



Τεχνητή Νοημοσύνη στη γεωργία: Αναγνώριση ασθενειών φυτών με μοντέλα βαθιάς μάθησης

Δρ Κωνσταντίνος Φερεντίνος, Εντεταλμένος Ερευνητής
Τμήμα Γεωργικής Μηχανικής
Ινστιτούτο Εδαφοϋδατικών Πόρων

Τα τελευταία χρόνια, οι εφαρμογές της Τεχνητής Νοημοσύνης (Artificial Intelligence) που σχετίζονται με τη Μηχανική Μάθηση (Machine Learning) γνωρίζουν αλματώδη ανάπτυξη. Ο τομέας της Μηχανικής Μάθησης περιλαμβάνει τις μεθόδους αυτές της Τεχνητής Νοημοσύνης που δίνουν τη δυνατότητα στις μηχανές (δηλαδή, σε προγράμματα υπολογιστών) να επιτελούν συγκεκριμένες διεργασίες και να επιλύουν προβλήματα χωρίς να έχουν προγραμματιστεί ειδικά για τον σκοπό αυτό. Ουσιαστικά, οι μέθοδοι αυτές επιτρέπουν στα υπολογιστικά συστήματα να “εκπαιδεύονται” χρησιμοποιώντας υπάρχουσες συσχετίσεις δεδομένων τού προς επίλυση προβλήματος.


Η μεγάλη αύξηση της υπολογιστικής ισχύος των τελευταίων ετών και η διαθεσιμότητα μεγάλου όγκου δεδομένων σε όλο και περισσότερους τομείς, οδήγησε στη δημιουργία μεθόδων και μοντέλων που εντάσσονται πλέον σε μια νέα κατηγορία της Μηχανικής Μάθησης, αυτή της Βαθιάς Μάθησης (Deep Learning), όπου πιο σύνθετα μοντέλα που παλαιότερα δεν μπορούσαν να υλοποιηθούν από τους υπάρχοντες υπολογιστές, πλέον είναι ρεαλιστικά και λειτουργικά. Τα αποτελέσματα των εφαρμογών βαθιάς μάθησης έχουν φέρει επανάσταση σε τομείς, όπως η αναγνώριση αντικειμένων, η αναγνώριση φωνής και άλλες αντίστοιχα πολύπλοκες διεργασίες που σχετίζονται με την ανάλυση μεγάλου όγκου δεδομένων. Η απόδοση των υπολογιστικών συστημάτων στις εφαρμογές αυτές έχει ανέλθει σε πολύ υψηλά επίπεδα, καθιστώντας τα σε συγκεκριμένες περιπτώσεις ικανά, αν όχι να αντικαθιστούν πλήρως τον ανθρώπινο παράγοντα, τουλάχιστον να τον βοηθούν επιτυχώς σε πολύ μεγάλο βαθμό.

Η χρήση μεθόδων βαθιάς μάθησης στη γεωργία έχει αρχίσει να λαμβάνει χώρα μόλις την τελευταία πενταετία, αρχικά σε τομείς της γεωπονίας που είχαν ανέκαθεν μεγάλη σχέση με τις νέες τεχνολογίες, όπως αυτός της Γεωργικής Μηχανικής, με τη δημιουργία προηγμένων ρομποτικών συστημάτων, ευφυών συστημάτων ελέγχου περιβάλλοντος κ.ά. Η ενσωμάτωση τέτοιων μεθόδων σε λιγότερο τεχνολογικούς τομείς της γεωπονίας, όπως π.χ. αυτός της φυτοπαθολογίας, παρουσιάζει, όπως είναι λογικό, κάποια καθυστέρηση, όμως τα τελευταία χρόνια αυτό τείνει να αλλάξει, τόσο μέσω της αυξανόμενης ενασχόλησης γεωπόνων με θέματα πληροφορικής όσο και με τη δημιουργία συνεργειών μεταξύ γεωπόνων και επιστημόνων της πληροφορικής και ειδικότερα της τεχνητής νοημοσύνης.

Αυτοματοποιημένη αναγνώριση ασθενειών

Ο έγκαιρος εντοπισμός και η επιτυχής αναγνώριση των προβολών μιας καλλιέργειας, αποτελούν βασικές προϋποθέσεις για την αντιμετώπιση των φυτοπαθολογικών προβλημάτων και τη μεγιστοποίηση της ποιότητας και ποσότητας του παραγόμενου προϊόντος. Ωστόσο, η διαδικασία της διάγνωσης ασθενειών φυτών μέσω οπτικής παρατήρησης των συμπτωμάτων των φύλλων τους αποτελεί πρόκληση με μεγάλες πιθανότητες σφάλματος ακόμα και για τους έμπειρους γεωπόνους, λόγω της μεγάλης ποικιλομορφίας των συμπτωμάτων των φυτοπαθολογικών προβλημάτων που παρουσιάζονται σε όλη τη γκάμα της τεράστιας ποικιλίας των καλλιεργούμενων φυτών.

Η ύπαρξη ενός αυτοματοποιημένου, υπολογιστικού συστήματος διάγνωσης ασθενειών, θα μπορούσε να αποτελέσει έναν πολύτιμο αρωγό για τον γεωπόνο που καλείται να πραγματοποιήσει αντίστοιχες διαγνώσεις ασθενειών φυτών μέσω οπτικής παρατήρησης των φύλλων τους. Εάν μάλιστα το σύστημα ήταν



απλό στη χρήση του και εύκολο προσβάσιμο, όπως π.χ. μέσω μιας απλής εφαρμογής κινητού τηλεφώνου, θα μπορούσε να αποτελέσει πολύτιμο εργαλείο, ειδικά για την υποστήριξη παραγωγών σε μέρη του κόσμου που στερούνται των κατάλληλων υποδομών ως προς τις γεωπονικές παροχές και την προσφορά φυτοπαθολογικών συμβουλών. Επίσης, για καλλιέργειες μεγάλων εκτάσεων, το σύστημα θα μπορούσε να λειτουργήσει ενσωματωμένο σε κάποιο γεωργικό όχημα (είτε επίγειο είτε εναέριο) ώστε να μπορεί να εντοπίζει φυτοπαθολογικά προβλήματα σε συγκεκριμένα σημεία της καλλιέργειας μέσω συνεχών λήψεων φωτογραφιών, έγκαιρα και με υψηλή χωρική ακρίβεια. Όλα αυτά φυσικά προϋποθέτουν την υψηλή απόδοση του συστήματος και την ευκολία χρήσης του σε πραγματικές συνθήκες καλλιέργειας.

Τεχνικές βαθιάς μάθησης

Ένα από τα βασικά εργαλεία βαθιάς μάθησης είναι τα συνελκτικά νευρωνικά δίκτυα (convolutional neural networks), τα οποία αποτελούν μετεξέλιξη των κλασικών τεχνητών νευρωνικών δικτύων (artificial neural networks) και επικεντρώνονται κυρίως σε εφαρμογές αναγνώρισης εικόνας. Τα τεχνητά νευρωνικά δίκτυα αποτελούν μαθηματικά μοντέλα που μιμούνται τη γενική αρχή λειτουργίας του εγκεφάλου, με τους νευρώνες και τις συνάψεις που τους συνδέουν και έχουν ως βασική ιδιότητα την ικανότητα «εκπαίδευσής» τους μέσω της διαδικασίας της εποπτευόμενης μάθησης (supervised learning). Κατά τη διαδικασία αυτή, τα νευρωνικά δίκτυα «εκπαιδεύονται» στο να μοντελοποιούν κάποιο σύστημα μέσω της χρήσης υπαρχόντων δεδομένων που περιγράφουν τη λειτουργία τού προς μοντελοποίηση συστήματος.

Μόλις πρόσφατα τα συνελκτικά νευρωνικά δίκτυα άρχισαν να χρησιμοποιούνται σε γεωπονικές εφαρμογές που σχετίζονται με ανάλυση εικόνας φυτών και οι σχετικές εργασίες δείχνουν ότι τα συγκεκριμένα νευρωνικά δίκτυα βαθιάς μάθησης υπερτερούν κατά πολύ σε απόδοση των κλασικών μεθόδων.

Ανάπτυξη μοντέλου αναγνώρισης ασθενειών

Στο Τμήμα Γεωργικής Μηχανικής του Ινστιτούτου Εδαφοδαιτικών Πόρων αναπτύχθηκε ένα πρότυπο μοντέλο βαθιάς μάθησης για την αναγνώριση ασθενειών φυτών, μέσω της οπτικής

παρατήρησης του φυλλώματός τους. Το μοντέλο βασίστηκε σε συγκεκριμένες αρχιτεκτονικές συνελκτικών νευρωνικών δικτύων, οι οποίες έχουν δοκιμαστεί με μεγάλη επιτυχία στην αναγνώριση προτύπων σε εικόνες.

Για την εκπαίδευση και δοκιμή του μοντέλου χρησιμοποιήθηκε μία ανοικτή βάση δεδομένων που περιέχει 87.848 φωτογραφίες φύλλων υγιών και προσβεβλημένων φυτών. Το φωτογραφικό αυτό υλικό αφορά 58 διαφορετικούς συνδυασμούς φυτού/ασθένειας και υγιών φυτών, περιλαμβάνοντας 25 διαφορετικά είδη υγιών και προσβεβλημένων φυτών, με 35 διαφορετικές ασθένειες. Από τις φωτογραφίες αυτές, οι 55.120 (ποσοστό 62,7%) έχουν ληφθεί σε εργαστηριακές συνθήκες (δηλαδή περιέχουν ένα μόνο φύλλο, σε ομοίμορφο φόντο, π.χ. σε πάγκο εργασίας), ενώ οι 32.728 (ποσοστό 37,3%) έχουν ληφθεί στον αγρό, σε πραγματικές συνθήκες καλλιέργειας. Στην παρακάτω εικόνα φαίνονται κάποια χαρακτηριστικά παραδείγματα των δύο τύπων λήψης, για τρεις τυχαίες κατηγορίες φυτού/ασθένειας. Αξίζει να σημειωθεί, ότι δυστυχώς δεν περιέχουν και οι 58 κατηγορίες φυτού/ασθένειας φωτογραφικό υλικό και των δύο τύπων λήψης: 28 κατηγορίες περιέχουν λήψεις μόνο σε εργαστηριακές συνθήκες, 18 περιέχουν λήψεις μόνο σε πραγματικές συνθήκες και 12 περιέχουν φωτογραφίες και των δύο τύπων λήψης. Επιπρόσθετα, το φωτογραφικό υλικό που έχει ληφθεί σε πραγματικές συνθήκες καλλιέργειας περιέχει αρκετές προβληματικές περιπτώσεις, που δυσκολεύουν την εκπαίδευση ενός συστήματος αυτοματοποιημένης αναγνώρισης. Οι περιπτώσεις αυτές περιλαμβάνουν φωτογραφίες φύλλων με υψηλή αντίθεση φωτεινότητας λόγω εκτεταμένης ή/και έντονης σκίασης, φωτογραφίες με πολλαπλά αντικείμενα και φωτογραφίες όπου το φύλλο του φυτού περιλαμβάνει μικρό ή/και μη-κεντρικό τμήμα της φωτογραφίας.



Αραβόσιτος με κερκόσπορα Μηλιά (υγιής) Τομάτα με αλτερναρίωση

Παραδείγματα φωτογραφιών της βάσης δεδομένων με φύλλα σε εργαστηριακές (αριστερά) και σε πραγματικές συνθήκες στον αγρό (δεξιά).



Προβληματικές συνθήκες λήψης: (α) εκτεταμένη/έντονη σκίαση, (β) & (γ) πολλαπλά αντικείμενα, (δ) φύλλο σε μικρό/μη-κεντρικό τμήμα της φωτογραφίας.

Το φωτογραφικό αυτό υλικό της βάσης δεδομένων χωρίστηκε σε δύο υποσύνολα. Το 80% του συνόλου των φωτογραφιών αποτέλεσε (με τυχαία επιλογή) το σύνολο εκπαίδευσης (training set). Το σύνολο αυτό χρησιμοποιήθηκε στην εκπαίδευση του μοντέλου, ώστε αυτό να αναγνωρίζει την κατηγορία φυτού/ασθένειας (ή υγιούς φυτού) στην οποία ανήκει η κάθε φωτογραφία. Η εκπαίδευση πραγματοποιήθηκε με διαφορετικές αρχιτεκτονικές συνελκτικτών νευρωνικών δικτύων και διάφορες παραμετροποιήσεις, ώστε να δημιουργηθεί το σύστημα με τα πιο ακριβή αποτελέσματα. Το υπόλοιπο 20% του συνόλου των φωτογραφιών αποτέλεσε το σύνολο δοκιμής (testing set) για την αξιολόγηση του μοντέλου σε φωτογραφικό υλικό το οποίο του είναι “άγνωστο”.

Αποτελέσματα - Συμπεράσματα

Το εκπαιδευμένο μοντέλο αναγνώρισης ασθενειών φυτών δοκιμάστηκε στο «σύνολο δοκιμής», δηλαδή στις φωτογραφίες που δε χρησιμοποιήθηκαν για την εκπαίδευσή του. Το ποσοστό επιτυχίας της αναγνώρισης της σωστής κατηγορίας φυτού/ασθένειας ή υγιούς φυτού μεταξύ των 58 κατηγοριών που περιελάμβαναν 25 είδη φυτών και 35 διαφορετικές ασθένειες (λαμβάνοντας υπόψη σε κάθε φωτογραφία την 1^η επιλογή του μοντέλου) έφτασε το 99,53%. Δηλαδή, το μοντέλο δεν έκανε σωστή διάγνωση σε μόλις 82 από τις 17.548 φωτογραφίες που περιελάμβανε το σύνολο δοκιμής (ποσοστό 0,47%). Στην παρακάτω Εικόνα φαίνονται κάποια ενδεικτικά παραδείγματα επιτυχημένων αναγνώρισεων του μοντέλου, με τα ποσοστά βεβαιότητάς του για την κάθε περίπτωση. Η αμέσως επόμενη εικόνα παρουσιάζει κάποια αντιπροσωπευτικά παραδείγματα φωτογραφιών της κατηγορίας «Μπανανιά με μαύρη κηλίδωση», η οποία παρουσίασε σχετικά υψηλό ποσοστό αποτυχίας σε σύγκριση με τις υπόλοιπες κατηγορίες (8,33% ποσοστό αποτυχίας έναντι του γενικού 0,47% στο σύνολο της δοκιμής), λόγω του υψηλού βαθμού σκίασης σε φωτογραφίες που έχουν ληφθεί σε συνθήκες ηλιοφάνειας στον αγρό, το οποίο αποτελεί ένα από τα προβλήματα που δυσκολεύει την αυτοματοποιημένη αναγνώριση, όπως προαναφέρθηκε.



Παραδείγματα επιτυχημένων αναγνώρισεων του μοντέλου σε διάφορες φωτογραφίες του “συνόλου δοκιμής”.



Αντιπροσωπευτικά παραδείγματα επιτυχημένων (πράσινα και πορτοκαλί ορθογώνια) και μη επιτυχημένων (κόκκινα ορθογώνια) αναγνώρισεων του μοντέλου σε φωτογραφίες της κατηγορίας c_5 (Μπανανιά με μαύρη κηλίδωση).

Σύμφωνα με τα αποτελέσματα διαφόρων πειραματισμών για τη διερεύνηση της επίδρασης των συνθηκών λήψης του φωτογραφικού υλικού στην απόδοση του μοντέλου, έγινε σαφές, όπως ήταν εξάλλου αναμενόμενο, ότι η επιτυχής αναγνώριση φωτογραφιών που έχουν ληφθεί σε πραγματικές συνθήκες καλλιέργειας είναι δυσκολότερη από την περίπτωση εργαστηριακών φωτογραφιών. Επίσης, η ύπαρξη μεγαλύτερου ποσοστού τέτοιων φωτογραφιών πραγματικών συνθηκών στα δεδομένα εκπαίδευσης του μοντέλου, αυξάνει δραστικά τον γενικό βαθμό επιτυχίας του. Επομένως, για την περαιτέρω ανάπτυξη και διεύρυνση των μοντέλων αυτών, θα πρέπει να δοθεί έμφαση στη λήψη υλικού εκπαίδευσής τους σε πραγματικές συνθήκες στον αγρό, υπό διάφορες περιβαλλοντικές συνθήκες καθώς και σε διάφορα στάδια ανάπτυξης των φυτών και επίπεδα προσβολής.

Τέλος, θα πρέπει να γίνει σαφές ότι απαιτείται ακόμα πολλή έρευνα ώστε να είναι εφικτή η ανάπτυξη μοντέλων που στην πράξη, δηλαδή σε πραγματικές συνθήκες στο πεδίο, θα έχουν ανάλογα ποσοστά επιτυχίας με το πολύ υψηλό ποσοστό (99,54%) του πειραματικού μοντέλου που αναπτύχθηκε και παρουσιάστηκε σε αυτό το άρθρο. Μπορεί μεν το υψηλό αυτό ποσοστό να επιτεύχθηκε σε άγνωστες για το μοντέλο φωτογραφίες, όμως δεν παύουν να αποτελούν παραπλήσιο υλικό με αυτό που χρησιμοποιήθηκε για την εκπαίδευσή του, αφού ανήκουν στην ίδια βάση δεδομένων.

Τα αποτελέσματα όμως είναι ενδεικτικά των δυνατοτήτων που έχουν οι τεχνικές βαθιάς μάθησης στον τομέα της αυτοματοποιημένης αναγνώρισης ασθενειών φυτών. Επομένως, είναι πλέον θέμα αύξησης της ποσότητας και ποικιλομορφίας των διαθέσιμων δεδομένων καθώς και διερεύνησης των απαιτούμενων χαρακτηριστικών τους και των στοιχείων ποιότητάς τους, ώστε να δημιουργηθούν βελτιωμένα μοντέλα που θα λειτουργούν ικανοποιητικά σε μεγάλο εύρος συνθηκών και θα περιλαμβάνουν ακόμα περισσότερα είδη φυτών και προσβολών ή άλλων προβλημάτων της καλλιέργειας. Αυτό που γίνεται σαφές και από τα αντίστοιχα αποτελέσματα νέων σχετικών εφαρμογών σε διάφορους γεωπονικούς τομείς, είναι ότι η Τεχνητή Νοημοσύνη αποτελεί το μέλλον **και** για τη γεωργία.

Πληροφορίες: Τμήμα Γεωργικής Μηχανικής - Ινστιτούτο Εδαφοδατικών Πόρων, Α. Δημοκρατίας 61, Άγιοι Ανάργυροι 135 61, Αθήνα, τηλ.: 210 2611011, e-mail: k.ferentinos@swri.gr