



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών
Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών

**Ταξινόμηση καλλιεργούμενων καρπών με αλγόριθμους
μηχανικής μάθησης χρησιμοποιώντας δορυφορικά
δεδομένα**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΧΑΡΙΣΗΣ ΧΡΗΣΤΟΣ

Επιβλέπων : Σταφυλοπάτης Ανδρέας-Γεώργιος
Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούλιος 2020



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών
Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών

**Ταξινόμηση καλλιεργούμενων καρπών με αλγόριθμους
μηχανικής μάθησης χρησιμοποιώντας δορυφορικά
δεδομένα**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΧΑΡΙΣΗΣ ΧΡΗΣΤΟΣ

Επιβλέπων : Σταφυλοπάτης Ανδρέας-Γεώργιος
Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 8η Ιουλίου 2020.

.....
Σταφυλοπάτης Ανδρέας-Γεώργιος
Καθηγητής Ε.Μ.Π.

.....
Γεώργιος Στάμου
Αναπλ.Καθηγητής Ε.Μ.Π.

.....
Παναγιώτης Τσανάκας
Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούλιος 2020

.....
Χαρίσης Χρήστος

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.

Copyright © Χαρίσης Χρήστος, 2020.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Ο συνδυασμός της συνεχόμενης αύξησης του πληθυσμού και της σταδιακής ερημοποίησης περιοχών της Γης λόγω της κλιματικής αλλαγής θα οδηγήσει στο μέλλον στην αδυναμία εξασφάλισης τροφής για όλους τους ανθρώπους. Η εύρεση αρόσιμης γης αλλά και η συνεχής και λεπτομερής παρακολούθηση των υπαρχουσών καλλιεργειών αποτελούν μείζονα θέματα που απαιτούν την γρήγορη απόκτηση και επεξεργασία δεδομένων από περιοχές μεγάλης έκτασης. Αυτή η ανάγκη καθιστά απαραίτητη τη χρήση δορυφορικής τηλεπισκόπησης, καθώς τα δεδομένα αποκτούνται γρήγορα, από κάθε σημείο της γης, χωρίς φυσική παρουσία και επεμβάσεις στην εξεταζόμενη περιοχή. Επιπλέον, η δυνατότητα λήψης δεδομένων από πληθώρα αισθητήρων (πολυφασματικοί, θερμοκοί, ραντάρ κ.α.) παρέχει μεγάλη ποικιλία πληροφοριών που μπορούν να χρησιμοποιηθούν για εύρεση αποτελεσματικότερων λύσεων. Ο μεγάλος όγκος αυτών των δεδομένων δυσχεραίνει την επεξεργασία τους και κρίνεται απαραίτητη η επιλογή μέρους αυτών, χωρίς όμως να έχει επίπτωση στην ακρίβεια του αποτελέσματος. Σκοπός της διπλωματικής εργασίας είναι η ταξινόμηση καλλιεργούμενων καρπών με αλγόριθμους μηχανικής μάθησης χρησιμοποιώντας δεδομένα από δορυφόρους. Τα δεδομένα αυτά απαρτίζονται από πολυφασματικές λήψεις των δορυφόρων Sentinel 2 και Landsat 8 κατά την διάρκεια του έτους 2019. Η επεξεργασία τους περιλαμβάνει την συμπλήρωση ελλειπών τιμών, τον υπολογισμό του Δείκτη Βλάστησης Κανονικοποιημένης Διαφοράς και τη δημιουργία τελικής χρονοσειράς εικόνων. Στη συνέχεια πραγματοποιείται ταξινόμηση των καλλιεργειών με τη χρήση δύο μεθόδων, που διαφέρουν στον ορισμό των προτύπων προς ταξινόμηση. Η πρώτη θεωρεί ως πρότυπα τα εικονοστοιχεία της εικόνας, ενώ η δεύτερη ομαδοποιεί τα γειτονικά εικονοστοιχεία, ανιχνεύοντας με αυτόν τον τρόπο τα υπάρχοντα αγροτεμάχια, τα οποία εν τέλει χρησιμοποιεί ως πρότυπα. Για τις μετρήσεις χρησιμοποιούνται ένα Τεχνητό Νευρωνικό Δίκτυο και οι αλγόριθμοι μηχανικής μάθησης Τυχαίων Δέντρων και Μηχανών Διανυσμάτων Υποστήριξης. Τέλος, εξετάζονται και συγκρίνονται τα αποτελέσματα όλων των συνδυασμών της επεξεργασίας των δεδομένων και των ταξινομητών.

Λέξεις κλειδιά

μηχανική μάθηση, δορυφορική τηλεπισκόπηση, ταξινόμηση καρπών, διαχείριση δεδομένων, sentinel 2, landsat 8, τυχαία δέντρα, μηχανές διανυσμάτων υποστήριξης, τεχνητό νευρωνικό δίκτυο.

Abstract

The combination of continuous population growth and the gradual desertification of areas of the Earth due to climate change will lead to the inability to provide food for all people in the future. Finding arable land as well as continuous and detailed monitoring of existing crops are major issues that require the rapid acquisition and processing of data from large areas. This need makes it necessary to use satellite remote sensing, as the data is obtained quickly, from anywhere in the world, without physical presence and interventions in the examined area. In addition, the ability to receive data from a variety of sensors (multispectral, thermal, radar, etc.) provides a wide variety of information that can be used to find more effective solutions. The large volume of this data makes it difficult to process and it is necessary to select part of it, but without affecting the accuracy of the result. The purpose of the thesis is to classify cultivated crops with machine learning algorithms using data from satellites. This data consists of multispectral images of the Sentinel 2 and Landsat 8 satellites during the year 2019. Their processing includes the completion of missing values, the calculation of the Normalized Difference Vegetation Index and the creation of a final time series of images. Then the crops are classified using two methods, which differ in the definition of the data to be classified. The first considers the image pixels as input data, while the second groups the neighboring pixels, thus detecting existing parcels, which it eventually uses as input data. The machine learning algorithms that were used are an Artificial Neural Network, Random Forest and Support Vector Machines. Finally, the results of all aforementioned combinations of data processing and classifiers are examined and compared.

Key words

machine learning, satellite remote sensing, crop classification, data management, sentinel 2, landsat 8, random forest, support vector machines, artificial neural network.

Ευχαριστίες

Αρχικά, θα ήθελα να ευχαριστήσω τον καθηγητή κ. Ανδρέα-Γεώργιο Σταφυλοπάτη ο οποίος ήταν ο επιβλέπων της εργασίας μου και μου έδωσε την δυνατότητα να εκπονήσω την διπλωματική μου πάνω σε ένα πολύ ενδιαφέρον αντικείμενο διευρύνοντας τις γνώσεις μου.

Επίσης, θα ήθελα να ευχαριστήσω θερμά τον κ. Γεώργιο Σιόλα για την μεγάλη συνεισφορά του και τη βοήθεια που μου προσέφερε. Η καθοδήγησή του ήταν καθοριστική για την ολοκλήρωση της διπλωματικής εργασίας μου. Παράλληλα, θα ήθελα να ευχαριστήσω τους καθηγητές κ. Γεώργιο Στάμου και κ. Παναγιώτη Τσανάκα για την συμμετοχή τους στην τριμελή επιτροπή εξέτασης.

Ακόμη, θα ήθελα να ευχαριστήσω τους ανθρώπους της εταιρείας SCiO, στην οποία έκανα την πρακτική μου άσκηση, για τις συμβουλές τους.

Τέλος, θα ήθελα να ευχαριστήσω ιδιαίτερα τους γονείς μου για την βοήθεια και την υποστήριξή τους όλα αυτά τα χρόνια, αλλά και όλους τους φίλους μου οι οποίοι υπήρξαν δίπλα μου κατά τη διάρκεια των φοιτητικών μου χρόνων βοηθώντας με ο καθένας με το δικό του τρόπο.

Χαρίσης Χρήστος,
Αθήνα, 8η Ιουλίου 2020

Περιεχόμενα

Περίληψη	5
Abstract	7
Ευχαριστίες	9
Περιεχόμενα	11
Κατάλογος σχημάτων	13
Κατάλογος πινάκων	17
1. Εισαγωγή	19
1.1 Κίνητρο	19
1.2 Οργάνωση του Τόμου	19
2. Μηχανική Μάθηση	21
2.1 Τι είναι η Μηχανική Μάθηση	21
2.2 Κατηγορίες Μηχανικής Μάθησης	21
2.2.1 Επιβλεπόμενη Μάθηση	21
2.2.2 Μη Επιβλεπόμενη Μάθηση	22
2.2.3 Ενισχυτική Μάθηση	22
2.3 Αλγόριθμοι Μηχανικής Μάθησης	22
2.3.1 Δέντρα Αποφάσεων - Decision Trees	22
2.3.2 Τυχαία Δάση - Random Forest	23
2.3.3 Μηχανές Διανυσμάτων Υποστήριξης - SVM	24
2.4 Τεχνητά Νευρωνικά Δίκτυα	26
2.4.1 Τεχνητός Νευρώνας	26
2.4.2 Πολυεπίπεδα Νευρωνικά Δίκτυα - Multilayer Perceptrons	27
2.4.3 Συναρτήσεις ενεργοποίησης - Activation Functions	28
2.4.4 Συναρτήσεις Κόστους - Cost Functions	30
2.4.5 Αλγόριθμος Οπίσθιας Διάδοσης Σφάλματος - Backpropagation Algorithm	31
2.4.6 Αλγόριθμοι Βελτιστοποίησης - Optimization Algorithms	31
2.5 Μετρικές Αξιολόγησης - Evaluation Functions	32
3. Δορυφορική Τηλεπισκόπηση και Δεδομένα	35
3.1 Τι είναι τηλεπισκόπηση	35
3.2 Ηλεκτρομαγνητική Ακτινοβολία και Ηλεκτρομαγνητικό Φάσμα	36
3.2.1 Ηλεκτρομαγνητική Ακτινοβολία	36
3.2.2 Ηλεκτρομαγνητικό Φάσμα	37
3.2.3 Φασματική Υπογραφή Αντικειμένων	38
3.3 Δορυφορική Τηλεπισκόπηση	39
3.3.1 Δορυφορικές Τροχιές	39

3.3.2	Ανάλυση Δορυφορικών Εικόνων	41
3.3.3	Δορυφόροι Γεωπαρατήρησης	41
3.4	Δείκτης Βλάστησης Κανονικοποιημένης Διαφοράς - Normalized Difference Vegetation Index (NDVI)	45
4.	Ερευνητική Εργασία	47
4.1	Σχετικές Εργασίες	47
4.2	Σκοπός της Ευρενητικής εργασίας	48
4.3	Υλικό και Μεθοδολογία	48
4.3.1	Δορυφορικά Δεδομένα	48
4.3.2	Νεφοκάλυψη και καθαρισμός δεδομένων	54
4.3.3	Εξαγωγή Χαρακτηριστικών	57
4.3.4	Μέθοδοι ορισμού προτύπων (Εικονοστοιχεία, Αντικείμενα)	58
4.3.5	Αλγόριθμοι Μηχανικής Μάθησης	61
4.4	Αποτελέσματα	61
4.4.1	Μέθοδος Εικονοστοιχείων	62
4.4.2	Μέθοδος Αντικειμένων	65
4.4.3	Σύγκριση καλύτερων αποτελεσμάτων ανά περιοχή	83
4.5	Συμπεράσματα - Μελλοντική Εργασία	85
4.5.1	Αξιολόγηση αποτελεσμάτων	85
4.5.2	Μελλοντική Εργασία	86

Κατάλογος σχημάτων

Σχήμα 1: Παράδειγμα Δέντρου Απόφασης	22
Σχήμα 2: Παράδειγμα Τυχαίου Δάσους	24
Σχήμα 3: Παράδειγμα Γραμμικών και Μη διαχωρίσιμων δεδομένων	25
Σχήμα 4: Παράδειγμα Υπερεπιπέδου και Περιθωρίου	25
Σχήμα 5: Αρχιτεκτονική Τεχνητού Νευρώνα (πηγή:towardsdatascience.com)	26
Σχήμα 6: Multi-Layer Perceptron (πηγή:deeprai.org)	28
Σχήμα 7: Σιγμοειδής Συνάρτηση (πηγή:wikipedia.org)	28
Σχήμα 8: Συνάρτηση Υπερβολικής Εφαπτομένης (πηγή:oreilly.com)	29
Σχήμα 9: Μονάδα Γραμμικής Ανόρθωσης (πηγή:researchgate.net)	29
Σχήμα 10: Ηλεκτρομαγνητική Ακτινοβολία (πηγή:imamamgnets.com)	36
Σχήμα 11: Ηλεκτρομαγνητικό Φάσμα (πηγή:sapling learning)	37
Σχήμα 12: Φασματικές Ταυτότητες (πηγή:remotesensing529)	38
Σχήμα 13: Δορυφορικές τροχιές. (πηγή:researchgate.net)	40
Σχήμα 14: Ίχνος δορυφόρου και λωρίδα παρατήρησης. (πηγή:researchgate.net)	40
Σχήμα 15: Υπερδειγματοληψία και Υποδειγματοληψία εικόνας. (πηγή:researchgate)	41
Σχήμα 16: Δείκτης NDVI (πηγή:The Landscape Toolbox)	46
Σχήμα 17: Περιοχή 1.	49
Σχήμα 18: Υποπεριοχή 1.	49
Σχήμα 19: Περιοχή 2.	50
Σχήμα 20: Υποπεριοχή 2.	50
Σχήμα 21: Περιοχή 3.	50
Σχήμα 22: Υποπεριοχή 3.	50
Σχήμα 23: Παράδειγμα κάλυψης Γης (πηγή:Cropscape)	52
Σχήμα 24: Καρπός βαμβάκι (πηγή:Cropscape)	53
Σχήμα 25: Καρπός καλαμπόκι (πηγή:Cropscape)	53
Σχήμα 26: Νεφοκάλυψη από λήψη Sentinel-2. (πηγή:USGS)	55
Σχήμα 27: Αρχείο-μάσκα από Fmask 4.0 σε εικόνα Sentinel-2.	55
Σχήμα 28: Παραστάσεις-ταυτότητες καρπών με τον δείκτη NDVI.	58
Σχήμα 29: Μορφολογικό άνοιγμα ακολουθολυμένο από μορφολογικό κλείσιμο. (πηγή:Udacity)	59
Σχήμα 30: Αρχική εικόνα με εσφαλμένα εικονοστοιχεία.	59
Σχήμα 31: Εικόνα μετά την μορφολογική επεξεργασία.	60
Σχήμα 32: Υποπεριοχή 1 - MLP - F1 Score ανά μέθοδο συμπλήρωσης κενών.	62
Σχήμα 33: Υποπεριοχή 1 - RF - F1 Score ανά μέθοδο συμπλήρωσης κενών.	62
Σχήμα 34: Υποπεριοχή 2 - MLP - F1 Score ανά μέθοδο συμπλήρωσης κενών.	63
Σχήμα 35: Υποπεριοχή 2 - RF - F1 Score ανά μέθοδο συμπλήρωσης κενών.	63
Σχήμα 36: Υποπεριοχή 3 - MLP - F1 Score ανά μέθοδο συμπλήρωσης κενών.	64
Σχήμα 37: Υποπεριοχή 3 - RF - F1 Score ανά μέθοδο συμπλήρωσης κενών.	64
Σχήμα 38: Περιοχή 1 - MLP - F1 Score ανά μέθοδο συμπλήρωσης κενών.	65
Σχήμα 39: Περιοχή 1 - MLP - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.	65
Σχήμα 40: Περιοχή 1 - MLP - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.	66

Σχήμα 41: Περιοχή 1 - MLP - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.	66
Σχήμα 42: Περιοχή 1 - RF - F1 Score ανά μέθοδο συμπλήρωσης κενών.	67
Σχήμα 43: Περιοχή 1 - RF - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.	67
Σχήμα 44: Περιοχή 1 - RF - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.	68
Σχήμα 45: Περιοχή 1 - RF - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.	68
Σχήμα 46: Περιοχή 1 - SVM - F1 Score ανά μέθοδο συμπλήρωσης κενών.	69
Σχήμα 47: Περιοχή 1 - SVM - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.	69
Σχήμα 48: Περιοχή 1 - SVM - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.	70
Σχήμα 49: Περιοχή 1 - SVM - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.	70
Σχήμα 50: Περιοχή 2 - MLP - F1 Score ανά μέθοδο συμπλήρωσης κενών.	71
Σχήμα 51: Περιοχή 2 - MLP - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.	71
Σχήμα 52: Περιοχή 2 - MLP - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.	72
Σχήμα 53: Περιοχή 2 - MLP - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.	72
Σχήμα 54: Περιοχή 2 - RF - F1 Score ανά μέθοδο συμπλήρωσης κενών.	73
Σχήμα 55: Περιοχή 2 - RF - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.	73
Σχήμα 56: Περιοχή 2 - RF - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.	74
Σχήμα 57: Περιοχή 2 - RF - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.	74
Σχήμα 58: Περιοχή 2 - SVM - F1 Score ανά μέθοδο συμπλήρωσης κενών.	75
Σχήμα 59: Περιοχή 2 - SVM - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.	75
Σχήμα 60: Περιοχή 2 - SVM - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.	76
Σχήμα 61: Περιοχή 2 - SVM - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.	76
Σχήμα 62: Περιοχή 3 - MLP - F1 Score ανά μέθοδο συμπλήρωσης κενών.	77
Σχήμα 63: Περιοχή 3 - MLP - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.	77
Σχήμα 64: Περιοχή 3 - MLP - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.	78
Σχήμα 65: Περιοχή 3 - MLP - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.	78
Σχήμα 66: Περιοχή 3 - RF - F1 Score ανά μέθοδο συμπλήρωσης κενών.	79
Σχήμα 67: Περιοχή 3 - RF - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.	79
Σχήμα 68: Περιοχή 3 - RF - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.	80
Σχήμα 69: Περιοχή 3 - RF - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.	80

Σχήμα 70: Περιοχή 3 - SVM - F1 Score ανά μέθοδο συμπλήρωσης κενών.	81
Σχήμα 71: Περιοχή 3 - SVM - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.	81
Σχήμα 72: Περιοχή 3 - SVM - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.	82
Σχήμα 73: Περιοχή 3 - SVM - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.	82
Σχήμα 74: Περιοχή 1 - Σύγκριση Καλύτερων αποτελεσμάτων για τις μεθόδους Εικονοστοιχείων-Αγροτεμαχίων.	83
Σχήμα 75: Περιοχή 2 - Σύγκριση Καλύτερων αποτελεσμάτων για τις μεθόδους Εικονοστοιχείων-Αγροτεμαχίων.	83
Σχήμα 76: Περιοχή 3 - Σύγκριση Καλύτερων αποτελεσμάτων για τις μεθόδους Εικονοστοιχείων-Αγροτεμαχίων.	84

Κατάλογος πινάκων

Πίνακας 1: Ζώνες Ηλεκτρομαγνητικού Φάσματος.	37
Πίνακας 2: Sentinel-2: Φασματικά κανάλια και ανάλυση εικόνων. (πηγή:researchgate) . . .	43
Πίνακας 3: Landsat8: Φασματικά κανάλια και ανάλυση εικόνων. (πηγή:usgs.gov)	45
Πίνακας 4: Χαρακτηριστικές τιμές NDVI (πηγή:JNRD)	46
Πίνακας 5: Συντεταγμένες σε δεκαδική μορφή για τις υπό εξέταση περιοχές.	49
Πίνακας 6: Συντεταγμένες σε δεκαδική μορφή για τις υπό εξέταση περιοχές.	49
Πίνακας 7: Ημερομηνίες χρονοσειρών για κάθε περιοχή.	51
Πίνακας 8: Μέγεθος εικόνων και αριθμός εικονοστοιχείων.	52
Πίνακας 9: Εξεταζόμενοι καρποί ανά περιοχή και ο αριθμός των εικονοστοιχείων που τους αντιστοιχούν	54
Πίνακας 10: Εξεταζόμενοι καρποί ανά περιοχή και ο αριθμός των αντίστοιχων αγροτεμαχίων	60

Κεφάλαιο 1

Εισαγωγή

1.1 Κίνητρο

Από όταν ο άνθρωπος άρχισε να ιδρύει τους πρώτους μόνιμους οικισμούς στην Νεολιθική εποχή η γεωργία αποτέλεσε την βασική πηγή τροφής για τον συνεχώς αυξανόμενο ανθρώπινο πληθυσμό. Σύμφωνα με τη Διεθνή Οργάνωση Τροφίμων και Γεωργίας [1] το 90% του παγκόσμιου πληθυσμού δεν θα μπορούσε να συντηρηθεί χωρίς τα παραγόμενα αγροτικά προϊόντα από τους κλάδους της γεωργίας, της κτηνοτροφίας και της αλιείας, με βασικότερο από αυτούς τη γεωργία [2]. Η παραγωγή τροφής, όμως, έρχεται αντιμέτωπη με επίκαιρα θέματα όπως ο υπερπληθυσμός [3] και η κλιματική αλλαγή [4]. Με την αύξηση του πληθυσμού αυξάνεται και η ανάγκη για μεγαλύτερη παραγωγή τροφίμων, η οποία μπορεί να επιτευχθεί με πιο σύγχρονους τρόπους παραγωγής και φροντίδας των καρπών αλλά και με την αύξηση της καλλιεργήσιμης γης. Το μεγαλύτερο μέρος της αρόσιμης γης ήδη χρησιμοποιείται για καλλιέργειες και η εύρεση επιπλέον περιοχών συνεπάγεται την αποψίλωση δασικών εκτάσεων και άλλων φυσικών περιοχών με αρνητικές συνέπειες για το περιβάλλον. Σύμφωνα με την Διεθνή Ένωση Προστασίας της Φύσης από το 1960 έχουν αποψιλωθεί περισσότερα από τα μισά τροπικά δάση του πλανήτη, ενώ σήμερα κάθε δευτερόλεπτο περισσότερο από ένα εκτάριο τροπικού δάσους καταστρέφεται ή υποβαθμίζεται σε μεγάλο βαθμό [5]. Δυστυχώς, όχι μόνο δεν είναι εύκολα εφικτή και βιώσιμη η επέκταση των καλλιεργήσιμων εκτάσεων αλλά, επιπλέον, η κλιματική αλλαγή και η μόλυνση του εδάφους σταδιακά μειώνουν τον αριθμό των ήδη υπάρχουσών, καθώς παρατηρείται σταδιακή ερημοποίηση περιοχών που μέχρι πρότινος χρησιμοποιούνταν για γεωργικούς σκοπούς [6]. Επιπρόσθετα, η αύξηση της θερμοκρασίας αλλάζει την καταλληλότητα μιας περιοχής για καλλιέργεια συγκεκριμένων ειδών καρπών και οδηγεί σε μείωση της παραγόμενης σοδειάς, ένα φαινόμενο το οποίο εξετάζει ο Chuang Zhao για τους 4 επικρατέστερους καρπούς στη γεωργία (σιτάρι, ρύζι, καλαμπόκι, σόγια) [7]. Τα προαναφερθέντα καθιστούν απαραίτητη την συνεχή και εκτενή παρακολούθηση και καταγραφή σε παγκόσμιο επίπεδο των καλλιεργούμενων καρπών, ώστε να διευκολύνεται η διαχείριση της παραγωγής τροφής, η λήψη αποφάσεων και ο καθορισμός μελλοντικών στρατηγικών.

1.2 Οργάνωση του Τόμου

Η παρούσα διπλωματική εργασία χωρίζεται σε 4 κεφάλαια. Στο κεφάλαιο 2 παρουσιάζεται το θεωρητικό υπόβαθρο στην μηχανική μάθηση και τους αλγορίθμους που χρησιμοποιήθηκαν κατά την υλοποίηση αυτής της διπλωματικής. Στο κεφάλαιο 3 παρουσιάζονται έννοιες της δορυφορικής τηλεσκόπησης και των δορυφορικών δεδομένων. Τέλος, στο κεφάλαιο 4 παρουσιάζονται η υλοποίηση που πραγματοποιήθηκε, καταγράφονται τα πειραματικά αποτελέσματα, αναφέρονται τα συμπεράσματα της διπλωματικής, καθώς και προτάσεις μελλοντικών εργασιών επί του θέματος.

Κεφάλαιο 2

Μηχανική Μάθηση

2.1 Τι είναι η Μηχανική Μάθηση

Η Μηχανική Μάθηση (Machine Learning) αποτελεί υποκλάδο της Τεχνητής Νοημοσύνης (Artificial Intelligence), που ασχολείται με την κατασκευή μοντέλων που υλοποιούν συγκεκριμένους αλγόριθμους και χρησιμοποιούν πειραματικά δεδομένα με σκοπό την εξαγωγή χρήσιμων προβλέψεων ή συμπερασμάτων. Τα μοντέλα αυτά πρέπει να έχουν την ικανότητα να βελτιώνουν την απόδοσή τους όταν λαμβάνουν επιπλέον δεδομένα χωρίς να χρειάζεται να προγραμματιστούν από την αρχή. Ο Mitchell [8] έχει δώσει τον εξής ορισμό για την μηχανική μάθηση:

“Ένα πρόγραμμα υπολογιστή λέμε ότι μαθαίνει από την εμπειρία E ως προς κάποια κλάση εργασιών T και μέτρο απόδοσης P , αν η απόδοσή του σε εργασίες από το T , όπως μετριέται από το P , βελτιώνεται μέσω της εμπειρίας E .”

Η διαδικασία εκπαίδευσης η οποία ακολουθείται είναι η τροφοδότηση του μοντέλου με δεδομένα, συνήθως αριθμητικά. Έπειτα, δημιουργούνται διανύσματα από αυτά τα δεδομένα, τα λεγόμενα Διανύσματα Χαρακτηριστικών (Feature Vectors) με τα οποία τροφοδοτούνται κατάλληλοι αλγόριθμοι. Τέλος, χρησιμοποιούνται μετρικές για τον υπολογισμό της αξιοπιστίας του κάθε μοντέλου.

Οι αλγόριθμοι μηχανικής μάθησης χωρίζονται σε 3 μεγάλες κατηγορίες:

- Επιβλεπόμενη Μάθηση (Supervised Learning)
- Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning)
- Ενισχυτική Μάθηση (Reinforcement Learning)

2.2 Κατηγορίες Μηχανικής Μάθησης

Ο διαχωρισμός των κατηγοριών της μηχανικής μάθησης προκύπτει από τον τρόπο με τον οποίο αλληλεπιδρά το σύστημα με το περιβάλλον του κατά την εκπαίδευση, δηλαδή τον τρόπο με τον οποίο δίνεται ανάδραση στην διάρκεια της εκμάθησης.

2.2.1 Επιβλεπόμενη Μάθηση

Στην Επιβλεπόμενη Μάθηση ο σκοπός είναι η προσέγγιση μιας συνάρτησης η οποία συνδέει την είσοδο με την έξοδο χρησιμοποιώντας υπάρχοντα ζεύγη τιμών εισόδου-εξόδου (δεδομένα-ετικέτες). Το σύνολο αυτών των ζευγών ονομάζεται σύνολο εκπαίδευσης και η διαδικασία υπολογισμού μιας τέτοιας συνάρτησης από το παραπάνω σύνολο λέγεται εκπαίδευση. Ο τελικός στόχος της μάθησης με επίβλεψη είναι ο υπολογισμός μιας συνάρτησης που γενικεύει επαρκώς στα δεδομένα εισόδου, ώστε να μπορεί να αντιστοιχίσει σε σωστές εξόδους νέα δεδομένα εισόδου τα οποία δεν είχε χρησιμοποιήσει κατά την εκπαίδευση.

2.2.2 Μη Επιβλεπόμενη Μάθηση

Σε αντίθεση με την προηγούμενη κατηγορία μηχανικής μάθησης, η μη επιβλεπόμενη μάθηση δεν χρησιμοποιεί ζεύγη τιμών εισόδου-εξόδου. Ο στόχος της είναι να αναγνωριστούν μοτίβα στα δεδομένα εισόδου χωρίς την ανατροφοδότηση από τιμές εξόδου. Ένα χαρακτηριστικό παράδειγμα μη επιβλεπόμενης τεχνικής είναι το πρόβλημα της ομαδοποίησης (clustering). Η μέθοδος αυτή στοχεύει στην ομαδοποίηση των δεδομένων εισόδου δημιουργώντας ομάδες των οποίων τα μέλη είναι παρόμοια το ένα με το άλλο, αλλά διαφέρουν σημαντικά από τα μέλη των άλλων ομάδων.

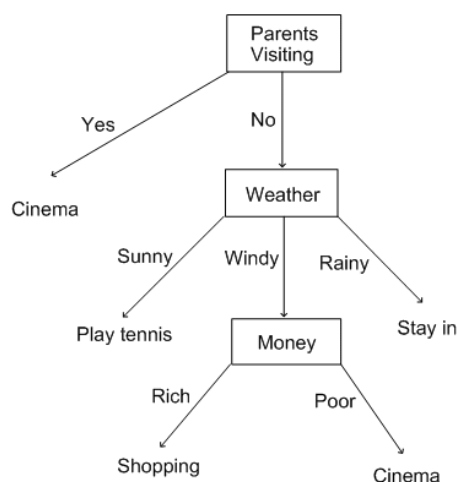
2.2.3 Ενισχυτική Μάθηση

Η ενισχυτική μάθηση επιτυγχάνει την εκπαίδευση με την χρήση "επιβραβεύσεων" και "τιμωριών" από το περιβάλλον και τις αλληλεπιδράσεις του μοντέλου με αυτό. Οι επιλογές που λήφθηκαν για να οδηγήσουν σε ένα αποτέλεσμα κρίνονται αν είχαν θετική ή αρνητική συμβολή στο αποτέλεσμα αυτό. Με αυτόν τον τρόπο το μοντέλο μπορεί να επιλέξει αν θα ξανακάνει τις ίδιες επιλογές ή θα ακολουθήσει ένα διαφορετικό μονοπάτι δράσεων, το οποίο μπορεί να διαφέρει σε μία ή και περισσότερες επιλογές.

2.3 Αλγόριθμοι Μηχανικής Μάθησης

2.3.1 Δέντρα Αποφάσεων - Decision Trees

Τα Δέντρα Αποφάσεων ανήκουν στους αλγόριθμους Επιβλεπόμενης Μηχανικής Μάθησης. Είναι ευρέως διαδεδομένα σε τομείς που απαιτούν ταξινόμηση όπως π.χ. η ιατρική διάγνωση περιστατικών, η αναγνώριση προτύπων σε εικόνες αλλά και η ανάλυση αποφάσεων για την τελική επιλογή στρατηγικής που να επιτυγχάνει κάποιο στόχο. Ο αλγόριθμος οδηγεί στη δημιουργία μιας δενδροειδούς μορφής που συγκεκριμένα μοιάζει με ανάποδο δέντρο, στην οποία τα φύλλα της αποτελούν κατηγορίες ταξινόμησης (classes), είναι δηλαδή η έξοδος του αλγόριθμου. Η μορφή αυτή μπορεί να αναγνωστεί και ως ένα σύνολο κανόνων που καλούνται κανόνες ταξινόμησης (classification rules). Κάθε κόμβος του δένδρου αποτελεί μία συνθήκη ταξινόμησης, η οποία ανάλογα την ορθότητα της απορρίπτει έναν αριθμό κατηγοριών ταξινόμησης. Εφόσον έχει σχηματίσει το δέντρο, η πρόβλεψη της κατηγορίας ενός δείγματος μπορεί να ληφθεί πραγματοποιώντας μία απλή διάσχιση στο δέντρο, όπου η τιμή του φύλλου στο οποίο θα καταλήξει η διάσχιση αποτελεί και την τελική πρόβλεψη. Για να γίνουν πιο κατανοητά τα παραπάνω ακολουθεί ένα απλό παράδειγμα καθημερινότητας Δέντρου Αποφάσεων που δείχνει την σκέψη για επιλογή μιας δραστηριότητας από ένα άτομο.



Σχήμα 1: Παράδειγμα Δέντρου Απόφασης

Έστω πως η είσοδος που έχουμε είναι η ακόλουθη:

(*Parents Visiting = No, Weather = Windy, Money = Poor*)

Το αποτέλεσμα που θα παράξει το δέντρο της εικόνας 1 είναι η επιλογή Cinema. Σε άλλες υλοποιήσεις δέντρων θα μπορούσαν να υπάρχουν μόνο δύο κατηγορίες ταξινόμησης, αρνητική και θετική, σε αντίθεση με το δοθέν παράδειγμα όπου έχουμε 5 κατηγορίες. Όπως είναι λογικό σε ένα υπολογιστικό Δέντρο Αποφάσεων δεν θα υπάρχουν λογικές ερωτήσεις αλλά συγκρίσεις μεταξύ αριθμητικών διανυσμάτων.

Θετικά σημεία του αλγόριθμου των Δέντρων Αποφάσεων είναι:

- Μπορούν εύκολα να παράξουν κατανοητούς κανόνες.
- Να υποδείξουν ποιες από τις μεταβλητές εισόδου οι οποίες έχουν το μεγαλύτερο βάρος για τελική πρόβλεψη.
- Δεν επηρεάζονται αρνητικά από προβλήματα πολλών κατηγοριών ταξινόμησης.
- Μπορούν να συνδυαστούν εύκολα με άλλους αλγόριθμους.

Αρνητικά σημεία του αλγόριθμου είναι:

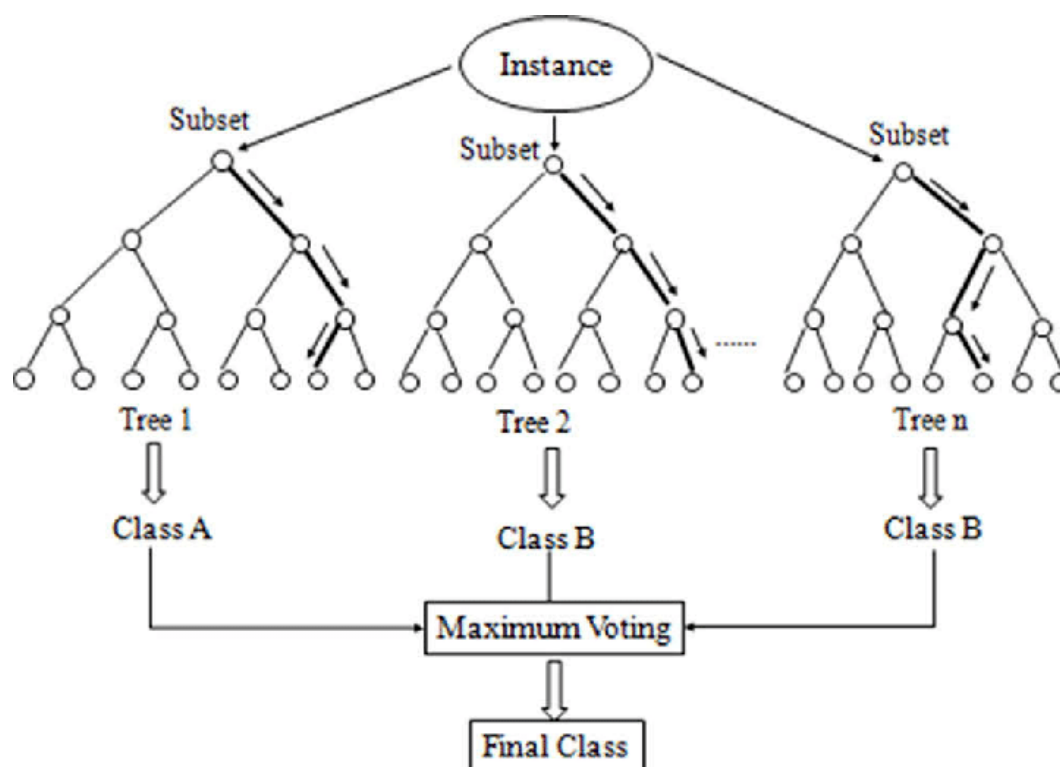
- Βρίσκουν δυσκολίες όταν το πρόβλημα απαιτεί στην έξοδο συνεχείς τιμές εντός και όχι ταξινόμηση σε κατηγορίες.
- Διακρίνονται από αστάθεια καθώς αλλαγές στα δεδομένα μπορεί να οδηγήσουν σε μεγάλες αλλαγές στην δομή τους.
- Χρειάζονται αρκετά μεγάλο όγκο δεδομένων στην εκπαίδευσή τους οδηγώντας σε μεγάλες απαιτήσεις πόρων και χρονοβόρες εκπαιδεύσεις.

Τα Δέντρα Αποφάσεων, παρά τα αρνητικά τους χαρακτηριστικά, αποτελούν μία από τις πιο διαδεδομένες μεθόδους στην Μηχανική Μάθηση σήμερα.

2.3.2 Τυχαία Δάση - Random Forest

Μία πολύ συνηθισμένη τεχνική στην Επιβλεπόμενη Μάθηση είναι η εκπαίδευση πολλαπλών ταξινομητών, ανεξάρτητα μεταξύ τους, συνδυάζοντας τα αποτελέσματά τους στο τέλος για την πρόβλεψη της τελικής τιμής (Ensemble). Αυτή η τεχνική επιφέρει καλύτερα αποτελέσματα από την χρήση ενός μόνο ταξινομητή, καθώς λόγω ανεξαρτησίας ο κάθε ταξινομητής μπορεί να επικεντρώνεται σε διαφορετικές παραμέτρους και να αδιαφορεί για άλλες, που αντίστοιχοι ταξινομητές θα αξιοποιούσαν. Αυτό έχει ως αποτέλεσμα κάθε ταξινομητής να εκπαιδεύεται ξεχωριστά και στο τέλος να συνδυάζονται όλες παραγόμενες τιμές, χρησιμοποιώντας μία συνάρτηση συσχέτισης, η οποία με είσοδο όλων των τιμών επιστρέφει την τελική πρόβλεψη. Παραδείγματα τέτοιων συναρτήσεων είναι η Πλειοψηφία, ο Μέσος Όρος, η Τυπική Απόκλιση κ.α. Η επιλογή αυτής της συνάρτησης επαφίεται στο είδος και τα χαρακτηριστικά του προβλήματος που αντιμετωπίζεται κάθε φορά.

Τα Τυχαία Δάση ανήκουν στην προαναφερθείσα τεχνική και συγκεκριμένα αποτελούν μια κατηγορία Συνδυαστικής Ταξινόμησης. Συγκεκριμένα, αποτελούνται από ένα πλήθος Δέντρων Αποφάσεων που ονομάζονται Ταξινομητές Βάσης, οι οποίοι είναι παράλληλοι και ανεξάρτητοι μεταξύ τους. Στο σχήμα 2 φαίνεται η μορφή ενός ταξινομητή Τυχαίων Δέντρων με συνάρτηση συσχέτισης την πλειοψηφία.



Σχήμα 2: Παράδειγμα Τυχαίου Δάσους

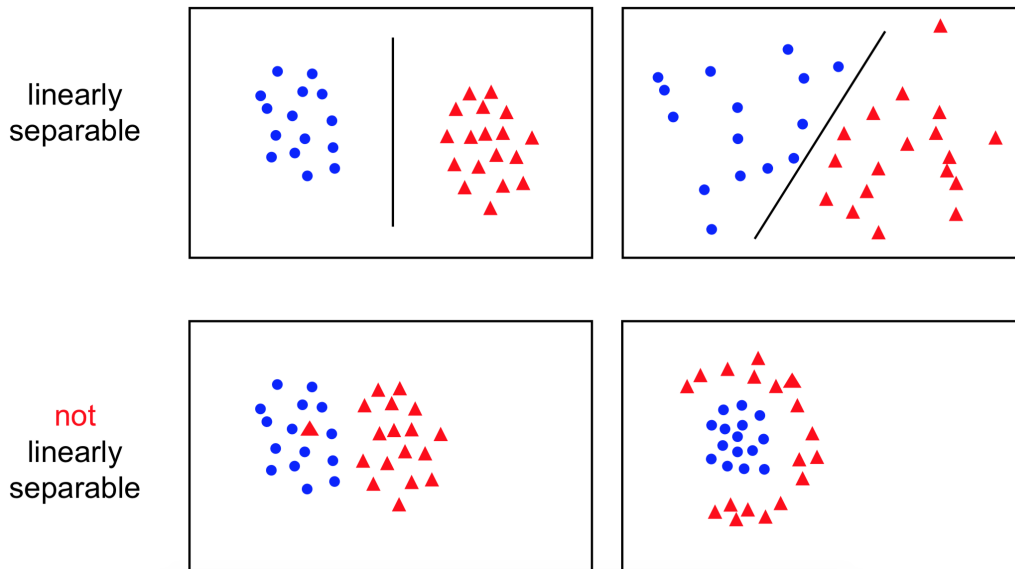
Τον αλγόριθμο Τυχαίων Δασών δημιούργησε πρώτος ο Tin Kam Ho [9] το 1995, χρησιμοποιώντας την τυχαία επιλογή υποσυνόλου των χαρακτηριστικών των δεδομένων για κάθε ταξινομητή βάσης, με στόχο της μείωση της συσχέτισης ανάμεσά τους. Δηλαδή, σε αυτήν την περίπτωση κάθε ταξινομητής βάσης χρησιμοποιεί όλα τα δεδομένα εκπαίδευσης αλλά με ένα υποσύνολο των χαρακτηριστικών που έχουν.

Μερικά χρόνια αργότερα ο Breiman [10] βελτίωσε περαιτέρω τον αλγόριθμο εισάγοντας την τεχνική bagging [11]. Συγκεκριμένα, η τεχνική αυτή ορίζει για κάθε ταξινομητή βάσης ένα υποσύνολο των δεδομένων εκπαίδευσης που θα χρησιμοποιήσει κατά την εκπαίδευσή του. Η επιλογή αυτού του υποσυνόλου γίνεται με τη χρήση ομοιόμορφης δειγματοληψίας με αντικατάσταση. Αυτή η αλλαγή στον αλγόριθμο από τον Breiman οδήγησε σε ακόμα καλύτερα αποτελέσματα μειώνοντας το overfitting και τη συσχέτιση μεταξύ των ταξινομητών. Ο τελικός αυτός αλγόριθμος που χρησιμοποιείται κατά κόρον σήμερα ονομάζεται Δέντρα Αποφάσεων με ελεγχόμενη διακύμανση.

2.3.3 Μηχανές Διανυσμάτων Υποστήριξης - SVM


Ο αλγόριθμος των Μηχανών Διανυσμάτων Υποστήριξης είναι ένας από τους βασικότερους αλγόριθμους της επιβλεπόμενης μηχανικής μάθησης. Βασίζεται στην χωρική αναπαράσταση των δεδομένων εισόδου και δημιουργώντας ένα υπερεπίπεδο τα διαχωρίζει στις κλάσεις εξόδου. Το υπερεπίπεδο αυτό πρέπει να διαχωρίζει όσο δυνατόν περισσότερο τις κλάσεις εξόδου και ταυτόχρονα να μεγιστοποιεί την απόσταση των δεδομένων εισόδου από αυτό. Η μορφή των δεδομένων μπορεί να τα κατατάσσει στην κατηγορία των γραμμικά διαχωρίσιμων ή μη γραμμικά διαχωρίσιμων δεδομένων.

Στην εικόνα 3 φαίνεται η διαφορά ανάμεσα στις δύο κατηγορίες. Στα δύο πάνω σχήματα οι κλάσεις είναι γραμμικά διαχωρίσιμες και οι Μηχανές Διανυσμάτων Υποστήριξης μπορούν να διαχωρίσουν τα δεδομένα. Στα δύο κάτω σχήματα, που οι κλάσεις είναι μη γραμμικά διαχωρίσιμες, απαιτείται η χρήση Μη Γραμμικών Μηχανών Διανυσμάτων Υποστήριξης, οι οποίες χρησιμοποιώντας τεχνικές μετασχηματισμού των συντεταγμένων των δεδομένων σε χώρο μεγαλύτερης διαστατικότητας μπορούν να υπολογίσουν υπερεπίπεδα που να διαχωρίζουν τα δεδομένα.



Σχήμα 3: Παράδειγμα Γραμμικών και Μη διαχωρίσιμων δεδομένων

Όπως αναφέρθηκε και προηγουμένως, το υπερεπίπεδο πρέπει να διαχωρίζει τα δεδομένα αλλά και να αφήνει όσο το δυνατόν μεγαλύτερο περιθώριο ανάμεσα στα στοιχεία των κλάσεων. Στην εικόνα 4, εφόσον έχουμε δύο διαστάσεις το υπερεπίπεδο θα είναι ευθεία γραμμή. Στο αριστερό σχήμα μπορούμε να δούμε πως η μαύρη γραμμή είναι το υπερεπίπεδο που διαχωρίζει βέλτιστα τις κλάσεις. Η πορτοκαλί γραμμή δεν κάνει ορθό διαχωρισμό, ενώ η μπλε γραμμή διαχωρίζει σωστά τις κλάσεις αλλά δεν αφήνει το μέγιστο περιθώριο ανάμεσα τους. Για να γίνει αυτή η επιλογή ο αλγόριθμος εξετάζει όλα τα δεδομένα εισόδου και επιλέγει τα οριακά διανύσματα δεδομένων ως διανύσματα υποστήριξης για να κατασκευάσει το υπερεπίπεδο. Στην εικόνα 4 στο δεξιό σχήμα φαίνεται ποια διανύσματα έχουν επιλεγεί για τον καθορισμό του υπερεπιπέδου.



Σχήμα 4: Παράδειγμα Υπερεπιπέδου και Περιθωρίου

Η μαθηματική έκφραση για το υπερεπίπεδο είναι η παρακάτω:

$$\mathbf{w}^T \cdot \mathbf{x} + b = 0 \quad (2.1)$$

η οποία ικανοποιεί τις παρακάτω συνθήκες:

$$\mathbf{w}^T \cdot \mathbf{x} + b = \begin{cases} 1, & \text{αν } \mathbf{x} \in \text{κλάση 1} \\ -1, & \text{αν } \mathbf{x} \in \text{κλάση 2} \end{cases} \quad (2.2)$$

όπου \mathbf{w} διάνυσμα βάρων, το οποίο αντιστοιχεί στο διάνυσμα του υπερεπιπέδου, \mathbf{x} ένα διάνυσμα εισόδου από τα δεδομένα, b μια πόλωση.

Στην περίπτωση που οι κλάσεις δεν είναι γραμμικά διαχωρίσιμες τα δεδομένα υπόκεινται κάποιους μετασχηματισμούς μεταφοράς σε χώρο μεγαλύτερης διαστατικότητας. Οι μετασχηματισμοί αυτοί αποκαλούνται πυρήνες και μερικοί από τους πιο γνωστούς είναι οι εξής:

- πολυωνυμικός πυρήνας:

$$k(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i \cdot \mathbf{x}_j + c)^d$$

- πυρήνας ακτινικών συναρτήσεων βάσης:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (\gamma > 0)$$

για $\gamma = \frac{1}{2\sigma^2}$ έχουμε τον πυρήνα Gauss ακτινικής βάσης

- πυρήνας Laplace ακτινικών συναρτήσεων βάσης:


$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|}{\sigma}\right)$$

Το κυριότερο μειονέκτημα των Μηχανών Διανυσμάτων Υποστήριξης είναι το υπολογιστικό τους κόστος όσο αυξάνεται ο αριθμός των κλάσεων προς ταξινόμηση. Για n κλάσεις απαιτείται ο υπολογισμός $n - 1$ υπερεπιπέδων, κάτι το οποίο μπορεί να αυξήσει πολύ την απαίτηση για υπολογιστικούς πόρους και να μετατρέψει την διαδικασία υπολογισμού σε υπερβολικά χρονοβόρα.

2.4 Τεχνητά Νευρωνικά Δίκτυα

2.4.1 Τεχνητός Νευρώνας

Τα Τεχνητά Νευρωνικά Δίκτυα είναι ένας αλγόριθμος επιβλεπόμενης μηχανικής μάθησης που έχει ως στόχο να προσομοιάσει την λειτουργία του ανθρώπινου εγκεφάλου. Τα δομικά στοιχεία τους είναι οι τεχνητοί νευρώνες, οι οποίοι έχουν δημιουργηθεί με βάση τον ανθρώπινο νευρώνα. Στην εικόνα 5 φαίνεται η αρχιτεκτονική ενός τεχνητού νευρώνα.



Σχήμα 5: Αρχιτεκτονική Τεχνητού Νευρώνα (πηγή:towardsdatascience.com)

Τα x_i αποτελούν τις εισόδους του νευρώνα, οι οποίες πολλαπλασιάζονται με τα βάρη w_i και αθροίζονται μαζί με μία πόλωση w_0 (πολλές φορές συναντάται και με το σύμβολο b). Το τελικό άθροισμα τροφοδοτείται σε μια συνάρτηση ενεργοποίησης f και ανάλογα την τιμή του αθροίσματος η έξοδος είναι 0 ή 1 , ή όπως αλλιώς λέγεται ο νευρώνας απενεργοποιείται ή ενεργοποιείται.

Η ολοκληρωμένη μαθηματική έκφραση είναι η εξής:

$$y = f\left(\sum_{i=1}^n x_i w_i + b\right) \quad (2.3)$$

Στην εικόνα 5 η συνάρτηση ενεργοποίησης είναι η απλή βηματική. Υπάρχουν αρκετές ακόμα συναρτήσεις, η επιλογή των οποίων εξαρτάται από την φύση του προβλήματος και το σχεδιαστή του νευρωνικού δικτύου. Μερικές συχνά χρησιμοποιούμενες συναρτήσεις περιγράφονται στην ενότητα 2.4.3.

Δεδομένης της δυαδικής εξόδου του τεχνητού νευρώνα είναι προφανές πως έχει την ικανότητα, προσαρμόζοντας κατάλληλα τα βάρη w_i να ταξινομεί τα δεδομένα εισόδου σε δυο κλάσεις αν αυτές είναι γραμμικά διαχωρίσιμες [12].

Ο προαναφερθής τεχνητός νευρώνας ονομάζεται Perceptron και ο Rosenblatt το 1958 ήταν ο πρώτος που τον πρότεινε [13]. Ο συνδυασμός πολλών Perceptrons μπορεί να δημιουργήσει ένα επίπεδο απλών νευρώνων, το οποίο λειτουργεί τόσο ως εισόδος όσο και ως έξοδος του δικτύου [14], το επονομαζόμενο Τεχνητό Νευρωνικό Δίκτυο ενός επιπέδου. Κάθε νευρώνας σε αυτό το δίκτυο είναι ανεξάρτητος από τους υπόλοιπους, άρα και η εκπαίδευση του γίνεται ανεξάρτητα από τους υπόλοιπους νευρώνες. Ωστόσο, οι Minsky-Papert το 1969 απέδειξαν ότι τα Τεχνητά Νευρωνικά Δίκτυα ενός επιπέδου δεν είναι ικανά να λύσουν μη γραμμικά προβλήματα [15], κάτι που μπορούν να καταφέρουν τα Πολυεπίπεδα Νευρωνικά Δίκτυα.

2.4.2 Πολυεπίπεδα Νευρωνικά Δίκτυα - Multilayer Perceptrons


Για την επίλυση πιο σύνθετων προβλημάτων με μεγάλη πολυπλοκότητα, είναι απαραίτητος ο συνδυασμός πολλών διαφορετικών νευρώνων μεταξύ τους, δημιουργώντας πολυεπίπεδες αρχιτεκτονικές νευρώνων Perceptrons και καλούνται Multi-Layer Perceptrons (MLPs). Στα MLP οι νευρώνες είναι οργανωμένοι κατά επίπεδα τα οποία χωρίζονται σε 3 κατηγορίες:

- Επίπεδο εισόδου (input layer)
- Κρυφά επίπεδα (hidden layer)
- Επίπεδο εξόδου (output layer)

Στην εικόνα 6 οι νευρώνες εισόδου σημειώνονται με κίτρινο χρώμα, οι κρυμμένοι νευρώνες με μπλε και οι νευρώνες εξόδου με πράσινο. Ο κάθε τεχνητός νευρώνας του δικτύου λειτουργεί όπως αναφέρθηκε στην ενότητα 2.4.1.

Ένα χαρακτηριστικό διαχωρισμού των Τεχνητών Νευρωνικών Δικτύων είναι ο τρόπος σύνδεσης μεταξύ των νευρώνων όλων των επιπέδων. Οι κατηγορίες που προκύπτουν είναι:

- **Πλήρως Συνδεδεμένα (Fully Connected):** δίκτυα στα οποία κάθε νευρώνας ενός επιπέδου συνδέεται με όλους τους νευρώνες του επόμενου επιπέδου.
- **Μερικώς Συνδεδεμένα (Partially Connected):** δίκτυα στα οποία σε κάθε επίπεδο υπάρχουν νευρώνες που δε συνδέονται με όλους τους νευρώνες του επόμενου επιπέδου.
- **Εμπρόσθια Τροφοδότηση (Feedforward):** δίκτυα στα οποία οι συνδέσεις των νευρώνων δεν δημιουργούν κύκλους συνδέσεων. Δηλαδή, κανένας νευρώνας δεν προωθεί την έξοδο του σε νευρώνες προηγούμενων επιπέδων.
- **Με Ανατροφοδότηση (Feedback):** δίκτυα που αντίθετα με την προηγούμενη κατηγορία, έχουν νευρώνες που προωθούν τις εξόδους τους σε νευρώνες προηγούμενου επιπέδου.




Σχήμα 6: Multi-Layer Perceptron (πηγή:deepai.org)

2.4.3 Συναρτήσεις ενεργοποίησης - Activation Functions

Η Συνάρτηση Ενεργοποίησης είναι μια συνάρτηση η οποία παίρνει ως είσοδο την παραγόμενη από το άθροισμα του νευρώνα τιμή και παράγει μια τιμή εξόδου που θα προωθηθεί ως είσοδος στους επόμενους νευρώνες. Η χρησιμότητά της έγκειται στο γεγονός πως η τιμή του αθροίσματος σε ένα νευρώνα μπορεί να είναι οποιοσδήποτε αριθμός. Με την χρήση της συνάρτησης ενεργοποίησης μπορούμε να μεταφέρουμε την τιμή αυτή σε οποιοδήποτε διάστημα κρίνεται βολικότερο, ώστε να είναι εύκολη η ερμηνεία του αποτελέσματος. Ουσιαστικά αυτή η συνάρτηση λειτουργεί ως ένα φίλτρο στις παραγόμενες τιμές. Στη συνέχεια παρουσιάζονται μερικές από τις συνηθέστερες συναρτήσεις ενεργοποίησης.

- **Σιγμοειδής συνάρτηση:** Η συνάρτηση αυτή μετατρέπει την είσοδό της στο διάστημα $(0, 1)$ χωρίς να μπορούν να πάρουν ποτέ τις τιμές 0 και 1. Η κανονικοποίηση των τιμών σε αυτό το διάστημα οδηγεί στο να μην υπάρχουν αισθητές διαφορές των τιμών στην έξοδο της συνάρτησης, ένα φαινόμενο που ονομάζεται εξασθένιση κλίσης (Vanishing Gradient). Η γραφική παράσταση της συνάρτησης φαίνεται στο σχήμα 7,




Σχήμα 7: Σιγμοειδής Συνάρτηση (πηγή:wikipedia.org)

και ο μαθηματικός τύπος της είναι ο ακόλουθος:

$$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.4)$$

- **Συνάρτηση Υπερβολικής Εφαπτομένης:** Η συνάρτηση αυτή είναι παρόμοια με την σιγμοειδή με την διαφορά πως οι τιμές αντιστοιχίζονται στο διάστημα $(-1, 1)$.




Σχήμα 8: Συνάρτηση Υπερβολικής Εφαπτομένης (πηγή:oreilly.com)

Ο μαθηματικός τύπος της είναι ο ακόλουθος:

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.5)$$

- **Μονάδα Γραμμικής Ανόρθωσης (Rectified Linear Unit, ReLU):** Η συνάρτηση αυτή αποτελεί την πιο διαδεδομένη συνάρτηση ενεργοποίησης στις εφαρμογές των Νευρωνικών Δικτύων. Αποτελείται από ένα μέρος μηδενισμού των τιμών για τις αρνητικές εισόδους, και μια γραμμική συνάρτηση για τις θετικές εισόδους. Η συνάρτηση αυτή είναι ιδανική για προβλήματα τα οποία δεν περιλαμβάνουν μεγάλες τιμές εισόδου. Επίσης, δεν αντιμετωπίζει το πρόβλημα της Εξαφανιζόμενης Κλίσης που έχουν οι δυο προηγούμενες συναρτήσεις. Ένα αρνητικό της είναι η αδρανοποίηση όλων των νευρώνων που έχουν αρνητικές τιμές, κάτι το οποίο μπορεί να επηρεάζει σε μεγάλο βαθμό την λύση του προβλήματος, ανάλογα βέβαια με την φύση που έχει το ίδιο το πρόβλημα. Η γραφική της παράσταση είναι η εξής.



Σχήμα 9: Μονάδα Γραμμικής Ανόρθωσης (πηγή:researchgate.net)

Ο μαθηματικός τύπος είναι ο ακόλουθος:

$$f(x) = (0, \max) \quad (2.6)$$

2.4.4 Συναρτήσεις Κόστους - Cost Functions

Οι Συναρτήσεις Κόστους χρησιμοποιούνται με στόχο τον έλεγχο της επίδοσης των Τεχνητών Νευρωνικών Δικτύων. Ο έλεγχος γίνεται με δεδομένα τα δείγματα εισόδου και της αναμενόμενης τιμής εξόδου τους. Έτσι, είναι δυνατή η παρακολούθηση της βελτίωσης του δικτύου και η προσαρμογή του ώστε να ελαχιστοποιήσει τα λάθη τα οποία κάνει. Η σύγκριση πραγματοποιείται ανάμεσα από τις τιμές που προέβλεψε το μοντέλο και στις πραγματικές τιμές. Μερικές συναρτήσεις κόστους είναι οι παρακάτω.

- **Μέσο Τετραγωνικό Σφάλμα - Mean Squared Error (MSE):** Υπολογίζεται ο μέσος όρος των τετραγώνων των σφαλμάτων. Ο μαθηματικός τύπος είναι ο εξής:

$$J(\theta) = \frac{1}{n} \sum_{i=1}^n (Y_i - P_i)^2 \quad (2.7)$$

όπου Y_i οι πραγματικές τιμές και P_i οι προβλέψεις.

- **Μέσο Απόλυτο Σφάλμα - Mean Absolute Error (MAE):** Υπολογίζεται ο μέσος όρος της απόλυτης τιμής των σφαλμάτων. Ο μαθηματικός τύπος είναι ο εξής:

$$J(\theta) = \frac{1}{n} \sum_{i=1}^n |Y_i - P_i| \quad (2.8)$$

όπου Y_i οι πραγματικές τιμές και P_i οι προβλέψεις.

- **Cross Entropy Loss:** Είναι η συνηθέστερη συνάρτηση κόστους στα προβλήματα ταξινόμησης. Η λειτουργία της είναι η σύγκριση των πιθανοτικών κατανομών των προβλεπόμενων τιμών και των πραγματικών τιμών. Όσο περισσότερο αποκλίνουν οι δύο κατανομές τόσο μεγαλύτερη είναι η τιμή της, με αποτέλεσμα ο στόχος να είναι να λάβει όσο δυνατόν μικρότερες τιμές ώστε οι δύο κατανομές να ταυτιστούν. Χαρακτηριστικό αυτής της συνάρτησης είναι το γεγονός πως ορίζει μεγάλη ποινή σε προβλέψεις με μεγάλο βαθμό σιγουριάς (confident predictions) που όμως είναι λανθασμένες. Ο μαθηματικός τύπος είναι ο παρακάτω:

$$J(\theta) = H(p, q) = - \sum_{x \in X} p(x) \log(q(x)) \quad (2.9)$$

όπου p, q οι πιθανοτικές κατανομές των πραγματικών τιμών και των προβλεπόμενων τιμών αντίστοιχα.

- **SVM Loss (Hinge loss):** Συναντάται σε προβλήματα κατηγοριοποίησης και ο σκοπός της ορίζεται στο να είναι το άθροισμα των σωστών προβλέψεων μεγαλύτερο από το αντίστοιχο των λανθασμένων. Όπως φανερώνει και το όνομα της χρησιμοποιείται στις Μηχανές Διανυσμάτων Υποστήριξης. Χαρακτηριστικό της αποτελεί το γεγονός πως δεν είναι παραγωγίσιμη αλλά είναι πολύ εύκολη στον υπολογισμό της. Ο μαθηματικός τύπος είναι ο παρακάτω:

$$J(\theta) = \sum_{j \neq y_i} \max(0, s_j - s_{y_i} + 1) \quad (2.10)$$

Όπου θ το διάνυσμα των παραμέτρων του εκάστοτε δικτύου.

2.4.5 Αλγόριθμος Οπίσθιας Διάδοσης Σφάλματος - Backpropagation Algorithm

Ο αλγόριθμος αυτός είναι μέλος της κατηγορίας των αλγορίθμων Βελτιστοποίησης και είναι από τους πιο γνωστούς. Πρώτος τον πρότεινε ο Kelley το 1960 [16] και η εφαρμόζεται ευρέως στην Επιβλεπόμενη Μάθηση και στα Νευρωνικά Δίκτυα Εμπρόσθιας Τροφοδότησης.

Ο αλγόριθμος υλοποιεί μια μικρή τροποποίηση σε κάθε βάρους του δικτύου, λαμβάνοντας υπόψη το σφάλμα που προκύπτει για μία συγκεκριμένη είσοδο, την αντίστοιχη επιθυμητή έξοδο και την ανάκληση του δικτύου. Η εφαρμογή του γίνεται σε εποχές, δηλαδή διατρέχοντας με προκαθορισμένο τρόπο όλα τα δεδομένα εισόδου κάθε εποχή. Τα βάρη του δικτύου προσαρμόζονται ανάλογα με το πόσο μεγάλη συνεισφορά είχαν στο συνολικό σφάλμα του δικτύου. Η προσαρμογή αυτή γίνεται ακολουθώντας την αντίθετη κατεύθυνση από την ροή των δεδομένων, δηλαδή από το επίπεδο εξόδου προς το επίπεδο εισόδου.

Οι δύο βασικοί τρόποι παρουσίασης των δεδομένων στο δίκτυο είναι οι εξής:

- **Αυξητική εκπαίδευση - Incremental Training:** Σε αυτήν την περίπτωση τα δεδομένα εισόδου παρουσιάζονται ξεχωριστά στο δίκτυο και για κάθε ένα γίνεται η τροποποίηση των βαρών.
- **Μαζική εκπαίδευση - Batch Training:** Σε αυτήν την περίπτωση πρώτα παρουσιάζονται όλα τα δεδομένα εισόδου μια φορά, υπολογίζονται οι αλλαγές στα βάρη για την κάθε είσοδο και στο τέλος γίνεται η ενημέρωση των βαρών.

Το συνολικό σφάλμα για όλα τα παραδείγματα προκύπτει ως το άθροισμα των τετραγώνων των σφαλμάτων των νευρώνων εξόδου. Επίσης, ορίζεται και μια συνθήκη τερματισμού του αλγορίθμου, η οποία είναι είτε η πτώση του συνολικού σφάλματος κάτω από ένα καθορισμένο όριο είτε η συμπλήρωση ενός προκαθορισμένου αριθμού εποχών εκπαίδευσης στην αρχή της όλης διαδικασίας.

2.4.6 Αλγόριθμοι Βελτιστοποίησης - Optimization Algorithms

Οι Αλγόριθμοι Βελτιστοποίησης χρησιμοποιούνται με στόχο να μεγιστοποιήσουν ή να ελαχιστοποιήσουν μία συνάρτηση. Στην συγκεκριμένη περίπτωση η συνάρτηση αυτή είναι κάποια Συνάρτηση Κόστους, η οποία πρέπει να ελαχιστοποιηθεί. Στα Τεχνητά Νευρωνικά Δίκτυα τα βάρη του Κρυφού Στρώματος έχουν πολύ βασικό ρόλο στην τελική απόδοση, συνεπώς είναι απαραίτητο η συνεχής ανανέωσή τους έως ότου φτάσουμε σε επιθυμητό αποτέλεσμα. Για αυτόν τον σκοπό χρησιμοποιούνται οι αλγόριθμοι αυτής της κατηγορίας. Στη συνέχεια παρουσιάζεται η ευρέως χρησιμοποιούμενη τεχνική της Κατάβασης Κλίσης (Gradient Descent) και μερικές παραλλαγές της.

Η μέθοδος αυτή έχει ως στόχο την ελαχιστοποίηση της συνάρτησης κόστους χρησιμοποιώντας την πρώτη μερική παράγωγό της. Σε κάθε επανάληψη του αλγορίθμου αφαιρείται από κάθε παράμετρο του δικτύου η μερική παράγωγος πολλαπλασιασμένη με μια αριθμητική παράμετρο που ονομάζεται ρυθμός μάθησης (learning rate). Ο μαθηματικός τύπος είναι ο παρακάτω.

$$\theta_{j,t+1} = \theta_{j,t} - \alpha \frac{\partial}{\partial \theta_{j,t}} J(\theta) \quad (2.11)$$

Στη γενική περίπτωση ο αλγόριθμος κατάβασης κλίσης εκτελείται αφού έχει γίνει μια πρόσθια τροφοδότηση όλου του συνόλου των δεδομένων στο δίκτυο. Συχνά όμως, επιλέγεται μέρος του συνόλου των δεδομένων για τροφοδότηση στο δίκτυο πριν γίνει μια ενημέρωση. Με βάση αυτό το κριτήριο διακρίνουμε τις εξής βασικές περιπτώσεις:

- **Batch Gradient Descent:** Όλα τα δείγματα εισόδου τροφοδοτούνται στο δίκτυο και στην συνέχεια γίνεται η ενημέρωση των παραμέτρων. Στη συγκεκριμένη περίπτωση ενδέχεται να εκτελεστούν αχρείαστοι υπολογισμοί, καθώς συχνά υπολογίζονται οι κλίσεις για όμοια παραδείγματα πριν από κάθε ενημέρωση των παραμέτρων. Βέβαια, είναι σίγουρο ότι θα βρεί το ολικό ελάχιστο της Συνάρτησης Κόστους εφόσον χρησιμοποιηθεί σε μία κυρτή επιφάνεια λάθους. Στις περιπτώσεις που τα δεδομένα εισόδου είναι πάρα πολλά δημιουργούνται προβλήματα στον υπολογισμό του λόγω υπολογιστικών πόρων.

- **Stochastic Gradient Descent-SGD:** Σε αντίθεση με την προηγούμενη περίπτωση εδώ οι παράμετροι του δικτύου ενημερώνονται για κάθε ένα δείγμα εισόδου ξεχωριστά. Στην προσέγγιση αυτή δεν συμβαίνουν περιττοί υπολογισμοί, αλλά δημιουργούνται προβλήματα όταν πλησιάζει σε τοπικό ελάχιστο της καμπύλης και ειδικά όταν οι πλαγιές του ελαχίστου είναι απότομες, με αποτέλεσμα να υπάρχει ταλάντωση στις πλαγιές αυτής της περιοχής. Επίσης, είναι αρκετά ευαίσθητος σε θορυβώδη δείγματα εισόδου, καθώς η ανανέωση των παραμέτρων του δικτύου με βάση "κακά" δείγματα εισόδου καθυστερούν τη διαδικασία εύρεσης του ελαχίστου. Αυτή η μέθοδος προτάθηκε από τον Robbins το 1951 [17].
- **Mini-Batch Gradient Descent:** Αυτή η μέθοδος χαρακτηρίζεται από την τυχαία επιλογή δειγμάτων αλλά σε μεγαλύτερες ομάδες. Προσπαθεί να συνδυάσει την τυχαιότητα και τον γρήγορο υπολογισμό της στοχαστικής περίπτωσης με τη χρήση περισσότερων δεδομένων εισόδου ώστε να μειώσει τον θόρυβο από μεμονωμένα θορυβώδη δείγματα εισόδου.

2.5 Μετρικές Αξιολόγησης - Evaluation Functions

Οι Μετρικές Αξιολόγησης είναι πολύ σημαντικές για την εξαγωγή συμπερασμάτων, προκειμένου να είναι δυνατή η σύγκριση διαφορετικών μοντέλων μεταξύ τους ως προς την αποτελεσματικότητά τους. Δεν υπάρχει αυστηρός κανόνας για την χρήση κάθε μετρικής καθώς ο τρόπος αξιολόγησης ενός μοντέλου εξαρτάται από τη φύση του προβλήματος που αντιμετωπίζεται. Οι μετρικές αυτές εφαρμόζονται στα **δεδομένα αξιολόγησης (test set)**.

- **Ορθότητα - Accuracy:** Αποτελεί τη βασικότερη μετρική αξιολόγησης ενός μοντέλου. Το μέτρο της εκφράζει το ποσοστό επιτυχίας του μοντέλου στην ταξινόμηση των δειγμάτων στις σωστές κατηγορίες επί του συνόλου δεδομένων.

$$Accuracy = \frac{Number\ of\ Correct\ predictions}{Total\ number\ of\ predictions\ made}$$

Η μετρική αυτή αποφεύγεται όταν οι κλάσεις των δεδομένων μας δεν είναι ισορροπημένες καθώς οι ορθές προβλέψεις της μεγαλύτερης κλάσης μπορούν να επισκιάσουν τις λανθασμένες προβλέψεις των μικρότερων κλάσεων. Για παράδειγμα, έστω ένα πρόβλημα με τρεις κλάσεις εκ των οποίων η κλάση Α έχει 980 δείγματα, η κλάση Β έχει 10 δείγματα και η κλάση Γ έχει 10 δείγματα. Αν το μοντέλο προβλέπει για κάθε δείγμα ότι είναι στην κλάση Α τότε η μετρική accuracy θα έχει τιμή $980/1000=0.98$ ή 98%. Από το παράδειγμα φαίνεται πως δεν είναι δυνατή η εξαγωγή πληροφοριών σχετικά με την ταξινόμηση των δεδομένων ανά κλάση και δεν αποτελεί το κατάλληλο μέτρο για την αξιολόγηση ενός τέτοιου μοντέλου. Αυτό αποτελεί πρόβλημα αν είναι σημαντικό να προβλέπονται σωστά και οι άλλες κλάσεις. Για αυτόν το λόγο, ορίζονται δύο καινούριες μετρικές, οι precision (ακρίβεια) και recall (ανάκληση).

Πριν οριστούν αυτές οι δυο μετρικές αξιολόγησης, ορίζονται πρώτα κάποιες κλάσεις βάσει της προβλεπόμενης και της πραγματικής κλάσης που ανήκουν τα υπό εξέταση δείγματα. Οι ορισμοί θα δωθούν για ένα πρόβλημα δύο κλάσεων (Positive, Negative) αλλά εύκολα μπορούν να επεκταθούν και για προβλήματα περισσότερων κλάσεων.

- **True Positive (TP):** Το σύνολο των δειγμάτων για τα οποία η πρόβλεψη είναι η κατηγορία Positive και η πραγματική κατηγορία είναι η Positive. Άρα, πραγματοποιείται σωστή ταξινόμηση.
- **True Negative (TN):** Το σύνολο των δειγμάτων για τα οποία η πρόβλεψη είναι η κατηγορία Negative και η πραγματική κατηγορία είναι η Negative. Άρα, πραγματοποιείται σωστή ταξινόμηση.
- **False Positive (FP):** Το σύνολο των δειγμάτων για τα οποία η πρόβλεψη είναι η κατηγορία Positive και η πραγματική κατηγορία είναι η Negative. Άρα, πραγματοποιείται λανθασμένη ταξινόμηση.

- **False Negative (FN):** Το σύνολο των δειγμάτων για τα οποία η πρόβλεψη είναι η κατηγορία Negative και η πραγματική κατηγορία είναι η Positive. Άρα, πραγματοποιείται λανθασμένη ταξινόμηση.

Ακολουθούν οι ορισμοί των Precision και Recall.

- **Ακρίβεια - Precision:** Είναι ο λόγος των σωστών αποτελεσμάτων πρόβλεψης μιας κλάσης προς τον συνολικό αριθμό των προβλέψεων αυτής της κλάσης.

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

Η μετρική αυτή συνοψίζει την ικανότητα του μοντέλου να επιστρέφει ως αποτελέσματα δείγματα συναφή με την συγκεκριμένη κλάση.

- **Ανάκληση - Recall:** Είναι ο λόγος των σωστών αποτελεσμάτων πρόβλεψης μιας κλάσης προς τον συνολικό αριθμό των δειγμάτων αυτής της κλάσης.

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

Η μετρική αυτή συνοψίζει την ικανότητα του μοντέλου να βρίσκει όλα τα δείγματα της συγκεκριμένης κλάσης.

Είναι επιθυμητό και οι δύο μετρικές να έχουν υψηλές τιμές. Συνήθως, όμως, υπάρχει ένας συμβιβασμός (trade-off) ανάμεσα τους, χωρίς όμως να αποκλείεται το γεγονός το μοντέλο που προτείνεται ως λύση να επιστρέφει μεγάλες τιμές και στις δύο. Μια μετρική η οποία συνδυάζει τις δυο προηγούμενες μετρικές είναι το F1-Score.

- **F1 Score:** Είναι ο αρμονικός μέσος όρος των Precision και Recall.

$$F1 = \frac{Precision \cdot Recall}{Precision + Recall}$$

Όσο υψηλότερη είναι αυτή η μετρική τόσο καλύτερα αποτελέσματα επιστρέφει το μοντέλο.

Στην περίπτωση των πολλαπλών κλάσεων στις οποίες εμφανίζεται ανισορροπία προτιμάται η χρήση μιας παραλλαγής του F1-Score που ονομάζεται micro-F1. Ο υπολογισμός πραγματοποιείται αθροίζοντας αρχικά από όλες τις κλάσεις τις μεταβλητές TP, FP, FN, υπολογίζονται οι μετρικές Precision και Recall, που πλέον ονομάζονται micro-Precision και micro-Recall αντίστοιχα και εν τέλει υπολογίζεται η μετρική micro-F1.

Κεφάλαιο 3

Δορυφορική Τηλεπισκόπηση και Δεδομένα

3.1 Τι είναι τηλεπισκόπηση

Σύμφωνα με τους Avery και Berlin [18], τηλεπισκόπηση (Remote sensing) ορίζεται ως η τεχνική απόκτησης πληροφοριών για αντικείμενα που βρίσκονται στη επιφάνεια της Γης, μέσα από την ανάλυση δεδομένων που συλλέγονται από ειδικά όργανα τα οποία όμως δεν έρχονται σε φυσική επαφή με τα αντικείμενα αυτά. Επομένως, η τηλεπισκόπηση μπορεί να αποδοθεί και ως η αναγνώριση ενός αντικειμένου από απόσταση.

Ένας ακόμα ενδιαφέρον ορισμός είναι αυτός του Mather [19], ο οποίος αναφέρει πως η τηλεπισκόπηση του περιβάλλοντος περιλαμβάνει τη μέτρηση και αποτύπωση της ηλεκτρομαγνητικής ενέργειας που ανακλάται ή εκπέμπεται από την επιφάνεια της Γης και την ατμόσφαιρα. Η μέτρηση και αποτύπωση γίνεται από ένα σημείο πάνω από την επιφάνεια της Γης και ακολουθεί ο συσχετισμός αυτών των μετρήσεων με τη φύση και την κατανομή των υλικών της επιφάνειας της Γης και των συνθηκών της ατμόσφαιρας.

Τα βασικά στάδια ενός συστήματος τηλεπισκόπησης μπορούν να συνοψιστούν στα εξής σημεία σύμφωνα με τον Παρχαρίδη [20]:

- Εκπομπή ηλεκτρομαγνητικής ακτινοβολίας από μια πηγή (φυσική όπως ο ήλιος ή τεχνητή από το ίδιο το σύστημα).
- Μετάδοση ενέργειας από την πηγή προς την επιφάνεια της Γης, η οποία συνεπάγεται και απορρόφηση και σκέδαση από την ανώτερη ατμόσφαιρα.
- Αλληλεπίδραση της ηλεκτρομαγνητικής ακτινοβολίας με την επιφάνεια της Γης μέσω αντανάκλασης και εκπομπής.
- Μετάδοση της ακτινοβολίας από την επιφάνεια προς τον απομακρυσμένο αισθητήρα του συστήματος.
- Συγκέντρωση δεδομένων που έλαβε ο αισθητήρας.
- Μετάδοση δεδομένων, επεξεργασία και ανάλυση.

Η τηλεπισκόπηση αποτελεί σημαντικό μέρος της γεωπληροφορικής καθώς προσφέρει πληροφορίες σχετικά με αντικείμενα πάνω στη γη, τις ιδιότητες τους στο χώρο και στο χρόνο αλλά και τις χρονικές σχέσεις που αναπτύσσουν με άλλα αντικείμενα. Οι πληροφορίες αυτές διατίθενται σε μεγάλη ποσότητα αλλά και σε καλύτερη ποιότητα από ότι θα μπορούσε να παρέχει ένας άνθρωπος ως παρατηρητής.

Μια από τις πιο σημαντικές εφαρμογές της τηλεπισκόπησης είναι η χαρτογράφηση της επιφάνειας της Γης και η καταγραφή των αλλαγών που γίνονται λόγω διαφόρων παραγόντων. Η συγκέντρωση πληροφοριών δεν περιορίζεται μόνο στην στεριά αλλά επεκτείνεται και στο υγρό στοιχείο στην επιφάνεια του πλανήτη και στις αέριες μάζες.

Τα συστήματα τηλεπισκόπησης ποικίλουν. Η συλλογή των δεδομένων μπορεί να πραγματοποιηθεί από πλατφόρμες όπως αεροσκάφη, δορυφόρους, μπαλόνια, ρουκέτες, διαστημικά λεωφορεία,

κ.λπ. Οι αισθητήρες που χρησιμοποιούνται περιλαμβάνουν εναέριες φωτογραφικές μηχανές και άλλα μη φωτογραφικά μέσα, όπως: ραδιόμετρα, ηλεκτροοπτικοί σαρωτές, συστήματα ραντάρ, κ.λπ.


Το μέσο μετάδοσης της πληροφορίας αποτελεί η ηλεκτρομαγνητική ενέργεια, η οποία καθώς ανακλάται μεταδίδεται ή εκπέμπεται από το στόχο και καταγράφεται από τον αισθητήρα. Κάθε αισθητήρας εστιάζει σε διαφορετικό μέρος του ηλεκτρομαγνητικού φάσματος και η επιλογή του γίνεται ανάλογα το πρόβλημα που αντιμετωπίζεται.

3.2 Ηλεκτρομαγνητική Ακτινοβολία και Ηλεκτρομαγνητικό Φάσμα

Όπως αναφέρθηκε στην προηγούμενη παράγραφο, η βασικότερη απαίτηση για την τηλεπισκόπηση είναι να υπάρχει μια ενεργειακή πηγή για να φωτίζει το στόχο (εκτός εάν η ανιχνευόμενη ενέργεια εκπέμπεται από το στόχο), αυτή η πηγή ενέργειας έχει τη μορφή ηλεκτρομαγνητικής ακτινοβολίας.

3.2.1 Ηλεκτρομαγνητική Ακτινοβολία

Η ακτινοβολία αυτή αποτελείται από ένα ηλεκτρικό πεδίο (E) σε διεύθυνση κάθετη προς την κατεύθυνση στην οποία η ακτινοβολία ταξιδεύει, και ένα μαγνητικό πεδίο (B) κάθετο προς το ηλεκτρικό πεδίο. Και τα δύο αυτά πεδία ταξιδεύουν με τη ταχύτητα του φωτός (C). Τα δύο σημαντικότερα χαρακτηριστικά της ηλεκτρομαγνητικής ακτινοβολίας για την τηλεπισκόπηση είναι το μήκος κύματος λ και η συχνότητα f .



Σχήμα 10: Ηλεκτρομαγνητική Ακτινοβολία (πηγή:imamamgnets.com)

Το μήκος κύματος (λ , wavelength) είναι το μήκος μίας περιόδου του ηλεκτρομαγνητικού κύματος, το οποίο μπορεί να μετρηθεί ως η απόσταση μεταξύ των διαδοχικών κορυφών των κυμάτων όπως φαίνεται και στο σχήμα 10. Η μονάδα μέτρησης του είναι το μέτρο (m), αλλά στην τηλεπισκόπηση συνήθως χρησιμοποιούνται οι υποδιαιρέσεις του όπως νανόμετρα ($nm = 10^{-9}m$) και μικρόμετρα ($\mu m = 10^{-6}m$).

Η συχνότητα (f , frequency) αναφέρεται στον αριθμό των περιόδων ενός κύματος που διέρχεται από σταθερό σημείο ανά μονάδα χρόνου. Η μονάδα μέτρησης της είναι το hertz (Hz), που είναι ισοδύναμο με μία περίοδο ανά δευτερόλεπτο, αλλά συνήθως χρησιμοποιούνται διάφορα πολλαπλάσια του όπως το megahertz ($MHz = 10^6 Hz$), το gigahertz ($GHz = 10^9 Hz$) και άλλα μεγαλύτερα.

Η μαθηματική σχέση που συνδέει τα παραπάνω μεγέθη είναι η εξής:

$$c = \lambda \cdot f \quad (3.1)$$

όπου c είναι η ταχύτητα του φωτός ($3 \cdot 10^8 m/s$).

Όπως φαίνεται από την σχέση 3.1 τα δυο μεγέθη είναι αντιστρόφως ανάλογα, δηλαδή η αύξηση του ενός συνεπάγεται την μείωση του άλλου.

3.2.2 Ηλεκτρομαγνητικό Φάσμα

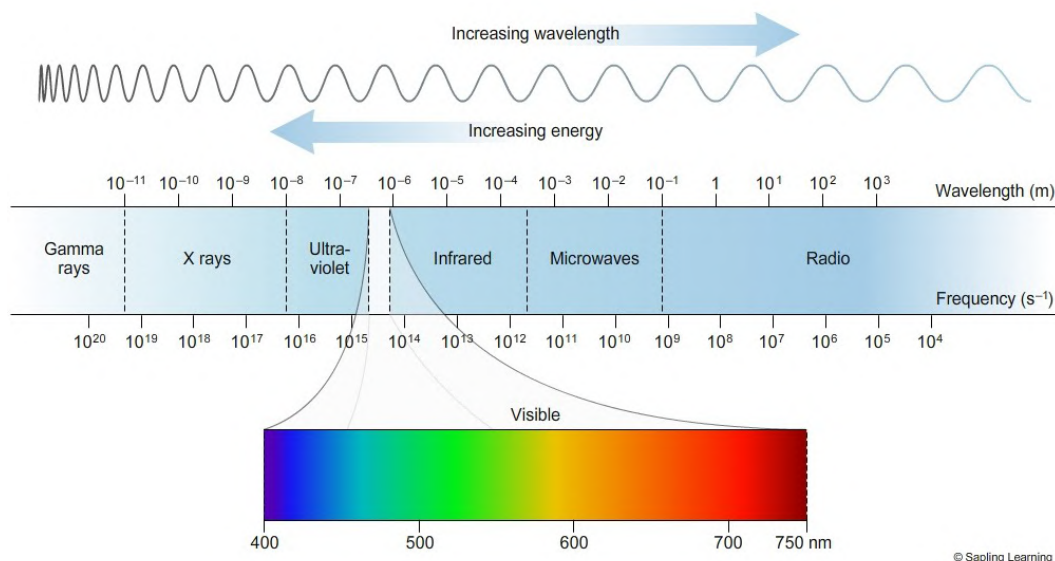
Από την ταξινόμηση της ηλεκτρομαγνητικής ακτινοβολίας, με βάση τη συχνότητα της, προκύπτει η κλίμακα που ονομάζεται ηλεκτρομαγνητικό φάσμα. Η ταξινόμηση μπορεί να πραγματοποιηθεί και με τα μεγέθη του μήκους κύματος και της ενέργειας της ακτινοβολίας οδηγώντας όμως στο ίδιο ακριβώς αποτέλεσμα.

Οι βασικές ζώνες στις οποίες χωρίζεται το φάσμα φαίνονται στον πίνακα 1.

Ζώνες ηλεκτρομαγνητικού φάσματος	
Περιοχή Φάσματος	Περιοχή Συχνοτήτων
Ραδιοκύματα	0-300 MHz
Μικροκύματα	300 MHz - 300 GHz
Υπέρυθρη ακτινοβολία	300 GHz - 400 THz
Ορατή ακτινοβολία	400 THz - 800 THz
Υπεριώδης ακτινοβολία	800 THz - $3 \cdot 10^{17} Hz$
Ακτίνες X	$3 \cdot 10^{17} Hz - 5 \cdot 10^{19} Hz$
Ακτίνες γ	$5 \cdot 10^{19} Hz - 3 \cdot 10^{22} Hz$
Κοσμικές ακτίνες	$3 \cdot 10^{22} Hz -$

Πίνακας 1: Ζώνες Ηλεκτρομαγνητικού Φάσματος.

Στο σχήμα 11 οπτικοποιούνται οι ζώνες του ηλεκτρομαγνητικού φάσματος ώστε να γίνουν πιο κατανοητές. Από όλες αυτές τις ζώνες εκείνες που χρησιμοποιούνται στην τηλεπισκόπηση είναι η υπεριώδης, η ορατή, η υπέρυθη ακτινοβολία και τα μικροκύματα.




Σχήμα 11: Ηλεκτρομαγνητικό Φάσμα (πηγή:sapling learning)

3.2.3 Φασματική Υπογραφή Αντικειμένων

Είναι χαρακτηριστική ιδιότητα κάθε υλικού στοιχείου να απορροφά και να ανακλά μέρος μιας προσπίπτουσας ηλεκτρομαγνητικής ακτινοβολίας. Το πιο μέρος του φάσματος της ακτινοβολίας θα απορροφηθεί ή θα ανακλαστεί και σε ποια ποσότητα εξαρτάται από το υλικό και ονομάζεται **φασματική απόκριση**. Αυτή η ιδιότητα μπορεί να χρησιμοποιηθεί ώστε σε κάθε υλικό στοιχείο να αποδίδεται μια χαρακτηριστική συμπεριφορά όταν ακτινοβολείται, δηλαδή είναι εφικτό να σχηματιστεί μια φασματική υπογραφή που θα διαχωρίζει τα παρατηρούμενα αντικείμενα. Με κατάλληλη μελέτη είναι εφικτό να εξαχθούν συμπεράσματα σχετικά με το σχήμα, τις διαστάσεις, τις φυσικές και σε ορισμένες περιπτώσεις και τις χημικές ιδιότητες του υπο εξέταση αντικειμένου.

Η προαναφερθείσα φασματική υπογραφή μπορεί να οπτικοποιηθεί όπως φαίνεται στο σχήμα 12. Για κάθε αντικείμενο φαίνεται σε ποια μήκη κύματος η ακτινοβολία αντανακλάται περισσότερο.



Σχήμα 12: Φασματικές Ταυτότητες (πηγή:remotesensing529)

Η φασματική υπογραφή κάθε επιφάνειας μπορεί να διαχωρίσει το είδος των επιφανειών που εξετάζονται. Στο σχήμα 12 είναι ξεκάθαρη η διαφοροποίηση ανάμεσα σε νερό, βλάστηση και έδαφος. Όσο πιο διαφορετικά είναι τα αντικείμενα μεταξύ τους τόσο πιο εμφανής είναι και η διαφοροποίηση των φασματικών υπογραφών τους. Ακόμα και σε παρόμοια αντικείμενα, όπως διαφορετικά είδη βλάστησης, είναι δυνατόν να παρατηρηθούν διαφορές στις φασματικές αποκρίσεις τους και άρα να ταξινομηθούν.

Η διαφοροποίηση που παρατηρείται από τους αισθητήρες μπορεί να μεταφερθεί και σε παράγωγα των δεδομένων που αποκτούνται μέσω μετασχηματισμών. Για παράδειγμα, ο υπολογισμός ενός αριθμητικού δείκτη από τα δεδομένα του αισθητήρα μπορεί να διατηρεί τις όποιες διαφορές παρατηρούνται για τα εξεταζόμενα αντικείμενα. Αυτή η ιδιότητα είναι πολύ σημαντική καθώς επιτρέπει την επεξεργασία των δεδομένων της τηλεπισκόπησης και την εξαγωγή εύκολα κατανοητών πληροφοριών και συμπερασμάτων ανάλογα με το πρόβλημα που αντιμετωπίζεται.

3.3 Δορυφορική Τηλεπισκόπηση

Αν και ο όρος Τηλεπισκόπηση είναι γενικός και περιλαμβάνει, όπως αναφέρθηκε, οποιαδήποτε μορφή παρακολούθησης από απόσταση, συλλογής δεδομένων και την επεξεργασία τους, πλέον κυριαρχεί η χρήση του για την καταγραφή και ανάλυση δορυφορικών δεδομένων.

Οι τεχνητοί δορυφόροι είναι συστήματα που στην γενική μορφή τους αποτελούνται από μια πηγή ηλεκτρικής ενέργειας (ηλεκτρικός συσσωρευτής ή φωτοβολταϊκό σύστημα), αισθητήρες για να δέχεται πληροφορίες και κεραία η οποία εκπέμπει πληροφορίες υπό μορφή ηλεκτρομαγνητικού σήματος.

Από τον πρώτο δορυφόρο που εκτοξεύθηκε το 1957 (ο δορυφόρος Sputnik 1 της πρώην ΕΣΣΔ) έχουν εκτοξευθεί πληθώρα δορυφόρων από πολλές χώρες. Οι αποστολές τους, οι αισθητήρες τους και η διάρκεια ζωής τους ποικίλει. Μερικές κατηγορίες δορυφόρων είναι οι εξής:

- Τηλεπικοινωνίας, για τη δημιουργία καναλιών επικοινωνίας μεταξύ ενός πομπού και ενός δέκτη.
- Τηλεσκοπικοί, οι οποίοι είναι εξοπλισμένοι με τηλεσκόπια και άλλα ειδικά όργανα για την παρακολούθηση του διαστήματος.
- Μετεωρολογικοί, για τη συλλογή πληροφοριών σχετικά με τον καιρό και το κλίμα της Γης.
- Πλοήγησης, για την παροχή πληροφοριών σχετικά με τις συντεταγμένες και την ακριβή θέση διαφόρων αντικειμένων-χρηστών.
- Γεωπαρατήρησης, για τη συλλογή πληροφοριών σχετικά με την επιφάνεια της γης .

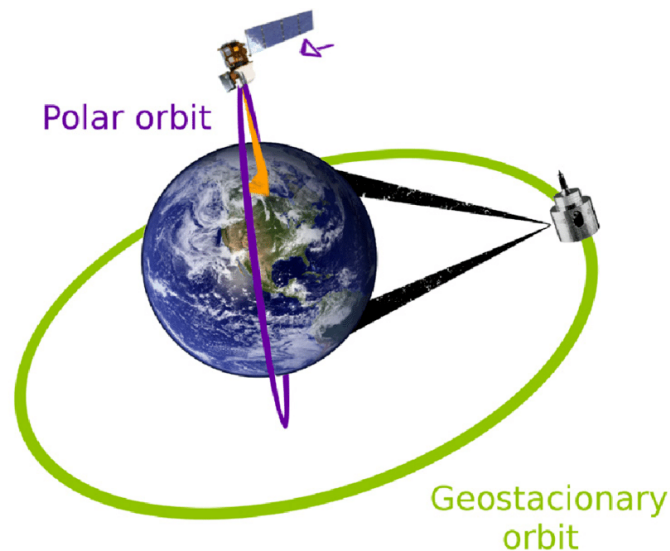
3.3.1 Δορυφορικές Τροχιές

Τροχιά ονομάζεται η καθορισμένη διαδρομή που ακολουθείται από ένα δορυφόρο. Οι δορυφορικές τροχιές επιλέγονται ανάλογα με τις ικανότητες και το στόχο των αισθητήρων που μεταφέρουν. Οι τροχιές μπορεί να διαφέρουν όσον αφορά το υψόμετρο που βρίσκεται ο δορυφόρος, του προσανατολισμού του και της περιστροφής του σε σχέση με τη Γη.

Μερικοί δορυφόροι βρίσκονται σε πολύ μεγάλο υψόμετρο και μπορούν να προβάλλουν το ίδιο τμήμα της επιφάνειας της Γης ανά πάσα στιγμή, λέγεται πως έχουν **γεωστατική τροχιά**. Περιστρέφονται με ταχύτητες συντονισμένες με την περιστροφή της γης με αποτέλεσμα να μπορούν να συλλέγουν πληροφορίες από συγκεκριμένες περιοχές. Τέτοιου είδους δορυφόροι είναι αυτοί του καιρού και των τηλεπικοινωνιών.

Άλλοι δορυφόροι έχουν σχεδιαστεί να ακολουθούν μια τροχιά με συνηθέστερη αυτή του Βορρά-Νότου. Αυτές ονομάζονται **πολικές τροχιές** λόγω της κίνησής τους σε σχέση με τη γραμμή που διέρχεται μεταξύ του Βόρειου και του Νότιου πόλου. Επίσης, πολλές από αυτές τις δορυφορικές τροχιές είναι συγχρονισμένες με τον ήλιο έτσι ώστε να καλύπτουν κάθε περιοχή του κόσμου σε μια σταθερή τοπική ώρα της ημέρας η οποία ονομάζεται τοπική ώρα ήλιου.

Στο σχήμα 13 φαίνονται τα δύο είδη τροχιών που αναφέρθηκαν. Η παρούσα διπλωματική εστιάζει στη χρήση δεδομένων από δορυφόρους με πολικές τροχιές και στη συνέχεια αναλύονται κάποια βασικά χαρακτηριστικά τους.



Σχήμα 13: Δορυφορικές τροχιές. (πηγή:researchgate.net)

Καθώς ένας δορυφόρος περιστρέφεται γύρω από τη Γη, ο αισθητήρας μπορεί να λάβει δεδομένα από ένα ορισμένο τμήμα της επιφάνειας της Γης. Αυτή η περιοχή ονομάζεται **ίχνος**. Ο συνδυασμός της τροχιάς των δορυφόρων και του ίχνους τους οδηγεί στην απεικόνιση της επιφάνειας της Γης σε λωρίδες όπως φαίνεται στο σχήμα 14.

Το πλάτος των λωρίδων αυτών ποικίλει μεταξύ λίγων και εκατοντάδων χιλιομέτρων. Ο δορυφόρος περιστρέφεται γύρω από τη Γη από πόλο σε πόλο και η ίδια η Γη περιστρέφεται από δυτικά προς ανατολικά κάτω από αυτόν. Επομένως, είναι δυνατό να καλυφθεί όλη η επιφάνεια της Γης από τις λωρίδες που σχηματίζουν διαδοχικά περάσματα του δορυφόρου με την ολοκλήρωση ενός πλήρους κύκλου τροχιών.



Σχήμα 14: Ίχνος δορυφόρου και λωρίδα παρατήρησης. (πηγή:researchgate.net)


Αν οριστεί μια τυχαία επιλεγμένη λωρίδα στην τροχιά ενός δορυφόρου τότε ένας **κύκλος τροχιάς** θα ολοκληρωθεί όταν ο δορυφόρος περάσει πάνω από αυτή την ορισμένη λωρίδα για δεύτερη φορά. Το χρονικό διάστημα που απαιτείται για την ολοκλήρωση ενός τροχιακού κύκλου ποικίλει από δορυφόρο σε δορυφόρο.

Ένα ακόμα χαρακτηριστικό των δορυφόρων είναι η **περίοδος επανάφιξης**. Αυτή ορίζεται ως ο χρόνος που απαιτείται να ανιχνευθεί ξανά από τους αισθητήρες του δορυφόρου ένα σημείο της επιφάνειας της Γης. Η περίοδος επανάφιξης, συνήθως, δεν ταυτίζεται με τον κύκλο τροχιάς καθώς πολλές φορές οι λωρίδες που διαγράφει ο δορυφόρος στην επιφάνεια της Γης αλληλοεπικαλύπτονται ως ένα βαθμό με αποτέλεσμα ορισμένα σημεία να απεικονίζονται από διαδοχικές λωρίδες. Επίσης, σε ορισμένους δορυφόρους είναι δυνατόν να στραφούν οι αισθητήρες και να μετατοπιστεί μερικώς το ίχνος του δορυφόρου στην επιφάνεια ώστε να επιτευχθεί αυτή η ανίχνευση σε διαδοχικές λωρίδες.

3.3.2 Ανάλυση Δορυφορικών Εικόνων

Η ανάλυση των δορυφορικών εικόνων είναι ένα πολύ βασικό χαρακτηριστικό των δορυφορικών συστημάτων. Όσο μεγαλύτερη η ανάλυση τόσο πιο μικρά αντικείμενα μπορούν να διακριθούν στην εικόνα. Υπάρχουν συστήματα που έχουν ανάλυση μερικά εκατοστά όπως το WorldView-3 με ανάλυση που φτάνει έως και 31 εκατοστά (cm) [21], αλλά και άλλα συστήματα όπως το MODIS που η ανάλυση του φτάνει έως τα 250 μέτρα (m) [22]. Ανάλογα το πρόβλημα που αντιμετωπίζεται υπάρχουν διαφορετικές απαιτήσεις ως προς την ανάλυση και πρέπει να επιλεγεί κατάλληλο σύστημα που να τις ικανοποιεί. Σε αντίθετη περίπτωση μπορεί να δημιουργηθούν προβλήματα στην επίλυση.

Σε μια προκαθορισμένη περιοχή, όσο μεγαλύτερη ανάλυση έχουν οι εικόνες της τόσο μεγαλύτερο είναι και το μέγεθος των δεδομένων που πρέπει να δεχθούν επεξεργασία. Από την άλλη, όσο μικρότερη ανάλυση έχουν οι εικόνες τόσο μεγαλύτερη απώλεια πληροφορίας υπάρχει καθώς δεν είναι διακριτά τα διαφορετικά αντικείμενα της εικόνας. Για παράδειγμα, αν στην εικόνα υπάρχουν αγροτεμάχια (συνήθως έχουν ευδιάκριτο προκαθορισμένο σχήμα) τα οποία είναι σε μεγέθη μερικών δεκάδων μέτρων και η ανάλυση της εικόνας είναι μερικές εκατοντάδες μέτρα τότε διαφορετικά αγροτεμάχια θα απεικονίζονται από ένα μόνο εικονοστοιχείο, χάνοντας έτσι μεγάλο μέρος της πληροφορίας που θα μπορούσε να δώσει το κάθε ένα ξεχωριστά. Στην εικόνα 15 παρατηρώντας τη δεύτερη από τα αριστερά εικόνα, στην οποία δεν υπάρχουν καθόλου σκούρα εικονοστοιχεία, φαίνεται πώς η μικρή ανάλυση μπορεί να επηρεάσει την ποιότητα των δεδομένων.



Σχήμα 15: Υπερδειγματοληψία και Υποδειγματοληψία εικόνας. (πηγή:researchgate)

3.3.3 Δορυφόροι Γεωπαρατήρησης

Σήμερα υπάρχουν πολλοί δορυφόροι γεωπαρατήρησης σε τροχιά γύρω από τη Γη, οι οποίοι είναι είτε εθνικών/διεθνών συμφερόντων είτε ιδιωτικών. Μερικοί ενεργοί δορυφόροι σήμερα είναι οι Pleiades [23], WorldView-3 [21], SPOT [24] κ.α. Διάφορες κρατικές διαστημικές υπηρεσίες έχουν δημιουργήσει προγράμματα που απαρτίζονται από πολλούς δορυφόρους, όπως το πρόγραμμα Copernicus [25] του Ευρωπαϊκού Οργανισμού Διαστήματος (European Space Agency - ESA) ή προγράμματα στα οποία οι δορυφόροι ανανεώνονται ανά διαστήματα με βελτιωμένα όργανα διατηρώντας το περιεχόμενο της αρχικής αποστολής, όπως το πρόγραμμα Landsat της αμερικανικής Εθνικής Υπηρεσίας Αεροναυπηγικής και Διαστήματος (National Aeronautics and Space Administration - NASA).

3.3.3.1 Πρόγραμμα Copernicus

Το Ευρωπαϊκό επιστημονικό Πρόγραμμα Κοπέρνικος (Copernicus) δημιουργήθηκε από την Επιτροπή Ευρωπαϊκών Κοινοτήτων (European Commission) σε συνεργασία με τον Ευρωπαϊκό Οργανισμό Διαστήματος. Αποτελεί την συνέχεια του προγράμματος GMES (Global Monitoring for Environment and Security) δηλαδή του Ευρωπαϊκού Προγράμματος για την «Παγκόσμια Παρακολούθηση του Περιβάλλοντος και της Ασφάλειας».

Έχει ως βασικό σκοπό την μελέτη και παρακολούθηση του περιβάλλοντος της γης και πιο στοχευμένα της επιφάνειας της γης (ξηρά-θάλασσα), της ατμόσφαιρας, της αλλαγής του κλίματος, την διαχείριση έκτακτων καταστάσεων και την ασφάλεια. Από τεχνολογικής πλευράς, πρόκειται για ένα σύνολο συστημάτων που αποτελείται από διαφόρων τύπων συστήματα και όργανα συλλογής δεδομένων από διαφορετικές πηγές: δορυφόρους γεωπαρατήρησης, αερομεταφερόμενες πλατφόρμες εφοδιασμένες με ειδικούς αισθητήρες και καταγραφείς της γήινης επιφάνειας και τέλος σταθερούς αισθητήρες συλλογής και καταγραφής των διαφόρων παραμέτρων και μεταβλητών που αφορούν το γήινο περιβάλλον [25].

Για τις ανάγκες του προγράμματος Copernicus ο Ευρωπαϊκός Οργανισμός Διαστήματος αναπτύσσει μια νέα οικογένεια δορυφόρων που ονομάζεται Sentinel. Αυτοί χωρίζονται σε αποστολές οι οποίες έχουν συγκεκριμένο σκοπό η κάθε μια και παρέχουν ένα μοναδικό σύνολο παρατηρήσεων [26]. Στη συνέχεια αναφέρονται συνοπτικά.

- **Sentinel-1:** Αποτελείται από ένα ζεύγος δορυφόρων τους Sentinel-1A και Sentinel-1B, οι οποίοι εκτοξεύθηκαν 3 Απριλίου 2014 και 25 Απριλίου 2016 αντίστοιχα. Οι δορυφόροι αυτοί φέρουν ένα προηγμένο όργανο ραντάρ για τη λήψη εικόνων της επιφάνειας της Γης ημέρα και νύχτα ανεξαρτήτως των καιρικών συνθηκών. Κάθε 6 ημέρες καλύπτουν ολόκληρη τη Γη. Τα δεδομένα αυτής της αποστολής είναι χρήσιμα σε υπηρεσίες που σχετίζονται με την έκταση και χαρτογράφηση του θαλάσσιου πάγου, την επιτήρηση του θαλάσσιου περιβάλλοντος, συμπεριλαμβανομένης της παρακολούθησης των πετρελαιοκηλίδων, την παρακολούθηση της επιφάνειας του εδάφους για παραμορφώσεις που οφείλονται σε ανθρωπογενή αίτια ή σε φυσικές καταστροφές, τη χαρτογράφηση των δασών και τους κινδύνους αποψίλωσης, το νερό και τη διαχείρισή του.
- **Sentinel-2:** Αποτελείται από ένα ζεύγος δορυφόρων τους Sentinel-2A και Sentinel-2B, οι οποίοι εκτοξεύθηκαν 23 Ιουνίου 2015 και 7 Μαρτίου 2017 αντίστοιχα. Φέρουν ένα όργανο καταγραφής ευρείας χωρικής λήψης και υψηλής χωρικής ανάλυσης πολυφασματικών δεδομένων. Καλύπτουν όλη την επιφάνεια της Γης κάθε 5 μέρες. Η αποστολή παρέχει πληροφορίες κυρίως για τις γεωργικές και δασοκομικές πρακτικές και βοηθάει στη διαχείριση της επισιτιστικής ασφάλειας. Οι δορυφορικές της εικόνες χρησιμοποιούνται για τον προσδιορισμό διαφόρων δεικτών των φυτών, που σχετίζονται με την παρουσία της χλωροφύλλης των φύλλων και την περιεκτικότητα σε νερό. Αυτό είναι ιδιαίτερα σημαντικό για τις εφαρμογές που σχετίζονται με τη βλάστηση της Γης.
- **Sentinel-3:** Αποτελείται από ένα ζεύγος δορυφόρων τους Sentinel-3A και Sentinel-3B, οι οποίοι εκτοξεύθηκαν 16 Φεβρουαρίου 2016 και 25 Απριλίου 2018 αντίστοιχα. Η αποστολή του δορυφόρου Sentinel-3 έχει ως στόχο την παρακολούθηση της τοπογραφίας της θαλάσσιας επιφάνειας, τη μέτρηση της χερσαίας και θαλάσσιας θερμοκρασίας, καθώς και γενικά την παρακολούθηση του περιβάλλοντος και του κλίματος. Σε σχεδόν πραγματικό χρόνο, παρέχονται δεδομένα για την πρόβλεψη κατάστασης των ωκεανών, χαρτογράφηση του θαλάσσιου πάγου, καταγραφή των ωκεάνιων οικοσυστημάτων, την ποιότητα του νερού και την παρακολούθηση της ρύπανσης. Όσον αφορά το χερσαίο περιβάλλον παρακολουθούνται οι αλλαγές χρήσεων γης, η δασική κάλυψη, η φωτοσυνθετική δραστηριότητα, η ποιότητα του εδάφους και η έγκαιρη προειδοποίηση κινδύνου πυρκαγιάς.
- **Sentinel-4:** Ο Ευρωπαϊκός Οργανισμός Διαστήματος σχεδιάζει να τον εκτοξεύσει μέσα στο 2023. Ο βασικός στόχος θα είναι η παρακολούθηση του ημερήσιου κύκλου της τροποσφαιρι-

κής σύνθεσης σε όλη την Ευρώπη και τη Βόρεια Αφρική, παρακολουθώντας βασικά στοιχεία ποιότητας αέρα όπως το O_3 (όζον), NO_2 (διοξείδιο του αζώτου), SO_2 (διοξείδιο του θείου), CH_2O (φορμαλδεΰδη), $C_2H_2O_2$ (γλυοξάλη), καθώς και ιδιότητες αερολύματος(aerosol) και νέφους για την υποστήριξη των εφαρμογών ποιότητας αέρα.

- **Sentinel-5:** Ο Ευρωπαϊκός Οργανισμός Διαστήματος σχεδιάζει να τον εκτοξεύσει μέσα στο 2021. Ο στόχος του Sentinel-5 είναι να παρακολουθεί σε παγκόσμιο επίπεδο τα βασικά αέρια και τα αερολύματα ποιότητας αέρα σε υψηλή χωρική ανάλυση. Σε μεγάλο βαθμό συνεργάζεται και αλληλοεπικαλύπτεται με τον Sentinel-4. Οι μετρήσεις του θα καλύπτουν το O_3 (όζον), την επιφανειακή υπεριώδη ακτινοβολία (UV), την ποιότητα του αέρα και άλλες κλιματικές εφαρμογές. Επικεντρώνεται, κατά κύριο λόγο, στην παρακολούθηση της ποιότητας του αέρα και στην αλληλεπίδραση διαφόρων στοιχείων ποιότητας του αέρα με το κλίμα.
- **Sentinel-5 Precursor (5P):** Εκτοξεύθηκε στις 13 Οκτωβρίου 2017 και όπως φανερώνει το όνομά του είναι ο πρόδρομος του Sentinel-5 και συλλέγει δεδομένα έως ότου το 2021 γίνει η εκτόξευσή του βασικού δορυφόρου. Ο σκοπός του είναι παρόμοιος με του Sentinel-5, δηλαδή την παρακολούθηση της ποιότητας του αέρα.

Η αποστολή **Sentinel-2** είναι η πιο σχετική με την παρούσα εργασία καθώς, όπως αναφέρθηκε, παρέχει δεδομένα για αγροτικές και δασικές περιοχές με σκοπό την διατροφική ασφάλεια του πλανήτη. Από τα δεδομένα αυτά προσδιορίζονται παράγοντες πολύ σημαντικοί για την ανθρώπινη διαβίωση και επιβίωση όπως δείκτες περιεκτικότητας νερού και χλωροφύλλης. Μερικές εφαρμογές των δεδομένων τους είναι οι εξής:

- Διαχείριση αλλαγών της κάλυψης-χρήσης της γης.
- Καταγραφή δασικών περιοχών και δασικών καταστροφών.
- Διαχείριση και καταγραφή ανάπτυξης φυτικών πληθυσμών.
- Καταγραφή της μόλυνσης παράκτιων και λιμναίων περιοχών.
- Καταγραφή και απεικόνιση φυσικών καταστροφών όπως πλημμύρες, ηφαιστειακές εκρήξεις, καθιζήσεις και ολισθήσεις εδαφών.

Στον πίνακα 2 αναγράφονται οι 13 φασματικές ζώνες που καλύπτει ο κάθε δορυφόρος.

Sentinel-2 Bands	Wavelength (micrometers)	Resolution (meters)
Band 1 - Coastal aerosol	0.433 - 0.453	60
Band 2 - Blue	0.458 - 0.523	10
Band 3 - Green	0.543 - 0.578	10
Band 4 - Red	0.650 - 0.680	10
Band 5 - Red Edge 1	0.698 - 0.713	20
Band 6 - Red Edge 2	0.733 - 0.748	20
Band 7 - Red Edge	0.773 - 0.793	20
Band 8 - Near Infrared (NIR)	0.785 - 0.900	10
Band 8A - Near Infrared narrow (NIRn)	0.855 - 0.875	20
Band 9 - Water vapour	0.935 - 0.955	60
Band 10 - Shortwave infrared/Cirrus	1.360 - 1.390	60
Band 11 - Shortwave infrared 1 (SWIR 1)	1.565 - 1.655	20
Band 12 - Shortwave infrared 2 (SWIR 2)	2.100 - 2.280	20

Πίνακας 2: Sentinel-2: Φασματικά κανάλια και ανάλυση εικόνων. (πηγή:researchgate)

Τα δεδομένα του Sentinel 2 είναι διαθέσιμα δωρεάν για το ευρύ κοινό από την επίσημη ιστοσελίδα του Ευρωπαϊκού Οργανισμού Διαστήματος για το πρόγραμμα Copernicus [27] αλλά και από την αμερικανική υπηρεσία United States Geological Survey (USGS) [26]. Στα δεδομένα αυτά έχει πραγματοποιηθεί προεπεξεργασία και ατμοσφαιρικές διορθώσεις με εργαλεία και αλγορίθμους της ESA πριν διατεθούν στο κοινό.

Η χωρική ανάλυση των 10 μέτρων του Sentinel-2 επιτρέπει την αναλυτικότερη και ευκρινέστερη απεικόνιση της επιφάνειας σε σχέση με τον Landsat 8 του προγράμματος Landsat που περιγράφεται στη συνέχεια.

3.3.3.2 Πρόγραμμα Landsat

Το πρόγραμμα Landsat ξεκίνησε ως ένα πείραμα της NASA το 1972 για να ελεγχθεί η σκοπιμότητα της συλλογής πολυφασματικών δεδομένων παρατήρησης της Γης από μία μη επανδρωμένη δορυφορική πλατφόρμα. Η ευθύνη και η διεύθυνση του προγράμματος μεταφέρθηκε στη NOAA (National Oceanic and Atmospheric Administration) το 1983.

Η επιτυχία του Landsat οφείλεται σε διάφορους παράγοντες, συμπεριλαμβανομένου: α) ενός συνδυασμού αισθητήρων με φασματικές ζώνες προσαρμοσμένες στην παρατήρηση της Γης, β) τη λειτουργική χωρική ανάλυση και γ) την καλή επιφανειακή κάλυψη (πλάτος λωρίδας και περίοδος επανάφιξης). Λόγω της μεγάλης διάρκειας ζωής του προγράμματος έχει συγκεντρωθεί ένα ογκώδες αρχείο δεδομένων από παρατηρήσεις της Γης, διευκολύνοντας την διαχρονική παρακολούθηση.

Ο πρώτος δορυφόρος του προγράμματος ήταν ο ERTS-1 και εκτοξεύθηκε το 1972, ενώ στη συνέχεια μετονομάστηκε σε Landsat 1. Στη συνέχεια, ακολούθησαν και άλλοι δορυφόροι έως τον πιο πρόσφατο που είναι ο Landsat 8. Όλοι οι δορυφόροι Landsat τοποθετούνται σε πολικές, ήλιο-σύγχρονες τροχιές. Οι πρώτοι τρεις δορυφόροι (Landsat 1-3) βρίσκονταν σε υψόμετρο περίπου 900 χλμ. και η περίοδος επανάφιξης ήταν 18 ημέρες, ενώ οι μεταγενέστεροι δορυφόροι (Landsat 4-8) βρίσκονται περίπου σε 700 χιλιόμετρα και η περίοδος επανάφιξης είναι 16 ημέρες. Όλοι οι δορυφόροι Landsat διασχίζουν τον ισημερινό το πρωί για τη βελτιστοποίηση των συνθηκών φωτισμού.

Αυτή τη στιγμή ενεργοί είναι μόνο οι δορυφόροι Landsat 7 (εκτόξευση 15 Απριλίου 1999) και Landsat 8 (εκτόξευση 11 Φεβρουαρίου 2013) [28], με βασικότερο τον δεύτερο καθώς τα χαρακτηριστικά του είναι πιο σύγχρονα και παράγει καλύτερα δεδομένα.

Ο **Landsat 8** μεταφέρει δύο όργανα καταγραφής:

- το **Operational Land Imager (OLI)**: Ο αισθητήρας OLI συλλέγει δεδομένα στο ορατό κοντινό υπέρυθρο, μικροκυματικό υπέρυθρο καθώς και στο παγχρωματικό τμήμα του ηλεκτρομαγνητικού φάσματος.
- το **Thermal Infrared Sensor (TIRS)**: Ο αισθητήρας TIRS, συλλέγει δεδομένα σε 2 φασματικά κανάλια στο τμήμα του θερμικού υπέρυθρου, σε αντίθεση με τους προηγούμενους δορυφόρους του προγράμματος Landsat στους οποίους υπήρχε μόνο 1 φασματικό κανάλι στο συγκεκριμένο τμήμα του ηλεκτρομαγνητικού φάσματος.

Ο Landsat 8 λαμβάνει περίπου 400 λήψεις εικόνων ανά ημέρα (150 παραπάνω από τον Landsat 7) έχοντας, έτσι, μεγαλύτερη πιθανότητα λήψης εικόνων χωρίς σύννεφα. Στον πίνακα 3 αναγράφονται τα φασματικά κανάλια των αισθητήρων του δορυφόρου και η ανάλυση του καθενός.

Το φασματικό κανάλι 1 (Coastal aerosol) ανιχνεύει το βαθύ μπλε χρησιμοποιείται για την απεικόνιση ρηχών υδάτων και την παρακολούθηση των λεπτών σωματιδίων, όπως η σκόνη και ο καπνός.

Το φασματικό κανάλι 9 (Cirrus) καταγράφει το μήκος της ακτινοβολίας το οποίο απορροφάται σε πολύ μεγάλο βαθμό από το έδαφος. Οτιδήποτε εμφανίζεται στην εικόνα αντανακλά πολύ φωτεινά και βρίσκεται πάνω από το μεγαλύτερο μέρος της ατμόσφαιρας, καθιστώντας αυτό το κανάλι ικανό να καταγράφει τα σύννεφα.

Τέλος, το φασματικό Κανάλι 5 (Near Infrared (NIR)) μετράει το κοντινό υπέρυθρο. Αυτό το τμήμα του ηλεκτρομαγνητικού φάσματος είναι ιδιαίτερα σημαντικό για την οικολογία γιατί τα υγιή φυτά το

Landsat 8 Bands	Wavelength (micrometers)	Resolution (meters)
Band 1 - Coastal aerosol	0.43 - 0.45	30
Band 2 - Blue	0.45 - 0.51	30
Band 3 - Green	0.53 - 0.59	30
Band 4 - Red	0.64 - 0.67	30
Band 5 - Near Infrared (NIR)	0.85 - 0.88	30
Band 6 - SWIR (Shortwave Infrared) 1	1.57 - 1.65	30
Band 7 - SWIR (Shortwave Infrared) 2	2.11 - 2.29	30
Band 8 - Panchromatic	0.50 - 0.68	15
Band 9 - Cirrus	1.36 - 1.38	30
Band 10 - Thermal Infrared (TIRS) 1	10.60 - 11.19	100
Band 11 - Thermal Infrared (TIRS) 2	11.50 - 12.51	100

Πίνακας 3: Landsat8: Φασματικά κανάλια και ανάλυση εικόνων. (πηγή:usgs.gov)

ανακλούν [29]. Συγκρίνοντάς το με τα άλλα κανάλια, μπορούν να υπολογιστούν δείκτες όπως ο δείκτης βλάστησης (NDVI), τα οποία μας επιτρέπουν να μετρήσουμε τη βλάστηση με μεγάλη ακρίβεια, όπως αναφέρεται σε παρακάτω ενότητα.

Τα δεδομένα του Landsat 8 αλλά και όλων των παλιότερων δορυφόρων του προγράμματος είναι διαθέσιμα δωρεάν για το ευρύ κοινό από την αμερικανική υπηρεσία United States Geological Survey (USGS) [30]. Στα δεδομένα αυτά έχει πραγματοποιηθεί προεπεξεργασία και ατμοσφαιρικές διορθώσεις με εργαλεία και αλγόριθμους του USGS πριν διατεθούν στο κοινό.

3.4 Δείκτης Βλάστησης Κανονικοποιημένης Διαφοράς - Normalized Difference Vegetation Index (NDVI)

Όπως παρουσιάστηκε στην ενότητα 3.2.3 κάθε φασματική υπογραφή διαφέρει περισσότερο ή λιγότερο από άλλες, παρόμοιων ή μη αντικειμένων. Πολλές φορές επιλέγεται μέρος της φασματικής υπογραφής ώστε να εφαρμοστούν μετασχηματισμοί και να προκύψουν δείκτες οι οποίοι έχουν πιο περιεκτική πληροφορία και μπορούν να βοηθήσουν περαιτέρω στον διαχωρισμό των αντικειμένων.

Στην περίπτωση της βλάστησης, ένας τέτοιος δείκτης είναι ο Δείκτης Βλάστησης Κανονικοποιημένης Διαφοράς. Αυτός ο δείκτης χρησιμοποιήθηκε πρώτη φορά το 1974 [31] και έχει ως στόχο τον διαχωρισμό της βλάστησης από την φωτεινότητα του εδάφους. Αποτελεί τον πιο συχνά χρησιμοποιούμενο δείκτη βλάστησης παγκοσμίως.

Η σκέψη πίσω από τη χρήση του είναι πως όσο πιο υγιής και πιο πυκνή είναι η βλάστηση τόσο περισσότερη χλωροφύλλη υπάρχει. Επιπρόσθετα, η χλωροφύλλη απορροφά τις ακτινοβολίες του μπλε και του ερυθρού μέρους του φάσματος ενώ αντανακλά το πράσινο και το υπέρυθρο μέρος του [29]. Επομένως ο συνδυασμός του ερυθρού και του κοντινού υπέρυθρου περιέχει αρκετή πληροφορία σχετικά με την βλάστηση που υπάρχει στην εξεταζόμενη περιοχή.

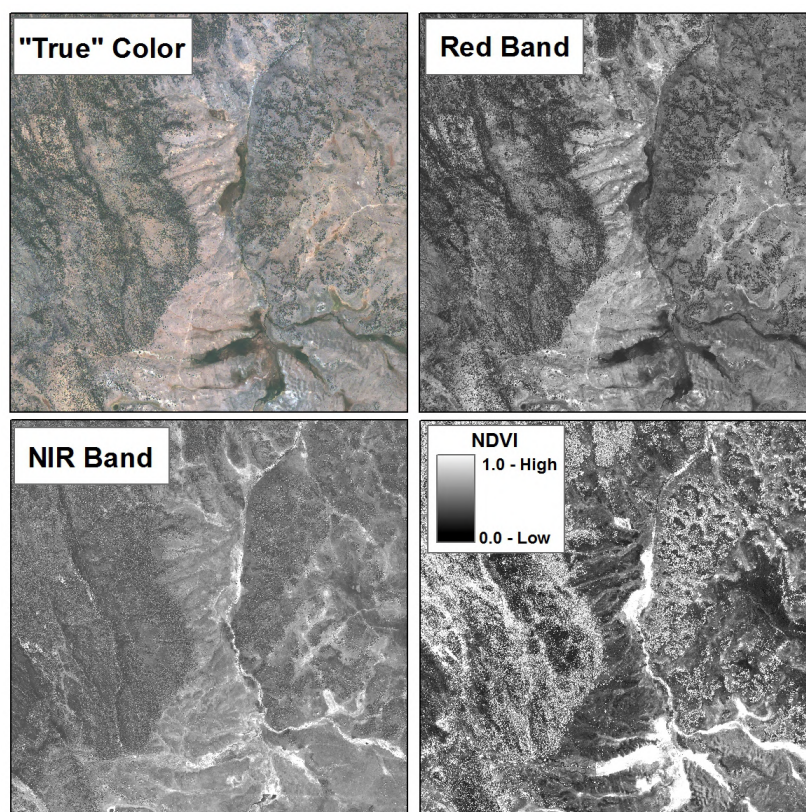
Ο μαθηματικός του τύπος είναι ο εξής:

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (3.2)$$

όπου *NIR* είναι η δορυφορική λήψη ακτινοβολίας του κοντινού υπέρυθρου (780nm - 2500nm) και *RED* είναι η δορυφορική λήψη ακτινοβολίας του ορατού κόκκινου (625nm - 740nm).

Στο σχήμα 16 οπτικοποιείται ο δείκτης και οι περιοχές του ερυθρού και του υπέρυθρου για μια περιοχή. Να σημειωθεί πως σε πολλές περιπτώσεις οι τιμές από -1 έως 0 δεν συμπεριλαμβάνονται στην ανάλυση καθώς το 0 αποτελεί το όριο ύπαρξης βλάστησης, όπως φαίνεται και στο σχήμα.

Στα πλεονεκτήματα του δείκτη είναι η ελαχιστοποίηση της επίδρασης της τοπογραφίας αλλά και ο εύκολος υπολογισμός του. Επιπλέον, είναι σχεδόν αναλλοίωτος από τις διάφορες ακραίες τιμές λόγω



Σχήμα 16: Δείκτης NDVI (πηγή: The Landscape Toolbox)

πιθανών ειδικών συνθηκών καθώς οι τιμές του είναι κανονικοποιημένες, με το εύρος τους να είναι από -1 έως και +1. Τέλος, περιγράφει πολλές ιδιότητες των φυτών με αποτέλεσμα να χρησιμεύει στην παρακολούθηση της υγείας τους, στην εκτίμηση της βιομάζας, στην απόδοση των καλλιεργειών κ.α.

Στα μειονεκτήματα του δείκτη είναι ότι παρουσιάζει δείγματα κορεσμού (saturation) σε πολύ υψηλές συγκεντρώσεις βλάστησης καθώς και υπερεκτίμηση σε χαμηλές συγκεντρώσεις βλάστησης εξαιτίας της ανακλαστικότητας του εδάφους. Επίσης, αποτελεί έναν μη γραμμικό μετασχηματισμό. Τέλος είναι ιδιαίτερα ευαίσθητος στη νεφοκάλυψη καθώς η ύπαρξη σύννεφων οδηγεί σε αλλοιωμένες τιμές του ή ακόμα και σε άχρηστες τιμές όταν δεν μπορεί να παρατηρηθεί το έδαφος. Στον πίνακα 4 φαίνεται η σχέση των τιμών του δείκτη NDVI με το είδος κάλυψης του εδάφους.

Κάλυψη εδάφους	NDVI
Μεγάλη πυκνότητα βλάστησης	0.500 - 1.000
Μέτρια πυκνότητα βλάστησης	0.140 - 0.500
Χαμηλή πυκνότητα βλάστησης	0.090 - 0.140
Γυμνό χόμα	0.025 - 0.090
Βαλτώδεις περιοχές/Υγρότοποι/Χιόνι/Σύννεφα	-0.046 - 0.025
Θάλασσα/Ποτάμια/Λίμνες	-1.000 - -0.046

Πίνακας 4: Χαρακτηριστικές τιμές NDVI (πηγή: JNRD)

Κεφάλαιο 4

Ερευνητική Εργασία

Η ταξινόμηση καρπών απαιτεί τη συγκέντρωση μεγάλου αριθμού δεδομένων για επεξεργασία και εξαγωγή κατάλληλων χαρακτηριστικών. Τα πολυφασματικά δορυφορικά δεδομένα είναι κατάλληλα για την ταξινόμηση μεγάλων καλλιεργήσιμων εκτάσεων. Ένα μειονέκτημα αυτών αποτελεί ο μεγάλος όγκος τους οδηγώντας σε σημαντικό πρόβλημα κατά την επεξεργασία τους, με αποτέλεσμα να παράγονται χρονοβόρες υλοποιήσεις με μεγάλες απαιτήσεις σε υπολογιστικούς πόρους. Επίσης, είναι σημαντική η εξαγωγή χαρακτηριστικών που να περιέχουν όσο το δυνατόν μεγαλύτερη πληροφορία σχετικά με το πρόβλημα, ώστε να είναι ικανά να διαχωρίσουν τα πρότυπα εισόδου στις αντίστοιχες κλάσεις με επιτυχία. Τέλος, η επιλογή κατάλληλων ταξινομητών είναι μείζονος σημασίας ώστε να μπορούν να εκμεταλλευτούν στο έπακρο την μορφή των δεδομένων και των χαρακτηριστικών τους για να καταλήξουν σε ακριβή αποτελέσματα.

4.1 Σχετικές Εργασίες

Μέχρι σήμερα έχουν πραγματοποιηθεί πολλές εργασίες για την ταξινόμηση του είδους κάλυψης της γης και ειδικότερα για ταξινόμηση καλλιεργούμενων καρπών, οι οποίες χρησιμοποιούν αλγόριθμους μηχανικής μάθησης αλλά και βαθιά μάθηση (Deep Learning). Στις διάφορες προσεγγίσεις χρησιμοποιούνται ευρέως διαδεδομένοι αλγόριθμοι και αρχιτεκτονικές αλλά και ειδικά σχεδιασμένες ή προσαρμοσμένες αρχιτεκτονικές.

Στις πιο επίκαιρες έρευνες έχουν επικρατήσει οι αλγόριθμοι Τυχαίων Δασών (Random Forest, RF), Μηχανών Διανυσματικής Υποστήριξης (Support Vector Machines, SVM) και k-Κοντινότερων Γειτόνων (k-Nearest Neighbours, k-NN). Τα αποτελέσματα που παράγουν είναι υψηλά [32] σε τέτοιου είδους προβλήματα καθιστώντας τους μια αξιόπιστη επιλογή. Πολλές φορές η χρήση αυτών των αλγόριθμων συνδυάζεται με άλλες προσεγγίσεις στην προεπεξεργασία των δεδομένων, όπως την επιλογή ειδικών χαρακτηριστικών δεικτών που καθιστούν τον διαχωρισμό των κλάσεων πιο εύκολο [33] ή τη μείωση των διαθέσιμων χαρακτηριστικών ώστε να είναι όσο δυνατό μικρότερο το υπολογιστικό κόστος χωρίς να χάνεται η ακρίβεια των αποτελεσμάτων [34]. Συγκρίνοντας τα αποτελέσματα, πολλές φορές, ο αλγόριθμος SVM δίνει τα καλύτερα ποσοστά, όπως φαίνεται από έρευνες που εξετάζουν τους προαναφερθέντες αλγόριθμους [32],[34],[35],[36].

Εκτός των αλγόριθμων μηχανικής μάθησης έχουν εξεταστεί και προσεγγίσεις βαθιάς μάθησης με χρήση νευρωνικών δικτύων. Η χρήση των Τεχνητών Νευρωνικών Δικτύων (Artificial Neural Networks, ANN) αν και επιφέρει σχετικά καλά αποτελέσματα δεν καταφέρει να ξεπεράσει τα ποσοστά επιτυχίας των προαναφερθέντων αλγόριθμων μηχανικής μάθησης [35],[37]. Επιπλέον, έχει ενδιαφέρον η αξιοποίηση των Συνελκτικών Νευρωνικών Δικτύων (Convolutional Neural Networks, CNN) με συνελίξεις μίας διάστασης (1-D) αλλά και δυο διαστάσεων (2-D). Η εφαρμογή μονοδιάστατων συνελίξεων δείχνει να παράγει καλύτερα αποτελέσματα τόσο από τους αλγόριθμους SVM και RF όσο και από υλοποιήσεις με Long Short-Term Memory (LSTM) και το αλγόριθμο XGBoost [38]. Σε μια άλλη έρευνα [37] η υλοποίηση συνελκτικού νευρωνικού δικτύου δύο διαστάσεων οδήγησε σε καλύτερα αποτελέσματα από την αντίστοιχη της μιας διάστασης.

Ιδιαίτερο ενδιαφέρον παρουσιάζουν υλοποιήσεις οι οποίες συνδυάζουν νευρωνικά δίκτυα δημιουργώντας ιδιαίτερες αρχιτεκτονικές. Για παράδειγμα, ο συνδυασμός Συνελκτικών Νευρωνικών Δικτύων (CNN) με Αναδρομικά Νευρωνικά Δίκτυα (Recursive Neural Networks, RNN) [39]. Σε τέτοιες υλοποιήσεις ο στόχος είναι να χρησιμοποιηθούν στο έπακρο οι ιδιότητες που παρουσιάζουν τα διαφορετικά δίκτυα, εξάγοντας την περισσότερη δυνατή πληροφορία. Τα αποτελέσματα της προαναφερθείσας έρευνας δείχνουν πως τέτοιες ειδικά σχεδιασμένες υλοποιήσεις είναι σε θέση να παράξουν καλύτερα αποτελέσματα από αλγόριθμους μηχανικής μάθησης και απλές υλοποιήσεις νευρωνικών δικτύων.

4.2 Σκοπός της Ευρενητικής εργασίας

Η παρούσα εργασία έχει ως στόχους την επιλογή ενός μικρού μέρους των διαθέσιμων δορυφορικών δεδομένων, την εξαγωγή λίγων, αλλά περιεκτικών σε πληροφορία, χαρακτηριστικών ώστε να είναι δυνατή η ταχεία επεξεργασία τους με κατάλληλους αλγόριθμους μηχανικής μάθησης, οδηγώντας εν τέλει στην αναγνώριση των καλλιεργούμενων καρπών με υψηλή ακρίβεια.

4.3 Υλικό και Μεθοδολογία

Τα δεδομένα που χρησιμοποιήθηκαν προέρχονται από τους δορυφόρους Sentinel-2 και Landsat 8 για την χρονιά 2019. Τα επιλεγμένα δορυφορικά δεδομένα επεξεργάστηκαν κατάλληλα και υπολογίστηκε ο δείκτης NDVI (4.3.3). Στη συνέχεια εξετάστηκαν δύο προσεγγίσεις όσον αφορά τη μορφή των τελικών δεδομένων εισόδου (εικονοστοιχεία εικόνας και ομαδοποίηση εικονοστοιχείων σε αντικείμενα). Τέλος, τα τελικά δεδομένα χρησιμοποιήθηκαν από αλγόριθμους ταξινόμησης μηχανικής μάθησης ώστε να παραχθούν αποτελέσματα και να αξιολογηθεί η διαδικασία επεξεργασίας που είχε επιλεγθεί.

Ο κώδικας που γράφτηκε για την επεξεργασία και παραγωγή αποτελεσμάτων ήταν σε γλώσσα Python. Χρησιμοποιήθηκε η βιβλιοθήκη scikit-learn [40] σε συνδυασμό με βιβλιοθήκες ειδικές για την επεξεργασία δεδομένων δορυφορικής τηλεπισκόπησης όπως οι gdal [41], rasterio [42] και rasterstats [43].

4.3.1 Δορυφορικά Δεδομένα

4.3.1.1 Δεδομένα Sentinel-2 και Landsat 8

Η επιλογή δεδομένων από τους συγκεκριμένους δορυφόρους έγινε καθώς:

- Είναι προσβάσιμα δωρεάν για το ευρύ κοινό και παρέχονται σε μορφή επεξεργασμένη ώστε να έχει εξαληφθεί ο θόρυβος των οργάνων, της ατμόσφαιρας ή άλλων παραγόντων.
- Έχουν πολύ καλή χωρική ανάλυση. Ειδικά ο Sentinel-2 με την ανάλυση των 10 μέτρων είναι ιδανικός για την αναγνώριση καλλιεργούμενων καρπών.
- Χρησιμοποιούνται σε πολλές παρόμοιες έρευνες καθιστώντας έτσι δυνατή την καλύτερη σύγκριση των αποτελεσμάτων [37],[35],[32].

Τα δεδομένα που συγκεντρώθηκαν αφορούσαν 3 περιοχές στις Ηνωμένες Πολιτείες Αμερικής για το έτος 2019. Οι περιοχές βρίσκονται στις πολιτείες Idaho (περιοχή 1), Arkansas (περιοχή 2) και North Dakota (περιοχή 3).

Area 1	Area 2	Area 3
42.4109 , -113.3706	34.3623 , -91.3302	47.9993 , -97.5793
42.2922 , -114.2264	35.1533 , -91.2820	48.6887 , -97.5962
42.7631 , -114.3521	35.1286 , -90.7026	48.6942 , -97.0020
42.8827 , -113.4906	34.3378 , -90.7567	48.0047 , -96.9913


Πίνακας 5: Συντεταγμένες σε δεκαδική μορφή για τις υπό εξέταση περιοχές.

Για λόγους που θα αναλυθούν σε επόμενη ενότητα επιλέχθηκαν εκτός των τριών βασικών περιοχών και από μια μικρότερη περιοχή η οποία βρίσκεται ολικώς ή μερικώς εντός των αρχικών περιοχών. Η τοπική εγγύτητα μεταξύ των βασικών περιοχών και των υποπεριοχών εξασφαλίζει την ομοιότητα των δεδομένων τους.


Area 1 reduced	Area 2 reduced	Area 3 reduced
42.4818 , -113.4613	34.5174 , -91.3102	47.8356 , -96.5456
42.4229 , -113.8892	34.8230 , -91.2916	47.8326 , -97.0669
42.7924 , -113.9860	34.7994 , -90.7387	48.1460 , -97.0721
42.8517 , -113.5559	34.4939 , -90.7594	48.1491 , -96.5482

Πίνακας 6: Συντεταγμένες σε δεκαδική μορφή για τις υπό εξέταση περιοχές.


Στα επόμενα σχήματα παρουσιάζονται οι περιοχές και οι υποπεριοχές που επιλέχθηκαν όπως καταγράφηκαν από τον δορυφόρο Sentinel-2.




Σχήμα 17: Περιοχή 1.




Σχήμα 18: Υποπεριοχή 1.




Σχήμα 19: Περιοχή 2.



Σχήμα 20: Υποπεριοχή 2.



Σχήμα 21: Περιοχή 3.



Σχήμα 22: Υποπεριοχή 3.

Χρησιμοποιώντας τις ιστοσελίδες παροχής των δορυφορικών δεδομένων που αναφέρθηκαν, για κάθε μια από τις περιοχές του πίνακα 5 συγκεντρώθηκαν χειροκίνητα λήψεις από ημερομηνίες που είχαν ποσοστό νεφοκάλυψης της εικόνας μικρότερο του 50%. Στις λήψεις αυτές συμπεριλαμβάνονταν και οι υποπεριοχές του πίνακα 6 καθώς όπως αναφέρθηκε αποτελούν υποσύνολα των αρχικών περιοχών. Με αυτόν τον τρόπο δημιουργήθηκαν χρονοσειρές δορυφορικών δεδομένων για κάθε περιοχή. Συγκεκριμένα, για κάθε περιοχή, για κάθε ημερομηνία υπήρχαν 11 ή 13 εικόνες (ανάλογα τον δορυφόρο παροχής των δεδομένων).

Το χρονικό διάστημα ανάμεσα σε δύο λήψεις δεν ήταν σταθερό καθώς δεν ήταν εφικτό να βρίσκονται πάντα καθαρές λήψεις καθ' όλη τη διάρκεια του έτους. Έγινε προσπάθεια το χρονικό αυτό διάστημα να μην είναι μικρότερο των 5 ημερών και μεγαλύτερο των 20 ημερών, ειδικά κατά την περίοδο Απριλίου-Οκτωβρίου. Τους μήνες Νοέμβρη έως Μάρτη, από τη μία λόγω καιρικών συνθηκών από την άλλη λόγω απουσίας καρπών στα αγροτεμάχια, το χρονικό διάστημα ανάμεσα από δύο συνεχόμενες λήψεις ήταν μεγαλύτερο ενώ σε κάποιες περιπτώσεις μπορεί να μην υπήρχε διαθέσιμη λήψη για μερικούς μήνες.

Οι περισσότεροι καλοκαιρινοί καρποί (με τους οποίους ασχολείται η παρούσα εργασία) τους πρώτους μήνες του έτους δεν έχουν ακόμα φυτευτεί ενώ κατά τους τελευταίους μήνες του έτους έχουν συγκεντρωθεί με αποτέλεσμα τα αγροτεμάχια να είναι άδεια. Επομένως, αυτή η έλλειψη δεδομένων κατά τους χειμερινούς μήνες δεν αποτελεί πρόβλημα καθώς αυτοί οι μήνες συνήθως δεν

φέρουν ουσιαστική πληροφορία για τους καρπούς της χρονιάς.

Από τους δύο δορυφόρους ως βασικός επιλέχθηκε ο Sentinel-2, ενώ από τον Landsat 8 χρησιμοποιήθηκαν ημερομηνίες για να καλύψουν μεγάλα κενά σε συνεχόμενες λήψεις του βασικού δορυφόρου. Οι ημερομηνίες που έχουν επιλεχθεί ανά περιοχή φαίνονται στον πίνακα 7.

Area 1		Area 2		Area 3	
Sentinel-2	Landsat 8	Sentinel-2	Landsat 8	Sentinel-2	Landsat 8
31/01		21/01		16/04	
	04/03	17/03		26/04	
15/03		22/03		16/05	
30/03		27/03			02/06
19/04		06/04			18/06
04/05		16/04		30/06	
14/05		21/04		10/07	
31/05		26/04		20/07	
05/06		06/05		30/07	
10/06		16/05			05/08
15/06		31/05		14/08	
	24/06	10/06		19/08	
	10/07	25/06		24/08	
12/08			03/07	29/08	
17/08		20/07			06/09
27/08			04/08		22/09
01/09		14/08		28/09	
	12/09	19/08			08/10
18/09		29/08			24/10
06/10			05/09		
	14/10	18/09			
	30/10	28/09			
07/11		08/10			
15/11		13/10			
		18/10			
		23/10			
		12/11			
		27/11			
Σύνολο: 24		Σύνολο: 28		Σύνολο: 19	

Πίνακας 7: Ημερομηνίες χρονοσειρών για κάθε περιοχή.

Η ύπαρξη δύο διαφορετικών αναλύσεων εικόνων (Sentinel-2: 10 μέτρα, Landsat 8: 30 μέτρα) δημιουργεί πρόβλημα κατά την κοινή επεξεργασία. Για το λόγο αυτό, επιλέχθηκε η μεγαλύτερη ανάλυση εικόνας και πραγματοποιήθηκε υπερδειγματοληψία των εικόνων ανάλυσης 30 μέτρων του Landsat 8 ώστε να ταυτιστούν με αυτές των 10 μέτρων Sentinel-2. Στον πίνακα 8 αναγράφονται τα μεγέθη των λήψεων για κάθε περιοχή και υποπεριοχή καθώς και ο συνολικός αριθμός των εικονοστοιχείων.

Τα αρχεία τα οποία χρησιμοποιήθηκαν διατίθονταν σε μορφή GeoTIFF (αρχείο εικόνας με ενσωματωμένο σύστημα συντεταγμένων) (Landsat 8) και JPEG 2000 (Sentinel-2). Για την επεξεργασία τους τα δεδομένα του Sentinel-2 μετατράπηκαν σε GeoTIFF με τη χρήση του προγράμματος γεωπληροφορικής QGIS [44], του οποίου η λήψη και η χρήση είναι δωρεάν. Κατά την μετατροπή δεν παρουσιάστηκε κάποια αλλαγή στις αριθμητικές τιμές των αρχείων. Ως σύστημα συντεταγμένων χρη-

	Area 1	Sub-Area 1	Area 2	Sub-Area 2	Area 3	Sub-Area 3
Image size	5982 x 7082	2988 x 5554	5472 x 8522	5247 x 3295	4235 x 7965	3764 x 3627
Total pixels	42.364.524	16.595.352	46.632.384	17.288.865	33.731.775	13.652.028
Area km²	3822.9	1495.4	4644	1720	3357	1360

Πίνακας 8: Μέγεθος εικόνων και αριθμός εικονοστοιχείων.


σιμοποιήθηκε το EPSG:5070 - NAD83 / Conus Albers και όσα αρχεία ήταν σε διαφορετικό σύστημα προβλήθηκαν σε αυτό μέσω του προγράμματος QGIS.

4.3.1.2 Δεδομένα Ετικετών

Τα δεδομένα ετικετών που χρησιμοποιήθηκαν λήφθηκαν από την πλατφόρμα CropScape [45] του Υπουργείου Γεωργίας των Ηνωμένων Πολιτειών της Αμερικής. Αυτά τα δεδομένα είναι δωρεάν για το ευρύ κοινό, γίνονται διαθέσιμα κάθε Ιανουάριο μήνα και αναφέρονται στο προηγούμενο έτος.

Στην πλατφόρμα αυτή παρέχεται ένας χάρτης κάλυψης Γης των Ηνωμένων Πολιτειών Αμερικής με ανάλυση 30m. Κάθε εικονοστοιχείο του χάρτη αντιστοιχίζεται σε μια κατηγορία κάλυψης Γης όπως δάσος, ποτάμι, ανθρώπινο περιβάλλον, καλλιέργειες κ.α. Το γεγονός που καθιστά αυτήν την πλατφόρμα χρήσιμη είναι πως η κατηγορία των καλλιεργειών χωρίζεται σε επιμέρους κατηγορίες καλλιεργούμενων καρπών. Έτσι, είναι δυνατή η απόκτηση των δεδομένων ετικετών για το είδος του καρπού που καλλιεργείται σε ολόκληρη τη χώρα.

Στο σχήμα 23 φαίνεται η ακριβής μορφή των δεδομένων που παρέχει η πλατφόρμα CropScape. Τα διάφορα χρώματα της εικόνας αποτελούν την κατηγορία κάλυψης Γης του εικονοστοιχείου. Για παράδειγμα, τα γκρι εικονοστοιχεία στο κέντρο της εικόνας αντιστοιχούν σε ανθρώπινο περιβάλλον (κτήρια, δρόμοι κ.α.), τα μπλε αντιστοιχούν σε υγρούς παράγοντες όπως ποτάμια, λίμνες και θάλασσα, τα κόκκινα αντιστοιχούν στον καρπό βαμβάκι, τα κίτρινα στον καρπό καλαμπόκι κ.λπ.




Σχήμα 23: Παράδειγμα κάλυψης Γης (πηγή:CropScape)


Επίσης, παρέχονται αρχεία που περιέχουν μόνο τα εικονοστοιχεία ενός καρπού σε μια επιλεγμένη περιοχή. Στα σχήματα 24 και 25 έχουν απομονωθεί από το προηγούμενο σχήμα μόνο οι καρποί βαμβάκι και καλαμπόκι αντίστοιχα.

Μπορεί κανείς να παρατηρήσει πιο εύκολα σε αυτές τις εικόνες αρκετά εικονοστοιχεία τα οποία εσφαλμένα ανήκουν σε αυτούς τους καρπούς. Για παράδειγμα, στις εικόνες υπάρχουν μεμονωμένα εικονοστοιχεία τα οποία προκύπτουν λόγω σφαλμάτων ταξινόμησης των αλγόριθμων της πλατφόρμας

και όχι επειδή υπάρχει καλλιέργεια σε εκείνο το σημείο. Επιπλέον, τα αγροτεμάχια της εικόνας είναι αρκετά ευδιάκριτα για κάθε καρπό, όμως μπορεί κανείς να παρατηρήσει ότι σε κάποιες περιπτώσεις εμφανίζονται περιγράμματα εικονοστοιχείων γύρω από τη θέση αγροτεμαχίων άλλων καρπών. Αυτό φαίνεται εύκολα στα κυκλικά αγροτεμάχια των εικόνων όπου εμφανίζονται μερικοί διακεκομμένοι κύκλοι με άδειο το εσωτερικό τους. Αυτό αποτελεί πάλι σφάλμα ταξινόμησης από την πλατφόρμα.



Σχήμα 24: Καρπός βαμβάκι (πηγή:Cropscape)



Σχήμα 25: Καρπός καλαμπόκι (πηγή:Cropscape)

Στις πληροφορίες που παρέχει η πλατφόρμα για μια επιλεγμένη περιοχή περιέχεται και ο αριθμός των εικονοστοιχείων που ανήκουν σε κάθε κλάση καρπών. Στον πίνακα 9 αναγράφονται αυτά τα μεγέθη κατά φθίνουσα σειρά ως προς τον αριθμό των εικονοστοιχείων. Η επιλογή των καρπών του πίνακα (υπό εξέταση καρποί) έγινε με βάση τον αριθμό των εικονοστοιχείων που τους αντιστοιχούσαν με σκοπό να είναι όσο πιο ισορροπημένες γίνεται, αλλά ταυτόχρονα να είναι ικανοποιητικός ο αριθμός αυτός για να γίνει σωστή εκπαίδευση των μοντέλων.

Η μορφή των αρχείων που προσφέρει η πλατφόρμα CropScape είναι GeoTIFF και πραγματοποιήθηκε υπερδειγματοληψία ώστε να ταυτιστεί η ανάλυση των αρχείων με αυτή των δορυφορικών

Περιοχή 1		Υποπεριοχή 1	
Καρπός	# Εικονοστοιχείων	Καρπός	# Εικονοστοιχείων
Αλφάλφα	588.601	Αλφάλφα	295.529
Κριθάρι	419.012	Κριθάρι	216.988
Ζαχαροκάλαμο	342.551	Ζαχαροκάλαμο	200.217
Πατάτες	270.633	Πατάτες	156.834
Καλαμπόκι	267.480	Σιτάρι	81.709
Σιτάρι	143.240	Καλαμπόκι	77.598

Περιοχή 2		Υποπεριοχή 2	
Καρπός	# Εικονοστοιχείων	Καρπός	# Εικονοστοιχείων
Σόγια	1.486.378	Σόγια	561.914
Καλαμπόκι	555.177	Καλαμπόκι	258.569
Ρύζι	488.370	Βαμβάκι	247.735
Βαμβάκι	480.685	Ρύζι	150.078

Περιοχή 3		Υποπεριοχή 3	
Καρπός	# Εικονοστοιχείων	Καρπός	# Εικονοστοιχείων
Σιτάρι	1.060.795	Σιτάρι	463.135
Σόγια	765.059	Σόγια	369.219
Ζαχαροκάλαμο	393.035	Ζαχαροκάλαμο	210.404
Φασόλια ξερά	354.898	Φασόλια ξερά	116.499
Καλαμπόκι	216.339	Καλαμπόκι	97.123

Πίνακας 9: Εξεταζόμενοι καρποί ανά περιοχή και ο αριθμός των εικονοστοιχείων που τους αντιστοιχούν

εικόνων της προηγούμενης ενότητας.

Ο συνδυασμός των δεδομένων των Sentinel-2 και Landsat 8 με τα δεδομένα της πλατφόρμας CropScare δημιούργησε για κάθε εξεταζόμενη περιοχή τα ζεύγη τιμών εισόδου-εξόδου που απαιτούνται στην επιβλεπόμενη μηχανική μάθηση, όπως αναφέρθηκε στην ενότητα 2.2.1.


4.3.2 Νεφοκάλυψη και καθαρισμός δεδομένων

Ένα άμεσο πρόβλημα που αντιμετωπίζουν τα πολυφασματικά δορυφορικά δεδομένα είναι η ύπαρξη νεφοκάλυψης κατά την λήψη των μετρήσεων από τους αισθητήρες. Τα σύννεφα είναι αδιαπέραστα από την φασματική ακτινοβολία με αποτέλεσμα να μην μπορούν να ληφθούν οι πραγματικές τιμές του εδάφους. Το ίδιο ισχύει και για την σκιά των συννέφων καθώς επίσης επηρεάζει την ανακλώμενη ακτινοβολία από το έδαφος. Οι τιμές οι οποίες καταγράφονται από τους αισθητήρες είναι τελείως διαφορετικές από τις πραγματικές, κάτι το οποίο αποτελεί πρόβλημα όταν κανείς τις εισάγει στο μοντέλο του για να το εκπαιδεύσει. Στο σχήμα 26 φαίνεται μια μέτρια νεφοκάλυψη, η οποία αποκρύπτει μέρος των δεδομένων που μπορούν να ληφθούν από το έδαφος.

Η εμφάνιση νεφοκάλυψης είναι τυχαία και δεν μπορεί να αποφευχθεί με κάποιο τρόπο από τους δορυφόρους καθώς η τροχιά τους είναι συγκεκριμένη και δεν μπορεί να αλλάξει. Ανάλογα την περιοχή το πρόβλημα αυτό μπορεί να είναι περισσότερο ή λιγότερο έντονο, κάτι που εξαρτάται από το κλίμα που επικρατεί και την εποχή στην οποία γίνεται η λήψη. Για παράδειγμα σε πιο βόρειες περιοχές είναι πιο συχνή η εμφάνισή της σε σχέση με πιο νότιες περιοχές, ενώ αντίστοιχα τους φθινοπωρινούς και χειμερινούς μήνες εμφανίζονται σύννεφα με μεγαλύτερο ρυθμό και παραμένουν για μεγαλύτερη διάρκεια στην ατμόσφαιρα.

Η αντιμετώπισή του προβλήματος αυτού είναι απαραίτητη ώστε τα συλλεγμένα δεδομένα εισόδου να είναι καλής ποιότητας. Μια προσέγγιση είναι η χρήση δεδομένων από επιπλέον δορυφόρους με


την ελπίδα να υπάρχουν καθαρές λήψεις κοντά στην επιθυμητές ημερομηνίες. Ακόμα και μερικές μέρες νωρίτερα ή αργότερα μπορεί να είναι αρκετές ώστε να έχει καθαρίσει η ατμόσφαιρα. Αυτή η προσέγγιση εφαρμόστηκε στην παρούσα εργασία με τη χρήση λήσεων από τον δορυφόρο Landsat 8 όταν δεν υπήρχαν καθαρές λήψεις από τον βασικό δορυφόρο Sentinel-2. Ακόμα και με δεδομένα από περισσότερους δορυφόρους είναι πιθανό να μην μπορούν να βρεθούν τελείως καθαρές λήψεις για μεγάλα χρονικά διαστήματα λόγω ύπαρξης μικρής έως μέτριας νεφοκάλυψης.



Σχήμα 26: Νεφοκάλυψη από λήψη Sentinel-2. (πηγή:USGS)

Μια άλλη προσέγγιση είναι η ανοχή σε μερική νεφοκάλυψη στις λήψεις και η προσπάθεια συμπλήρωσης των ελλειπών τιμών της εικόνας λόγω των σύννεφων. Στις περιπτώσεις που τα σύννεφα καταλαμβάνουν πλήρως ή σε μεγάλο βαθμό την εικόνα δεν είναι εφικτή η συμπλήρωση των ελλειπών τιμών με αρκετά ακριβείς τιμές. Στις άλλες περιπτώσεις όμως είναι δυνατή η συμπλήρωση χρησιμοποιώντας υπάρχουσες πληροφορίες.

Για να γίνει η συμπλήρωση με βάση τις υπάρχουσες πληροφορίες το πρώτο βήμα είναι ο καθορισμός των καθαρών και μη εικονοστοιχείων. Αυτό γίνεται με την ανίχνευση των νεφών και των σκιών τους και την δημιουργία ενός αρχείου ποιότητας των εικονοστοιχείων, το οποίο έχει αντιστοιχία ένα προς ένα με τα εικονοστοιχεία της αρχικής εικόνας. Σε αυτό το αρχείο-μάσκα (mask file) ανατίθενται τιμές στα εικονοστοιχεία που αντιστοιχούν στο είδος της ποιότητας των αντιστοιχών εικονοστοιχείων της αρχικής εικόνας. Για παράδειγμα, η τιμή **0** αντιστοιχεί σε καθαρό εικονοστοιχείο, η τιμή **1** σε παρουσία σκιάς σύννεφου και η τιμή **2** σε παρουσία σύννεφου. Στο σχήμα 27 φαίνεται το αρχείο-μάσκα της προηγούμενης εικόνας. Στη συνέχεια η τιμή των εικονοστοιχείων με ελλιπείς τιμές αντικαθίσταται με έναν πολύ αρνητικό αριθμό (αρκετά μεγαλύτερος από το φυσιολογικό εύρος τιμών των δεδομένων) ώστε να έχουν όλα την ίδια τιμή ώστε να είναι πιο εύκολος ο εντοπισμός τους και η επεξεργασία τους.



Σχήμα 27: Αρχείο-μάσκα από Fmask 4.0 σε εικόνα Sentinel-2.

Όπως φαίνεται και στο προηγούμενο σχήμα τα αρχεία-μάσκες είναι απαραίτητα αρχεία για τον καθαρισμό των ελλিপών τιμών. Η ακρίβεια τους δεν είναι πάντα η βέλτιστη καθώς μπορεί να επεκτείνουν τα όρια των σύννεφων ή των σκιών τους περιλαμβάνοντας και καθαρά εικονοστοιχεία. Αυτό φαίνεται συγκρίνοντας τα σχήματα 26 και 27. Όταν συμβαίνει σε μικρό βαθμό δεν αποτελεί πρόβλημα καθώς από τη μία είναι σίγουρο ότι έχουν συμπεριληφθεί πλήρως στο αρχείο-μάσκα τα εικονοστοιχεία με ελλιπείς τιμές και από την άλλη ο αριθμός των καθαρών στοιχείων που χάνονται λόγω της μάσκας είναι λίγα σε σχέση με τα υπόλοιπα. Συνήθως, οι πάροχοι δορυφορικών δεδομένων συμπεριλαμβάνουν τέτοια αρχεία ποιότητας εικόνας.

Στα δεδομένα των δύο δορυφόρων που χρησιμοποιήθηκαν υπήρχαν αυτά τα αρχεία, όμως, έγινε χρήση μόνο του αρχείου-μάσκα του δορυφόρου Landsat 8 καθώς το αντίστοιχο του Sentinel-2 δεν είχε ικανοποιητική ποιότητα. Στη θέση αυτού έγινε χρήση του αλγορίθμου εντοπισμού σύννεφων Fmask 4.0 Qiu, Zhu και He [46]. Το σχήμα 27 είναι αποτέλεσμα αυτού του αλγορίθμου.

Εφόσον υπάρχει ένα αρχείο που καθορίζει την ποιότητα των εικονοστοιχείων της εικόνας το επόμενο βήμα είναι η συμπλήρωση των ελλিপών τιμών εξαιτίας της νεφοκάλυψης.

Στην παρούσα εργασία εξετάστηκαν δύο προσεγγίσεις:

1. **Χωρική συμπλήρωση:** Σε αυτή την περίπτωση χρησιμοποιήθηκαν τα καθαρά εικονοστοιχεία της υπό εξέταση εικόνας. Πιο συγκεκριμένα σε κάθε εικόνα και για κάθε έναν από τους εξεταζόμενους καρπούς:

- συνδυάστηκε το αρχείο-μάσκα με το αρχείο ετικετών ώστε να βρεθούν τα καθαρά εικονοστοιχεία του συγκεκριμένου καρπού,
- υπολογίστηκε η μέση τιμή και η διασπορά αυτών των εικονοστοιχείων,
- δημιουργήθηκε μια Γκαουσιανή κατανομή με την υπολογισμένη μέση τιμή και διασπορά,
- ανατέθηκε σε κάθε εικονοστοιχείο με ελλιπή τιμή μια τυχαία τιμή από την γκαουσιανή κατανομή.

Η μέθοδος αυτή είχε ως στόχο την αξιοποίηση της διαθέσιμη χωρικής πληροφορίας. Η λογική πίσω από αυτή την προσέγγιση ήταν πως όλοι οι καρποί μιας περιοχής έχουν τα ίδια χαρακτηριστικά. Επομένως, ακόμα και αν εξαιτίας νεφοκάλυψης δεν υπήρχε πρόσβαση στις τιμές ορισμένων καρπών της εικόνας, υπήρχε η δυνατότητα να αναπαραχθούν οι τιμές αυτές με βάση τους γειτονικούς καρπούς.

2. **Χρονική συμπλήρωση:** Σε αυτή την περίπτωση χρησιμοποιήθηκαν τα εικονοστοιχεία της αμέσως προηγούμενης και αμέσως επόμενης χρονικά λήψης. Για κάθε έναν από τους εξεταζόμενους καρπούς:

- συνδυάστηκε το αρχείο-μάσκα με το αρχείο ετικετών ώστε να βρεθούν τα εικονοστοιχεία με ελλιπείς τιμές του συγκεκριμένου καρπού,
- υπολογίστηκε ο μέσος όρος για κάθε εικονοστοιχείο με ελλιπή τιμή χρησιμοποιώντας την αμέσως προηγούμενη και αμέσως επόμενη χρονικά λήψη .

Η πρώτη και η τελευταία λήψη στην περίπτωση που είχαν νεφοκάλυψη δέχονταν επεξεργασία με την χωρική μέθοδο καθώς δεν υπήρχε προηγούμενη και επόμενη λήψη αντίστοιχα για τον υπολογισμό του μέσου όρου.

Στην ειδική περίπτωση όπου υπήρχαν δύο συνεχόμενες λήψεις με νεφοκάλυψη και υπήρχαν πάνω από τα ίδια εικονοστοιχεία σύννεφα ο μέσος όρος έπαιρνε μια επίσης μεγάλη αρνητική τιμή, καθώς τουλάχιστον ένας από τους δύο αριθμούς που χρησιμοποιούνταν για τον υπολογισμό του ήταν πολύ αρνητικός. Για την πλήρη εξάλειψη των λίγων αρνητικών τιμών, που υποδήλωναν ελλιπή, δεδομένα εφαρμοζόταν η χωρική συμπλήρωση αμέσως μετά το τέλος της χρονικής συμπλήρωσης.

Η μέθοδος αυτή είχε ως σκοπό την αξιοποίηση της διαθέσιμης χρονικής πληροφορίας. Η λογική πίσω από αυτή την προσέγγιση ήταν πως ανάμεσα σε δύο συνεχόμενες λήψεις δεν θα έχει αλλάξει σημαντικά η μορφή του καρπού και κατ' επέκταση οι ανιχνευόμενες τιμές από τα όργανα του δορυφόρου. Όσο λιγότερες μέρες απέχουν οι λήψεις τόσο πιο λιγότερες αλλαγές έχουν γίνει στον καρπό. Στην ειδική, επίσης, περίπτωση που έχει γίνει συγκομηδή των καρπών σε κάποια από τις χρησιμοποιούμενες λήψεις αυτή η μέθοδος δεν δίνει πάλι καλή προσέγγιση, ειδικά αν το φυτό του καρπού έχει ξεριζωθεί και έχει μείνει γυμνό έδαφος.

Η δεύτερη συμπλήρωση με την χωρική μέθοδο δεν επηρέαζε σχεδόν καθόλου την χρονική φύση αυτής της προσέγγισης καθώς η χρήση της γινόταν σε σπάνιες περιπτώσεις που υπήρχαν τουλάχιστον δύο συνεχόμενες λήψεις με νεφοκάλυψη και τα σύννεφα βρίσκονταν πάνω από τα ίδια εικονοστοιχεία. Ακόμα και όταν εφαρμοζόταν τα περισσότερα εικονοστοιχεία με ελλειπίς τιμές είχαν συμπληρωθεί με το πρώτο πέρασμα της χρονικής μεθόδου.

Για την σύγκριση των παραπάνω μεθόδων πραγματοποιήθηκαν μετρήσεις με τους εξής τρόπους:


- Χωρίς καμία μέθοδο συμπλήρωσης ελλিপών τιμών.
- Συμπλήρωση με τη χρονική μέθοδο.
- Συμολήρωση με τη χωρική μέθοδο.

4.3.3 Εξαγωγή Χαρακτηριστικών

Καθώς ο σκοπός ήταν να υλοποιηθεί μια μέθοδος που θα χρησιμοποιεί όσο το δυνατόν λιγότερα χαρακτηριστικά ώστε να είναι μικρό το κόστος επεξεργασίας, αξιοποιήθηκαν μόνο δύο φασματικά κανάλια των διαθέσιμων δορυφόρων για τον υπολογισμό του δείκτη NDVI, όπως αναφέρθηκε στην ενότητα . Επομένως, οι χρονοσειρές που αρχικά είχαν δημιουργηθεί για κάθε ημερομηνία λήψης με 11 ή 13 εικόνες (ανάλογα το δορυφόρο) πλέον είχαν μόνο μία εικόνα για κάθε ημερομηνία, αυτή του NDVI. Με αυτόν τον τρόπο, για κάθε περιοχή το κάθε εικόστοιχείο είχε τόσα χαρακτηριστικά όσα και οι ημερομηνίες που είχαν επιλεγεί, τα οποία χαρακτηριστικά αντιστοιχούσαν στην τιμή του δείκτη NDVI εκείνη την ημερομηνία.

Με αυτό τον τρόπο σχηματίζονταν για κάθε καρπό μια γραφική παράσταση της βλάστησης του, η οποία λειτουργούσε σαν ταυτότητα με την οποία ήταν δυνατό να διαχωριστούν οι καρποί. Στο σχήμα 28 φαίνονται αυτές οι γραφικές παραστάσεις για τους καρπούς της περιοχής 3, έχοντας πάρει το μέσο όρο όλων των εικονοστοιχείων του κάθε καρπού για την κάθε ημερομηνία. Οι συγκεκριμένες γραφικές παραστάσεις έχουν προκύψει χωρίς κάποια μέθοδο συμπλήρωσης ελλিপών τιμών. Η κλάση Rest περιλαμβάνει όλους τους υπόλοιπους καρπούς που ήταν στην περιοχή αλλά δεν επιλέχθηκαν για ταξινόμηση.

Απο το σχήμα φαίνεται πως υπάρχουν διαφορές στις γραφικές παραστάσεις που καθιστούν δυνατή τη διαχώριση των καρπών. Για παράδειγμα, η κόκκινη γραμμή που αντιστοιχεί στο σιτάρι έχει αρκετά διαφορετική μορφή από την πράσινη που αντιστοιχεί στη σόγια. Βέβαια, είναι φανερό πως κάποιες γραφικές παραστάσεις μοιάζουν αρκετά μεταξύ τους όπως φαίνεται από την πράσινη γραμμή και τη μωβ (ζαχαροκάλαμο). Σε αυτές τις περιπτώσεις αναμένεται να μην υπάρχει τόσο καλός διαχωρισμός των δυο κλάσεων. Ένας λόγος που σε ορισμένες ημερομηνίες υπάρχει μεγάλη ομοιότητα στις παραστάσεις είναι η πιθανή νεφοκάλυψη του μεγαλύτερου μέρους των συγκεκριμένων καρπών, με αποτέλεσμα να επικρατεί η τιμή των σύννεφων αντί των πραγματικών τιμών.



Σχήμα 28: Παραστάσεις-ταυτότητες καρπών με τον δείκτη NDVI.

4.3.4 Μέθοδοι ορισμού προτύπων (Εικονοστοιχεία, Αντικείμενα)

Έχοντας καθορίσει τα χαρακτηριστικά που θα χρησιμοποιηθούν το επόμενο βήμα ήταν ο καθορισμός της μορφής των προτύπων που θα τροφοδοτούνταν στους αλγορίθμους. Χρησιμοποιήθηκαν δύο προσεγγίσεις τα εικονοστοιχεία και τα αντικείμενα.

4.3.4.1 Εικονοστοιχεία

Η πρώτη προσέγγιση ήταν η χρήση των εικονοστοιχείων ως πρότυπα. Με αυτή την προσέγγιση ήταν δυνατή η εκπαίδευση του μοντέλου να ξεχωρίζει τους καρπούς τόσο σε σχέση με άλλους καρπούς που δεν είχαν επιλεγεί αλλά και σε σχέση με τα υπόλοιπα είδη κάλυψης της επιφάνειας της Γης (νερό, δάσος, ανθρώπινο τεχνητό περιβάλλον) χωρίς να χρειάζεται να απομονωθούν τα εικονοστοιχεία των εξεταζόμενων καρπών και να εκπαιδευτεί το μοντέλο μόνο σε αυτά.

Το μειονέκτημα αυτής της προσέγγισης ήταν ο μεγάλος όγκος δεδομένων εισόδου που προέκυπτε. Όπως φαίνεται και από τον πίνακα 8 ο αριθμός των εικονοστοιχείων φτάνει έως τα 46 εκατομμύρια οδηγώντας σε χρονοβόρες εκπαιδεύσεις και σε προβλήματα με τους υπολογιστικούς πόρους. Γι αυτό τον λόγο χρησιμοποιήθηκαν οι υποπεριοχές των οποίων ο αριθμός των εικονοστοιχείων είναι κάτω από 20 εκατομμύρια.

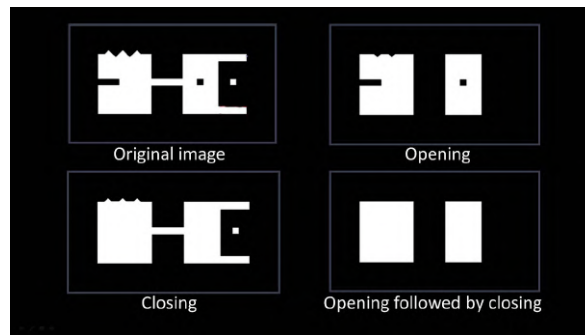
Μια άλλη πιθανή λύση στο πρόβλημα αυτό θα ήταν να εξεταστεί ακόμα μικρότερη περιοχή. Όμως, με αυτόν τον τρόπο χάνεται πληροφορία που μπορεί να συγκεντρωθεί από πολλά διαφορετικά αγροτεμάχια των ίδιων καρπών και εστιάζεται η προσοχή σε λίγα υπάρχοντα. Ακόμα και έτσι όμως, τα εικονοστοιχεία της εικόνας θα ήταν ένας αρκετά μεγάλος αριθμός.

Άλλη πιθανή λύση είναι η χρήση μεθόδων υποδειγματοληψίας των δεδομένων εισόδου ώστε να μειωθεί ο αριθμός τους. Στην περίπτωση της τυχαίας επιλογής μέρους των δεδομένων εισόδου είναι πιθανό να μη συμπεριληφθούν δείγματα τα οποία έχουν ουσιαστική πληροφορία βοηθώντας στην καλύτερη ταξινόμηση και στην θέση τους να επιλεγθούν θορυβώδη δείγματα. Στην περίπτωση των πιο εξειδικευμένων αλγορίθμων υποδειγματοληψίας εμφανίζεται εκ νέου το πρόβλημα του μεγάλου αριθμού προτύπων, οδηγώντας σε χρονοβόρες διαδικασίες οι οποίες αδυνατούν να δώσουν και τελικό αποτέλεσμα.

4.3.4.2 Αντικείμενα


Η δεύτερη προσέγγιση ήταν η δημιουργία αντικειμένων μέσα στην υπο εξέταση εικόνα ομαδοποιώντας εικονοστοιχεία. Η μέθοδος αυτή είχε ως σκοπό να εκμεταλευτεί την ιδιότητα των καλλιεργούμενων καρπών να οργανώνονται σε αγροτεμάχια. Ο διαχωρισμός των καρπών γινόταν τόσο ανάμεσα στους υπό εξέταση καρπούς όσο και στους μη επιλεγμένους καρπούς της περιοχής οι οποίοι ομαδοποιήθηκαν σε μία κατηγορία (Λοιπά αγροτεμάχια). Με αυτή τη σκέψη ορίστηκαν ως αντικείμενα τα υπάρχοντα αγροτεμάχια στην εικόνα τα οποία αποτέλεσαν και τα δεδομένα εισόδου.

Για την εύρεσή τους αξιοποιήθηκαν τα δεδομένα ετικετών για τους μεμονομένους καρπούς (σχήματα 24, 25). Για να αντιμετωπιστούν τα εσφαλμένα εικονοστοιχεία που αναφέρθηκαν στην 4.3.1.2 εφαρμόστηκαν στις εικόνες διαδοχικά οι μέθοδοι του μορφολογικού ανοίγματος και κλεισίματος. Οι διαδοχική εφαρμογή τους εξαλείφει τα μεμονωμένα εικονοστοιχεία και εξομαλύνει τα σχήματα της εικόνας με την ίδια λογική που φαίνεται στο σχήμα 29.




Σχήμα 29: Μορφολογικό άνοιγμα ακολουθούμενο από μορφολογικό κλείσιμο. (πηγή:Udacity)

Ταυτόχρονα ήταν δυνατή η επιλογή ή η απόρριψη ομάδων γειτονικών εικονοστοιχείων που δεν ξεπερνούσαν έναν αριθμό κατώφλιου. Έτσι, αν υπήρχαν μερικά γειτονικά εσφαλμένα εικονοστοιχεία τα οποία δεν εξαφανίζονταν από την μορφολογική επεξεργασία τότε το ορισμένο κατώφλι λειτουργούσε ως φίλτρο ξεκαθαρίσματος. Ύστερα από πολλές δοκιμές το κατώφλι ορίστηκε στα 1000 εικονοστοιχεία. Στην εικόνα 30 φαίνεται η αρχική εικόνα ενός καρπού η οποία περιέχει και εσφαλμένα εικονοστοιχεία και στην εικόνα 31 το αποτέλεσμα μετά την επεξεργασία.



Σχήμα 30: Αρχική εικόνα με εσφαλμένα εικονοστοιχεία.



Σχήμα 31: Εικόνα μετά την μορφολογική επεξεργασία.

Φαίνεται από τη δεύτερη εικόνα πως πολλά εικονοστοιχεία τα οποία θα αποτελούσαν θόρυβο έχουν εξαφανιστεί και είναι πιο ξεκάθαρες οι μορφές και τα όρια των αγροτεμαχίων.

Το επόμενο βήμα ήταν η ομαδοποίηση των εικονοστοιχείων που απάρτιζαν τα αγροτεμάχια της εικόνας και η εξαγωγή μετρικών από αυτά. Πλέον ως αγροτεμάχια ορίστηκαν οι μεμονωμένες ομάδες εικονοστοιχείων που προέκυψαν από την επεξεργασία κατα αντιστοιχία με την κάτω δεξιά εικόνα του σχήματος 29.

Η μέθοδος αυτή είχε σαν αποτέλεσμα την τεράστια μείωση δεδομένων εισόδου από εκατομμύρια εικονοστοιχεία σε μερικές εκατοντάδες ή χιλιάδες αγροτεμάχια. Έτσι, ήταν πολύ γρήγορη η επεξεργασία των δεδομένων και η εκπαίδευση των μοντέλων. Για αυτή την προσέγγιση χρησιμοποιήθηκαν οι βασικές περιοχές. Στον πίνακα 10 φαίνεται ο αριθμός των αγροτεμαχίων που προέκυψαν από τον αντίστοιχο αριθμό εικονοστοιχείων κάθε περιοχής. Η μέθοδος αυτή εφαρμόστηκε και στους υπόλοιπους καρπούς ώστε να ανιχνευθούν τα αγροτεμάχιά τους και να δημιουργήσουν την κλάση "λοιπά αγροτεμάχια".

Περιοχή 1		Περιοχή 2		Περιοχή 3	
Καρπός	# Αγροτεμαχίων	Καρπός	# Αγροτεμαχίων	Καρπός	# Αγροτεμαχίων
Αλφάλφα	776	Σόγια	1506	Σιτάρι	1294
Κριθάρι	593	Καλαμπόκι	919	Σόγια	970
Ζαχαροκάλαμο	532	Ρύζι	813	Ζαχαροκάλαμο	699
Πατάτες	442	Βαμβάκι	508	Φασόλια ξερά	576
Καλαμπόκι	369			Καλαμπόκι	348
Σιτάρι	471				

Πίνακας 10: Εξεταζόμενοι καρποί ανά περιοχή και ο αριθμός των αντίστοιχων αγροτεμαχίων

Για κάθε αγροτεμάχιο υπολογίστηκε ο μέσος όρος των εικονοστοιχείων του, δηλαδή ο μέσος όρος του δείκτη NDVI για τον καρπό του συγκεκριμένου αγροτεμαχίου. Με αυτόν τον τρόπο κάθε αγροτεμάχιο είχε μια τιμή για κάθε ημερομηνία λήψης, διατηρώντας έτσι την χρονοσειρά των δεδομένων.

Λόγω των λίγων προτύπων εισόδου ήταν δυνατή η περαιτέρω προσπάθεια καθαρισμού των δεδομένων. Ο στόχος δεν ήταν η περαιτέρω μείωση των δειγμάτων εισόδου αλλά η εύρεση και διαγραφή θορυβώδων δειγμάτων που επηρέαζαν τα αποτελέσματα. Για να επιτευχθεί αυτό εφαρμόστηκε ο αλ-

γόριθμος Neighbourhood Cleaning Rule (NCR) [47]. Ο αλγόριθμος αυτός δίνει βάση στον εντοπισμό και διαγραφή των δειγμάτων τα οποία είναι ασαφή με αποτέλεσμα να μην μπορούν να ταξινομηθούν εύκολα και σωστά. Η βάση του είναι η μέθοδος των K-Κοντινότερων Γειτόνων (k-Nearest Neighbors). Διαισθητικά θα μπορούσε κανείς να πει πως ο NCR απορρίπτει τα δείγματα εισόδου τα οποία είναι πολύ κοντά ή μέσα στον χώρο κάποιας άλλης κλάσης.

Ο αλγόριθμος αυτός δεν ήταν δυνατό να εφαρμοστεί στην μέθοδο των εικονοστοιχείων καθώς ο αριθμός των δεδομένων εισόδου ήταν απαγορευτικός για την υπολογιστική πολυπλοκότητα του και δεν μπορούσε να δωθεί αποτέλεσμα.

4.3.5 Αλγόριθμοι Μηχανικής Μάθησης

Για την αξιολόγηση των προηγούμενων επιλογών επεξεργασίας των δεδομένων επιλέχθηκαν τρεις αλγόριθμοι μηχανικής μάθησης που αναφέρονται στο κεφάλαιο 2 (Random Forest, Support Vector Machines, Multilayer Perceptron). Για την περίπτωση των αντικειμένων (αγροτεμαχίων) εξετάστηκαν και οι τρεις ενώ για την περίπτωση των εικονοστοιχείων εξετάστηκαν μόνο οι Random Forest και Multilayer Perceptron. Οι ρυθμιζόμενες παράμετροι σε όλους τους αλγορίθμους έμειναν στις προεπιλεγμένες τιμές τους εκτός από κάποιες που αναφέρονται στη συνέχεια.

Αυτό συνέβη καθώς ο αριθμός των δεδομένων εισόδου για τον αλγόριθμο Support Vector Machines ήταν απαγορευτικός. Η χρήση του αλγορίθμου σε δεδομένα εισόδου παραπάνω από μερικές δεκάδες χιλιάδες δεν είναι εφικτή λόγω του μεγάλου υπολογιστικού κόστους που δημιουργείται. Επομένως, με την μέθοδο των εικονοστοιχείων που τα δεδομένα εισόδου ήταν πάνω από 10 εκατομμύρια αντικειμενικά δεν γινόταν να εφαρμοστεί ο αλγόριθμος.

Για την αρχιτεκτονική του Multilayer Perceptron επιλέχθηκαν δύο κρυφά στρώματα όπου στο πρώτο στρώμα ο αριθμός των νευρώνων ήταν ίσος με τον αριθμό των χαρακτηριστικών των δεδομένων εισόδου (δηλαδή ίσως με τον αριθμό των ημερομηνιών λήψεων) ενώ στο δεύτερο στρώμα ο αριθμός των νευρώνων ήταν ίσος με την ακέραια διαίρεση του αριθμού των χαρακτηριστικών με τον αριθμό 2. Άρα τα κρυφά επίπεδα για κάθε περιοχή ήταν ως εξής:

- **Περιοχή 1:** (24 , 12)
- **Περιοχή 2:** (28 , 14)
- **Περιοχή 3:** (19 , 9)


Στον αλγόριθμο Random Forest επιλέχθηκε η δημιουργία 100 δέντρων αποφάσεων ενώ στον αλγόριθμο Support Vector Machines η παράμετρος C έλαβε την τιμή 25 μειώνοντας έτσι το αποδεκτό περιθώριο από το υπερεπίπεδο διαχωρισμού με αποτέλεσμα η ταξινόμηση να είναι πιο αυστηρή ως προς τις λάθος προβλέψεις.

4.4 Αποτελέσματα

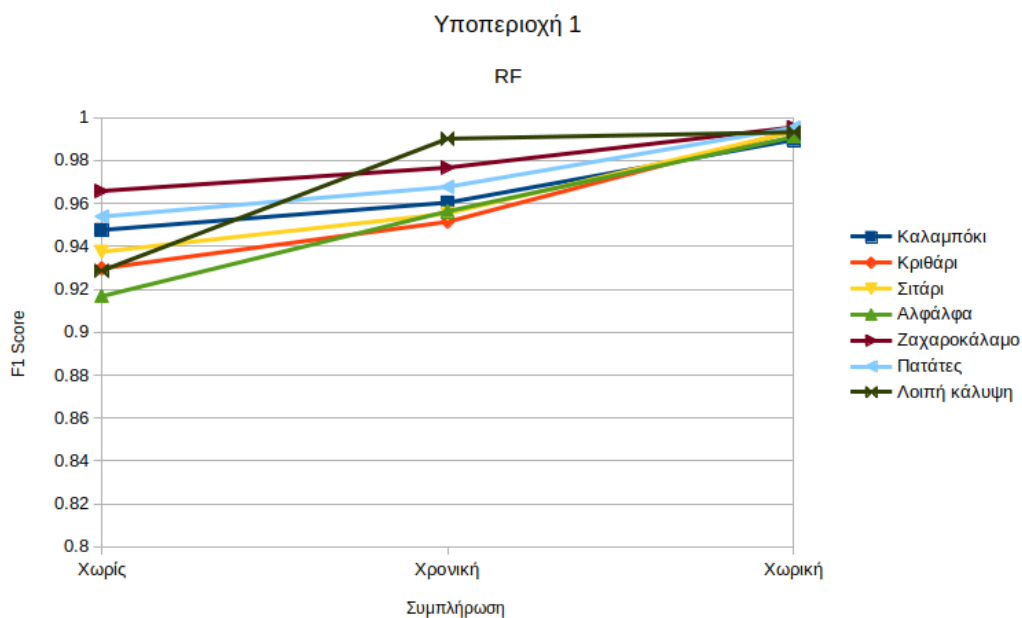
Στην ενότητα αυτή εμφανίζονται τα αποτελέσματα των μετρήσεων που πραγματοποιήθηκαν. Η παρουσίασή τους γίνεται αρχικά με μέθοδο καθορισμού των προτύπων εισόδου (εικονοστοιχεία-αντικείμενα), ενώ για κάθε μέθοδο τα αποτελέσματα χωρίζονται εκ νέου ανά περιοχή/υποπεριοχή (1 έως 3) και σε κάθε μία από αυτές παραθέτονται τα διαγράμματα των F1 Score των αλγορίθμων που χρησιμοποιήκαν σε συνδυασμό με την εκάστοτε μέθοδο συμπλήρωσης ελλিপών τιμών. Τέλος γίνεται σύγκριση των καλύτερων αποτελεσμάτων των αλγορίθμων σε συνδυασμό με τις μεθόδους που χρησιμοποιήθηκαν.

4.4.1 Μέθοδος Εικονοστοιχείων

4.4.1.1 Υποπεριοχή 1




Σχήμα 32: Υποπεριοχή 1 - MLP - F1 Score ανά μέθοδο συμπλήρωσης κενών.




Σχήμα 33: Υποπεριοχή 1 - RF - F1 Score ανά μέθοδο συμπλήρωσης κενών.

Και στα δυο σχήματα παρατηρούμε τη σταδιακή βελτίωση των αποτελεσμάτων για κάθε κλάση, ειδικά για τον MLP ο οποίος παρουσιάζει τη μεγαλύτερη βελτίωση. Η Χωρική συμπλήρωση τιμών δίνει καλύτερα αποτελέσματα σε σχέση με τη Χρονική. Επίσης, ο αλγόριθμος Random Forest ξεκινά και καταλήγει σε πιο μεγάλες τιμές του δείκτη F1.

4.4.1.2 Υποπεριοχή 2




Σχήμα 34: Υποπεριοχή 2 - MLP - F1 Score ανά μέθοδο συμπλήρωσης κενών.




Σχήμα 35: Υποπεριοχή 2 - RF - F1 Score ανά μέθοδο συμπλήρωσης κενών.

Και στα δυο σχήματα παρατηρούμε τη σταδιακή βελτίωση των αποτελεσμάτων για κάθε κλάση, ειδικά για τον MLP ο οποίος παρουσιάζει τη μεγαλύτερη βελτίωση. Η Χωρική συμπλήρωση τιμών δίνει καλύτερα αποτελέσματα σε σχέση με τη Χρονική. Επίσης, ο αλγόριθμος Random Forest ξεκινά και καταλήγει σε πιο μεγάλες τιμές του δείκτη F1.

4.4.1.3 Υποπεριοχή 3



Σχήμα 36: Υποπεριοχή 3 - MLP - F1 Score ανά μέθοδο συμπλήρωσης κενών.



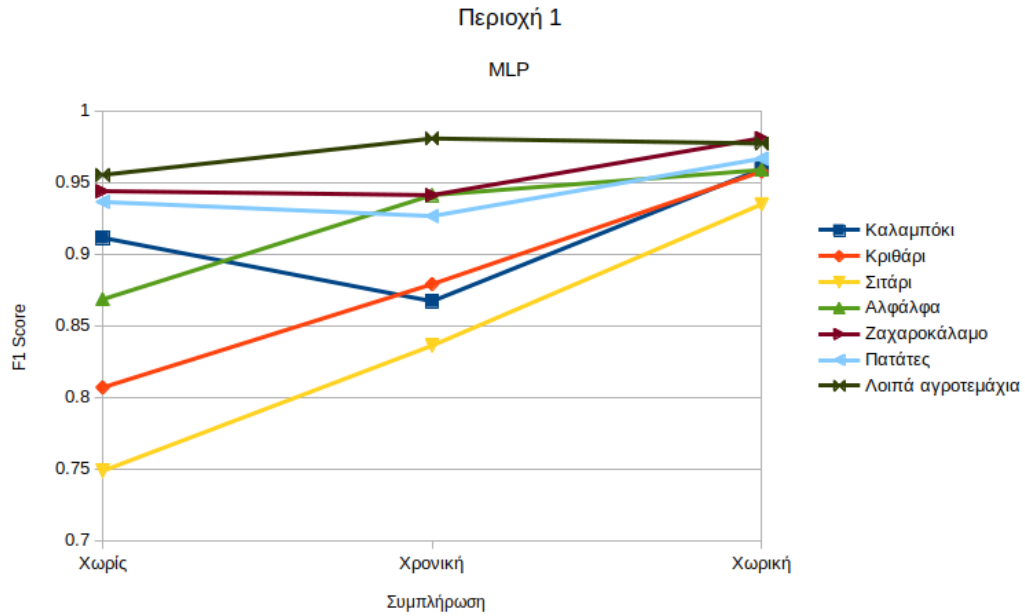
Σχήμα 37: Υποπεριοχή 3 - RF - F1 Score ανά μέθοδο συμπλήρωσης κενών.

Και στα δυο σχήματα παρατηρούμε τη σταδιακή βελτίωση των αποτελεσμάτων για κάθε κλάση, ειδικά για τον MLP ο οποίος παρουσιάζει τη μεγαλύτερη βελτίωση. Η Χωρική συμπλήρωση τιμών δίνει καλύτερα αποτελέσματα σε σχέση με τη Χρονική. Επίσης, ο αλγόριθμος Random Forest ξεκινά και καταλήγει σε πιο μεγάλες τιμές του δείκτη F1.


4.4.2 Μέθοδος Αντικειμένων

4.4.2.1 Περιοχή 1


Multi-Layer Perceptron




Σχήμα 38: Περιοχή 1 - MLP - F1 Score ανά μέθοδο συμπλήρωσης κενών.



Σχήμα 39: Περιοχή 1 - MLP - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.



Σχήμα 40: Περιοχή 1 - MLP - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.




Σχήμα 41: Περιοχή 1 - MLP - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.

Στο σχήμα 38 παρατηρούμε βελτίωση για όλες τις κλάσεις στη Χωρική μέθοδο. Στη Χρονική φαίνεται μια πτώση σε μια κλάση αλλά και στασιμότητα σε άλλες δυο. Αυτό πιθανώς οφείλεται στην ύπαρξη νεφοκάλυψης πάνω από αγροτεμάχια του καρπού, σε σημαντικές ημερομηνίες για την ανάπτυξη και τα χαρακτηριστικά του. Ταυτόχρονα, η συμπλήρωση με την συγκεκριμένη μέθοδο δεν μπόρεσε να αναπαράγει αποτελεσματικά τις ελλειπείς τιμές, κάτι το οποίο φαίνεται να κατάφερε η Χωρική μέθοδος. Οι μεγαλύτερες τιμές προκύπτουν για τη Χωρική συμπλήρωση.


Στα σχήματα 39 και 40 παρατηρούμε πως η εφαρμογή του αλγόριθμου NCR βελτιώνει περαιτέρω τα αποτελέσματα και στις δύο μεθόδους συμπλήρωσης.

Η σύγκριση μεταξύ των τελικών αποτελεσμάτων φανερώνει πως ο συνδυασμός Χωρικής συμπλήρωσης με τον αλγόριθμο NCR δίνει τη συνολικά μεγαλύτερη βελτίωση, σχήμα 41 .


Random Forest




Σχήμα 42: Περιοχή 1 - RF - F1 Score ανά μέθοδο συμπλήρωσης κενών.



Σχήμα 43: Περιοχή 1 - RF - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.



Σχήμα 44: Περιοχή 1 - RF - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.




Σχήμα 45: Περιοχή 1 - RF - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.

Στο σχήμα 42 παρατηρούμε βελτίωση και στις δύο μεθόδους συμπλήρωσης σε σχέση με την απουσία συμπλήρωσης. Οι μεγαλύτερες τιμές προκύπτουν για τη Χωρική μέθοδο.


Στα σχήματα 43 και 44 παρατηρούμε πως η εφαρμογή του αλγόριθμου NCR βελτιώνει περαιτέρω τα αποτελέσματα και στις δύο μεθόδους συμπλήρωσης.

Στη σύγκριση μεταξύ των τελικών αποτελεσμάτων, σχήμα 45, βλέπουμε πως ο συνδυασμός Χρονικής συμπλήρωσης με τον αλγόριθμο NCR δίνει στις περισσότερες κλάσεις μεγαλύτερη βελτίωση αλλά σε δυο περιπτώσεις βλέπουμε πως το ποσοστό παραμένει σχετικά χαμηλά (κάτω από 94.5%). Αντιθέτως, ο συνδυασμός Χωρικής συμπλήρωσης με τον αλγόριθμο NCR αυξάνει το ποσοστό σε όλες τις κλάσεις πάνω από 97%.


Support Vector Machines




Σχήμα 46: Περιοχή 1 - SVM - F1 Score ανά μέθοδο συμπλήρωσης κενών.



Σχήμα 47: Περιοχή 1 - SVM - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.



Σχήμα 48: Περιοχή 1 - SVM - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.



Σχήμα 49: Περιοχή 1 - SVM - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.


Στο σχήμα 46 παρατηρούμε βελτίωση και στις δύο μεθόδους συμπλήρωσης σε σχέση με την απουσία συμπλήρωσης. Οι μεγαλύτερες τιμές προκύπτουν για τη Χωρική συμπλήρωση.

Στα σχήματα 47 και 48 παρατηρούμε πως η εφαρμογή του αλγόριθμου NCR βελτιώνει περαιτέρω τα αποτελέσματα και στις δύο μεθόδους συμπλήρωσης.


Συγκρίνοντας μεταξύ τους τα τελικά αποτελέσματα, βλέπουμε πως ο συνδυασμός Χωρικής συμπλήρωσης με τον αλγόριθμο NCR δίνει τη συνολικά μεγαλύτερη βελτίωση, σχήμα 49 .

4.4.2.2 Περιοχή 2


Multi-Layer Perceptron




Σχήμα 50: Περιοχή 2 - MLP - F1 Score ανά μέθοδο συμπλήρωσης κενών.



Σχήμα 51: Περιοχή 2 - MLP - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.



Σχήμα 52: Περιοχή 2 - MLP - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.




Σχήμα 53: Περιοχή 2 - MLP - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.

Στο σχήμα 50 παρατηρούμε βελτίωση και στις δύο μεθόδους συμπλήρωσης σε σχέση με την απουσία συμπλήρωσης. Οι μεγαλύτερες τιμές προκύπτουν για τη Χωρική συμπλήρωση.


Στα σχήματα 51 και 52 παρατηρούμε πως η εφαρμογή του αλγόριθμου NCR βελτιώνει περαιτέρω τα αποτελέσματα και στις δύο μεθόδους συμπλήρωσης.

Στη σύγκριση μεταξύ των τελικών αποτελεσμάτων, το σχήμα 53 φανερώνει πως ο συνδυασμός Χωρικής συμπλήρωσης με τον αλγόριθμο NCR δίνει τη συνολικά μεγαλύτερη βελτίωση.


Random Forest




Σχήμα 54: Περιοχή 2 - RF - F1 Score ανά μέθοδο συμπλήρωσης κενών.



Σχήμα 55: Περιοχή 2 - RF - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.



Σχήμα 56: Περιοχή 2 - RF - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.




Σχήμα 57: Περιοχή 2 - RF - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.

Στο σχήμα 54 παρατηρούμε βελτίωση και στις δύο μεθόδους συμπλήρωσης σε σχέση με την απουσία συμπλήρωσης. Οι μεγαλύτερες τιμές προκύπτουν για τη Χωρική συμπλήρωση.


Στα σχήματα 55 και 56 παρατηρούμε πως η εφαρμογή του αλγόριθμου NCR βελτιώνει περαιτέρω τα αποτελέσματα και στις δύο μεθόδους συμπλήρωσης. Μόνο η τιμή για την κλάση Ρύζι στη Χρονική συμπλήρωση με εφαρμογή του NCR φανερώνει μια μικρή μείωση στο σχήμα 55. Αυτό πιθανώς οφείλεται στην αφαίρεση προτύπων εισόδου της κλάσης αυτής από τον NCR τα οποία περιείχαν ουσιαστική πληροφορία για την σωστή ταξινόμηση της κλάσης.

Στη σύγκριση μεταξύ των τελικών αποτελεσμάτων, στο σχήμα 57, φαίνεται πως ο συνδυασμός Χωρικής συμπλήρωσης με τον αλγόριθμο NCR δίνει τη συνολικά μεγαλύτερη βελτίωση.


Support Vector Machines




Σχήμα 58: Περιοχή 2 - SVM - F1 Score ανά μέθοδο συμπλήρωσης κενών.



Σχήμα 59: Περιοχή 2 - SVM - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.



Σχήμα 60: Περιοχή 2 - SVM - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.



Σχήμα 61: Περιοχή 2 - SVM - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.


Στο σχήμα 58 παρατηρούμε βελτίωση και στις δύο μεθόδους συμπλήρωσης σε σχέση με την απουσία συμπλήρωσης. Οι μεγαλύτερες τιμές προκύπτουν για τη Χωρική συμπλήρωση.

Στα σχήματα 59 και 60 παρατηρούμε πως η εφαρμογή του αλγόριθμου NCR βελτιώνει περαιτέρω τα αποτελέσματα και στις δύο μεθόδους συμπλήρωσης.


Στο σχήμα 61 βλέπουμε πως στη σύγκριση μεταξύ των τελικών αποτελεσμάτων ο συνδυασμός Χωρικής συμπλήρωσης με τον αλγόριθμο NCR δίνει τη συνολικά μεγαλύτερη βελτίωση.

4.4.2.3 Περιοχή 3


Multi-Layer Perceptron




Σχήμα 62: Περιοχή 3 - MLP - F1 Score ανά μέθοδο συμπλήρωσης κενών.



Σχήμα 63: Περιοχή 3 - MLP - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.



Σχήμα 64: Περιοχή 3 - MLP - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.




Σχήμα 65: Περιοχή 3 - MLP - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.

Στο σχήμα 62 παρατηρούμε βελτίωση και στις δύο μεθόδους συμπλήρωσης σε σχέση με την απουσία συμπλήρωσης. Οι μεγαλύτερες τιμές προκύπτουν για τη Χωρική συμπλήρωση.


Στα σχήματα 63 και 64 παρατηρούμε πως η εφαρμογή του αλγόριθμου NCR βελτιώνει περαιτέρω τα αποτελέσματα και στις δύο μεθόδους συμπλήρωσης.

Στο σχήμα 65 φαίνεται πως στη σύγκριση μεταξύ των τελικών αποτελεσμάτων, ο συνδυασμός Χωρικής συμπλήρωσης με τον αλγόριθμο NCR δίνει σε κάθε κλάση τη μέγιστη βελτίωση.


Random Forest




Σχήμα 66: Περιοχή 3 - RF - F1 Score ανά μέθοδο συμπλήρωσης κενών.



Σχήμα 67: Περιοχή 3 - RF - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.



Σχήμα 68: Περιοχή 3 - RF - F1 Score με Χρονική συμπλήρωση κενών και εφαρμογή του NCR.




Σχήμα 69: Περιοχή 3 - RF - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.

Στο σχήμα 66 παρατηρούμε βελτίωση και στις δύο μεθόδους συμπλήρωσης σε σχέση με την απουσία συμπλήρωσης. Οι μεγαλύτερες τιμές προκύπτουν για τη Χωρική συμπλήρωση.


Στα σχήματα 67 και 68 παρατηρούμε πως η εφαρμογή του αλγόριθμου NCR βελτιώνει περαιτέρω τα αποτελέσματα και στις δύο μεθόδους συμπλήρωσης.

Στη σύγκριση μεταξύ των τελικών αποτελεσμάτων, το σχήμα 69 φανερώνει πως ο συνδυασμός Χωρικής συμπλήρωσης με τον αλγόριθμο NCR δίνει σε κάθε κλάση τη μεγαλύτερη βελτίωση.


Support Vector Machines




Σχήμα 70: Περιοχή 3 - SVM - F1 Score ανά μέθοδο συμπλήρωσης κενών.



Σχήμα 71: Περιοχή 3 - SVM - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.



Σχήμα 72: Περιοχή 3 - SVM - F1 Score με Χωρική συμπλήρωση κενών και εφαρμογή του NCR.



Σχήμα 73: Περιοχή 3 - SVM - Σύγκριση F1 Score των δυο μεθόδων συμπλήρωσης με εφαρμογή του NCR.

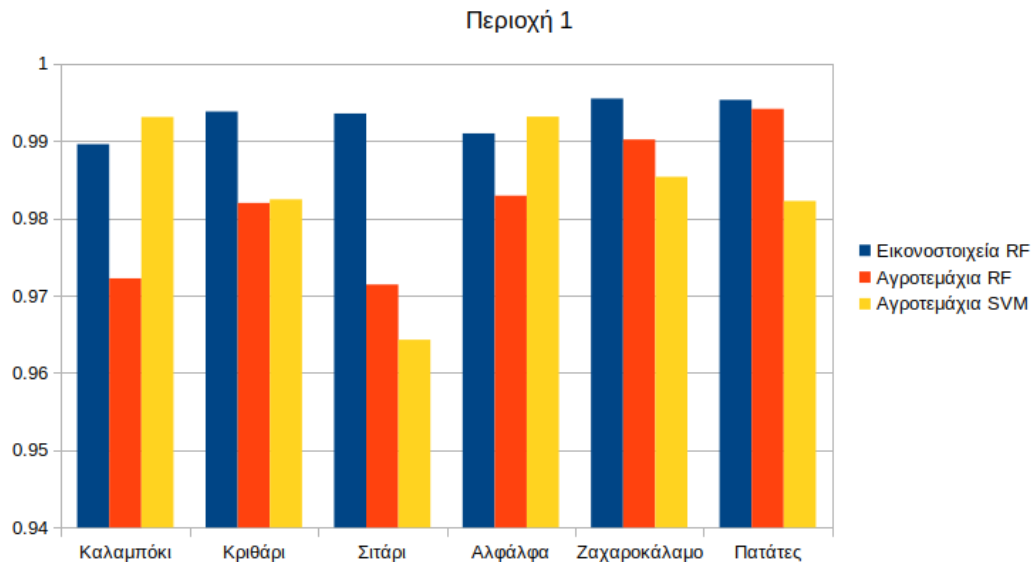
Στο σχήμα 70 παρατηρούμε βελτίωση και στις δύο μεθόδους συμπλήρωσης σε σχέση με την απουσία συμπλήρωσης. Οι μεγαλύτερες τιμές προκύπτουν για τη Χωρική συμπλήρωση.

Στα σχήματα 71 και 72 παρατηρούμε πως η εφαρμογή του αλγόριθμου NCR βελτιώνει περαιτέρω τα αποτελέσματα και στις δύο μεθόδους συμπλήρωσης.


Το αποτέλεσμα της σύγκρισης μεταξύ των τελικών αποτελεσμάτων μας δείχνει πως ο συνδυασμός Χωρικής συμπλήρωσης με τον αλγόριθμο NCR δίνει συνολικά τη μεγαλύτερη βελτίωση, σχήμα 73.

4.4.3 Σύγκριση καλύτερων αποτελεσμάτων ανά περιοχή


Στη μέθοδο των εικονοστοιχείων ο αλγόριθμος Random Forest έδωσε καλύτερα αποτελέσματα από τον MLP. Αντίστοιχα, στην μέθοδο των αγροτεμαχίων τα καλύτερα αποτελέσματα βρέθηκαν για τους αλγορίθμους RF και SVM. Και στις δυο περιπτώσεις η μέθοδος συμπλήρωσης ελλειπών τιμών ήταν η χωρική μέθοδος, ενώ στα αγροτεμάχια συνδυάστηκε και με τον αλγόριθμο NCR. Στη συνέχεια φαίνονται τα διαγράμματα του F1-Score για κάθε περιοχή ανά καρπό που πέτυχαν οι προαναφερθέντες αλγόριθμοι.



Σχήμα 74: Περιοχή 1 - Σύγκριση Καλύτερων αποτελεσμάτων για τις μεθόδους Εικονοστοιχείων-Αγροτεμαχίων.



Σχήμα 75: Περιοχή 2 - Σύγκριση Καλύτερων αποτελεσμάτων για τις μεθόδους Εικονοστοιχείων-Αγροτεμαχίων.



Σχήμα 76: Περιοχή 3 - Σύγκριση Καλύτερων αποτελεσμάτων για τις μεθόδους Εικονοστοιχείων-Αγροτεμαχίων.

Στα σχήματα 74, 75 και 76 παρατηρούμε πως με την μέθοδο των εικονοστοιχείων έχουμε τα υψηλότερα αποτελέσματα στους 11 από τους 15 καρπούς που εξετάζονται και στις τρεις περιοχές. Σε 3 από τους 15 καρπούς έχουμε τα υψηλότερα ποσοστά με τη μέθοδο των αγροτεμαχίων με τον αλγόριθμο SVM και σε 1 από τους 15 καρπούς τα αποτελέσματα είναι ίσα για όλες τις υλοποιήσεις.

4.5 Συμπεράσματα - Μελλοντική Εργασία

4.5.1 Αξιολόγηση αποτελεσμάτων

Εξετάζοντας συνολικά τα αποτελέσματα της εργασίας, αυτό που παρατηρούμε είναι το υψηλό ποσοστό του δείκτη F1 Score ($> 80\%$) ακόμη και χωρίς να έχουν υποστεί τα δεδομένα κάποια επεξεργασία. Αυτό καταδεικνύει πως η ποιότητα των δεδομένων των Sentinel-2 και Landsat 8 αλλά και η προσέγγιση του προβλήματος με τη χρήση χρονοσειρών είναι ουσιαστικοί παράγοντες για την λύση του προβλήματος. Οι καρποί στην διάρκεια του χρόνου εμφανίζουν διαφοροποιήσεις οι οποίες συνήθως είναι καθοριστικές για την ταξινόμησή τους. Για αυτό το λόγο, σε πολλές έρευνες πάνω στο θέμα αυτό χρησιμοποιούνται χρονοσειρές λήψεων ώστε να είναι δυνατή η αξιοποίηση της χρονικής πληροφορίας κατά την διάρκεια ανάπτυξης των καρπών [37],[35],[34],[33],[48],[49],[39],[50]. Εν αντιθέσει, η χρήση λήψεων από μια μόνο χρονική στιγμή δεν συνηθίζεται, αλλά έχουν δοκιμαστεί [32],[51]. Οι προσεγγίσεις με τις χρονοσειρές δίνουν καλύτερα αποτελέσματα και αποτελούν μια πιο ολοκληρωμένη προσέγγιση του θέματος γι' αυτό και προτιμούνται ευρύτερα.

Όσον αφορά τη συμπλήρωση ελλিপών τιμών, παρατηρούμε πως η αξιοποίηση των χωρικών πληροφοριών που είναι διαθέσιμες, προσφέρει καλύτερα αποτελέσματα συνολικά σε ποσοστό πάνω από 95%). Αυτό οφείλεται στην καλά δομημένη δημιουργία νέων τιμών μέσω της Γκαουσιανής κατανομής, σε αντίθεση με την απλή μέση τιμή που προσφέρει η χρονική προσέγγιση. Ενώ στην πρώτη περίπτωση δημιουργούνται τεχνητά δείγματα εισόδου τα οποία είναι όμοια με τα πραγματικά, στην δεύτερη δημιουργούνται δείγματα τα οποία πολλές φορές δεν έχουν υπόσταση από βιολογική άποψη. Παρ' όλα αυτά η βελτίωση των αποτελεσμάτων ακόμα και με τη χρονική προσέγγιση φανερώνει το πρόβλημα που δημιουργούν οι ελλιπείς τιμές λόγω νεφοκάλυψης, καθιστώντας την ένα θέμα το οποίο πρέπει να αντιμετωπίζεται σε κάθε παρόμοια έρευνα. Για παράδειγμα η Kussul [37] χρησιμοποίησε αυτοοργανωμένους χάρτες (Self-Organising Maps, SOMs) για την συμπλήρωση των ελλειπών τιμών. Για κάθε εικόνα οι χάρτες χρησιμοποιούσαν τα καθαρά εικονοστοιχεία της ίδιας εικόνας για να παράξουν προσεγγίσεις των εικονοστοιχείων που δεν είχαν τιμή, αξιοποιώντας έτσι της υπάρχουσα χωρική πληροφορία.

Επιπρόσθετα, η εύρεση αξιόλογων χαρακτηριστικών είναι βασική προϋπόθεση για την αποτελεσματική επίλυση ενός προβλήματος ταξινόμησης. Σε ορισμένες μελέτες έχουν επιλεχθεί ως χαρακτηριστικά όλα ή ένα μεγάλο μέρος από τα διαθέσιμα φασματικά κανάλια ενός δορυφόρου [35],[37],[32],[49] ενώ σε άλλες συνδυάζονται μερικά φασματικά κανάλια με ειδικούς δείκτες οι οποίοι υπολογίζονται από τον συνδυασμό φασματικών καναλιών [33],[34],[48]. Ο δείκτης που χρησιμοποιείται κατά κόρον είναι ο NDVI ενώ έχει ελεγχθεί και η χρήση του ως μοναδικό δείκτη, αφήνοντας στην άκρη τα υπόλοιπα φασματικά κανάλια και δείκτες που υπάρχουν [51]. Το συμπέρασμα της χρήσης αυτού του δείκτη ως μοναδική πηγή πληροφορίας για τους καρπούς αξιολογώντας και τα αποτελέσματα της παρούσας εργασίας είναι πως μπορεί να χρησιμοποιηθεί μόνος του με πολύ καλά αποτελέσματα.

Σχετικά με τις δυο μεθόδους ορισμού των προτύπων εισόδου (εικονοστοιχεία, αγροτεμάχια) παρατηρούμε και στις δύο περιπτώσεις πολύ υψηλά ποσοστά. Η ουσιαστική διαφορά τους έγκειται στο μέγεθος των δεδομένων. Στην προσέγγιση των εικονοστοιχείων ο αριθμός των δειγμάτων εισόδου μπορεί να φτάσει αρκετά εκατομμύρια, ενώ στην προσέγγιση των αγροτεμαχίων ο αριθμός των δειγμάτων φτάνει τις μερικές χιλιάδες. Όταν ο αριθμός των δειγμάτων εισόδου είναι πολύ μεγάλος (περίπτωση εικονοστοιχείων) υπάρχει σημαντικό αντίκτυπο στο υπολογιστικό κόστος κατά την επεξεργασία και την εκπαίδευση των αλγόριθμων. Αντίθετα, η εξαγωγή από μεγάλες περιοχές μικρού αριθμού δειγμάτων εισόδου (περίπτωση αγροτεμαχίων) καθιστά εφικτή την επιλογή μεγαλύτερων περιοχών, οδηγώντας στην πιο γρήγορη κάλυψη μεγάλων εκτάσεων χωρίς να γίνεται απαγορευτικό το υπολογιστικό κόστος. Επομένως, στην περίπτωση που το ενδιαφέρον της έρευνας εστιάζεται στην μελέτη των καλλιεργούμενων καρπών προτείνεται η μέθοδος των αγροτεμαχίων, ώστε να αξιοποιηθεί η οργανωμένη μορφή που έχουν τα αγροτεμάχια και να αποφευχθούν τα μεγάλα υπολογιστικά κόστη της μεθόδου των εικονοστοιχείων.

Στην προσέγγιση με τη μέθοδο των αγροτεμαχίων αν και τα ποσοστά που έχουμε είναι υψηλά και

για τις δύο μεθόδους συμπλήρωσης τιμών, υπάρχει η δυνατότητα περαιτέρω αύξησής τους. Ο αλγόριθμος Neighbourhood Cleaning Rule κατάφερε να καθαρίσει τα δεδομένα ακόμα περισσότερο και οδήγησε σε ακόμα υψηλότερα ποσοστά, ειδικότερα σε συνδυασμό με τη χωρική συμπλήρωση ελλিপών τιμών. Χαρακτηριστικό παράδειγμα είναι πως ο συνδυασμός του με την χωρική μέθοδο συμπλήρωσης έφτασε στην συντριπτική πλειονότητα των αποτελεσμάτων πάνω από 98%. Αυτό σημαίνει πως αν και σωστές οι αρχικές επεξεργασίες των δεδομένων είχαν περιθώριο για περαιτέρω βελτίωση με τη χρήση εξειδικευμένων αλγορίθμων για καθαρισμό δεδομένων.

Τέλος, εξετάζοντας τους διαφορετικούς αλγόριθμους που χρησιμοποιήθηκαν βλέπουμε πως όλοι δίνουν εξαιρετικά αποτελέσματα πάνω στα επεξεργασμένα δεδομένα. Στη μέθοδο των εικονοστοιχείων (Υποπεριοχές 1,2,3) ο αλγόριθμος Random Forest δίνει καλύτερα αποτελέσματα, ειδικά όταν συνδυάζεται με τη χωρική συμπλήρωση, τα ποσοστά του F1 Score φτάνουν πολύ κοντά στο 100%. Αυτό επιτυγχάνεται καθώς υπάρχει πολύ μεγάλος αριθμός διαθέσιμων δεδομένων εισόδου για την εκπαίδευση.

Στη μέθοδο των αγροτεμαχίων (Περιοχές 1,2,3), αν και όλοι οι αλγόριθμοι έχουν πάρα πολύ καλή απόδοση, μπορούμε να πούμε πως ο αλγόριθμος SVM, ακολουθούμενος από τον RF, έχει δώσει τα καλύτερα αποτελέσματα, γεγονός που συμφωνεί και με άλλες έρευνες [35],[34],[32]. Τα καλύτερα αποτελέσματα των δύο αυτών αλγορίθμων προέκυψαν από το συνδυασμό της χωρικής συμπλήρωσης και του αλγορίθμου καθαρισμού δεδομένων NCR.

Και οι δύο αλγόριθμοι είναι ιδανικοί για προβλήματα ταξινόμησης και ο συνδυασμός τους με καθαρά δεδομένα οδηγεί σε πολύ καλά αποτελέσματα. Ο MLP αν και έχει, επίσης, καλή απόδοση παρατηρούμε πως υπάρχουν περιπτώσεις που πετυχαίνει λίγο χαμηλότερα ποσοστά από τους άλλους δύο. Επομένως, εκμεταλευόμενοι το μικρό αριθμό των δεδομένων αυτής της μεθόδου προτείνονται ο αλγόριθμος SVM.

4.5.2 Μελλοντική Εργασία

Η παρούσα διπλωματική εργασία ανέδειξε τα προβλήματα που προκύπτουν στην ταξινόμηση καρπών από δορυφορικά δεδομένα και εξερεύνησε πιθανές λύσεις τους. Στη συνέχεια η εργασία αυτή θα μπορούσε να επεκταθεί και στις εξής ενδεικτικές κατευθύνσεις:

- Χρήση δεδομένων από περισσότερους δορυφόρους ώστε να είναι οι χρονοσειρές πιο πυκνές και με καθαρές λήψεις. Με αυτόν τον τρόπο θα είναι πιο ακριβείς οι φασματικές ταυτότητες των καρπών και θα είναι πιο συνεχής η παρακολούθηση των σταδίων ανάπτυξης του καρπού.
- Εύρεση των αγροτεμαχίων και καθορισμός των ορίων τους μέσω των διαθέσιμων δορυφορικών δεδομένων.
- Εξερεύνηση άλλων μεθόδων συμπλήρωσης ελλিপών τιμών ώστε να έχουν ακόμα καλύτερη ποιότητα τα παραγόμενα δεδομένα.
- Ενσωμάτωση και άλλων ειδικών δεικτών όπως ο NDVI ώστε να αναδειχτούν επιπλέον χαρακτηριστικά των καρπών βοηθώντας στην ταξινόμηση καρπών οι οποίοι στις εξεταζόμενες περιοχές βρίσκονται σε μικρότερο αριθμό.
- Εξερεύνηση άλλων αλγορίθμων και μεθόδων μηχανικής μάθησης για την ταξινόμηση των καρπών.

Βιβλιογραφία

- [1] FAO, *Agriculture, food and water: A contribution to the World Water Development Report*, English, ser. FAO AQUASTAT REPORTS. Rome, Italy: FAO, 2003, isbn: 92-5-104943-2. [Online]. Available: <http://www.fao.org/publications/card/en/c/Y4683E/> (visited on 05/02/2020).
- [2] —, *FAO Statistical Yearbook 2012 - Europe and Central Asia Food and agriculture*, English. Rome, Italy: FAO, 2013, isbn: ISBN 978-92-5-107427-5. [Online]. Available: <http://www.fao.org/3/i3138e/i3138e00.htm> (visited on 05/02/2020).
- [3] A. Obaisi, “OVERPOPULATION: A THREAT TO SUSTAINABLE AGRICULTURE AND FOOD SECURITY IN DEVELOPING COUNTRIES? A Review,” 2017. doi: 10.13140/RG.2.2.20613.04325. [Online]. Available: https://www.researchgate.net/publication/324792051_OVERPOPULATION_A_THREAT_TO_SUSTAINABLE_AGRICULTURE_AND_FOOD_SECURITY_IN_DEVELOPING_COUNTRIES_A_Review (visited on 05/02/2020).
- [4] R. Bhadouria, R. Singh, V. K. Singh, A. Borthakur, A. Ahamad, G. Kumar, and P. Singh, “Chapter 1 - Agriculture in the Era of Climate Change: Consequences and Effects,” in *Climate Change and Agricultural Ecosystems*, K. K. Choudhary, A. Kumar, and A. K. Singh, Eds., Woodhead Publishing, 2019, pp. 1–23, isbn: 978-0-12-816483-9. doi: 10.1016/B978-0-12-816483-9.00001-3. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/B9780128164839000013>.
- [5] *Deforestation and forest degradation*, en, Library Catalog: www.iucn.org, Nov. 2017. [Online]. Available: <https://www.iucn.org/resources/issues-briefs/deforestation-and-forest-degradation> (visited on 05/02/2020).
- [6] O. Milman, “Earth has lost a third of arable land in past 40 years, scientists say,” en-GB, *The Guardian*, Dec. 2015, issn: 0261-3077. [Online]. Available: <https://www.theguardian.com/environment/2015/dec/02/arable-land-soil-food-security-shortage> (visited on 05/02/2020).
- [7] C. Zhao, B. Liu, S. Piao, X. Wang, D. B. Lobell, Y. Huang, M. Huang, Y. Yao, S. Bassu, P. Ciais, J.-L. Durand, J. Elliott, F. Ewert, I. A. Janssens, T. Li, E. Lin, Q. Liu, P. Martre, C. Müller, S. Peng, J. Peñuelas, A. C. Ruane, D. Wallach, T. Wang, D. Wu, Z. Liu, Y. Zhu, Z. Zhu, and S. Asseng, “Temperature increase reduces global yields of major crops in four independent estimates,” *Proceedings of the National Academy of Sciences*, vol. 114, no. 35, pp. 9326–9331, 2017, Publisher: National Academy of Sciences _eprint: <https://www.pnas.org/content/114/35/9326.full.pdf>, issn: 0027-8424. doi: 10.1073/pnas.1701762114. [Online]. Available: <https://www.pnas.org/content/114/35/9326>.
- [8] T. M. Mitchell, *Machine Learning*, 1st ed. New York, NY, USA, 1997, p. 2.
- [9] T. K. Ho, “Random decision forests,” in *Proceedings of 3rd International Conference on Document Analysis and Recognition*, vol. 1, Aug. 1995, 278–282 vol.1. doi: 10.1109/ICDAR.1995.598994.
- [10] L. Breiman, “Random Forests,” en, *Machine Learning*, vol. 45, no. 1, pp. 5–32, Oct. 2001, issn: 1573-0565. doi: 10.1023/A:1010933404324. [Online]. Available: <https://doi.org/10.1023/A:1010933404324> (visited on 05/03/2020).

- [11] —, “Bagging Predictors,” en, *Machine Learning*, vol. 24, no. 2, pp. 123–140, Aug. 1996, issn: 1573-0565. doi: 10.1023/A:1018054314350. [Online]. Available: <https://doi.org/10.1023/A:1018054314350> (visited on 05/03/2020).
- [12] S. Haykin, *Neural Networks: A Comprehensive Foundation*, 1st. USA: Prentice Hall PTR, 1994, isbn: 978-0-02-352761-6.
- [13] F. Rosenblatt, “The perceptron: A probabilistic model for information storage and organization in the brain,” *Psychological Review*, vol. 65, no. 6, pp. 386–408, 1958, Place: US Publisher: American Psychological Association, issn: 1939-1471(Electronic),0033-295X(Print). doi: 10.1037/h0042519.
- [14] E. Kussul, T. Baidyk, L. Kasatkina, and V. Lukovich, “Rosenblatt perceptrons for handwritten digit recognition,” in *IJCNN’01. International Joint Conference on Neural Networks. Proceedings (Cat. No.01CH37222)*, ISSN: 1098-7576, vol. 2, Jul. 2001, 1516–1520 vol.2. doi: 10.1109/IJCNN.2001.939589.
- [15] M. Olazaran, “A Sociological Study of the Official History of the Perceptrons Controversy:” en, *Social Studies of Science*, Jun. 2016, Publisher: SAGE Publications London. doi: 10.1177/030631296026003005. [Online]. Available: <https://journals.sagepub.com/doi/10.1177/030631296026003005> (visited on 05/04/2020).
- [16] H. J. Kelley, “Gradient Theory of Optimal Flight Paths,” *ARS Journal*, vol. 30, no. 10, pp. 947–954, Oct. 1960, Publisher: American Institute of Aeronautics and Astronautics. doi: 10.2514/8.5282. [Online]. Available: <https://arc.aiaa.org/doi/10.2514/8.5282> (visited on 05/04/2020).
- [17] H. Robbins and S. Monro, “A Stochastic Approximation Method,” EN, *Annals of Mathematical Statistics*, vol. 22, no. 3, pp. 400–407, Sep. 1951, Publisher: Institute of Mathematical Statistics, issn: 0003-4851, 2168-8990. doi: 10.1214/aoms/1177729586. [Online]. Available: <https://projecteuclid.org/euclid.aoms/1177729586> (visited on 05/04/2020).
- [18] T. E. Avery and G. L. Berlin, *Fundamentals of Remote Sensing and Airphoto Interpretation*, en. Macmillan, 1992, Google-Books-ID: 5WYZAQAIAAJ, isbn: 978-0-02-305035-0.
- [19] P. M. Mather and M. Koch, *Computer Processing of Remotely-Sensed Images: An Introduction*, en. John Wiley & Sons, Jul. 2011, Google-Books-ID: GWhvDMNh1hAC, isbn: 978-1-119-95640-2.
- [20] I. Parcharidis and I. Παρχαρίδης, *Αρχές δορυφορικής τηλεπισκόπησης*, el. 2015, Journal Abbreviation: ΘΕΩΡΕΙΑ ΚΑΙ ΕΦΑΡΜΟΓΕΣ, isbn: 978-960-603-443-5. [Online]. Available: <https://repository.kallipos.gr/handle/11419/3960> (visited on 05/06/2020).
- [21] *DigitalGlobe | WorldView-3*. [Online]. Available: <http://worldview3.digitalglobe.com/> (visited on 05/10/2020).
- [22] *MODIS Web*. [Online]. Available: <https://modis.gsfc.nasa.gov/about/specifications.php> (visited on 05/12/2020).
- [23] *Pleiades*, en, Library Catalog: pleiades.cnes.fr. [Online]. Available: <https://pleiades.cnes.fr/en/PLEIADES/index.htm> (visited on 05/10/2020).
- [24] *Spot*, en, Library Catalog: spot.cnes.fr. [Online]. Available: <https://spot.cnes.fr/en/SPOT/index.htm> (visited on 05/11/2020).
- [25] *Homepage | Copernicus*. [Online]. Available: <https://www.copernicus.eu/en> (visited on 05/08/2020).
- [26] *Missions - Sentinel Online*. [Online]. Available: <https://sentinel.esa.int/web/sentinel/missions> (visited on 05/11/2020).
- [27] *Sentinel Data Access Overview - Sentinel Online*. [Online]. Available: <https://sentinel.esa.int/web/sentinel/sentinel-data-access> (visited on 05/11/2020).

- [28] *Landsat Satellite Missions*. [Online]. Available: https://www.usgs.gov/land-resources/nli/landsat/landsat-satellite-missions?qt-science_support_page_related_con=2#qt-science_support_page_related_con (visited on 05/13/2020).
- [29] D. M. Gates, *Biophysical Ecology*, en, ser. Springer Advanced Texts in Life Sciences. New York: Springer-Verlag, 1980, isbn: 978-1-4612-6026-4. doi: 10.1007/978-1-4612-6024-0. [Online]. Available: <https://www.springer.com/gp/book/9781461260264> (visited on 05/07/2020).
- [30] *EarthExplorer - Home*. [Online]. Available: <https://earthexplorer.usgs.gov/> (visited on 05/10/2020).
- [31] J. W. Rouse Jr., R. H. Haas, J. A. Schell, and D. W. Deering, “Monitoring Vegetation Systems in the Great Plains with Erts,” *NASA Special Publication*, vol. 351, p. 309, 1974. [Online]. Available: <http://adsabs.harvard.edu/abs/1974NASSP.351..309R> (visited on 05/07/2020).
- [32] T.-N. Phan and M. Kappas, “Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery,” *Sensors*, vol. 18, p. 18, Dec. 2017. doi: 10.3390/s18010018.
- [33] R. B. Arango, I. Díaz, A. M. Campos, E. R. Canas, and E. F. Combarro, “Automatic arable land detection with supervised machine learning,” *Earth Science Informatics*, 2016. doi: 10.1007/s12145-016-0270-6.
- [34] J. Gilbertson and A. Van Niekerk, “Value of dimensionality reduction for crop differentiation with multi-temporal imagery and machine learning,” *Computers and Electronics in Agriculture*, vol. 142, pp. 50–58, Nov. 2017. doi: 10.1016/j.compag.2017.08.024.
- [35] N. Laban, B. Abdel latif, H. Ebied, H. Shedeed, and M. Tolba, “Improving Land-Cover and Crop-Types Classification of Sentinel-2 Satellite Images,” in, Jan. 2018, pp. 449–458, isbn: 978-3-319-74689-0. doi: 10.1007/978-3-319-74690-6_44.
- [36] J. K. Gilbertson, J. Kemp, and A. van Niekerk, “Effect of pan-sharpening multi-temporal Landsat 8 imagery for crop type differentiation using different classification techniques,” en, *Computers and Electronics in Agriculture*, vol. 134, pp. 151–159, Mar. 2017, issn: 0168-1699. doi: 10.1016/j.compag.2016.12.006. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0168169916303520> (visited on 06/04/2020).
- [37] N. Kussul, M. Lavreniuk, S. Skakun, and A. Shelestov, “Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data,” *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 5, pp. 778–782, May 2017, Conference Name: IEEE Geoscience and Remote Sensing Letters, issn: 1558-0571. doi: 10.1109/LGRS.2017.2681128.
- [38] L. Zhong, L. Hu, and H. Zhou, “Deep learning based multi-temporal crop classification,” en, *Remote Sensing of Environment*, vol. 221, pp. 430–443, Feb. 2019, issn: 0034-4257. doi: 10.1016/j.rse.2018.11.032. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0034425718305418> (visited on 06/05/2020).
- [39] D. Ienco, R. Interdonato, R. Gaetano, and D. Ho Tong Minh, “Combining Sentinel-1 and Sentinel-2 Satellite Image Time Series for land cover mapping via a multi-source deep learning architecture,” en, *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 158, pp. 11–22, Dec. 2019, issn: 0924-2716. doi: 10.1016/j.isprsjprs.2019.09.016. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0924271619302278> (visited on 05/12/2020).
- [40] *scikit-learn: machine learning in Python — scikit-learn 0.23.0 documentation*. [Online]. Available: <https://scikit-learn.org/stable/> (visited on 05/15/2020).
- [41] *GDAL — GDAL documentation*. [Online]. Available: <https://gdal.org/> (visited on 05/15/2020).

- [42] *Rasterio: access to geospatial raster data — rasterio documentation*. [Online]. Available: <https://rasterio.readthedocs.io/en/latest/> (visited on 05/15/2020).
- [43] *rasterstats — rasterstats 0.10.3 documentation*. [Online]. Available: <https://pythonhosted.org/rasterstats/> (visited on 05/15/2020).
- [44] *Welcome to the QGIS project!* [Online]. Available: <https://qgis.org/en/site/> (visited on 05/13/2020).
- [45] *CropScape - NASS CDL Program*. [Online]. Available: <https://nassgeodata.gmu.edu/cropScape/> (visited on 05/13/2020).
- [46] S. Qiu, Z. Zhu, and B. He, “Fmask 4.0: Improved cloud and cloud shadow detection in Landsats 4–8 and Sentinel-2 imagery,” en, *Remote Sensing of Environment*, vol. 231, p. 111 205, Sep. 2019, issn: 0034-4257. doi: 10.1016/j.rse.2019.05.024. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0034425719302172> (visited on 05/14/2020).
- [47] J. Laurikkala, “Improving Identification of Difficult Small Classes by Balancing Class Distribution,” en, in *Artificial Intelligence in Medicine*, S. Quaglini, P. Barahona, and S. Andreassen, Eds., ser. Lecture Notes in Computer Science, Berlin, Heidelberg: Springer, 2001, pp. 63–66, isbn: 978-3-540-48229-1. doi: 10.1007/3-540-48229-6_9.
- [48] M. A. Peña, R. Liao, and A. Brenning, “Using spectrotemporal indices to improve the fruit-tree crop classification accuracy,” en, *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 128, pp. 158–169, Jun. 2017, issn: 0924-2716. doi: 10.1016/j.isprsjprs.2017.03.019. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0924271616305019> (visited on 05/12/2020).
- [49] M. A. Peña and A. Brenning, “Assessing fruit-tree crop classification from Landsat-8 time series for the Maipo Valley, Chile,” en, *Remote Sensing of Environment*, vol. 171, pp. 234–244, Dec. 2015, issn: 0034-4257. doi: 10.1016/j.rse.2015.10.029. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0034425715301814> (visited on 05/12/2020).
- [50] J. Inglada, M. Arias, B. Tardy, O. Hagolle, S. Valero, D. Morin, G. Dedieu, G. Sepulcre, S. Bontemps, P. Defourny, and B. Koetz, “Assessment of an Operational System for Crop Type Map Production Using High Temporal and Spatial Resolution Satellite Optical Imagery,” en, *Remote Sensing*, vol. 7, no. 9, pp. 12 356–12 379, Sep. 2015, Number: 9 Publisher: Multidisciplinary Digital Publishing Institute. doi: 10.3390/rs70912356. [Online]. Available: <https://www.mdpi.com/2072-4292/7/9/12356> (visited on 05/12/2020).
- [51] A. Unnikrishnan, S. Vishvanathan, and S. Kp, “Deep learning architectures for land cover classification using red and near-infrared satellite images,” *Multimedia Tools and Applications*, Jan. 2019. doi: 10.1007/s11042-019-7179-2.