική πτώση της macro-F1 αποτυπώνει τη μέση επίδραση κάθε ζώνης στο σύνολο του προβλήματος, αλλά δεν αποκαλύπτει αν όλες οι ασθένειες επηρεάζονται με τον ίδιο τρόπο από την απόκρυψη της ίδιας φασματικής πληροφορίας.

Για τον σκοπό αυτό, μετά την απόκρυψη κάθε ζώνης υπολογίστηκε όχι μόνο η συνολική μεταβολή της macro-F1, αλλά και η μεταβολή του F1-score για κάθε επιμέρους κλάση ασθένειας. Η τιμή $\Delta F1$ για κάθε ζώνη και κάθε κλάση ορίστηκε ως η διαφορά μεταξύ του αρχικού F1-score της κλάσης και του F1-score μετά την απόκρυψη της συγκεκριμένης ζώνης. Μεγαλύτερη τιμή $\Delta F1$ υποδηλώνει ότι η αντίστοιχη ζώνη είχε μεγαλύτερη επίδραση στην αναγνώριση της συγκεκριμένης ασθένειας.

Πίνακας 7.14. Μέση πτώση F1-score ανά κλάση μετά από απόκρυψη κάθε φασματικής ζώνης στο πλήρες πολυφασματικό μοντέλο.

Ζώνη	Aphid $\Delta F1$	Blast $\Delta F1$	RPH $\Delta F1$	Rust $\Delta F1$
B8A	0.3936	0.3366	0.2159	0.4528
B3	0.3869	0.2861	0.1714	0.4263
B4	0.4692	0.2252	0.2002	0.3454
B7	0.2385	0.2116	0.1235	0.4165
B8	0.3067	0.1613	0.1090	0.3866
B12	0.2295	0.1874	0.1173	0.3454
B6	0.1795	0.2067	0.0951	0.3623
B11	0.1771	0.1967	0.0983	0.3479

Ζώνη	Aphid $\Delta F1$	Blast $\Delta F1$	RPH $\Delta F1$	Rust $\Delta F1$
B2	0.1523	0.1505	0.0647	0.2769
B5	0.1659	0.1106	0.0612	0.2905

Οι τιμές εκφράζουν τη μέση πτώση του F1-score κάθε κλάσης μετά από την απόκρυψη της αντίστοιχης ζώνης. Υψηλότερες τιμές υποδηλώνουν μεγαλύτερη εξάρτηση της κλάσης από τη συγκεκριμένη φασματική πληροφορία.

Τα αποτελέσματα του Πίνακα 7.14 δείχνουν ότι η φασματική ευαισθησία διαφοροποιείται μεταξύ των επιμέρους κατηγοριών ασθενειών. Η ζώνη B8A εμφανίζει υψηλή επίδραση σε όλες τις κλάσεις, με ιδιαίτερα μεγάλη πτώση F1 στις κλάσεις Rust, Aphid και Blast. Το εύρημα αυτό ενισχύει τη συνολική band occlusion analysis, σύμφωνα με την οποία η B8A ήταν η σημαντικότερη ζώνη του πλήρους πολυφασματικού μοντέλου. Η θέση της B8A στην περιοχή μετάβασης red-edge/NIR την καθιστά ιδιαίτερα ευαίσθητη σε μεταβολές που σχετίζονται με τη φυτική δομή, τη χλωροφύλλη και τη φυσιολογική κατάσταση της βλάστησης.

Ιδιαίτερα σημαντική είναι επίσης η συμβολή των ορατών ζωνών B3 και B4. Η B4 παρουσιάζει τη μεγαλύτερη επίδραση στην κλάση Aphid, ενώ οι B3 και B4 εμφανίζουν υψηλές τιμές $\Delta F1$ και στις υπόλοιπες κλάσεις. Το αποτέλεσμα αυτό υποστηρίζει την υψηλή απόδοση του RGB σχήματος στη συνολική αξιολόγηση, καθώς δείχνει ότι η ορατή πληροφορία δεν είναι σημαντική μόνο σε επίπεδο συνολικής macro-F1, αλλά και σε επίπεδο επιμέρους ασθενειών.

Η κλάση Rust παρουσιάζει ιδιαίτερα υψηλή ευαισθησία στις ζώνες B8A, B3, B7, B8 και B6. Το πρότυπο αυτό δείχνει ότι η διάκρισή της βασίζεται σε συνδυασμό ορατής και red-edge/NIR πληροφορίας. Η παρατήρηση αυτή είναι ερμηνευτικά σημαντική, καθώς υποδηλώνει ότι για ορισμένες ασθένειες η μη ορατή φασματική πληροφορία μπορεί να έχει έντονη συμπληρωματική αξία, ακόμη και αν το πλήρες πολυφασματικό σχήμα δεν υπερτερεί συνολικά του RGB.

Αντίθετα, η κλάση RPH εμφανίζει χαμηλότερες τιμές $\Delta F1$ στις περισσότερες ζώνες. Αυτό μπορεί να υποδηλώνει ότι η ταξινόμησή της δεν εξαρτάται έντονα από μία μεμονωμένη φασματική ζώνη, αλλά από πιο κατανεμημένη πληροφορία στο σύνολο της εισόδου. Εναλλακτικά, μπορεί να σχετίζεται με τη μεγαλύτερη εκπροσώπηση της συγκεκριμένης κλάσης στο dataset, γεγονός που επιτρέπει στο μοντέλο να μάθει πιο σταθερά πρότυπα ταξινόμησης.

Η κλάση Blast εμφανίζει ενδιάμεση συμπεριφορά, με μεγαλύτερη εξάρτηση από τις B8A, B3, B4, B7 και B6. Ωστόσο, οι τιμές $\Delta F1$ παραμένουν χαμηλότερες σε σχέση με τις αντίστοιχες τιμές της Aphid και της Rust. Το αποτέλεσμα αυτό είναι συμβατό με την παρατηρούμενη δυσκολία ταξινόμησης της Blast, η οποία πιθανόν συνδέεται με τον μικρό αριθμό διαθέσιμων δειγμάτων, τη φασματική επικάλυψη με άλλες μορφές στρες και τη χωρική ανάλυση των Sentinel-2 δεδομένων [4], [9], [13].


Πίνακας 7.15. Πέντε σημαντικότερες φασματικές ζώνες ανά κλάση με βάση την ανά κλάση band occlusion analysis.

Κλάση	Πέντε σημαντικότερες ζώνες	Ερμηνευτική παρατήρηση
Aphid	B4, B8A, B3, B8, B7	Ισχυρή συμβολή ορατού κόκκινου, πράσινου και NIR/red-edge πληροφορίας
Blast	B8A, B3, B4, B7, B6	Συνδυασμός red-edge/NIR και ορατής πληροφορίας, με μέτρια συνολική ευαισθησία
RPH	B8A, B4, B3, B7, B12	Πιο κατανεμημένη φασματική εξάρτηση και χαμηλότερες επιμέρους πτώσεις

Κλάση	Πέντε σημαντικότερες ζώνες	Ερμηνευτική παρατήρηση
Rust	B8A, B3, B7, B8, B6	Έντονη εξάρτηση από red-edge/NIR και ορατή πληροφορία

Ο Πίνακας 7.15 δείχνει ότι οι σημαντικότερες ζώνες δεν είναι ταυτόσημες για όλες τις ασθένειες. Παρότι οι B8A, B3 και B4 εμφανίζονται συχνά στις πρώτες θέσεις, η σχετική τους σημασία διαφοροποιείται ανά κλάση. Η παρατήρηση αυτή υποδηλώνει ότι οι ασθένειες παρουσιάζουν διαφορετικά φασματικά προφίλ ευαισθησίας, γεγονός που μπορεί να αξιοποιηθεί σε μελλοντικές εργασίες για την ανάπτυξη class-specific ή disease-specific φασματικών μοντέλων.

Στην παρούσα εργασία, η πληροφορία αυτή αξιοποιείται κυρίως ερμηνευτικά και όχι για την τελική επιλογή διαφορετικού μοντέλου ανά κλάση. Η επιλογή αυτή έγινε ώστε να διατηρηθεί ενιαίο και συγκρίσιμο πειραματικό πλαίσιο, ενώ η ανάπτυξη ξεχωριστών class-wise spectral classifiers αφήνεται ως πιθανή κατεύθυνση μελλοντικής έρευνας.



Σχήμα 7.9. Ανά κλάση επίδραση της απόκρυψης φασματικών ζωνών στο F1-score. Οι τιμές αντιστοιχούν στη μέση πτώση F1-score ανά κλάση και ανά ζώνη Sentinel-2 στα 25 repeat-fold runs του πλήρους πολυφασματικού μοντέλου.

Το heatmap του Σχήματος 7.9 επιβεβαιώνει ότι η φασματική σημαντικότητα δεν είναι ομοιόμορφη μεταξύ των κλάσεων. Η Rust εμφανίζει υψηλή ευαισθησία σε αρκετές red-edge/NIR ζώνες, ενώ η Aphid επηρεάζεται ιδιαίτερα από τις ορατές ζώνες και την B8A. Η RPH παρουσιάζει χαμηλότερες τιμές $\Delta F1$ συνολικά, γεγονός που υποδηλώνει ότι η ταξινόμησή της είναι λιγότερο εξαρτημένη από μία μεμονωμένη ζώνη. Η Blast παρουσιάζει πιο περιορισμένες αλλά σαφείς εξαρτήσεις, κυρίως από τις B8A, B3 και B4.

7.8 Αξιολόγηση XAI-guided Top-5 φασματικού σχήματος

Με βάση την ανάλυση band occlusion σχεδιάστηκε ένα πρόσθετο φασματικό σχήμα εισόδου, το οποίο περιλαμβάνει τις πέντε ζώνες με τη μεγαλύτερη μέση επίδραση στη macro-F1. Οι ζώνες αυτές ήταν οι B8A, B3, B4, B7 και B8. Για λόγους σταθερής σειράς εισόδου στο μοντέλο, το σχήμα ορίστηκε ως B3, B4, B7, B8 και B8A.

Το νέο αυτό σχήμα αξιολογήθηκε με το ίδιο πολυσταδιακό pipeline που εφαρμόστηκε και στα υπόλοιπα φασματικά σχήματα: αυτοεπιβλεπόμενη προεκπαίδευση, ενδιάμεση προσαρμογή σε ταξινόμηση καλλιεργείων και τελικό fine-tuning για ταξινόμηση ασθενειών. Με τον τρόπο αυτό διατηρήθηκε η φασματική συνέπεια μεταξύ των σταδίων του pipeline και αποφεύχθηκε η χρήση encoder που είχε προεκπαιδευτεί σε διαφορετικό σύνολο ζωνών.

Στόχος του πειράματος δεν ήταν να αντικαταστήσει την αρχική συγκριτική αξιολόγηση των φασματικών σχημάτων, αλλά να διερευνήσει κατά πόσο η ερμηνευτική σημαντικότητα των ζωνών μπορεί να μεταφραστεί σε ένα μικρότερο και ανταγωνιστικό φασματικό subset.


Πίνακας 7.16. Απόδοση του XAI-guided Top-5 φασματικού σχήματος σε repeated 5-fold cross-validation.

Επανάληψη	Mean best validation Macro-F1	Std
1	0.7500	0.0307
2	0.7605	0.0655
3	0.7561	0.0458
4	0.7398	0.0619
5	0.7727	0.0376
Σύνολο	0.7558	0.0471

Το XAI-guided Top-5 σχήμα πέτυχε συνολική μέση macro-F1 ίση με 0.7558 και τυπική απόκλιση 0.0471 σε 25 repeat-fold runs. Η επίδοση αυτή είναι πολύ κοντά στην απόδοση του πλήρους πολυφασματικού σχήματος, το οποίο πέτυχε mean macro-F1 ίση με 0.7553. Το εύρημα αυτό δείχνει ότι οι πέντε ζώνες που αναδείχθηκαν ως σημαντικότερες από την band occlusion analysis συγκροτούν έναν συμπαγή και πληροφοριακά επαρκή φασματικό πυρήνα.

Παρότι το XAI-guided Top-5 δεν ξεπέρασε το RGB σχήμα, η επίδοσή του έχει ιδιαίτερη ερμηνευτική σημασία. Δείχνει ότι η στοχευμένη επιλογή ζωνών μπορεί να περιορίσει τη διαστατικότητα της εισόδου και να διατηρήσει μεγάλο μέρος της πληροφορίας του πλήρους πολυφασματικού μοντέλου. Επομένως, το αποτέλεσμα αυτό δεν αναιρεί την υπεροχή του RGB, αλλά ενισχύει την άποψη ότι η φασματική πληροφορία πρέπει να επιλέγεται προσεκτικά και όχι απλώς να αυξάνεται ποσοτικά.

XAI Top-5 band selection diagram



Σχήμα 7.10. XAI-guided επιλογή των πέντε σημαντικότερων φασματικών ζωνών Sentinel-2 με βάση την band occlusion analysis του πλήρους πολυφασματικού μοντέλου.

Το XAI-guided subset συνδυάζει ορατή πληροφορία μέσω των B3 και B4 με red-edge/NIR πληροφορία μέσω των B7, B8 και B8A. Η επιλογή αυτή αποτυπώνει την ανάγκη συνδυασμού χρωματικών και βιοφυσικών χαρακτηριστικών για την ερμηνεία της ταξινόμησης ασθενειών.

7.9 Ερμηνεία φασματικών αποτελεσμάτων

Η συνολική εικόνα των φασματικών αποτελεσμάτων δείχνει ότι η σχέση μεταξύ αριθμού φασματικών ζωνών και ταξινομητικής απόδοσης δεν είναι γραμμική. Παρότι θα μπορούσε να αναμένεται ότι το πλήρες πολυφασματικό σχήμα θα παρείχε τη μεγαλύτερη πληροφοριακή πληρότητα, τα αποτελέσματα δείχνουν ότι το RGB πέτυχε την υψηλότερη μέση macro-F1. Το εύρημα αυτό υποδηλώνει ότι, για το συγκεκριμένο dataset και τη συγκεκριμένη διατύπωση του προβλήματος, οι ορατές ζώνες ευθυγραμμίζονται ιδιαίτερα καλά με τα διαθέσιμα disease labels.

Μία πιθανή ερμηνεία είναι ότι οι κατηγορίες ασθενειών του dataset συνδέονται σε σημαντικό βαθμό με ορατά ή χρωματικά εκφρασμένα συμπτώματα, όπως μεταβολές στη χλωροφύλλη, αποχρωματισμοί ή διαφοροποιήσεις στην επιφανειακή εμφάνιση της βλάστησης. Σε αυτή την περίπτωση, οι ορατές ζώνες B2, B3 και B4 μπορούν να παρέχουν ισχυρό και άμεσα σχετικό σήμα για την ταξινόμηση.

Αντίθετα, οι πρόσθετες red-edge, NIR και SWIR ζώνες παρέχουν μεν σημαντική βιοφυσική πληροφορία, αλλά η πληροφορία αυτή δεν μεταφράζεται απαραίτητα σε καλύτερη γενίκευση όταν χρησιμοποιείται συνολικά. Η αύξηση της διαστατικότητας μπορεί να εισάγει επιπλέον θόρυβο, να ενισχύσει τον κίνδυνο υπερπροσαρμογής και να δυσκολέψει τη μάθηση σε ένα μικρό και ανισόρροπο dataset. Επιπλέον, οι ζώνες των 20 m, όπως αρκετές red-edge και SWIR ζώνες, απαιτούν επαναδειγματοληψία στο πλέγμα των 10 m, γεγονός που μπορεί να εισάγει παρεμβαλλόμενη και όχι πραγματική χωρική πληροφορία.

Η band occlusion analysis προσφέρει πρόσθετη ερμηνεία σε αυτή τη συμπεριφορά. Παρότι το Full multispectral σχήμα δεν πέτυχε την υψηλότερη συνολική απόδοση, το μοντέλο αξιοποίησε ουσιαστικά συγκεκριμένες μη ορατές ζώνες, κυρίως την B8A, την B7 και την B8. Αυτό δείχνει ότι η red-edge/NIR πληροφορία έχει πραγματική συμβολή μέσα στο πλήρες μοντέλο, αλλά η παρουσία όλων των διαθέσιμων ζωνών δεν οδηγεί απαραίτητα σε βέλτιστο ανεξάρτητο φασματικό σχήμα.

Το XAI-guided Top-5 πείραμα επιβεβαιώνει αυτή την ερμηνεία. Οι ζώνες B3, B4, B7, B8 και B8A πέτυχαν απόδοση σχεδόν ίδια με το Full multispectral σχήμα, χρησιμοποιώντας μόνο τις μισές ζώνες.

Το αποτέλεσμα αυτό δείχνει ότι η ερμηνευτικά καθοδηγούμενη επιλογή ζωνών μπορεί να μειώσει τη διαστατικότητα της εισόδου χωρίς ουσιαστική απώλεια απόδοσης. Παράλληλα, η μη υπέρβαση του RGB υποδηλώνει ότι η φασματική σημαντικότητα μέσα σε ένα πλήρες μοντέλο δεν ταυτίζεται απαραίτητα με τη βέλτιστη ανεξάρτητη επιλογή εισόδου.

Συνολικά, τα αποτελέσματα υποστηρίζουν ένα σημαντικό συμπέρασμα: περισσότερες φασματικές ζώνες δεν σημαίνουν απαραίτητα καλύτερη ταξινόμηση. Η αποτελεσματικότητα ενός φασματικού σχήματος εξαρτάται από τη σχέση μεταξύ των διαθέσιμων labels, της χωρικής και φασματικής ανάλυσης των δεδομένων, της διαστατικότητας της εισόδου, της ανισορροπίας των κλάσεων και της ικανότητας του μοντέλου να γενικεύει. Για τον λόγο αυτό, η φασματική επιλογή πρέπει να αξιολογείται πειραματικά και να υποστηρίζεται από ερμηνευτικές αναλύσεις.

Συνοψίζοντας, τα αποτελέσματα του Κεφαλαίου 7 δείχνουν ότι το προτεινόμενο πολυσταδιακό pipeline μπορεί να επιτύχει ανταγωνιστική απόδοση στο πρόβλημα ταξινόμησης ασθενειών από δεδομένα Sentinel-2. Η επαναλαμβανόμενη διασταυρούμενη επικύρωση ανέδειξε το RGB ως το ισχυρότερο φασματικό σχήμα, ενώ τα σχήματα που περιλαμβάνουν NIR και red-edge πληροφορία παρουσίασαν επίσης ανταγωνιστικές επιδόσεις. Το πλήρες πολυφασματικό σχήμα δεν οδήγησε σε βελτίωση, γεγονός που ανέδειξε την ανάγκη ερμηνευτικής διερεύνησης της συμβολής των επιμέρους ζωνών.

Η band occlusion analysis στο Full multispectral μοντέλο έδειξε ότι οι σημαντικότερες ζώνες ήταν οι B8A, B3, B4, B7 και B8. Με βάση αυτές σχεδιάστηκε το XAI-guided Top-5 σχήμα, το οποίο πέτυχε απόδοση συγκρίσιμη με το Full multispectral χρησιμοποιώντας μόνο πέντε ζώνες. Το εύρημα αυτό ενισχύει την κεντρική θέση της εργασίας ότι η προσεκτική φασματική επιλογή και η ερμηνευσιμότητα του μοντέλου είναι κρίσιμες για την ανάπτυξη αξιόπιστων συστημάτων ανίχνευσης ασθενειών από πολυφασματικά δορυφορικά δεδομένα.

Κεφάλαιο 8ο: ΣΥΖΗΤΗΣΗ

8.1 Εισαγωγή

Στο παρόν κεφάλαιο πραγματοποιείται η ερμηνεία και η κριτική αποτίμηση των αποτελεσμάτων που παρουσιάστηκαν στο προηγούμενο κεφάλαιο. Η συζήτηση επικεντρώνεται στην αποτελεσματικότητα της προτεινόμενης πολυσταδιακής μεθοδολογίας, στη συμβολή των επιμέρους σταδίων εκπαίδευσης, στη συμπεριφορά των διαφορετικών φασματικών συνδυασμών εισόδου και στην ερμηνευσιμότητα του τελικού μοντέλου μέσω της ανάλυσης band occlusion.

Η ανίχνευση ασθενειών καλλιεργείων από δορυφορικά δεδομένα αποτελεί ιδιαίτερα σύνθετο πρόβλημα, καθώς η ασθένεια δεν παρατηρείται άμεσα, αλλά αποτυπώνεται έμμεσα μέσω μεταβολών στη φασματική συμπεριφορά της βλάστησης. Οι μεταβολές αυτές επηρεάζονται από το είδος της καλλιέργειας, το φαινολογικό στάδιο, τη χωρική ανάλυση των δεδομένων, την ανισορροπία των διαθέσιμων labels και την πιθανή παρουσία άλλων μορφών στρες. Συνεπώς, η αξιολόγηση ενός μοντέλου δεν πρέπει να περιορίζεται αποκλειστικά στη συνολική απόδοση, αλλά να συνοδεύεται από ερμηνευτική διερεύνηση του τρόπου με τον οποίο αξιοποιείται η διαθέσιμη φασματική πληροφορία.

Στο πλαίσιο αυτό, η συζήτηση οργανώνεται γύρω από τρεις βασικούς άξονες. Ο πρώτος αφορά την απόδοση και αξιοπιστία του πολυσταδιακού pipeline $SSL \rightarrow Crop \rightarrow Disease$. Ο δεύτερος αφορά τη φασματική αξιολόγηση των διαφορετικών συνδυασμών Sentinel-2, με έμφαση στο εύρημα ότι το RGB σχήμα πέτυχε την υψηλότερη μέση απόδοση. Ο τρίτος αφορά την ερμηνευσιμότητα του πλήρους πολυφασματικού μοντέλου μέσω band occlusion και τη διερεύνηση του XAI-guided Top-5 φασματικού σχήματος.

8.2 Συνολική αποτίμηση των αποτελεσμάτων

Τα αποτελέσματα της εργασίας δείχνουν ότι το προτεινόμενο πολυσταδιακό pipeline μπορεί να επιτύχει ανταγωνιστική απόδοση στο πρόβλημα ταξινόμησης ασθενειών καλλιεργείων από πολυφασματικά δεδομένα Sentinel-2. Η διαδοχική διαδικασία αυτοεπιβλεπόμενης προεκπαίδευσης, ενδιάμεσης ταξινόμησης καλλιεργείων και τελικής προσαρμογής στο disease task προσφέρει μια δομημένη στρατηγική αξιοποίησης τόσο μη επισημασμένων όσο και επισημασμένων δεδομένων.

Η αυτοεπιβλεπόμενη προεκπαίδευση επέτρεψε στον encoder να μάθει γενικές φασματικές και χωρικές αναπαραστάσεις από μη επισημασμένα δεδομένα Sentinel-2. Το στάδιο ταξινόμησης καλλιεργείων λειτούργησε στη συνέχεια ως ενδιάμεσο επίπεδο γεωργικής εξειδίκευσης, επιτρέποντας στο μοντέλο να προσαρμόσει τις αναπαραστάσεις του σε χαρακτηριστικά που σχετίζονται με τη φυσιολογία και τη φαινολογική εξέλιξη των καλλιεργείων. Τέλος, το στάδιο ταξινόμησης ασθενειών αξιοποίησε αυτές τις αναπαραστάσεις για τη διάκριση λεπτότερων φυτοπαθολογικών αποκλίσεων.

Παράλληλα, η συγκριτική αξιολόγηση των φασματικών σχημάτων ανέδειξε ότι η προσθήκη περισσότερων φασματικών ζωνών δεν οδηγεί απαραίτητα σε καλύτερη ταξινομητική απόδοση. Το RGB σχήμα πέτυχε την υψηλότερη μέση macro-F1, ενώ το πλήρες πολυφασματικό σχήμα δεν παρουσίασε σαφή υπεροχή. Το εύρημα αυτό αποτέλεσε τη βάση για την περαιτέρω ερμηνευτική διερεύνηση της συμβολής των επιμέρους ζωνών μέσω band occlusion analysis.

8.3 Αξιοπιστία της αξιολόγησης και σημασία της επαναλαμβανόμενης διασταυρούμενης επικύρωσης

Η αξιοπιστία των αποτελεσμάτων αποτελεί κρίσιμο ζήτημα στην παρούσα εργασία, λόγω του σχετικά μικρού και ανισόρροπου συνόλου δεδομένων ασθενειών. Σε τέτοια προβλήματα, μία μεμονωμένη εκτέλεση ή ένα μόνο train-validation split μπορεί να οδηγήσει σε υπερεκτίμηση ή υποεκτίμηση της πραγματικής γενικευτικής ικανότητας του μοντέλου [4], [9]. Η διακύμανση της απόδοσης μεταξύ folds και επαναλήψεων επιβεβαιώνει ότι η αξιολόγηση πρέπει να βασίζεται σε πολλαπλές εκτελέσεις και όχι σε ένα μοναδικό αποτέλεσμα.

Η χρήση repeated 5-fold cross-validation επέτρεψε την εκτίμηση τόσο της μέσης απόδοσης όσο και της μεταβλητότητας κάθε φασματικού σχήματος. Η χρήση macro-F1 ως βασικής μετρικής είναι κατάλληλη για προβλήματα πολλαπλών κλάσεων με άνιση εκπροσώπηση [9], [12].

Η στατιστική αξιολόγηση με τον έλεγχο Friedman και τις pairwise συγκρίσεις με διόρθωση Holm συνέβαλε στην αποφυγή υπερερμηνείας μικρών διαφορών μεταξύ φασματικών σχημάτων. Η ύπαρξη συνολικής στατιστικά σημαντικής διαφοράς υποδηλώνει ότι η επιλογή φασματικών ζωνών επηρεάζει πράγματι την απόδοση του μοντέλου. Ωστόσο, οι επιμέρους συγκρίσεις πρέπει να ερμηνεύονται προσεκτικά, ιδίως όταν οι διαφορές μεταξύ γειτονικών σχημάτων είναι μικρές.

8.4 Συμβολή των επιμέρους σταδίων της μεθοδολογίας

Η πολυσταδιακή δομή της μεθοδολογίας αποτελεί ένα από τα βασικά στοιχεία της εργασίας. Η άμεση εκπαίδευση ενός μοντέλου στο τελικό πρόβλημα ταξινόμησης ασθενειών θα ήταν πιθανό να οδηγήσει σε λιγότερο σταθερές αναπαραστάσεις, καθώς το διαθέσιμο σύνολο ασθενειών είναι περιορισμένο και ανισόρροπο. Αντίθετα, η προτεινόμενη προσέγγιση επιτρέπει στο μοντέλο να οικοδομήσει σταδιακά τη γνώση του: πρώτα σε γενικό επίπεδο φασματικής αναπαράστασης, στη συνέχεια σε επίπεδο καλλιέργειας και τελικά σε επίπεδο ασθένειας.

Το SSL στάδιο συνέβαλε στην εκμάθηση γενικών χαρακτηριστικών από μη επισημασμένα δεδομένα, αξιοποιώντας τον μεγάλο όγκο διαθέσιμης δορυφορικής πληροφορίας [14], [27]. Το crop stage λειτουργήσε ως μορφή γεωργικού domain adaptation, καθώς μετέφερε τον encoder από γενικές αναπαραστάσεις βλάστησης σε χαρακτηριστικά πιο άμεσα συνδεδεμένα με καλλιέργειες [10]. Το disease stage, τέλος, εξειδίκευσε περαιτέρω αυτές τις αναπαραστάσεις στις φυτοπαθολογικές κατηγορίες.

Η σημασία του ενδιάμεσου crop stage είναι ιδιαίτερη, καθώς η φασματική έκφραση μιας ασθένειας δεν είναι ανεξάρτητη από την καλλιέργεια στην οποία εμφανίζεται. Διαφορετικές καλλιέργειες μπορεί να παρουσιάζουν διαφορετική φαινολογική εξέλιξη, δομή φυλλώματος και βασική φασματική υπογραφή. Επομένως, η προηγούμενη εκμάθηση χαρακτηριστικών σχετικών με την καλλιέργεια μπορεί να βοηθήσει το μοντέλο να ερμηνεύσει καλύτερα τις παθολογικές αποκλίσεις.

8.5 Ερμηνεία της απόδοσης ανά κλάση

Η ανάλυση της απόδοσης ανά κλάση δείχνει ότι το πρόβλημα δεν παρουσιάζει την ίδια δυσκολία για όλες τις κατηγορίες ασθενειών. Η ανισορροπία του dataset, σε συνδυασμό με τη φασματική ομοιότητα ορισμένων κατηγοριών, οδηγεί σε διαφοροποιήσεις στην ικανότητα του μοντέλου να αναγνωρίζει κάθε κλάση. Οι πολυπληθέστερες ή πιο φασματικά διακριτές κατηγορίες τείνουν να παρουσιάζουν σταθερότερη απόδοση, ενώ οι σπανιότερες ή πιο ετερογενείς εμφανίζουν μεγαλύτερη μεταβλητότητα μεταξύ folds.

Η κλάση Blast παρουσιάζει ιδιαίτερο ενδιαφέρον, καθώς εμφανίζει συχνά μεγαλύτερη αστάθεια. Το γεγονός αυτό μπορεί να συνδέεται τόσο με τον μικρότερο αριθμό διαθέσιμων δειγμάτων όσο και με τη δυσκολία διαχωρισμού της από άλλες μορφές φυτικού στρες σε χωρική ανάλυση Sentinel-2. Σε τέτοιες περιπτώσεις, το μοντέλο δεν παρατηρεί άμεσα λεπτομερή οπτικά συμπτώματα, αλλά προσπαθεί να συσχετίσει σχετικά αδρές πολυφασματικές αποκρίσεις με την αντίστοιχη κατηγορία.

Αντίστοιχα, η Rust φαίνεται να επηρεάζεται έντονα από ζώνες που σχετίζονται τόσο με την ορατή πληροφορία όσο και με την περιοχή red-edge/NIR. Η παρατήρηση αυτή είναι συμβατή με το γεγονός ότι η συγκεκριμένη κατηγορία μπορεί να συνδέεται με χρωματικές μεταβολές αλλά και με φυσιολογικές αποκλίσεις στη βλάστηση. Η ανά κλάση συμπεριφορά, επομένως, υποδηλώνει ότι η φασματική πληροφορία δεν έχει ενιαία χρησιμότητα για όλες τις κατηγορίες, αλλά μπορεί να διαφοροποιείται ανάλογα με το είδος της ασθένειας και τη φασματική της έκφραση.

8.6 Ερμηνεία των φασματικών αποτελεσμάτων

Η συγκριτική αξιολόγηση των φασματικών σχημάτων οδηγεί σε ένα ιδιαίτερα ενδιαφέρον εύρημα: το RGB σχήμα πέτυχε την υψηλότερη μέση απόδοση, παρότι περιλαμβάνει μόνο τις τρεις ορατές ζώνες B2, B3 και B4. Το αποτέλεσμα αυτό μπορεί αρχικά να φαίνεται αντίθετο με τη θεωρητική προσδοκία ότι η προσθήκη NIR, red-edge και SWIR πληροφορίας θα έπρεπε να οδηγεί σε καλύτερη διάκριση φυτοπαθολογικών καταστάσεων. Ωστόσο, η παρατήρηση αυτή μπορεί να ερμηνευθεί με βάση τη φύση του dataset, τη χωρική ανάλυση των δεδομένων και τη σημασία των διαθέσιμων labels.

Οι ορατές ζώνες ενδέχεται να ευθυγραμμίζονται περισσότερο με τον τρόπο με τον οποίο εκφράζονται οι συγκεκριμένες κατηγορίες ασθενειών στο διαθέσιμο dataset. Εάν τα labels βασίζονται σε καταστάσεις που σχετίζονται με ορατά συμπτώματα, όπως αλλαγές χρώματος, χλωρώσεις, αποχρωματισμοί ή επιφανειακές διαφοροποιήσεις της βλάστησης, τότε οι RGB ζώνες μπορεί να παρέχουν ιδιαίτερα άμεσο και διακριτικό σήμα. Σε αυτή την περίπτωση, η επιπλέον μη ορατή πληροφορία μπορεί να είναι βιοφυσικά σημαντική, αλλά όχι απαραίτητα πιο χρήσιμη για τη συγκεκριμένη ταξινομητική διατύπωση.

Η χαμηλότερη απόδοση του Full multispectral σχήματος σε σχέση με το RGB δεν σημαίνει ότι οι μη ορατές ζώνες είναι άχρηστες. Αντίθετα, δείχνει ότι η ταυτόχρονη χρήση όλων των ζωνών μπορεί να αυξήσει τη διαστατικότητα και τον θόρυβο της εισόδου, χωρίς η πρόσθετη πληροφορία να μεταφράζεται απαραίτητα σε καλύτερη γενίκευση. Το πρόβλημα αυτό είναι εντονότερο όταν το dataset είναι μικρό και ανισόρροπο, καθώς το μοντέλο έχει περιορισμένη δυνατότητα να μάθει σταθερές σχέσεις για όλες τις διαθέσιμες φασματικές διαστάσεις.

Επιπλέον, οι ζώνες red-edge και SWIR του Sentinel-2 έχουν χαμηλότερη χωρική ανάλυση από τις βασικές RGB και NIR ζώνες και απαιτούν επαναδειγματοληψία για να χρησιμοποιηθούν σε κοινό πλέγμα εισόδου. Η διαδικασία αυτή είναι απαραίτητη για την κατασκευή πολυκαναλικών tensors, αλλά δεν αυξάνει την πραγματική χωρική πληροφορία των ζωνών. Επομένως, μέρος της πρόσθετης πληροφορίας μπορεί να είναι λιγότερο χωρικά ευκρινές ή να εισάγει παρεμβαλλόμενες τιμές που δεν βελτιώνουν την ταξινόμηση.

Συνολικά, τα φασματικά αποτελέσματα δείχνουν ότι η επιλογή ζωνών πρέπει να αντιμετωπίζεται ως ουσιαστικό ερευνητικό ζήτημα και όχι ως απλή τεχνική λεπτομέρεια. Η ύπαρξη περισσότερων φασματικών καναλιών δεν εγγυάται καλύτερη απόδοση. Αντίθετα, η καταλληλότητα ενός φασματικού σχήματος εξαρτάται από τη σχέση μεταξύ της φυσικής σημασίας των ζωνών, της ποιότητας των δεδομένων, της χωρικής ανάλυσης, της ισορροπίας των κλάσεων και της φύσης των labels.

8.7 Ερμηνευσιμότητα μοντέλου και σημασία της band occlusion analysis

Η band occlusion analysis προσφέρει ένα πρόσθετο επίπεδο ερμηνείας των φασματικών αποτελεσμάτων. Η απλή σύγκριση φασματικών σχημάτων δείχνει ποιος συνδυασμός ζωνών οδηγεί σε υψηλότερη απόδοση, αλλά δεν εξηγεί απαραίτητα ποιες ζώνες αξιοποιεί περισσότερο ένα εκπαιδευμένο πλήρες μοντέλο. Αντίθετα, η απόκρυψη κάθε ζώνης χωριστά επιτρέπει την εκτίμηση της εξάρτησης του μοντέλου από κάθε κανάλι εισόδου.

Τα αποτελέσματα της band occlusion analysis έδειξαν ότι η σημαντικότερη ζώνη στο Full multispectral μοντέλο ήταν η B8A, ακολουθούμενη από τις B3, B4, B7 και B8. Το εύρημα αυτό είναι ιδιαίτερα ενδιαφέρον, διότι συνδυάζει ορατή πληροφορία με red-edge και NIR πληροφορία. Επομένως, παρότι το RGB σχήμα πέτυχε την υψηλότερη συνολική απόδοση, το πλήρες μοντέλο δεν βασίστηκε αποκλειστικά στις ορατές ζώνες. Αντίθετα, αξιοποίησε ουσιαστικά και μη ορατή πληροφορία που σχετίζεται με τη φυσιολογική κατάσταση και τη δομή της βλάστησης.

Η υψηλή σημαντικότητα της B8A μπορεί να ερμηνευθεί με βάση τη θέση της στην περιοχή μετάβασης μεταξύ red-edge και NIR. Η περιοχή αυτή είναι ιδιαίτερα ευαίσθητη σε μεταβολές που σχετίζονται με τη χλωροφύλλη, τη φυλλική δομή και τη γενικότερη φυσιολογική κατάσταση των φυτών. Αντίστοιχα, η υψηλή σημαντικότητα των B3 και B4 συνδέεται με τη χρωματική και χλωροφυλλική πληροφορία του ορατού φάσματος, η οποία φαίνεται να έχει άμεση σχέση με το συγκεκριμένο disease classification task.

Η band occlusion analysis πρέπει, ωστόσο, να ερμηνεύεται με προσοχή. Δεν αποδεικνύει αιτιώδη σχέση μεταξύ μιας ζώνης και μιας συγκεκριμένης ασθένειας, ούτε σημαίνει ότι μια ζώνη με υψηλή σημαντικότητα μέσα σε ένα πλήρες μοντέλο θα οδηγήσει απαραίτητα σε βέλτιστο ανεξάρτητο φασματικό subset. Αντίθετα, αποτυπώνει τη λειτουργική εξάρτηση του συγκεκριμένου εκπαιδευμένου μοντέλου από κάθε ζώνη, υπό το συγκεκριμένο πειραματικό πλαίσιο.

Παρά τον περιορισμό αυτό, η ανάλυση είναι ιδιαίτερα χρήσιμη, διότι παρέχει ερμηνευτική γέφυρα ανάμεσα στα αριθμητικά αποτελέσματα και στη βιοφυσική σημασία των φασματικών ζωνών. Με τον τρόπο αυτό, η εργασία δεν περιορίζεται σε μια “black-box” ταξινόμηση, αλλά επιχειρεί να εξηγήσει ποια φασματική πληροφορία αξιοποιείται από το μοντέλο και πώς αυτή συνδέεται με τη φυσιολογία της βλάστησης.

8.7.1 Ανά κλάση φασματική ευαισθησία

Η ανά κλάση band occlusion analysis προσφέρει μια πιο λεπτομερή εικόνα της φασματικής συμπεριφοράς του μοντέλου. Ενώ η συνολική ανάλυση ανέδειξε τις B8A, B3, B4, B7 και B8 ως τις σημαντικότερες ζώνες, η ανά κλάση ανάλυση έδειξε ότι η σχετική σημασία αυτών των ζωνών διαφοροποιείται μεταξύ των ασθενειών. Το εύρημα αυτό είναι αναμενόμενο, καθώς διαφορετικές φυτοπαθολογικές καταστάσεις μπορούν να επηρεάζουν τη βλάστηση με διαφορετικό τρόπο, προκαλώντας μεταβολές είτε στην ορατή εμφάνιση είτε στη φυσιολογική και δομική κατάσταση των φυτών.

Η σταθερά υψηλή σημαντικότητα της B8A σε όλες σχεδόν τις κλάσεις υποδηλώνει ότι η περιοχή red-edge/narrow-NIR αποτελεί κρίσιμο φασματικό κανάλι για το πλήρες πολυφασματικό μοντέλο. Παράλληλα, οι υψηλές τιμές των B3 και B4 δείχνουν ότι η ορατή πληροφορία παραμένει καθοριστική, γεγονός που ερμηνεύει και την ισχυρή απόδοση του RGB σχήματος. Η Rust φαίνεται να αξιοποιεί εντονότερα τον συνδυασμό ορατών και red-edge/NIR ζωνών, ενώ η RPH παρουσιάζει πιο κατανομημένη φασματική εξάρτηση.

Τα ευρήματα αυτά δεν σημαίνουν ότι πρέπει απαραίτητα να εκπαιδευτούν ξεχωριστά μοντέλα ανά ασθένεια στο πλαίσιο της παρούσας εργασίας. Αντίθετα, δείχνουν ότι η ερμηνευσιμότητα μπορεί να

αποκαλύπτει διαφοροποιήσεις που δεν είναι εμφανείς από τη συνολική macro-F1. Σε μελλοντικές εργασίες, τα αποτελέσματα αυτά θα μπορούσαν να αξιοποιηθούν για την ανάπτυξη class-specific spectral models ή disease-specific band selection strategies, υπό την προϋπόθεση ύπαρξης μεγαλύτερου και πιο ισορροπημένου αριθμού δειγμάτων ανά κλάση.

8.8 Αξιολόγηση του XAI-guided Top-5 σχήματος

Το XAI-guided Top-5 σχήμα σχεδιάστηκε με βάση τις πέντε ζώνες που εμφάνισαν τη μεγαλύτερη μέση πτώση macro-F1 στην band occlusion analysis: B8A, B3, B4, B7 και B8. Για λόγους σταθερής σειράς εισόδου, το τελικό subset ορίστηκε ως B3, B4, B7, B8 και B8A. Η αξιολόγηση του σχήματος αυτού είχε διερευνητικό χαρακτήρα και στόχο να εξετάσει αν η ερμηνευτική σημαντικότητα των ζωνών μπορεί να μεταφραστεί σε ανταγωνιστική ταξινομητική απόδοση.

Τα αποτελέσματα έδειξαν ότι το XAI-guided Top-5 πέτυχε mean macro-F1 ίση με 0.7558, δηλαδή σχεδόν ταυτόσημη με την απόδοση του Full multispectral σχήματος. Το εύρημα αυτό είναι σημαντικό, επειδή δείχνει ότι ένα subset πέντε ζωνών μπορεί να διατηρήσει σχεδόν όλη την απόδοση του πλήρους δεκακάναλου μοντέλου. Με άλλα λόγια, η μείωση της διαστατικότητας από δέκα σε πέντε ζώνες δεν οδήγησε σε ουσιαστική απώλεια απόδοσης.

Παρότι το XAI-guided Top-5 δεν ξεπέρασε το RGB, η αξία του αποτελέσματος παραμένει σημαντική. Το σχήμα αυτό δεν προτάθηκε ως αντικατάσταση του RGB, αλλά ως ερμηνευτικά καθοδηγούμενος έλεγχος της πληροφορίας που χρησιμοποιεί το Full multispectral μοντέλο. Το γεγονός ότι πέτυχε απόδοση συγκρίσιμη με το Full δείχνει ότι οι ζώνες που ανέδειξε η band occlusion analysis πράγματι συγκροτούν έναν φασματικό πυρήνα υψηλής πληροφοριακής αξίας.

Το αποτέλεσμα αυτό οδηγεί σε μια πιο λεπτή ερμηνεία της φασματικής πληροφορίας. Από τη μία πλευρά, το RGB παραμένει το ισχυρότερο συνολικό σχήμα για το συγκεκριμένο dataset. Από την άλλη πλευρά, η red-edge/NIR πληροφορία που περιλαμβάνεται στο Top-5 φαίνεται να έχει σημαντική συμπληρωματική αξία μέσα στο πλήρες μοντέλο. Επομένως, η φασματική επιλογή δεν πρέπει να βασίζεται αποκλειστικά ούτε στη θεωρητική βιοφυσική σημασία ούτε μόνο στην αριθμητική κατάταξη των spectral schemes, αλλά σε συνδυασμό πειραματικής αξιολόγησης και ερμηνευτικής ανάλυσης.

8.9 Πλεονεκτήματα της προτεινόμενης προσέγγισης

Η προτεινόμενη προσέγγιση παρουσιάζει ορισμένα σημαντικά πλεονεκτήματα. Πρώτον, αξιοποιεί μη επισημασμένα δεδομένα μέσω αυτοεπιβλεπόμενης μάθησης, γεγονός ιδιαίτερα χρήσιμο σε πεδία όπως η τηλεπισκόπηση, όπου τα διαθέσιμα μη επισημασμένα δεδομένα είναι πολύ περισσότερα από τα αξιόπιστα επισημασμένα παραδείγματα. Δεύτερον, ενσωματώνει ενδιάμεσο στάδιο ταξινόμησης καλλιιεργειών, το οποίο λειτουργεί ως γέφυρα μεταξύ γενικής φασματικής γνώσης και ειδικής φυτοπαθολογικής ταξινόμησης.

Τρίτον, η μεθοδολογία δεν περιορίζεται στην αξιολόγηση ενός μόνο φασματικού σχήματος, αλλά εξετάζει συστηματικά διαφορετικές ομάδες ζωνών Sentinel-2. Η σύγκριση αυτή επιτρέπει πιο ουσιαστική κατανόηση του ρόλου της ορατής, NIR, red-edge και SWIR πληροφορίας στην ταξινόμηση ασθενειών. Τέταρτον, η χρήση repeated cross-validation και στατιστικών ελέγχων ενισχύει την

αξιοπιστία των συμπερασμάτων και μειώνει την πιθανότητα εξαγωγής συμπερασμάτων από τυχαίες διαφοροποιήσεις μεταξύ folds.

Πέμπτον, η ενσωμάτωση band occlusion analysis προσδίδει ερμηνευτικό χαρακτήρα στην εργασία. Το μοντέλο δεν αξιολογείται μόνο ως προς το αν ταξινομεί σωστά, αλλά και ως προς το ποιες φασματικές ζώνες φαίνεται να αξιοποιεί περισσότερο. Αυτό είναι ιδιαίτερα σημαντικό για εφαρμογές γεωργίας ακριβείας, όπου η κατανόηση της σχέσης μεταξύ φασματικών δεδομένων και βιοφυσικών φαινομένων είναι απαραίτητη για την πρακτική αξιοποίηση των αποτελεσμάτων.

8.10 Σύγκριση με παραδοσιακές και απλούστερες προσεγγίσεις

Σε σχέση με παραδοσιακές προσεγγίσεις που βασίζονται σε μεμονωμένους δείκτες βλάστησης ή χειροποίητα χαρακτηριστικά, η προτεινόμενη μεθοδολογία έχει τη δυνατότητα να αξιοποιεί απευθείας πολυκαναλική φασματική πληροφορία. Αντί να συμπυκνώνει τη βλάστηση σε έναν ή λίγους δείκτες, το μοντέλο μαθαίνει σύνθετες μη γραμμικές σχέσεις μεταξύ των φασματικών ζωνών και των κατηγοριών ασθενειών.

Ωστόσο, τα αποτελέσματα της εργασίας δείχνουν ότι η απλή αύξηση της φασματικής πληροφορίας δεν αρκεί. Παρότι το Full multispectral σχήμα παρέχει περισσότερα κανάλια από το RGB, δεν πέτυχε καλύτερη απόδοση. Αυτό δείχνει ότι η πολυπλοκότητα του input πρέπει να είναι συμβατή με το μέγεθος και την ποιότητα του dataset. Σε μικρά και ανισόρροπα σύνολα δεδομένων, ένα πιο απλό σχήμα εισόδου μπορεί να γενικεύει καλύτερα από ένα πιο πλούσιο αλλά θορυβώδες φασματικό σχήμα.

Σε σχέση με απλές deep learning προσεγγίσεις που εκπαιδεύονται απευθείας στο τελικό πρόβλημα ταξινόμησης ασθενειών, το προτεινόμενο pipeline προσφέρει πιο δομημένη μεταφορά γνώσης. Η σταδιακή μετάβαση από μη επισημασμένα δεδομένα σε crop classification και τελικά σε disease classification επιτρέπει στο μοντέλο να αξιοποιήσει ευρύτερη γεωργική πληροφορία πριν αντιμετωπίσει το πιο δύσκολο και περιορισμένο task. Παράλληλα, η XAI ανάλυση προσφέρει ερμηνευτικό βάθος που συνήθως απουσιάζει από απλές black-box προσεγγίσεις.

8.11 Πρακτική σημασία για τη γεωργία ακριβείας

Η πρακτική σημασία της παρούσας εργασίας εντοπίζεται κυρίως στη δυνατότητα ανάπτυξης αυτοματοποιημένων εργαλείων παρακολούθησης φυτοπαθολογικών καταστάσεων σε μεγάλη χωρική κλίμακα. Τα δεδομένα Sentinel-2 είναι ανοικτά, δωρεάν και συστηματικά διαθέσιμα, γεγονός που τα καθιστά ιδιαίτερα ελκυστικά για εφαρμογές γεωργίας ακριβείας και επιχειρησιακής παρακολούθησης καλλιεργειών.

Παρότι η χωρική ανάλυση του Sentinel-2 δεν επιτρέπει την άμεση αναγνώριση λεπτομερών συμπτωμάτων σε επίπεδο φύλλου, μπορεί να υποστηρίξει την ανίχνευση χωρικών και φασματικών αποκλίσεων που σχετίζονται με στρες ή ασθένειες. Ένα τέτοιο σύστημα δεν θα αντικαθιστούσε την επιτόπια γεωπονική διάγνωση, αλλά θα μπορούσε να λειτουργήσει ως εργαλείο προτεραιοποίησης, εντοπίζοντας περιοχές που χρήζουν περαιτέρω ελέγχου.

Η φασματική αξιολόγηση της εργασίας έχει επίσης πρακτική σημασία. Το εύρημα ότι το RGB σχήμα πέτυχε την υψηλότερη μέση απόδοση δείχνει ότι, για ορισμένα προβλήματα, απλούστερα και λιγότερο απαιτητικά φασματικά inputs μπορεί να είναι επαρκή ή ακόμη και προτιμότερα. Παράλληλα, το XAI-

guided Top-5 δείχνει ότι η επιλογή μικρότερου αριθμού στοχευμένων ζωνών μπορεί να μειώσει το υπολογιστικό κόστος και τη διαστατικότητα χωρίς σημαντική απώλεια απόδοσης.

Σε επιχειρησιακό πλαίσιο, τέτοια ευρήματα μπορούν να υποστηρίξουν τον σχεδιασμό πιο αποδοτικών συστημάτων ανάλυσης, τα οποία δεν βασίζονται απαραίτητα στη χρήση όλων των διαθέσιμων ζωνών, αλλά επιλέγουν εκείνες που προσφέρουν την καλύτερη ισορροπία μεταξύ πληροφορίας, σταθερότητας και υπολογιστικής αποδοτικότητας.

8.12 Περιορισμοί της μελέτης

Παρά τα ενθαρρυντικά αποτελέσματα, η παρούσα μελέτη συνοδεύεται από ορισμένους σημαντικούς περιορισμούς. Ο πρώτος αφορά το μέγεθος και την ισορροπία του συνόλου δεδομένων ασθενειών. Ο αριθμός των διαθέσιμων δειγμάτων είναι περιορισμένος και οι κλάσεις δεν εκπροσωπούνται ισοδύναμα. Η ανισορροπία αυτή επηρεάζει τόσο την εκπαίδευση όσο και την αξιολόγηση του μοντέλου, ιδίως για τις υποεκπροσωπούμενες κατηγορίες.

Δεύτερος περιορισμός αφορά τη φύση των labels. Οι κατηγορίες ασθενειών δεν αντιστοιχούν απαραίτητα σε άμεσα παρατηρήσιμα συμπτώματα στη χωρική ανάλυση του Sentinel-2. Το μοντέλο μαθαίνει έμμεσες συσχετίσεις μεταξύ πολυφασματικών προτύπων και κατηγοριών ασθενειών, γεγονός που εισάγει αβεβαιότητα στην ερμηνεία των προβλέψεων. Η αβεβαιότητα αυτή ενισχύεται από τη χωρική ανάλυση των 10–20 m και από την πιθανή παρουσία μικτών εικονοστοιχείων.

Τρίτος περιορισμός αφορά την επαναδειγματοληψία των ζωνών διαφορετικής χωρικής ανάλυσης. Οι red-edge και SWIR ζώνες παρέχονται σε χαμηλότερη χωρική ανάλυση από τις βασικές ορατές ζώνες και απαιτείται χωρική ενοποίηση πριν από την εισαγωγή στο μοντέλο. Η διαδικασία αυτή είναι απαραίτητη, αλλά δεν δημιουργεί νέα πραγματική χωρική πληροφορία και μπορεί να επηρεάσει την αποτελεσματικότητα των μη ορατών ζωνών.

Τέταρτος περιορισμός αφορά τη XAI-guided επιλογή ζωνών. Το Top-5 σχήμα προέκυψε από post-hoc ανάλυση του πλήρους πολυφασματικού μοντέλου και όχι από ανεξάρτητο σχεδιασμό πριν από την πειραματική διαδικασία. Επομένως, τα αποτελέσματά του πρέπει να ερμηνεύονται ως διερευνητική επιβεβαίωση της χρησιμότητας της ερμηνευτικής ανάλυσης και όχι ως πλήρως ανεξάρτητο συμπέρασμα επιλογής χαρακτηριστικών.

Τέλος, η μελέτη δεν περιλαμβάνει ανεξάρτητη εξωτερική επικύρωση σε διαφορετική γεωγραφική περιοχή, χρονική περίοδο ή πλήρως ανεξάρτητο dataset. Επομένως, τα αποτελέσματα τεκμηριώνουν τη συμπεριφορά του μοντέλου στο συγκεκριμένο πειραματικό πλαίσιο, αλλά απαιτείται περαιτέρω διερεύνηση για την αξιολόγηση της γενικευσιμότητας σε ευρύτερες συνθήκες.

8.13 Κατευθύνσεις βελτίωσης της μεθοδολογίας

Με βάση τα αποτελέσματα και τους περιορισμούς της μελέτης, προκύπτουν ορισμένες σαφείς κατευθύνσεις για μελλοντική βελτίωση. Πρώτη και σημαντικότερη κατεύθυνση είναι η αξιολόγηση της μεθοδολογίας σε μεγαλύτερα και πιο ισορροπημένα σύνολα δεδομένων. Η αύξηση του αριθμού δειγμάτων, ιδίως για τις υποεκπροσωπούμενες κατηγορίες, θα μπορούσε να βελτιώσει τη σταθερότητα της εκπαίδευσης και να επιτρέψει πιο ασφαλή συμπεράσματα για τις διαφορές μεταξύ φασματικών σχημάτων.

Δεύτερη κατεύθυνση αφορά την εξωτερική επικύρωση του μοντέλου σε ανεξάρτητα γεωγραφικά ή χρονικά σύνολα δεδομένων. Μια τέτοια αξιολόγηση θα επέτρεπε να εξεταστεί αν τα συμπεράσματα

σχετικά με την υπεροχή του RGB, τη σημαντικότητα της B8A και τη χρησιμότητα του XAI-guided Top-5 παραμένουν σταθερά εκτός του συγκεκριμένου dataset.

Τρίτη κατεύθυνση αφορά τη συστηματικότερη επιλογή φασματικών ζωνών. Η παρούσα εργασία αξιοποίησε band occlusion analysis ως post-hoc μέθοδο ερμηνευσιμότητας. Μελλοντικά, θα μπορούσαν να εξεταστούν συνδυαστικές προσεγγίσεις που ενσωματώνουν XAI, wrapper-based feature selection, embedded feature selection ή attention-based μηχανισμούς, ώστε η επιλογή ζωνών να γίνεται με πιο συστηματικό και γενικεύσιμο τρόπο.

Τέταρτη κατεύθυνση αφορά τη χρονική μοντελοποίηση. Στην παρούσα εργασία η χρονική πληροφορία αξιοποιήθηκε κυρίως στο crop stage μέσω temporal mean pooling. Μελλοντικά, θα μπορούσαν να εξεταστούν πιο σύνθετες αρχιτεκτονικές, όπως temporal transformers, recurrent networks ή attention-based temporal aggregation, ώστε να αποτυπώνονται καλύτερα οι φαινολογικές μεταβολές και οι χρονικές αποκλίσεις που σχετίζονται με ασθένειες.

Τέλος, μελλοντική έρευνα θα μπορούσε να εστιάσει στη συνδυαστική αξιοποίηση δορυφορικών δεδομένων με πρόσθετες πηγές πληροφορίας, όπως UAV εικόνες υψηλότερης ανάλυσης, μετεωρολογικά δεδομένα, εδαφολογικά χαρακτηριστικά ή επιτόπιες παρατηρήσεις. Η ενσωμάτωση τέτοιων δεδομένων θα μπορούσε να μειώσει την αβεβαιότητα που προκύπτει από τη μέση χωρική ανάλυση του Sentinel-2 και να ενισχύσει την πρακτική αξιοπιστία ενός συστήματος έγκαιρης ανίχνευσης ασθενειών.

8.14 Σύνοψη της συζήτησης

Συνοψίζοντας, η συζήτηση των αποτελεσμάτων δείχνει ότι η προτεινόμενη μεθοδολογία προσφέρει μια ολοκληρωμένη και ερμηνεύσιμη προσέγγιση για την ανίχνευση ασθενειών καλλιέργειών από δεδομένα Sentinel-2. Το πολυσταδιακό pipeline SSL → Crop → Disease επιτρέπει τη σταδιακή εκμάθηση αναπαραστάσεων από γενική φασματική γνώση προς πιο εξειδικευμένη φυτοπαθολογική διάκριση. Η repeated cross-validation και η στατιστική αξιολόγηση ενισχύουν την αξιοπιστία των συμπερασμάτων, αποτρέποντας την υπερερμηνεία μεμονωμένων εκτελέσεων.


Η φασματική αξιολόγηση ανέδειξε ότι το RGB σχήμα πέτυχε την υψηλότερη μέση απόδοση, γεγονός που υποδηλώνει ισχυρή σύνδεση των ορατών ζωνών με τη φύση των διαθέσιμων disease labels. Παράλληλα, η band occlusion analysis έδειξε ότι το πλήρες πολυφασματικό μοντέλο αξιοποιεί ουσιαστικά και μη ορατή πληροφορία, ιδίως από τις ζώνες B8A, B7 και B8. Το XAI-guided Top-5 πείραμα έδειξε ότι ένα μικρότερο subset ζωνών μπορεί να διατηρήσει σχεδόν την απόδοση του Full multispectral σχήματος.

Το βασικό συμπέρασμα της συζήτησης είναι ότι η αποτελεσματική αξιοποίηση πολυφασματικών δεδομένων δεν εξαρτάται απλώς από τον αριθμό των διαθέσιμων ζωνών, αλλά από την καταλληλότητα, τη σταθερότητα και την ερμηνευτική αξία της φασματικής πληροφορίας. Επομένως, η ανάπτυξη μοντέλων βαθιάς μάθησης για γεωργική τηλεπισκόπηση πρέπει να συνοδεύεται από συστηματική φασματική αξιολόγηση, στατιστική τεκμηρίωση και τεχνικές ερμηνευσιμότητας.

Πίνακας 8.1. Συνοπτική ερμηνεία των βασικών ευρημάτων της εργασίας.

Εύρημα	Ερμηνεία	Σημασία
To RGB πέτυχε την υψηλότερη mean macro-F1	Οι ορατές ζώνες ευθυγραμμίζονται ισχυρά με τα διαθέσιμα disease labels	Τα απλούστερα φασματικά σχήματα μπορεί να γενικεύουν καλύτερα
To Full multispectral δεν	Η πρόσθετη πληροφορία μπορεί να συνοδεύεται από	Περισσότερες ζώνες δεν σημαίνουν

Εύρημα	Ερμηνεία	Σημασία
ξεπέρασε το RGB	θόρυβο, μεγαλύτερη διαστατικότητα και επίδραση επαναδειγματοληψίας	απαραίτητα καλύτερη απόδοση
Η B8A ήταν η σημαντικότερη ζώνη στο XAI	Το full model αξιοποιεί red-edge/NIR πληροφορία σχετική με φυσιολογική κατάσταση	Οι μη ορατές ζώνες έχουν συμπληρωματική ερμηνευτική αξία
Οι B3 και B4 ήταν επίσης πολύ σημαντικές	Η χρωματική και χλωροφυλλική πληροφορία είναι κρίσιμη	Εξηγεί τη δυνατή επίδοση του RGB
Το XAI-guided Top-5 πλησίασε το Full	Πέντε στοχευμένες ζώνες διατηρούν μεγάλο μέρος της πληροφορίας	Δυνατότητα μείωσης διαστατικότητας χωρίς ουσιαστική απώλεια απόδοσης
Υπάρχει μεταβλητότητα μεταξύ folds	Το dataset είναι μικρό και ανισόρροπο	Απαιτείται repeated CV και προσεκτική ερμηνεία



Σχήμα 8.1. Συνοπτική ερμηνεία των φασματικών ευρημάτων και της ΧAI-guided επιλογής ζωνών.

Κεφάλαιο 9ο: ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΜΕΛΛΟΝΤΙΚΗ ΕΡΕΥΝΑ

9.1 Εισαγωγή

Στο παρόν κεφάλαιο συνοψίζονται τα βασικά συμπεράσματα της διπλωματικής εργασίας, αποτιμάται η επιστημονική της συνεισφορά και παρουσιάζονται οι σημαντικότεροι περιορισμοί και οι προτεινόμενες κατευθύνσεις μελλοντικής έρευνας. Η εργασία επικεντρώθηκε στην ανάπτυξη και αξιολόγηση ενός πολυσταδιακού πλαισίου βαθιάς μάθησης για την ανίχνευση ασθενειών καλλιεργειών από πολυφασματικά δεδομένα Sentinel-2, με ιδιαίτερη έμφαση στη φασματική αξιολόγηση των δεδομένων εισόδου και στην ερμηνευσιμότητα της συμβολής των επιμέρους ζωνών.

Η μεθοδολογία βασίστηκε σε τρία διαδοχικά στάδια: αυτοεπιβλεπόμενη προεκπαίδευση σε μη επισημασμένα δεδομένα Sentinel-2, ενδιάμεση προσαρμογή σε πρόβλημα ταξινόμησης καλλιεργειών και τελικό fine-tuning για ταξινόμηση ασθενειών. Παράλληλα, αξιολογήθηκαν διαφορετικοί φασματικοί συνδυασμοί εισόδου, εφαρμόστηκε επαναλαμβανόμενη διασταυρούμενη επικύρωση και πραγματοποιήθηκε ερμηνευτική ανάλυση μέσω band occlusion.

Τα συμπεράσματα που ακολουθούν δεν περιορίζονται στην τελική ταξινομητική απόδοση του μοντέλου, αλλά αφορούν ευρύτερα τη σχέση μεταξύ φασματικής πληροφορίας, επιλογής ζωνών, ερμηνευσιμότητας και γενίκευσης σε προβλήματα ανίχνευσης ασθενειών από δορυφορικά δεδομένα.

9.2 Συμπεράσματα

Η παρούσα εργασία έδειξε ότι η αξιοποίηση πολυφασματικών δεδομένων Sentinel-2 σε συνδυασμό με τεχνικές βαθιάς μάθησης μπορεί να υποστηρίξει την ανάπτυξη αυτοματοποιημένων μεθόδων για την ανίχνευση ασθενειών καλλιεργειών. Το προτεινόμενο πολυσταδιακό pipeline SSL → Crop → Disease αποτέλεσε μια δομημένη στρατηγική εκμάθησης και μεταφοράς γνώσης, η οποία επιτρέπει στο μοντέλο να ξεκινά από γενικές φασματικές αναπαραστάσεις, να προσαρμόζεται σε γεωργικά χαρακτηριστικά και τελικά να εξειδικεύεται στη διάκριση φυτοπαθολογικών κατηγοριών.

Το πρώτο βασικό συμπέρασμα αφορά τη χρησιμότητα της αυτοεπιβλεπόμενης προεκπαίδευσης. Η χρήση μη επισημασμένων πολυφασματικών δεδομένων επέτρεψε στον encoder να μάθει γενικές φασματικές και χωρικές αναπαραστάσεις πριν από την εποπτευόμενη εκπαίδευση. Το στάδιο αυτό είναι ιδιαίτερα σημαντικό σε εφαρμογές τηλεπισκόπησης, όπου ο όγκος των διαθέσιμων μη επισημασμένων δεδομένων είναι συνήθως πολύ μεγαλύτερος από τον όγκο των αξιόπιστων labels.

Το δεύτερο συμπέρασμα αφορά τη σημασία της ενδιάμεσης ταξινόμησης καλλιεργειών. Το crop stage λειτούργησε ως γέφυρα μεταξύ της γενικής αυτοεπιβλεπόμενης αναπαραστάσης και του τελικού disease task. Η προσαρμογή του encoder σε καλλιέργειες θεωρείται κρίσιμη, καθώς η φασματική έκφραση μιας ασθένειας δεν είναι ανεξάρτητη από το φυτικό υπόβαθρο στο οποίο εμφανίζεται. Με τον τρόπο αυτό, η μεθοδολογία αντιμετωπίζει την ανίχνευση ασθενειών ως αποτέλεσμα σταδιακής εξειδίκευσης και όχι ως απομονωμένο πρόβλημα ταξινόμησης.

Το τρίτο και ιδιαίτερα σημαντικό συμπέρασμα αφορά τη φασματική αξιολόγηση. Τα αποτελέσματα έδειξαν ότι το RGB σχήμα εισόδου πέτυχε την υψηλότερη μέση macro-F1 μεταξύ των εξεταζόμενων φασματικών συνδυασμών. Το εύρημα αυτό υποδηλώνει ότι, για το συγκεκριμένο dataset και τη συγκεκριμένη διατύπωση του προβλήματος, οι ορατές ζώνες B2, B3 και B4 ευθυγραμμίζονται ισχυρά με τα διαθέσιμα disease labels. Επομένως, η προσθήκη περισσότερων φασματικών ζωνών δεν οδήγησε απαραίτητα σε καλύτερη γενίκευση.

Το τέταρτο συμπέρασμα αφορά το πλήρες πολυφασματικό σχήμα. Παρότι το Full multispectral input περιλαμβάνει πληροφορία από το ορατό, το NIR, το red-edge και το SWIR τμήμα του φάσματος, δεν ξεπέρασε την απόδοση του RGB. Η παρατήρηση αυτή δείχνει ότι η αύξηση της φασματικής διαστατικότητας μπορεί να συνοδεύεται από πρόσθετο θόρυβο, μεγαλύτερο κίνδυνο υπερπροσαρμογής και επίδραση της επαναδειγματοληψίας ζωνών χαμηλότερης χωρικής ανάλυσης. Συνεπώς, περισσότερες φασματικές ζώνες δεν σημαίνουν απαραίτητα καλύτερη ταξινόμηση.

Το πέμπτο συμπέρασμα αφορά την ερμηνευσιμότητα του μοντέλου. Η band occlusion analysis στο πλήρες πολυφασματικό μοντέλο έδειξε ότι οι ζώνες με τη μεγαλύτερη επίδραση στη macro-F1 ήταν οι B8A, B3, B4, B7 και B8. Το αποτέλεσμα αυτό δείχνει ότι το Full multispectral μοντέλο αξιοποιεί συνδυαστικά ορατή πληροφορία και πληροφορία από την περιοχή red-edge/NIR. Ιδιαίτερα η υψηλή σημαντικότητα της B8A υποδηλώνει ότι η περιοχή μετάβασης μεταξύ red-edge και NIR παρέχει ουσιαστική πληροφορία για τη λειτουργία του μοντέλου.

Το έκτο συμπέρασμα αφορά το XAI-guided Top-5 φασματικό σχήμα. Με βάση την band occlusion analysis σχεδιάστηκε ένα υποσύνολο πέντε ζωνών, αποτελούμενο από τις B3, B4, B7, B8 και B8A. Το σχήμα αυτό πέτυχε απόδοση σχεδόν ίδια με το Full multispectral σχήμα, χρησιμοποιώντας όμως μόνο τις μισές φασματικές ζώνες. Το εύρημα αυτό δείχνει ότι η ερμηνευτικά καθοδηγούμενη επιλογή ζωνών μπορεί να μειώσει τη διαστατικότητα της εισόδου χωρίς ουσιαστική απώλεια απόδοσης.

Συνολικά, η εργασία καταλήγει στο συμπέρασμα ότι η αποτελεσματική αξιοποίηση πολυφασματικών δεδομένων για ανίχνευση ασθενειών δεν εξαρτάται αποκλειστικά από τον αριθμό των διαθέσιμων ζωνών, αλλά από την καταλληλότητα, τη σταθερότητα και την ερμηνευτική αξία της φασματικής πληροφορίας. Η φασματική επιλογή πρέπει να αξιολογείται πειραματικά και να υποστηρίζεται από τεχνικές ερμηνευσιμότητας, ιδιαίτερα όταν τα διαθέσιμα δεδομένα είναι μικρά, ανισόρροπα και θορυβώδη.

9.3 Επιστημονική συνεισφορά της εργασίας

Η επιστημονική συνεισφορά της παρούσας εργασίας εντοπίζεται σε τέσσερα βασικά επίπεδα: στη μεθοδολογία μάθησης, στη φασματική αξιολόγηση, στην ερμηνευσιμότητα του μοντέλου και στην πειραματική τεκμηρίωση των αποτελεσμάτων.

Πρώτον, προτείνεται ένα πολυσταδιακό πλαίσιο βαθιάς μάθησης για δεδομένα Sentinel-2, το οποίο συνδυάζει αυτοεπιβλεπόμενη προεκπαίδευση, ενδιάμεση προσαρμογή σε ταξινόμηση καλλιεργειών και τελικό fine-tuning σε ταξινόμηση ασθενειών. Η προσέγγιση αυτή αντιμετωπίζει το πρόβλημα όχι ως απλή εφαρμογή ταξινόμησης, αλλά ως ιεραρχική διαδικασία σταδιακής εξειδίκευσης αναπαραστάσεων.

Δεύτερον, η εργασία πραγματοποιεί συστηματική αξιολόγηση διαφορετικών φασματικών συνδυασμών εισόδου Sentinel-2. Η αξιολόγηση περιλαμβάνει σχήματα που βασίζονται στο ορατό φάσμα, στο NIR, στις red-edge ζώνες, στις SWIR ζώνες και στο πλήρες πολυφασματικό input. Με τον τρόπο αυτό, η μελέτη διερευνά πειραματικά τη συμβολή διαφορετικών φασματικών περιοχών στην ανίχνευση ασθενειών.

Τρίτον, εφαρμόζεται επαναλαμβανόμενη διασταυρούμενη επικύρωση και στατιστική αξιολόγηση για την αποτίμηση των φασματικών σχημάτων. Η επιλογή αυτή ενισχύει την αξιοπιστία των συμπερασμάτων, καθώς μειώνει την εξάρτηση από μεμονωμένα splits ή τυχαίες αρχικοποιήσεις και αποτρέπει την υπερερμηνεία μικρών αριθμητικών διαφορών.

Τέταρτον, η εργασία ενσωματώνει τεχνική ερμηνευσιμότητας μέσω band occlusion analysis στο πλήρες πολυφασματικό μοντέλο. Η ανάλυση αυτή επιτρέπει την εκτίμηση της σχετικής σημαντικότητας κάθε

φασματικής ζώνης και συνδέει την απόδοση του μοντέλου με τη βιοφυσική σημασία των καναλιών Sentinel-2.

Πέμπτον, με βάση τα αποτελέσματα της ΧΑΙ ανάλυσης σχεδιάζεται και αξιολογείται ένα πρόσθετο ΧΑΙ-guided Top-5 φασματικό σχήμα. Το σχήμα αυτό δείχνει ότι ένα μικρότερο και ερμηνευτικά επιλεγμένο υποσύνολο ζωνών μπορεί να διατηρήσει απόδοση συγκρίσιμη με το πλήρες πολυφασματικό input. Η συνεισφορά αυτή είναι σημαντική, καθώς συνδέει την ερμηνευσιμότητα με τον πρακτικό σχεδιασμό πιο αποδοτικών φασματικών εισόδων.

Τέλος, η εργασία αναδεικνύει ένα κρίσιμο συμπέρασμα για τη χρήση πολυφασματικών δεδομένων σε προβλήματα βαθιάς μάθησης: η χρήση περισσότερων ζωνών δεν οδηγεί κατ' ανάγκη σε υψηλότερη απόδοση. Η φασματική πληροφορία πρέπει να αξιολογείται, να ερμηνεύεται και να επιλέγεται με βάση το εκάστοτε πρόβλημα, το είδος των labels, το μέγεθος του dataset και τη δυνατότητα γενίκευσης του μοντέλου.

Πίνακας 9.1. Κύριες επιστημονικές συνεισφορές της εργασίας.

Αξονας συνεισφοράς	Περιγραφή
Πολυσταδιακή μάθηση	SSL → Crop → Disease pipeline για σταδιακή εξειδίκευση αναπαραστάσεων
Φασματική αξιολόγηση	Σύγκριση διαφορετικών συνδυασμών Sentinel-2 ζωνών
Στατιστική τεκμηρίωση	Repeated cross-validation, Friedman test και Holm correction
Ερμηνευσιμότητα	Band occlusion analysis στο πλήρες πολυφασματικό μοντέλο
ΧΑΙ-guided επιλογή ζωνών	Σχεδιασμός Top-5 φασματικού subset βάσει σημαντικότητας
Κεντρικό εύρημα	Περισσότερες ζώνες δεν οδηγούν απαραίτητα σε καλύτερη γενίκευση

9.4 Περιορισμοί και προσεκτική ερμηνεία των αποτελεσμάτων

Παρά τη συστηματική πειραματική διαδικασία, τα αποτελέσματα της παρούσας εργασίας πρέπει να ερμηνευθούν με προσοχή. Ο πρώτος βασικός περιορισμός αφορά το μέγεθος και την ανισορροπία του συνόλου δεδομένων ασθενειών. Ορισμένες κατηγορίες ασθενειών εκπροσωπούνται από σημαντικά λιγότερα δείγματα, γεγονός που επηρεάζει τόσο τη σταθερότητα της εκπαίδευσης όσο και την αξιοπιστία της ανά κλάση απόδοσης. Παρότι η χρήση Weighted Random Sampler και macro-F1 περιορίζει εν μέρει το πρόβλημα, δεν το εξαλείφει πλήρως.

Δεύτερος περιορισμός αφορά τη φύση των labels και τη χωρική ανάλυση των δεδομένων Sentinel-2. Οι ασθένειες δεν παρατηρούνται άμεσα σε επίπεδο φύλλου ή φυτού, αλλά έμμεσα μέσα από φασματικές αποκλίσεις σε patches μέσης χωρικής ανάλυσης. Ένα patch μπορεί να περιλαμβάνει μικτή πληροφορία από διαφορετικές επιφάνειες, διαφορετικά στάδια ανάπτυξης ή γειτονικά αγροτεμάχια. Αυτό εισάγει αβεβαιότητα στη σχέση μεταξύ φασματικού σήματος και πραγματικής φυτοπαθολογικής κατάστασης.

Τρίτος περιορισμός σχετίζεται με τις φασματικές ζώνες διαφορετικής χωρικής ανάλυσης. Οι red-edge και SWIR ζώνες παρέχονται σε χαμηλότερη χωρική ανάλυση από τις βασικές ορατές ζώνες και απαιτούν επαναδειγματοληψία για να ενταχθούν στο ίδιο πολυκαναλικό tensor. Η διαδικασία αυτή είναι αναγκαία, αλλά δεν προσθέτει νέα πραγματική χωρική πληροφορία και μπορεί να συμβάλλει στην υποβάθμιση της συνεισφοράς ορισμένων μη ορατών ζωνών.

Τέταρτος περιορισμός αφορά την ερμηνευτική ανάλυση. Η band occlusion analysis προσφέρει πρακτική εκτίμηση της εξάρτησης του μοντέλου από κάθε ζώνη, αλλά δεν αποδεικνύει αιτιώδη σχέση μεταξύ μιας ζώνης και μιας ασθένειας. Τα αποτελέσματά της πρέπει να ερμηνεύονται ως post-hoc ανάλυση της συμπεριφοράς του εκπαιδευμένου μοντέλου και όχι ως απόλυτη βιοφυσική εξήγηση.

Πέμπτος περιορισμός αφορά το XAI-guided Top-5 σχήμα. Το σχήμα αυτό προέκυψε μετά την ανάλυση του πλήρους πολυφασματικού μοντέλου και όχι ως ανεξάρτητη υπόθεση πριν από την έναρξη των πειραμάτων. Επομένως, πρέπει να θεωρηθεί ως διερευνητικό πείραμα που αξιολογεί τη χρησιμότητα της ερμηνευτικά καθοδηγούμενης επιλογής ζωνών και όχι ως πλήρως ανεξάρτητη επιβεβαίωση βέλτιστου spectral subset.

Τέλος, η μελέτη δεν περιλαμβάνει εξωτερική επικύρωση σε πλήρως ανεξάρτητο γεωγραφικό ή χρονικό dataset. Συνεπώς, τα συμπεράσματα αφορούν το συγκεκριμένο πειραματικό πλαίσιο και πρέπει να επιβεβαιωθούν σε μεγαλύτερα, πιο ισορροπημένα και ανεξάρτητα σύνολα δεδομένων πριν θεωρηθούν γενικεύσιμα σε επιχειρησιακή κλίμακα.

9.5 Προτάσεις για μελλοντική έρευνα

Η παρούσα εργασία ανοίγει αρκετές κατευθύνσεις για μελλοντική έρευνα. Πρώτη και σημαντικότερη κατεύθυνση είναι η αξιολόγηση της προτεινόμενης μεθοδολογίας σε μεγαλύτερα και πιο ισορροπημένα datasets ασθενειών. Η αύξηση του αριθμού δειγμάτων, ιδίως για τις υποεκπροσωπούμενες κατηγορίες, θα επέτρεπε πιο σταθερή εκπαίδευση, πιο αξιόπιστη ανά κλάση αξιολόγηση και ασφαλέστερη στατιστική σύγκριση μεταξύ φασματικών σχημάτων.

Δεύτερη κατεύθυνση είναι η εξωτερική επικύρωση σε διαφορετικές γεωγραφικές περιοχές, χρονικές περιόδους και καλλιεργητικά περιβάλλοντα. Ένα τέτοιο πείραμα θα επέτρεπε να εξεταστεί κατά πόσο τα βασικά ευρήματα της εργασίας, όπως η ισχυρή απόδοση του RGB και η σημαντικότητα της B8A, παραμένουν σταθερά εκτός του αρχικού dataset.

Τρίτη κατεύθυνση αφορά την περαιτέρω ανάπτυξη μεθόδων επιλογής φασματικών ζωνών. Η παρούσα εργασία χρησιμοποίησε band occlusion ως post-hoc τεχνική ερμηνευσιμότητας και στη συνέχεια αξιολόγησε ένα XAI-guided Top-5 subset. Μελλοντικά, θα μπορούσαν να εξεταστούν πιο συστηματικές μέθοδοι feature selection, όπως wrapper-based επιλογή, embedded sparsity constraints, attention-based μηχανισμοί ή learnable band selection layers.

Τέταρτη κατεύθυνση αφορά τη βελτίωση της χρονικής μοντελοποίησης. Στην παρούσα μεθοδολογία η χρονική πληροφορία αξιοποιήθηκε κυρίως στο crop stage μέσω temporal mean pooling. Μελλοντικές εκδόσεις του μοντέλου θα μπορούσαν να ενσωματώσουν temporal transformers, recurrent architectures ή attention-based temporal aggregation, ώστε να αποτυπώνεται καλύτερα η φαινολογική εξέλιξη και η χρονική δυναμική των φυτοπαθολογικών αποκλίσεων.

Πέμπτη κατεύθυνση αφορά την ενσωμάτωση πρόσθετων πηγών δεδομένων. Η συνδυαστική αξιοποίηση Sentinel-2 με δεδομένα UAV υψηλής χωρικής ανάλυσης, μετεωρολογικά δεδομένα, εδαφολογικές πληροφορίες ή επιτόπιες γεωπονικές παρατηρήσεις θα μπορούσε να μειώσει την αβεβαιότητα που προκύπτει από τη μέση χωρική ανάλυση των δορυφορικών δεδομένων και να βελτιώσει την πρακτική αξιοπιστία του συστήματος.

Έκτη κατεύθυνση αφορά την περαιτέρω διερεύνηση τεχνικών ερμηνευσιμότητας. Εκτός από τη band occlusion analysis, μπορούν να εξεταστούν μέθοδοι όπως permutation importance, gradient-based saliency, integrated gradients ή attention visualization. Η σύγκριση πολλαπλών XAI τεχνικών θα μπορούσε να προσφέρει πιο ολοκληρωμένη εικόνα για το πώς τα μοντέλα βαθιάς μάθησης αξιοποιούν την πολυφασματική πληροφορία.

Τέλος, σημαντική μελλοντική κατεύθυνση αποτελεί η μεταφορά της μεθοδολογίας από το ερευνητικό περιβάλλον σε πιο επιχειρησιακά σενάρια γεωργίας ακριβείας. Αυτό απαιτεί αξιολόγηση σε πραγματικές συνθήκες, διασύνδεση με συστήματα γεωχωρικής πληροφορίας και ανάπτυξη εργαλείων

που μπορούν να υποστηρίξουν γεωπόνους και παραγωγούς στον εντοπισμό περιοχών που χρειάζονται περαιτέρω έλεγχο.

Επιπλέον, η ανά κλάση ανάλυση band occlusion ανέδειξε ότι διαφορετικές ασθένειες παρουσιάζουν διαφορετικά φασματικά προφίλ ευαισθησίας. Μελλοντική έρευνα θα μπορούσε να αξιοποιήσει το εύρημα αυτό για την ανάπτυξη class-specific ή disease-specific φασματικών ταξινομητών, στους οποίους κάθε ασθένεια θα αναγνωρίζεται με βάση τις ζώνες που αποδείχθηκαν σημαντικότερες για τη συγκεκριμένη κλάση. Ωστόσο, μια τέτοια προσέγγιση απαιτεί μεγαλύτερο και πιο ισορροπημένο αριθμό δειγμάτων ανά ασθένεια, ώστε να αποφευχθεί η υπερπροσαρμογή των επιμέρους ταξινομητών.

9.6 Τελική αποτίμηση

Η παρούσα διπλωματική εργασία ανέπτυξε και αξιολόγησε ένα πολυσταδιακό πλαίσιο βαθιάς μάθησης για την ανίχνευση ασθενειών καλλιεργειών από πολυφασματικά δεδομένα Sentinel-2. Η συμβολή της δεν περιορίζεται στην υλοποίηση ενός ταξινομητή, αλλά επεκτείνεται στη συστηματική διερεύνηση της φασματικής πληροφορίας και στην ερμηνεία της λειτουργίας του μοντέλου.

Τα αποτελέσματα ανέδειξαν ότι το RGB σχήμα πέτυχε την υψηλότερη μέση απόδοση, γεγονός που υπογραμμίζει τη σημασία των ορατών ζωνών για το συγκεκριμένο πρόβλημα. Παράλληλα, η band occlusion analysis έδειξε ότι το πλήρες πολυφασματικό μοντέλο αξιοποιεί ουσιαστικά και πληροφορία από τη red-edge/NIR περιοχή, κυρίως μέσω των B8A, B7 και B8. Το XAI-guided Top-5 πείραμα έδειξε ότι ένα μικρότερο, ερμηνευτικά καθοδηγούμενο subset μπορεί να διατηρήσει απόδοση συγκρίσιμη με το πλήρες πολυφασματικό σχήμα.

Το κεντρικό συμπέρασμα της εργασίας είναι ότι η αποτελεσματική χρήση πολυφασματικών δορυφορικών δεδομένων δεν εξαρτάται απλώς από την ποσότητα των διαθέσιμων φασματικών ζωνών, αλλά από την κατάλληλη επιλογή, αξιολόγηση και ερμηνεία τους. Η φασματική πληροφορία πρέπει να αντιμετωπίζεται ως αντικείμενο συστηματικής πειραματικής διερεύνησης και όχι ως δεδομένη προσθήκη στο μοντέλο.

Με τον τρόπο αυτό, η εργασία συμβάλλει στην κατεύθυνση πιο αξιόπιστων, ερμηνεύσιμων και αποδοτικών μεθόδων βαθιάς μάθησης για τη γεωργική τηλεπισκόπηση. Παρά τους περιορισμούς της, παρέχει ένα ισχυρό μεθοδολογικό και πειραματικό υπόβαθρο για μελλοντική έρευνα και για τη διαμόρφωση επιστημονικής δημοσίευσης με αντικείμενο τη φασματική αξιολόγηση και την ερμηνευσιμότητα μοντέλων ανίχνευσης ασθενειών από Sentinel-2 δεδομένα.

Πίνακας 9.2. Τελική σύνδεση ερευνητικών ερωτημάτων και συμπερασμάτων.

Ερευνητικός άξονας	Κύριο εύρημα	Συμπέρασμα
Πολυσταδιακή μάθηση	To SSL → Crop → Disease pipeline παρείχε σταθερή βάση ταξινόμησης	Η σταδιακή εξειδίκευση είναι κατάλληλη για περιορισμένα labels
Φασματικά σχήματα	To RGB πέτυχε την υψηλότερη μέση macro-F1	Οι ορατές ζώνες είναι ιδιαίτερα ισχυρές για το συγκεκριμένο task
Full multispectral	Δεν ξεπέρασε το RGB	Περισσότερες ζώνες δεν συνεπάγονται καλύτερη γενίκευση
Band occlusion	B8A, B3, B4, B7, B8 ήταν οι σημαντικότερες ζώνες	To full model αξιοποιεί συνδυασμό visible και red-edge/NIR πληροφορίας
XAI-guided Top-5	Πλησίασε την απόδοση του Full με τις μισές ζώνες	Η ερμηνευτικά καθοδηγούμενη επιλογή ζωνών μπορεί να μειώσει τη διαστατικότητα
Περιορισμοί	Μικρό, ανισόρροπο dataset και έμμεση φύση labels	Απαιτείται εξωτερική επικύρωση και μεγαλύτερα datasets

ΒΙΒΛΙΟΓΡΑΦΙΑ

Βιβλία

[1] J. B. Adams, M. O. Smith, and A. R. Gillespie, “Imaging spectroscopy: Interpretation based on spectral mixture analysis,” in *Remote Geochemical Analysis: Elemental and Mineralogical Composition*, C. M. Pieters and P. A. J. Englert, Eds. Cambridge, U.K.: Cambridge University Press, 1993, pp. 145-166.

[2] Food and Agriculture Organization of the United Nations, *The State of the World’s Biodiversity for Food and Agriculture*, J. Bélanger and D. Pilling, Eds. Rome, Italy: FAO, 2019.

Άρθρα σε επιστημονικά περιοδικά

[3] J. E. Ball, D. T. Anderson, and C. S. Chan, “A comprehensive survey of deep learning in remote sensing: Theories, tools, and challenges for the community,” *J. Appl. Remote Sens.*, vol. 11, no. 4, Art. no. 042609, 2017.

[4] W. Chen, K. Yang, Z. Yu, Y. Shi, and C. L. P. Chen, “A survey on imbalanced learning: Latest research, applications and future directions,” *Artif. Intell. Rev.*, vol. 57, Art. no. 137, 2024.

[5] J. M. A. Duncan, J. Dash, and P. M. Atkinson, “The potential of satellite-observed crop phenology to enhance yield gap assessments in smallholder landscapes,” *Front. Environ. Sci.*, vol. 3, Art. no. 56, 2015.

[6] B.-C. Gao, “NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space,” *Remote Sens. Environ.*, vol. 58, no. 3, pp. 257-266, 1996.

[7] A. R. Huete, “A soil-adjusted vegetation index (SAVI),” *Remote Sens. Environ.*, vol. 25, no. 3, pp. 295-309, 1988.

[8] A. Huete, K. Didan, T. Miura, E. P. Rodriguez, X. Gao, and L. G. Ferreira, “Overview of the radiometric and biophysical performance of the MODIS vegetation indices,” *Remote Sens. Environ.*, vol. 83, no. 1-2, pp. 195-213, 2002.

[9] A. Luque, A. Carrasco, A. Martín, and A. de las Heras, “The impact of class imbalance in classification performance metrics based on the binary confusion matrix,” *Pattern Recognit.*, vol. 91, pp. 216-231, 2019.

[10] S. J. Pan and Q. Yang, “A survey on transfer learning,” *IEEE Trans. Knowl. Data Eng.*, vol. 22, no. 10, pp. 1345-1359, Oct. 2010.

[11] J. B. Ristaino *et al.*, “The persistent threat of emerging plant disease pandemics to global food security,” *Proc. Natl. Acad. Sci. U.S.A.*, vol. 118, no. 23, Art. no. e2022239118, 2021.

[12] M. Sokolova and G. Lapalme, “A systematic analysis of performance measures for classification tasks,” *Inf. Process. Manag.*, vol. 45, no. 4, pp. 427-437, 2009.

- [13] A. Terentev, V. Dolzhenko, A. Fedotov, and D. Eremenko, "Current state of hyperspectral remote sensing for early plant disease detection: A review," *Sensors*, vol. 22, no. 3, Art. no. 757, 2022.
- [14] Y. Wang, C. M. Albrecht, N. Ait Ali Braham, L. Mou, and X. X. Zhu, "Self-supervised learning in remote sensing: A review," *IEEE Geosci. Remote Sens. Mag.*, vol. 10, no. 4, pp. 213-247, 2022.
- [15] X. X. Zhu, D. Tuia, L. Mou, G.-S. Xia, L. Zhang, F. Xu, and F. Fraundorfer, "Deep learning in remote sensing: A comprehensive review and list of resources," *IEEE Geosci. Remote Sens. Mag.*, vol. 5, no. 4, pp. 8-36, 2017.
- [24] R. Karthik, R. Hariharan, and M. Sujatha, "Deep learning for plant disease detection and diagnosis: A review," *Multimedia Tools and Applications*, vol. 81, 2022.
- [25] Y. Xu, J. Zhang, and Q. Li, "A survey on deep learning in Sentinel-2 data technology: Comprehensive and systematic," *Remote Sensing*, vol. 15, no. 4, 2023.
- [26] Y. Bazi, L. Bashmal, M. M. Al Rahhal, R. Al Dayil, and N. Al Ajlan, "Vision Transformers for Remote Sensing Image Classification," *Remote Sensing*, vol. 13, no. 3, Art. no. 516, 2021, doi: 10.3390/rs13030516.

Εργασίες σε πρακτικά συνεδρίων

- [16] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2016, pp. 770-778.
- [17] P. Khosla, P. Teterwak, C. Wang, A. Sarna, Y. Tian, P. Isola, A. Maschinot, C. Liu, and D. Krishnan, "Supervised contrastive learning," in *Advances in Neural Information Processing Systems (NeurIPS)*, vol. 33, 2020, pp. 18661-18673.
- [18] J. W. Rouse, R. H. Haas, J. A. Schell, and D. W. Deering, "Monitoring vegetation systems in the Great Plains with ERTS," in *Proc. 3rd Earth Resources Technology Satellite-1 Symp.*, vol. 1, 1974, pp. 309-317.
- [27] O. Mañas, A. Lacoste, X. Giró-i-Nieto, D. Vazquez, and P. Rodríguez, "Seasonal Contrast: Unsupervised Pre-Training From Uncurated Remote Sensing Data," in *Proc. IEEE/CVF Int. Conf. Computer Vision (ICCV)*, 2021, pp. 9414-9423, doi: 10.1109/ICCV48922.2021.00928.

Τεχνικές αναφορές / Handbooks / Product Specifications

- [19] European Space Agency, *Sentinel-2 User Handbook*. Paris, France: ESA, 2015.
- [20] Copernicus Sentinel, *Sentinel-2 Products Specification Document*, 2021.

Διαδικτυακές πηγές

- [21] European Space Agency, "Sentinel-2," [Online]. Available: <https://www.esa.int/>. [Accessed: Mar. 31, 2026].
- [22] Copernicus Data Space Ecosystem, "Sentinel-2 documentation," [Online]. Available: <https://documentation.dataspace.copernicus.eu/>. [Accessed: Mar. 31, 2026].

Σύνολα δεδομένων / Πλατφόρμες δεδομένων

[23] Kaggle, “Beyond Visible Spectrum: AI for Agriculture 2026,” [Online]. Available: <https://www.kaggle.com/>. [Accessed: Mar. 31, 2026].

Πρόσθετες πηγές ερμηνευσιμότητας / XAI

[28] M. D. Zeiler and R. Fergus, “Visualizing and Understanding Convolutional Networks,” in Computer Vision – ECCV 2014, Lecture Notes in Computer Science, vol. 8689, Springer, 2014, pp. 818–833, doi: 10.1007/978-3-319-10590-1_53.

[29] W. Samek, T. Wiegand, and K.-R. Müller, “Explainable Artificial Intelligence: Understanding, Visualizing and Interpreting Deep Learning Models,” arXiv preprint arXiv:1708.08296, 2017.

[30] M. T. Ribeiro, S. Singh, and C. Guestrin, “‘Why Should I Trust You?’: Explaining the Predictions of Any Classifier,” in Proc. 22nd ACM SIGKDD Int. Conf. Knowledge Discovery and Data Mining (KDD), 2016, pp. 1135–1144, doi: 10.1145/2939672.2939778.

[31] C. Molnar, Interpretable Machine Learning: A Guide for Making Black Box Models Explainable, 2nd ed., 2022. [Online]. Available: <https://christophm.github.io/interpretable-ml-book/>.

ΠΑΡΑΡΤΗΜΑ Α

Σύνοψη βασικών παραμέτρων πειραματικής διαδικασίας

Στο παρόν παράρτημα συνοψίζονται συγκεντρωτικά οι βασικές ρυθμίσεις των κύριων πειραματικών σταδίων, ώστε να διευκολύνεται η αναπαραγωγή της μεθοδολογίας.

Στάδιο	Κύρια είσοδος	Βασικές ρυθμίσεις	Κριτήριο / έξοδος
SSL προεκπαίδευση	10 ζώνες Sentinel-2, έως 4 χρονικές λήψεις	25 εποχές, batch size 8, learning rate 2×10^{-4} , SupConLoss	Επιλογή checkpoint με βάση τη μικρότερη contrastive loss
Ταξινόμηση καλλιέργειας	10 ζώνες Sentinel-2, 4 χρονικές λήψεις ανά δείγμα	25 εποχές, batch size 16, seed 42, AdamW	Ενδιάμεση γεωργική εξειδίκευση του encoder
Ταξινόμηση ασθενειών	Πολυφασματικά patches Sentinel-2	45 εποχές, batch size 32, learning rate 2×10^{-4} , weight decay 10^{-4} , Weighted Random Sampler	Επιλογή checkpoint με βάση τη validation macro-F1
Φασματική αξιολόγηση	Εναλλακτικοί συνδυασμοί ζωνών	Repeated 5-fold cross-validation	Σύγκριση mean macro-F1 και τυπικής απόκλισης
Band occlusion	Πλήρες πολυφασματικό μοντέλο	Απόκρυψη μίας ζώνης κάθε φορά με αντικατάσταση από τη μέση κανονικοποιημένη τιμή	Εκτίμηση πτώσης macro-F1 και ανά κλάση F1