

مقاله پژوهشی

شناسایی دقیق و سریع نوع بافت خاک مبتنی بر الگوریتم یادگیری عمیق و سامانه بینایی ماشین

رحیم آزادنیا^{*}

چکیده

خاک یکی از مهم‌ترین منابع تولید در کشاورزی محسوب می‌شود. بنابراین با شناسایی دقیق خاک و خصوصیات مهم آن می‌توان به مدیریت صحیح و استفاده پایدار از زمین‌های کشاورزی دست یافت. مطالعه حاضر با هدف شناسایی انواع بافت خاک با استفاده از روش بینایی ماشین و شبکه عصبی پیچشی عمیق انجام شد. مدل کانولوشن ارائه شده از دو بلوک متفاوت تشکیل شده است که شامل انواع لایه‌ها از جمله لایه‌های پیچشی، لایه‌های تجمیع‌کننده بیشینه، لایه‌های هموارساز، لایه برون‌انداز، نرمال‌سازی دسته‌ای، لایه‌های کاملاً متصل و یک طبقه‌بند ماشین بردار پشتیبان بود. این مدل بر روی تصاویر نمونه‌های مختلف خاک (۱۱ نوع بافت و در مجموع ۷۹۰ نمونه) مورد آموزش و آزمون قرار گرفت. این داده‌ها توسط یک سامانه بینایی ماشین و یک دوربین تلفن همراه هوشمند آماده‌سازی شدند. پارامترهای آماری مهم از جمله دقت، صحت، خاصیت، حساسیت و مساحت زیر نمودار به ترتیب ۹۹/۶۵٪، ۹۸/۷۵٪، ۹۹/۸٪، ۹۸/۷۵٪ و ۹۹/۲۷٪ با استفاده از ماتریس اغتشاش محاسبه شد. مدل پیشنهادی توانست با دقت ۹۸/۱٪ تصاویر نمونه‌های خاک را با موفقیت طبقه‌بندی نماید. نتایج به‌دست آمده نشان داد که مدل پیاده‌سازی شده در این مطالعه می‌تواند جایگزین مناسبی برای روش‌های پر هزینه و زمان‌بر آزمایشگاهی تعیین نوع بافت خاک باشد.

واژه‌های کلیدی: بافت خاک، بینایی ماشین، طبقه‌بندی، یادگیری عمیق.

ارجاع: آزادنیا، ر. ۱۴۰۱. شناسایی دقیق و سریع نوع بافت خاک مبتنی بر الگوریتم یادگیری عمیق و سامانه بینایی ماشین. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی. ۲۲: ۶۱-۷۲. DOI: <https://dx.doi.org/10.22034/JRMAM.2022.10089.539>

۱- دانشجوی دکتری، گروه مکانیک بیوسیستم، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران.

* نویسنده مسئول: rahim.azadnia@ut.ac.ir

تاریخ دریافت: ۱۴۰۰/۰۲/۳۰ تاریخ پذیرش: ۱۴۰۰/۰۶/۲۱

مقدمه

نوآوری‌ها و فناوری‌های نوظهور در حوزه کشاورزی باعث پیشرفت‌های چشمگیری در این حوزه شده است. کشاورزی دقیق به یکی از مهم‌ترین بخش‌ها در کشاورزی تبدیل شده است، به خصوص در کشورهایی که زمین‌های بزرگ، برای کشاورزی اختصاص داده شده‌اند (Swetha et al., 2020). خاک یکی از اصلی‌ترین منابع تولید در کشاورزی است، چرا که محیطی مناسب برای استقرار گیاهان، جوانه‌زنی بذر، و همچنین رشد و نمو ریشه‌ها فراهم می‌کند. بنابراین مدیریت صحیح این منبع طبیعی نیازمند شناسایی و مطالعه مناسب خصوصیات آن است (Barrios & Trejo, 2003). طبقه‌بندی نمونه‌های خاک به منظور مدیریت بهینه و استفاده پایدار از زمین زراعی بسیار اهمیت دارد (Boul et al., 2011). نمونه‌های خاک دارای ترکیبات و خصوصیات مختلف محیطی و فیزیکی هستند (Rassol et al., 2006). یکی از مهم‌ترین و اساسی‌ترین ویژگی‌های خاک، بافت خاک است، چرا که بافت، تا حدود زیادی بیانگر خصوصیات فیزیکی، شیمیایی و بیولوژیکی خاک است. بافت خاک به صورت مستقیم با میزان نفوذ هوا و آب، جذب مواد مغذی، حساسیت به فرسایش ذخیره مناسب آب، جوانه‌زنی و ریشه‌زایی محصولات کشاورزی در ارتباط است (Phogat et al., 2015). بافت خاک توسط توزیع اندازه قطر ذرات موجود در آن و توسط روش قراردادی وزارت کشاورزی آمریکا (USDA) مشخص می‌شود. قطر ذرات خاک در گروه رسی کمتر از 0.002 میلی‌متر، در گروه سیلتی بین 0.053 - 0.002 میلی‌متر و در گروه شنی بین 0.075 - 0.053 میلی‌متر است.

آهک زدن، کوددهی، کنترل فرسایش و آبیاری به طور چشم‌گیر به بافت خاک بستگی دارد (Kettler et al., 2001). اطلاع از نوع بافت خاک در مزارع زراعی سبب کاهش در مقادیر متغیرهای ورودی مانند میزان کودها و سموم دفع آفات به محیط زیست می‌شود و رشد محصول در شرایط متنوع را بهبود می‌بخشد (Malhi et al., 2007). بنابراین استفاده از غلظت مناسب متغیرها باعث کاهش در هزینه‌ها، کاهش در آلودگی آب‌های زیرزمینی توسط علف‌کش‌ها، سموم دفع آفات و کودها می‌شود و در نهایت عملکرد محصول را افزایش می‌دهد.

در حال حاضر برای تعیین نوع بافت خاک از روش‌های مکانیکی استفاده می‌شود که شامل نمونه‌برداری، انتقال نمونه‌ها به آزمایشگاه، خشک‌کردن، خرد کردن و الک کردن نمونه‌ها قبل از تعیین نوع بافت است. از مرسوم‌ترین روش‌های مکانیکی می‌توان به روش پیپ (Robinson, 1922) و هیدرومتر (Bouyoucos, 1936) اشاره کرد. این روش‌ها نیازمند آزمایشگاه، صرف زمان و هزینه زیادی هستند و به دلیل استفاده از ترکیبات هیدروژن پراکسید و مواد شیمیایی اکسید کننده، با محیط زیست سازگار نیستند. امروزه با ظهور فن‌آوری‌ها و تکنولوژی‌های پیشرفته به منظور تعیین بافت خاک در بخش کشاورزی از روش‌های جدیدی مانند پرتوهای گاما (Vaz et al., 1999)، ایکس (Andrenelli et al., 2013)، لیزر (Fisher et al., 2017) و طیف‌سنجی مادون قرمز (Jaconi et al., 2019) استفاده می‌شود.

در مطالعه‌ای (Vohland et al., 2014) محتویات شن و رس در نمونه‌های خاک خشک را با استفاده از روش‌های طیف‌سنجی مادون قرمز و تبدیل فوریه بازتاب منتشر شده نور تعیین کردند. آن‌ها در این تحقیق از هیچ گونه ماده شیمیایی استفاده نکردند. مطالعات دیگر در این زمینه با استفاده از پرتو گاما (Vaz et al., 1999)، پرتو ایکس (Andrenelli et al., 2013) و انکسار نور لیزر (Fisher et al., 2017) انجام شده‌اند.

روش‌های اشاره شده هنوز به عنوان روش‌های استاندارد در نظر گرفته نشده‌اند، چرا که نیازمند ابزارهای دقیق و پرهزینه هستند و برای استفاده از آن‌ها باید قبل از تعیین بافت خاک مقدار توزیع ذرات رس، سیلت و شن را محاسبه کرد. این عملیات نیازمند زمان، هزینه و آزمایشگاه مناسب است. علاوه بر روش‌ها و تجهیزات اشاره شده، از سیستم رنگی مانسل (Murti & Stayanarayana, 1971) و رنگ‌سنج‌ها نیز برای شناسایی بافت خاک استفاده می‌شود، اما این روش‌ها توانایی آماری پایینی در طبقه‌بندی بافت خاک دارند.

با پیشرفت فن‌آوری پردازش تصاویر دیجیتال، بینایی ماشین و یادگیری عمیق می‌توان به راحتی ویژگی‌های تصویر نمونه‌های خاک را استخراج و تصاویر را طبقه‌بندی کرد (Elyeznansi et al., 2012). امروزه یادگیری ماشین و سیستم‌های رایانه‌ای به طور فزاینده‌ای در طیف وسیعی از کارها از جستجو در وب گرفته تا استخراج ویژگی‌ها برای

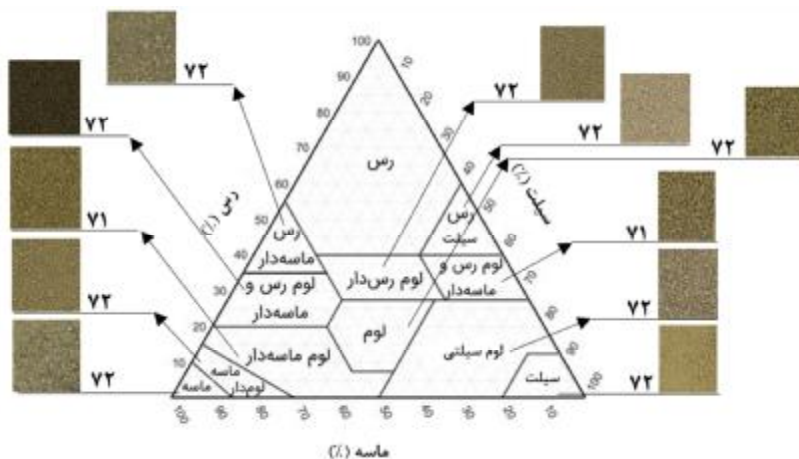
هوشمند یادگیری عمیق استفاده شده است. با توجه به اینکه روش‌های تعیین بافت خاک اشاره شده در بالا زمان‌بر، پرهزینه، نیاز به آزمایشگاه تخصصی و مواد شیمیایی خاص و افراد خبره دارند، لذا در این تحقیق سعی شده است تا با استفاده از تلفیق سامانه بینایی ماشین و الگوریتم یادگیری عمیق، تصاویر نمونه‌های خاک براساس نوع بافتی که دارند، طبقه‌بندی شوند.

مواد و روش‌ها

نمونه‌برداری این تحقیق در ایران، استان آذربایجان غربی (37.5528°N 45.0759°E) و در شهرهای ارومیه، سلماس و خوی انجام گرفت. این مناطق به دلیل دارا بودن اقلیم مناسب و خاک غنی، شرایط لازم برای رشد محصولات کشاورزی را دارند. به طور کلی ۱۰۰ ناحیه از مناطق مختلف برای نمونه‌برداری انتخاب شد. در هر ناحیه از شهرستان‌های مختلف، نمونه‌های متفاوت خاک در عمق‌های مختلف توسط بیلچه‌ای مخصوص و دستی از عمق‌های ۵ و ۱۰ سانتی‌متری جمع‌آوری شدند. در مجموع ۱۴۵۰ نمونه خاک، تهیه و به آزمایشگاه منتقل شدند. مطابق شکل ۱، ۱۱ نوع بافت به‌عنوان نمونه‌های مرجع از میان نمونه‌ها در نظر گرفته و از هر نوع بافت ۷۲ نمونه برای تصویربرداری آماده شدند (در مجموع ۷۹۰ نمونه).

طبقه‌بندی تصاویر، تشخیص چهره با دوربین‌ها و تلفن‌های همراه هوشمند و همچنین تشخیص اشیاء در تصویر مورد استفاده قرار می‌گیرند. در سال‌های اخیر به منظور بهبود عملکرد روش‌های اشاره شده از الگوریتم‌های یادگیری عمیق استفاده می‌شود (LeCun *et al.*, 2015). توانایی و ظرفیت یادگیری در مسائل پیچیده باعث شده است که از الگوریتم یادگیری عمیق در حل مسائل تشخیص الگو و طبقه‌بندی با کارایی بالا استفاده شود (Amara *et al.*, 2017). روش‌های یادگیری عمیق هم‌زمان دو مرحله مهم پردازش تصاویر یعنی استخراج و طبقه‌بندی ویژگی‌ها را با هم ترکیب می‌کند و باعث صرفه‌جویی در زمان و حجم عملیات پردازشی روی تصاویر ورودی می‌شود.

در سال‌های اخیر از روش یادگیری عمیق در حوزه کشاورزی و صنایع غذایی نیز استفاده شده است. از سال ۲۰۱۵ تا کنون مطالعات زیادی در این حوزه انجام شده است که از جمله مهم‌ترین آن‌ها می‌توان به شناسایی اشیاء و طبقه‌بندی اشاره کرد. مطالعاتی مانند طبقه‌بندی انواع برگ‌ها و شناسایی بیماری گیاهان (Hall *et al.*, 2015; Mohanty *et al.*, 2016; Lee *et al.*, 2015) شناسایی و شمارش محصولات کشاورزی از جمله سیب، انبه، گوجه فرنگی و بادام (Sa *et al.*, 2016; Rahneemoonfar & Shaepard, 2017; Chen *et al.*, 2017; Bargoti & Milioto, 2017) و شناسایی علف‌های هرز (Underwood, 2017) از الگوریتم‌های (et al., 2017; McCool *et al.*, 2017)









شکل ۱- تصاویر و مثلث یازده نوع از بافت خاک مطابق USDA

آزمایشگاه مورد استفاده قرار می‌گیرند. روش هیدرومتر به دلیل سادگی، قیمت مناسب و تشخیص سریع نوع بافت خاک نسبت به روش پیپ بیشتر استفاده می‌شود. لذا در

توزیع ذرات موجود در خاک، نوع بافت خاک را مشخص می‌کند. از بین روش‌های موجود و مرسوم، بیشتر هیدرومتر و پیپ به عنوان معمولی‌ترین روش‌ها در

آماده‌سازی نمونه‌ها، میانگین درصد ذرات شن، سیلت و ماسه برای نمونه‌های مربوط به هر یازده نوع بافت خاک توسط روش هیدرومتر اندازه‌گیری شد (شکل ۲) و مطابق با قانون استوکس و روابط بین ذرات نوع بافت هر نمونه مشخص شد.

این تحقیق برای تشخیص نوع بافت نمونه‌های جمع‌آوری شده از روش هیدرومتر استفاده شد. قبل از آزمایش هیدرومتر ذرات ریز و بقایای گیاهی موجود بر روی سطح نمونه‌ها توسط هیدروپراکسید جداسازی شدند. همچنین به منظور دستیابی به نتایج دقیق، از هیدروکلریک اسید برای حذف کربن غیرآلی نیز استفاده شد. بعد از



شکل ۲- توزیع میزان میانگین ذرات رس، سیلت و شن نمونه‌های خاک استفاده شده


شرایط نورپردازی مناسب به طور چشم‌گیر بر روی کیفیت تصاویر گرفته شده تأثیر می‌گذارد. بنابراین به منظور کاهش نوفه‌های ناشی از تداخلات نوریمحیطی، یکجعبه

آماده‌سازی تصاویر

شرایط نوری مناسب با بهبود میزان وضوح، سبب تقویت عملیات پردازش تصاویر می‌شود (Gunasekaran, 1996).

تصویربرداری با کیفیت از نمونه‌ها تنظیم شد. بهترین فاصله بین دوربین و نمونه با سعی و خطا ۱۰ سانتی‌متر به دست آمد. یک الگوریتم پردازش تصویر با زبان برنامه‌نویسی پایتون (Python Software, USA, V3.6) طراحی و کد نویسی شد تا قسمت‌های مورد نظر تصاویر (ROI) گرفته شده توسط دوربین را برش داده و در یک دستگاه رایانه (Asus X555L, CORE i7, 1T H.D.D, 6GB Memory) با فرمت JPEG برای عملیات بعدی ذخیره کند. شکل ۳ مراحل آماده‌سازی تصاویر نمونه‌های خاک را به صورت طرح‌واره نشان می‌دهد.

تصویربرداری مناسب طراحی شد تا از نمونه‌های خاک در شرایط محیطی مناسب تصویربرداری شود. یک حلقه از لامپ‌های LED به منظور روشنایی محیط داخل جعبه به گونه ای قرار گرفت که از ایجاد سایه جلوگیری شود. شدت نور متناسب با نوع و رنگ نمونه به‌راحتی قابل تنظیم بود. تصاویر توسط یک دستگاه تلفن همراه هوشمند (Galaxy A50, SAMSUNG, South Korea,) (16MP camera) گرفته شدند. تنظیمات مربوط به دوربین تلفن همراه هوشمند مانند ISO, White balance, Shutter speed و Focal length نیز به منظور



شکل ۳- طرح‌واره آماده‌سازی تصاویر نمونه‌های خاک

برای کاهش اندازه ابعاد تصاویر استفاده می‌شوند (Farooq & Sazonov, 2017). شبکه‌های کانولوشن مانند شبکه‌های عصبی از لایه‌های متصل به هم تشکیل شده‌اند. آموزش شبکه‌های پیچشی شامل دو مرحله است: (۱) پیش‌انتشار و (۲) پس‌انتشار. در مرحله پیش‌انتشار، خطای شبکه با مقایسه اختلاف بین خروجی شبکه، براساس تصاویر داده شده به شبکه به عنوان ورودی و خروجی واقعی برچسب شده محاسبه می‌شوند. در مرحله پس‌انتشار، پارامترهای شبکه براساس خطای شبکه محاسبه می‌شوند و در گام بعدی هر ماتریس وزن براساس گرادینان محاسبه شده بروزرسانی می‌شود (Rahmoonfar & Shepard, 2017).

شبکه‌های کانولوشن دارای یک‌سری ساختارهای از پیش آموزش دیده متفاوتی هستند که با موفقیت توسط یک مجموعه از داده‌های برچسب گذاری شده مانند ImageNet (شامل ۱۰۰۰ کلاس متفاوت) آموزش داده

توسعه مدل طبقه‌بند

برای طبقه‌بندی تصاویر آماده شده از نمونه‌های خاک، از یک مدل شبکه عصبی پیچشی استفاده شد.

معماری شبکه عصبی پیچشی


شبکه‌های کانولوشن از لایه‌های مختلفی تشکیل شده‌اند که هر یک از لایه‌ها عملیات خاصی را انجام می‌دهند. این شبکه‌ها از لایه‌های کانولوشن (پیچشی)^۱ برای آموزش تصاویر رنگی ورودی استفاده می‌کنند. این لایه‌ها آن دسته از ویژگی‌های سطح پایین مانند لبه‌ها، گوشه‌ها و رنگ‌ها را توسط یک سری فیلتر که هسته نام دارند استخراج می‌کنند. عملگر لایه‌های پیچشی نسبت به حالات چرخشی و انتقالی ثابت هستند و این امر سبب حفظ بهتر فرآیند آموزشی توسط لایه‌ها می‌شود (Dyrmann *et al.*, 2016). لایه‌های تجمیع‌کننده در شبکه‌های کانولوشن

1- Convolutional

فرآیند آموزش به جای شروع از ماتریس وزن‌های تصادفی، از ماتریس وزن شبکه به‌کارگرفته شده شروع می‌شود (Sa *et al.*, 2016). از معمولی‌ترین شبکه‌های از پیش آموزش دیده شده می‌توان به AlexNet (Krizhevsky *et al.*, 2012) و ResNet (He *et al.*, 2016) و GoogleNet (Szegedy *et al.*, 2015) اشاره نمود.

به‌منظور طبقه‌بندی تصاویر نمونه‌های خاک با بافت‌های مختلف، یک مدل کانولوشن VGGNet 16 مطابق شکل ۴ پیاده‌سازی شد تا ۱۱ نوع بافت خاک را طبقه‌بندی کند. بعد از هر لایه ادغام بیشینه، لایه برون‌انداز قرار می‌گیرد. هدف اصلی استفاده از این لایه‌ها، کاهش ابعاد و جلوگیری از بیش‌برازش داده‌ها یا آموزش است.

می‌شوند (Russakovsky *et al.*, 2015). از آنجا که ویژگی‌های استخراج شده توسط این نوع شبکه‌ها برای طبقه‌بندی داده‌های خاصی طراحی شده‌اند، لذا برای طبقه‌بندی تصاویر نمونه‌های خاک نمی‌توان از این نوع ساختار شبکه استفاده کرد. برای رفع این چالش و استفاده مجدد از این مدل‌ها، روش تنظیم دقیق استفاده می‌کنند. در واقع استفاده از مدل‌های کانولوشن از پیش آموزش داده شده برای تعیین وزن‌های شبکه و انتقال ویژگی‌های آموخته شده به یک عملیات جدید (تنظیم دقیق) یک فرآیند کاملاً استاندارد است. باید توجه داشت که در این فرآیند تمامی پارامترهای مدل توسط مجموعه داده‌های جدید بر روزرسانی می‌شوند. به همین دلیل است که



شکل ۴- معماری شبکه VGGNet 16 ارائه شده، شامل دو قسمت ساختار شبکه و بلوک طبقه‌بند (Fouladi *et al.*, 2021)

همچنین یک لایه برون‌انداز بعد از بیشینه لایه ادغام^۲ با گام ۰/۱ استفاده شد. در نهایت به منظور تبدیل خروجی دوبعدی آخرین لایه ادغام بیشینه به خروجی تک بعدی، از یک لایه هموارساز^۳ استفاده شد. لایه‌های پیچشی با لایه‌های ادغام در ارتباط هستند و در نهایت به تعدادی لایه‌های تماماً متصل وصل می‌شوند. به‌منظور کنترل اندازه لایه‌های پیچشی و پر کردن گوشه‌ها و لبه‌ها در داده‌های ورودی از لایه‌گذاری استفاده شد. در بلوک ۲ قبل از لایه هموارساز یک بیشینه لایه ادغام و بعد از آن نیز از یک لایه تماماً متصل^۴ (۱۰۲۴) و یک لایه تماماً متصل (۱۱)

از مجموع ۷۹۰ داده، ۸۰٪ داده‌ها برای آموزش و ۲۰٪ باقی‌مانده برای آزمون شبکه استفاده شد. مطابق با شکل ۴ شبکه پیشنهاد شده از دو بلوک شبکه پیچشی و طبقه‌بند تشکیل شده است. در قسمت بلوک ۱، تصاویر نمونه‌های خاک ۲۵۶×۲۵۶ پیکسل به عنوان ورودی به شبکه داده می‌شود. این بلوک شامل دو لایه پیچشی با طول فیلتر ۶۴، دو لایه پیچشی با طول ۳۲، دو لایه پیچشی با طول ۱۶ و دو لایه پیچشی با طول ۸ بود. اندازه فیلتر ۲×۲ پیکسل برای تمامی لایه‌ها در نظر گرفته شد. به‌منظور ایجاد تغییرات در توزیع داده‌های ورودی بعد از هر لایه پیچشی از یک نرمال‌سازی دسته‌ای^۱ استفاده شد.

2- Max Pooling Layer
3- Flatten Layer
4- Fully Connected Layer

1- Batch Normalization

واقع استفاده از نرم‌سازی دسته‌ای باعث می‌شود که شبکه مورد نظر عمیق‌تر شده و تعداد تکرار برای فرآیندهای آموزش کاهش یابد. با استفاده از معادله (۲) این روش ورودی لایه‌ها را در همان محدوده مقادیر ثابت نگه می‌دارد.

$$y = \frac{x - \mu}{\sqrt{\sigma^2 + \varepsilon}} \gamma + \beta \quad (2)$$

که x دسته فعلی، μ و σ به ترتیب میانگین و انحراف معیار x هستند. پارامترهای β و γ قابل آموزش هستند که بعد از هر دسته بروزرسانی می‌شوند. مقدار کوچک ε نیز به منظور جلوگیری از تقسیم معادله بر صفر اعمال می‌شود (Ioffe & Szegedy, 2015).

لایه‌های تماماً متصل

این لایه‌ها که لایه تراکمی نیز نامیده می‌شوند، مانند شبکه‌های عصبی، تمامی نرون‌های ورودی را به نرون‌های خروجی متصل می‌کنند. بنابراین باعث حذف اطلاعات مکانی می‌شوند (Dyrmann et al., 2016). الگوریتم شبکه ارائه شده در این تحقیق در نرم افزار Python (ver 3.6) با استفاده از کتابخانه Keras در بستر Tensor flow پیاده‌سازی شد تا تمامی فرآیندهای پردازشی و طبقه‌بندی را روی تصاویر نمونه‌های خاک انجام دهد.

ارزیابی عملکرد مدل ارائه شده

یک ماتریس اغتشاش به منظور ارزیابی عملکرد طبقه‌بندی مدل استخراج شد. مقادیر داخل ماتریس اغتشاش کلاس‌های واقعی و پیش‌بینی شده را توسط مدل ارائه شده نشان می‌دهد. مقادیر روی قطر اصلی، طبقه‌بندی صحیح و اعداد روی قطرهای فرعی (غیر اصلی) طبقه‌بندی نادرست نمونه‌ها را نشان می‌دهند. عملکرد مدل کاتولوشن اصلاح شده براساس پارامترهای آماری از جمله دقت، صحت، خاصیت، حساسیت و مساحت زیر منحنی به دست آمد. این مقادیر توسط معادلات (۳) تا (۷) به دست آمدند.

$$\text{Accuracy} = \frac{n_{TP} + n_{TN}}{n_{TP} + n_{TN} + n_{FP} + n_{FN}} \quad (3)$$

$$\text{Precision} = \frac{n_{TP}}{n_{TP} + n_{FP}} \quad (4)$$

$$\text{Specificity} = \frac{n_{TN}}{n_{TN} + n_{FN}} \quad (5)$$

$$\text{Sensitivity} = \frac{n_{TP}}{n_{TP} + n_{FN}} \quad (6)$$

همراه با یک طبقه‌بند ماشین بردار پشتیبان برای طبقه‌بندی ویژگی‌های استخراج شده استفاده شد. لازم به ذکر است که تابع بهینه‌سازی مورد استفاده برای شبکه ارائه شده تابع Adam بود.

در شبکه‌های پیچشی، عمق شبکه نقش عمده‌ای در افزایش دقت طبقه‌بندی دارد، به گونه‌ای که هرگونه افزایش در عمق سبب کاهش خطا در طبقه‌بندی می‌شود (Simonyan & Zisserman, 2014).

بیشینه لایه ادغام (فشرده‌ساز)

بیشینه لایه ادغام، یک لایه نمونه‌برداری زیرین است که سبب کاهش ابعاد نقشه ویژگی می‌شود. در واقع نقشه ویژگی همان خروجی لایه‌های پیچشی یا ادغام است. تابع فعال‌سازی هریک از لایه‌های پیچشی، واحد خطی اصلاح شده نام دارد که مطابق با رابطه (۱) روی هر یک از داده‌های ورودی عملیات ریاضی انجام می‌دهد (Ghazi et al., 2017). لایه‌های بیشینه و میانگین دو نوع از مهم‌ترین لایه‌های ادغام محسوب می‌شوند.

$$f(x) = \begin{cases} x, & \text{if } x > 0 \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

لایه‌های برون انداز

لایه برون انداز^۱ یک روش منظم‌سازی است که بیش‌برازش در آموزش مدل‌های کانولوشن را کاهش می‌دهد. در هر مرحله از فرآیند آموزش، لایه‌های برون‌انداز به صورت تصادفی تعدادی از نرون‌ها را حذف می‌کنند تا به نرون‌های باقی‌مانده اجازه دهند در فرآیند آموزش شرکت کنند، تا وزن آن‌ها بروزرسانی شوند. در واقع این فرآیند به صورت خودکار به نرون‌های باقی‌مانده این امکان را می‌دهد تا بیشتر آموزش ببینند (Srivastava et al., 2014).

لایه‌های نرمال‌سازی دسته‌ای

نرمال‌سازی دسته‌ای این اطمینان را می‌دهد که ورودی‌های لایه‌ها همیشه در همان محدوده لایه‌های قبلی بروزرسانی می‌شوند. این لایه‌ها به دلیل اینکه تغییراتی در توزیع ورودی لایه‌ها براساس لایه‌های قبلی ایجاد می‌کنند، بعد از یک سری فرآیندهای انتقالی بسیار مفید هستند. در

به منظور مقایسه مدل VGGNet16 ارائه شده با مدل‌های یادگیری ماشین، ویژگی‌های بافت و رنگ از تصاویر مربوط به نمونه‌های خاک استخراج شدند (جدول ۱). ویژگی‌های بافتی مختلف با استفاده از روش‌های Gray Level Cooccurrence Matrix (GLCM) و Local Binary Pattern (LBP) استخراج شدند. چندین ویژگی رنگی نیز از فضاهای مختلفی رنگی استخراج شدند. در نهایت ترکیب ویژگی‌های رنگ و بافت با استفاده از مدل‌های SVM، ANN و RF به منظور شناسایی تصاویر بافت خاک استفاده و با مدل یادگیری عمیق پیشنهاد شده، مقایسه شد.

$$AUC = \frac{1}{2} \left(\frac{n_{TP}}{n_{TP} + n_{FN}} + \frac{n_{TN}}{n_{TN} + n_{FP}} \right) \quad (7)$$

که T درست، F نادرست، P مثبت و N منفی است. براین اساس در هر ماتریس اغتشاش چهار گروه می‌توانند وجود داشته باشند که TP نمونه‌هایی که مثبت هستند و صحیح طبقه‌بندی شده‌اند، FP نمونه‌هایی که مثبت بودند اما به نادرستی پیش‌بینی شده‌اند، TN نمونه‌هایی که منفی بودند و به درستی طبقه‌بندی شده‌اند و FN به آن دسته از نمونه‌ها تعلق دارد که منفی بودند و به نادرستی طبقه‌بندی شدند.

استخراج ویژگی‌ها

جدول ۱- ویژگی‌های رنگ و بافت استخراج شده از تصاویر نمونه‌های خاک

ویژگی رنگ		ویژگی بافت ماتریس GLCM		ویژگی بافت LBP	
معادله	ویژگی	معادله	ویژگی	معادله	ویژگی
$\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N P(i,j)$	میانگین سطح خاکستری	$\sum_{i=0}^{Ng} \sum_{j=0}^{Ng} i-j ^2 p(i,j)$	تباين	$\sum_{i=0}^{L-1} Z_i P_d(Z_i)$	میانگین سطح خاکستری
$\left[\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (P(i,j) - \mu) \right]^{1/2}$	انحراف معیار	$\frac{\sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (1 - \mu_i) P_d(i,j)}{\sigma_i \sigma_j}$	همبستگی	$\left(\sum_{i=0}^{L-1} (Z_i - \mu)^2 P_d(Z_i) \right)^{1/2}$	انحراف معیار
σ/μ	ضریب واریانس	$-\sum_{i=0}^{Ng} \sum_{j=0}^{Ng} P_d^2(i,j)$	انرژی	$-\sum_{i=0}^{L-1} P_d(Z_i) \log_2 P_d(Z_i)$	آنتروبی
$\sum_{i=1}^M \sum_{j=1}^N p(i-j)^2$	یکنواختی	$\sum_{i=0}^{Ng-1} (i - \mu)^2 P_d$	واریانس	$\frac{1}{\sigma^4} \sum_{i=0}^{L-1} (Z_i - \mu)^4 Z_i P_d(Z_i)$	گشتاور چهارم

همان‌طور که در جدول ۲ نشان داده شده است میانگین مقادیر پارامترهای عملکرد طبقه‌بند شامل دقت، صحت، حساسیت، خاصیت و مساحت زیر منحنی به ترتیب ۹۹/۶۵٪، ۹۸/۷۵٪، ۹۸/۷۵٪، ۹۸/۸٪ و ۹۹/۲۷٪ به دست آمد. همچنین میانگین مقدار کلی پارامتر دقت برای نمونه‌های خاک ۹۹/۶۵٪ به دست آمد. دقت کلی عملکرد طبقه‌بندی مدل ارائه شده به دو پارامتر حساسیت و خاصیت بستگی دارد. در حالت کلی پارامتر حساسیت نشان می‌دهد که یک مدل چگونه نمونه‌های مثبت را شناسایی و پارامتر خاصیت نشان می‌دهد که مدل چگونه نمونه‌های منفی را شناسایی می‌کند، اما پارامتر دقت چگونگی شناسایی هر دو نمونه‌های منفی و مثبت را با هم تعریف می‌کند. بنابراین اگر دو پارامتر اشاره شده افزایش یابند دقت کلی نیز افزایش پیدا خواهد کرد و هرگونه روند کاهش در پارامترهای حساسیت و خاصیت سبب کاهش دقت خواهد شد (Aggarwal & Agrawal, 2012). با توجه به جدول ۲ به دلیل بالا بودن مقادیر پارامتر

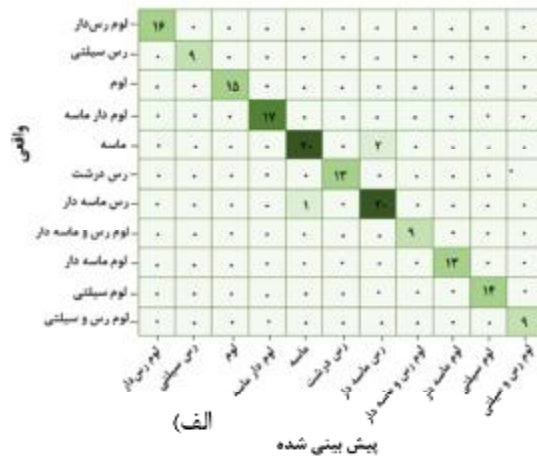
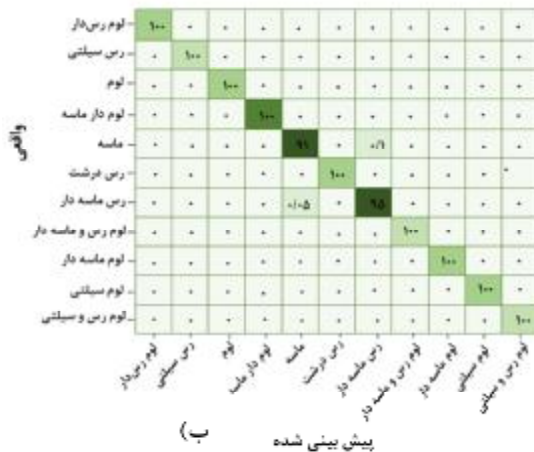
نتایج و بحث

نتایج ماتریس اغتشاش

ماتریس اغتشاش و پارامترهای مربوط به عملکرد ماتریس اغتشاش به منظور ارزیابی عملکرد مدل ارائه شده در پیش‌بینی نوع بافت نمونه‌های خاک به ترتیب در شکل ۵ و جدول ۲ آورده شده‌اند. ماتریس اغتشاش در شکل ۵ توزیع پیش‌بینی‌ها برای هر یک از انواع بافت خاک را نشان می‌دهد. همان‌طور که از ماتریس اغتشاش مشخص است، نمونه‌های لوم رس دار، رس سیلتی، لوم، لوم‌دار ماسه، رس درشت، لوم رس و ماسه‌دار، لوم ماسه‌دار، لوم سیلتی ولوم رس و سیلتی به درستی و با دقت ۱۰۰٪ طبقه‌بندی شده‌اند. دو تصویر از نمونه‌های ماسه به اشتباه، رس ماسه‌دار و یک تصویر نیز از نمونه‌های مربوط به بافت، رس ماسه‌دار به نادرستی ماسه پیش‌بینی شده بودند. هرچند تصاویری که در ماتریس اغتشاش در طبقه‌بندی نادرست قرار گرفتند، نزدیک به قطر اصلی توزیع شده بودند که نشان از نزدیکی این نمونه‌ها به کلاس‌های اصلی بود.

لوم‌دار ماسه، رس درشت، لوم رس و ماسه‌دار، لوم ماسه‌دار، لوم سیلتی ولوم رس و سیلتی و کمترین مقدار این پارامتر نیز برای ماسه و رس ماسه‌دار به دست آمد. این مقادیر نشان می‌دهد که نمونه‌های خاک با بافت‌های ماسه و رس ماسه‌دار کمترین مقدار دقت طبقه‌بندی را نسبت به گروه‌های دیگر داشتند.

حساسیت (۹۸/۷۵٪) و خاصیت (۹۹/۸٪) دقت کلی طبقه‌بندی تصاویر نمونه‌های خاک نیز بالا بود (۹۹/۶۵٪). مساحت زیر نمودار برای بررسی بیشتر دقت طبقه‌بندی مدل پیشنهاد شده کانولوشن محاسبه شد. مساحت زیر نمودار یک رابطه مؤثر در ارزیابی عملکرد یک مدل طبقه‌بند است. مطابق با جدول ۲، بیشترین مقدار ناحیه زیر منحنی برای نمونه‌های لوم رس‌دار، رس سیلتی، لوم،



شکل ۵- توزیع پیش‌بینی شده ۱۱ کلاس از بافت خاک به صورت (الف) ماتریس اغتشاش و (ب) ماتریس اغتشاش نرمال شده

جدول ۲- نتایج عملکرد طبقه‌بندی شبکه اصلاح شده CNN

پارامترهای آماری (%)					نمونه‌های خاک
مساحت زیر نمودار	خاصیت	حساسیت	صحت	دقت	
۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	لوم رس‌دار
۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	رس سیلتی
۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	لوم
۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	لوم دار ماسه
۹۵/۱۵	۹۹/۳	۹۱	۹۵/۲۳	۹۸/۱	ماسه
۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	رس درشت
۹۶/۸۸	۹۸/۵۴	۹۵/۲۳	۹۱	۹۸/۱	رس ماسه دار
۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	لوم رس و ماسه دار
۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	لوم ماسه دار
۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	لوم سیلتی
۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	لوم رس و سیلتی
۹۹/۲۷	۹۹/۸	۹۸/۷۵	۹۸/۷۵	۹۹/۶۵	کلاس/ میانگین

مختلف و ماتریس هم وقوعی به دست آمد. ویژگی‌های استخراج شده به عنوان ورودی به مدل‌های ANN, SVM و RF داده شدند. مطابق با جدول ۳ از بین الگوریتم‌های یادگیری ماشین اشاره شده مدل SVM دقت بیشتری نسبت به مدل‌های ANN و RF داشت. طبقه‌بندی تصاویر نمونه‌های خاک بر اساس ویژگی‌های بافتی، نتایج بهتری

مقایسه دقت مدل CNN با سایر روش‌های یادگیری ماشین

جدول ۳ دقت طبقه‌بندی تصاویر نمونه‌های خاک با بافت‌های مختلف را توسط مدل اصلاح شده کانولوشن و سایر روش‌های یادگیری ماشین نشان می‌دهد. برای این منظور ویژگی‌های رنگ و بافت به ترتیب از فضای رنگی

آماده‌سازی تصویر، انتخاب ویژگی‌های استاندارد و یک مدل طبقه‌بند بهینه در استفاده از الگوریتم‌های مبتنی بر استخراج دستی ویژگی برای دستیابی به نتایج بهتر ضروری است. بنابراین مدل اشاره شده در این مطالعه علاوه بر اینکه پیچیدگی چندان نداشت، بلکه توانست تصاویر نمونه‌های خاک را با دقت ۹۸/۱٪ دقت طبقه‌بندی کند.

نسبت به ویژگی‌های رنگی به دنبال داشت. برخلاف مدل‌های یادگیری ماشین، شبکه‌های کانولوشن می‌توانند با تقسیم عمق و وزن شبکه بین گره‌ها، به طور خودکار و همزمان استخراج و انتخاب ویژگی‌ها را انجام دهند که می‌تواند به کاهش بیش‌برازش داده‌ها کمک کند و از بار محاسباتی طولانی بکاهد (Abdel-Hamid et al., 2013). برخلاف مدل اشاره‌شده کنترل شرایط نورپردازی برای

جدول ۳- مقایسه عملکرد مدل کانولوشن ارائه شده در این مطالعه و الگوریتم‌های مبتنی بر استخراج ویژگی

نتایج آزمون		نتایج آموزش		ویژگی	مدل	عملیات
RMSE	R ²	RMSE	R ²			
۰/۳۷۳	۰/۷۹۱	۰/۲۶۲	۰/۷۹۴	رنگ	ANN	
۰/۲۳۱	۰/۸۲۹	۰/۲۴۸	۰/۸۱۶	بافت		
۰/۳۴	۰/۷۳۳	۰/۳۳۸	۰/۷۵	رنگ	RF	طبقه‌بندی تصاویر نمونه‌های خاک
۰/۳۳۸	۰/۷۳۹	۰/۳۲۶	۰/۷۵۳	بافت		
۰/۲۲۵	۰/۸۳۱	۰/۲۲۱	۰/۸۴۳	رنگ	SVM	
۰/۲۵۷	۰/۸۲۵	۰/۲۰۳	۰/۸۶۷	بافت		
۰/۰۳۶	۰/۹۴۵	۰/۰۲۳	۰/۹۸۱	تصاویر رنگی	CNN ^{Modified}	

قالب‌های نرم‌افزاری مانند یک اپلیکیشن تلفن همراه برای کشاورزان و محققان در زمینه مدیریت منابع ورودی خاک‌های کشاورزی بسیار مفید باشد و تا حد زیادی در صرف هزینه و زمان آن‌ها صرفه‌جویی شود.

منابع

- Abdel-Hamid, O., Deng, L., & Yu, D. (2013). Exploring convolutional neural network structures and optimization techniques for speech recognition. In *Interspeech*, 11: 73-5.
- Aggarwal, N., & Agrawal, R. K. (2012). First and Second Order Statistics Features for Classification of Magnetic Resonance Brain Images. *Journal of Signal and Information Processing*, 3, 146-153.
- Amara, J., Bouaziz, B., & Algergawy, A. (2017). A deep learning-based approach for banana leaf diseases classification. *Datenbanksysteme für Business, Technologie und Web (BTW 2017)-Workshopband*.
- Andrenelli, M. C., Fiori, V., & Pellegrini, S. (2013). Soil particle-size analysis up to 250 μm by X-ray granulometer: device set-up and regressions for data conversion into pipette-equivalent values. *Geoderma*, 192: 380-393.
- Bargoti, S., & Underwood, J. (2017). Deep fruit detection in orchards. In *2017 IEEE International Conference on Robotics and Automation (ICRA)* (pp. 3626-3633). IEEE.

نتیجه‌گیری

تعیین نوع بافت خاک به منظور مدیریت و استفاده پایدار از زمین‌های کشاورزی از اهمیت بالایی برخوردار است. در حال حاضر روش‌های تعیین نوع بافت خاک زمان‌بر، پرهزینه و نیازمند کاربر متخصص است. تحقیق حاضر با هدف شناسایی نوع بافت نمونه‌های مختلف خاک انجام گرفت. در این مطالعه از الگوریتم VGGNet16 که دارای ۸ لایه پیچشی و ۴ لایه تجمیع‌کننده بود و به‌منظور طبقه‌بندی تصاویر ۱۱ نوع بافت خاک شامل لوم رس‌دار، رس سیلتی، لوم، لوم‌دار ماسه، رس درشت، لوم رس و ماسه‌دار، لوم ماسه‌دار، لوم سیلتی ولوم رس و سیلتی، ماسه و رس ماسه‌دار استفاده شد. ورودی مدل پیشنهاد شده، ویژگی‌های استخراج شده از تصاویر رنگی نمونه‌های خاک بودند. میانگین پارامترهای دقت، صحت، خاصیت، حساسیت و مساحت زیر نمودار به ترتیب ۹۹/۶۵٪، ۹۸/۷۵٪، ۹۹/۸٪، ۹۸/۷۵٪ و ۹۹/۲۷٪ به دست آمد. نتایج به‌دست آمده نشان داد که مدل پیاده‌سازی شده کانولوشن توانست نمونه‌های خاک با بافت‌های مختلف را با دقت ۹۸/۱٪ طبقه‌بندی کند، که پتانسیل بالای این روش در تشخیص نوع بافت خاک را نشان می‌دهد. بنابراین مدل ارائه شده در این مطالعه می‌تواند در

- In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 770-778.
- Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning*, 448-456
- Jaconi, A., Vos, C., & Don, A. (2019). Near infrared spectroscopy as an easy and precise method to estimate soil texture. *Geoderma*, 337: 906-913.
- Kettler, T. A., Doran, J. W., & Gilbert, T. L. (2001). Simplified method for soil particle-size determination to accompany soil-quality analyses. *Soil Science Society of America Journal*, 65(3): 849-852.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25: 1097-1105.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lee, S. H., Chan, C. S., Wilkin, P., & Remagnino, P. (2015). Deep-plant: Plant identification with convolutional neural networks. In *2015 IEEE international conference on image processing, (ICIP)*, 452-456.
- Malhi, S. S., Johnson, A. M., & Grant, C. A. (2007). Nitrogen fertilization management for no-till cereal production in the Canadian great plains. In *Soils and Crops Workshop*.
- McCool, C., Perez, T., & Upcroft, B. (2017). Mixtures of lightweight deep convolutional neural networks: Applied to agricultural robotics. *IEEE Robotics and Automation Letters*, 2(3): 1344-1351.
- Milioto, A., Lottes, P., & Stachniss, C. (2017). REAL-TIME BLOB-WISE SUGAR BEETS VS WEEDS CLASSIFICATION FOR MONITORING FIELDS USING CONVOLUTIONAL NEURAL NETWORKS. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, 4.
- Murti, G. K., & Satyanarayana, K. V. S. (1971). Influence of chemical characteristics in the development of soil colour. *Geoderma*, 5(3): 243-248.
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in plant science*, 7: 14-19.
- Phogat, V. K., Tomar, V. S., & Dahiya, R. I. T. A. (2015). Soil physical properties. *Soil Science: An Introduction*, 135-171.
- Rahnemoonfar, M., & Sheppard, C. (2017). Deep count: fruit counting based on deep
- Barrios, E., & Trejo, M. T. (2003). Implications of local soil knowledge for integrated soil management in Latin America. *Geoderma*, 111(3-4): 217-231.
- Bouyoucos, G. J. (1936). Directions for making mechanical analyses of soils by the hydrometer method. *Soil Science*, 42(3): 225-230.
- Buol, S. W., Southard, R. J., Graham, R. C., & McDaniel, P. A. (2011). *Soil genesis and classification*. John Wiley & Sons.
- Chen, S. W., Shivakumar, S. S., Dcunha, S., Das, J., Okon, E., Qu, C., & Kumar, V. (2017). Counting apples and oranges with deep learning: A data-driven approach. *IEEE Robotics and Automation Letters*, 2(2): 781-788.
- Dyrmann, M., Karstoft, H., & Midtiby, H. S. (2016). Plant species classification using deep convolutional neural network. *Biosystems Engineering*, 151: 72-80.
- Elyeznasni, N., Sellami, F., Pot, V., Benoit, P., Vieublé-Gonod, L., Young, I., & Peth, S. (2012). Exploration of soil micromorphology to identify coarse-sized OM assemblages in X-ray CT images of undisturbed cultivated soil cores. *Geoderma*, 179: 38-45.
- Farooq, M., & Sazonov, E. (2017). Feature extraction using deep learning for food type recognition. In *International conference on bioinformatics and biomedical engineering* (pp. 464-472). Springer, Cham.
- Fisher, P., Aumann, C., Chia, K., O'Halloran, N., & Chandra, S. (2017). Adequacy of laser diffraction for soil particle size analysis. *PloS one*, 12(5): 176-510.
- Fouladi, S., Ebadi, M. J., Safaei, A. A., Bajuri, M. Y., & Ahmadian, A. (2021). Efficient deep neural networks for classification of COVID-19 based on CT images: Virtualization via software defined radio. *Computer communications*, 176: 234-248.
- Ghazi, M. M., Yanikoglu, B., & Aptoula, E. (2017). Plant identification using deep neural networks via optimization of transfer learning parameters. *Neurocomputing*, 235: 228-235.
- Gunasekaran, S. (1996). Computer vision technology for food quality assurance. *Trends in Food Science & Technology*, 7(8): 245-256.
- Hall, D., McCool, C., Dayoub, F., Sunderhauf, N., & Upcroft, B. (2015, January). Evaluation of features for leaf classification in challenging conditions. In *2015 IEEE Winter Conference on Applications of Computer Vision*, 797-804.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition

- simulated learning. *Sensors*, 17(4): 905.
- Richardson, J. L., & Daniels, R. B. (1993). Stratigraphic and hydraulic influences on soil color development. *Soil color*, 31: 109-125.
- Robinson, G. W. (1922). A new method for the mechanical analysis of soils and other dispersions. *The Journal of Agricultural Science*, 12(3): 306-321.
- Rossel, R. V., Minasny, B., Roudier, P., & Mcbratney, A. B. (2006). Colour space models for soil science. *Geoderma*, 133: 320-337.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., & Fei-Fei, L. (2015). Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115(3): 211-252.
- Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T., & McCool, C. (2016). Deepfruits: A fruit detection system using deep neural networks. *sensors*, 16(8): 1222.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1): 1929-1958.
- Swetha, R. K., Bende, P., Singh, K., Gorthi, S., Biswas, A., Li, B., & Chakraborty, S. (2020). Predicting soil texture from smartphone-captured digital images and an application. *Geoderma*, 376(11): 45-62.
- Vaz, C. M. P., de Mendonça Naime, J., & Macedo, Á. (1999). Soil particle size fractions determined by gamma-ray attenuation. *Soil science*, 164(6): 403-410.
- Vohland, M., Ludwig, M., Thiele-Bruhn, S., & Ludwig, B. (2014). Determination of soil properties with visible to near-and mid-infrared spectroscopy: Effects of spectral variable selection. *Geoderma*, 223: 88-96.