

Γεωργία Ακριβείας

&

Μηχανική Μάθηση

από

Φοιτητής: Δημήτριος Αντωνόπουλος

A.M.: 18389066

Επιβλέπων Καθηγητής: Νικολάου Γρηγόριος

Διατριβή για λήψη *Βασικού Πτυχίου/Διπλώματος*

Τμήμα Μηχανικών Βιομηχανικής Σχεδίασης και Παραγωγής

Πανεπιστήμιο Δυτικής Αττικής

Αιγάλεω – Αθήνα, Μάρτιος 2023

Επιτροπή Αξιολόγησης Διπλωματικής Εργασίας

Η παρούσα διπλωματική εργασία εξετάστηκε επιτυχώς από την παρακάτω αναφερόμενη εξεταστική επιτροπή:

No	Όνοματεπώνυμο	Ψηφιακή Υπογραφή
1	Νικολάου Γρηγόριος	
2	Βασιλειάδου Σουλτάνα	
3	Δρόσος Χρήστος	

Δήλωση Συγγραφέα Διπλωματικής Εργασίας

Ο κάτωθι υπογεγραμμένος Δημήτριος Αντωνόπουλος του Χρήστου, με αριθμό μητρώου 18389066 φοιτητής του Πανεπιστημίου Δυτικής Αττικής της Σχολής Μηχανικών του Τμήματος Μηχανικών Βιομηχανικής σχεδίασης και παραγωγής, δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της πτυχιακής/διπλωματικής εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του πτυχίου μου».

Ο Δηλών

Δημήτριος Αντωνόπουλος



Περιεχόμενα

ΠΕΡΙΛΗΨΗ	7
ΑΝΑΓΝΩΡΙΣΕΙΣ	9
ΕΝΟΤΗΤΑ 1 ^η	10
Κεφάλαιο 1: Γεωργία Ακριβείας.....	10
1.1 Εισαγωγή στη διατριβή	10
1.2 Εισαγωγή στο Αντικείμενο.....	12
1.3 Ορισμοί.....	15
1.4 Θεωρητικές Πληροφορίες	16
1.5 Δομικά Στοιχεία ενός Γεωργικού Συστήματος Ακριβείας	18
1.6 Συλλογή Δεδομένων – Χαρτογράφηση.....	19
1.7 Τεχνολογικές Εξελίξεις στο Πεδίο	21
1.8 Παγκόσμια Γεωργία Ακριβείας.....	23
1.9 Οφέλη Γεωργίας Ακριβείας.....	28
1.10 Περιβαλλοντικές Ανησυχίες από τη Γεωργία Ακριβείας.....	30
1.11 Συμπεράσματα.....	31
Κεφάλαιο 2: Εφαρμογές στη Γεωργία Ακριβείας	32
2.1 Εισαγωγή στο Αντικείμενο	32
2.2 Κύριες εφαρμογές.....	33
2.2.1 Δειγματοληψία και Χαρτογράφηση Εδάφους	33
2.2.2 Άρδευση	34
2.2.3 Λίπανση.....	34
2.2.4 Ασθένειες καλλιεργειών & Διαχείριση Παρασίτων	36
2.2.5 Παρακολούθηση Απόδοσης, Πρόβλεψη και Συγκομιδή.....	37
2.3 Μη επανδρωμένα ιπτάμενα οχήματα (Unmanned Aerial Vehicle UAV) στη γεωργία	38
2.3.1 Ανάλυση Εδάφους και Πεδίου	39
2.3.2 Φύτευση.....	40
2.3.3 Παρακολούθηση Καλλιεργειών	40
2.3.4 Άρδευση	40
2.3.5 Καταμέτρηση Φυτών και Ανίχνευση Κενών.....	41
2.3.6 Ψεκασμός Φυτοφαρμάκων/Ζιζανιοκτόνων.....	41
2.3.7 Αξιολόγηση Υγείας Καλλιεργειών.....	41
2.3.8 Ανίχνευση - Αναγνώριση Φυτικών Ειδών	42
2.4 Επανδρωμένα και μη επίγεια οχήματα στη γεωργία	42

2.4.1 Τρακτέρ με Βάση το IoT	42
2.4.2 Ρομπότ Συγκομιδής	42
2.5 Συμπεράσματα.....	46
Κεφάλαιο 3: Εξοπλισμός & Τεχνολογίες Γεωργίας Ακριβείας	47
3.1 Εισαγωγή στο αντικείμενο	47
3.2 Ασύρματοι Αισθητήρες.....	48
1) Ακουστικοί Αισθητήρες.....	49
2) Προγραμματιζόμενοι Αισθητήρες Πυλών Πεδίου (FPGA)	49
3) Οπτικοί Αισθητήρες.....	49
4) Υπερηχητικοί Αισθητήρες	50
5) Ηλεκτροχημικοί Αισθητήρες	50
6) Ηλεκτρομαγνητικοί Αισθητήρες.....	50
7) Μηχανικοί Αισθητήρες	51
8) Αισθητήρες Ροής Μάζας.....	51
9) Αισθητήρες με Βάση τη Μεταβλητότητα	51
11) Ανίχνευση Φωτός και Εμβέλειας (LIDAR)	52
12) Αισθητήρες Τηλεματικής	52
13) Τηλεπισκόπηση	52
3.3 Πρωτόκολλα Επικοινωνίας στις γεωργία	53
1) Κυψελοειδής Επικοινωνία (CELLULAR COMMUNICATION)	53
2) ZigBee	54
3) Bluetooth.....	54
4) Lora	55
5) Sigfox	55
3.4 Ανάλυση Δεδομένων.....	55
Παραδείγματα Εφαρμογών Ανάλυσης Δεδομένων	57
3.5 Μηχανική Όραση (Computer vision).....	58
3.6 Μηχανική Μάθηση (Machine Learning).....	59
Συμπεράσματα Μελέτης – Προτάσεις για μελλοντική έρευνα	60
Ενότητα 2 ^H	64
Επιλογή Δεδομένων	64
Επιλογή Πλατφόρμας.....	65
Εισαγωγή Βιβλιοθηκών.....	65
Εισαγωγή Δεδομένων.....	68
Ανάλυση Δεδομένων.....	68
Στάδιο Εκπαίδευσης.....	74

ALEXNET.....	74
VGG16.....	79
MobileNet_V2.....	83
Inception_V3.....	88
Επιλογή Βέλτιστου Μοντέλου.....	95
ΠΗΓΕΣ.....	102
ΠΑΡΑΡΤΗΜΑ.....	110

ΠΕΡΙΛΗΨΗ

Η γεωργία ακριβείας, γνωστή και ως έξυπνη γεωργία, έχει αναδειχθεί ως ένα καινοτόμο εργαλείο για την αντιμετώπιση των τρεχουσών προκλήσεων στη γεωργική βιωσιμότητα. Ο μηχανισμός που οδηγεί αυτήν την τεχνολογία αιχμής είναι η μηχανική μάθηση (Machine Learning). Δίνεται δηλαδή στη μηχανή η δυνατότητα να μαθαίνει χωρίς να είναι ρητά προγραμματισμένη. Το Machine Learning μαζί με το Internet of Things (IoT) δίνουν στα αγροτικά μηχανήματα τη δυνατότητα να αποτελούν βασικά συστατικά της επόμενης αγροτικής επανάστασης.

Η γεωργία ακριβείας είναι μία από τις λύσεις για τη διασφάλιση της επισιτιστικής ασφάλειας για ολόκληρο τον κόσμο. Η γεωργία ακριβείας που επίσης συντομογραφείται ως ψηφιακή γεωργία, είναι ένα σύστημα βιώσιμης διαχείρισης αγροκτημάτων βασισμένο σε τεχνολογικά δεδομένα. Είναι βασικά η υιοθέτηση σύγχρονων ενημερωτικών τεχνολογιών, εργαλείων λογισμικού και έξυπνων ενσωματωμένων συσκευών για υποστήριξη διαφόρων αποφάσεων στη γεωργία.

Σκοπός της παρούσας εργασίας είναι η ολιστική προσέγγιση της γεωργίας ακριβείας, καθώς και η διερεύνηση των εξελίξεων που έχουν επιτευχθεί στον συγκεκριμένο τομέα. Στο πρώτο κεφάλαιο γίνεται μία αναλυτική παρουσίαση του όρου γεωργία ακριβείας, των πλεονεκτημάτων και των μειονεκτημάτων της εξέλιξης αυτής στον τομέα της γεωργίας, παρουσιάζονται οι πρακτικές εφαρμογές της καθώς και τα οφέλη, αλλά και οι περιβαλλοντικές ανησυχίες που επικρατούν παγκοσμίως.

Στο δεύτερο κεφάλαιο παρουσιάζονται παραδείγματα πρακτικών εφαρμογών της γεωργίας ακριβείας, όπως είναι οι εφαρμογές στη λίπανση, την άρδευση, την παρακολούθηση της απόδοσης και των ασθενειών. Στο τρίτο κεφάλαιο παραθέτονται πληροφορίες, σχετικά με τον εξοπλισμό και τις τεχνολογίες που περιλαμβάνονται σε ένα σύστημα γεωργίας ακριβείας. Ειδικότερα, γίνεται αναφορά στα συστήματα αισθητήρων που χρησιμοποιούνται και στις δυνατότητές τους. Ακόμη, αναλύονται πληροφορίες, που αφορούν τα δίκτυα επικοινωνίας που αναπτύσσονται αυτή τη στιγμή στη γεωργία ακριβείας, τα πλεονεκτήματα και τα μειονεκτήματά τους, καθώς και τον τρόπο δημιουργίας και λειτουργίας τους. Σημαντική αναφορά γίνεται και για πιο σύνθετες και καιρίες, χρησιμοποιούμενες τεχνολογίες αιχμής, όπως οι: Computer

Vision, Machine Learning και Data Analysis, καθώς και σε παραδείγματα εφαρμογών για μεγαλύτερη κατανόηση. Στο τέταρτο κεφάλαιο παρουσιάζονται τα συμπεράσματα της παρούσας έρευνας και γίνεται αναφορά στους περιορισμούς που εντοπίστηκαν κατά την εκπόνηση της.

Στην Ενότητα 2 της παρούσας εργασίας παρουσιάζονται παραδείγματα ανάπτυξης αλγόριθμου Μηχανικής Μάθησης (Machine Learning ML) και Τεχνητής Νοημοσύνης (Artificial Intelligence, AI). Σκοπός της ενότητας αυτής είναι, να αναδείξει τη χρήση απλών διαδικτυακών εργαλείων για την υλοποίηση κώδικα κατηγοριοποίησης και πρόβλεψης νέων δεδομένων. Τα δεδομένα αυτά σχετίζονται με τη γεωργία ακριβείας και συγκεκριμένα χρησιμοποιείται αλγόριθμος μηχανικής μάθησης για την κατηγοριοποίηση και πρόβλεψη των δεδομένων, σχετικά με διάφορες ασθένειες φυτών στο φύλλωμα τους.

ΑΝΑΓΝΩΡΙΣΕΙΣ

Θα ήθελα να εκφράσω τις ειλικρινείς ευχαριστίες μου στον κύριο επιβλέποντα Νικολάου Γρηγόριο (Λέκτορα) για τη συνεχή υποστήριξη της πτυχιακής μου διατριβής καθώς και για τα κίνητρα που μου έδωσε, να ερευνήσω εις βάθος ένα ιδιαίτερα σημαντικό και αξιοσημείωτο θέμα, αυτό της Γεωργίας Ακριβείας και της Μηχανικής Μάθησης. Με τη στήριξή του με βοήθησε να καταλάβω ποια βήματα έπρεπε να ακολουθήσω για να ολοκληρώσω με επιτυχία τη συγγραφή της διατριβής μου.

Ευχαριστώ από καρδιάς την οικογένειά μου, που με στήριξε με κάθε δυνατό τρόπο, τόσο πνευματικά, και οικονομικά, όσο και ψυχολογικά, ώστε να ολοκληρώσω επιτυχώς την διατριβή μου. Τους ευχαριστώ ιδιαίτερα για την ενθάρρυνση, την υπομονή και την επιμονή που μου υπέδειξαν να με διακατέχουν σε κάθε εμπόδιο ή δυσκολία που συναντούσα σε κάθε «βήμα» της διαδρομής μου.

ΕΝΟΤΗΤΑ 1^η

Κεφάλαιο 1: Γεωργία Ακριβείας

1.1 Εισαγωγή στη διατριβή

Οι πρώτοι αγρότες καλλιεργούσαν μεμονωμένα είδη φυτών και αναζητούσαν το μικροκλίμα, κάθε περιοχής και το κατάλληλο έδαφος, που ευνοούσαν την ανάπτυξή τους. Καθώς οι αγρότες άρχισαν να αποκτούν, με το πέρασμα των αιώνων, επιστημονικές και μηχανικές γνώσεις, διεύρυναν τις καλλιέργειές τους, χρησιμοποιώντας τυποποιημένες προσεγγίσεις, όπως το όργωμα του εδάφους, η διασπορά ζωικής κοπριάς ως λίπασμα, αλλά και την εναλλαγή των καλλιεργειών από έτος σε έτος, για να αυξήσουν έτσι τις αποδόσεις των καλλιεργειών τους. Με τα χρόνια, ανέπτυξαν καλύτερες μεθόδους επεξεργασίας του εδάφους και προστασίας των φυτών από έντομα. Ταυτόχρονα, δημιουργήθηκαν γεωργικά μηχανήματα που συνέβαλλαν στη μείωση της απαιτούμενης εργασίας. Το 19^ο αιώνα εφευρέθηκαν από τους επιστήμονες τα πρώτα χημικά φυτοφάρμακα και άρχισαν να χρησιμοποιούνται γενετικές μέθοδοι για να επιλεχθούν τα πιο παραγωγικά φυτά. Η μεγιστοποίηση της γεωργικής παραγωγής με τη χρήση των παραπάνω μεθόδων είχε ως αποτέλεσμα, ορισμένες γεωργικές εκτάσεις να παρουσιάσουν χαμηλή απόδοση μετά από κάποιο χρονικό διάστημα, λόγω της συνεχιζόμενης υπερ-εκμετάλλευσης. Ωστόσο, το ζήτημα της χαμηλής απόδοσης του εδάφους δεν θεωρήθηκε σημαντικό μπροστά στο δεκαπλασιασμό της γεωργικής παραγωγής από τον 19^ο αιώνα έως σήμερα (Grassi, 2015).

Σήμερα, ωστόσο κατά τον Grassi (2015), οι συμβατικές γεωργικές πρακτικές αντιστρέφονται, χάρη στη νέα τάση που είναι γνωστή ως «γεωργία ακριβείας». Με την εκμετάλλευση της τεχνολογίας των πληροφοριών, οι αγρότες μπορούν τώρα να συλλέγουν ακριβή δεδομένα για τα χωράφια και τις καλλιέργειές τους και να αξιοποιούν αυτά τα δεδομένα για να προσαρμόσουν τον τρόπο με τον οποίο καλλιεργούν, βελτιστοποιώντας τη παραγωγή τους.

Σύμφωνα με έγκυρες μετρήσεις από διεθνείς οργανισμούς, η γεωργία ακριβείας επιτρέπει στους αγρότες να εξάγουν όσο το δυνατόν περισσότερη αξία από κάθε σπόρο. Αυτό θα βοηθήσει στη διατροφή του παγκόσμιου πληθυσμού, που ο ΟΗΕ προβλέπει

ότι θα ανέλθει στα 9,6 δισεκατομμύρια έως το 2050. Επιπλέον, η γεωργία ακριβείας στοχεύει στην ελαχιστοποίηση των περιβαλλοντικών επιπτώσεων της γεωργίας, καθώς μειώνει τα παραγόμενα απόβλητα και χρησιμοποιεί λιγότερη ενέργεια (Grassi, 2015).

Η πίεση που δέχονται παγκοσμίως οι αγρότες, για να εξασφαλίσουν τροφή για όλο και περισσότερο πληθυσμό, διαρκώς αυξάνεται. Από την αντίθετη πλευρά οι καταναλωτές γίνονται όλο και πιο επιλεκτικοί στα τρόφιμα που καταναλώνουν. Στην Ευρωπαϊκή Ένωση, η αγορά βιολογικών προϊόντων αυξήθηκε κατά 7,4% το 2014, με τις πωλήσεις να ανέρχονται σε 24 δισεκατομμύρια ευρώ. Εκτός από τη ζήτηση για περισσότερα βιολογικά τρόφιμα, οι διεθνείς φορείς, παγκοσμίως, αλλά και οι συνέπειες της κλιματικής αλλαγής ωθούν τη γεωργία να υιοθετήσει τεχνικές φιλικότερες προς το περιβάλλον, περιορίζοντας τη χρήση νερού και φυτοφαρμάκων. Χαρακτηριστική είναι η αναφορά της τεχνολογικής εταιρείας Deepfield Robotics, ότι «Η γεωργία είναι πιο ευάλωτη στις επιπτώσεις της κλιματικής αλλαγής, αλλά είναι επίσης μία από τις αιτίες της και είναι απαραίτητο να καταστεί η καλλιέργεια βιώσιμη» (van Poppel, 2016).

Σύμφωνα με τον van Poppel (2016), οι προαναφερόμενες συνθήκες (κλιματική αλλαγή και αύξηση πληθυσμού), ωθούν τους αγρότες να παράγουν μεγαλύτερες ποσότητες, ωστόσο αυτό θα πρέπει να συμβεί με βιώσιμο τρόπο για το περιβάλλον και καλύτερη ποιότητα για τους καταναλωτές. Αποκλειστικός στόχος της γεωργίας ακριβείας δεν είναι η αύξηση της παραγωγής καλλιεργειών, όπως το σιτάρι και το καλαμπόκι, αλλά η δυνατότητα να προσφέρει νέες τεχνικές και μεθόδους παρακολούθησης και διαχείρισης των γεωργικών καλλιεργειών και της κτηνοτροφικής παραγωγής (van Poppel, 2016).

Η απομάκρυνση της νεολαίας από τον τομέα της γεωργίας και η έλλειψη έμπειρου εργατικού δυναμικού δημιουργούν τις προϋποθέσεις για την ταχύτερη ενσωμάτωση καινοτόμων τεχνολογιών. Στο μέλλον, πιθανότατα, οι αγρότες θα εξαρτώνται από ρομποτικά μηχανήματα για να αξιολογήσουν, να γονιμοποιήσουν και να ποτίσουν κάθε μεμονωμένο φυτό της καλλιέργειάς τους, εξαλείφοντας έτσι την αγγαρεία που χαρακτηρίζει τη γεωργία από την εφεύρεσή της (Grassi, 2015).

Κατά τους Serraj και Pingali (2019), οι αγροτικοί αυτοματισμοί με προηγμένα μηχανολογικά και ηλεκτρονικά μέρη θα κυριαρχήσουν στις γεωργικές εργασίες, στο

άμεσο μέλλον. Μηχανήματα διαφόρων τύπων και εργασιών θα είναι διαθέσιμα στα χέρια των αγροτών και σε προσιτή τιμή στο άμεσο μέλλον. Η ανάπτυξη της τεχνητής νοημοσύνης θα συνεχιστεί, ώστε να επιτευχθεί η μέγιστη δυνατή προώθηση των γεωργικών συστημάτων όπως, για παράδειγμα, αυτοκινούμενων αγροτικών οχημάτων, χωρίς οδηγό, αυτοματοποιημένων συστημάτων άρδευσης και αναγνώρισης προσώπου βοοειδών και άλλα.

Επιπλέον, με τη χρήση μηχανικής μάθησης πρόκειται να παραχθούν εξελιγμένοι αλγόριθμοι οι οποίοι αναμένεται να συμβάλλουν στην ενίσχυση των εφαρμογών της τεχνητής νοημοσύνης στη γεωργία ακριβείας. Ταυτόχρονα, η επεξεργασία, η ανάλυση, ο έλεγχος και η προσαρμογή γεωργικών δεδομένων σε πραγματικό χρόνο θα διαδραματίσουν σημαντικό ρόλο στην υποστήριξη αποφάσεων σε γεωργικές εργασίες και διαχείριση ακριβείας (Serraj & Pingali, 2019).

1.2 Εισαγωγή στο Αντικείμενο

Στο παρόν κεφάλαιο παρουσιάζονται θεωρητικές πληροφορίες, σχετικά με τη γεωργία ακριβείας. Ειδικότερα γίνεται αναφορά σε διαφορετικούς ορισμούς της γεωργίας ακριβείας από διάφορους μελετητές, ερευνητές και από επίσημους οργανισμούς. Παρουσιάζονται ιστορικά και στατιστικά στοιχεία ένταξης της γεωργίας ακριβείας σε καλλιέργειες χωρών ανά τον κόσμο, καθώς και τα οφέλη που προκύπτουν από τη χρήση της. Επιπλέον, εκφράζονται περιβαλλοντικές ανησυχίες, οι ανησυχίες των αγροτών, τα οφέλη και τα δομικά στοιχεία ενός συστήματος γεωργίας ακριβείας.

Η γεωργία ακριβείας ασκούνταν αρχικά από αγρότες που εργάζονταν χειρωνακτικά σε χωράφια. Με τη γεωργική μηχανοποίηση, η γεωργία ακριβείας εφαρμόστηκε στη διαχείριση της συγκεκριμένης εκμετάλλευσης με βάση τους χάρτες απόδοσης και εδάφους. Στη δεκαετία του 2010, με την ανάπτυξη του διαδικτύου και των κινητών τεχνολογιών, η γεωργία ακριβείας άρχισε να παρέχει υπηρεσίες στο διαδίκτυο μέσω κινητών πλατφορμών με ασύρματα δικτυωμένους αισθητήρες. Τώρα, τεχνολογίες όπως τα μη επανδρωμένα εναέρια οχήματα (UAV), τα μεγάλα δεδομένα (Big Data), η τεχνητή νοημοσύνη και ο αυτοματισμός έχουν αναπτυχθεί για εφαρμογή σε όλες τις πτυχές της ανθρώπινης καθημερινότητας για να βοηθήσουν στην επίλυση ζητημάτων στην κοινωνία, τις κατασκευές, την παραγωγή και τη γεωργία (Serraj, Pingali, 2019).

Κατά τους Serraj και Pingali (2019), η γεωργία ακριβείας παρέχει την ευκαιρία άμεσης ανταπόκρισης στις μεταβαλλόμενες κλιματικές συνθήκες και στους ολοένα ακριβότερους σπόρους και άλλες γεωργικές εισροές, οι οποίες μειώνουν την κερδοφορία των εκμεταλλεύσεων παγκοσμίως. Τα επόμενα δέκα χρόνια, η νέα γενιά γεωργίας ακριβείας θα χαρακτηρίζεται από υπηρεσίες υψηλής απόδοσης, από εντατική ανάλυση μεγάλων δεδομένων, από τεχνητή νοημοσύνη, αντίληψη, έλεγχο και αυτοματοποίηση σε πραγματικό χρόνο. Δεδομένης της αναδύομενης προόδου στις τεχνολογίες πληροφοριών και ηλεκτρονικών, η γεωργία ακριβείας αναμένεται να αναπτυχθεί ακόμη περισσότερο την επόμενη δεκαετία.

Σύμφωνα με την άποψη των Zhang et al. (2002), μετά από περισσότερα από δέκα χρόνια ανάπτυξης, η γεωργία ακριβείας έχει φτάσει σε ένα σταυροδρόμι, όπου η απαραίτητη τεχνολογία είναι μεν διαθέσιμη, αλλά με τα περιβαλλοντικά και οικονομικά οφέλη να μην έχουν ακόμη αποδειχθεί. Μάλιστα οι ίδιοι υποστηρίζουν πως έχουν παρουσιαστεί πολλές τεχνολογικές καινοτομίες, αλλά η ανάπτυξη αγρονομικών και οικολογικών αρχών για βελτιστοποιημένες συστάσεις, για εισροές σε τοπικό επίπεδο καθυστερούν. Πολλοί γεωργοί δεν είναι βέβαιοι, εάν θα υιοθετήσουν τις διαθέσιμες τεχνολογίες γεωργίας ακριβείας στις εκμεταλλεύσεις τους.

Οι Zhang et al. (2002) πιστεύουν πως υπάρχουν πολλά κίνητρα που μπορούν να ωθήσουν τους αγρότες σε μια ευρεία υιοθέτηση των γεωργικών τεχνολογιών και μάλιστα πιστεύουν πως ποικίλουν. Μερικά από αυτά, θα μπορούσαν να προέρχονται από την αυστηρή περιβαλλοντική νομοθεσία, την ανησυχία των καταναλωτών για την υπερβολική χρήση αγροχημικών προϊόντων, το οικονομικό όφελος από τη μείωση των περιττών γεωργικών εισροών και τη βελτίωση της αποτελεσματικότητας της διαχείρισης των γεωργικών εκμεταλλεύσεων. Σε τελική ανάλυση, η επιτυχία των τεχνολογιών γεωργίας ακριβείας θα εξαρτηθεί από τα οικονομικά και περιβαλλοντικά οφέλη (Zhang et al., 2002).

Το 1998, ο οργανισμός USDA (United States Department of Agriculture) διεξήγαγε μια πανεθνική έρευνα για την οποία απευθύνθηκε σε 8500 γεωργικούς παραγωγούς στις ΗΠΑ. Σύμφωνα με τα αποτελέσματα της έρευνας, προέκυψε το συμπέρασμα ότι, μέχρι το 1998, μόνο το 4% όλων των γεωργικών εκμεταλλεύσεων χρησιμοποιούσαν μία ή περισσότερες τεχνολογίες γεωργίας ακριβείας, για τη φυτική παραγωγή (Zhang

et al., 2002). Από την έρευνα προέκυψε ότι, οι πιο ευρέως αποδεκτές τεχνολογίες ήταν η δειγματοληψία πλέγματος (2% όλων των εκμεταλλεύσεων) και η τεχνολογία μεταβλητού ρυθμού (VRT – *Variable Rate Technology*, τεχνολογία γεωργίας ακριβείας που βοηθά τους αγρότες να εφαρμόζουν τις συλλεγόμενες πληροφορίες σχετικά με τις δραστηριότητές τους για να κατευθύνουν την αυτοματοποιημένη και μεταβλητή εφαρμογή σπόρων, λιπασμάτων και χημικών εφαρμογών στη καλλιεργήσιμη γη τους) για λίπασμα (2%). Επιπλέον, ακολουθούν η τεχνολογία παρακολούθησης απόδοσης (1%) και η χαρτογράφηση απόδοσης (1%). Οι τεχνολογίες εφαρμογής σπόρων και φυτοφαρμάκων μεταβλητού ρυθμού και τηλεπισκόπησης χρησιμοποιήθηκαν μόνο σε λιγότερο από το 1% όλων των εκμεταλλεύσεων (Zhang et al., 2002).

Επιπρόσθετο συμπέρασμα της έρευνας ήταν ότι οι γεωργικές εκμεταλλεύσεις σιτηρών και ελαιούχων σπόρων έχουν το υψηλότερο ποσοστό υιοθέτησης γεωργικών τεχνολογιών (14%). Το ποσοστό υιοθέτησης για εξειδικευμένες εκμεταλλεύσεις φρούτων, λαχανικών και ξηρών καρπών ανέρχεται στο 5%. Η κύρια τεχνολογία γεωργίας ακριβείας που χρησιμοποιήθηκε σε αυτές τις εκμεταλλεύσεις ήταν μεταβλητού ρυθμού (VRT) για τον έλεγχο των φυτοφαρμάκων (Zhang et al., 2002).

Σε άλλη έρευνα που μελετούν οι Zhang et al. (2002), διαπιστώθηκε ότι οι αγρότες στην Αυστραλία υιοθετούν τεχνολογίες γεωργίας ακριβείας πιο αργά από το αναμενόμενο. Αυτό οφείλεται κυρίως σε τέσσερις παράγοντες: 1) κόστος εφαρμογής, 2) έλλειψη αντιληπτού οφέλους από την πρακτική εφαρμογή, 3) απροθυμία για πρόωρη εφαρμογή και 4) έλλειψη του κατάλληλου τεχνολογικού μηχανισμού. Αν και το κόστος, η έλλειψη αντιληπτού οφέλους και ο συντηρητισμός μεταξύ των γεωργών είναι ορισμένοι από τους λόγους που καθυστερούν την υιοθέτηση τους, το μεγαλύτερο πρόβλημα εντοπίζεται στην παράδοση των τεχνολογιών της γεωργίας ακριβείας στους αγρότες. Η παροχή εξειδικευμένων τεχνολογιών γεωργίας ακριβείας στους αγρότες απαιτεί γνώσεις και δεξιότητες, που δεν είναι ευρέως διαθέσιμες. Ο συντηρητισμός του τομέα των γεωργικών συμβουλευτικών υπηρεσιών φάνηκε να δημιουργεί περισσότερες δυσκολίες από τον συντηρητισμό των αγροτών στην εφαρμογή των αντίστοιχων τεχνολογιών.

Έρευνα που διεξήχθη στο Ηνωμένο Βασίλειο (Zhang et al., 2002) απευθυνόταν μεταξύ του 25% περίπου 350 αγροτών που διεξάγουν επί του παρόντος χαρτογράφηση

απόδοσης χρησιμοποιώντας GPS. Οι γεωργοί που υιοθετούν τη χαρτογράφηση της απόδοσης χρειάζονται άμεσα χρήσιμες συμβουλές από εξειδικευμένους γεωπόνους σχετικά με την ερμηνεία των χαρτών απόδοσης και τη μετατροπή τους σε σχέδια διαχείρισης. Οι πληροφορίες χαρτογράφησης της απόδοσης πρέπει να ενσωματωθούν στα συστήματα υποστήριξης αποφάσεων της εκμετάλλευσης.

Παρόμοια έρευνα που διεξήχθη στο Αρκάνσας των Ηνωμένων Πολιτειών (Zhang et al., 2002) έδειξε ότι μόνο το 20% των αγροτών υιοθέτησαν σχετικές γεωργικές τεχνολογίες. Όσοι τις υιοθέτησαν είναι νέοι ηλικιακά, με υψηλό μορφωτικό επίπεδο, που χρησιμοποιούν υπολογιστές, έμπειροι αγρότες με μεγάλες ποσότητες στρεμμάτων που αφιερώνονται κυρίως στο ρύζι και τη σόγια. Επιπλέον, φάνηκε πως οι εκπρόσωποι της γεωργικής βιομηχανίας συμβάλλουν στην προώθηση των γεωργικών τεχνολογιών, ενώ παρέχονται και συμβουλές από ειδικούς.

Τέλος στην έρευνά τους οι Zhang et al. (2002) συμπεραίνουν ό,τι η γεωργία ακριβείας πιθανότατα θα κερδίσει μεγαλύτερη αναγνώριση όταν πρόσθετα οφέλη, όπως η μείωση των περιβαλλοντικών επιβαρύνσεων και η αυξημένη ροή πληροφοριών, αναγνωριστούν ως μέρος των ανταμοιβών της.

1.3 Ορισμοί

Η γεωργία ακριβείας ξεκίνησε να απασχολεί την επιστημονική κοινότητα, περίπου τη δεκαετία του '90, οπότε και άρχισαν να δημιουργούνται οι πρώτοι ορισμοί από τους επιστήμονες. Ο οργανισμός ISPA (International Society of Precision Agriculture) έχει υιοθετήσει ως επίσημο ορισμό τον εξής:

«Η Γεωργία Ακριβείας είναι μια στρατηγική διαχείρισης που συγκεντρώνει, επεξεργάζεται και αναλύει χρονικά, χωρικά και μεμονωμένα δεδομένα και τα συνδυάζει με άλλες πληροφορίες για να υποστηρίξει τις αποφάσεις διαχείρισης σύμφωνα με την εκτιμώμενη μεταβλητότητα για τη βελτίωση της αποδοτικότητας της χρήσης των πόρων, της παραγωγικότητας, της ποιότητας, της κερδοφορίας και της βιωσιμότητας της γεωργικής παραγωγής».

Επιπλέον, ο οργανισμός έχει δημιουργήσει ένα ευρετήριο ορισμών που έχουν διατυπώσει ερευνητές οι οποίοι έχουν ασχοληθεί με αυτόν τον τομέα της επιστήμης. Ενδεικτικά, μερικοί ορισμοί αναφέρονται παρακάτω:

Η γεωργία ακριβείας είναι μια στρατηγική διαχείρισης που χρησιμοποιεί τεχνολογίες πληροφοριών για να φέρει δεδομένα από πολλαπλές πηγές σε αποφάσεις που σχετίζονται με τη φυτική παραγωγή. (The National Research Council, 1997)

Κατά τους McBratney & Taylor (2000), «η γεωργία ακριβείας είναι η χρήση νέων τεχνολογιών πληροφοριών σε συνδυασμό με τη γεωπονική εμπειρία για την: 1) μεγιστοποίηση της απόδοσης της παραγωγής, 2) τη μεγιστοποίηση της ποιότητας, 3) την ελαχιστοποίηση των περιβαλλοντικών επιπτώσεων, 4) την ελαχιστοποίηση του ρίσκου.

Σύμφωνα με τους Fountas et al. (2016), η Γεωργία Ακριβείας μπορεί να οριστεί ως η διαχείριση της χωρικής και χρονικής μεταβλητότητας στα πεδία με τη χρήση Τεχνολογιών Πληροφορικής και Επικοινωνιών (ΤΠΕ).

Επίσης, η γεωργία ακριβείας ορίζεται ως η λειτουργία ενός συγκεκριμένου αγρού για τη διαχείριση της μεταβλητότητας εντός του αγρού (Zhang et al., 2002). Φαίνεται πως η γεωργία ακριβείας εφαρμοζόταν πρακτικά, αρχικά από αγρότες που εργάζονταν σε χωράφια. Με τη γεωργική μηχανοποίηση, η γεωργία ακριβείας εφαρμόστηκε στη διαχείριση της συγκεκριμένης εκμετάλλευσης με βάση τους χάρτες απόδοσης της παραγωγής και του εδάφους.

Συμπερασματικά η γεωργία ακριβείας ορίζεται ως μια στρατηγική διαχείρισης που χρησιμοποιεί την τεχνολογία για να συλλέξει δεδομένα από πολλαπλές πηγές αλλά και για να εφαρμόσει αποφάσεις που σχετίζονται με τη φυτική παραγωγή. Τα εργαλεία γεωργίας ακριβείας περιλαμβάνουν εργαλεία συλλογής πληροφοριών, όπως συσκευές παρακολούθησης της απόδοσης, στοχευμένη δειγματοληψία εδάφους και εργαλεία τηλεπισκόπησης, συστήματα καθοδήγησης και άλλα.

1.4 Θεωρητικές Πληροφορίες

Υπάρχουν πολλοί ορισμοί της γεωργίας ακριβείας οι οποίοι συχνά επηρεάζονται από τον εμπορικό εξοπλισμό ή την τεχνολογία που βρίσκεται επί του παρόντος διαθέσιμη

στην αγορά. Η γεωργία ακριβείας θα μπορούσε να οριστεί ως ένα σύστημα διαχείρισης που βασίζεται στην πληροφορία και την τεχνολογία, είναι εξειδικευμένο για κάθε τόπο και χρησιμοποιεί, ως πηγές δεδομένων τα στοιχεία εδάφους, τις καλλιέργειες, τα θρεπτικά συστατικά, τα παράσιτα, την υγρασία και την απόδοση, για βέλτιστη κερδοφορία, βιωσιμότητα και προστασία του περιβάλλοντος.

Η έρευνα του Lowenberg-DeBoer (1996) αναφέρει ό,τι τα αποτελέσματα από τη χρήση της γεωργίας ακριβείας μπορούν να διαφέρουν σε κάθε περίπτωση. Ορισμένα από τα αποτελέσματα έχουν να κάνουν με τη μείωση του κόστους και την αποτελεσματικότερη χρήση των αναλώσιμων υλικών, όπως τα λιπάσματα, τη χρήση της τεχνολογίας των πληροφοριών για την αύξηση του μεγέθους και του πεδίου εφαρμογής των γεωργικών εργασιών χωρίς ταυτόχρονη αύξηση των εργατοωρών και του εργατικού δυναμικού. Επιπλέον, η χρήση της γεωργίας ακριβείας μπορεί να συμβάλλει στην επιλογή κατάλληλων χώρων καλλιέργειας και στον έλεγχο των διαδικασιών παραγωγής, που βοηθούν στην παραγωγή προϊόντων υψηλότερης αξίας ή ειδικότητας. Επιπροσθέτως, συμβάλλει στη βελτίωση της τήρησης αρχείων και την παρακολούθηση της παραγωγής για την ασφάλεια των τροφίμων και την προστασία του περιβάλλοντος.

Από την πλευρά του γεωργού, η γεωργία ακριβείας καθοδηγείται κυρίως από την οικονομική απόδοση της καλλιέργειας και δευτερευόντως από τις θετικές περιβαλλοντικές επιπτώσεις που προσδίδει. Οι θετικές περιβαλλοντικές επιπτώσεις, σχετίζονται με την ποιότητα του εδάφους και των υδάτων, και μπορούν να προκύψουν από τη μειωμένη ή στοχευμένη εφαρμογή εισροών, όπως θρεπτικά συστατικά, φυτοφάρμακα και αρδευτικό νερό. Επιπλέον, πλεονέκτημα, όπως διατυπώνεται στην έρευνα των Bongiovanni και Lowenberg-DeBoer (2004), είναι η χρήση της γεωργίας ακριβείας για τον ακριβή έλεγχο του εξοπλισμού που λειτουργεί σε ένα χωράφι για τη μείωση της συμπίεσης και της διάβρωσης του εδάφους. Σε πρώτο και βασικό επίπεδο, η γεωργία ακριβείας περιλαμβάνει απλές πρακτικές, όπως η ανίχνευση πεδίου και η άμεση εφαρμογή φυτοφαρμάκων. Ωστόσο, η γεωργία ακριβείας συνήθως φέρνει στο νου πολύπλοκα, έντονα διαχειριζόμενα συστήματα παραγωγής χρησιμοποιώντας την τεχνολογία του παγκόσμιου συστήματος εντοπισμού θέσης (GPS) για τη χωρική αναφορά του εδάφους, του νερού, της απόδοσης και άλλων δεδομένων για την εφαρμογή μεταβλητού ρυθμού των γεωργικών εισροών σε ένα πεδίο.

Αρκετές, έρευνες βρίσκονται σε εξέλιξη για την ανάπτυξη ή τη βελτίωση μεθόδων και εξοπλισμού παρακολούθησης της απόδοσης, τον προσδιορισμό των οικονομικών και περιβαλλοντικών επιπτώσεων της εφαρμογής των γεωργικών εισροών με μεταβλητό ρυθμό και τη χρήση δεδομένων με τηλεπισκόπηση για τη λήψη συστάσεων διαχείρισης. Πολλοί αγρότες θεωρούν ότι η γεωργία ακριβείας θα τους επιτρέψει να επιτύχουν ομοιόμορφη παραγωγή στη φάρμα τους. Ωστόσο, στην πραγματικότητα ο στόχος της γεωργίας ακριβείας θα πρέπει να είναι η βελτιστοποίηση των εισροών (λιπάσματα, φυτοφάρμακα) για τη γεωργική παραγωγή ανάλογα με την ικανότητα της γης.

Οι μέθοδοι αυτές βοηθούν τους αγρότες να αναγνωρίζουν περιοχές που έχουν προβλήματα παραγωγικότητας και να επιλέγουν την καλύτερη λύση για κάθε μία. Ιδανικά, η γεωργία ακριβείας μπορεί να βοηθήσει έναν παραγωγό να εντοπίσει εκτάσεις που θα πρέπει να αφαιρεθούν από το τρέχον σύστημα παραγωγής. Η αφορμή μιας συμβουλής σαν και αυτής, μπορεί να οφείλεται στην υπό-γονιμότητα του εδάφους της συγκεκριμένης έκτασης. Το αποτέλεσμα θα είναι να προφυλαχτεί ο γεωργός από την ασύστολη χρήση λιπασμάτων και κατά συνέπεια από οικονομική ζημία, αλλά και το περιβάλλον από περαιτέρω μόλυνση (Bongiovanni & Lowenberg-DeBoer, 2004).

Οι προοπτικές της δημογραφικής και οικονομικής έρευνας έχουν δώσει μεγάλη προσοχή τα τελευταία χρόνια στην υιοθέτηση της γεωργίας ακριβείας. Ωστόσο, ελάχιστη προσοχή έχει δοθεί στις αντιλήψεις και τους λόγους συμπεριφοράς των γεωργών να υιοθετήσουν αυτές τις τεχνολογίες. Ενώ το οικονομικό όφελος είναι ο πρωταρχικός λόγος που δίνεται από τους παραγωγούς για να υιοθετήσουν γεωργικές τεχνολογίες ακριβείας, άλλες συμπεριφορές παίζουν ρόλο στην απόφαση έγκρισης. Η εμπιστοσύνη στην αναδυόμενη τεχνολογία της γεωργίας ακριβείας και η αντίληψη του οφέλους που προκύπτει από τη χρήση της επηρεάζουν την πρόθεση των καλλιεργητών να την χρησιμοποιήσουν στη παραγωγή τους (Bongiovanni & Lowenberg-DeBoer, 2004).

1.5 Δομικά Στοιχεία ενός Γεωργικού Συστήματος Ακριβείας

Η γεωργία ακριβείας βασίζεται σε δεδομένα τα οποία συλλέγονται από μετρήσεις οι οποίες πρέπει να επεξεργαστούν κατάλληλα και να αρχειοθετηθούν πριν χρησιμοποιηθούν.

Ένα σύστημα τήρησης αρχείων είναι πολύ σημαντικό για την επιτυχή εφαρμογή της γεωργίας ακριβείας. Με τον συγκεκριμένο τρόπο μπορούν να παραχθούν μεγάλες ποσότητες δεδομένων, οι οποίες αν δεν οργανωθούν σωστά από το γεωργό, ώστε να μπορέσει να επεξεργαστεί τα δεδομένα, τότε η επένδυση θα είναι άσκοπη. Με την κατάλληλη οργάνωση, τα αρχεία μετατρέπονται σε δεδομένα ιστορικού που χρειάζεται ο αγρότης για να λάβει αποφάσεις. Μια διαδικασία ανάλυσης και λήψης αποφάσεων είναι ένα κρίσιμο βήμα για την ανάπτυξη ενός γεωργικού σχεδίου ακριβείας. Τα δεδομένα δεν έχουν νόημα, εκτός εάν αναλύονται σωστά και τα αποτελέσματα εφαρμόζονται για την επίλυση ενός προβλήματος ή την επίτευξη των στόχων της εκμετάλλευσης.

Η αξιολόγηση και η αναθεώρηση του γεωργικού σχεδίου ακριβείας είναι απαραίτητη μετά από κάθε καλλιεργητική περίοδο. Καθώς συλλέγονται περισσότερα δεδομένα για κάθε καλλιέργεια και έτος παραγωγής, τα οποία επιτρέπουν την περαιτέρω βελτίωση ενός γεωργικού σχεδίου ακριβείας. Για την εκτέλεση της ανάλογης απόφασης είναι απαραίτητη η χρήση εξειδικευμένου γεωργικού εξοπλισμού για να επιτευχθεί η μεγαλύτερη ακρίβεια κατά την αντίστοιχη γεωργική δραστηριότητα. Τα συστήματα καθοδήγησης GPS, οι αισθητήρες αγωγιμότητας και μέτρησης υγρασίας και πολλά ακόμα, συμβάλλουν στη συλλογή των απαραίτητων δεδομένων, βοηθώντας στην ανάπτυξη ενός σχεδίου γεωργίας ακριβείας. Η συλλογή δεδομένων, η επεξεργασία τους και η εφαρμογή τους με τη καθοδήγηση αυτόνομων γεωργικών μηχανημάτων θα ήταν αδύνατη, χωρίς την πρόοδο της τεχνολογίας στους αισθητήρες, στην ηλεκτρονική, στην πληροφορική, αλλά και σε άλλους κρίσιμους τομείς που συμβάλλουν στην ανάπτυξη της τεχνολογίας ακριβείας.

1.6 Συλλογή Δεδομένων – Χαρτογράφηση

Στη δεκαετία του 1980 τα δορυφορικά δεδομένα που προβλέπονταν για τη γεωργία ακριβείας ήταν περιορισμένα και χαμηλής ποιότητας. Από το 2010, ωστόσο, η τηλεπισκόπηση δορυφόρων πολύ υψηλής ανάλυσης γίνεται περισσότερο εύχρηστη και

διαθέσιμη στο κόσμο. Συγκεκριμένα, εικόνες υψηλής ανάλυσης από δορυφόρους χαμηλής τροχιάς είναι πλέον εμπορικά διαθέσιμες για έρευνα και γεωργικό σχεδιασμό ακριβείας. Οι εικονολήπτες στα αεροπλάνα μπορούν εύκολα να παρέχουν εικόνες ανάλυσης μισού χιλιομέτρου των γεωργικών πεδίων. Επιπλέον, τα UAV είναι ικανά να παρέχουν εικόνες με αναλύσεις λίγων εκατοστών, ακόμη και χιλιοστών, ανά εικονοστοιχείο. Αυτές οι τεχνολογίες έχουν μετατοπίσει τη γεωργία ακριβείας από τον στρατηγικό σχεδιασμό στη δεκαετία του 1980 στον τακτικό έλεγχο στη δεκαετία του 2010.

Οι εταιρείες που πωλούν γεωργικά αναλώσιμα (λιπάσματα, σπόρους, χημικά) και μηχανήματα, υψηλής αξίας είναι πρόθυμες να επενδύσουν σε δεδομένα που θα αποτυπώνουν το μέγεθος του εμπορικού γεωργικού τομέα μιας χώρας και τις καλλιέργειες που φυτεύονται εκεί. Τα στοιχεία αυτά, ωστόσο, θα πρέπει να πληρούν ορισμένα κριτήρια, όπως να είναι ειδικά για τις καλλιέργειες, να ενημερώνονται ετησίως, να είναι επαρκώς ακριβή, διαθέσιμα σε ανάλυση τουλάχιστον 30 μέτρων για την αποτύπωση μικρών αγρών και διαθέσιμα για τις χώρες ενδιαφέροντος.

Η ακαδημαϊκή κοινότητα τηλεπισκόπησης είχε από καιρό ως στόχο τη δημιουργία ετήσιων χαρτών σιταριού, αραβοσίτου, ρυζιού και σόγιας, αλλά δεν το κατόρθωσε ποτέ λόγω έλλειψης επαρκών δεδομένων δορυφορικής παρατήρησης, υπολογιστικής ισχύος και χρηματοδότησης (Zhang et al., 2002).

Τέτοιοι χάρτες απαιτούν έναν αλγόριθμο που είναι κατασκευασμένος για να επιτρέπει τον υπολογισμό των τάσεων με την πάροδο του χρόνου, να είναι συνεπής με τις γειτονικές περιοχές και να ανταποκρίνεται σε διαφορετικά αγρό-οικολογικά πρότυπα και τύπους εδάφους. Σύμφωνα με πρόσφατη βιβλιογραφία, οι εικόνες που ανιχνεύονται εξ αποστάσεως έχουν χρησιμοποιηθεί για την πρόβλεψη της ανάγκης αζώτου στο καλαμπόκι, για την εκτίμηση της απόδοσης χνουδιού βαμβακιού, για την εκτίμηση της βλάβης των εντόμων στο σιτάρι, για την ανίχνευση ακάρεων αράχνης στο βαμβάκι, για να βοηθήσουν στην εφαρμογή εντομοκτόνων, για την εκτίμηση της συγκέντρωσης αργίλου του επιφανειακού εδάφους, για την ανίχνευση ζιζανίων, για τον ποσοτικό προσδιορισμό των ζημιών από χαλάζι ή τον άνεμο στις καλλιέργειες, ή για την ανίχνευση και ταξινόμηση ανωμαλιών (Zhang et al., 2002).

Αν και η δορυφορική τηλεπισκόπηση είναι πολλά υποσχόμενη για επιτόπια παρακολούθηση δεν έχει ακόμη αποδείξει αδιάσειστα στοιχεία για την πλήρη επιτυχία. Τα προβλήματα περιλαμβάνουν την επικαιρότητα, την κάλυψη σύννεφων, το αυξημένο κόστος, την κακή χωρική ανάλυση και την έλλειψη επεξεργασίας για την παραγωγή δεδομένων εικόνας χρήσιμων στους διαχειριστές καλλιεργειών. Η υπερ-φασματική ανίχνευση είναι μια σχετικά νέα τεχνολογία που είναι ικανή να παρέχει πληροφορίες σε ένα σχεδόν συνεχές φάσμα στις ορατές, NIR και MIR κυματο-ζώνες. Οι εικόνες που λαμβάνονται από υπερφασματικούς αισθητήρες έχουν χρησιμοποιηθεί για την εκτίμηση της σφριγηλότητας των καλλιεργειών και την πρόβλεψη της απόδοσης, διάκριση μεταξύ καλλιεργειών, ζιζανίων, υπολειμμάτων και εδάφους και ποσοτικές μετρήσεις της περιεκτικότητας σε νερό των καλλιεργειών και του δείκτη φυλλικής επιφάνειας. Η μέτρηση στη ζώνη MIR έχει επίσης τη δυνατότητα να παρέχει πληροφορίες σχετικά με τα θρεπτικά συστατικά των φυτών και τις ιδιότητες του εδάφους (Zhang et al., 2002).

Η χρήση εμπορικά διαθέσιμων σπόρων, προϊόντων φυτοπροστασίας και λιπασμάτων είναι κρίσιμη για τους μικροκαλλιεργητές σε πολλές περιοχές της Αφρικής και όχι μόνο, ώστε να μπορέσουν να αυξήσουν τα εισοδήματά τους και να ξεφύγουν από τη φτώχεια (Jayne et al., 2010). Οι χάρτες τύπου καλλιέργειας που ενημερώνονται ετησίως θα επιτρέψουν στις εταιρείες και σε άλλα ιδρύματα που πωλούν σπόρους και προστασία των καλλιεργειών, να προσδιορίσουν το μέγεθος του εμπορικού γεωργικού τομέα σε μια συγκεκριμένη περιοχή, να αξιολογήσουν τον αντίκτυπο μιας κακής καλλιεργητικής περιόδου στη ζήτηση για τα προϊόντα τους και να σχεδιάσουν την επέκταση στην καλλιεργούμενη περιοχή μιας ποικιλίας ή ενός τύπου καλλιέργειας. Μπορεί να χρειαστούν χρόνια για να αναπτυχθεί και να παραχθεί αρκετός σπόρος μιας καλλιεργημένης ποικιλίας για να καλύψει τη ζήτηση της αγοράς. Ο σχεδιασμός είναι το κλειδί για να έχουμε το κατάλληλο προϊόν στη σωστή τοποθεσία για να διασφαλίσουμε ότι οι αγρότες έχουν πρόσβαση σε κατάλληλες γεωργικές εισροές όταν τις χρειάζονται. Τα αβέβαια στατιστικά στοιχεία και η σύγχυση σχετικά με την έκταση που φυτεύεται με καλαμπόκι και σόγια, για παράδειγμα, μειώνει την ικανότητα των εταιρειών να σχεδιάζουν τη μελλοντική ζήτηση της αγοράς (Jayne et al., 2010).

1.7 Τεχνολογικές Εξελίξεις στο Πεδίο

Η σύγχρονη γεωργία χαρακτηρίζεται από μεγάλες εκτάσεις, αποτελεσματικά συστήματα και σύγχρονο γεωργικό εξοπλισμό που επιτρέπει οικονομίες κλίμακας και την παρακολούθηση της ανάπτυξης των καλλιεργειών, που είναι ιδιαίτερα σημαντική. Η επεξεργασία των δεδομένων που προέρχονται από τον αγροτικό εξοπλισμό και την απομακρυσμένη παρακολούθηση περιλαμβάνει τη χρήση της τεχνολογίας πληροφοριών, που χαρακτηρίζεται από συγκεντρωτικούς και βελτιστοποιημένους αλγόριθμους, μαζική επεξεργασία δεδομένων και υπολογιστική ισχύ υψηλής απόδοσης. Στην έρευνα των Sladojevic et al. (2016), περιγράφεται ότι στο πλαίσιο της τεχνητής νοημοσύνης, η βαθιά μάθηση (deep learning) χρησιμοποιήθηκε για την επέκταση τεχνητών νευρωνικών δικτύων και τη δημιουργία προηγμένων αλγορίθμων, για την εξαγωγή λεπτομερών χαρακτηριστικών από εικόνες και για την ακριβή ταξινόμηση των φύλλων των καλλιεργειών για τον εντοπισμό ορισμένων ασθενειών. Οι αλγόριθμοι βαθιάς μηχανικής μάθησης έχουν την ικανότητα να ανιχνεύσουν με ακρίβεια τα παράσιτα και τις ασθένειες των καλλιεργειών, τα είδη ιωαρίων και τους φαινότυπους τους. Ταυτόχρονα, η βαθιά μάθηση συμβάλλει στη μαζική εξόρυξη δεδομένων, απαιτώντας όμως υπέρ-υπολογιστική ισχύ (Sladojevic et al., 2016).

Οι τεχνολογίες αισθητήρων και απεικόνισης έχουν προωθηθεί αρκετά τα τελευταία χρόνια. Πριν από πέντε έως δέκα χρόνια, οι χρήστες βασιζόντουσαν σε ευρυζωνικές πολυφασικές και θερμικές κάμερες 1 έως 2 κιλών και σε συστήματα υπερφασματικών απεικονίσεων μεγέθους pixel. Αυτή τη στιγμή, διατίθενται στο εμπόριο φορητές κάμερες, βάρους 100-500 γραμμαρίων με ενισχυμένες δυνατότητες. Οι φορητές κάμερες διαθέτουν φθηνούς αισθητήρες λέιζερ LIDAR (ανίχνευση φωτός και εύρος) και SAR (ραντάρ συνθετικού διαφράγματος), μπορούν να τοποθετηθούν σε SUAVs για να δημιουργήσουν νέες ερευνητικές χρήσεις και εφαρμογές γεωργίας ακριβείας για συγκεκριμένους τομείς καλλιέργειας. Ωστόσο, για να δημιουργηθούν αξιόπιστα τελικά προϊόντα που μπορούν να χρησιμοποιήσουν οι γεωργοί για τη βελτίωση της διαχείρισης πεδίου στα συστήματα γεωργίας ακριβείας, τα συστήματα αυτά πρέπει να εμπλέξουν τους γεωργούς στη διαδικασία απόκτησης, ερμηνείας και ανάλυσης εικόνων, όπως αναφέρεται σε αυτή την έρευνα (Zhang και Kovacs, 2012).

Αρκετές εφαρμογές της γεωργίας ακριβείας περιλαμβάνουν τεχνολογίες μεταβλητού ρυθμού. Η εφαρμογή φυτοφαρμάκων μεταβλητού ρυθμού αποτελεί μια από τις βασικές τεχνολογικές εφαρμογές που χρησιμοποιούνται για την προστασία των καλλιεργειών

στη γεωργία ακριβείας. Επιπλέον, κάποιες δραστηριότητες σχετίζονται με την εφαρμογή λιπασμάτων και τη διαχείριση άρδευσης με αυτόματο σύστημα διεύθυνσης και ελεγχόμενα συστήματα κυκλοφορίας ενσωματωμένα σε ελκυστήρες (Zhang και Kovacs, 2012).

Όταν η ανίχνευση πεδίου υψηλής ανάλυσης συνδυάζεται με τρακτέρ και εξοπλισμό με τη βοήθεια υπολογιστή, οι αγρότες μπορούν εύκολα να προσαρμόσουν τη μεταβλητότητα στα χωράφια τους με μεγάλη ακρίβεια. Η εφαρμογή μεταβλητού ρυθμού είναι επί του παρόντος εμπορικά διαθέσιμη για χρήση σε επίγειες πλατφόρμες, όπου ειδικά συστήματα τοποθετούνται σε ελκυστήρες. Ωστόσο, η εναέρια εφαρμογή μεταβλητού ρυθμού βρίσκεται ακόμη στο στάδιο της έρευνας και ανάπτυξης, όπως συμπεραίνουμε από τη μελέτη των Thomson et al. (2010), διότι αντιμετωπίζει προκλήσεις, όπως είναι ο έλεγχος των ψεκαστήρων.

Οι Pederson και Lind (2017) στη μελέτη τους μας πληροφορούν, ότι η υιοθέτηση τεχνολογιών εφαρμογής μεταβλητού ρυθμού δεν είχε την αναμενόμενη ζήτηση τα τελευταία χρόνια. Ωστόσο, η υιοθέτηση συστημάτων καθοδήγησης αυτόματης οδήγησης ή ακρίβειας υπήρξε σημαντική την τελευταία δεκαετία με τον εκσυγχρονισμό του γεωργικού εξοπλισμού, επιτρέποντας έτσι την εξάπλωση των συστημάτων εφαρμογής μεταβλητού ρυθμού. Αφορμή αποτέλεσε η εξέλιξη της τεχνολογίας, εντοπισμού θέσης, η οποία είναι απαραίτητη για να επιτευχθεί η μέγιστη δυνατή ακρίβεια.

Η παγκόσμια τεχνολογία εντοπισμού θέσης αποτελεί καθοριστικό παράγοντα στη γεωργία ακριβείας και εξαρτάται από την ακριβή τοποθέτηση του γεωργικού εξοπλισμού στο χωράφι. Επί του παρόντος, τρία συστήματα δορυφορικής πλοήγησης έχουν παγκόσμια κάλυψη και έτσι χαρακτηρίζονται παγκόσμια δορυφορικά συστήματα πλοήγησης (GNSSs). Αυτά είναι το GPS των Ηνωμένων Πολιτειών, το GLONASS της Ρωσίας και το Galileo της Ευρωπαϊκής Ένωσης.

1.8 Παγκόσμια Γεωργία Ακριβείας

Η γεωργία ακριβείας είναι μια παγκόσμια γεωργική πρακτική, όπου τα επίπεδα έρευνας και εφαρμογών ποικίλλουν σε διάφορα μέρη του κόσμου, όπως γίνεται αντιληπτό και

από τις αναφορές (Spiertz, 2013) για αρκετά διαφορετικούς λόγους. Αν και έχει καταβληθεί σημαντική ερευνητική προσπάθεια, διεθνώς, ο αριθμός των αγροτών που χρησιμοποιούν οποιοδήποτε είδος γεωργικών τεχνολογιών εξακολουθεί να είναι μικρός. Η υλοποίηση της γεωργίας ακριβείας, στην πράξη, έγινε κυρίως μέσω της αξιοποίησης των υπαρχόντων μηχανημάτων πεδίου με την προσθήκη ελεγκτών και GPS για την ενεργοποίηση χωρικά μεταβλητών εφαρμογών. Μέχρι σήμερα, η κύρια εφαρμογή της γεωργίας ακριβείας εξακολουθεί να είναι η συγκεκριμένη εφαρμογή λιπασμάτων (Zhang et al., 2002).

Παρά το γεγονός ότι τα περισσότερα πειράματα γεωργίας ακριβείας επικεντρώθηκαν σε εφαρμογές μεταβλητού ρυθμού VRT (Variable Rate Technology) λιπασμάτων και ζιζανιοκτόνων, διάφοροι τύποι τεχνολογιών γεωργίας ακριβείας έχουν εφαρμοστεί σε όλο τον κόσμο. Πειράματα στην γεωργία ακριβείας έχουν αναφερθεί στην Κίνα, την Κορέα, την Ινδονησία, το Μπαγκλαντές, τη Σρι Λάνκα, την Τουρκία, τη Σαουδική Αραβία, την Αυστραλία, τη Βραζιλία, την Αργεντινή, τη Χιλή, την Ουρουγουάη, τη Ρωσία, την Ιταλία, τις Κάτω Χώρες, τη Γερμανία, τη Γαλλία, το Ηνωμένο Βασίλειο, τις Ηνωμένες Πολιτείες και τον Καναδά σύμφωνα με πρόσφατες βιβλιογραφικές αναφορές (Zhang et al., 2002).

Οι Gassner et al., (2013) περιγράφουν ότι η σύγχρονη γεωργία ακριβείας ξεκίνησε, αρχικά στις βιομηχανικά ανεπτυγμένες χώρες. Οι Ηνωμένες Πολιτείες ήταν μία από τις πρώτες χώρες που εφάρμοσε γεωργία ακριβείας, στη γεωργία μεγάλης κλίμακας. Στα μέσα της δεκαετίας του 1980, οι Ηνωμένες Πολιτείες άρχισαν να εφαρμόζουν γεωργία ακριβείας με βάση τα δεδομένα GPS, GIS και τηλεπισκόπησης, που διαδίδονταν μέσω συστημάτων υπηρεσιών γεωργικών πληροφοριών. Επί του παρόντος, η γεωργία ακριβείας στις Ηνωμένες Πολιτείες υποστηρίζεται από εθνικά και περιφερειακά δίκτυα γεωργικής πληροφόρησης με εντατικούς πόρους δεδομένων για την υποστήριξη αποφάσεων και από σχετικές πολιτικές, κανόνες και νόμους.

Η τεχνολογία μεταβλητού ρυθμού VRT έχει αποδειχθεί επιτυχής στη νοτιοανατολική περιοχή των ΗΠΑ σύμφωνα με την μελέτη. Επιπλέον, η τεχνολογία δοκιμάστηκε και σε υβρίδια καλαμποκιού στο Κολοράντο. Επίσης σημαντικές είναι οι δοκιμές πεδίου που διεξήχθησαν στο Μιζούρι για να προσδιορίσουν τις βέλτιστες πυκνότητες φύτευσης σε διαφορετικά χωράφια. Από την άλλη, ένα παρόμοιο πείραμα που διεξήχθη

στο Κάνσας δεν έδειξε κανένα οικονομικό όφελος από τη διαφοροποίηση του ρυθμού φύτευσης (Zhang et al., 2022).

Στην πολιτεία της Καλιφόρνιας, αναφέρεται ότι μέσα από εντατικές μελέτες γίνεται προσπάθεια να διευκρινιστούν οι δυνατότητες των τεχνολογιών της γεωργίας ακριβείας στην παραγωγή ρυζιού. Οι ίδιοι ερευνητές πραγματοποίησαν ξανά ένα πείραμα στην Καλιφόρνια, για τη μελέτη της σκοπιμότητας των τεχνολογιών γεωργίας ακριβείας στην παραγωγή ντομάτας. Σε διαφορετική μελέτη οι εφαρμογές της γεωργίας ακριβείας χρησιμοποιήθηκαν για τη βελτιστοποίηση των αρδευτικών λειτουργιών (Zhang et al., 2022).

Συγκεκριμένα στη πολιτεία της Νότιας Καρολίνα, η μελέτη των Evans et al. (2000) εστιάστηκε στην υδατική καταπόνηση των φυτών η οποία παρακολούθηθηκε κάνοντας χρήση υπέρυθρων θερμομέτρων σε ένα σύστημα άρδευσης ώστε να ελεγχθεί η λειτουργία του συστήματος και να επιτευχθεί η βελτιστοποίηση της καλλιέργειας. Στην Αριζόνα, μελετήθηκαν επιφανειακά συστήματα άρδευσης και διαπίστωσαν ότι η εφαρμογή νερού είναι εγγενώς μη ομοιόμορφη σε αυτά τα συστήματα, λόγω της χωρικής και χρονικής μεταβλητότητας των χαρακτηριστικών διήθησης του εδάφους.

Έτσι, η προσαρμογή του φυσικού σχεδιασμού του συστήματος άρδευσης ή η ανάπτυξη πρακτικών διαχείρισης, με τεχνολογίες γεωργίας ακριβείας, ειδικά για μεμονωμένα χωράφια μπορεί να αποδειχθεί επωφελής για τους αγρότες. Οι McKinion et al. (2001) στη έρευνά τους εφάρμοσαν μια προσέγγιση της γεωργίας ακριβείας στην παραγωγή βαμβακιού στο Μισισσιπή για να αυτοματοποιήσουν τον υπολογισμό των βέλτιστων ρυθμών νερού και αζώτου (N). Στόχος της έρευνας ήταν ο συνδυασμός της γεωργίας ακριβείας, με μοντέλα προσομοίωσης καλλιέργειών και GIS (Geographic Information Systems) ώστε να μπορούν να βελτιστοποιήσουν τις αποδόσεις παραγωγής ελαχιστοποιώντας παράλληλα τις εισροές νερού και αζώτου. Οι τεχνολογίες γεωργίας ακριβείας έχουν επίσης χρησιμοποιηθεί στη δασική παραγωγή. Στην Ουάσιγκτον, οι δέκτες GPS και τα καταγραφικά χρησιμοποιήθηκαν για την παρακολούθηση των δραστηριοτήτων των μηχανών συλλογής κορμών, σύμφωνα με τη μελέτη (Zhang et al., 2002).

Η Ευρώπη υιοθέτησε επίσης τις τεχνολογίες γεωργίας ακριβείας νωρίς, χάρη στην κυβερνητική πολιτική που υιοθέτησε και τη χρηματοδοτική στήριξη που προσέφερε (Lowenberg-DeBoer, 2015). Χώρες όπως η Γαλλία, η Γερμανία, η Ιταλία, οι Κάτω Χώρες και το Ηνωμένο Βασίλειο προσφέρουν τεχνολογίες όπως το GNSS (Global Navigation Satellite System), η τηλεπισκόπηση και η ρομποτική για την καθοδήγηση της εφαρμογής θρεπτικών ουσιών και φυτοφαρμάκων. Ενώ, η Γερμανία αναπτύσσει το πρόγραμμα ψηφιακής γεωργίας μέσω της βιομηχανικής ανάπτυξης, των επιδοτήσεων των γεωργών και του περιβαλλοντικού ρυθμιστικού ελέγχου.

Σε άλλη έρευνα που πραγματοποιήθηκε στο Ισραήλ φαίνεται πως, η γεωργία προωθήθηκε από την εφεύρεση της άρδευσης σταγονιδίων στα μέσα της δεκαετίας του 1960. Σήμερα, η γεωργία ακριβείας στο Ισραήλ καθοδηγείται από ένα εκσυγχρονισμένο πρόγραμμα διαχείρισης νερού, το οποίο προωθεί και επιτρέπει την τεχνική ανάπτυξη και τις εφαρμογές της.

Σε Αυστραλία και Νέα Ζηλανδία, όπως παρουσιάζεται από μελέτες (Cook και Bramley, 1998), υιοθετήθηκαν σχετικά νωρίς προγράμματα γεωργίας ακριβείας στην παραγωγή καλλιεργειών και στη διαχείριση βοσκοτόπων και ζώων. Αυτές οι χώρες έχουν χρησιμοποιήσει το διαδίκτυο για να προωθήσουν γεωργικές εφαρμογές του Διαδικτύου των Πραγμάτων (IoT), των μαζικών δεδομένων και του υπολογιστικού νέφους.

Στην Ιαπωνία, το Υπουργείο Γεωργίας επένδυσε σε ερευνητικά έργα που αφορούν τη γεωργία ακριβείας, εστιάζοντας στην ανίχνευση και τους ελέγχους που σχετίζονται με τη γεωργική μηχανοποίηση. Η Ιαπωνία χαρακτηρίζεται από μια γεωργία μικρής κλίμακας και έντασης εργασίας που βασίζεται στην ατομική διαχείριση των φυτών. Η ιαπωνική γεωργία αντιμετώπισε πολλά σοβαρά προβλήματα κατά τη διάρκεια των τελευταίων δύο δεκαετιών, συμπεριλαμβανομένου του πλεονάσματος παραγωγής ρυζιού, της ταχείας μείωσης του γεωργικού εργατικού δυναμικού, της μετατόπισης της ηλικιακής ομάδας των αγροτών και των αυξανόμενων περιβαλλοντικών ανησυχιών. Η ιαπωνική γεωργία είναι ποικίλη σε μέγεθος πεδίου, ποικιλία καλλιεργειών, υψόμετρο πεδίου, σύστημα διαχείρισης νερού, κλίμα και έδαφος. Πιστεύεται ότι οι εφαρμογές της γεωργίας ακριβείας μπορούν να χρησιμοποιηθούν σε διαφορετικές γεωργικές

κλίμακες μόνο μετά από αναδιοργάνωση της γεωργικής δομής της χώρας (Zhang et al., 2002).

Σε άλλη έρευνα (Zhane et al. 2002), φαίνεται ότι στην Ιαπωνία, η ανάπτυξη της γεωργίας ακριβείας συμβαδίζει με την ανάπτυξη των πληροφοριών και των ηλεκτρονικών τεχνολογιών. Στις αρχές της δεκαετίας του 1980, η Yamaha Motor Corporation άρχισε να αναπτύσσει και να χρησιμοποιεί μη επανδρωμένα ελικόπτερα για γεωργικές εφαρμογές, όπως ο έλεγχος παρασίτων εντόμων στα χωράφια ρυζιού, σόγιας και σιταριού.

Η Νότια Κορέα επίσης έχει εφαρμόσει πλήρως συστήματα γεωργικής πληροφόρησης για την υποστήριξη της γεωργίας ακριβείας με πληροφορίες σχετικά με το έδαφος, την ανάπτυξη των καλλιεργειών, τα παράσιτα των καλλιεργειών και τις καιρικές συνθήκες, όπως περιγράφεται στη μελέτη των Wang et al., το 2016.

Η Κίνα άρχισε να εφαρμόζει γεωργία ακριβείας στις αρχές της δεκαετίας του 2000 σε συνδυασμό με έρευνες σε πανεπιστήμια και ακαδημίες γεωργικών επιστημών. Επί του παρόντος, εφαρμογές της γεωργίας ακριβείας χρησιμοποιούνται για το βιομηχανικά παραγόμενο αραβόσιτο, σιτάρι, ρύζι και βαμβάκι στα βορειοανατολικά και βορειοδυτικά τμήματα της Κίνας και μόνο σε μικρή κλίμακα σε άλλα μέρη της χώρας. Δεδομένης της γήρανσης του πληθυσμού των γεωργών, των μικρών μεγεθών των γεωργικών εκμεταλλεύσεων και της έλλειψης πολιτικής στήριξης από την κυβέρνηση για την εξ αποστάσεως απεικόνιση των γεωργικών εκτάσεων, η γεωργία ακριβείας δεν επεκτείνεται εκτός αυτών των περιοχών βιομηχανικής γεωργίας στην Κίνα (Wang, 2001).

Παράλληλα αναφέρεται ότι οι μεγάλες βιομηχανικές εκμεταλλεύσεις στις αναπτυσσόμενες χώρες έχουν υιοθετήσει τεχνολογίες γεωργίας ακριβείας, συγκεκριμένη μεταβλητή εφαρμογή και παρακολούθηση της απόδοσης με τη χρήση συστημάτων GPS σε γεωργικό εξοπλισμό. Το κινητό διαδίκτυο, οι φορητοί αισθητήρες εγκαταστάσεων και τα μικρά UAV (sUAVs) είναι αρκετά ανεπτυγμένα στην Αφρική, προχωρώντας στην επόμενη γενιά γεωργίας ακριβείας, για να εφαρμόσουν σύγχρονα γεωργικά προγράμματα ακριβείας σε συστήματα γεωργικής παραγωγής υψηλής αξίας.

Στην Κόστα Ρίκα, πραγματοποιήθηκε ένα πείραμα από τους Stoorvogel και Orlich (2000) για την εφαρμογή τεχνολογιών γεωργίας ακριβείας σε μια φυτεία μπανάνας. Το σύστημα επιτρέπει στους γεωργούς να συνδέονται με μια βάση δεδομένων η οποία περιέχει στοιχεία για το έδαφος, ώστε να λαμβάνουν αποφάσεις για συγκεκριμένες τοποθεσίες σχετικά με προβλήματα γονιμότητας και ασθενειών του εδάφους μέσω της παρακολούθησης της απόδοσης.

Οι Marcotte et al., (1999) πειραματίστηκαν με τις τεχνολογίες γεωργίας ακριβείας στην παραγωγή σανού και χορτονομής στο Κεμπέκ του Καναδά. Δοκιμάστηκαν αισθητήρες που μετρούν συνεχώς τα βάρη στο χορτοδετικό (γεωργικό μηχάνημα) και το συρόμενο βαγόνι και αισθητήρες που μετρούν ταυτόχρονα τη ροή μάζας και την περιεκτικότητα σε υγρασία. Η επιτυχής λειτουργία αυτών των αισθητήρων μπορεί να επιτρέψει την ανάπτυξη διαφόρων εφαρμογών της γεωργίας ακριβείας, συμπεριλαμβανομένης της επιλογής ποικιλιών, της βελτιστοποίησης των προσθέτων σανού ή ενσίρωσης (*η διαδικασία της ζύμωσης φυτικών προϊόντων με υψηλό περιεχόμενο υγρασίας και υπό αναερόβιες συνθήκες, με σκοπό τη διατήρηση του προϊόντος αλλά και τη βελτίωση της θρεπτικής του αξίας για χρήση ως ζωοτροφή*), της χαρτογράφησης της απόδοσης και της διαχείρισης των καλλιεργειών χορτονομής.

1.9 Οφέλη Γεωργίας Ακριβείας

Η εξάπλωση της τεχνολογίας ακριβείας παγκοσμίως οφείλεται στα πλεονεκτήματα που προκύπτουν από τη χρήση της. Τα πρωταρχικά οφέλη από τη γεωργία ακριβείας, τόσο οικονομικά όσο και περιβαλλοντικά, προκύπτουν από τη μειωμένη, στοχευμένη τοποθέτηση εισροών στις καλλιέργειες, όπως θρεπτικά συστατικά, φυτοφάρμακα και νερό. Ο στόχος είναι να εφαρμοστούν μόνο τα θρεπτικά συστατικά που χρειάζονται και μπορούν να χρησιμοποιήσουν τα φυτά, ώστε να αυξηθεί η απόδοση της καλλιέργειας (Natural Resources Conservation Service, 2023).

Τα ποσοστά εφαρμογής θρεπτικών ουσιών είναι πιθανόν να ποικίλλουν εντός ενός αγροκτήματος με βάση τα υπάρχοντα επίπεδα γονιμότητας, τους τύπους εδάφους και την περιβαλλοντική ευαισθησία. Ορισμένα εδάφη σε έναν τομέα απλά δεν έχουν τη δυνατότητα απόδοσης για να δικαιολογήσουν τα μέγιστα ποσοστά εφαρμογής

θρεπτικών ουσιών, ενώ άλλες περιοχές ενδέχεται να απαιτούν μειωμένους συντελεστές λόγω περιβαλλοντικής ευαισθησίας (Natural Resources Conservation Service, 2023).

Επιπροσθέτως, με τη γεωργία ακριβείας είναι δυνατή η ακριβής παρακολούθηση και ο συντονισμός της γεωργικής παραγωγής. Οι τεχνολογίες γεωργίας ακριβείας, μέσα από τη συλλογή δεδομένων, παρέχουν στους αγρότες τη δυνατότητα να καθορίζουν την ποσότητα και τη κατάλληλη χρονική στιγμή, που χρειάζεται να προστεθούν στη καλλιέργειά τους αγροχημικά προϊόντα και λιπάσματα. Οι αγρότες, χάριν στις εφαρμογές της γεωργίας ακριβείας και από τα δεδομένα που συλλέγονται, μπορούν να κάνουν οικονομικές αναλύσεις με βάση τη μεταβλητότητα της απόδοσης των καλλιεργειών σε ένα χωράφι για να αποκτήσουν ακριβή εκτίμηση του κινδύνου, αλλά και του κέρδους που θα πρέπει να αναμένουν. Γνωρίζοντας το κόστος των εισροών, οι αγρότες μπορούν επίσης να υπολογίσουν την απόδοση μετρητών πάνω από το κόστος για κάθε εκτάριο. Με τις εφαρμογές της γεωργίας ακριβείας μπορούν να εξακριβωθούν, ορισμένα τμήματα εντός ενός αγρού, τα οποία δεν παράγουν κέρδος. Η απώλεια κέρδους προκύπτει, είτε γιατί το έδαφος δεν είναι τόσο παραγωγικό, είτε επειδή απαιτείται η προσθήκη περισσότερων, κοστοβόρων αγροχημικών ουσιών. Η λύση σε αυτό το ζήτημα είναι η απομόνωση των εκτάσεων αυτών από την υπόλοιπη παραγωγή, ώστε να αναπτυχθεί ένα ειδικό σχέδιο διαχείρισης τους, σύμφωνα με τη μελέτη του Goddard (1997).

Επιπλέον οφέλη που μπορούν να προκύψουν από τη γεωργία ακριβείας σχετίζονται με τον έλεγχο της κυκλοφορίας των αγροτικών μηχανημάτων στο χωράφι για τον περιορισμό της συμπίκνωσης, συμπίεσης του εδάφους, σε καθορισμένες διαδρομές. Με χρήση της τεχνολογίας GPS, auto-steer για όλο τον εξοπλισμό που χρησιμοποιείται σε έναν τομέα, οι ίδιες διαδρομές χρησιμοποιούνται χρόνο με το χρόνο. Με την πάροδο του χρόνου, αυτό θα οδηγήσει σε λιγότερη συμπίεση και βελτιωμένη ποιότητα του εδάφους στις περιοχές έξω από τις οποίες κινούνται τα αγροτικά μηχανήματα, όπου φυτεύονται καλλιέργειες (Goddard, 1997).

Τέλος, η μελέτη των Oriade and Popp (2000) υποστηρίζει ότι, αν οι αγρότες αλλάξουν το τρόπο που προσεγγίζουν και αξιοποιούν μια γεωργική εκμετάλλευση, λαμβάνοντας υπόψη όλες τις γεωργικές δραστηριότητες καλλιέργειας και τους περιορισμούς των

πόρων, οι τεχνολογίες γεωργίας ακριβείας μπορεί να αποδειχθούν επωφελείς για τη βελτίωση του δυναμικού κέρδους και για τη μείωση των κινδύνων (Zhang et al., 2002).

1.10 Περιβαλλοντικές Ανησυχίες από τη Γεωργία Ακριβείας

Μέχρι σήμερα, η κύρια κινητήρια δύναμη πίσω από τη γεωργία ακριβείας ήταν η οικονομική ανταπόδοση στον γεωργό. Πολλοί άνθρωποι αναγνωρίζουν ότι η γεωργία ακριβείας, σε ορισμένες περιπτώσεις, μπορεί επίσης να έχει θετικές περιβαλλοντικές επιπτώσεις. Ωστόσο, για να επιτευχθεί θετικός αντίκτυπος στο περιβάλλον, η χρήση της γεωργίας ακριβείας πρέπει να αποτελείσει μέρος ενός μεγαλύτερου συστήματος που αναπτύσσεται ειδικά για την αντιμετώπιση περιβαλλοντικών ζητημάτων, όπως είναι η αλόγιστη χρήση λιπασμάτων και φυτοφαρμάκων που επιβαρύνουν με επικίνδυνες ουσίες το περιβάλλον (Natural Resources Conservation Service, 2023).

Αυστηρές περιβαλλοντικές νομοθεσίες υπάρχουν σε χώρες όπως οι ΗΠΑ, η Αυστραλία, το Ηνωμένο Βασίλειο, η Δανία και η Γερμανία. Επιπλέον, η Ευρωπαϊκή Ένωση έχει θεσπίσει οδηγίες που αναγκάζουν τους αγρότες στις χώρες μέλη να μειώσουν σημαντικά τη χρήση αγροχημικών προϊόντων.

Από την άλλη πλευρά, αρκετοί μεγάλοι παραγωγοί που ασχολούνται με τη γεωργία ακριβείας επιβεβαιώνουν ότι η βελτίωση της παραγωγής είναι το πρωταρχικό τους κίνητρο. Ενώ ορισμένοι παραγωγοί αναγνωρίζουν την προστασία των πόρων ως δευτερεύον όφελος. Υπάρχουν πολλές ανησυχίες σχετικά με τους πόρους, που μπορούν να αντιμετωπιστούν με τη γεωργία ακριβείας. Μερικές από τις ανησυχίες αυτές περιλαμβάνουν επιπτώσεις στην εφαρμογή θρεπτικών ουσιών και φυτοφαρμάκων στην ποιότητα των επιφανειακών ή των υπόγειων υδάτων, επιπτώσεις φυτοφαρμάκων στα μη στοχαζόμενα είδη, την ανακύκλωση θρεπτικών ουσιών και την αντοχή στα φυτοφάρμακα (Natural Resources Conservation Service, 2023).

Ωστόσο, η γεωργία ακριβείας παρέχει τα μέσα ακριβούς και στοχευμένης εφαρμογής και καταγραφής όλων των γεωργικών επεξεργασιών που εφαρμόζονται σε ένα πεδίο, παρακολούθησης από λειτουργία σε λειτουργία και μεταφοράς καταγεγραμμένων πληροφοριών για τη συλλογή των τελικών προϊόντων. Η μελέτη του Stafford (2000) υποστηρίζει, ότι οι παραπάνω συλλεγόμενες πληροφορίες θα μπορούσαν να δράσουν

βοηθητικά στην δημιουργία και εφαρμογή των νομοθεσιών. Αν και τα περιβαλλοντικά οφέλη της γεωργίας ακριβείας δεν έχουν μετρηθεί συστηματικά και ποσοτικά.

Χαρακτηριστικό γεωργικό παράδειγμα αποτελεί, η έκπλυση νιτρικών αλάτων. Μείζον πρόβλημα που εντοπίζεται στα συστήματα καλλιέργειας πατάτας, ιδίως σε εδάφη με χονδροειδή υφή. Μια μελέτη που διεξήχθη σε δύο γειτονικές καλλιέργειες, η μία επεξεργασμένη με URT για αζωτούχο λίπασμα και η άλλη με VRT, κατέδειξε την επίδραση της τεχνολογίας μεταβλητού ρυθμού (*VRT – Variable Rate Technology*) στη μείωση της μόλυνσης των υπόγειων υδάτων. Με τη διαθεσιμότητα τοπογραφικών δεδομένων για καλλιέργειες στις οποίες εφαρμόζονται τεχνολογίες γεωργίας ακριβείας, μπορεί να εξεταστεί η αλληλεπίδραση μεταξύ οργώματος και διάβρωσης εδάφους - νερού και έτσι, μπορεί να επιτευχθεί μείωση της διάβρωσης, όπως περιγράφεται και από τη μελέτη των Schumacher et al. (2000).

1.11 Συμπεράσματα

Στο πρώτο κεφάλαιο αναφέρθηκαν ορισμοί και ερμηνείες που περιγράφουν τη γεωργία ακριβείας και είναι αναγνωρισμένοι διεθνώς. Ειδικότερα, ο οργανισμός ISPA (International Society of Precision Agriculture) υιοθετεί ως επίσημο ορισμό τον εξής:

«Η Γεωργία Ακριβείας είναι μια στρατηγική διαχείρισης που συλλέγει, επεξεργάζεται και αναλύει χρονικά, χωρικά και μεμονωμένα δεδομένα και τα συνδυάζει με άλλες πληροφορίες για να υποστηρίξει διαχειριστικές αποφάσεις σύμφωνα με εκτιμώμενη μεταβλητότητα για βελτιωμένη αποδοτικότητα χρήσης πόρων, παραγωγικότητα, ποιότητα, κερδοφορία και βιωσιμότητα της γεωργικής παραγωγής.»

Επιπλέον, έγινε αναφορά στη συλλογή δεδομένων, με τη χρήση αισθητήρων, στην ανάλυσή τους με εξιδεικευμένους αλγόριθμους και σε προηγμένα συστήματα καθοδήγησης, που όλα μαζί αποτελούν τα δομικά στοιχεία ενός σύγχρονου γεωργικού συστήματος. Ακόμα παρουσιάστηκε η πρόοδος της τεχνολογίας στη χαρτογράφηση του εδάφους από τα παλιά, συμβατικά αερόστατα, μέχρι τα αεροπλάνα και τους δορυφόρους. Καθώς, και η πρόοδος της τεχνολογίας στο πεδίο με σύγχρονους αισθητήρες και κάμερες. Επιπροσθέτως, παρατέθηκαν δεδομένα σχετικά με την ένταξη της γεωργίας ακριβείας σε χώρες ανά το κόσμο και την πρόοδο της τεχνολογίας αυτής

με το πέρασμα των χρόνων. Τέλος, έγινε αναφορά τόσο στα οφέλη που προκύπτουν, όπως η προστασία του περιβάλλοντος και η εξοικονόμηση πόρων και χρημάτων των καλλιεργητών, όσο και στις ανησυχίες, ως προς το ποιος θα πληρώσει το αυξημένο κόστος αυτής της τεχνολογίας. Καταλήγουμε λοιπόν στο συμπέρασμα ότι η γεωργία ακριβείας αποτελείται από έναν συνδυασμό τεχνολογιών οι οποίες χρειάζεται και πρόκειται να αναπτυχθούν ακόμη περισσότερο, ώστε να ενσωματωθούν σε περισσότερες καλλιέργειες και να υιοθετηθούν από ακόμη περισσότερους γεωργούς.

Κεφάλαιο 2: Εφαρμογές στη Γεωργία Ακριβείας

2.1 Εισαγωγή στο Αντικείμενο

Με την εξέλιξη της γεωργικής τεχνολογίας ήταν αναμενόμενο η χειρωνακτική γεωργική παραγωγή, να αντικατασταθεί από τη γεωργική μηχανοποίηση, με το πέρασμα των χρόνων. Στο κεφάλαιο αυτό παρουσιάζονται εφαρμογές και παραδείγματα της γεωργίας ακριβείας, τα οποία είτε χρησιμοποιούνται ήδη από τους καλλιεργητές, είτε δεν κατάφεραν να φτάσουν ποτέ στην αγορά για διάφορους λόγους (Ayaz et al., 2019).

Τεχνολογίες όπως τα μη επανδρωμένα εναέρια οχήματα (UAV), τα μαζικά δεδομένα, η τεχνητή νοημοσύνη και οι αυτοματισμοί αναπτύχθηκαν, για να βοηθήσουν στην επίλυση ζητημάτων σε πολλούς τομείς της καθημερινότητας. Η ενσωμάτωση σύγχρονων, ασύρματων αισθητήρων ανίχνευσης και η χρήση της τεχνολογίας IoT σε γεωργικές εφαρμογές έχει παρατηρηθεί ότι αλλάζει ριζικά τις παραδοσιακές μορφές καλλιέργειας. Η εφαρμογή των παραπάνω τεχνολογιών στην έξυπνη γεωργία έχει τη δυνατότητα να συμβάλλει στην αύξηση της παραγωγής, των καλλιεργήσιμων εκτάσεων και όχι μόνο. Επιπλέον, η γεωργία ακριβείας παρέχει την ευκαιρία να ανταποκριθεί η κοινωνία γενικότερα, στις ραγδαία μεταβαλλόμενες κλιματικές συνθήκες και στους όλο και πιο ακριβούς σπόρους και αναλώσιμες πρώτες ύλες, οι οποίες μειώνουν την κερδοφορία των γεωργικών εκμεταλλεύσεων παγκοσμίως (Crowder και Reganold, 2015).

Στα επόμενα 10 χρόνια, η νέα γενιά γεωργίας ακριβείας θα χαρακτηρίζεται από υπολογιστικό νέφος και τη δημιουργία κινητής τηλεφωνίας υψηλής απόδοσης, την εντατική ανάλυση μαζικών δεδομένων, την τεχνητή ευφυή αντίληψη και τον έλεγχο και την αυτοματοποίηση σε πραγματικό χρόνο. Ορισμένες, από τις κυριότερες περιπτώσεις, όπου οι προηγμένες τεχνολογίες, ήδη συμβάλλουν καθοριστικά στην ενίσχυση της συνολικής αποτελεσματικότητας αναφέρονται στα παρακάτω κεφάλαια (Ayaz et al., 2019).

2.2 Κύριες εφαρμογές

2.2.1 Δειγματοληψία και Χαρτογράφηση Εδάφους

Το έδαφος περιέχει όλα εκείνα τα απαραίτητα συστατικά που χρειάζεται κάθε φυτό για να αναπτυχθεί. Επομένως, αποτελεί το πρώτο σημείο ανάλυσης, έρευνας και άντλησης δεδομένων, ώστε να εξαχθούν κρίσιμες πληροφορίες. Η ανάλυση του εδάφους στοχεύει στον προσδιορισμό της θρεπτικότητας ενός χωραφιού, έτσι ώστε να λαμβάνονται τα κατάλληλα μέτρα αντιμετώπισης, όταν εντοπίζονται ελλείψεις θρεπτικών ουσιών. Οι παράγοντες που εξετάζονται κατά τη συλλογή στοιχείων έχουν να κάνουν με τα θρεπτικά συστατικά του χωραφιού, τον τύπο του πεδίου, το ιστορικό καλλιέργειας, την χρήση λιπασμάτων, την άρδευση και την τοποθεσία του του χωραφιού. Τα στοιχεία αυτά είναι κρίσιμα διότι πληροφορούν τον γεωργό σχετικά με τις χημικές, φυσικές και βιολογικές καταστάσεις ενός εδάφους και για τον προσδιορισμό των περιοριστικών παραγόντων, έτσι ώστε να πάρει την σωστή απόφαση για το ποια ή ποιες καλλιέργειες τον συμφέρει να επιλέξει. Αυτή τη στιγμή, στην αγορά βρίσκονται διαθέσιμοι αισθητήρες από αρκετούς κατασκευαστές οι οποίοι μπορούν να συμβάλλουν στην παρακολούθηση της ποιότητας του εδάφους, μειώνοντας τη διάβρωση, την πύκνωση, την αλατοποίηση, την όξυνση και τη ρύπανση σε αυτό (Ayaz et al., 2019).

Η ξηρασία αποτελεί ένα φυσικό φαινόμενο που εμφανίζεται όλο και πιο συχνά σε όλο και περισσότερες περιοχές του πλανήτη, μειώνοντας την απόδοση των καλλιεργειών. Κατά το φαινόμενο της ξηρασίας εξατμίζεται το νερό από το έδαφος, δηλαδή η υγρασία του εδάφους που είναι απαραίτητη για την ανάπτυξη των φυτών. Η αντιμετώπιση της

ξηρασίας μπορεί να πραγματοποιηθεί με τη συλλογή δεδομένων υγρασίας είτε από δορυφόρους (SMOS, δορυφόρος υγρασίας εδάφους και αλατότητας των ωκεανών που εκτοξεύτηκε το 2009) με τη μέθοδο της τηλεπισκόπησης, είτε με τη χρήση τοπικών αισθητήρων (Ayaz et al., 2019).

2.2.2 Άρδευση

Εκτιμάται ότι, το 70% του διαθέσιμου και άμεσα προσβάσιμου γλυκού νερού αξιοποιείται στις βιομηχανικές καλλιέργειες. Σε πολλές χώρες, η κατανάλωση νερού στη γεωργία αυξάνεται στο 75%, π.χ. η Βραζιλία, ενώ σε ορισμένες υπανάπτυκτες χώρες υπερβαίνει το 80%. Η βασική αιτία της υψηλής κατανάλωσης νερού έχει να κάνει με τη διαδικασία παρακολούθησης η οποία μέχρι και σήμερα σε μεγάλο ποσοστό βασίζεται στην ανθρώπινη επιθεώρηση των καλλιεργειών, ώστε να αποφασισθούν οι επόμενες κινήσεις των γεωργών σχετικά με την άρδευση της καλλιέργειας. Ελεγχόμενες μέθοδοι άρδευσης, όπως είναι η άρδευση με σταγόνα και η άρδευση με ψεκαστήρα, προωθούνται από διάφορους φορείς, στα πλαίσια της γεωργίας ακριβείας, για την αντιμετώπιση των ζητημάτων σπατάλης νερού. Η ποιότητα και η ποσότητα των καλλιεργειών επηρεάζονται σοβαρά από την εμφάνιση φαινομένων έλλειψης νερού, οι ξαφνικές και έντονες αλλαγές στην άρδευση των καλλιεργειών μπορούν να οδηγήσουν σε μείωση των θρεπτικών συστατικών του εδάφους, στην ανάπτυξη μικροβιακών λοιμώξεων, ακόμα και στην απώλεια της παραγωγής. Η ακριβής εκτίμηση της ζήτησης νερού που χρειάζονται οι καλλιέργειες δεν είναι απλή περίπτωση, διότι εξαρτάται παράγοντες, όπως το είδος καλλιέργειας, τη μέθοδο άρδευσης, το τύπο του χωραφιού, την ένταση των βροχοπτώσεων, τις ανάγκες της καλλιέργειας και τη κατακράτηση υγρασίας του εδάφους (FAO, 2017).

Η βέλτιστη χρήση του νερού και η καλύτερη υγεία των καλλιεργειών θα μπορούσε να επιτευχθεί με τη χρήση ενός συστήματος ελέγχου υγρασίας του εδάφους και του αέρα, τεχνολογίας IoT, όπου θα χρησιμοποιούνται σύγχρονοι, ασύρματοι αισθητήρες (FAO, 2017).

2.2.3 Λίπανση

Ως λίπασμα ορίζεται η φυσική ή χημική ουσία η οποία παρέχει θρεπτικά συστατικά, απαραίτητα για την ανάπτυξη και τη γονιμότητα των φυτών. Τα φυτά χρειάζονται 3 κύρια θρεπτικά συστατικά: άζωτο (N) για την ανάπτυξη των φύλλων, φώσφορος (P) για την ανάπτυξη ριζών, λουλουδιών και φρούτων και κάλιο (K) για την ανάπτυξη του στελέχους και την κίνηση του νερού. Η έλλειψη οποιασδήποτε από τις παραπάνω ουσίες μπορεί να προκαλέσει βλάβες στην ανάπτυξη των φυτών. Επιπλέον, η χρήση λιπασμάτων σε υπερβολικό βαθμό προκαλεί οικονομική ζημία στους καλλιεργητές, ενώ ταυτόχρονα μολύνει το έδαφος και το περιβάλλον, εξαντλώντας την ποιότητα του εδάφους, δηλητηριάζοντας τα υπόγεια ύδατα και συμβάλλοντας στις παγκόσμιες κλιματικές αλλαγές. Ύστερα από έρευνες, έχει διαπιστωθεί ότι οι καλλιέργειες απορροφούν λιγότερο από το ήμισυ του αζώτου που εφαρμόζεται ως λίπασμα, ενώ το υπόλοιπο που παραμένει είτε εκπέμπεται στην ατμόσφαιρα είτε χάνεται ως απορροή. Η γονιμοποίηση και η ανάπτυξη των καλλιεργειών με εφαρμογή της γεωργίας ακριβείας βοηθά στην ακριβή εκτίμηση της απαιτούμενης δόσης θρεπτικών ουσιών, ελαχιστοποιώντας τις αρνητικές επιπτώσεις τους στο περιβάλλον και περιορίζοντας τα έξοδα των γεωργών. Οι νέες προσεγγίσεις λίπανσης βασίζονται στη χρήση εφαρμογών IoT, οι οποίες συμβάλλουν στην εκτίμηση των απαιτήσεων θρεπτικών ουσιών με υψηλότερη ακρίβεια, απαιτώντας λιγότερη εργασία (Kiiski et al., 2009).

Η παρακολούθηση της κατάστασης των θρεπτικών συστατικών των καλλιεργειών μπορεί να γίνει με την εφαρμογή του δείκτη ομαλοποιημένης βλάστησης διαφορών (NDVI) που χρησιμοποιεί αεροφωτογραφίες και δορυφορικές εικόνες. Η παραπάνω τεχνική NDVI βασίζεται στην αντανάκλαση του ορατού και σχεδόν υπέρυθρου φωτός από τη καλλιέργεια και χρησιμοποιείται για την εκτίμηση της υγείας της, του σθένους της βλάστησης και της πυκνότητας, συμβάλλοντας περαιτέρω στην αξιολόγηση του επιπέδου θρεπτικών συστατικών του εδάφους. Το NDVI μπορεί να βελτιώσει σε σημαντικό βαθμό την απόδοση του λιπάσματος, προστατεύοντας το περιβάλλον από τυχόν παρενέργειες. Αρκετές, νέες τεχνολογίες γενικής εφαρμογής, όπως η ακρίβεια GPS, τα αυτόνομα οχήματα, η τεχνολογία μεταβλητού ρυθμού (VRT) και η γεωγραφική χαρτογράφηση συμβάλλουν σημαντικά στην έξυπνη γονιμοποίηση των φυτών κάνοντας χρήση IoT εφαρμογών. Εκτός από τη γονιμοποίηση ακριβείας, η λίπανση και η χημεία είναι μερικά ακόμα από αυτά που μπορεί να προσφέρει το IoT. Η λίπανση των φυτών αποτελεί τη βέλτιστη πρακτική διαχείρισης για τη βελτίωση της αποτελεσματικότητας πολλών γεωργικών θεμάτων, ενώ έχει το πλεονέκτημα ότι

μπορεί να ενσωματωθεί απρόσκοπτα στη γεωργία ακριβείας και σε μια έξυπνη γεωργική υποδομή βασιζόμενη στο IoT (IOF, 2019).

2.2.4 Ασθένειες καλλιεργειών & Διαχείριση Παρασίτων

Ο Οργανισμός Τροφίμων και Γεωργίας (FAO, 2015) εκτιμά ότι το 20-40% των παγκόσμιων αποδόσεων των καλλιεργειών χάνονται ετησίως λόγω παρασίτων και ασθενειών. Φυτοφάρμακα και αγροτικά χημικά προϊόντα αναπτύχθηκαν για τον περιορισμό των τεράστιων απωλειών παραγωγής και αποτέλεσαν σημαντικό συστατικό της γεωργικής βιομηχανίας κατά τη διάρκεια του περασμένου αιώνα.

Μελέτη του οργανισμού εκτιμά ότι μόνο στις ΗΠΑ γίνεται χρήση, περίπου μισό εκατομμύριο τόνοι φυτοφαρμάκων, κάθε χρόνο, με περισσότερους από δύο εκατομμύρια τόνους να χρησιμοποιούνται παγκοσμίως. Η χρήση των φυτοφαρμάκων ευθύνεται για τη πρόκληση σημαντικών βλαβών ακόμα και θανάτων, των ανθρώπων που έρχονται σε συχνή επαφή με αυτά. Από τις επιπτώσεις των φυτοφαρμάκων δεν θα μπορούσαν να εξαιρεθούν οι ζωικοί οργανισμοί και η ανεπανόρθωτη μόλυνση του περιβάλλοντος. Νέες τεχνολογικές εφαρμογές που βασίζονται στη τεχνολογία IoT, όπως ασύρματοι αισθητήρες, ρομπότ και drones, επιτρέπουν στους καλλιεργητές να περιορίσουν σημαντικά τις χρήσεις φυτοφαρμάκων εντοπίζοντας με μεγάλη ακρίβεια τους «εχθρούς» των καλλιεργειών, δηλαδή τα ζιζάνια.

Οι σύγχρονοι μέθοδοι διαχείρισης των παρασίτων βασίζονται σε IoT εφαρμογές, οι οποίες παρέχουν παρακολούθηση σε πραγματικό χρόνο, μοντελοποίηση και πρόβλεψη ασθενειών με μεγάλη ακρίβεια. Η αποτελεσματική παρακολούθηση των ασθενειών των καλλιεργειών και η διαχείριση των παρασίτων εξαρτάται από την μέθοδο ανίχνευσης, τον τρόπο αξιολόγησης και τη χρησιμοποιούμενη θεραπεία. Οι σύγχρονες μέθοδοι αναγνώρισης ασθενειών και παρασίτων περιλαμβάνουν την επεξεργασία εικόνων οι οποίες συλλέγονται από ολόκληρη την καλλιέργεια χρησιμοποιώντας εξειδικευμένες τεχνολογίες, όπως αισθητήρες πεδίου, UAV ή δορυφόρους τηλεπισκόπησης. Οι εικόνες που προκύπτουν μέσω τηλεπισκόπησης καλύπτουν μεγάλες γεωργικές εκτάσεις, προσφέροντας υψηλότερη απόδοση με μειωμένο κόστος. Οι αισθητήρες πεδίου έχουν τη δυνατότητα να υποστηρίξουν περισσότερες γεωργικές εφαρμογές κατά τη συλλογή δεδομένων. Οι γεωργικές εφαρμογές διακρίνονται στη

δειγματοληψία περιβάλλοντος, στην υγεία των φυτών και στην ύπαρξη παρασίτων, σε καθ' όλη τη διάρκεια του κύκλου καλλιέργειας. Οι αυτοματοποιημένες παγίδες που βασίζονται στο IoT μπορούν να «συλλάβουν», να μετρήσουν, ακόμη και να χαρακτηρίσουν τύπους εντόμων, ανεβάζοντας περαιτέρω δεδομένα στο Cloud για λεπτομερή ανάλυση, κάτι που δεν είναι δυνατό μέσω τηλεπισκόπησης, αποτελούν χαρακτηριστικό παράδειγμα (Stein et al. 2017).

Ο ακριβής ψεκασμός οχημάτων και η αυτόματη τεχνολογία μεταβλητού ρυθμού ψεκασμού VRT μπορούν να χρησιμοποιηθούν για τη θεραπεία ασθενειών, καθώς και σε άλλες εφαρμογές φυτοφαρμάκων. Η πρόοδος της ρομποτικής τεχνολογίας προσφέρει νέες λύσεις, συμβάλλοντας στον εξοπλισμό ενός γεωργικού ρομπότ με πολυφασικές συσκευές ανίχνευσης και ακροφύσια ψεκασμού ακριβείας. Η τεχνολογία αυτή μπορεί να εντοπίσει και να αντιμετωπίσει τα προβλήματα παρασίτων με αρκετά μεγαλύτερη ακρίβεια, με αποτέλεσμα τη μείωση των δαπανών για τους γεωργούς, ενώ ταυτόχρονα υποστηρίζει την αποκατάσταση του φυσικού κλίματος. Χαρακτηριστικό παράδειγμα αποτελεί το γεγονός ότι η ανεξέλεγκτη χρήση φυτοφαρμάκων οδήγησε σε κατάρρευση αποικίας μελισσών η οποία συνέβαλλε στην διαδικασία της επικονίασης των καλλιεργειών προκαλώντας σοβαρά προβλήματα στην καλλιέργεια (Stein et al., 2017).

2.2.5 Παρακολούθηση Απόδοσης, Πρόβλεψη και Συγκομιδή

Ουσιαστικό μέρος της γεωργίας ακριβείας και της γεωργικής παραγωγής, γενικότερα, θεωρείται η παρακολούθηση της απόδοσης, όχι μόνο κατά τη διάρκεια της συγκομιδής, αλλά ακόμη και στα στάδια πριν από αυτή, καθώς ο έλεγχος ποιότητας και απόδοσης διαδραματίζει καίριο ρόλο (Ayaz, 2018).

Οι καταναλωτές σε όλο τον κόσμο γίνονται όλο και πιο απαιτητικοί ως προς την ποιότητα των παραγόμενων προϊόντων, που συνηθίζουν να αγοράζουν. Ως εκ τούτου, η αποτελεσματική παραγωγή εξαρτάται από το σωστό μέγεθος του προϊόντος, τη σωστή αγορά και την κατάλληλη χρονική στιγμή. Η πρόβλεψη της απόδοσης της παραγωγής, πριν από τη συγκομιδή, είναι μια τεχνική που βοηθά τον γεωργό στην υλοποίηση σωστού σχεδιασμού και λήψης αποφάσεων στο εγγύς μέλλον. Η παρακολούθηση καλύπτει όλα τα διαφορετικά στάδια ανάπτυξης του βλαστού, του

φυτού και του προϊόντος και χρησιμοποιεί όλες τις ιδιαιτερότητες της καλλιέργειας, όπως το χρώμα, το μέγεθος, οι καιρικές συνθήκες, θρεπτικά συστατικά και άλλα, για να συλλέξει τα απαραίτητα δεδομένα. Αν και η συγκομιδή αποτελεί το τελευταίο στάδιο μιας γεωργικής παραγωγής, ο σωστός προγραμματισμός προσδίδει σημαντικά πλεονεκτήματα στον γεωργό. Για να αποκομίσουν τα μέγιστα οφέλη από τις καλλιέργειες τους, οι γεωργοί πρέπει να γνωρίζουν πότε αυτές οι καλλιέργειες είναι πραγματικά έτοιμες για συγκομιδή (Ayaz, 2018).

Η ακριβής εκτίμηση της παραγωγής και της ποιότητας του παραγόμενου προϊόντος μπορεί να πραγματοποιηθεί και μέσω εφαρμογών στο κινητό, όπως είναι για παράδειγμα η εφαρμογή FarmRTX, η οποία εμφανίζει δεδομένα συγκομιδής σε πραγματικό χρόνο και τα ανεβάζει αυτόματα στην διαδικτυακή πλατφόρμα του κατασκευαστή. Η εφαρμογή έχει τη δυνατότητα να δημιουργήσει χάρτες απόδοσης υψηλής ποιότητας και να τους μοιραστεί με έναν γεωπόνο, ο οποίος στη συνέχεια θα συμβουλέψει τον γεωργό. Επιπλέον, υπάρχουν και οι δορυφορικές εικόνες οι οποίες αποτελούν αξιόλογη εναλλακτική επιλογή για την παρακολούθηση της απόδοσης των καλλιεργειών σε αρκετά μεγάλες εκτάσεις (Ayaz, 2018).

2.3 Μη επανδρωμένα ιπτάμενα οχήματα (Unmanned Aerial Vehicle UAV) στη γεωργία

Η τεχνολογία έχει σημειώσει αξιοσημείωτη πρόοδο σε πολλούς κλάδους, συμπεριλαμβανομένων των γεωργικών και κτηνοτροφικών τομέων, αλλά στην περίπτωση της γεωργίας, οι εγκαταστάσεις επικοινωνίας όπως οι σταθμοί βάσης και το Wi-Fi είναι πολύ περιορισμένες, εμποδίζοντας την ανάπτυξη της τεχνολογίας IoT σε αυτόν τον τομέα (Uddin et al., 2018).

Τα δεδομένα που αποκτώνται μέσω των ασύρματων αισθητήρων δεν μπορούν να μεταδοθούν ελλείψει αξιόπιστης υποδομής επικοινωνίας. Υπό αυτές τις συνθήκες τα Μη Επανδρωμένα Ιπτάμενα Οχήματα (UAV) προσφέρουν μια εναλλακτική λύση, καθώς μπορούν να επισκέπτονται και να επικοινωνούν με τους ασύρματους αισθητήρες που συνήθως είναι τοποθετημένοι σε πολλά σημεία, στις μεγάλες καλλιεργήσιμες εκτάσεις, προκειμένου να συλλέξουν δεδομένα για περαιτέρω επεξεργασία και

ανάλυση. Επιπλέον, τα UAV γνωστά και ως drones, εξοπλισμένα με κάμερες υψηλής ανάλυσης και ακριβείς αισθητήρες, μπορούν να πετάξουν σε χιλιάδες εκτάρια γεωργικών εκμεταλλεύσεων, επιτηρώντας και συλλέγοντας δεδομένα συνεχώς. Τα UAV θεωρούνται το μέλλον της γεωργίας ακριβείας, λόγω των πλεονεκτημάτων τους τα οποία είναι η πολύ καλύτερη ανάλυση αεροφωτογραφιών σε αντίθεση με τους δορυφόρους και η δυνατότητα να λειτουργούν και να συλλέγουν δεδομένα, όποτε κρίνεται αναγκαίο. Επιπλέον, τα UAV υποστηρίζουν ταχύτερη και καλύτερη NDVI (γραφικός δείκτης που χρησιμοποιείται για την ανάλυση μετρήσεων τηλεπισκόπησης, αξιολογώντας εάν ο στόχος που παρατηρείται περιέχει ή όχι ζωντανή πράσινη βλάστηση) για την αξιολόγηση των συνθηκών καλλιέργειας, παρέχουν άμεση ανατροφοδότηση, ώστε οι αγρότες να μπορούν να δραστηριοποιούνται άμεσα και τέλος επηρεάζονται λιγότερο από τις καιρικές συνθήκες, όταν βρίσκονται σε κατάσταση πτήσης (Uddin et al., 2018).

Τα UAV, που χρησιμοποιούνται σε γεωργικές εφαρμογές χωρίζονται σε δύο κατηγορίες, τα μη επανδρωμένα αεροσκάφη σταθερής πτέρυγας και αυτά των πολλαπλών ρότορων. Αυτή τη στιγμή υπάρχουν στην αγορά προϊόντα και από τις 2 κατηγορίες drone τα οποία καλύπτουν διαφορετικές απαιτήσεις και ανάγκες. Τα UAV έχουν την ικανότητα να μεταφέρουν κάμερες, αυτοματισμούς, τεχνολογία GPS και αισθητήρες, ανάλογα με τις ανάγκες του καλλιεργητή. Ο τομέας της γεωργίας θεωρείται ένα ευνοϊκό πεδίο, όπου τα UAV μπορούν να προσφέρουν λύσεις για την επίλυση πολλών κυρίαρχων και μακροχρόνιων ζητημάτων. Ορισμένοι από τους βασικούς τομείς στους οποίους τα drones διαδραματίζουν ήδη καίριο ρόλο για να βοηθήσουν τους αγρότες καθ' όλη τη διάρκεια του κύκλου καλλιέργειας επισημαίνονται παρακάτω (Uddin et al., 2018).

2.3.1 Ανάλυση Εδάφους και Πεδίου

Τα drones είναι σε θέση να συλλέγουν ακριβείς πληροφορίες για την ανάλυση του εδάφους, πριν από τη σπορά της καλλιέργειας, γεγονός που βοηθά στον προσδιορισμό της καταλληλότερης καλλιέργειας για τη συγκεκριμένη γη. Επιπλέον, από την ανάλυση των δεδομένων προτείνεται στο γεωργό οι τύποι σπόρων και τα πρότυπα φύτευσης, που μπορούν να αξιοποιηθούν, ώστε να εξασφαλιστεί μεγαλύτερη απόδοση (Eltner et al., 2013).

2.3.2 Φύτευση

Εκατομμύρια στρέμματα γης υπό χρησιμοποιούνται αυτή τη στιγμή, λόγω του ότι είναι απρόσιτα από τον άνθρωπο ή επειδή παρατηρείται έλλειψη κατάλληλου εργατικού δυναμικού. Οι ανησυχίες για την ασφάλεια, ως προς τη σταθερότητα, του ακατέργαστου εδάφους είναι ο κύριος λόγος για να μην χρησιμοποιηθούν αυτές οι περιοχές για δασικούς ή γεωργικούς σκοπούς. Για το σκοπό αυτό, αναπτύσσονται συστήματα φύτευσης με χρήση μη επανδρωμένων αεροσκαφών, που μειώνουν το κόστος φύτευσης έως και 85%. Εκτός, από την εξοικονόμηση χρημάτων εξοικονομείται και χρόνος, καθώς ορισμένα μη επανδρωμένα αεροσκάφη που αναπτύχθηκαν πρόσφατα μπορούν να φυτέψουν, μέχρι και 100.000 δέντρα σε μία μόνο ημέρα. Αυτά τα συστήματα εκτοξεύουν λοβούς που περιλαμβάνουν τους σπόρους και τα απαραίτητα θρεπτικά συστατικά που απαιτούνται για την ανάπτυξη του φυτού, στο έδαφος. Αυτή η μέθοδος θεωρείται πολύ αποτελεσματική σε τραχιά εδάφη, ενώ το ποσοστό επιτυχίας υπερβαίνει το 75% (Johnson, 2018).

2.3.3 Παρακολούθηση Καλλιεργειών

Η συνεχής παρακολούθηση των καλλιεργειών, με συμβατικά μέσα είναι μία επίπονη εργασία στην οποία παρατηρείται χαμηλή απόδοση, λόγω του ότι πρέπει να καλυφθούν μεγάλες εκτάσεις. Τα drones δίνουν τη λύση επιτρέποντας την οικονομική και ακριβή παρακολούθηση σε πραγματικό χρόνο των μεγάλων καλλιεργειών. Η χρήση drones για την παρατήρηση των θρεπτικών συστατικών των καλλιεργειών, τα επίπεδα υγρασίας, την επίδραση των λιπασμάτων στη υγεία των φυτών και η χαρτογράφηση των τρισδιάστατων γεωμετρικών χαρακτηριστικών των δέντρων και των δενδρόφυτων καλλιεργειών, είναι μερικά μόνο παραδείγματα εφαρμογών, όπου καλύπτουν τα UAV (Szewczyk, 2019).

2.3.4 Άρδευση

Η χρήση drones σε αρδευτικές εφαρμογές είναι γεγονός. Ο εξοπλισμός των UAV με μια ποικιλία αισθητήρων και καμερών μπορεί να βοηθήσει στον εντοπισμό περιοχών που βρίσκονται υπό έλλειψη νερού και να προτείνει ποιες αλλαγές στο τρόπο άρδευσης

απαιτούνται. Ταυτόχρονα, μπορούν να χρησιμοποιηθούν για ψεκασμό νερού και φυτοφαρμάκων στις καλλιέργειες, ειδικά σε κρίσιμες περιπτώσεις, όπως είναι η ξηρασία, εξοικονομώντας χρόνο από το γεωργό και περιορίζοντας τη σπατάλη νερού (Hoffmann et al., 2016).

2.3.5 Καταμέτρηση Φυτών και Ανίχνευση Κενών

Η γεωργία ακριβείας χρειάζεται την δημιουργία χωρικών δεδομένων, σχετικά με την πυκνότητα των καλλιεργειών για τη λήψη αποφάσεων κατά τη διάρκεια διαφόρων εφαρμογών. Η ποσότητα και η αρίθμηση των φυτών όχι μόνο αντικατοπτρίζουν την κατάσταση στο χωράφι, αλλά επιτρέπουν την καλύτερη και ακριβέστερη αξιολόγηση της απόδοσης της παραγωγής. Η τεχνολογία των UAV προσφέρει ευέλικτες λύσεις για το σκοπό αυτό, με την ενσωμάτωση αισθητήρων και αυτοματισμών για την επίτευξη αυτής της εφαρμογής (Jin et al., 2017).

2.3.6 Ψεκασμός Φυτοφαρμάκων/Ζιζανιοκτόνων

Η εφαρμογή UAV για ψεκασμό είναι εξαιρετικά αποτελεσματική σε σύγκριση με τις τρέχουσες διαδικασίες, διότι μπορεί να ψεκάσει απευθείας στα ανεπιθύμητα ζιζάνια ή μπορεί να στοχεύσει μόνο τις πληγείσες περιοχές μιας καλλιέργειας. Σε αντίθεση με ότι συμβαίνει στις περισσότερες περιπτώσεις, όπου τα ζιζανιοκτόνα/φυτοφάρμακα ψεκάζονται σε ολόκληρο το αγρόκτημα, σπαταλώντας πολύτιμους πόρους και μολύνοντας το περιβάλλον (Faiçal et al., 2017).

2.3.7 Αξιολόγηση Υγείας Καλλιεργειών

Οι καλλιέργειες σάρωσης με ορατούς και υπέρυθρους αισθητήρες φωτός (IR) που είναι ενσωματωμένοι σε drones μπορούν να προσδιορίσουν ποια φυτά μπορεί να μολυνθούν από βακτήρια ή μύκητες. Με τη χρήση UAV, αυτή η διαδικασία μπορεί να επαναλαμβάνεται αρκετά συχνά και με ευελιξία, προλαμβάνοντας την εξάπλωση της νόσου σε άλλα φυτά ή περιοχές καλλιεργειών. Η έγκαιρη συλλογή δεδομένων μπορεί να βοηθήσει στην ανίχνευση της νόσου ή της ασθένειας σε πρώιμα στάδια, ακόμη και πριν φτάσουν στο σημείο να ανιχνευτούν με το ανθρώπινο μάτι (Puig et al., 2015).

2.3.8 Ανίχνευση - Αναγνώριση Φυτικών Ειδών

Η εξέλιξη της τεχνολογίας των UAV επιτρέπει την ανίχνευση και αναγνώριση διαφόρων φυτικών ειδών, ακόμα και εκείνα που θεωρούνται εξαφανισμένα ή παραμένουν ελάχιστα στη Γη μας. Τα UAV έχουν το πλεονέκτημα ότι μπορούν να προσεγγίσουν σημεία τα οποία θεωρούνται δυσπρόσιτα για τον άνθρωπο. Συγκεκριμένα, ο Εθνικός Τροπικός Βοτανικός Κήπος (NTBG) είχε ανακοινώσει, ότι ένα λουλούδι της Χαβάης, το οποίο θεωρούταν εξαφανισμένο το 2009, ανακαλύφθηκε σε κάθετη πλαγιά γκρεμού χρησιμοποιώντας drone (Johnson et al, 2019).

2.4 Επανδρωμένα και μη επίγεια οχήματα στη γεωργία

2.4.1 Τρακτέρ με Βάση το IoT

Η ενσωμάτωση γεωργικών ελκυστήρων και αυτόματων γεωργικών μηχανημάτων στη βιομηχανοποιημένη καλλιέργεια κρίθηκε αναγκαία, λόγω παραγόντων όπως η έλλειψη εργατικού δυναμικού, το κόστος της απασχόλησης υπαλλήλων, αλλά και ο όγκος παραγωγής ο οποίος αυξήθηκε, εξαιτίας της αύξησης του πληθυσμού. Αξίζει να σημειωθεί ότι ένας γεωργικός ελκυστήρας μεσαίου μεγέθους μπορεί να λειτουργήσει 40 φορές ταχύτερα και με αρκετά λιγότερα έξοδα, από τα μέσα που χρησιμοποιούνταν στη παραδοσιακή γεωργία. Χάρη στην πρόοδο της τεχνολογίας οι κατασκευαστές γεωργικών μηχανημάτων δημιουργούν μηχανήματα προσαρμοσμένα στις απαιτήσεις των καλλιεργητών, όπως αυτοκινούμενους ελκυστήρες με υπολογιστικές δυνατότητες cloud, οι οποίοι δεν προϋποθέτουν την ύπαρξη χειριστή. Το πλεονέκτημα αυτών των προϊόντων είναι η επίτευξη μεγαλύτερης ακρίβειας σε εφαρμογές, όπως ο ψεκασμός με εντομοκτόνο. Χαρακτηριστικό παράδειγμα αποτελεί η προσπάθεια της εταιρείας Case IH η οποία χρησιμοποίησε αυτόνομο τρακτέρ για τη φύτευση σόγιας. Παράλληλα, οι κατασκευαστές αυτοκινούμενων γεωργικών μηχανημάτων στοχεύουν στη σύνδεση του γεωργικού μηχανήματος με το διαδίκτυο, ώστε ο αγρότης να μπορεί να παρακολουθεί και να αναλύει τα δεδομένα που συλλέγονται (IDTechEx, 2018).

2.4.2 Ρομπότ Συγκομιδής

Η συγκομιδή μιας καλλιέργειας αποτελεί το σημαντικότερο και τελευταίο στάδιο κατά τη διάρκεια της παραγωγικής διαδικασίας από την οποία γίνεται αντιληπτό το μέγεθος της παραγωγής και ο τελικός βαθμός επιτυχίας της. Σε ορισμένες καλλιέργειες, αυτό γίνεται μία φορά (καλλιέργειες σιτηρών, βαμβακιού, κλπ.), ενώ, σε ορισμένες εκτελείται αρκετές φορές (καλλιέργειες φρούτων, λαχανικών κλπ.), ακόμη και σε καθημερινή βάση, ανάλογα με τη πρόοδο της. Η συγκομιδή της καλλιέργειας την κατάλληλη στιγμή είναι κρίσιμη, διότι αν εκτελεστεί νωρίτερα ή αργότερα είναι δυνατό να επηρεαστεί η ποιότητα του προϊόντος που θα παραλάβει ο καταναλωτής. Προκειμένου να αυτοματοποιηθεί, όσο το δυνατόν περισσότερο η διαδικασία συγκομιδής, ώστε να γίνει ακριβέστερη, ο ρόλος των ρομπότ αυξάνεται τις τελευταίες δεκαετίες. Λαμβάνοντας υπόψη τις υπηρεσίες συγκομιδής που πρέπει να καλύψουν οι ρομποτικές γεωργικές πλατφόρμες, πολλοί ερευνητές μελετούν συνεχώς τρόπους, προκειμένου να επιλύσουν ζητήματα που σχετίζονται με την ευαισθησία της ανίχνευσης φρούτων, το σχήμα, το μέγεθος, το χρώμα και τον εντοπισμό τους. Η αυτόματη συγκομιδή φρούτων απαιτεί τη διερεύνηση εξελιγμένων αισθητήρων ικανών να συλλέγουν ακριβείς πληροφορίες για τη συγκεκριμένη καλλιέργεια. Η ανίχνευση του σωστού στόχου (φρούτου) σε φυσικές συνθήκες δεν είναι απλή υπόθεση, καθώς οι περισσότεροι καρποί καλύπτονται πίσω από φύλλα και κλαδιά ή επικαλύπτονται με άλλους καρπούς. Για την επίλυση αυτού του προβλήματος οι περισσότερες έρευνες εστιάζουν στη χρήση υπολογιστικής όρασης για την επεξεργασία εικόνας και σε τεχνικές μηχανικής μάθησης για την εξαγωγή συμπερασμάτων. Αυτή η διαδικασία απαιτεί εξειδικευμένα και εξελιγμένα εργαλεία για την διαφοροποίηση των φρούτων, καθώς μπορούν να υπάρξουν περισσότερα από εξήντα σχήματα, μεγέθη και χρώματα μόνο για την συγκομιδή ενός είδους πιπεριών, για παράδειγμα. Οι δυσκολίες που προκύπτουν από την συγκομιδή των τελικών προϊόντων των καλλιεργειών έχει οδηγήσει στη δημιουργία γεωργικών ρομποτικών πλατφορμών μόνο σε συγκεκριμένες καλλιέργειες. Μερικές από τις γεωργικές ρομποτικές πλατφόρμες που χρησιμοποιούνται για τη συγκομιδή καλλιεργειών είναι το Rubion της εταιρείας Octinion για τη συγκομιδή φράουλας, το ρομπότ SWEEPER για τη συγκομιδή πιπεριών, και το FFRobot για τη συλλογή φρούτων δενδροκαλλιεργειών, όπως τα μήλα (Zhao et al., 2016).

2.4.2.1 SWEEPER



Εικόνα 1: Ρομπότ Sweeper κατά τη συγκομιδή



Εικόνα 2: Ρομπότ Sweeper

Στα σύγχρονα θερμοκήπια η ζήτηση για αυτοματοποίηση της εργασίας συγκομιδής, είναι αρκετά μεγάλη. Η διαθεσιμότητα ειδικευμένου εργατικού δυναμικού που να αποδέχεται επαναλαμβανόμενα καθήκοντα υπό τις σκληρές κλιματικές συνθήκες ενός θερμοκηπίου μειώνεται ραγδαία. Με συνέπεια, οι καλλιεργητές να πρέπει να αντιμετωπίσουν και την αυξανόμενη παραγωγή-ζήτηση και την έλλειψη ανθρώπινου δυναμικού. Η λύση του παραπάνω προβλήματος θα μπορούσε να προέλθει από την εξέλιξη της τεχνολογίας, ωστόσο η τεχνολογία αυτοματοποιημένης συγκομιδής φρούτων και λαχανικών έχει παραμείνει στάσιμη τις τελευταίες δεκαετίες. Για το έργο EE-7-7 CROPS, που χρηματοδοτήθηκε από ευρωπαϊκά κονδύλια και υλοποιήθηκε στο πλαίσιο συνεργασίας αρκετών δημόσιων και ιδιωτικών φορέων, διεξήχθησαν εκτενής

έρευνες στο τομέα της γεωργικής ρομποτικής. Μία από τις εφαρμογές που προέκυψαν, ήταν η δημιουργία και η διάθεση, στη γεωργική αγορά, ενός ρομπότ συγκομιδής γλυκών πιπεριών, για το ελεγχόμενο περιβάλλον ενός θερμοκηπίου. Μέχρι τώρα αυτό δεν είχε επιτευχθεί ποτέ και θα εξασφάλιζε τον ηγετικό ρόλο της Ευρώπης στη γεωργική ρομποτική. Το SWEEPER χρησιμοποίησε την τεχνολογία που αναπτύχθηκε στο CROPS για να εισαγάγει, να δοκιμάσει και να επικυρώσει μια ρομποτική λύση συγκομιδής για γλυκές πιπεριές υπό πραγματικές συνθήκες.

2.4.2.2 Rubion

Το αυτόνομο ρομπότ συλλογής φράουλας Rubion κινείται ανάμεσα στην καλλιέργεια, μαζεύοντας φράουλες, όπως θα μάζευε ιδανικά και ένας άνθρωπος, χωρίς να τις μελανιάσει. Χάρη στην ενσωματωμένη παρακολούθηση ποιότητας, το ρομποτικό σύστημα επιτρέπει τη διαλογή, την προηγμένη παρακολούθηση των καλλιεργειών και την καλλιέργεια ακριβείας. Ο ρομποτικός βραχίονας μαζεύει τις φράουλες και τις τοποθετεί με μεγάλη προσοχή και ακρίβεια στο καλάθι μεταφοράς (Rubion, Retrieved Online: January 2023).



Εικόνα 3: Ρομπότ Rubion

2.4.2.3 FFRobot

Η FFRobotics έχει δημιουργήσει μια μοναδική, κατοχυρωμένη πατέντα για τη ρομποτική συγκομιδή φρούτων. Το FFRobot αποτελεί μια αξιόπιστη και στιβαρή πλατφόρμα συγκομιδής, που μιμείται τη διαδικασία συλλογής με το χέρι για αποτελεσματική, οικονομικά αποδοτική και χωρίς μώλωπες, στο προϊόν, συγκομιδή

φρούτων. Η πλατφόρμα αυτή προσφέρει μια μοναδική ευκαιρία για τους αγρότες/καλλιεργητές να ανταποκριθούν στις προκλήσεις εύρεσης και διατήρησης εργατικού δυναμικού, αύξησης του κόστους εργασίας και πιθανής ζημιάς σε καρπούς που μαζεύτηκαν με το χέρι, μειώνοντας ή και αντικαθιστώντας τους ανθρώπινους συλλέκτες από τη συρρικνούμενη δεξαμενή εργατικού δυναμικού. Αξίζει να σημειωθεί, ότι η γεωργική ρομποτική πλατφόρμα χρησιμοποιεί προηγμένο λογισμικό αναγνώρισης και ταξινόμησης καρπών σύμφωνα με τα προκαθορισμένα κριτήρια του Grower για την επιλογή συγκομιδής. Ενώ τα στατιστικά στοιχεία έχουν αποδείξει ότι η χρήση του ρομπότ προσφέρει 10 φορές πιο παραγωγική και ταχύτερη συγκομιδή φρούτων διατηρώντας πρότυπα υψηλής ποιότητας, σε σύγκριση με τον μέσο άνθρωπο (FFRobotics.com, Retrieved online: January 2023).



Εικόνα 4: FFRobot

2.5 Συμπεράσματα

Στο κεφαλαίο αυτό αναλύθηκαν γεωργικές δραστηριότητες, όπως η χαρτογράφηση, η άρδευση και η λίπανση του εδάφους, που είναι απαραίτητες για την ανάπτυξη μιας καλλιέργειας. Επιπλέον, αναλύθηκε η αντιμετώπιση των ασθενειών των καλλιεργειών και η πρόβλεψη απόδοσης της παραγωγής. Οι παραπάνω γεωργικές δραστηριότητες περιλαμβάνουν ποικίλες και συνεχείς μετρήσεις, οι οποίες μπορούν να εκτελεστούν είτε με τη χρήση επίγειων αισθητήρων και IoT αυτοματισμών, είτε με τη χρήση drones και UAV που έχουν τη δυνατότητα να μεταφέρουν τον κατάλληλο εξοπλισμό. Παρουσιάστηκαν πληροφορίες σχετικά με την ανάπτυξη αυτόνομων γεωργικών ελκυστήρων, καθώς και αυτόνομων γεωργικών μηχανημάτων συγκομιδής, που έχουν υλοποιηθεί και χρησιμοποιούνται ήδη στις καλλιέργειες. Γίνεται αντιληπτό, ότι

πληθώρα εφαρμογών ακριβείας χρησιμοποιούνται αυτή τη στιγμή σε γεωργικές καλλιέργειες παρέχοντας υπηρεσίες που διευκολύνουν τους γεωργούς σε όλα τα στάδια της παραγωγικής διαδικασίας και εξασφαλίζοντας ποιοτικά τελικά προϊόντα.

Κεφάλαιο 3: Εξοπλισμός & Τεχνολογίες Γεωργίας Ακριβείας

3.1 Εισαγωγή στο αντικείμενο

Στο παρόν κεφάλαιο παρουσιάζονται ο εξοπλισμός και τα μέσα, που συνδυάζονται, ώστε να υλοποιηθούν εφαρμογές της γεωργίας ακριβείας, όπως είναι τα συστήματα αισθητήρων. Επιπλέον, γίνεται αναφορά και ανάλυση του τρόπου λειτουργίας της τεχνολογίας, που υποστηρίζει την γεωργία ακριβείας, όπως είναι τα δίκτυα επικοινωνίας, τα πρωτόκολλα λογισμικού και οι αλγόριθμοι.

Οι περισσότερες γεωργικές εργασίες της σύγχρονης γεωργίας μεγάλης κλίμακας εκτελούνται από μηχανολογικό εξοπλισμό, όπως τρακτέρ, θεριζοαλωνιστικές μηχανές και άλλα γεωργικά μηχανήματα που υποστηρίζονται πλήρως ή εν μέρει από τεχνολογίες τηλεπισκόπησης και τεχνολογίες επικοινωνίας. Στη γεωργία ακριβείας, οι γεωργικές εργασίες, όπως η σπορά, η λίπανση, η άρδευση και η συγκομιδή, εκτελούνται από σύγχρονα γεωργικά οχήματα εξοπλισμένα με τεχνολογικές συσκευές GPS (Global Positioning System) και GIS (Geographic Information Systems), ώστε να μπορούν να λειτουργούν με μεγαλύτερη ακρίβεια (Zhang et al., 2002).

Η επιτυχία της σύγχρονης γεωργίας ακριβείας βασίζεται στα ακριβή συλλεγόμενα δεδομένα. Η υψηλή ακρίβεια των δεδομένων επιτυγχάνεται με τη χρήση εξελιγμένων τεχνολογικών συσκευών, που εξοπλίζουν πλατφόρμες τηλεπισκόπησης, όπως δορυφόρους, γεωργικά αεροπλάνα, ειδικά μετεωρολογικά αερόστατα (μπαλόνια) και UAV και με τη χρήση διαφόρων τύπων αισθητήρων, που αναπτύσσονται στη καλλιέργεια (Zhang et al., 2002).

Η συμβατική γεωργία τις τελευταίες δεκαετίες έχει βιομηχανοποιηθεί σε αρκετά μεγάλο βαθμό, πράγμα που σημαίνει ότι η συλλογή δεδομένων και ο έλεγχος τους αποτελούν καθοριστικό παράγοντα για την διατήρηση ισορροπίας μεταξύ κόστους και παραγωγής, με σκοπό την αύξηση των κερδών σε μια καλλιέργεια. Στόχος είναι η

περαιτέρω αυτοματοποίηση και η ψηφιοποίηση της γεωργίας, μέσα από τη δημιουργία εξελιγμένων τεχνολογικών εργαλείων, που να καλύπτουν όλο το φάσμα των γεωργικών δραστηριοτήτων και της γεωργικής παραγωγής γενικότερα (Zhang et al., 2002).

Με βάση αυτά τα δεδομένα, εκτιμάται ότι, η διεθνής αγορά έξυπνης γεωργίας αυξήθηκε με ρυθμό ανάπτυξης 19,3% ετησίως, κατά την περίοδο 2017-2022 αγγίζοντας τα 23,14 δισεκατομμύρια δολάρια το 2022. Οι κατασκευαστές γεωργικών τεχνολογιών και εξαρτημάτων προσφέρουν στην αγορά μια ποικιλία προϊόντων και λύσεων, που βασίζονται σε αισθητήρες, δίκτυα επικοινωνίας, αλγόριθμους και άλλα για μια σειρά εφαρμογών (Zhang et al., 2002).

3.2 Ασύρματοι Αισθητήρες

Οι ασύρματοι αισθητήρες είναι το κρισιμότερο εργαλείο σε μια αυτοματοποιημένη καλλιέργεια, διότι διαδραματίζουν καίριο ρόλο όσον αφορά τη συλλογή των δεδομένων σχετικά με τις συνθήκες μιας καλλιέργειας. Οι ασύρματοι αισθητήρες μπορούν να χρησιμοποιηθούν είτε αυτόνομα, επί του πεδίου σε σημεία της καλλιέργειας, είτε μπορούν να ενσωματωθούν σε υφιστάμενες γεωργικές πλατφόρμες και τμήματα προηγμένων γεωργικών εργαλείων και βαρέων μηχανημάτων, ανάλογα με τις απαιτήσεις της γεωργικής εφαρμογής (Ayaz et al., 2019). Παρακάτω, αναφέρονται οι κύριοι τύποι αισθητήρων, σύμφωνα με τη διαδικασία εργασίας, το σκοπό τους και τα οφέλη που προσφέρουν.



Εικόνα 5 Διαφορετικοί τύποι αισθητήρων που χρησιμοποιούνται για ανίχνευση.

1) Ακουστικοί Αισθητήρες

Συσκευή που συμβάλλει στη διαχείριση των γεωργικών εκμεταλλεύσεων, συμπεριλαμβανομένης της καλλιέργειας εδάφους και της συγκομιδής φρούτων. Κατά τη διάρκεια της γεωργικής εργασίας, όπου το γεωργικό μηχάνημα αλληλεπιδρά με τα σωματίδια του εδάφους ο αισθητήρας καταγράφει τις διαφορές που παρατηρούνται στα επίπεδα θορύβου. Η παρακολούθηση, η ανίχνευση παρασίτων και η ταξινόμηση των ποικιλιών των σπόρων είναι μερικές από τις χρήσεις που καλύπτει το συγκεκριμένο είδος αισθητήρων (Gasso-Tortajada, 2010).

2) Προγραμματιζόμενοι Αισθητήρες Πυλών Πεδίου (FPGA)

Οι αισθητήρες που βασίζονται στο FPGA είναι μια νέα τεχνολογία η οποία τώρα αρχίζει να ενσωματώνεται στη γεωργία, λόγω της ευελιξίας τους για αναδιαμόρφωση. Οι κυριότερες γεωργικές εφαρμογές στις οποίες χρησιμοποιούνται, περιλαμβάνουν τη μέτρηση της διαπνοής των φυτών, τη μέτρηση της άρδευσης και της υγρασίας των φυτών σε πραγματικό χρόνο. Η χρήση τους στη γεωργία, ωστόσο βρίσκεται σε πρώιμο στάδιο, λόγω περιορισμών, όπως το μέγεθος, το κόστος και η κατανάλωση ενέργειας. Με την επίλυση των παραπάνω ζητημάτων, οι αισθητήρες που βασίζονται στη τεχνολογία αυτή, θα μπορούν να προσφέρουν ικανοποιητικές λύσεις ανάλογα με τις απαιτήσεις της γεωργικής εφαρμογής (Millan-Almaraz et al., 2010).

3) Οπτικοί Αισθητήρες

Συμβάλλουν στη μέτρηση οργανικών ουσιών του εδάφους, υγρασίας, χρώματος του εδάφους, παρουσίας ορυκτών και της σύνθεσής τους, χρησιμοποιώντας φαινόμενα ανάκλασης φωτός και παράλληλα ανιχνεύουν την περιεκτικότητα του εδάφους σε άργιλο. Αυτοί οι αισθητήρες δοκιμάζουν την ικανότητα του εδάφους να αντανακλά το φως με βάση διαφορετικά μέρη του ηλεκτρομαγνητικού φάσματος. Οι οπτικοί αισθητήρες χρησιμοποιούνται για βασική εκτίμηση της ανάπτυξης των φυτών των φυτών και ιδιαίτερα για την επίβλεψη της ωρίμανσης των φρούτων, καθώς και για την ένδειξη αλλαγών στη πυκνότητα του εδάφους. Έχουν τη δυνατότητα να αντιλαμβάνονται τα διαφορετικά είδη φυτών συμβάλλοντας στην ανίχνευση ζιζανίων και άλλων ανεπιθύμητων φυτών, ιδίως σε μεγάλες καλλιέργειες. Ο συνδυασμός ενός

οπτικού αισθητήρα με πληροφορίες θέσης, μπορεί να χαρτογραφήσει τη διανομή και την ανάλυση ζιζανιοκτόνων. Επιπλέον έχουν την ικανότητα να διακρίνουν μεταξύ βλάστησης και εδάφους από τα φάσματα αντανάκλασης τους (Murray, 2018).

4) Υπερηχητικοί Αισθητήρες

Είναι αισθητήρες χαμηλού κόστους, με δυνατότητα να λειτουργούν σε διάφορες εφαρμογές, διακρίνονται για την ευχρηστία τους και την προσαρμοστικότητά τους, όπως ο ρυθμός δειγματοληψίας. Η παρακολούθηση δεξαμενών και η μέτρηση απόστασης ψεκασμού (έλεγχος θέσεως βραχιόνων για αποτελεσματικότερο ψεκασμό), η ανίχνευση αντικειμένου για αποφυγή σύγκρουσης και η παρακολούθηση των καλλιεργειών αποτελούν μερικές μόνο από τις γεωργικές εφαρμογές χρήσεις. Ο σωστός συνδυασμός των υπερηχητικών αισθητήρων με τον κατάλληλο εξοπλισμό κάμερας χρησιμοποιείται για την ανίχνευση ιωδίων, ώστε να προσδιορισθούν τα ύψη των φυτών της καλλιέργειας (Dvorak et al., 2016).

5) Ηλεκτροχημικοί Αισθητήρες

Βοηθούν στην αξιολόγηση των χαρακτηριστικών του εδάφους και την ανάλυση των θρεπτικών ουσιών του εδάφους, όπως το pH. Η τυπική χημική ανάλυση εδάφους, η οποία είναι ως επί το πλείστον δαπανηρή και χρονοβόρα, καθώς απαιτεί την εκσκαφή ορισμένης ποσότητας χώματος και μεταφοράς του σε κάποιο ερευνητικό κέντρο, μπορεί εύκολα να αντικατασταθεί με αυτούς τους αισθητήρες. Θρεπτικά συστατικά του εδάφους, όπως η αλατότητα και το pH μετρούνται με αισθητήρες αυτού του είδους (Yew et al., 2014).

6) Ηλεκτρομαγνητικοί Αισθητήρες

Καταγράφουν την ηλεκτρική αγωγιμότητα, τον εντοπισμό ηλεκτρικής απόκρισης, τη παροδική ηλεκτρομαγνητική απόκριση και τη ρύθμιση εφαρμογών μεταβλητού ρυθμού σε πραγματική κατάσταση. Η συγκεκριμένη τεχνολογία αισθητήρων χρησιμοποιεί κατάλληλα ηλεκτρικά κυκλώματα ώστε να εξακριβωθεί η ικανότητα των σωματιδίων του εδάφους να διεξάγουν ή να συσσωρεύουν ηλεκτρικό φορτίο, το οποίο γίνεται κυρίως με τις ακόλουθες δύο μεθόδους: επαφή ή μη επαφή. Συστατικά του

εδάφους, όπως τα υπολειμματικά νιτρικά άλατα και η οργανική ύλη στο έδαφος καταγράφονται με τη χρήση των ηλεκτρομαγνητικών αισθητήρων (Yunus and Mukhopadhyay, 2011).

7) Μηχανικοί Αισθητήρες

Οι μηχανικοί αισθητήρες αξιολογούν τη μηχανική αντίσταση του εδάφους (συμπίεση) για να υποδείξουν το μεταβλητό επίπεδο συμπίεσης. Οι μηχανικοί αισθητήρες εισέρχονται στο έδαφος και καταγράφουν τη δύναμη που ασκείται σε αυτό από γεωργικά μηχανήματα και φορτία που φέρουν (Hemmat et al., 2013).

8) Αισθητήρες Ροής Μάζας

Το είδος των αισθητήρων αυτών χρησιμοποιείται για την παρακολούθηση της απόδοσης της παραγωγής, μετρώντας την ποσότητα της ροής των σιτηρών, όταν αυτά διέρχονται από τα γεωργικά μηχανήματα, όπως η θεριζοαλωνιστική μηχανή. Η ανίχνευση της ροής μάζας των σιτηρών για τον προσδιορισμό της απόδοσης των καλλιεργειών δεν αποτελεί νέα τεχνική, καθώς πραγματοποιείται τις τελευταίες δύο δεκαετίες. Ο αισθητήρας ροής μάζας αποτελεί ένα από τα σημαντικότερα συστατικά του συστήματος παρακολούθησης της απόδοσης, το οποίο συνεργάζεται και με διαφορετικές τεχνολογίες, όπως ο αισθητήρας υγρασίας σιτηρών, η συσκευή αποθήκευσης δεδομένων και ένα εσωτερικό λογισμικό για την ανάλυση των δεδομένων αυτών (Schuster et al., 2017).

9) Αισθητήρες με Βάση τη Μεταβλητότητα

Μετρούν τον ποσοτικό προσδιορισμό των ανταλλαγών διοξειδίου του άνθρακα, υδρατμών, μεθανίου ή άλλων αερίων και ενέργειας μεταξύ της επιφάνειας της γης και της ατμόσφαιρας. Ο αισθητήρας αυτός προσφέρει έναν ακριβή τρόπο μέτρησης των διακυβευμάτων ενέργειας και ιχνοστοιχείων αερίου σε διάφορα οικοσυστήματα γεωργικών εφαρμογών. Οι αισθητήρες που βασίζονται σε αυτή την τεχνολογία προτιμώνται από άλλες παρόμοιες επιλογές, όπως ο στενός θάλαμος, λόγω της υψηλής ακρίβειας και της ικανότητάς τους να μετρούν τη συνεχή ροή σε μεγάλες εκτάσεις (Kumar et al., 2017).

10) Αισθητήρες με Βάση τη Στάθμη του Νερού (SWLB)

Ο χαρακτηρισμός υδρολογικής συμπεριφοράς, όπως η στάθμη του νερού, σε γεωργικές λεκάνες απορροής προϋποθέτει την ύπαρξη της συγκεκριμένης τεχνολογίας αισθητήρων. Αυτό γίνεται με τη μέτρηση των βροχοπτώσεων, των ροών ρευμάτων και άλλων πηγών προέλευσης νερού.

11) Ανίχνευση Φωτός και Εμβέλειας (LIDAR)

Τεχνολογία διαδεδομένη σε πλήθος γεωργικών εφαρμογών, όπως η χαρτογράφηση και η τμηματοποίηση της γης. Η παρακολούθηση της διάβρωσης και της απώλειας εδάφους, η πρόβλεψη της απόδοσης και ο προσδιορισμός του τύπου του εδάφους αποτελούν μερικές ακόμα περιπτώσεις στις οποίες εφαρμόζεται η ανίχνευση φωτός και εμβέλειας. Επιπρόσθετη λειτουργία χρήσης του LIDAR είναι η λήψη δυναμικών πληροφοριών μέτρησης σχετικά με την περιοχή των φύλλων οπωροφόρων δένδρων, ενώ σε συνδυασμό με τεχνολογία GPS δημιουργεί έναν τρισδιάστατο χάρτη. Επιπλέον, μπορεί να χρησιμοποιηθεί και για την εκτίμηση της βιομάζας διαφόρων καλλιεργειών και δέντρων (Weiss and Biber, 2011).

12) Αισθητήρες Τηλεματικής

Οι αισθητήρες τηλεμετρίας χρησιμοποιούνται για τη συλλογή δεδομένων από απομακρυσμένες τοποθεσίες και απρόσιτα σημεία, για την καταγραφή της θέσης και των ταξιδιωτικών διαδρομών για την αποφυγή επίσκεψης στο ίδιο σημείο. Οι υπηρεσίες αυτές επιτρέπουν στους καλλιεργητές να καταγράψουν και να αποθηκεύουν αυτόματα και ασταμάτητα, όλες τις πληροφορίες που σχετίζονται με τις γεωργικές εργασίες, μεγιστοποιώντας τα οφέλη για το περιβάλλον, ενώ επιπλέον μπορεί να ελαχιστοποιήσει τις κλοπές αγροτικού εξοπλισμού (Mark and Griffin, 2016).

13) Τηλεπισκόπηση

Οι αισθητήρες αυτής της κατηγορίας συμβάλλουν στη λήψη και αποθήκευση των γεωγραφικών πληροφοριών, την επεξεργασία τους, την ανάλυση τους και την

παρουσίαση όλων των τύπων χωρικών ή γεωγραφικών δεδομένων. Διακρίνονται για τη χρήση τους σε γεωργικές εφαρμογές, συμπεριλαμβανομένης της εκτίμησης των καλλιεργειών, των ημερομηνιών πρόβλεψης της απόδοσης, της μοντελοποίησης και πρόβλεψης της απόδοσης, της ταυτοποίησης φυτών και παρασίτων, της κάλυψης της γης και της χαρτογράφησης της υποβάθμισης. Το δορυφορικό σύστημα αισθητήρων γνωστό και ως Argos που χρησιμοποιείται για τη συλλογή, επεξεργασία και διάδοση περιβαλλοντικών δεδομένων από σταθερές και κινητές πλατφόρμες παγκοσμίως, αποτελεί χαρακτηριστικό παράδειγμα της τηλεπισκόπησης. Το ενσωματωμένο, αυτόματο σύστημα αναφοράς πακέτων (APRS) χρησιμοποιείται στην αναφορά δεδομένων τηλεμετρίας μέσω δορυφορικής επικοινωνίας (Hegazy and Kaloop, 2015).

3.3 Πρωτόκολλα Επικοινωνίας στην γεωργία

Η έγκαιρη επικοινωνία και η μεταφορά πληροφοριών θεωρούνται η ραχοκοκαλιά της γεωργίας ακριβείας. Ο πραγματικός σκοπός δεν μπορεί να επιτευχθεί εάν δεν παρέχεται μια σταθερή, αξιόπιστη και ασφαλής σύνδεση μεταξύ όλων των τεχνολογικών συσκευών και εφαρμογών που εκπέμπουν και δέχονται δεδομένα. Παράγοντες όπως το κόστος, το εύρος κάλυψης, η κατανάλωση ενέργειας και η αξιοπιστία είναι κρίσιμοι και πρέπει να ληφθούν υπόψη πριν από την επιλογή του μέσου επικοινωνίας. Η επικοινωνία, μέσω δικτύων χαμηλής ενέργειας παρέχει συνδεσιμότητα μόνο σε μία τοποθεσία, με αποτέλεσμα να μην προσφέρουν υπηρεσίες σε απομακρυσμένες περιοχές, όπου τα δεδομένα που συλλέγονται πρέπει να διαβιβάζονται στο σύστημα (FMS). Ανάλογα με το σκοπό που χρειάζεται να επιτευχθεί, τη διαθεσιμότητα, την επεκτασιμότητα και τις απαιτήσεις της εφαρμογής, μπορούν να χρησιμοποιηθούν διάφοροι τρόποι επικοινωνίας και διάφορες τεχνολογίες, για το σκοπό αυτό μερικοί από τους οποίους αναφέρονται παρακάτω.

1) Κυψελοειδής Επικοινωνία (CELLULAR COMMUNICATION)

Οι κυψελοειδής επικοινωνίες λειτουργούν από 2G έως 4 G και εξαρτώνται από την απαίτηση του εύρους ζώνης και το σκοπό της εφαρμογής. Ωστόσο, η αξιοπιστία, ακόμη και η διαθεσιμότητα, ενός δικτύου κινητής τηλεφωνίας στις αγροτικές περιοχές αποτελεί μείζον πρόβλημα. Για την αντιμετώπισή του, παρέχεται η επιλογή της

μετάδοσης δεδομένων μέσω δορυφόρου, ωστόσο το κόστος αυτής της λειτουργίας επικοινωνίας είναι αρκετά υψηλό, γεγονός που την καθιστά ακατάλληλη για μικρές και μεσαίες καλλιέργειες.

2) ZigBee

Η τεχνολογία επικοινωνίας Zigbee καλύπτει ένα ευρύ φάσμα εφαρμογών και μπορεί να αντικαταστήσει υφιστάμενες μη τυποποιημένες τεχνολογίες. Ανάλογα με τις απαιτήσεις της εφαρμογής, οι συσκευές που βασίζονται σε αυτό το πρωτόκολλο μπορεί να είναι ένας από τους τρεις τύπους, συμπεριλαμβανομένου του Συντονιστή, του Δρομολογητή και του Τελικού Χρήστη. Με βάση τα παραπάνω χαρακτηριστικά και λαμβάνοντας υπόψη τις απαιτήσεις εφαρμογής του στη γεωργία, το Zigbee μπορεί να διαδραματίσει καθοριστικό ρόλο, στοχεύοντας ιδιαίτερα στο περιβάλλον του θερμοκηπίου όπου συνήθως απαιτούνται επικοινωνίες μικρής εμβέλειας. Για εφαρμογές όπως η άρδευση και η λίπανση, οι μονάδες Zigbee δικτυώνονται για επικοινωνία, όπως στη περίπτωση της γεωργικής εφαρμογής άρδευσης με σταγόνες που χρησιμοποιείται για την παρακολούθηση του περιεχομένου του εδάφους, όπως η υγρασία.

3) Bluetooth

Αποτελεί ένα πρότυπο ασύρματης επικοινωνίας που συνδέει μικροσυσκευές σε μικρές αποστάσεις που συνήθως συνεργάζονται σε κοντινή απόσταση. Τα πλεονεκτήματα αυτής της τεχνολογίας είναι η απαίτηση χαμηλής ισχύος, η εύκολη χρήση και το χαμηλό κόστος, για αυτό το λόγο χρησιμοποιείται σε πολλές εφαρμογές έξυπνης γεωργίας. Επιπλέον, το Bluetooth σημειώνει πρόοδο σε πολλά συστήματα IoT με την απελευθέρωση χαμηλής ενέργειας Bluetooth (Bluetooth Low Energy) ή κοινώς γνωστό ως Bluetooth Smart. Η τοποθέτηση ενός αισθητήρα υγρασίας και θερμοκρασίας, που αναπτύσσεται σε γεωργικό περιβάλλον και εστιάζει στις καιρικές συνθήκες των καλλιεργειών και η δημιουργία ενός κόμβου αισθητήρων που πρόκειται να παρακολουθεί το περιβαλλοντικό φως και τη θερμοκρασία, αποτελούν μερικά μόνο παραδείγματα εφαρμογών στα οποία χρησιμοποιείται η τεχνολογία BLE (Bluetooth Low Energy). Η τεχνολογία αυτή προτιμάται από αντίστοιχες τεχνολογίες γιατί το

πρωτόκολλο αυτό είναι βασισμένο σε IoT εφαρμογές, ενώ παράλληλα υποστηρίζει και την σύνδεσή του με ένα έξυπνο τηλέφωνο.

4) Lora

Το πρότυπο επικοινωνίας LoRa είναι μια πλατφόρμα μεγάλης εμβέλειας και χαμηλής ισχύος που χρησιμοποιείται εκτενώς στις εφαρμογές IoT. Απαιτεί μικρή κατανάλωση ενέργειας και προσφέρει συνδεσιμότητα LPWAN (Low Power Wide Area Network) μεταξύ των ασύρματων αισθητήρων και του Cloud. Η τεχνολογία αυτή έχει αποδειχθεί πολύ πιο αποτελεσματική και αξιόπιστη από τις τεχνολογίες Bluetooth και Wi-Fi, διότι η ισχύς του σήματός της μπορεί να διεισδύσει σε παχιά και μονωμένα αντικείμενα, όπως είναι το έδαφος και να καλύψει μια μεγαλύτερη περιοχή δικτύου. Συνολικά, τα δίκτυα που βασίζονται στη τεχνολογία LoRa έχουν υψηλότερες επιδόσεις όσον αφορά τη διάρκεια ζωής και ταυτόχρονα, δημιουργούν μειωμένο φόρτο συντήρησης.

5) Sigfox

Το Sigfox χρησιμοποιείται για την παροχή υπηρεσιών συνδεσιμότητας δικτύου σε αντικείμενα χαμηλής ισχύος. Βασίζεται σε τεχνολογία στενής ζώνης ή εξαιρετικά στενής ζώνης. Ως εκ τούτου, χρειάζονται πολύ στενά κομμάτια φάσματος και αλλάζει τη φάση του ραδιοκύματος φορέα για να κωδικοποιήσει τα δεδομένα. Με βάση αυτά τα χαρακτηριστικά, προσφέρει απόδοση υψηλού επιπέδου, ακόμη και αν 100 αισθητήρες πρέπει να μεταδίδουν δεδομένα ταυτόχρονα.

3.4 Ανάλυση Δεδομένων

Την τελευταία δεκαετία η επιστήμη και η τεχνολογία έχουν φέρει την επανάσταση στον κόσμο και ειδικότερα στη γεωργική παραγωγή. Τα ασύρματα δίκτυα αισθητήρων και το διαδίκτυο των πραγμάτων (IoT) διαδραματίζουν ουσιαστικό ρόλο σε αυτή την επανάσταση.

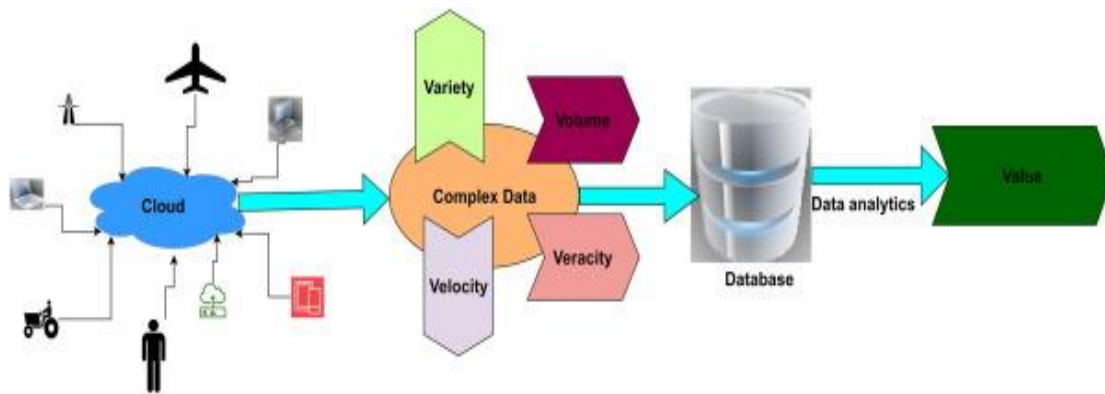
Σύμφωνα με την έρευνα (Abdmeziem et al., 2016), στο IoT, οι ασύρματες τεχνολογίες διαδραματίζουν κεντρικό ρόλο στη συλλογή και την επικοινωνία δεδομένων, ενώ όπως

αναφέρεται από τους (Marjani et al., 2017, Fortino et al., 2020), τα ασύρματα δίκτυα αισθητήρων (WSN) και η αναγνώριση ραδιοσυχνοτήτων (RFID) θεωρούνται ως τα δύο κύρια δομικά στοιχεία των τεχνολογιών ανίχνευσης και επικοινωνίας για το IoT.

Σκοπός τους είναι η συνεχής δημιουργία δεδομένων, η ανάλυσή τους, η οποία περιλαμβάνει μια διαδικασία που αποτελείται από τα στάδια της συλλογής, του μετασχηματισμού, του ‘καθαρισμού’ και της μοντελοποίησης τους με στόχο την ανακάλυψη των απαιτούμενων γνώσεων, όπως αναφέρεται και στην έρευνα (Dai et al., 2019). Τα τελικά αποτελέσματα μετά την ανάλυση των δεδομένων υποστηρίζουν τη λήψη αποφάσεων.

Όπως, περιγράφεται και από τη μελέτη (Rumpf et al., 2010), οι παραδοσιακές μέθοδοι, όπως είναι η χειροκίνητη ανίχνευση ασθενειών των καλλιεργειών και παρασίτων και οι υπολογισμοί που βασίζονται σε στατιστικά στοιχεία για την εκτίμηση της ποσότητας και την πρόβλεψη της παραγωγής και της απώλειας των καλλιεργειών είναι δύσχρηστοι και η πιθανότητα λάθους είναι αρκετά μεγάλη. Ωστόσο, αυτά γινόντουσαν πριν την εμφάνιση της τεχνολογίας των πληροφοριών.

Η ανάλυση δεδομένων και η μηχανική μάθηση μας επιτρέπει να εξάγουμε σημαντικά συμπεράσματα από τα δεδομένα που συλλέγονται από τις καλλιέργειες. Αποκαλύπτει τα κρυμμένα μοτίβα, τις κρυφές σχέσεις μεταξύ των παραμέτρων που επηρεάζουν την παραγωγή, όπως η θερμοκρασία, η αλατότητα του εδάφους και η υγρασία. Οι τεχνικές μηχανικής μάθησης που χρησιμοποιούνται στην πρόβλεψη ασθενειών των καλλιεργειών και παρασίτων στις οποίες αναλύονται τα δεδομένα καιρού είναι το Τεχνητό Νευρωνικό Δίκτυο (ANN), η Παλινδρόμηση SVM και η Υλικοτεχνική Παλινδρόμηση, η τεχνολογία αναγνώρισης χρησιμοποιώντας νευρωνικό δίκτυο, η Διανυσματική Μηχανή Υποστήριξης (SVM), η ασαφής τεχνολογία αναγνώρισης και άλλες, σύμφωνα με τη μελέτη (Singh και Gupta, 2016). Ορισμένες εφαρμογές της ανάλυσης δεδομένων αναφέρονται παρακάτω.



Διάγραμμα 1: *Internet of Things and Data Analytics Relationship.*

Παραδείγματα Εφαρμογών Ανάλυσης Δεδομένων

- 1) Οι Singh και το Gupta (2018) στην ερευνά τους πρότειναν ένα σύστημα ταξινόμησης των ασθενειών των μήλων χρησιμοποιώντας τους αλγόριθμους ταξινόμησης μηχανικής μάθησης. Οι δύο ασθένειες που ταξινομήσαν είναι η ψώρα μήλου και ο κορονοϊός *marsonina* χρησιμοποιώντας τις εικόνες των φύλλων των δέντρων ως δεδομένα. Οι αλγόριθμοι ταξινόμησης, Support Vector Machine (SVM), K κοντινότερος γείτονας (K – nearest Neighbor) και το δέντρο αποφάσεων (Decision Tree) χρησιμοποιήθηκαν για τα ίδια στοιχεία και το Matlab 2016 χρησιμοποιήθηκε για το προτεινόμενο σύστημα προσομοίωσης. Η ανάλυση έδειξε ότι ο αλγόριθμος K nearest neighbour ήταν ο αποτελεσματικότερος, διότι ταξινομήσε τις ασθένειες με ακρίβεια 99,4%.

- 2) Στην μελέτη Geetha (2015) χρησιμοποιήθηκαν τεχνικές τεχνολογίας IoT και ML (Machine Learning) από τους συγγραφείς για την πρόβλεψη της ασθένειας της όψιμης μάστιγας στις πατάτες. Οι περιβαλλοντικές παράμετροι όπως η θερμοκρασία και η υγρασία καταγράφηκαν με τη χρήση αισθητήρων που αναπτύχθηκαν σε ορισμένα χωράφια. Τα δεδομένα που συλλέγονται βοηθούν στην πρόληψη της ασθένειας ανιχνεύοντας το επίπεδο και το κίνδυνο μάστιγας. Τα αποτελέσματα έδειξαν ότι η ανάλυσή τους για την πρόληψη της ασθένειας είχε ακρίβεια 94%.

- 3) Στην επόμενη μελέτη Αγγελοπούλου κ.ά. (2011) οι συγγραφείς χρησιμοποίησαν αλγόριθμους επεξεργασίας εικόνας και ανάλυσης δεδομένων στα πλαίσια ανάπτυξης εφαρμογής για τη γεωργία ακριβείας, ώστε να μπορεί να προβλεφθεί η απόδοση ανά τόπο. Τα συμπεράσματα της μελέτης τους απέδειξαν, ότι υπάρχει υψηλή συσχέτιση μεταξύ της πυκνότητας των λουλουδιών και της απόδοσης των φρούτων προβλέποντας την απόδοση ενός οπωρώνα μήλων με ακρίβεια μεγαλύτερη από 80%.

3.5 Μηχανική Όραση (Computer vision)

Αξίζει να σημειωθεί, ότι οι εφαρμογές επεξεργασίας εικόνας και όρασης υπολογιστών έχουν αυξηθεί, στη γεωργία ακριβείας, λόγω του μειωμένου κόστους του εξοπλισμού, της αυξημένης υπολογιστικής ισχύος και του αυξανόμενου ενδιαφέροντος για μη καταστροφικές μεθόδους αξιολόγησης τροφίμων, σύμφωνα με την έρευνα (Mahajan et al., 2015). Η χρήση αυτών των τεχνικών παρουσιάζει πλεονεκτήματα σε σύγκριση με τις παραδοσιακές μεθόδους που βασίζονται στη χειρωνακτική εργασία, ωστόσο, εξακολουθούν να υπάρχουν ορισμένες προκλήσεις που πρέπει να ξεπεραστούν, όπως διατυπώνεται και από τον (Barbedo, 2016). Η υπολογιστική όραση, η μηχανική μάθηση και η υπολογιστική υψηλών επιδόσεων έχουν αποδειχθεί αρκετά υποσχόμενες και ελπιδοφόρες για την επίλυση διαφορετικών προβλημάτων στη γεωργία.

Η υπολογιστική όραση αξιοποιεί μεθόδους και τεχνικές μέσω των οποίων τα συστήματα τεχνητής όρασης μπορούν να κατασκευαστούν και να χρησιμοποιηθούν με λογικό τρόπο σε πρακτικές εφαρμογές. Αυτός ο τομέας της επιστήμης των υπολογιστών περιλαμβάνει τις απαραίτητες τεχνικές λογισμικού, υλικού και απεικόνισης, σύμφωνα και με τη διατύπωση του (Davies, 2005).

Ένα σύστημα υπολογιστικής όρασης αποτελείται από τα στάδια της απόκτησης και επεξεργασία εικόνας.

- **Απόκτηση εικόνας:** Ξεκινά με τη μεταφορά ηλεκτρονικών σημάτων από έναν αισθητήρα σε μια αριθμητική αναπαράσταση από μια συσκευή όπως η κάμερα (Zareiforush et al., 2015).

- **Επεξεργασία εικόνας:** Περιλαμβάνει εργασίες που εκτελούνται για το χειρισμό ψηφιακών εικόνων με σκοπό, για παράδειγμα, τη βελτίωση της ποιότητάς τους, τη μείωση του θορύβου ή τη διόρθωση προβλημάτων φωτισμού (Hornberg, 2017).


3.6 Μηχανική Μάθηση (Machine Learning)

Η μηχανική μάθηση ασχολείται με μεθόδους και τεχνικές υπολογιστικών εφαρμογών ικανών να τροποποιήσουν ή να προσαρμόσουν τις ενέργειές τους, προκειμένου να γίνουν περισσότερο ακριβείς. Οι αλγόριθμοι μηχανικής μάθησης ταξινομούνται στις ακόλουθες κατηγορίες: supervised learning (επιβλεπόμενη μάθηση), unsupervised learning (μη επιβλεπόμενη μάθηση), reinforcement learning (ενισχυμένη μάθηση), and evolutionary learning(εξελικτική μάθηση).

Η μελέτη του Marsland (2014) διαχωρίζει τα βήματα της μηχανικής μάθησης στα εξής:

- **Προετοιμασία και απόκτηση δεδομένων:** Αρχικό βήμα που συνίσταται στη λήψη των κατάλληλων δεδομένων που περιέχουν χαρακτηριστικά που πρέπει να ληφθούν υπόψη στη μάθηση.
- **Επιλογή χαρακτηριστικών ενδιαφέροντος:** ο προσδιορισμός των σημαντικότερων χαρακτηριστικών του προβλήματος που θα αντιμετωπιστεί.
- **Επιλογή αλγορίθμων:** επιλογή του καταλληλότερου αλγορίθμου για τη επίλυση του προβλήματος που μελετάται.
- **Επιλογή παραμέτρων:** Ορισμένοι αλγόριθμοι πρέπει να συντονιστούν με παραμέτρους που απαιτούν τον καθορισμό του πειραματισμού.
- **Εκπαίδευση:** Λαμβάνοντας υπόψη ένα σύνολο εισόδων, τον αλγόριθμο και τις παραμέτρους, η εκπαίδευση αποτελείται από την κατασκευή του υπολογιστικού μοντέλου που θα χρησιμοποιηθεί στην πρόβλεψη των απαντήσεων σε νέα δεδομένα.

- **Αξιολόγηση:** Το σύστημα πρέπει να αξιολογηθεί για την ακρίβειά του μετά από την εκπαίδευσή του στα δεδομένα.



Εικόνα 6 Grape disease detection system using ML algorithms.

Συμπεράσματα Μελέτης – Προτάσεις για μελλοντική έρευνα

Συμπεραίνεται λοιπόν ότι η γεωργία ακριβείας παρέχει στους αγρότες όλες εκείνες τις τεχνολογίες που χρειάζονται για βελτιστοποιηθούν οι εκροές και οι εισροές μιας καλλιέργειας, σε επίπεδο ακριβείας. Μερικές από τις βασικές τεχνολογίες που συνέβαλλαν στην εξέλιξη της γεωργικής βιομηχανίας αποτελούνται από έξυπνους αισθητήρες, ενεργοποιητές, δορυφορικές εικόνες, γεωργικά ρομπότ και drones. Η χρήση των παραπάνω τεχνολογιών για τη συλλογή δεδομένων ακριβείας σε συνεργασία με τη τεχνητή νοημοσύνη συμβάλλουν στη ταχύτατη επεξεργασία τους και στη λήψη αποφάσεων, χωρίς ανθρώπινη επιμέλεια, σε άμεσο χρόνο και υπό πραγματικές συνθήκες στο πεδίο. Η ύπαρξη της τεχνητής νοημοσύνης, ως εργαλείο αποτελεί το σημαντικότερο κρίκο μιας νοητής αλυσίδας που στόχο έχει την αυτοματοποίηση της ευφυούς συμπεριφοράς ωφελώντας τον πλανήτη και τους ανθρώπους καθημερινά. Χαρακτηριστικό παράδειγμα ανάπτυξης της τεχνητής νοημοσύνης σε καθημερινές εφαρμογές αποτελεί και η γεωργία ακριβείας, όπου συσκευές όπως τα drones και αγροτικές ρομποτικές πλατφόρμες σε συνδυασμό με

τεχνολογίες, όπως τα έξυπνα συστήματα άρδευσης και οι τεχνικές συγκομιδής εκπληρώνουν καθημερινώς πολύπλοκες και απαιτητικές αγροτικές εργασίες σε σύντομο χρονικό διάστημα και με ασφάλεια, περιορίζοντας παράλληλα το ανθρώπινο λάθος αλλά και τη κούραση.

Η τεχνολογία της γεωργίας ακριβείας έχει τη δυνατότητα να αποτελέσει μέρος ενός περιβαλλοντικά και οικονομικά βιώσιμου συστήματος, υπό τη προϋπόθεση ότι περισσότερες πληροφορίες, σχετικά με τις εισροές μιας καλλιέργειας, θα γίνουν διαθέσιμες προς επεξεργασία για την εξαγωγή συμπερασμάτων. Οι έρευνες και οι μελέτες που έχουν πραγματοποιηθεί μέχρι στιγμής αποδεικνύουν ότι η γεωργία ακριβείας μπορεί να συνεισφέρει με πολλούς τρόπους στη μακροπρόθεσμη βιωσιμότητα της παραγωγικής γεωργίας μειώνοντας την περιβαλλοντική επιβάρυνση με την εφαρμογή χημικών ουσιών μόνο όπου και όταν χρειάζονται. Τα οφέλη που δημιουργούνται από τη χρήση εφαρμογών της γεωργίας ακριβείας αφορούν την στοχευμένη χρήση εισροών, όπως χημικά και φυτοφάρμακα, τη μείωση των απωλειών στη παραγωγή λόγω μη επαρκών θρεπτικών ουσιών στο έδαφος, το περιορισμό των ζιζανίων και των εντόμων που προκαλούν καταστροφή της καλλιέργειας.

Την επόμενη δεκαετία, η περαιτέρω εξέλιξη της τεχνολογίας πρόκειται να οδηγήσει στη δημιουργία μιας νέας γενιάς εφαρμογών γεωργίας ακριβείας που θα περιλαμβάνει την αυξημένη χρήση του διαδικτύου, υπερυπολογιστική ανάλυση μεγάλων δεδομένων και παρακολούθηση, βελτιστοποίηση και έλεγχο σε πραγματικό χρόνο (Nie et al., 2014). Την ίδια στιγμή, η γεωργική αεροπορία θα είναι πιο προηγμένη με την ανάπτυξη πιο ικανών γεωργικών αεροπλάνων που μπορούν να φορτώσουν έως και 3.800 λίτρα χημικών ουσιών, από την τρέχουσα χωρητικότητα των 340 έως 3.000 λίτρων (Bretthauer, 2015). Η χρήση drones για εφαρμογές προστασίας των φυτών από πλατφόρμες UAV θα αναπτυχθεί περαιτέρω και θα εφαρμοστεί σε περισσότερες απαιτητικές καλλιέργειες και σε περισσότερες χώρες. Επιπλέον, η ανάπτυξη και η ενσωμάτωση νέων συστημάτων πληροφοριών, τηλεπισκόπησης και επιστήμης δεδομένων για τη βελτίωση των επιδόσεων της γεωργίας ακριβείας θεωρείται δεδομένη το επόμενο χρονικό διάστημα. Για παράδειγμα, μικροί δορυφόροι και CubeSats σε τροχιά μερικών εκατοντάδων χιλιομέτρων θα παρέχουν νέες πλατφόρμες τηλεπισκόπησης που θα μπορούν να διατεθούν για χρήση σε γεωργικά περιβάλλοντα

(Jacobson, 2017). Οι μικροί δορυφόροι θα μπορούν να μεταφέρουν διάφορους αισθητήρες, όπως οπτικούς και αισθητήρες μικροκυμάτων/ραντάρ, για να παρέχουν δεδομένα παρατήρησης πεδίου υψηλής ανάλυσης ανά πάσα στιγμή και υπό όλες τις καιρικές συνθήκες. Στη μελέτη τους οι (Zhang and Kovacs, 2012; etc., 2017) αναφέρουν ότι η τεχνολογία των μη επανδρωμένων ιπτάμενων οχημάτων (UAV) πρόκειται να αναπτυχθεί περαιτέρω για να καλύψει τη ζήτηση που προκύπτει από τις εφαρμογές της γεωργίας ακριβείας παγκοσμίως. Η εξέλιξη των τεχνολογιών που χρησιμοποιούνται για την απεικόνιση και παρατήρηση μιας καλλιέργειας θα συμβάλλει στην αποτελεσματικότερη παρακολούθηση της γεωργίας γενικότερα, καθώς οι εικόνες στην αρχή, την κορύφωση και το τέλος της καλλιεργητικής περιόδου είναι αρκετά σημαντικές για τη λήψη αποφάσεων.

Εκτός από την εξέλιξη των γεωργικών πλατφορμών, των δορυφόρων και των υποσυστημάτων τους, την επόμενη δεκαετία προβλέπεται και η εξέλιξη της επιστήμης και τεχνολογίας διαχείρισης των δεδομένων, έτσι ώστε τα δεδομένα να μπορούν να αναλυθούν άμεσα για τη λήψη αποφάσεων (Bendre et al., 2015; Γούλφερτ κ.ά., 2017). Ωστόσο, όπως αναφέρεται και στην έρευνα των (Sabarina and Priya, 2015) είναι αναγκαίο να πραγματοποιηθεί περισσότερη έρευνα σχετικά με τον τρόπο χειρισμού των μεγάλων δεδομένων και τον τρόπο μετατροπής των μεγάλων δεδομένων σε «μικρά» δεδομένα που αντιμετωπίζουν συγκεκριμένα ζητήματα ή πεδία, για την ακριβή λειτουργία της γεωργίας ακριβείας. Καινοτόμες μέθοδοι, βελτιστοποιημένοι αλγόριθμοι, μαζικά δεδομένα και υπερυπολογιστική ισχύς θα χρησιμοποιούνται όλο και περισσότερο για την υποστήριξη της έξυπνης γεωργίας, ενώ ο γεωργικός αυτοματισμός θα κυριαρχήσει στις γεωργικές εργασίες με προηγμένα υλικά, μηχανική και ηλεκτρονική επιστήμη. Η επομένη δεκαετία θα διακριθεί και από την αυξημένη παραγωγή και χρήση περισσότερων γεωργικών ρομπότ από του αγρότες (SPARC, 2017), καθώς η τεχνητή νοημοσύνη θα αναπτύσσεται διαρκώς ώστε να παραχθούν και να προωθηθούν αυτόνομα και αυτοκινούμενα γεωργικά ρομποτικά συστήματα, για παράδειγμα, γεωργικά οχήματα χωρίς οδηγό και αυτοματοποιημένων συστημάτων άρδευσης (WPG, 2017). Οι δημιουργία προηγμένων αλγορίθμων με τη χρήση βαθιάς μάθησης (deep learning) θα ενισχύσει τις εφαρμογές της τεχνητής νοημοσύνης στη γεωργία ακριβείας (Mohanty et al., 2016; Σλαντόγεβιτς κ.ά., 2016), διότι η επεξεργασία, η ανάλυση, ο έλεγχος και η προσαρμογή των γεωργικών δεδομένων σε

πραγματικό χρόνο θα έχουν σημαντικούς ρόλους για την υποστήριξη αποφάσεων στις γεωργικές εργασίες και τη διαχείριση ακριβείας.

Σύμφωνα με μελέτες η γεωργία ακριβείας μπορεί να έχει θετικό αντίκτυπο στην βελτίωση της ποιότητας του περιβάλλοντος. Η πρόοδος της τεχνολογίας αποτελεί μια μοναδική ευκαιρία για να γίνει κατανοητό στους παραγωγούς πώς η αλλαγή των πρακτικών παραγωγής δεν θα θέσει τις καλλιέργειες σε κίνδυνο και θα αποφέρει θετικά οικονομικά και περιβαλλοντικά οφέλη, προς όλους. Ωστόσο, κρίνεται απαραίτητη η περαιτέρω διεξαγωγή μελετών και πειραμάτων σε περισσότερα και μεγαλύτερα αγροκτήματα. Το κύριο πρόβλημα που προκύπτει συνεχώς και λειτουργεί ως ανασταλτικός παράγοντας της προώθησης της γεωργίας ακριβείας ήταν και είναι η προθυμία των παραγωγών να εφαρμόσουν νέες πρακτικές διαχείρισης στις καλλιέργειές τους χωρίς κάποια διαβεβαίωση ότι τα περιθώρια κέρδους δεν θα τεθούν σε κίνδυνο. Η ελλιπής υποστήριξη και παροχή συμβουλών από τις εταιρείες του κλάδου, τους γεωργικούς συμβούλους, αλλά και από τις δημόσιες αρχές, προς τους καλλιεργητές που είναι πρόθυμοι να υιοθετήσουν περισσότερες εφαρμογές της γεωργίας ακριβείας λειτουργεί ανασταλτικά στη προώθηση αυτών των τεχνολογιών. Για να επιλυθούν αυτές οι προκλήσεις θα πρέπει να δοθεί περισσότερη έμφαση στον άνθρωπο, στους αγρότες, ώστε να ενημερωθούν και να αντιληφθούν ότι η πλήρης υιοθέτηση της γεωργίας ακριβείας θα συμβάλλει στη βελτίωση της ποιότητας ζωής, του περιβάλλοντος, του παραγόμενου προϊόντος, καθώς και του εισοδήματός τους.

Τέλος, η μελλοντική κατεύθυνση της γεωργίας θα εξαρτηθεί από την ικανότητα της ερευνητικής κοινότητας να διεξάγει το είδος μελέτης που χρειάζεται, με εμπιστοσύνη από τις περιβαλλοντικές και παραγωγικές κοινότητες ότι οι αλλαγές θα ωφελήσουν το περιβάλλον και θα αυξήσουν την αποδοτικότητα της γεωργικής παραγωγής.

Ενότητα 2^H

Ο κώδικας που πρόκειται να αναλυθεί, λεπτομερώς, παρακάτω έχει στόχο την υλοποίηση ενός αλγορίθμου μηχανικής μάθησης. Ο αλγόριθμος θα έχει την ικανότητα να εντοπίζει, να αντιλαμβάνεται και να κατηγοριοποιεί σωστά φωτογραφίες από φύλλα 38 διαφορετικών γεωργικών καλλιεργειών τα οποία είτε είναι υγιή, είτε έχουν προσβληθεί από κάποια ασθένεια.

Επιλογή Δεδομένων

Η βάση δεδομένων, με τις φωτογραφίες των φύλλων των φυτών, ανακτήθηκε από την ιστοσελίδα Kaggle.com (<https://www.kaggle.com/>) και συγκεκριμένα στη διεύθυνση (<https://www.kaggle.com/datasets/vipooool/new-plant-diseases-dataset>). Συντάκτης της βάσης δεδομένων, σύμφωνα με την ιστοσελίδα είναι ο SAMIR BHATTARA, ο οποίος τη δημιούργησε 4 χρόνια πριν. Αξίζει να αναφερθεί, ότι πριν την επιλογή του συγκεκριμένου αρχείου δεδομένων προήλθε ύστερα από έρευνα σε αρκετές σχετικές ιστοσελίδες όπου αναλύθηκαν αρκετά dataset, ώστε να βρεθεί το επιθυμητό, το οποίο πληρούσε τα κριτήρια που είχαν τεθεί. Τα κριτήρια που είχαν τεθεί ήταν να είναι εύχρηστο, να έχει σχετικά μεγάλο πλήθος δεδομένων, ώστε τα αποτελέσματα να είναι όσο το δυνατόν πιο ακριβή και να μπορούν να εφαρμοστούν τεχνικές μηχανικής μάθησης σε αυτή τη βάση δεδομένων.

Σχετικά με τη βάση δεδομένων, αξίζει να αναφερθεί ότι περιλαμβάνει 87.000 έγχρωμες φωτογραφίες, υγιών και άρρωστων φύλλων από καλλιέργειες. Το πλήθος των δεδομένων χωρίζεται σε 38 διαφορετικές κατηγορίες. Ολόκληρη η βάση δεδομένων είναι χωρισμένη σε 2 ευρετήρια, με ποσοστό 80/20, αντίστοιχα. Στο 1^ο ευρετήριο περιέχεται το 80% των δεδομένων, που αποτελούν τα δεδομένα εκπαίδευσης και στο 2^ο ευρετήριο περιέχεται το 20% των δεδομένων, που αντιστοιχούν στα δεδομένα επικύρωσης. Τέλος, έχει δημιουργηθεί και ένα 3^ο ευρετήριο με 33 φωτογραφίες για την αξιολόγηση του μοντέλου εκπαίδευσης σε δεδομένα που δεν έχει δει ξανά, ο αλγόριθμος.

Επιλογή Πλατφόρμας

Για την υλοποίηση του κώδικα και τη δημιουργία του αλγορίθμου χρησιμοποιήθηκε το προ-εγκατεστημένο πρόγραμμα Jupyter Notebook (Anacoda). Υπήρχε η δυνατότητα χρήσης αντίστοιχων προγραμμάτων, όπως το Google Colab και το αντίστοιχο στο Kaggle.

Τα πλεονέκτημά τους είναι ότι λειτουργούν στο Drive, επομένως είναι εύκολα προσβάσιμα από οποιοδήποτε υπολογιστή και δεν απαιτείται η χρήση ιδιωτικών υπολογιστικών πόρων, διότι καταναλώνονται δημόσιοι πόροι της Google και του Kaggle, αντίστοιχα. Ωστόσο, όπως αναφέρθηκε και νωρίτερα, χρησιμοποιήθηκε το πρόγραμμα Jupyter Notebook (Anacoda), διότι είχε χρησιμοποιηθεί σε μαθήματα του προγράμματος σπουδών, όπως το μάθημα Σχεδίαση Αυτοκινούμενων Οχημάτων και το μάθημα Επιχειρηματική Ευφυΐα & Ανάλυση Μεγάλων Δεδομένων, οπότε υπήρχε μια εξοικείωση με το πρόγραμμα αυτό.

Εισαγωγή Βιβλιοθηκών

Το αρχικό βήμα για την δημιουργία του κώδικα είναι η εισαγωγή των απαραίτητων «βιβλιοθηκών», που θα επιτρέπουν τη χρήση εξιδεικευμένων εντολών. Η βιβλιοθήκη "pandas" παρέχει δυνατότητες ανάλυσης δεδομένων, η "os" δυνατότητες δημιουργίας και μεταφοράς ευρετηρίου (φακέλου), η βιβλιοθήκη "numpy" προσδίδει γενικές ικανότητες επεξεργασίας πίνακα και η "matplotlib.pyplot" παρέχει την ικανότητα δημιουργίας διαγραμμάτων, πινάκων και οποιοδήποτε σχεδιαγράμματος γενικότερα.

Επιπλέον, εισήχθη η πλατφόρμα "tensorflow" που βοηθά στην εφαρμογή βέλτιστων πρακτικών για την αυτοματοποίηση δεδομένων, την παρακολούθηση μοντέλων, την παρακολούθηση απόδοσης και την επανεκπαίδευση μοντέλων. η "keras" που είναι υψηλού επιπέδου και χρησιμοποιείται για την ανάπτυξη βαθιάς μάθησης για χρήση σε τεχνητά νευρωνικά δίκτυα. Στη συνέχεια, εισάγονται από τη βιβλιοθήκη keras της πλατφόρμας tensorflow (tensorflow.keras) οι υπό βιβλιοθήκες Model, Sequential, layers, optimizers. Η Model προσφέρει έναν απλό, φιλικό προς τον χρήστη τρόπο για να οριστεί ένα νευρωνικό δίκτυο, το οποίο στη συνέχεια θα κατασκευαστεί με τη βοήθεια της πλατφόρμας TensorFlow. Η βασική λειτουργία του Sequential API είναι

η διάταξη των επιπέδων Keras με διαδοχική σειρά. Το μεγαλύτερο μέρος ενός Artificial Neural Network (ANN) έχει επίσης επίπεδα σε διαδοχική σειρά και τα δεδομένα ρέουν από το ένα επίπεδο στο άλλο με τη συγκεκριμένη ακολουθία έως ότου τα δεδομένα φτάσουν τελικά στο επίπεδο εξόδου. Τα επίπεδα (layers) είναι τα βασικά δομικά στοιχεία των νευρωνικών δικτύων. Ένα επίπεδο αποτελείται από μια συνάρτηση υπολογισμού νευρώνα με νευρώνα, από την οποία προκύπτουν τα βάρη του επιπέδου. Οι βελτιστοποιητές (optimizers) είναι αλγόριθμοι ή μέθοδοι που χρησιμοποιούνται για την αλλαγή των χαρακτηριστικών ενός νευρωνικού δικτύου. Τα χαρακτηριστικά που μπορούν να διαφοροποιηθούν είναι τα βάρη και ο ρυθμός εκμάθησης, προκειμένου να μειωθούν οι απώλειες.

Επόμενο βήμα είναι η εισαγωγή του Adam optimizer από την βιβλιοθήκη optimizers. Ο Adam είναι ένας αλγόριθμος βελτιστοποίησης αντικατάστασης για στοχαστική κλίση κατάβασης για εκπαίδευση μοντέλων βαθιάς μάθησης. Ο Adam συνδυάζει τις καλύτερες ιδιότητες των αλγορίθμων AdaGrad και RMSProp για να παρέχει έναν αλγόριθμο βελτιστοποίησης που μπορεί να χειριστεί αραιές κλίσεις σε θορυβώδη προβλήματα.

Από τη βιβλιοθήκη επίπεδα (layers) εισάγονται τα Conv2D, Dropout, Flatten, Dense, MaxPooling2D, BatchNormalization.

- Το Dense layer είναι απλό στρώμα νευρώνων στο οποίο κάθε νευρώνας λαμβάνει είσοδο από όλους τους νευρώνες του προηγούμενου στρώματος, που ονομάζεται έτσι πυκνός (dense). Το Dense Layer χρησιμοποιείται για την ταξινόμηση της εικόνας με βάση την έξοδο από συνελκτικά επίπεδα. Ένα στρώμα περιέχει πολλαπλούς αριθμούς τέτοιων νευρώνων.
- Το επίπεδο Dropout ακυρώνει τη συμβολή ορισμένων νευρώνων στο επόμενο στρώμα και αφήνει αμετάβλητους όλους τους άλλους.
- Το Flatten επίπεδο χρησιμοποιείται για να μετατρέψει όλους τους δισδιάστατους πίνακες από ομαδοποιημένους χάρτες χαρακτηριστικών σε ένα ενιαίο μεγάλο συνεχές γραμμικό διάνυσμα. Αυτό στη συνέχεια τροφοδοτείται ως είσοδος στο πλήρως συνδεδεμένο στρώμα για την ταξινόμηση μιας εικόνας.
- Το επίπεδο Conv2D δημιουργεί έναν πυρήνα συνέλιξης που περιπλέκεται με την είσοδο του επιπέδου για να παράγει έναν νευρώνα εξόδου.

- Το MaxPooling 2D είναι μια λειτουργία συγκέντρωσης που επιλέγει το μέγιστο στοιχείο από την περιοχή του χάρτη χαρακτηριστικών (πχ. εικόνας) που καλύπτεται από το φίλτρο. Έτσι, η έξοδος μετά το επίπεδο max-pooling θα είναι ένας χάρτης χαρακτηριστικών που περιέχει τα πιο σημαντικά χαρακτηριστικά του προηγούμενου χάρτη χαρακτηριστικών.
- Το BatchNormalization επίπεδο είναι μια τεχνική για την εκπαίδευση πολύ βαθιών νευρωνικών δικτύων που κανονικοποιεί τις συνεισφορές σε ένα επίπεδο για κάθε μίνι παρτίδα. Αυτό έχει ως αποτέλεσμα τη διευθέτηση της μαθησιακής διαδικασίας και τη δραστική μείωση του αριθμού των εποχών εκπαίδευσης που απαιτούνται για την εκπαίδευση των βαθιών νευρωνικών δικτύων.

Στη συνέχεια, εισάγουμε τη βιβλιοθήκη image από τη κεντρική βιβλιοθήκη keras.preprocessing. Με αυτή την βιβλιοθήκη δίνεται η δυνατότητα να χρησιμοποιηθούν εντολές επεξεργασίας εικόνας.

Η ImageDataGenerator αποτελεί υπό βιβλιοθήκη της image και επιτρέπει την επεξεργασία εικόνων σε πραγματικό χρόνο, ενώ το μοντέλο εξακολουθεί να εκπαιδεύεται. Μπορούν να εφαρμοστούν τυχαίοι μετασχηματισμοί σε κάθε εικόνα εκπαίδευσης, καθώς αυτές μεταβιβάζονται στο μοντέλο. Αυτό κάνει το μοντέλο ανθεκτικό και εξοικονομεί χώρο από την γενική μνήμη.

Η πλατφόρμα Keras παρέχει τη συνάρτηση load_img() που χρησιμοποιείται για τη φόρτωση μιας εικόνας από αρχείο ως αντικείμενο εικόνας.

Τέλος, χρησιμοποιείται αυτή η εντολή (from tensorflow.keras.callbacks import) για να εισαχθούν τα EarlyStopping ,ReduceLROnPlateau ,ModelCheckpoint.

- Το EarlyStopping παύει την εκπαίδευση του μοντέλου όταν μια παρακολουθούμενη μέτρηση σταματήσει να βελτιώνεται. Υποθέτοντας ότι ο στόχος μιας εκπαίδευσης είναι η ελαχιστοποίηση της απώλειας, με αυτή την εντολή η μέτρηση που θα παρακολουθείται θα είναι "απώλεια" και η εκπαίδευση θα σταματήσει όταν η " απώλεια " θα είναι "ελάχιστη".

- `ReduceLROnPlateau` μειώνει τον ρυθμό εκμάθησης του μοντέλου όταν μια μέτρηση έχει σταματήσει να βελτιώνεται. Τα μοντέλα συχνά επωφελούνται από τη μείωση του ποσοστού μάθησης, όταν η μάθηση παραμένει στάσιμη. Με αυτή τη λειτουργία παρακολουθείται μια ποσότητα και εάν δεν παρατηρηθεί βελτίωση για έναν αριθμό εκπαιδεύσεων «υπομονής», ο ρυθμός εκμάθησης μειώνεται.
- Η εντολή `ModelCheckpoint` αξιοποιείται για την αποθήκευση του μοντέλου Keras ή των βαρών μοντέλου σε κάποια συχνότητα, έτσι ώστε το μοντέλο ή τα βάρη να μπορούν να φορτωθούν αργότερα για να συνεχιστεί η εκπαίδευση από την κατάσταση που έχει αποθηκευτεί.

Εισαγωγή Δεδομένων

Μετά την εισαγωγή των απαραίτητων βιβλιοθηκών, εισήχθησαν τα δεδομένα που θα χρησιμοποιηθούν. Τα δεδομένα, αρχικά είχαν αποθηκευτεί στη μνήμη προσωπικού υπολογιστή και στη συνέχεια εισήχθησαν με τη μορφή καταλόγου (`directory`). Συγκεκριμένα εισήχθησαν 3 διαφορετικοί κατάλογοι, ο κατάλογος με τα δεδομένα εκπαίδευσης (`train_dir`), ο κατάλογος με τα δεδομένα επικύρωσης (`val_dir`) και τέλος ο κατάλογος με τα δεδομένα ελέγχου (`test_dir`). Επιπλέον, με την εντολή (`os.listdir(train_dir)`) όλα τα δεδομένα και οι λίστες που βρίσκονται στο κατάλογο με τα δεδομένα εκπαίδευσης μεταφέρονται σε μια μεταβλητή με το όνομα (`diseases`). Σκοπός είναι η καλύτερη και ευκολότερη χρήση των δεδομένων.

Ανάλυση Δεδομένων

Κατά την ανάλυση των δεδομένων δίνεται η δυνατότητα να εξαχθούν χρήσιμα στοιχεία σχετικά με τα δεδομένα και την ποιότητά τους. Συγκεκριμένα, εξάγονται πληροφορίες σχετικά με τις ονομασίες των λιστών, κατηγοριών που υπάρχουν στα δεδομένα εκπαίδευσης. Με τη κατάλληλη εντολή εμφανίζεται ο συνολικός αριθμός των κατηγοριών που περιλαμβάνονται στο αρχείο δεδομένων εκπαίδευσης, ενώ με διαφορετική εντολή αποτυπώνεται το συνολικό πλήθος των φυτών. Να αναφερθεί ότι κάθε είδος, κατηγορία φυτού (μήλο, φράουλα, τομάτα) έχει παραπάνω από 3 κατηγορίες που ανήκουν στην ίδια κατηγορία ('Apple___Apple_scab',

'Apple__Black_rot', 'Apple__Cedar_apple_rust', 'Apple__healthy'). Να προστεθεί ότι με σχετική εντολή εκτυπώνονται, εμφανίζονται ονομαστικά οι κατηγορίες των φυτών που υπάρχουν στη βάση δεδομένων, χωρίς τις υπό κατηγορίες των ασθενειών. Με τη δημιουργία μεταβλητής και τη χρήση συνθήκης (for) εμφανίζονται με τη μορφή πίνακα οι 38 κατηγορίες δεδομένων και ο αριθμός φωτογραφιών που περιέχουν κάθε μια από αυτές.

Out[11]:

	no. of images
Apple__Apple_scab	2016
Apple__Black_rot	1987
Apple__Cedar_apple_rust	1760
Apple__healthy	2008
Blueberry__healthy	1816
Cherry_(including_sour)__healthy	1826
Cherry_(including_sour)__Powdery_mildew	1683
Corn_(maize)__Cercospora_leaf_spot Gray_leaf_spot	1642
Corn_(maize)__Common_rust_	1907
Corn_(maize)__healthy	1859
Corn_(maize)__Northern_Leaf_Blight	1908
Grape__Black_rot	1888
Grape__Esca_(Black_Measles)	1920
Grape__healthy	1692
Grape__Leaf_blight_(Isariopsis_Leaf_Spot)	1722
Orange__Haunglongbing_(Citrus_greening)	2010
Peach__Bacterial_spot	1838
Peach__healthy	1728
Pepper,_bell__Bacterial_spot	1913
Pepper,_bell__healthy	1988
Potato__Early_blight	1939
Potato__healthy	1824

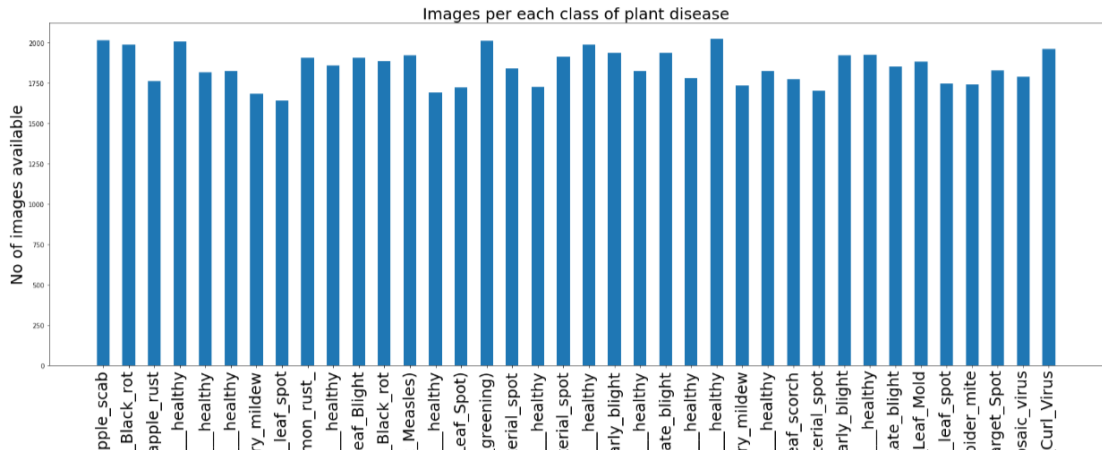
Orange__Haunglongbing_(Citrus_greening)	2010
Peach__Bacterial_spot	1838
Peach__healthy	1728
Pepper,_bell__Bacterial_spot	1913
Pepper,_bell__healthy	1988
Potato__Early_blight	1939
Potato__healthy	1824
Potato__Late_blight	1939
Raspberry__healthy	1781
Soybean__healthy	2022
Squash__Powdery_mildew	1736
Strawberry__healthy	1824
Strawberry__Leaf_scorch	1774
Tomato__Bacterial_spot	1702
Tomato__Early_blight	1920
Tomato__healthy	1926
Tomato__Late_blight	1851
Tomato__Leaf_Mold	1882
Tomato__Septoria_leaf_spot	1745
Tomato__Spider_mites Two-spotted_spider_mite	1741
Tomato__Target_Spot	1827
Tomato__Tomato_mosaic_virus	1790
Tomato__Tomato_Yellow_Leaf_Curl_Virus	1961

Πίνακας 1 Οι κατηγορίες δεδομένων και ο αριθμός φωτογραφιών που αντιστοιχούν σε κάθε μια.

Οι παραπάνω κατηγορίες και το πλήθος δεδομένων κάθε μιας αποτυπώνεται και σε γράφημα με διαφορετικές εντολές κώδικα.

```
In [17]: # plotting number of images available for each disease
index = [n for n in range(38)]
plt.figure(figsize=(30, 10))
plt.bar(index, [n for n in nums.values()], width=0.5)
plt.xlabel('Plants/Diseases', fontsize=25)
plt.ylabel('No of images available', fontsize=25)
plt.xticks(index, diseases, fontsize=25, rotation=90)
plt.title('Images per each class of plant disease', fontsize=25)
```

Out[17]: Text(0.5, 1.0, 'Images per each class of plant disease')



Διάγραμμα 2 Οι κατηγορίες δεδομένων σε στήλες και ο αριθμός φωτογραφιών που περιέχουν σε κάθε μια.

Μετά την ανάλυση των δεδομένων ρυθμίζονται ορισμένες χρήσιμες παράμετροι, όπως το μέγεθος (μήκος - πλάτος) των εικόνων (`IMAGE_SHAPE = 224`) και το `BATCH_SIZE = 32` το οποίο συμβολίζει τον ρυθμό των εικόνων/δειγμάτων που υποβάλλονται για επεξεργασία κάθε φορά. Αξίζει να αναφερθεί ότι, ο αριθμός του `BATCH_SIZE` δεν μπορεί να είναι κάτω από 1 και πάνω από το συνολικό πλήθος των δεδομένων/φωτογραφιών. Ο καθορισμός των παραμέτρων αυτών γίνεται δημιουργώντας τις παραπάνω μεταβλητές και αναθέτοντας την επιθυμητή τιμή.

Στη συνέχεια δημιουργούνται μεταβλητές στις οποίες θα εισαχθούν εντολές που θα αφορούν την τροποποίηση, παραμόρφωση των εικόνων. Επομένως, για να μην γράφονται συνέχεια οι ίδιες εντολές τροποποίησης εικόνων, εισάγονται σε μεταβλητές, ώστε η χρήση τους να είναι άμεση, ευέλικτη και εύχρηστη. Η εισαγωγή των εντολών παραμόρφωσης εικόνας εφαρμόζεται με τη χρήση της βιβλιοθήκης `ImageDataGenerator` που εισήχθη στην αρχή. Σημαντικό είναι να αναφερθεί ότι δημιουργούνται τόσες μεταβλητές, όσες και τα ευρετήρια δεδομένων που έχουν εισαχθεί νωρίτερα (`train_dir`, `val_dir`, `test_dir`) και κάθε μεταβλητή δέχεται διαφορετικές εντολές παραμόρφωσης εικόνας.

Ειδικότερα, η μεταβλητή που αφορά το (`train_dir`) σε αυτή τη περίπτωση θα δεχτεί εντολές παραμόρφωσης εικόνας, όπως η κανονικοποίηση της εισόδου (`rescale = 1./255`) κατά την οποία τα pixel μιας εικόνας/δείγμα μετατρέπονται από την περιοχή $[0,255]$ σε εύρος $[0,1]$. Η αλλαγή της κλιμάκωσης κάθε εικόνας στο ίδιο εύρος συμβάλλει στην ομοιομορφία των εικόνων. Οι εντολές (`shear_range = 0,2`) και (`zoom_range = 0.2`) σημαίνουν ότι η εικόνα θα κοπεί κατά 20% με τυχαίο τρόπο και αντίστοιχα ότι θα μεγεθυνθεί ή σμικρυνθεί κατά 20% με τυχαίο τρόπο πάλι. Με την εντολή (`fill_mode = nearest`) η άδεια περιοχή μιας εικόνας αντικαθίσταται με τα κοντινότερα pixel. Η τυχαία μεταβολή της εικόνας κατά 0,2 είτε προς τα αριστερά ή δεξιά, είτε προς τα πάνω ή κάτω επιτυγχάνεται με τη χρήση των εντολών (`width_shift_range = 0.2`) και (`height_shift_range = 0.2`). Τέλος, αξιοποιήθηκαν και οι εντολές (`featurewise_center = True`) και (`featurewise_std_normalization = True`) οι οποίες αφορούν τον ορισμό μέσης τιμής εισόδου των δεδομένων από πλευράς χαρακτηριστικών και τη διαίρεση των εισόδων κατά std του συνόλου των δεδομένων. Στις μεταβλητές που χρησιμοποιήθηκαν για το (`val_dir`) και το (`test_dir`) εισήχθησαν μόνο εντολές κανονικοποίησης των εικόνων στο ίδιο εύρος με πριν.

Ο σκοπός που εφαρμόζονται τα παραπάνω φίλτρα, εντολές στα δεδομένα εκπαίδευσης είναι για τη δημιουργία, επιπλέον, θορύβου, πληροφορίας, ώστε να γίνει ο αλγόριθμος καλύτερος και αποτελεσματικότερος και να αποφευχθεί η υπερεκπαίδευσή του.

Το επόμενο βήμα είναι η δημιουργία 3 ακόμη διαφορετικών μεταβλητών. Συγκεκριμένα δημιουργούνται οι μεταβλητές (`train_data_gen`, `val_data_gen`, `test_data_gen`) στις οποίες εισέρχονται οι μεταβλητές που δημιουργήθηκαν νωρίτερα (`image_gen_train`, `image_gen_val`, `image_gen_test`). Στις νέες μεταβλητές καθορίζονται παράμετροι που αφορούν τις μεταβλητές των εικόνων που έχουν παραμορφωθεί νωρίτερα. Οι παράμετροι αυτοί αφορούν, το `batch_size = 32` το οποίο συμβολίζει τον ρυθμό των εικόνων/δειγμάτων που υποβάλλονται για επεξεργασία κάθε φορά, το κατάλογο (`directory`) από το οποίο θα χρησιμοποιηθούν δεδομένα (`train_dir`, `val_dir`, `test_dir`). Επιπλέον, καθορίζονται παράμετροι που αφορούν το σχήμα των εικόνων, δηλαδή το πλάτος και το ύψος τους, τον τρόπο απόδοσης των τιμών (`class_mode`) με προκαθορισμένη τιμή την επιλογή (`categorical`), ωστόσο σε αυτή την περίπτωση χρησιμοποιήθηκε η επιλογή (`sparse`), διότι τα δεδομένα είναι σε μονοδιάστατο πίνακα. Μια επιπλέον παράμετρος που ρυθμίζεται μόνο στα δεδομένα

εκπαίδευσης έχει να κάνει με το ανακάτεμα (shuffle) των δεδομένων, η οποία έχει προκαθορισμένη τιμή (True).

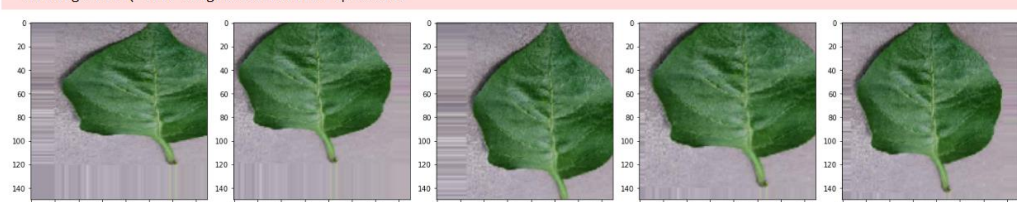
Στη συνέχεια δημιουργούνται 2 λίστες στις οποίες εμφανίζονται όλες οι κατηγορίες (38) των δεδομένων και θα χρησιμοποιηθούν σε επόμενο στάδιο.

Παρακάτω εμφανίζεται η συνθήκη που χρησιμοποιήθηκε για τη δημιουργία ενός πίνακα και την εμφάνιση μιας τυχαίας επεξεργασμένης εικόνας στην οποία εφαρμόστηκαν τα φίλτρα που επιλέχθηκαν, νωρίτερα. Επομένως τα δεδομένα που θα χρειαστεί να μάθει, για να εκπαιδευτεί ο αλγόριθμος θα έχουν τις διαμορφώσεις και θα είναι με τυχαία σειρά.

```
In [14]: # Δημιουργία συνθήκης για να εμφανιστούν οι επεξεργασμένες εικόνες
def plotImages(images_arr):
    fig, axes = plt.subplots(1, 5, figsize=(20,20))
    axes = axes.flatten()
    for img, ax in zip( images_arr, axes):
        ax.imshow(img)
    plt.tight_layout()
    plt.show()

In [15]: # Εμφάνιση 1 τυχαίας, επεξεργασμένης φωτογραφίας, με την επίδραση του κάθε φίλτρου
augmented_images = [train_data_gen[0][0][0] for i in range(5)]
plotImages(augmented_images)

C:\Anacoda\lib\site-packages\keras_preprocessing\image\image_data_generator.py:720: UserWarning: This ImageDataGenerator specifies 'featurewise_center', but it hasn't been fit on any training data. Fit it first by calling '.fit(numpy_data)'.
warnings.warn('This ImageDataGenerator specifies '
C:\Anacoda\lib\site-packages\keras_preprocessing\image\image_data_generator.py:728: UserWarning: This ImageDataGenerator specifies 'featurewise_std_normalization', but it hasn't been fit on any training data. Fit it first by calling '.fit(numpy_data)'.
warnings.warn('This ImageDataGenerator specifies '


```

Εικόνα 8 Οι εντολές κώδικα και η τυχαία εικόνα επεξεργασμένη με τα φίλτρα

Πριν την έναρξη της εκπαίδευσης χρειάζεται να ρυθμιστούν εντολές επανάκλησης για τη βελτιστοποίηση της εκπαίδευσης των δικτύων. Οι εντολές επανάκλησης που χρησιμοποιήθηκαν είναι οι Early_Stopping, ReduceLROnPlateau και ModelCheckpoint. Η 1^η εντολή επανάκλησης σταματάει την εκπαίδευση του αλγόριθμου, όταν η παρακολουθούμενη μέτρηση σταματάει να βελτιώνεται, μετά από κάποιους κύκλους εκπαίδευσης (patience = 5). Η 2^η εντολή μειώνει τον ρυθμό εκμάθησης όταν η παρακολουθούμενη μέτρηση σταματάει να βελτιώνεται για κάποιο

αριθμό εποχών εκπαίδευσης. Η τελευταία εντολή επανάκλησης αξιοποιείται για την αποθήκευση του μοντέλου, κάθε φορά που αυτό βελτιώνεται, ώστε να μπορεί να χρησιμοποιηθεί αργότερα, για να συνεχίσει η εκπαίδευση από το σημείο που σταμάτησε.

Στάδιο Εκπαίδευσης

ALEXNET

Alexnet ονομάζεται ένα προ εκπαιδευμένο μοντέλο που χρησιμοποιείται στο τομέα της μηχανικής όρασης. Έχει 8 επίπεδα με μαθητευόμενες παραμέτρους, από τα οποία τα 5 συνδυάζονται με την τεχνική max pooling, ακολουθούμενα από 3 πλήρως συνδεδεμένα επίπεδα. Σε όλα τα επίπεδα χρησιμοποιείται η συνάρτηση ενεργοποίησης RELU (τμηματικά γραμμική συνάρτηση που εξάγει απευθείας την είσοδο αν είναι θετική, διαφορετικά βγάζει μηδέν), ενώ επιταχύνει τη διαδικασία εκπαίδευσης κατά 6 φορές. Ωστόσο, στην προκειμένη περίπτωση το τελευταίο επίπεδο, εξόδου έχει διαφοροποιηθεί και χρησιμοποιείται η συνάρτηση ενεργοποίησης SOFTMAX (μαθηματική συνάρτηση που μετατρέπει ένα διάνυσμα αριθμών σε ένα διάνυσμα πιθανοτήτων, όπου οι πιθανότητες κάθε τιμής είναι ανάλογες με τη σχετική κλίμακα κάθε τιμής στο διάνυσμα). Επιπλέον, το μοντέλο έχει εκπαιδευτεί στη βάση δεδομένων Imagenet η οποία αποτελείται από 1000 διαφορετικές κατηγορίες και σχεδόν 14 εκατομμύρια εικόνες.

Αρχιτεκτονική Μοντέλου

Αξίζει να σημειωθεί ότι, καθώς το Alexnet είναι μια βαθιά αρχιτεκτονική (deep learning), χρησιμοποιείται η τεχνική padding, ώστε να αποτραπεί η απότομη μείωση του μεγέθους των χαρακτηριστικών των εικόνων. Το μοντέλο Alexnet έχει ως είσοδο εικόνες μεγέθους 227X227X3. Όπου, οι 2 πρώτες τιμές δηλώνουν το μέγεθος (πλάτος, ύψος) της εισερχόμενης εικόνας και η τελευταία τιμή (3) δηλώνει ότι η εικόνα είναι έγχρωμη. Ωστόσο, στη περίπτωση αυτή οι εισερχόμενες εικόνες είχαν διαστάσεις 224X224X3.

Στον παρακάτω πίνακα απεικονίζεται η τεχνική που αξιοποιήθηκε για την υλοποίηση του μοντέλου Alexnet κατά την εκπαίδευσή του στη βάση δεδομένων Imagenet.

Layer	# filters / neurons	Filter size	Stride	Padding	Size of feature map	Activation function
Input	-	-	-	-	227 x 227 x 3	-
Conv 1	96	11 x 11	4	-	55 x 55 x 96	ReLU
Max Pool 1	-	3 x 3	2	-	27 x 27 x 96	-
Conv 2	256	5 x 5	1	2	27 x 27 x 256	ReLU
Max Pool 2	-	3 x 3	2	-	13 x 13 x 256	-
Conv 3	384	3 x 3	1	1	13 x 13 x 384	ReLU
Conv 4	384	3 x 3	1	1	13 x 13 x 384	ReLU
Conv 5	256	3 x 3	1	1	13 x 13 x 256	ReLU
Max Pool 3	-	3 x 3	2	-	6 x 6 x 256	-
Dropout 1	rate = 0.5	-	-	-	6 x 6 x 256	-

Πίνακας 2 Αρχιτεκτονική μοντέλου Alexnet

Η τεχνική που ακολουθήθηκε για την υλοποίηση και εκπαίδευση του μοντέλου Alexnet στα δεδομένα που του διατέθηκαν, αναλύεται παρακάτω. Επισημαίνεται, ότι σε μεγάλο βαθμό η τεχνική, που χρησιμοποιήθηκε, είναι κοινή με αυτή που περιγράφεται στον παραπάνω πίνακα.

Το 1^ο επίπεδο συνέλιξης αποτελείται από 96 φίλτρα, νευρώνες, τα οποία έχουν μέγεθος 11X11 και διασκελισμό (stride) 4. Η συνάρτηση ενεργοποίησης που χρησιμοποιείται είναι η RELU και η έξοδος που παράγεται από το 1^ο επίπεδο είναι μια εικόνα με μέγεθος χαρακτηριστικών 55X55X96. Στη συνέχεια ακολουθεί το επίπεδο Maxpooling (μέγιστης συγκέντρωσης), το οποίο έχει μέγεθος 3X3 και διασκελισμό (stride) 2 και εφαρμόζεται στην έξοδο του 1^{ου} επιπέδου συνέλιξης. Ο συνδυασμός αυτών των 2 επιπέδων δημιουργεί έναν νέο χάρτη χαρακτηριστικών με μέγεθος 27X27X96 ως έξοδο.

Στο 2^ο επίπεδο συνέλιξης έχουμε αύξηση των φίλτρων από 96 σε 256 και μείωση του μεγέθους του από 11X11 σε 5X5 και διασκελισμό (stride) 1 (στοιχείο συνελκτικών νευρωνικών δικτύων ή νευρωνικών δικτύων που έχουν συντονιστεί για τη συμπίεση

εικόνων και δεδομένων βίντεο, παράμετρος του φίλτρου του νευρωνικού δικτύου που τροποποιεί το μέγεθος της κίνησης πάνω από την εικόνα ή το βίντεο). Η συνάρτηση ενεργοποίησης είναι η RELU και η έξοδος που παράγεται έχει μέγεθος 27X27X256. Με την εφαρμογή του επιπέδου Maxpooling μεγέθους 3X3 και διασκελισμό (stride) 2, δημιουργείται ως αποτέλεσμα χάρτης χαρακτηριστικών με μέγεθος 13X13X256.

Στο 3^ο επίπεδο συνέλιξης υπάρχουν 384 νευρώνες/φίλτρα, μεγέθους 3X3, διασκελισμό (stride) 1, με συνάρτηση ενεργοποίησης RELU και τελική έξοδο χάρτη χαρακτηριστικών 13X13X384. Στο 4^ο επίπεδο συνέλιξης ισχύουν οι ίδιες τιμές, επομένως, η έξοδος παραμένει σταθερή.

Στο τελικό επίπεδο συνέλιξης δημιουργούνται 256 νευρώνες/ φίλτρα με μέγεθος 3X3, διασκελισμό (stride), με σταθερή την συνάρτηση ενεργοποίησης και τελικό παραγόμενο χάρτη χαρακτηριστικών με διαστάσεις 13X13X256.

Παρατηρώντας την αρχιτεκτονική του μοντέλου, έως τώρα, ο αριθμός των φίλτρων αυξάνεται, καθώς πηγαίνουμε βαθύτερα, προσθέτουμε επίπεδα συνέλιξης. Ως εκ τούτου, εξάγονται περισσότερα λεπτομερή χαρακτηριστικά καθώς η αρχιτεκτονική αναπτύσσεται βαθύτερα. Επίσης, το μέγεθος του φίλτρου μειώνεται, πράγμα που σημαίνει ότι το αρχικό φίλτρο ήταν μεγαλύτερο και καθώς προχωράμε το μέγεθος του φίλτρου μειώνεται, με αποτέλεσμα τη μείωση του σχήματος του χάρτη χαρακτηριστικών και την άντληση περισσότερων λεπτομερών χαρακτηριστικών.


Στη συνέχεια, εφαρμόζεται το 3^ο στρώμα max pooling (μέγιστης συγκέντρωσης) μεγέθους 3X3 και το βήμα (padding) 2. Με αποτέλεσμα τη δημιουργία χάρτη χαρακτηριστικών του σχήματος, διαστάσεων 6X6X256.

Στη συνέχεια, έχουμε 2 πλήρως συνδεδεμένα επίπεδα, τα οποία έχουν 4096 νευρώνες το καθένα και λειτουργία ενεργοποίησης relu.

Τέλος, έχουμε το τελευταίο πλήρως συνδεδεμένο επίπεδο ή επίπεδο εξόδου με 38 νευρώνες, διότι τόσες είναι οι κατηγορίες δεδομένων που υπάρχουν στη βάση δεδομένων. Η λειτουργία ενεργοποίησης που χρησιμοποιείται σε αυτό το επίπεδο είναι η Softmax.

Αυτή είναι η αρχιτεκτονική του μοντέλου Alexnet και έχει συνολικά 21,7 εκατομμύρια μαθησιακές παραμέτρους.

Παρακάτω αποτυπώνεται γραφικά ο τρόπος που συνδέονται τα επίπεδα συνέλιξης μεταξύ τους.



Διάγραμμα 3 Σύνδεση επιπέδων συνέλιξης Alexnet

Μετά την επιθυμητή διαμόρφωση του μοντέλου Alexnet, χρησιμοποιείται κατάλληλος κώδικας, ώστε να συνταχθεί το διαμορφωμένο μοντέλο. Για να γίνει αυτό χρησιμοποιείται η συνάρτηση (compile) η οποία έχει ορισμένες παραμέτρους:

- **Model_optimizer:** Οι βελτιστοποιητές μοντέλου είναι μαθηματικές συναρτήσεις που εξαρτώνται από τις εκπαιδευόμενες παραμέτρους του μοντέλου, π.χ. Weights & Biases. Οι βελτιστοποιητές βοηθούν στην αλλαγή των βαρών και του ρυθμό εκμάθησης του νευρωνικού δικτύου, ώστε να μειωθούν οι απώλειες. Στην προκειμένη περίπτωση αξιοποιείται ο βελτιστοποιητής Adam που αποτελεί μια μέθοδος στοχαστικής κλίσης καθόδου που βασίζεται στην προσαρμοστική εκτίμηση ροπών πρώτης και δεύτερης τάξης. Σύμφωνα με τους Kingma et al., 2014, η μέθοδος είναι «υπολογιστικά αποδοτική, έχει μικρή απαίτηση μνήμης, αμετάβλητη στη διαγώνια επανακλιμάκωση των κλίσεων και είναι κατάλληλη για προβλήματα που είναι μεγάλα από άποψη δεδομένων/παραμέτρων».
- **Model_loss:** παρακολουθεί τα λάθη που πραγματοποιούνται κατά την εκπαίδευση. Εδώ, χρησιμοποιήθηκε η επιλογή SparseCategoricalCrossentropy

,η οποία υπολογίζει την απώλεια διασταυρούμενης εντροπίας μεταξύ των ετικετών και των προβλέψεων. Η συνάρτηση απώλειας διασταυρούμενης εντροπίας αξιοποιείται, όταν υπάρχουν δύο ή περισσότερες κατηγορίες ετικετών, (εδώ έχουμε 38 ετικέτες/ κατηγορίες).

- `Model_metrics`: ελέγχει την εκτέλεση του νευρωνικού δικτύου και υπολογίζει το βαθμό ακρίβειας. Σε αυτό το μοντέλο εκπαίδευσης ζητείται ο υπολογισμός του βαθμού ακριβείας, ο οποίος προκύπτει από τα δεδομένα εκπαίδευσης και ελέγχου.

Προσαρμογή νευρωνικού δικτύου

Τα δεδομένα εκπαίδευσης (`train_dir`) θα εκπαιδεύσουν το βαθύ νευρωνικό δίκτυο, έτσι, ώστε αυτό να μπορέσει να μάθει και να κατανοήσει την ταξινόμηση των ασθενειών και υγιών φυτών.

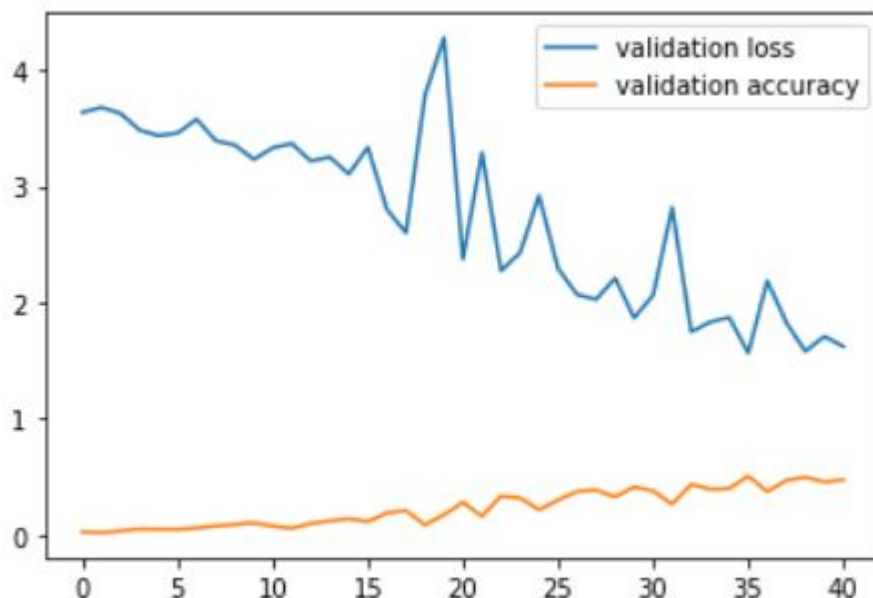
Το δεδομένα επικύρωσης (`val_dir`) θα προσαρμόσει και θα ρυθμίσει τις παραμέτρους του βαθιού νευρωνικού δικτύου, ώστε να παραχθεί ένα βελτιωμένο μοντέλο με ακριβή αποτελέσματα.

Για να συμβούν όλα τα παραπάνω θα πρέπει να καθοριστούν ορισμένες παράμετροι, όπως οι εποχές εκπαίδευσης (`epochs = 100`), το μέγεθος των δειγμάτων/ εικόνων που θα εισέρχονται κάθε φορά για εκπαίδευση στο μοντέλο (`batch_size = 32`). Επιπλέον, θα πρέπει να καθοριστούν οι παράμετροι `steps_per_epoch` (ο συνολικός αριθμός δειγμάτων/εικόνων πριν από τη δήλωση λήξης μιας εποχής και την έναρξη της επόμενης εποχής.), `validation_steps` (ο συνολικός αριθμός δειγμάτων, που πρέπει να ληφθούν πριν από τη διακοπή κατά την εκτέλεση της επικύρωσης στο τέλος κάθε εποχής.), οι επανακλήσεις (`callbacks`) και `verbose = 1` (η επιλογή εμφάνισης της εξόδου του νευρωνικού δικτύου).

Μετά την διαμόρφωση του προ εκπαιδευμένου μοντέλου Alexnet και τον καθορισμό όλων των παραπάνω παραμέτρων, η εκπαίδευση του μοντέλου για τα συγκεκριμένα δεδομένα πραγματοποιήθηκε για 41 εποχές. Τα αποτελέσματα που προέκυψαν από την εκπαίδευση είναι:

Accuracy: 49% και Loss: 1,6

Οι τιμές αποτυπώνονται και στο παρακάτω γράφημα:



Διάγραμμα 4 Απεικόνιση πορείας εκπαίδευσης μοντέλου


Από το γράφημα αντλούμε τα στοιχεία ότι κατά την εκπαίδευση του μοντέλου η τιμή validation loss μειωνόταν συνεχώς με ορισμένες διακυμάνσεις, ενώ η τιμή validation accuracy αυξανόταν με σταθερό σχεδόν ρυθμό.

VGG16

Στη συνέχεια δοκιμάστηκε το προ εκπαιδευμένο μοντέλο VGG16. Το VGG16 είναι ένα συνελκτικό νευρωνικό δίκτυο, που είναι γνωστό και ως ConvNet (Convolutional Network) και γενικότερα αποτελεί ένα είδος τεχνητού νευρωνικού δικτύου. Ο VGG16 είναι αλγόριθμος ανίχνευσης και ταξινόμησης αντικειμένων που μπορεί να ταξινομήσει 1000 εικόνες 1000 διαφορετικών κατηγοριών με ακρίβεια 92,7%. Είναι ένας από τους δημοφιλείς αλγόριθμους ταξινόμησης εικόνων και είναι εύκολος στη χρήση με την εκμάθηση μεταφοράς. Το VGG16 θεωρείται, ως ένα από τα καλύτερα μοντέλα μηχανικής όρασης που υπάρχουν σήμερα. Οι δημιουργοί αυτού του μοντέλου αξιολόγησαν τα δίκτυα και αύξησαν το βάθος χρησιμοποιώντας μια αρχιτεκτονική με πολύ μικρά συνελκτικά φίλτρα μεγέθους (3X3) τα οποία έδειξαν σημαντική βελτίωση

από τις προηγούμενες διαμορφώσεις. Συγκεκριμένα, με αυτή την αρχιτεκτονική το βάθος του μοντέλου αυξήθηκε στα 16 με 19 επίπεδα, φτάνοντας τις 138 εκπαιδεύσιμες παραμέτρους.

Αρχιτεκτονική Μοντέλου VGG16



Διάγραμμα 5 Τρισδιάστατη αρχιτεκτονική απεικόνιση μοντέλου Alexnet



Διάγραμμα 6 Αρχιτεκτονική απεικόνιση μοντέλου VGG16

- Ο αριθμός 16 στην ονομασία VGG16 αναφέρεται στα 16 επίπεδα του μοντέλου, που έχουν «βάρη». Στο μοντέλο υπάρχουν 13 συνελκτικά επίπεδα (convolutional layers), 5 επίπεδα υψηλής συγκέντρωσης (Max Pooling) και 3 τελικά επίπεδα (dense layers). Από τα 21 συνολικά επίπεδα μόνο τα 16 συμβάλλουν με εκπαιδεύσιμους νευρώνες.
- Έχει ως είσοδο πληροφορία/εικόνα/νευρώνες μεγέθους 224X224 και 3 χρωματικών αποχρώσεων (RGB channel)

- Διακρίνεται από το γεγονός ότι έχει μικρά συνελκτικά φίλτρα 3X3, με διασκελισμό (stride) 1 και βήμα (padding) 2 συνεχώς. Επιπλέον, χρησιμοποιείται πάντα το ίδιο max pool επίπεδο 2X2 και διασκελισμός (stride) 2.
- Τα στρώματα συνέλιξης και max pool είναι διατεταγμένα με συνέπεια σε ολόκληρη την αρχιτεκτονική.
- Conv-1 Layer έχει 64 φίλτρα/νευρώνες, Conv-2 έχει 128 φίλτρα/νευρώνες, Conv-3 έχει 256 φίλτρα/νευρώνες, Conv 4 and Conv 5 έχουν 512 φίλτρα/νευρώνες.
- Τα τελευταία 3 επίπεδα είναι πλήρως συνδεδεμένα (FC) μεταξύ τους και ακολουθούν μια στοίβα συνελκτικών επιπέδων: το 1^ο έχει 512 κανάλια και το 2^ο έχει 256, ενώ το 3^ο έχει 38, όσες και οι κατηγορίες δεδομένων για τις οποίες πρέπει να εκτελέσει σωστή κατηγοριοποίηση. Η συνάρτηση ενεργοποίησης στο τελικό επίπεδο είναι η Softmax. Να αναφερθεί ότι, επιλέχθηκε μικρότερος αριθμός νευρώνων (512 και 256) αντί για 4096 στα επίπεδα 1^ο και 2^ο του Dense layer, για εξοικονόμηση χρόνου και υπολογιστικής ισχύς κατά την εκπαίδευση του μοντέλου.
- Επιπλέον, προστέθηκε και ένα επίπεδο Dropout κατά (0,25), ώστε να αποφευχθεί το φαινόμενο της υπέρ εκπαίδευσης.

Μετά την διαμόρφωση του μοντέλου VGG16 προκύπτουν 27,7 εκατομμύρια περίπου παράμετροι, από τις οποίες μόνο οι 12 εκατομμύρια είναι εκπαιδευσιμες. Η χρήση κατάλληλου κώδικα είναι απαραίτητη, ώστε να συνταχθεί το διαμορφωμένο μοντέλο.

Για να γίνει αυτό χρησιμοποιείται η συνάρτηση (compile) η οποία έχει ορισμένες παραμέτρους:

- Model_optimizer: Οι βελτιστοποιητές μοντέλου είναι μαθηματικές συναρτήσεις που εξαρτώνται από τις εκπαιδευόμενες παραμέτρους του μοντέλου, π.χ. Weights & Biases. Οι βελτιστοποιητές βοηθούν στην αλλαγή των βαρών και του ρυθμό εκμάθησης του νευρωνικού δικτύου, ώστε να μειωθούν οι απώλειες. Στην προκειμένη περίπτωση αξιοποιείται ο βελτιστοποιητής Adam που αποτελεί μια μέθοδος στοχαστικής κλίσης καθόδου που βασίζεται στην προσαρμοστική εκτίμηση ροπών πρώτης και δεύτερης τάξης. Σύμφωνα με τους Kingma et al., 2014, η μέθοδος είναι «υπολογιστικά

αποδοτική, έχει μικρή απαίτηση μνήμης, αμετάβλητη στη διαγώνια επανακλιμάκωση των κλίσεων και είναι κατάλληλη για προβλήματα που είναι μεγάλα από άποψη δεδομένων/παραμέτρων».

- `Model_loss`: παρακολουθεί τα λάθη που πραγματοποιούνται κατά την εκπαίδευση. Εδώ, χρησιμοποιήθηκε η επιλογή `SparseCategoricalCrossentropy`, η οποία υπολογίζει την απώλεια διασταυρούμενης εντροπίας μεταξύ των ετικετών και των προβλέψεων. Η συνάρτηση απώλειας διασταυρούμενης εντροπίας αξιοποιείται, όταν υπάρχουν δύο ή περισσότερες κατηγορίες ετικετών, (εδώ έχουμε 38 ετικέτες/ κατηγορίες).
- `Model_metrics`: ελέγχει την εκτέλεση του νευρωνικού δικτύου και υπολογίζει το βαθμό ακρίβειας. Σε αυτό το μοντέλο εκπαίδευσης ζητείται ο υπολογισμός του βαθμού ακριβείας, ο οποίος προκύπτει από τα δεδομένα εκπαίδευσης και ελέγχου.

Προσαρμογή νευρωνικού δικτύου

Τα δεδομένα εκπαίδευσης (`train_dir`) θα εκπαιδεύσουν το βαθύ νευρωνικό δίκτυο, έτσι, ώστε αυτό να μπορέσει να μάθει και να κατανοήσει την ταξινόμηση των ασθενειών και υγιών φυτών.


Το δεδομένα επικύρωσης (`val_dir`) θα προσαρμόσει και θα ρυθμίσει τις παραμέτρους του βαθιού νευρωνικού δικτύου, ώστε να παραχθεί ένα βελτιωμένο μοντέλο με ακριβή αποτελέσματα.

Για να συμβούν όλα τα παραπάνω θα πρέπει να καθοριστούν ορισμένες παράμετροι, όπως οι εποχές εκπαίδευσης (`epochs = 100`), το μέγεθος των δειγμάτων/ εικόνων που θα εισέρχονται κάθε φορά για εκπαίδευση στο μοντέλο (`batch_size = 32`). Επιπλέον, θα πρέπει να καθοριστούν οι παράμετροι `steps_per_epoch` (ο συνολικός αριθμός δειγμάτων/εικόνων πριν από τη δήλωση λήξης μιας εποχής και την έναρξη της επόμενης εποχής.), `validation_steps` (ο συνολικός αριθμός δειγμάτων, που πρέπει να ληφθούν πριν από τη διακοπή κατά την εκτέλεση της επικύρωσης στο τέλος κάθε εποχής.), οι επανακλήσεις (`callbacks`) και `verbose = 1` (η επιλογή εμφάνισης της εξόδου του νευρωνικού δικτύου).

Η εκπαίδευση του μοντέλου VGG16 και οι καθορισμένες παράμετροι είχαν ως αποτέλεσμα, σε 16 εποχές εκπαίδευσης, να επιτευχθεί:

Accuracy: 83.8% και Loss: 0,48

Οι τιμές αποτυπώνονται και στο παρακάτω γράφημα:



Διάγραμμα 7 Απεικόνιση πορείας εκπαίδευσης μοντέλου

Σύμφωνα με το γράφημα, παρατηρούμε ότι από την 5^η εποχή εκπαίδευσης και μετά η ακρίβεια σταθεροποιείται κοντά στο 80%, ενώ από τη 1^η έως τη 5^η εποχή η ακρίβεια ανεβαίνει αυξάνεται αρκετά γρήγορα. Αυτό προκύπτει από το γεγονός ότι από τη 1^η έως τη 5^η εποχή εκπαίδευσης η απώλεια μειώνεται ταχύτατα από τη τιμή 1,6 στη τιμή 0,4. Αν και στις επόμενες εποχές εκπαίδευσης η απώλεια αυξομειώνεται από 0,5 έως 0,1 η ακρίβεια διατηρείται σχεδόν σταθερή.

MobileNet_V2

Το μοντέλο MobileNet είναι ένα εργαλείο ανοιχτού κώδικα που δημιουργήθηκε από τη Google και χρησιμοποιεί την αρχιτεκτονική των συνελκτικών νευρωνικών δικτύων για να κατηγοριοποιήσει εικόνες. Αυτή τη στιγμή είναι διαθέσιμες 2 εκδόσεις αυτού

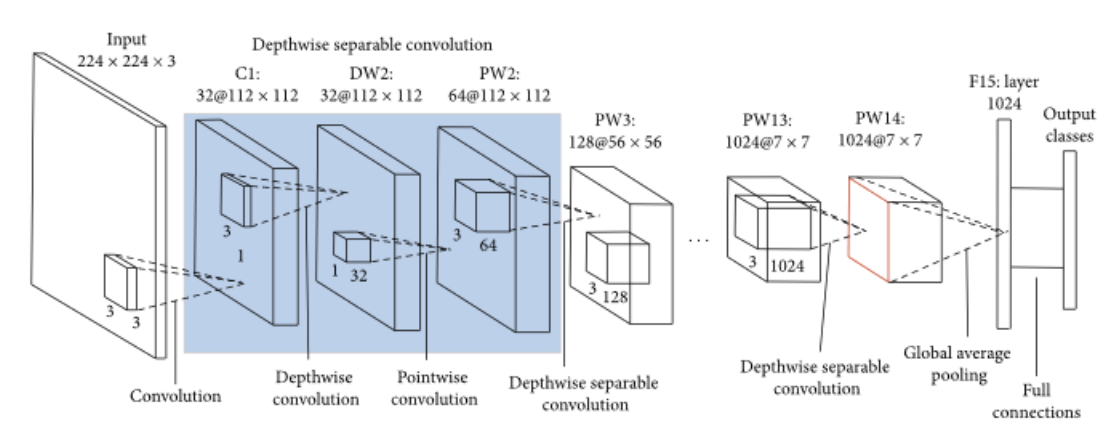
του μοντέλου, αυτές είναι οι MobilenetV1 και MobilenetV2. Σε αυτή τη μελέτη περίπτωσης αξιοποιήθηκε το μοντέλο MobilenetV2, το οποίο και θα περιγραφεί.

Αρχιτεκτονική Μοντέλου MobileNet_V2

Η αρχιτεκτονική του μοντέλου MobileNet είναι ιδιαίτερη για το λόγο ότι καταναλώνει ελάχιστους υπολογιστικούς πόρους, κατά τη λειτουργία της. Αυτή η ιδιαιτερότητα τη καθιστά ιδανική για εφαρμογές σε κινητά, σε ενσωματωμένα συστήματα και υπολογιστές χωρίς GPUs.

Το μοντέλο MobileNetV2, είναι η 2^η έκδοση του αρχικού μοντέλου MobileNet, και αποτελεί ένα προ-εκπαιδευμένο μοντέλο ταξινόμησης εικόνων. Τα προεκπαιδευμένα μοντέλα είναι βαθιά νευρωνικά δίκτυα που εκπαιδεύονται χρησιμοποιώντας ένα μεγάλο σύνολο δεδομένων εικόνων. Το συγκεκριμένο μοντέλο διακρίνεται για το γεγονός ότι έχει αρκετά λιγότερους εκπαιδευσιμους παραμέτρους στο βαθύ νευρωνικό δίκτυο, με αποτέλεσμα να είναι αρκετά «ελαφρύτερο», ταχύτερο, μικρότερο και απλό στη χρήση. Αυτή η ιδιότητα το καθιστά πολύτιμο για εφαρμογές σε κινητά τηλέφωνα και ενσωματωμένα συστήματα.

Η παρακάτω εικόνα παρουσιάζει την αρχιτεκτονική δομή και τον αριθμό των επιπέδων του προ εκπαιδευμένου μοντέλου MobileNetV2:



Διάγραμμα 8 Διάγραμμα 8 Τρισδιάστατη αναπαράσταση αρχιτεκτονικής μοντέλου MobileNetV2

Table 1. MobileNet Body Architecture

Type / Stride	Filter Shape	Input Size
Conv / s2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Conv dw / s1	$3 \times 3 \times 32$ dw	$112 \times 112 \times 32$
Conv / s1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Conv dw / s2	$3 \times 3 \times 64$ dw	$112 \times 112 \times 64$
Conv / s1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Conv dw / s1	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Conv dw / s2	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$
Conv dw / s1	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$
Conv dw / s2	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
5× Conv dw / s1	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
Conv dw / s2	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 1024$	$7 \times 7 \times 512$
Conv dw / s2	$3 \times 3 \times 1024$ dw	$7 \times 7 \times 1024$
Conv / s1	$1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$
Avg Pool / s1	Pool 7×7	$7 \times 7 \times 1024$
FC / s1	1024×1000	$1 \times 1 \times 1024$
Softmax / s1	Classifier	$1 \times 1 \times 1000$

Πίνακας 3 Αρχιτεκτονική μοντέλου MobileNet

Ο παραπάνω πίνακας παρουσιάζει την αρχιτεκτονική του μοντέλου MobileNetV2 κατά την εκπαίδευση σε διαφορετικά δεδομένα. Για την αξιοποίηση του μοντέλου στα δεδομένα αυτής της μελέτης χρειάστηκε να προστεθούν 3 τελευταία συνελκτικά επίπεδα (dense layers), που είναι πλήρως συνδεδεμένα μεταξύ τους. Στα 2 πρώτα περιέχονται 4096 νευρώνες και συνάρτησης ενεργοποίησης είναι η RELU και το τελευταίο επίπεδο έχει 38 νευρώνες, όσες και οι κατηγορίες των δεδομένων της περίπτωσης που μελετάται, ενώ συνάρτηση ενεργοποίησης είναι η SOFTMAX. Η διαμορφωμένη αρχιτεκτονική δημιούργησε 276,1 εκατομμύρια παραμέτρους από τις οποίες εκπαιδευσιμες είναι οι 273,8 εκατομμύρια.

Πριν την εκπαίδευση του μοντέλου είναι απαραίτητο να γραφεί κατάλληλος κώδικας, ώστε να συνταχθεί το διαμορφωμένο μοντέλο. Για να γίνει αυτό χρησιμοποιείται η

συνάρτηση (compile) η οποία έχει ορισμένες παραμέτρους, που πρέπει να καθοριστούν πριν την εκπαίδευση:

- `Model_optimizer`: Οι βελτιστοποιητές μοντέλου είναι μαθηματικές συναρτήσεις που εξαρτώνται από τις εκπαιδευόμενες παραμέτρους του μοντέλου, π.χ. `Weights & Biases`. Οι βελτιστοποιητές βοηθούν στην αλλαγή των βαρών και του ρυθμό εκμάθησης του νευρωνικού δικτύου, ώστε να μειωθούν οι απώλειες. Στην προκειμένη περίπτωση αξιοποιείται ο βελτιστοποιητής Adam που αποτελεί μια μέθοδος στοχαστικής κλίσης καθόδου που βασίζεται στην προσαρμοστική εκτίμηση ροπών πρώτης και δεύτερης τάξης. Σύμφωνα με τους Kingma et al., 2014, η μέθοδος είναι «υπολογιστικά αποδοτική, έχει μικρή απαίτηση μνήμης, αμετάβλητη στη διαγώνια επανακλιμάκωση των κλίσεων και είναι κατάλληλη για προβλήματα που είναι μεγάλα από άποψη δεδομένων/παραμέτρων».
- `Model_loss`: παρακολουθεί τα λάθη που πραγματοποιούνται κατά την εκπαίδευση. Εδώ, χρησιμοποιήθηκε η επιλογή `SparseCategoricalCrossentropy`, η οποία υπολογίζει την απώλεια διασταυρούμενης εντροπίας μεταξύ των ετικετών και των προβλέψεων. Η συνάρτηση απώλειας διασταυρούμενης εντροπίας αξιοποιείται, όταν υπάρχουν δύο ή περισσότερες κατηγορίες ετικετών, (εδώ έχουμε 38 ετικέτες/ κατηγορίες).
- `Model_metrics`: ελέγχει την εκτέλεση του νευρωνικού δικτύου και υπολογίζει το βαθμό ακρίβειας. Σε αυτό το μοντέλο εκπαίδευσης ζητείται ο υπολογισμός του βαθμού ακριβείας, ο οποίος προκύπτει από τα δεδομένα εκπαίδευσης και ελέγχου.

Προσαρμογή νευρωνικού δικτύου

Τα δεδομένα εκπαίδευσης (`train_dir`) θα εκπαιδεύσουν το βαθύ νευρωνικό δίκτυο, έτσι, ώστε αυτό να μπορέσει να μάθει και να κατανοήσει την ταξινόμηση των ασθενειών και υγιών φυτών.


Το δεδομένα επικύρωσης (val_dir) θα προσαρμόσει και θα ρυθμίσει τις παραμέτρους του βαθιού νευρωνικού δικτύου, ώστε να παραχθεί ένα βελτιωμένο μοντέλο με ακριβή αποτελέσματα.

Για να συμβούν όλα τα παραπάνω θα πρέπει να καθοριστούν ορισμένες παράμετροι, όπως οι εποχές εκπαίδευσης (epochs = 100), το μέγεθος των δειγμάτων/ εικόνων που θα εισέρχονται κάθε φορά για εκπαίδευση στο μοντέλο (batch_size = 32). Επιπλέον, θα πρέπει να καθοριστούν οι παράμετροι steps_per_epoch (ο συνολικός αριθμός δειγμάτων/εικόνων πριν από τη δήλωση λήξης μιας εποχής και την έναρξη της επόμενης εποχής.), validation_steps (ο συνολικός αριθμός δειγμάτων, που πρέπει να ληφθούν πριν από τη διακοπή κατά την εκτέλεση της επικύρωσης στο τέλος κάθε εποχής.), οι επανακλήσεις (callbacks) και verbose = 1 (η επιλογή εμφάνισης της εξόδου του νευρωνικού δικτύου).

Η εκπαίδευση του μοντέλου μετά από 24 εποχές είχε ως αποτέλεσμα την επίτευξη των παρακάτω τιμών:

Accuracy: 83.6% και Loss: 0,56

Οι τιμές αποτυπώνονται και στη παρακάτω γραφική παράσταση:



Διάγραμμα 9 Απεικόνιση πορείας εκπαίδευσης μοντέλου

Από το γράφημα παρατηρούμε ότι από την 1^η έως τη 5^η εποχή εκπαίδευσης η απώλεια μειώνεται δραστικά από 1,8 σε 0,7, ενώ την ίδια στιγμή η ακρίβεια αυξάνεται από 0,5 σε 0,8, δηλαδή με πολύ αργό ρυθμό. Ωστόσο, από την 5^η έως και την 20^η εποχή εκπαίδευσης η απώλεια δεν παραμένει σταθερή, αλλά μειώνεται σταδιακά, ενώ διακρίνονται και απότομες αυξήσεις της απώλειας, χωρίς όμως να επηρεάζεται η ακρίβεια σχεδόν καθόλου. Η ακρίβεια στο ίδιο φάσμα εποχών διακρίνεται από μεγάλη σταθερότητα και ελάχιστες αυξομειώσεις που δεν επηρεάζουν τη πορεία της, παρά τις πιο έντονες αυξομειώσεις της απώλειας.

Inception_V3

Ο αλγόριθμος Inception V3 είναι ένα μοντέλο βαθιάς μάθησης που βασίζεται στα συνελκτικά νευρωνικά δίκτυα (CNN) και χρησιμοποιείται για κατηγοριοποίηση εικόνων. Το μοντέλο InceptionV3 είναι βελτιωμένη έκδοση του μοντέλου InceptionV1, το οποίο δημιουργήθηκε από τη Google και παρουσιάστηκε το 2014, ως GoogLeNet. Το μοντέλο αυτό χρησιμοποιεί αρκετές τεχνικές για τη βελτιστοποίηση του δικτύου, ώστε να επιτευχθεί καλύτερη προσαρμογή του μοντέλου. Ορισμένα χαρακτηριστικά του μοντέλου είναι η υψηλή αποτελεσματικότητα, ότι έχει περισσότερα συνελκτικά επίπεδα, σε σχέση με τα μοντέλα InceptionV1 και InceptionV2, χωρίς όμως να πλήττεται η ταχύτητα του μοντέλου. Επιπλέον, χαρακτηρίζεται για την μειωμένη κατανάλωση υπολογιστικών πόρων και από το ότι χρησιμοποιεί βοηθητικούς ταξινομητές ως κανονικοποιητές.

Αρχιτεκτονική Μοντέλου Inception_V3

Το μοντέλο «κυκλοφόρησε» το 2015, έχει συνολικά 42 επίπεδα και χαμηλό ποσοστό σφάλματος, σε σύγκριση με τις προηγούμενες εκδόσεις V1, V2. Παρακάτω διακρίνονται ποιες είναι οι διαφορετικές βελτιστοποιήσεις που κάνουν το μοντέλο V3 καλύτερο. Οι κύριες τροποποιήσεις που έγιναν στο μοντέλο Inception V3 είναι:


1. Παραγοντοποίηση σε μικρότερες συνελίξεις
2. Χωρική Παραγοντοποίηση σε Ασύμμετρες Συνελίξεις
3. Χρησιμότητα βοηθητικών ταξινομητών

4. Αποτελεσματική μείωση μεγέθους πλέγματος

Ας δούμε πώς εφαρμόζεται κάθε μία από αυτές τις βελτιστοποιήσεις και πώς συμβάλλει στη βελτίωση της λειτουργίας του


Παραγοντοποίηση σε μικρότερες συνελίξεις

Ένα από τα κύρια πλεονεκτήματα του μοντέλου Inception V1 ήταν η γενναιόδωρη μείωση των διαστάσεων. Για να βελτιστοποιηθεί περισσότερο, οι μεγαλύτερες περιελίξεις στο μοντέλο παραγοντοποιήθηκαν σε μικρότερες συνελίξεις.




Διάγραμμα 10 Παραγοντοποίηση Συνελίξεων

Έχει ένα συνελικτικό στρώμα μεγέθους 5×5 το οποίο ήταν υπολογιστικά «ακριβό» (κατανάλωση πολλών υπολογιστικών πόρων, πολύ ώρα επεξεργασίας) όπως αναφέρθηκε προηγουμένως. Έτσι, για να μειωθεί το υπολογιστικό κόστος, το συνελικτικό στρώμα 5×5 αντικαταστάθηκε από δύο συνελικτικά στρώματα 3×3 .



Διάγραμμα 11 Παραγοντοποίηση Συνελίξεων

Για να γίνει καλύτερα κατανοητό παρατηρήστε πως μειώνονται οι αριθμοί των παραμέτρων κατά τη χρήση 2 συνελκτικών επιπέδων μεγέθους 3X3.



Εικόνα 7 Εικονική αναπαράσταση μείωσης παραμέτρων


Η μείωση των παραμέτρων συμβάλλει στην εξοικονόμηση υπολογιστικού κόστους. Γενικότερα από τη μετατροπή μεγάλων συνελκτικών σε μικρότερα δημιουργείται σχετικό κέρδος κατά 28%.

Χωρική Παραγοντοποίηση σε Ασύμμετρες Συνελίξεις

Αν και οι μεγαλύτερες συνελίξεις μπορούν να μετατραπούν σε μικρότερες, η καλύτερη αρχιτεκτονική για να γίνει το μοντέλο αποτελεσματικότερο είναι οι ασύμμετρες συνελίξεις.

Το τελευταίο μοντέλο Inception V3

Μετά την εκτέλεση όλων των βελτιστοποιήσεων, το τελικό μοντέλο Inception V3 έχει αυτή τη μορφή.



Εικόνα 8 Αναπαράσταση τελικού μοντέλου Inception V3

Συνολικά, το αρχικό μοντέλο V3 αποτελείται από 42 επίπεδα, τα οποία είναι λίγο περισσότερα από τα προηγούμενα μοντέλα V1 και V2. Παρόλο το μεγαλύτερο μέγεθος η αποτελεσματικότητα αυτού του μοντέλου είναι εντυπωσιακή.

TYPE	PATCH / STRIDE SIZE	INPUT SIZE
Conv	3x3/2	299x299x3
Conv	3x3/1	149x149x32
Conv padded	3x3/1	147x147x32

TYPE	PATCH / STRIDE SIZE	INPUT SIZE
Pool	3×3/2	147×147×64
Conv	3×3/1	73×73×64
Conv	3×3/2	71×71×80
Conv	3×3/1	35×35×192
3 × Inception	Module 1	35×35×288
5 × Inception	Module 2	17×17×768
2 × Inception	Module 3	8×8×1280
Pool	8 × 8	8 × 8 × 2048
Linear	Logits	1 × 1 × 2048
Softmax	Classifier	1 × 1 × 1000

Πίνακας 4 Συνελικτικά επίπεδα μοντέλου Inception V3

Ο παραπάνω πίνακας περιγράφει το περίγραμμα του αρχικού μοντέλου V3. Εδώ, το μέγεθος εξόδου κάθε μονάδας είναι το μέγεθος εισόδου της επόμενης μονάδας.

Στα δεδομένα ωστόσο που χρησιμοποιούνται σε αυτή τη μελέτη περίπτωσης, κατασκευάζεται μια διαφορετική διαμόρφωση του μοντέλου. Συγκεκριμένα, τοποθετείται ένα επίπεδο Flatten (μετατρέπει την πολυδιάστατη είσοδο σε μονοδιάστατη, χρησιμοποιείται συνήθως στη μετάβαση από το στρώμα συνέλιξης στο πλήρες συνδεδεμένο στρώμα), 2 πλήρη συνδεδεμένα επίπεδα με αριθμό νευρώνων 2048 και 1024 αντίστοιχα, ώστε να εξοικονομηθεί υπολογιστική ισχύ και χρόνος εκπαίδευσης. Τα 2 πυκνά επίπεδα ακολουθούνται από ένα επίπεδο Dropout κατά (0,2) μειώνονται δηλαδή οι νευρώνες με τυχαίο τρόπο κατά 20% και τελευταίο επίπεδο είναι ένα Dense, πλήρες συνδεδεμένο με 38 εξόδους, όσες και οι κατηγορίες στις οποίες πρέπει ο αλγόριθμος να ταξινομήσει τις εικόνες. Επίσης η συνάρτηση ενεργοποίησης που

χρησιμοποιείται στα 2 πρώτα πλήρως συνδεδεμένα επίπεδα είναι η RELU, ενώ στο τελευταίο επίπεδο είναι η συνάρτηση SOFTMAX.

Από τη διαμορφωμένη αρχιτεκτονική του μοντέλου InceptionV3 δημιουργήθηκαν 122,7 εκατομμύρια παραμέτρους από τις οποίες εκπαιδευσιμες είναι οι 106,9 εκατομμύρια.

Πριν την εκπαίδευση του μοντέλου είναι απαραίτητο να γραφεί κατάλληλος κώδικας, ώστε να συνταχθεί το διαμορφωμένο μοντέλο. Για να γίνει αυτό χρησιμοποιείται η συνάρτηση (compile) η οποία έχει ορισμένες παραμέτρους, που πρέπει να καθοριστούν πριν την εκπαίδευση:

- **Model_optimizer:** Οι βελτιστοποιητές μοντέλου είναι μαθηματικές συναρτήσεις που εξαρτώνται από τις εκπαιδευόμενες παραμέτρους του μοντέλου, π.χ. Weights & Biases. Οι βελτιστοποιητές βοηθούν στην αλλαγή των βαρών και του ρυθμό εκμάθησης του νευρωνικού δικτύου, ώστε να μειωθούν οι απώλειες. Στην προκειμένη περίπτωση αξιοποιείται ο βελτιστοποιητής Adam που αποτελεί μια μέθοδος στοχαστικής κλίσης καθόδου που βασίζεται στην προσαρμοστική εκτίμηση ροπών πρώτης και δεύτερης τάξης. Σύμφωνα με τους Kingma et al., 2014, η μέθοδος είναι *«υπολογιστικά αποδοτική, έχει μικρή απαίτηση μνήμης, αμετάβλητη στη διαγώνια επανακλιμάκωση των κλίσεων και είναι κατάλληλη για προβλήματα που είναι μεγάλα από άποψη δεδομένων/παραμέτρων»*.
- **Model_loss:** παρακολουθεί τα λάθη που πραγματοποιούνται κατά την εκπαίδευση. Εδώ, χρησιμοποιήθηκε η επιλογή SparseCategoricalCrossentropy, η οποία υπολογίζει την απώλεια διασταυρούμενης εντροπίας μεταξύ των ετικετών και των προβλέψεων. Η συνάρτηση απώλειας διασταυρούμενης εντροπίας αξιοποιείται, όταν υπάρχουν δύο ή περισσότερες κατηγορίες ετικετών, (εδώ έχουμε 38 ετικέτες/ κατηγορίες).
- **Model_metrics:** ελέγχει την εκτέλεση του νευρωνικού δικτύου και υπολογίζει το βαθμό ακρίβειας. Σε αυτό το μοντέλο εκπαίδευσης ζητείται ο υπολογισμός του βαθμού ακριβείας, ο οποίος προκύπτει από τα δεδομένα εκπαίδευσης και ελέγχου.

Προσαρμογή νευρωνικού δικτύου


Τα δεδομένα εκπαίδευσης (`train_dir`) θα εκπαιδεύσουν το βαθύ νευρωνικό δίκτυο, έτσι, ώστε αυτό να μπορέσει να μάθει και να κατανοήσει την ταξινόμηση των ασθενειών και υγιών φυτών.

Το δεδομένα επικύρωσης (`val_dir`) θα προσαρμόσει και θα ρυθμίσει τις παραμέτρους του βαθιού νευρωνικού δικτύου, ώστε να παραχθεί ένα βελτιωμένο μοντέλο με ακριβή αποτελέσματα.

Για να συμβούν όλα τα παραπάνω θα πρέπει να καθοριστούν ορισμένες παράμετροι, όπως οι εποχές εκπαίδευσης (`epochs = 100`), το μέγεθος των δειγμάτων/ εικόνων που θα εισέρχονται κάθε φορά για εκπαίδευση στο μοντέλο (`batch_size = 32`). Επιπλέον, θα πρέπει να καθοριστούν οι παράμετροι `steps_per_epoch` (ο συνολικός αριθμός δειγμάτων/εικόνων πριν από τη δήλωση λήξης μιας εποχής και την έναρξη της επόμενης εποχής.), `validation_steps` (ο συνολικός αριθμός δειγμάτων, που πρέπει να ληφθούν πριν από τη διακοπή κατά την εκτέλεση της επικύρωσης στο τέλος κάθε εποχής.), οι επανακλήσεις (`callbacks`) και `verbose = 1` (η επιλογή εμφάνισης της εξόδου του νευρωνικού δικτύου).

Με το πέρας της εκπαίδευσης μετά από 17 εποχές προέκυψαν ορισμένα αποτελέσματα: Accuracy: 91% και Loss: 0,27

Τα αποτελέσματα παρουσιάζονται και γραφικά στο παρακάτω γράφημα:




Διάγραμμα 12 Απεικόνιση πορείας εκπαίδευσης μοντέλου

Από το γράφημα παρατηρούμε ότι η ακρίβεια που πετυχαίνει ο αλγόριθμος είναι από την αρχή αρκετά υψηλή, περίπου στο 75% και με το πέρασμα των εποχών εκπαίδευσης αυξάνεται σταδιακά, μέχρι τη τιμή 91%. Απώλεια στις 5 πρώτες εποχές εκπαίδευσης μειώνεται ραγδαία από 0,83 στη τιμή 0,35, ενώ από την 5^η έως την 9^η διατηρείται σταθερή. Ωστόσο, από την 9^η μέχρι και την 11^η η απώλεια μειώνεται σχεδόν κατακόρυφα από 0,4 σε 0,1 για να ανέβει ξανά και να σταθεροποιηθεί στη τιμή 0,3 περίπου.

Επιλογή Βέλτιστου Μοντέλου

Μετά την εκπαίδευση των 4 μοντέλων, Alexnet, VGG16, MobileNetV2, InceptionV3 πάνω στα δεδομένα εκπαίδευσης της βάσης δεδομένων New Disease Dataset και σε δείγμα 70295 εικόνων, κατάλληλες εντολές κώδικα ανέδειξαν ως πιο αποτελεσματικό και ακριβή το αλγοριθμικό μοντέλο InceptionV3, του οποίου το ποσοστό ακρίβειας ανήλθε στο 91%.

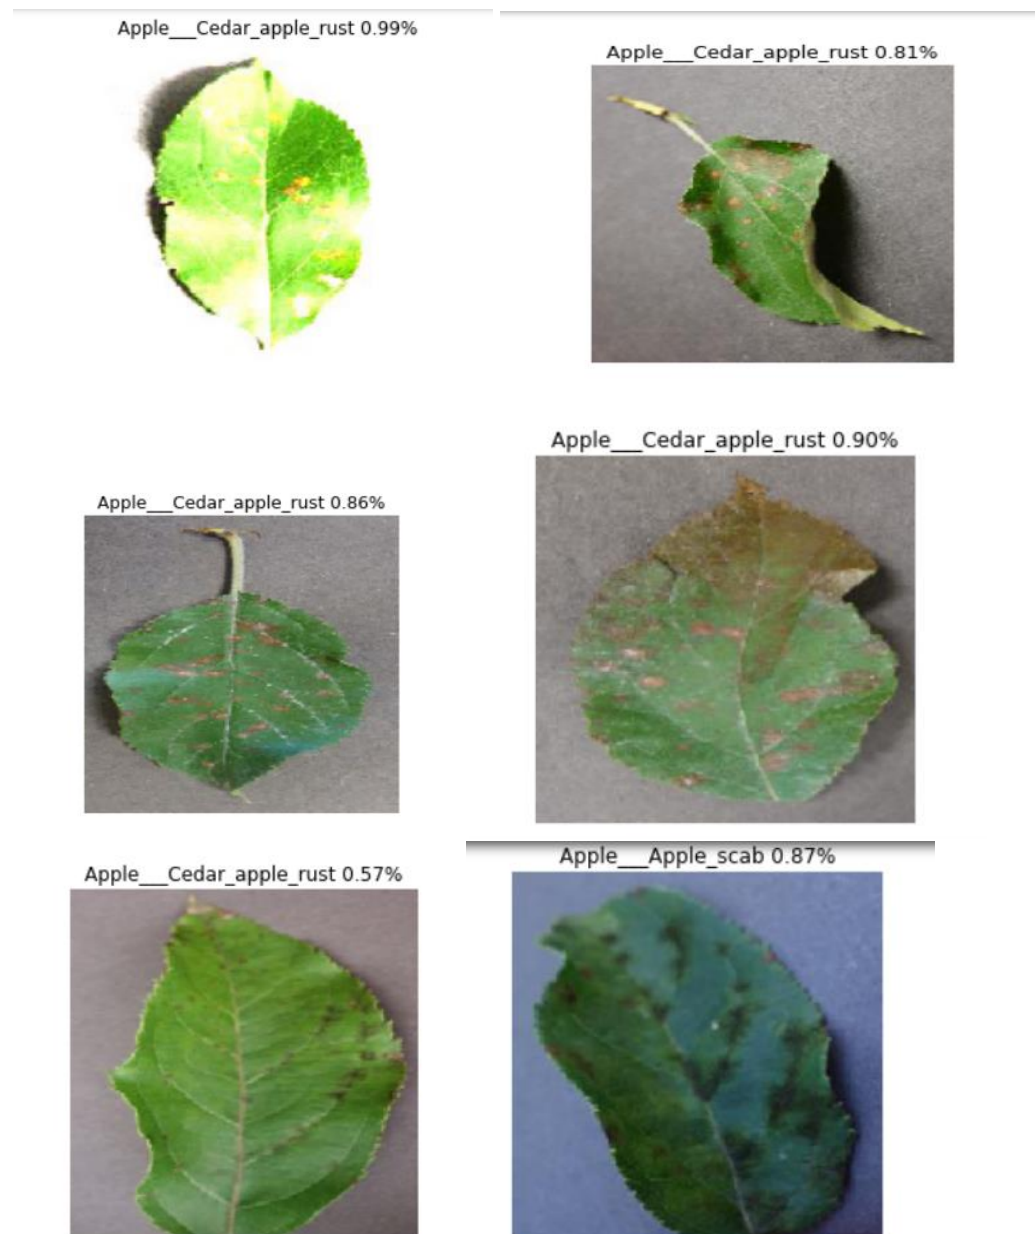
Με αντίστοιχο κώδικα είναι δυνατόν να εμφανίσουμε ένα πίνακα συσχέτισης μεταξύ των 38 κατηγοριών των δεδομένων.



Εικόνα 9 Πίνακας συσχέτισης

Όσο εντονότερο είναι το χρώμα μεταξύ ενός κοινού σημείου μιας γραμμής και μια στήλης, τόσο μεγαλύτερη συσχέτιση εμφανίζεται στις 2 αυτές κατηγορίες. Η συσχέτιση αυτή δημιουργείται διότι ορισμένες εικόνες μοιάζουν μεταξύ τους, οπότε ο αλγόριθμος τις θεωρεί σχεδόν ίδιες.

Όπως έχει αναφερθεί νωρίτερα υπήρχε και ένα 3^ος κατάλογος δεδομένων το test_dir. Αυτός ο κατάλογος περιέχει 20 περίπου εικόνες οι οποίες μπορούν να χρησιμοποιηθούν για την αξιολόγηση του αλγορίθμου InceptionV3 σε δεδομένα/ δείγματα/ εικόνες που δεν έχει δει ξανά. Με τον αντίστοιχο κώδικα αξιολογείται στην πράξη, δηλαδή η εκπαίδευση του διαμορφωμένου μοντέλου.



Potato__Early_blight 0.99%



Corn_(maize)__Common_rust_ 0.78%



Corn_(maize)__Common_rust_ 0.96%



Corn_(maize)__Common_rust_ 0.99%

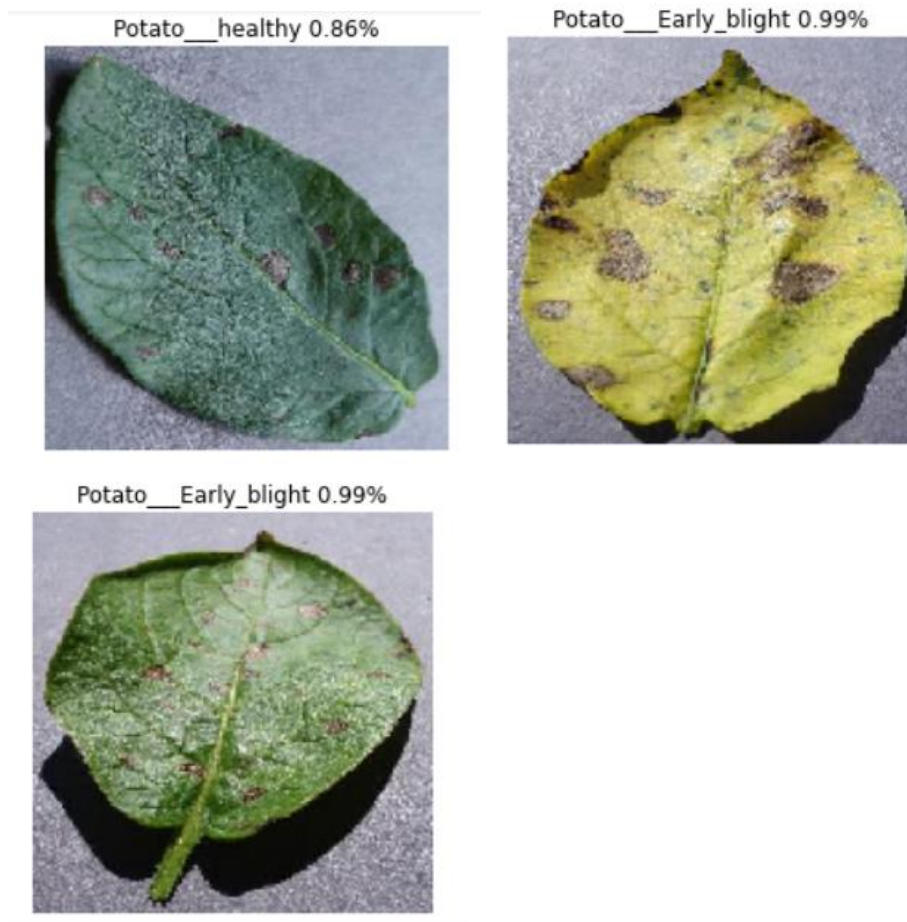


Potato__Early_blight 0.99%



Potato__Early_blight 1.0%














Εικόνα 10 Εμφάνιση φυλλωμάτων και ποσοστού ακρίβειας αναγνώρισης από τον αλγόριθμο


Γίνεται λοιπόν εύκολα αντιληπτό ότι ο διαμορφωμένος αλγόριθμος InceptionV3 είναι σε θέση να κατηγοριοποιεί εικόνες φυτών που δεν έχει ξαναδεί με αρκετά μεγάλη ακρίβεια. Επομένως, συμπεραίνουμε ότι έχει εκπαιδευτεί αρκετά καλά και είναι αποτελεσματικός και λειτουργικός.

Τελευταίο και σημαντικό στοιχείο του κώδικα είναι η αποθήκευση του μοντέλου σε μορφή αρχείου (.h5).

```
In [46]: # Εικονική εμφάνιση της διαδικασίας εκπαίδευσης
visuals_prediction(img)
```

```
<ipython-input-45-204973ee3e19>:37: UserWarning: Attempting to set identical bottom == top == -0.5 results in singular transformations; automatically expanding.
plt.imshow(display_grid, aspect='auto', cmap='viridis')
<ipython-input-45-204973ee3e19>:26: RuntimeWarning: invalid value encountered in true_divide
channel_image /= channel_image.std()
```





Εικόνα 11 Εικονική απεικόνιση σταδίων εκπαίδευσης βέλτιστου μοντέλου Inception V3

ΠΗΓΕΣ

Agriculture, I. S. of P. (n.d.). *Precision AG definition: International Society of Precision Agriculture*. Retrieved February 19, 2023, from <https://www.ispag.org/about/definition>

Ayaz, M., Ammad-Uddin, M., Baig, I., and Aggoune, E.-H. M. (2018). “Wireless sensor’s civil applications, prototypes, and future integration possibilities: A review,” *IEEE Sensors J.*, 18 (1), 4–30.

Ayaz, M., Ammad-Uddin, M., Sharif, Z., Mansour, A., & Aggoune, E.-H. M. (2019). Internet-of-things (iot)-based smart agriculture: Toward making the fields talk. *IEEE Access*, 7, 129551–129583. <https://doi.org/10.1109/access.2019.2932609>

Bongiovanni, R., & Lowenberg-Deboer, J. (2004). Precision Agriculture and Sustainability. *Precision Agriculture*, 5, 359-387.

Cook, S.E. and Bramley, R.G. (1998) “Precision Agriculture — opportunities, benefits and pitfalls of site-specific crop management in Australia,” *Australian Journal of Experimental Agriculture*, 38(7), p. 753. Available at: <https://doi.org/10.1071/ea97156>

Crowder, D. W., & Reganold, J. P. (2015). Financial competitiveness of organic agriculture on a global scale. *Proceedings of the National Academy of Sciences*, 112(24), 7611–7616. <https://doi.org/10.1073/pnas.1423674112>

Eltner, A., Mulsow, C., and Maas, H. (2013). Quantitative measurement of soil erosion from Tls and Uav data. *International Architecture Photogramm, Remote Sens., Spatial Inf. Sci.*, vol. XL-1, no. W2, 119–124

Evans, D.E.; Sadler, E.J.; Camp, C.R.; Millen, J.A (2000). Spatial canopy temperature measurements using center pivot mounted IRTs. *Proceedings of the 5th International Conference on Precision Agriculture and Other Resource Management July 16-19, 2000*

Dvorak, J. S., Stone, M. L., and Self, K. P. (2016). Object detection for agricultural and construction environments using an ultrasonic sensor. *Journal of Agriculture Safety and Health*, 22 (2), pp. 107–119.

Faiçal, B. S., Freitas, H., Gomes, P. H., Mano, L. Y., Pessin, G., de Carvalho, A. C. P. L. F., Krishnamachari, B., and Ueyama, J. (2017). An adaptive approach for UAV-based pesticide spraying in dynamic environments. *Computer Electronic Agriculture*, vol. 138, 210–223.

Fountas, S., Aggelopoulou, K., & Gemtos, T. A. (2016). Precision Agriculture. In *Supply Chain Management for Sustainable Food Networks* (pp. 41–65). Chichester, UK: John Wiley & Sons, Ltd. <http://doi.org/10.1002/9781118937495.ch2>

Gassner, A., Coe, R., and Sinclair, F. (2013). Improving food security through increasing the precision of agricultural development. In Oliver, M., Bishop, T., and Marchant, B., eds., *Precision agriculture for sustainability and environmental protection*, Chapter 3, pp. 35–57. Abingdon, UK: Routledge

Gasso-Tortajada, V., Ward, A. J., Mansur, H., Brøchner, T., Sørensen, C. G., and Green, O. (2010). A novel acoustic sensor approach to classify seeds based on sound absorption spectra. *Sensors*, 10 (11), 10027–10039.

Grassi, M. J. (2015, April 21). *The Precision Agriculture Revolution*. Global Ag Tech Initiative. Retrieved February 16, 2023, from <https://www.globalagtechinitiative.com/in-field-technologies/guidance/the-precision-agriculture-revolution/>

Goddard, T., (1997) What is precision farming. *Proceedings of Precision Farming Conference*, January 20–21.

Hegazy, I. R., and Kaloop, M. R. (2015). Monitoring urban growth and land use change detection with GIS and remote sensing techniques in Daqahlia governorate Egypt. *International Journal of Sustainable Built Environment*, 4 (1), pp. 117–124.

Hemmat, A., Binandeh, A. R., Ghaisari, J., and Khorsandi, A. (2013). Development and field testing of an integrated sensor for on-the-go measurement of soil mechanical resistance. *Sens. Actuators A, Phys.*, 198, pp. 61–68.

Hoffmann, H., Jensen, R., Thomsen, A., Nieto, H., Rasmussen, J., and Friberg, T. (2016). Crop water stress maps for an entire growing season from visible and thermal UAV imagery. *Biogeosciences*, 13 (24), 6545–6563.

Jayne, T. S., Mather, D., & Mghenyi, E. (2010). Principal challenges confronting Smallholder Agriculture in sub-saharan africa. *World Development*, 38(10), 1384–1398. <https://doi.org/10.1016/j.worlddev.2010.06.002>

Jin, X., Liu, S., Baret, F., Hemerlé, M., and Comar, A. (2017). Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery. *Remote Sensory Environment*, vol. 198, 105–114.

Johnson, E. (2018, February 11). *Harvesting the agricultural potential of drones*. Sanford Journal of Public Policy. Retrieved March 7, 2023, from <https://www.sanfordjournal.org/sjpp/2017/harvesting-the-agricultural-potential-of-drones>

Johnson, L. M. (2019). *Hawaiian flower, thought extinct, rediscovered by a drone*. CNN. Retrieved March 7, 2023, from <https://www.cnn.com/2019/04/18/us/hawaiian-flower-thought-extinct-rediscovered-trnd/index.html>

Keeping Plant Pests and Diseases at Bay: Experts Focus on Global Measures. Accessed: Apr. 13, 2019. [Online]. Available: <http://www.fao.org/news/story/en/item/280489/icode/>

Kumar, A., Bhatia, A., Fagodiya, R. K., Malyan, S. K., and Meena, B. L. (2017). Eddy covariance flux tower: A promising technique for greenhouse gases measurement. *Adv. Plants Agricult. Res.*, 7 (4), pp. 337–340.

Kiiski, H., Dittmar, H., Drach, M., Vosskamp, R., Trenkel, M. E., Gutser, R., and Steffens, G. (2009) “Fertilizers, 2. types,” in Ullmann’s Encyclopedia of Industrial Chemistry.

Lowenberg-DeBoer, J. (1996). Precision farming and the new information technology: Implications for Farm Management, policy, and research: Discussion. *American Journal of Agricultural Economics*, 78(5), 1281–1284.
<https://doi.org/10.2307/1243507>

Lowenberg-DeBoer, J. (2015). The precision agriculture revolution: Making the modern farmer. *Foreign Affairs*

Marcotte, E. M., Pellegrini, M., Ng, H. L., Rice, D. W., Yeates, T. O., & Eisenberg, D. (1999). Detecting protein function and protein-protein interactions from genome sequences. *Science*, 285(5428), 751-753.

Mark T., and Griffin, T. (2016). Defining the barriers to telematics for precision agriculture: Connectivity supply and demand. Presented at the SAEA Annual Meeting, Austin, TX, USA.

McBratney, A. B., & Taylor, J. A. 2000. PV or not PV? In 5th International Symposium on Cool Climate Viticulture and Oenology- a workshop on Precision Management (Vol. Melbourne,). Melbourne, Australia.

McKinion, J. M., Jenkins, J. N., Akins, D., Turner, S. B., Willers, J. L., Jallas, E., Whisler, F. D. (2001). Analysis of a precision agriculture approach to cotton production. *Computers and Electronics in Agriculture*, 32(3), 213-228.
[https://doi.org/10.1016/S0168-1699\(01\)00166-1](https://doi.org/10.1016/S0168-1699(01)00166-1)

Millan-Almaraz, J. R., de Jesus Romero-Troncoso, R., Guevara-Gonzalez, R. G., Contreras-Medina, L. M., Carrillo-Serrano, R. V., Osornio-Rios, R. A., Duarte-Galvan, C., Rios-Alcaraz, M. A., and Torres-Pacheco, I. (2010). FPGA-based fused smart sensor for real-time plant-transpiration dynamic estimation. *Sensors*, 10 (9), 8316–8331.

Murray, S. C. (2018). Optical sensors advancing precision in agricultural production. *Photon. Spectra*, 51 (6), p. 48.

National Research Council. (1997). *Precision Agriculture in the 21st Century: Geospatial and Information Technologies in Crop Management*. Washington, D.C., USA: National Academy Press.

Natural Resources Conservation Service. Natural Resources Conservation Service. (2023, January 30). Retrieved March 5, 2023, from <https://www.nrcs.usda.gov/>

New Robotics and drones 2018-2038: Technologies, forecasts, players. IDTechEx. (2018, February 19). Retrieved March 7, 2023, from <https://www.idtechex.com/en/research-report/new-robotics-and-drones-2018-2038-technologies-forecasts-players/584>

Pedersen, S. M., & Lind, K. M. (2017). Precision Agriculture – from mapping to site-specific application. *Progress in Precision Agriculture*, 1–20. https://doi.org/10.1007/978-3-319-68715-5_1

Puig, E., Gonzalez, F., Hamilton, G., and Grundy, P. (2015). Assessment of crop insect damage using unmanned aerial systems: A machine learning approach. in Proc. 21st Int. Congr. Modelling Simulation.

van Poppel, R. (2016, May 4). *Farming with robots*. Robohub. Retrieved February 16, 2023, from <https://robohub.org/farming-with-robots/>

Rubion. (n.d.). Retrieved March 7, 2023, from <http://octinion.com/products/agricultural-robotics/rubion>

Schuster, J. N., Darr, M. J., and McNaull, R. P. (2017). Performance benchmark of yield monitors for mechanical and environmental influences. in Proc. Agricult. Biosyst. Eng. Conf. Presentations, pp. 1–17.

Serraj, R., & Pingali, P. L. (Eds.). (2019). *Agriculture & Food Systems to 2050: Global trends, challenges and opportunities*. World Scientific.
<https://www.worldscientific.com/doi/pdf/10.1142/11212#page=302>

Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanovic, D. (2016). Deep Neural Networks based recognition of plant diseases by Leaf Image Classification. *Computational Intelligence and Neuroscience*, 2016, 1–11.
<https://doi.org/10.1155/2016/3289801>

Spiertz, H. (2013). Challenges for Crop Production Research in Improving Land Use, Productivity and Sustainability. *Sustainability*, 5(4), 1632–1644.
<https://doi.org/10.3390/su5041632>

Stafford, V. J. (2000). Implementing Precision Agriculture in the 21st Century, *Journal of Agricultural Engineering Research*, 76(3), 267-275.
<https://doi.org/10.1006/jaer.2000.0577>

Stein, K., Coulibaly, D., Stenchly, K., Goetze, D., Porembski, S., Lindner, A., Konaté, S., and Linsenmair, E. K. (2017). “Bee pollination increases yield quantity and quality of cash crops in Burkina Faso, West Africa,” *Sci. Rep.*, vol. 7, Art. no. 17691

Stoorvogel, J. J., & Orlich, R. A. (2000). An integrated system for precision agriculture in bananas. In *Proceedings of the 5th International Conference on Precision Agriculture, Bloomington, Minnesota, USA*, (pp. 1-14). American Society of Agronomy.

Schumacher, K., Ravikovitch, P. I., Du Chesne, A., Neimark, A. V., & Unger, K. K. (2000). Characterization of MCM-48 materials. *Langmuir*, 16(10), 4648-4654.

Szewczyk, R., Zieliński, C., Kaliczyńska, M. (2019) *Automation 2018: Advances in Automation, Robotics and Measurement Techniques*.

The future of Fresh Fruit Harvest. frobotics. (n.d.). Retrieved March 8, 2023, from <https://www.ffrobotics.com/>

Thomson, B. C., Ostle, N. J., McNamara, N. P., Whiteley, A. S., & Griffiths, R. I. (2010). Effects of sieving, drying and rewetting upon soil bacterial community structure and respiration rates. *Journal of Microbiological Methods*, 83(1), 69–73. <https://doi.org/10.1016/j.mimet.2010.07.021>

Uddin, M., A., Mansour, A., Le Jeune, D., Ayaz, M., and Aggoune, E-H. (2018). UAV-assisted dynamic clustering of wireless sensor networks for crop health monitoring. *Sensors*, 18 (2), 555.

Water for Sustainable Food and Agriculture by FAO. Accessed: Apr. 15, 2019. [Online]. Available: <https://www.fao.org/3/a-i7959e.pdf>

Weiss, U., and Biber, P. (2011). Plant detection and mapping for agricultural robots using a 3D LIDAR sensor. *Robot. Auton. Syst.*, 59 (5), pp. 265–273.

Why IOT is Reinventing Plant Fertilization. Accessed: Sep. 6, 2019. [Online]. Available: <https://www.iof2020.eu/latest/news/2017/09/whythe-internet-of-things-is-reinventing-plant-fertilization>

Yew, T. K., Yusoff, Y., Sieng, L. K., Lah, H. C., Majid, H., and Shelida, N. (2014). An electrochemical sensor ASIC for agriculture applications. in Proc. 37th Int. Conv. Inf. Commun. Technol., Electron. Microelectron. (MIPRO), Opatija, Croatia, pp. 85–90.

Yunus, M. A. M., and Mukhopadhyay, S. C. (2011). Novel planar electromagnetic sensors for detection of nitrates and contamination in natural water sources. *IEEE Sensors J.*, 11 (6), pp. 1440–1447.

Zhang, N., Wang, M., & Wang, N. (2002). Precision Agriculture - a worldwide overview. *Computers and Electronics in Agriculture*, 36(2-3), 113–132. [https://doi.org/10.1016/s0168-1699\(02\)00096-0](https://doi.org/10.1016/s0168-1699(02)00096-0)

Zhang, C., and Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: A review. *Precis. Agric.*, 13 (6), pp. 693–712.

Zhao, Y., Gong, L., Huang, Y., and Liu, C. (2016). A review of key techniques of vision-based control for harvesting robot. *Computer Electronic Agriculture*, vol. 127, pp. 311–323.

ΠΑΡΑΡΤΗΜΑ

Διάγραμμα 1: Internet of Things and Data Analytics Relationship.	57
Διάγραμμα 2 Οι κατηγορίες δεδομένων σε στήλες και ο αριθμός φωτογραφιών που περιέχουν σε κάθε μια.	71
Διάγραμμα 3 Σύνδεση επιπέδων συνέλιξης Alexnet.....	77
Διάγραμμα 4 Απεικόνιση πορείας εκπαίδευσης μοντέλου.....	79
Διάγραμμα 5 Τρισδιάστατη αρχιτεκτονική απεικόνιση μοντέλου Alexnet	80
Διάγραμμα 6 Αρχιτεκτονική απεικόνιση μοντέλου VGG16.....	80
Διάγραμμα 7 Απεικόνιση πορείας εκπαίδευσης μοντέλου.....	83
Διάγραμμα 8 Διάγραμμα 8 Τριασδιάστατη αναπαράσταση αρχιτεκτονικής μοντέλου MobileNetV2.....	84
Διάγραμμα 9 Απεικόνιση πορείας εκπαίδευσης μοντέλου.....	87
Διάγραμμα 10 Παραγοντοποίηση Συνελίξεων.....	89
Διάγραμμα 11 Παραγοντοποίηση Συνελίξεων.....	90
Διάγραμμα 12 Απεικόνιση πορείας εκπαίδευσης μοντέλου.....	95

Εικόνα 1: Ρομπότ Sweeper κατά τη συγκομιδή	44
Εικόνα 2: Ρομπότ Sweeper.....	44
Εικόνα 3: Ρομπότ Rubion.....	45
Εικόνα 4: FFRobot	46
Εικόνα 5 Διαφορετικοί τύποι αισθητήρων που χρησιμοποιούνται για ανίχνευση.....	48
Εικόνα 6 Grape disease detection system using ML algorithms.	60
Εικόνα 7 Εικονική αναπαράσταση μείωσης παραμέτρων.....	90
Εικόνα 8 Αναπαράσταση τελικού μοντέλου Inception V3	91
Εικόνα 9 Πίνακας συσχέτισης.....	96
Εικόνα 10 Εμφάνιση φυλλωμάτων και ποσοστού ακρίβειας αναγνώρισης από τον αλγόριθμο	99
Εικόνα 11 Εικονική απεικόνιση σταδίων εκπαίδευσης βέλτιστου μοντέλου Inception V3..	101

Πίνακας 1 Οι κατηγορίες δεδομένων και ο αριθμός φωτογραφιών που αντιστοιχούν σε κάθε μια.....	70
Πίνακας 2 Αρχιτεκτονική μοντέλου Alexnet	75
Πίνακας 3 Αρχιτεκτονική μοντέλου MobileNet.....	85
Πίνακας 4 Συνελικτικά επίπεδα μοντέλου Inception V3	92