



فصلنامه علوم محیطی، دوره بیستم، شماره ۴، زمستان ۱۴۰۱

۳۷-۵۲

مقاله پژوهشی

## طبقه بندی محصولات کشاورزی با شبکه کانولوشنی عمیق مبتنی بر شاخص محصول

محمد رضا گیلی\*، داود عاشورلو، حسین عقیقی، علی اکبر متکان و علی رضا شکیبیا

مرکز سنجش از دور، دانشکده علوم زمین، دانشگاه شهید بهشتی، تهران، ایران

تاریخ دریافت: ۱۴۰۰/۹/۱۲ تاریخ پذیرش: ۱۴۰۱/۲/۱۰

گیلی، م.ر.، د. عاشورلو، ح. عقیقی، ع.ا. متکان و ع.ر. شکیبیا. ۱۴۰۱. طبقه بندی محصولات کشاورزی با شبکه کانولوشنی عمیق مبتنی بر شاخص محصول. فصلنامه علوم محیطی. ۲۰(۴): ۳۷-۵۲.

**سابقه و هدف:** با توجه به اینکه کشاورزی مهمترین نقش را در تأمین امنیت غذایی برعهده دارد، تهیه نقشه ای که پراکندگی مکانی، وسعت اراضی و نوع محصولات کشت شده را با دقت بالایی نشان دهد، بسیار ضروری است. پوشش اراضی کشاورزی در فواصل زمانی نسبتاً کوتاه، بسیار پویا و متغیر است. این موضوع، طبقه بندی محصولات زراعی روی تصاویر ماهواره ای را به کاری چالش برانگیز مبدل می کند. کمبود یا فقدان داده های دارای نقاط کنترل زمینی نیز مزید بر علت است. بنابراین روش هایی که به نمونه های زمینی وابستگی کمتری دارند و از ویژگی های فنولوژیک حاصل از سری زمانی باندها و شاخص های گیاهی برای طبقه بندی محصولات استفاده می کنند، مناسب تر خواهند بود. هدف از این مطالعه استفاده از روش یادگیری عمیق مبتنی بر شبکه های عصبی کانولوشن (Convolutional Neural Network (CNN)) برای طبقه بندی محصولات کشاورزی و بهبود عملکرد این شبکه از طریق استفاده از کانال های ویژگی محصولات بعنوان تصویر ورودی به شبکه و افزایش دقت طبقه بندی است.

**مواد و روش ها:** در این مطالعه از تصاویر باندهای مرئی و فرورسرخ نزدیک ماهواره سنتینل-۲ در ۱۰ تاریخ مختلف از سال ۲۰۱۹ برای ناحیه ای واقع در ایالت آیداهو ایالات متحده آمریکا که یک منطقه مهم کشاورزی به شمار می رود و از لایه داده های زراعی (Cropland Data Layer) برای استخراج برچسب نوع محصولات در مزارع نمونه، استفاده گردید. سپس در نرم افزار متلب، سری زمانی باندها ساخته شد و با استفاده از آنها پروفیل زمانی NDVI برای شناسایی ویژگی های فنولوژیکی منحصر به فرد برای هر محصول استخراج گردید. در ادامه توابعی که بر اساس ویژگی های فنولوژیک هر محصول توسعه داده شده اند، بر روی سری زمانی باندها اعمال گردید و برای هر محصول یک کانال ویژگی به دست آمد که در دو فرآیند جداگانه، یکبار از باندها و بار دیگر از کانال های ویژگی به عنوان ورودی به شبکه CNN استفاده گردید و شبکه، با استفاده از کانال های ورودی و نمونه های زمینی، آموزش دیده و نتیجه عملکرد شبکه در طبقه بندی محصولات زراعی در سایت تست، مورد مقایسه قرار گرفت.

**نتایج و بحث:** در مرحله اول، سری زمانی باندها، ورودی شبکه کانولوشنی عمیق را تشکیل دادند و شبکه در ناحیه آموزش، با استفاده از

\* Corresponding Author: Email Address. m\_gili@sbu.ac.ir

<http://dx.doi.org/10.52547/envs.2022.1126>

<http://dorl.net/dor/20.1001.1.17351324.1401.20.4.3.8>

اطلاعات طیفی-زمانی باندها به عنوان کانال‌های ورودی و نمونه های زمینی محصولات به عنوان برچسب، آموزش دید. به دلیل همپوشانی طیفی محصولات در برخی از دوره های زمانی، آموزش شبکه با خطای نسبتاً بالایی همراه بود و به همین دلیل برای ناحیه تست، دقت کلی طبقه بندی ۶۹ (درصد) و ضریب کاپای ۰/۵۵ به دست آمد. در مرحله دیگر، توابعی که به عنوان شاخص‌های فنولوژیک برای هر محصول توسعه داده شده بود، روی سری زمانی باندها اعمال گردید و برای هر محصول، یک کانال ویژگی بعنوان شاخص انحصاری آن محصول، به دست آمد. آنگاه الگوریتم با استفاده از این کانال‌های ویژگی، در ناحیه تست اجرا گردید و دقت کلی به ۸۶ (درصد) و ضریب کاپا به ۰/۸۲ ارتقا یافت که نشان دهنده بهبود چشمگیر نتایج در مقایسه با حالت قبل است.

**نتیجه‌گیری:** شبکه کانولوشنی عمیق برای تشخیص محصولات کشاورزی، به نوع کانال‌های ورودی بسیار حساس است و انتخاب کانال‌هایی با ویژگی‌های طیفی-زمانی مناسب برای انواع محصولات، بر دقت آموزش شبکه بسیار تاثیرگذار بوده و می تواند هزینه یا خطای آموزش شبکه کانولوشنی عمیق را پایین آورده و کارایی آن را در طبقه بندی محصولات گوناگون، بالا ببرد.

**واژه‌های کلیدی:** سری زمانی تصاویر، طبقه بندی، محصولات کشاورزی، پروفیل زمانی NDVI، ویژگی های فنولوژیک، شبکه‌های کانولوشنی عمیق.

## مقدمه

کشت شوند و نوع محصول کشت شده، متفاوت از دوره قبل باشد. بنابراین، پوشش اراضی کشاورزی بسیار پویا و متغیر است.

این موضوع باعث می گردد که روی تصاویر ماهواره‌ای، مزارع مربوط به محصولات مختلف در برخی از روزهای تقویم زراعی علیرغم تفاوت در نوع محصول، با یکدیگر شباهت‌های طیفی داشته باشند. همچنین اراضی مرتبط با یک محصول خاص نظیر گندم نیز به دلایل متعددی نظیر آبی یا دیم بودن، نوع رقم زراعی، اختلاف زمانی کاشت و شرایط متفاوت آبیاری و خاک، متفاوت ظاهر شوند.

در تحقیقی در شمال آلمان، از ترکیب تصاویری راداری سنجنده Sentinel-1 و اطلاعات متوالی فنولوژیکی زمین‌های زراعی به منظور تهیه نقشه محصولات نظیر ذرت، کزله، چغندر قند و سیب‌زمینی استفاده گردید و امتیاز F برابر ۰/۸ به دست آمد. در این مطالعه محققین بیان داشتند که افزایش اختلافات طیفی درون کلاسی (میان یک نوع محصول در مزارع گوناگون) به همراه افزایش شباهت‌های طیفی میان انواع محصولات، کار طبقه‌بندی محصولات زراعی روی تصاویر ماهواره‌ای و تهیه نقشه محصولات کشاورزی را به کاری چالش برانگیز مبدل می کند (Bargiel et al., 2017). این امر به ویژه در تصاویر چند طیفی با تعداد محدود باند طیفی کاملاً مشهود است (Esch et al., 2014; Peña-Barragán et al., 2011) زیرا

با ظهور تعداد بیشتری از داده های سنجش از دور، روش های مبتنی بر تصاویر ماهواره‌ای به رویکرد غالب نقشه برداری از پوشش زمین تبدیل می شوند و نقشه‌هایی از نوع محصول با وضوح و مقیاس های مختلف تولید می‌کنند (Azzari and Lobell, 2017).

با توجه به اینکه کشاورزی مهمترین نقش را در تأمین امنیت غذایی برعهده دارد (Johnston and Kilby, 1989)، تهیه نقشه ای که پراکندگی مکانی، وسعت اراضی و نوع محصولات کشت شده را با دقت بالایی نشان دهد، برای سیستم های پشتیبانی تصمیم گیری از برنامه های دولتی و کشاورزی از جمله برقراری امنیت غذایی، طراحی الگوهای مناسب کشت، تأمین زنجیره انواع تدارکات مورد نیاز نظیر کودها و ماشین آلات کشاورزی، دسترسی به آمار و اطلاعات وضعیت تولید، بیمه محصولات کشاورزی، تنظیم بازار و تعیین قیمت محصولات بسیار ضروری است (Kang et al., 2009; Mingwei et al., 2008; Ramankutty et al., 2018).

پوشش اراضی کشاورزی بر خلاف بیشتر انواع پوشش‌های زمین، در فواصل زمانی کوتاه، بسیار متغیر است. زیرا فنولوژی گیاهان زراعی در طول دوره کاشت تا برداشت، چندین بار تغییر می کند. همچنین بسیاری از اراضی کشاورزی در طول یکسال زراعی ممکن است بیش از یک بار

ابعاد بالا به جای داده های سنجش از دور چند زمانه طراحی شده اند و در آنها الگوهای متوالی نهفته در پروفایل های سری زمانی، به طور صریح مورد استفاده قرار نمی گیرد. بنابراین نیاز به ساخت ویژگی های دست ساز یا از پیش تعریف شده در مجموعه متغیرهای ورودی دارند. از آنجا که مهندسی دستی و توسعه ویژگی ها یا استفاده از توابع از پیش تعریف شده به دلیل تنوع پیچیده هیبریدها، شرایط هواشناسی و مکانیزم های پراکندگی نور، کاری بسیار وقت گیر و چالش برانگیز بوده و نیز با توجه به دسترسی به تعداد محدودی از معیارهای فنولوژیک قبل از پایان فصل رشد، این روش ها برای تولید نقشه های محصول در فصل مناسب نیستند (Xu et al., 2020).

شایان ذکر است که مهمترین محدودیت طبقه بندی دقیق محصولات زراعی به خصوص در مناطق وسیع، کمبود یا فقدان داده های دارای برجسب واقعیت زمینی است. تهیه بانک اطلاعاتی این داده ها که حاوی موقعیت اراضی و نوع محصولات کشت شده در آنها است اگر چه برای استخراج پارامترهای آماری-طیفی محصولات، ویژگی های فنولوژیک آنها و همچنین آموزش انواع مختلف مدل های طبقه بندی یادگیری نظارتی ضروریست، اما کاری بسیار هزینه بر، زمانبر و دشوار است (Gadiraju and Vatsavai, 2020).

بنابراین روش هایی که به نمونه های زمینی وابستگی کمتری دارند و قادرند ویژگی های فنولوژیک را از سری های زمانی تصاویر استخراج کنند مناسبتر خواهند بود (Ashourloo et al., 2020). پیشرفت های اخیر در یادگیری عمیق نشان داده است که شبکه های عصبی عمیق می توانند روابط پیچیده ای را از داده های با ابعاد بالا کشف کنند (LeCun et al., 2015). شبکه عصبی کانولوشن (CNN) یکی از معماری های برجسته یادگیری عمیق است که می تواند به طور موثر داده های متوالی را پردازش کند. CNN برای استخراج ویژگی های چند سطحی مکانی و طیفی مورد تأیید قرار گرفته اما به ندرت در دامنه زمانی به کار گرفته شده است (Huang et al., 2018; Zhong et al., 2019).

اگر فقط در یک زمان نامناسب از یک تصویر چند طیفی استفاده گردد ممکن است دقت نقشه برداری به شدت محدود شود (Shelestov et al., 2017).

بنابراین در نقشه برداری محصولات کشاورزی بر پایه تجزیه و تحلیل مشاهدات سنجش از دور، توسعه رویکردهای چند زمانه بسیار مورد توجه قرار گرفته و در مطالعات متعددی از مشاهدات ماهواره ای چند زمانه در مدل های یادگیری ماشین از جمله درخت تصمیم، جنگل تصادفی و ماشین بردار پشتیبان استفاده شده است (Khatami et al., 2017; King et al., 2017).

Zheng et al. (2004) توانایی ماشینهای بردار پشتیبان را در تشخیص انواع مختلف محصولات آبی مورد بررسی قرار داده و با استفاده از داده های سری زمانی NDVI حاصل از تصاویر لندست، ۳ گونه محصول اصلی را با دقت کلی بهتر از ۸۶٪ استخراج نمودند. آنها پتانسیل استفاده از تصاویر چند زمانی لندست را در پایش سیستماتیک انواع محصول و الگوهای کشت آنها در طول زمان، در مناطق بایر و نیمه بایر به اثبات رساندند. در این تحقیق مشکل ترین بخش، جداسازی گندم از جو به علت ساختار فنولوژیکی رشد شبیه به هم این دو محصول عنوان گردیده است.

در تحقیقی دیگر Liu et al. (2017) نقشه اراضی زیر کشت گندم را با استفاده از داده های چند زمانه و چند منبعی، و الگوریتم جنگل تصادفی تهیه نمودند. آنها از تصاویر لندست ۸ و GF-1 WFV در شش مقطع زمانی طول رشد گندم استفاده کرده و کار طبقه بندی را با دو کلاس گندم و غیر گندم انجام داده و با دقت کلی ۹۲/۹ و ضریب کاپای ۰/۸۵ درصد نقشه اراضی زیر کشت گندم را تهیه نمودند. آنها از ۳۶ باند تصویر و تعداد ۱۲ شاخص گیاهی (شاخص های NDVI و SAVI در شش مقطع زمانی) و در کل ۴۸ ویژگی را بعنوان ورودی الگوریتم در نظر گرفته و تعداد بهینه درخت جنگل تصادفی را با توجه به خطای خارج از کیسه، ۱۰۰ درخت تخمین زدند.


مدل های فوق در اصل برای پردازش داده های غیر زمانی با

کشت محصولات مختلف در برنامه ریزی های مرتبط با تأمین امنیت غذایی و آمایش کشاورزی، این تحقیق با هدف بررسی تاثیر شاخص های فنولوژیک توسعه داده شده برای هر محصول در بهبود عملکرد شبکه کانولوشنی عمیق در طبقه بندی محصولات کشاورزی و در نتیجه دستیابی به اطلاعاتی دقیق تر برای انجام برنامه ریزی های یاد شده، انجام پذیرفت که می توان در تحقیقات بعدی و برای مقایسه با سایر روش های طبقه بندی، از آن بهره جست.

## مواد و روش ها

### منطقه مطالعاتی

با توجه به در دسترس بودن داده های واقعیت زمینی، ناحیه ای واقع در ایالت آیداهو در شمال غربی ایالات متحده آمریکا که دارای آب و هوای سرد کوهستانی است و از مناطق مهم کشاورزی در آن کشور به شمار می رود، برای مطالعه در نظر گرفته شده است. آن ایالت دارای محصولات عمده ای مانند سیب زمینی، گندم و چغندر قند می باشد. موقعیت جغرافیایی منطقه مورد مطالعه در محدوده طول ۱۱۲.۱ تا ۱۱۳.۵ غربی و عرض ۴۲.۳ تا ۴۳.۳ شمالی قرار دارد. شکل ۱، موقعیت منطقه مطالعاتی را نشان می دهد:




شکل ۱- محدوده جغرافیایی منطقه مورد مطالعه  
Fig. 1- Geographical border of the study area

این الگوریتم در صورت آموزش صحیح شبکه و داشتن دقت مناسب، بدون نیاز به جمع آوری مجدد نمونه های آموزشی، در مناطق دیگر یا در سالهای آتی، می تواند برای تهیه نقشه محصولات کشاورزی استفاده می شود (Zhong et al., 2019b). از این رو در مقایسه با سایر روش های موجود، بسیار سریعتر و کم هزینه تر می باشد.

بنابراین در این مطالعه، با هدف استفاده از CNN در دامنه های مکانی، طیفی و زمانی به منظور استخراج دقیق تر نقشه محصولات زراعی، در مرحله اول، سری زمانی تصاویر ماهواره ای، وارد شبکه CNN شده و با استفاده از نقاط کنترل زمینی، آموزش دیده، در منطقه تست اجرا و دقت طبقه بندی محاسبه می گردد. در مرحله دوم، توابع فنولوژیک توسعه داده شده برای هر محصول، روی سری زمانی باندها اعمال و یک کانال ویژگی بعنوان شاخص انحصاری آن محصول، استخراج می گردد. در ادامه، کانال های ویژگی حاصل، وارد الگوریتم CNN شده و بدون تعیین هیچ آستانه ای، الگوریتم با استفاده از نمونه های زمینی، آموزش دیده و در منطقه تست، کانال های ویژگی، طبقه بندی و نقشه محصولات به همراه معیار ارزیابی دقت، ارائه خواهد شد. در پایان هم نتیجه دو مرحله با هم مقایسه خواهد شد. با توجه به لزوم نیاز به اطلاعات دقیقتر در خصوص وسعت و پراکندگی مکانی

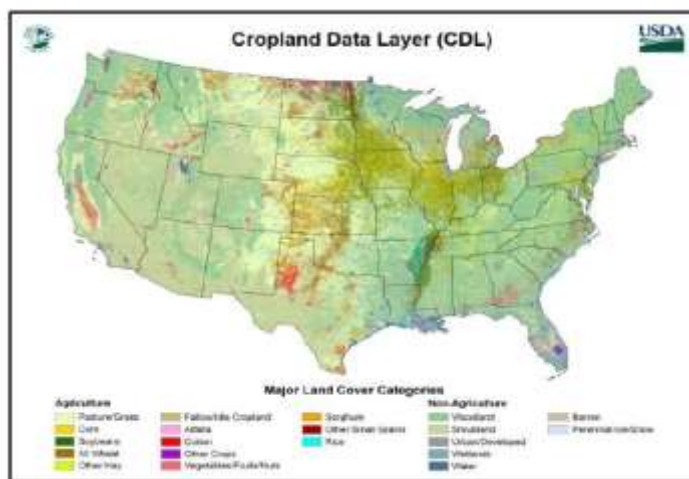
دوره رشد محصولات و عدم پوشش ابر، از تصاویر ۱۰ تاریخ متفاوت در سال ۲۰۱۹ میلادی شامل باندهای مرئی (Blue: B, Green: G, Red: R) و فرورسرخ نزدیک (Near infrared: NIR) استفاده شد. شکل ۲، تاریخ اخذ تصاویر استفاده شده را بر اساس تعداد روزهای سپری شده از اول سال میلادی (Julian Days) نشان می دهد:



شکل ۲- تاریخ اخذ تصاویر استفاده شده بر اساس Julian Day

Fig. 2- Acquisition dates of Images based on Julian Day

درخت تصمیم، تهیه و منتشر می شود. تولید این لایه بر پایه بهره گیری از ماهواره های ایتیکی است که داده های زمینی مورد نیاز از طریق آژانس خدمات کشاورزی آمریکا و داده های کمکی نیز از سازمان زمین شناسی آمریکا فراهم می شوند (Boryan *et al.*, 2011). از این لایه برای استخراج برچسب نوع محصولات در مزارع نمونه، استفاده گردید. شکل ۳، لایه داده های زراعی در سال ۲۰۱۹ را نشان می دهد:



شکل ۳- لایه داده های زراعی ایالات متحده آمریکا

Fig. 3- Cropland data layer of the USA in 2019 (Sandborn *et al.*, 2019)

مبتنی بر فنولوژی برای تهیه نقشه محصولات، معمولاً از سری زمانی شاخص های طیفی گیاهی مانند NDVI (شاخص پوشش گیاهی تفاضلی نرمال شده)، EVI (شاخص

### تصاویر ماهواره ای مورد استفاده

با توجه به اینکه ماهواره های A و B سنتینل-۲ دارای زمان بازدید مجدد ۵ روزه می باشد و در طیفهای مرئی و فرورسرخ، تصاویر با تفکیک مکانی ۱۰ و ۲۰ متر تصویر برداری می کند برای پایش مداوم مزارع کشاورزی بسیار مناسب است. از این رو در این مطالعه با در نظر گرفتن

### داده های واقعیت زمینی مورد استفاده

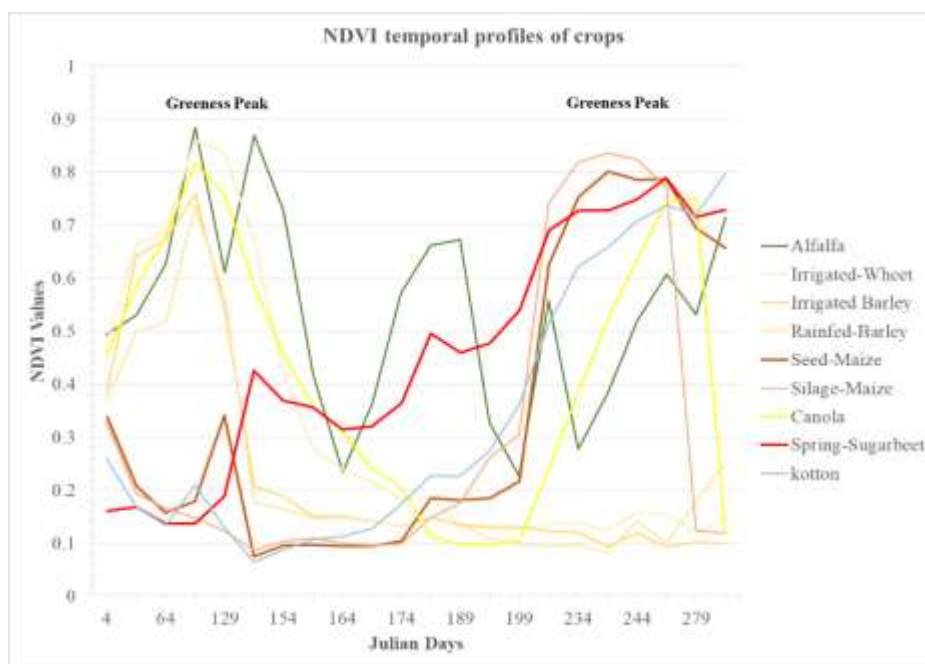
لایه داده های زراعی (Cropland Data Layer)، یک لایه رستری دارای سیستم مختصات، با اندازه سلول ۳۰ متر، در کشور ایالات متحده است که هر ساله در طول بازه رشد محصولات، از تصاویر ماهواره های با توان تفکیک متوسط مانند لندست-۸، Deimos-1 و UK2، Resourcesat-2 LISS-III و سنتینل-۲ با استفاده از روش طبقه بندی یادگیری نظارتی

### بررسی پروفیل زمانی NDVI برای محصولات

سری زمانی تصاویر ماهواره ای، اطلاعات مفیدی در مورد ویژگی های فنولوژیکی محصولات فراهم می کند. روش های

کلاسی است. از طرف دیگر، محصولی مانند یونجه یا کلزا در اراضی مختلف معمولا با یک فاصله زمانی کشت می شوند که همین امر باعث می شود که می دهد. بنابراین استفاده از شاخص های فنولوژیکی منحصر به فرد برای هر محصول که از پروفایل های زمانی استخراج می شوند و بر تفاوت های فنولوژیکی هر محصول با سایر محصولات مانند زمان های کاشت، برداشت، گلدهی و اوج سبزیگی، شیب های رشد و پیری و سایر تفاوتها تکیه دارند می توانند با استفاده از روش هایی که توانایی یادگیری این ویژگی های منحصر به فرد را دارند، برای طبقه بندی و شناسایی محصولات مفید باشند. بنابراین در این مطالعه، ما از این شاخص ها که در قسمت بعد آورده شده اند به عنوان کانال های ورودی به شبکه CNN استفاده خواهیم کرد و تاثیر آنها را بر دقت طبقه بندی در مقایسه با استفاده از سری های زمانی باندهای آبی، سبز، قرمز و فرورسرخ بررسی خواهیم کرد.

پوشش گیاهی بهبود یافته) و دیگر شاخص های پوشش گیاهی، برای نشان دادن منحنی رشد محصولات در طول فصل رشد استفاده می کنند (Foerster et al., 2012). ما در این مطالعه از شاخص NDVI استفاده می کنیم. به نظر می رسد که یک بررسی جامع زمانی از میزان این شاخص برای پیکسل های مرتبط با نمونه های زمینی محصولات، می تواند ما را به سمت یافتن ویژگی های منحصر بفرد طیفی-زمانی برای تشخیص انواع محصولات سوق دهد. شکل ۴، پروفیل زمانی NDVI را برای محصولات مورد مطالعه نشان می دهد. شایان ذکر است برای هر محصول، مقدار میانگین شاخص در مزارع مختلف لحاظ شده است. همانطور که از شکل مشاهده می شود در برخی از فواصل دوره ی رشد مانند روزهای ۱۷۶ تا ۲۰۰، مقدار شاخص محصولات مورد نظر، به یکدیگر بسیار نزدیک است و این به معنی همپوشانی طیفی میان این محصولات و به عبارت دیگر کاهش واریانس میان



شکل ۴- پروفیل زمانی NDVI محصولات بر اساس تعداد روز از ابتدای سال در منطقه مورد مطالعه  
Fig. 4- NDVI temporal profiles of crops based on Julian Day in the study area

روی سری زمانی باندها اعمال شد و یک تصویر یا کانال ویژگی برای این دو محصول به دست آمد:  
الف- بالا بودن شاخص پوشش گیاهی در زمان اوج سبزیگی

### شناسایی ویژگی های مختص هر محصول گندم/جو

ویژگی منحصر به فرد گندم/جو در واقع باقیماندن کلش این محصولات پس از برداشت است. بنابراین شروط زیر

قرمز و فرسرخ در این زمانها می توان این محصول را از سایر محصولات تفکیک نمود. بدین منظور برای به دست آوردن کانال ویژگی سیب زمینی، روی سری زمانی باندها رابطه

$$\text{Potatofeature} = \frac{(\sum_{t=1}^{N-1} (\rho_{(t+1)\text{NIR}} - \rho_{t\text{NIR}})) \times (\rho_{\text{NIRPG}})}{(\rho_{\text{redPG}})(\rho_{\text{NIRh}})}$$

که در آن  $\rho_{t\text{NIR}}$  مقدار بازتاب در باند فرسرخ در زمان  $t$  در طول بازه رسیدن به حداکثر سبزیگی،  $\rho_{\text{NIRPG}}$  مقدار بازتاب در باند فرسرخ در زمان اوج سبزیگی و  $\rho_{\text{redPG}}$  مقدار بازتاب در باند قرمز در زمان اوج سبزیگی و  $\rho_{\text{NIRh}}$  مقدار باند فرسرخ در زمان برداشت محصول می باشد، اعمال شد. مقدار این شاخص برای محصول سیب زمینی نسبت به سایر محصولات بیشتر می باشد. (Ashourloo *et al.*, 2020).

#### چغندر قند

با نگاه به پروفیل زمانی چغندر در شکل ۴ دریافت می شود پارامتر طول رشد و سبزیگی بلند مدت این محصول می تواند به عنوان شاخص شناسایی آن به کار گرفته شود. شاخص NDVI برای این محصول از اوسط ماه ژوئن روند افزایشی خود را شروع کرده و تا اواسط اکتبر بالا می باشد. همین امر موجب بالا بودن سطح زیر منحنی سری زمانی این شاخص و به تبع آن بالاتر بودن مجموع NDVI ها در این بازه زمانی نسبت به سایر محصولات است. با اعمال شروط بالا بودن مجموع NDVI ها در طول رشد نسبت به سایر محصولات، محدوده زمانی شروع رشد و محدوده زمانی برداشت این محصول بر روی سری زمانی شاخص NDVI، کانال ویژگی مربوط به چغندر به دست آمد (Gudarzdashti, 2021).

#### شبکه کانولوشنی عمیق

طبقه بندی تصاویری که در آنها اطلاعات زمینه ای تصویر یا عبارت دیگر وابستگی و همسایگی پیکسل ها مهم است با روش شبکه عصبی پرسپترون چند لایه (Multilayer Perceptron | MLP)، به دلیل برداری کردن تصویر ورودی و از بین رفتن روابط همسایگی پیکسل ها فاقد

ب- بالا بودن تفاضل مقادیر باند قرمز بین زمان های برداشت و اوج سبزیگی

بنابراین، مقدار  $(\rho_{\text{redh}} - \rho_{\text{redPG}})$  که در آن  $\rho_{\text{redh}}$  مقدار بازتاب در باند قرمز در زمان برداشت محصول و  $\rho_{\text{redPG}}$  مقدار بازتاب در باند قرمز در زمان اوج سبزیگی است برای کلاس گندم و جو از سایر محصولات بیشتر بوده می باشد (Gholampur, 2008).

#### کلزا

برای به دست آوردن کانال ویژگی کلزا، شروط زیر روی سری زمانی باندها اعمال شد:

الف- بالا بودن شاخص پوشش گیاهی در زمان اوج سبزیگی،

ب- بالا بودن شاخص طیفی شناسایی محصول کلزا در زمان گل دهی نسبت به سایر محصولات

$(\text{CanolaIndex} = \rho_{\text{NIR}} \times (\rho_{\text{Red}} + \rho_{\text{Green}}))$  که  $\rho_{\text{NIR}}$  برابر بازتابش در باند NIR است،  $\rho_{\text{Red}}$  بازتابش در باند Red و  $\rho_{\text{Green}}$  بازتابش در باند Green را نشان می دهد. پ- پایین بودن شاخص پوشش گیاهی در زمان برداشت. (Ashourloo *et al.*, 2019).

#### یونجه

با توجه به اینکه یونجه به طور پر یودیک برداشت می شود، لذا به منظور به دست آوردن کانال ویژگی یونجه، شروط زیر روی سری زمانی باندها اعمال گردید:

الف- بالا بودن شاخص پوشش گیاهی در طول دوره رشد و ب- بالا بودن شاخص طیفی شناسایی محصول یونجه در طول دوره کشت نسبت به سایر محصولات (Alfalfa)  $(\text{Feature} = \sum_{i=1}^n |\text{sd}(\text{NDVI})_i|)$  که در این رابطه  $\text{sd}(\text{NDVI})$  معادل انحراف معیار NDVI و  $n$  تعداد ماه های طول دوره رشد محصول است که در آن برداشت صورت می گیرد (Ashourloo *et al.*, 2018).

#### سیب زمینی

زمان اوج سبزیگی این محصول اواسط ماه آگوست بوده و تا اواسط اکتبر برداشت می شود. بنابراین با استفاده از باندهای

صحیح مقایسه شده و بر اساس یک تابع خطا (loss function)، میزان خطا محاسبه می‌گردد.

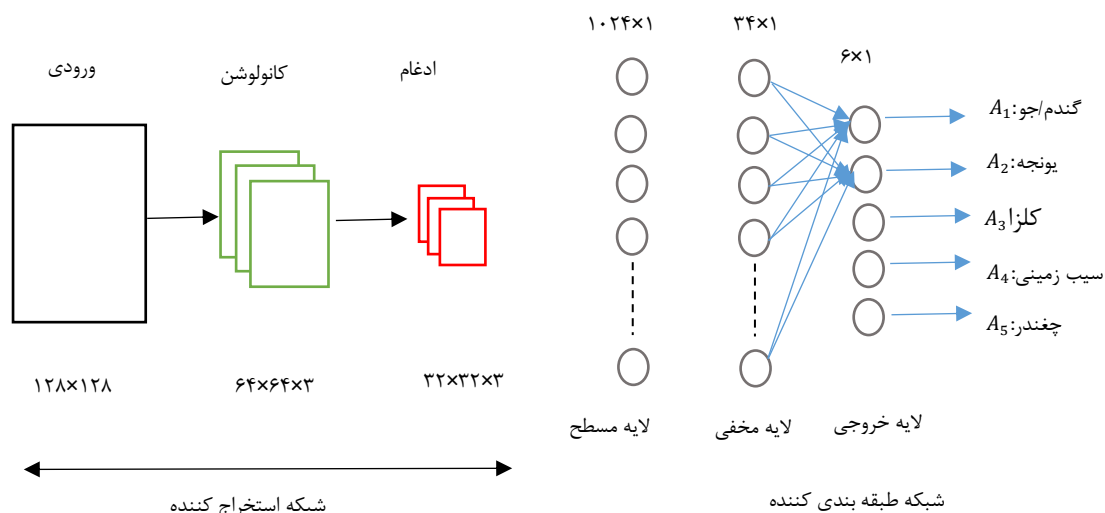
در مرحله بعدی برای بهینه سازی تابع خطا، براساس میزان خطای محاسبه شده، مرحله backpropagation آغاز می‌شود. در این مرحله گرادینانت هر پارامتر با توجه به قاعده chain rule محاسبه می‌شود و تمامی پارامترها با توجه به تاثیری که بر خطای ایجاد شده در شبکه دارند تغییر پیدا می‌کنند. بعد از به روزرسانی پارامترها، مرحله بعدی feed-forward شروع می‌شود. بعد از تکرار تعداد مناسبی از این مراحل، آموزش شبکه پایان می‌یابد. لازم به ذکر است که در آخرین لایه این شبکه، از طریق اعمال تابع سافت‌مکس روی نرونهای این لایه، احتمال تعلق ورودی شبکه به کلاسهای مختلف از طریق رابطه زیر محاسبه می‌گردد:

$$P(x \in A_1) = \frac{e^{(v_1)}}{e^{(v_1)} + e^{(v_2)} + e^{(v_3)} + e^{(v_4)} + e^{(v_5)}} \quad (1)$$

در رابطه فوق  $v_1$  تا  $v_5$  به ترتیب برابر جمع وزنی در اولین تا پنجمین نرون لایه خروجی است.  $x$ ، ورودی شبکه و  $A_1$ ، کلاس یک می باشد. در واقع تابع سافت‌مکس هنگام اعمال روی هر نرون، سایر نرونها را نیز در نظر می‌گیرد. شکل ۵، معماری این شبکه را نشان می‌دهد.

دقت مناسب خواهد بود. شبکه های عمیق کانولوشنی برای کار بر روی تصاویر طراحی گردیده‌اند و دارای سه لایه هستند: لایه کانولوشن، لایه ادغام (Pooling) و لایه تماما متصل (Fully connected).

در این شبکه ها آموزش دو مرحله است. مرحله پیش خور (feed forward) و مرحله پس انتشار (backpropagation). در مرحله اول، ورودی به شکل کانال تصویری به شبکه وارد می‌شود و عملیات کانولوشن که همان ضرب نقطه ای عناصر نظیر به نظیر فیلتر کانولوشن با تصویر و مجموع نتایج حاصله است روی آن اعمال و سپس عملیات لایه ادغام که شامل ادغام ماکزیمم (Max Pooling) یا ادغام میانگین (Average Pooling) است روی نتیجه اعمال می‌گردد. فیلترهای کانولوشن و ادغام، با گامهای (Stride) تعیین شده روی کانال ورودی می‌لغزند تا تمام سطح تصویر را پوشش دهند و کانال‌های ویژگی را تولید کنند. در ادامه، کانال‌های ویژگی، مسطح شده و به یک شبکه تماما متصل که وظیفه طبقه بندی را برعهده دارد، وارد و در آخرین لایه با استفاده از اعمال تابع softmax روی نرونهای آن، خروجی شبکه که همان نتیجه طبقه بندی است محاسبه می‌شود. سپس خروجی شبکه، با پاسخ



شکل ۵- معماری استفاده شده شبکه CNN بر روی یک کانال با اعمال سه فیلتر کانولوشن و ادغام با گام ۲. به جز لایه خروجی که از تابع فعالسازی Softmax استفاده شده، تابع فعالسازی سایر لایه ها Relu می باشد

Fig. 5- The architecture of used CNN on a channel with three convolution and pooling kernels. The activation function of the output layer is Softmax. For Others is Relu



## نتایج و بحث

مقاطع زمانی، این الگوها به هم نزدیک می شود. از آنجا که با افزایش یا کاهش مقدار سبزینگی در گیاهان، میزان بازتابش آنها در طول موجهای مختلف خصوصاً R و NIR تغییر می کند و نیز با توجه به تفاوت در الگوی رشد آنها، بازتاب مزارع مرتبط با محصولات مختلف، در طیفهای مرئی و فروسرخ نزدیک در برخی از مقاطع زمانی با یکدیگر متفاوت است که از این تفاوت می توان برای تفکیک محصولات کشاورزی روی تصویر استفاده نمود. از این رو باندهای R, G, B و NIR ماهواره سنتینل-۲ در ۱۰ تاریخ مختلف تشکیل چهار سری زمانی هر یک با ۱۰ باند استفاده شد. سپس این سریهای زمانی، با هم تشکیل یک تصویر ۴۰ باندهای دادند که از آن بعنوان تصویر ورودی به شبکه CNN استفاده گردید و شبکه با استفاده از این تصویر و نمونه های زمینی آن آموزش دید. جدول ۱، ماتریس اغتشاش یا ماتریس خطای نتیجه طبقه بندی محصولات با استفاده از این شبکه آموزش دیده و شکل ۷ دقت آموزش و تابع هزینه این آموزش را نشان می دهد. همانگونه که جدول ۱ و شکل ۷ نشان می دهند شبکه به خوبی نتوانسته با استفاده از سری زمانی باندها، آموزش ببیند و بتواند محصولات را از هم تفکیک نماید. علت این موضوع بواسطه همپوشانیهای طیفی میان محصولات در طول فصل رشد است که مانع آموزش مناسب شبکه و در نتیجه مقدار دقت کلی برابر با ۶۹ درصد گردیده است. بنابراین استفاده از شاخصها و ویژگیهایی که بتوانند تباین میان محصولات گوناگون را افزایش و دقت و کارایی الگوریتم را بهبود ببخشند ضروری به نظر می رسد که در قسمت بعدی به آن پرداخته می شود.

جدول ۱- ماتریس ابهام مربوط به نتیجه طبقه بندی محصولات با استفاده سری زمانی باندهای طیفی

Table 1. Confusion matrix of Crop classification with time series spectral bands

جمع Summation	کلزا Canola	سیب زمینی Potato	چغندر Sugar Beet	یونجه Alfalfa	گندم/جو Wheat/Barley	
112	7	2	8	8	88	گندم/جو Wheat/Barley
110	8	10	10	68	14	یونجه Alfalfa

در این مطالعه، ابتدا سری زمانی باندها، ورودی شبکه کانواوشنی عمیق را تشکیل دادند و شبکه در ناحیه آموزش، با استفاده از اطلاعات طیفی-زمانی باندها به عنوان کانالهای ورودی و نمونه های زمینی محصولات به عنوان برچسب، آموزش دید و ناحیه تست با استفاده از شبکه آموزش دیده، طبقه بندی و به منظور ارزیابی دقت، نتیجه با نمونه های تست زمینی مقایسه شد. در مرحله دیگر، توابعی که به عنوان شاخصهای فنولوژیک برای هر محصول توسعه داده شده بود، روی سری زمانی باندها اعمال گردید و برای هر محصول، یک کانال ویژگی بعنوان شاخص انحصاری آن محصول، به دست آمد. آنگاه این کانالهای ویژگی، وارد الگوریتم شبکه شدند و بدون تعیین هیچ آستانه ای (بر خلاف روشهای اتوماتیک که برای تهیه نقشه محصولات زراعی که نیاز به تعیین آستانه برای هر ویژگی دارند)، الگوریتم مانند حالت قبل آموزش دید و کانالهای ویژگی، طبقه بندی و نقشه محصولات به همراه معیارهای ارزیابی دقت، تهیه و نتایج دو مرحله با هم مقایسه گردیدند. نتایج این فرآیندها، در ادامه به شرح زیر است:

## استفاده از سری زمانی تصاویر ماهواره ای، به عنوان


## کانالهای ورودی به شبکه CNN

بررسی پروفیل زمانی شاخص NDVI مربوط به محصولات مورد نظر در طول دوره رشد، نشان داد که الگوی فنولوژیکی یا به عبارت دیگر روند تغییر سبزینگی محصولات مختلف از مرحله کاشت تا زمان برداشت، در شکل کلی با یکدیگر متفاوت است اگرچه در برخی از

ادامه جدول ۱- ماتریس ابهام مربوط به نتیجه طبقه بندی محصولات با استفاده سری زمانی باندهای طیفی

Table 1. Cont. Confusion matrix of Crop classification with time series spectral bands

جمع Summation	کلزا Canola	سیب زمینی Potato	چغندر Sugar Beet	یونجه Alfalfa	گندم/جو Wheat/Barley	
140	4	15	101	15	8	چغندر Sugar Beet
117	2	75	17	17	6	سیب زمینی Potato
81	32	3	1	12	30	کلزا Canola
560	50	105	140	120	145	جمع Summation
ضریب کاپا = ۰/۵۵ Kappa Coefficient = 0.55				۶۹ = (بر حسب درصد) دقت کلی Overall Accuracy (%) = 69		



شکل ۷- دقت و هزینه مربوط به آموزش شبکه با استفاده از سری زمانی باندهای طیفی

Fig. 7- Accuracy and loss amount of training CNN with time series of spectral bands

فنولوژیک هر محصول در مقایسه با بقیه محصولات در نظر گرفته شده است اعمال فیلترهای کانولوشن و ادغام منجر به استخراج ویژگی‌های طیفی و زمانی متفاوت‌تری برای هر محصول در مقایسه با دیگر محصولات شده و شبکه طبقه بندی کننده، بهتر می تواند محصولات مختلف را از یکدیگر تمیز دهد و انتظار می رود این طبقه بندی، با دقت بیشتری نسبت به حالت قبل، نقشه محصولات را استخراج نماید. بنابراین شبکه با استفاده از این کانال‌ها و نمونه های زمینی مرتبط با هر پیکسل، آموزش دید. پس از بررسی دقت آموزش، سایت جنوبی که به عنوان سایت تست در نظر گرفته شده بود با استفاده از شبکه آموزش دیده، طبقه بندی گردید که شکل ۸ و جدول ۲ نتایج طبقه بندی را نشان می دهند.

استفاده از کانال‌های ویژگی مختص هر محصول، به عنوان کانال‌های ورودی به شبکه CNN

پس از بررسی پروفیل زمانی NDVI و شناسایی خصوصیات منحصر به فرد محصولات مورد نظر، از قبیل سطح زیر منحنی رشد، اوج سبزی‌نگی، وضعیت سبزی‌نگی محصول در زمان برداشت، شرایط زمین پس از برداشت و سایر مشخصه هایی که در بخش ۵-۵ به آن پرداخت شد، برای هر یک از ۵ محصول مورد مطالعه، یک کانال ویژگی منحصر به فرد، با مقادیر بیشینه برای پیکسل‌های آن محصول نسبت به سایر محصولات به دست آمد که این ۵ کانال، تصویر ورودی به شبکه کانولوشنی عمیق را تشکیل دادند. از آنجا که این کانال‌ها برای هر محصول به طور انحصاری توسعه داده شده اند و خصوصیات متفاوت

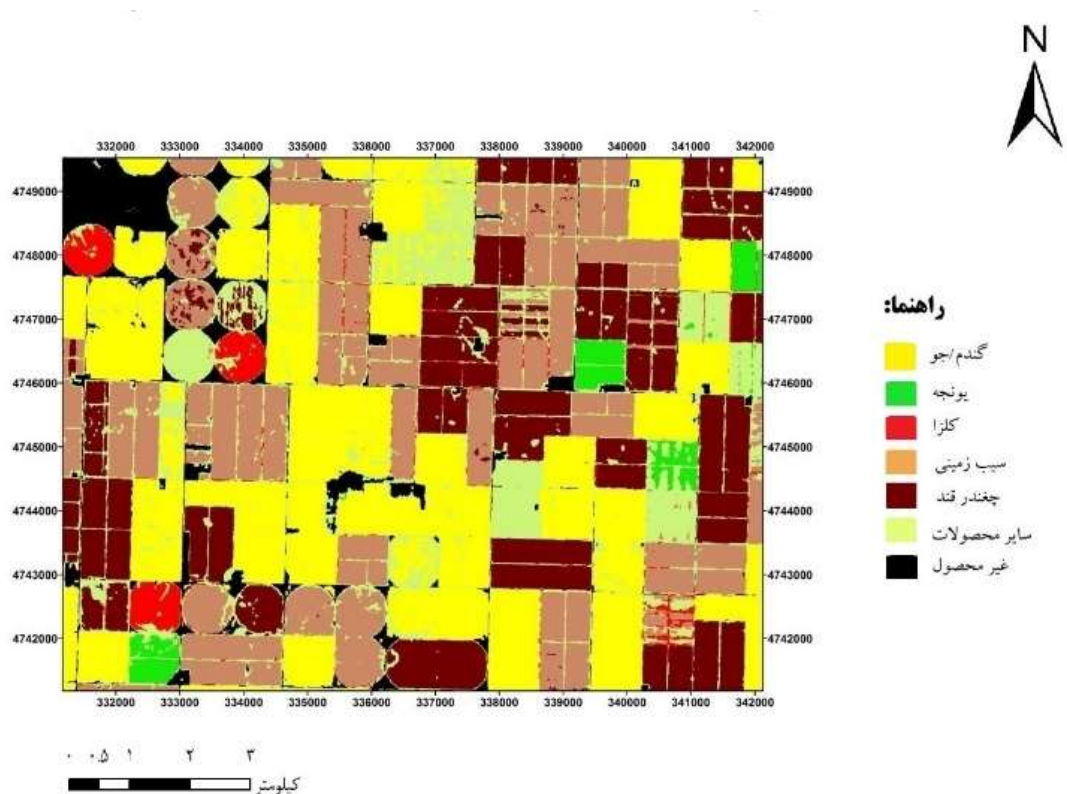
جدول ۲- ماتریس اغتشاش حاصل از نتیجه طبقه بندی محصولات با استفاده از کانال‌های ویژگی

Table 2. Confusion matrix of Crop classification with feature channels

جمع Summation	کلزا Canola	سیب زمینی Potato	چغندر Sugar Beet	یونجه Alfalfa	گندم/جو Wheat/Barley	
130	3	1	1	1	124	گندم/جو Wheat/Barley
113	1	4	3	100	5	یونجه Alfalfa
140	0	8	125	6	1	چغندر Sugar Beet
113	5	91	10	7	0	سیب زمینی Potato
64	41	1	1	6	15	کلزا Canola
560	50	105	140	120	145	جمع Summation

ضریب کاپا = ۰/۸۲  
Kappa Coefficient = 0.82

86 = (بر حسب درصد) دقت کلی  
Overall Accuracy(%) = 86



شکل ۸ - نتیجه طبقه بندی محصولات توسط شبکه آموزش دیده CNN با کانال‌های ویژگی محصولات

Fig. 8- Crop classification result by trained CNN with feature channels of crops

دقت کلی ۹۲/۹ درصد و ضریب کاپای ۰/۸۵ را در طبقه بندی دو کلاس گندم و غیر گندم به دست آوردند، و نیز مطالعه ای که Ashourloo *et al.* (2020) برای تفکیک سیب زمینی با دقت کلی ۹۰ درصد و ضریب کاپای ۰/۸۶

در مقایسه با مطالعاتی که برای تفکیک یک نوع محصول با استفاده از روشهای یادگیری ماشین انجام گردیده از جمله مطالعه Liu *et al.* (2017) که با استفاده از داده‌های چند زمانه و الگوریتم جنگل تصادفی،

را پایین آورده و کارایی آن را در طبقه بندی محصولات گوناگون، بالا ببرد. در این میان نقش پراهمیت داده های زمینی نبایستی مورد غفلت قرار گیرد. برچسبهای زمینی اشتباه، به راحتی می توانند تاثیر کانالهای ورودی مناسب را از بین ببرند و شبکه را گمراه سازند. شایان ذکر است که گردآوری داده های زمینی به خصوص در موضوع نقشه برداری از محصولات، بسیار وقت گیر، هزینه بر و دشوار است. بنابراین روشهایی که قابلیت یادگیری الگوهای زمانی رشد محصولات را دارا هستند اگر چه برای یادگیری نیاز به حجم بالایی از داده های زمینی دارند اما اگر خوب آموزش ببینند وابستگی دوباره آنها به داده های زمینی کاهش پیدا خواهد کرد. اگر یک شبکه یادگیری عمیق، به طور مناسبی آموزش ببیند می تواند برای سالهای آتی و یا در مناطق دیگر به کار گرفته شود بدون اینکه نیاز به گردآوری مجدد حجم بالایی از داده های واقعی زمینی داشته باشد. مقایسه این روش با سایر روشها یا الگوریتمها، در مناطق مختلفی که محصولات متفاوت دارند غیر ممکن خواهد بود. برای چنین مقایسه ای، نوع، تعداد محصولات و نیز فواصل زمانی استفاده شده در سری زمانی تصاویر بسیار مهم خواهد بود.

Ashourloo, D., Shahrabi, H.S., Azadbakht, M., Aghighi, H., Matkan, A.A. and Radiom, S., 2018. A novel automatic method for alfalfa mapping using time series of landsat-8 OLI Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 11(11), 4478-4487.

Ashourloo, D., Shahrabi, H.S., Azadbakht, M., Aghighi, H., Nematollahi, H., Alimohammadi, A. and Matkan, A.A., 2019. Automatic canola mapping using time series of sentinel 2 images. *ISPRS Journal of Photogrammetry and Remote Sensing*. 156, 63-76.76.

Ashourloo, D., Shahrabi, H.S., Azadbakht, M.,

انجام دادند، در این مطالعه رسیدن به دقت کلی ۸۶ درصد و ضریب کاپای ۰/۸۲ برای طبقه بندی هفت کلاس محصول و غیر محصول، خود بیانگر کارایی این روش برای طبقه بندی محصولات گوناگون است. شایان ذکر است که ایجاد شاخص های موثرتر و تاثیر آنها بر افزایش دقت طبقه بندی در این روش باید همچنان مورد مطالعه قرار گیرد.

### نتیجه گیری

با مقایسه بخش ۶-۱ و ۶-۲ مشاهده می کنیم که استفاده از کانالهای ویژگی به جای سری زمانی باندها، ۱۷ درصد دقت کلی و ۰/۲۷ ضریب کاپا را افزایش داد که می تواند در تهیه نقشه دقیق تر و دسترسی به آمار و اطلاعات صحیح تر برای برنامه ریزیهای مرتبط با امنیت غذایی بسیار مفید باشد. این امر نشان می دهد که شبکه کانولوشنی عمیق برای تشخیص محصولات کشاورزی، به نوع کانالهای ورودی بسیار حساس است و انتخاب کانالهایی با ویژگیهای طیفی-زمانی مناسب برای انواع محصولات، بر دقت آموزش شبکه بسیار تاثیرگذار بوده و می تواند هزینه یا خطای آموزش شبکه کانولوشنی عمیق

### منابع

Rad, A.M., Aghighi, H. and Radiom, S., 2020. A novel method for automatic potato mapping using time series of Sentinel-2 images. *Computers and Electronics in Agriculture*. 175, 105583.

Azzari, G. and Lobell, D.B., 2017. Landsat-based classification in the cloud: an opportunity for a paradigm shift in land cover monitoring. In: *Remote Sensing of Environment, Big Remotely Sensed Data: tools, applications and experiences*. 202. pp. 64-74. <https://doi.org/10.1016/j.rse.2017.05.025>.

Bargiel, D., 2017. A new method for crop classification combining time series of radar images and crop phenology information. *Remote*

- sensing of environment. 198, 369-383.
- Boryan, C., Yang, Z., Mueller, R. and Craig, M., 2011. Monitoring US agriculture: the US department of agriculture, national agricultural statistics service, and cropland data layer program. *Geocarto International*. 26(5), 341-358.
- Cai, Y., Guan, K., Peng, J., Wang, S., Seifert, C., Wardlow, B. and Li, Z., 2018. A high-performance and in-season classification system of field-level crop types using time-series Landsat data and a machine learning approach. *Remote sensing of environment*. 210, 35-47.
- Esch, T., Metz, A., Marconcini, M. and Keil, M., 2014. Combined use of multi-seasonal high and medium resolution satellite imagery for parcel-related mapping of cropland and grassland. *International Journal of Applied Earth Observation and Geoinformation*. 28, 230-237.
- Foerster, S., Kaden, K., Foerster, M. and Itzerott, S., 2012. Crop type mapping using spectral-temporal profiles and phenological information. *Computers and Electronics in Agriculture*. 89, 30-40.
- Gadiraju, K.K. and Vatsavai, R.R., 2020. Comparative analysis of deep transfer learning performance on crop classification, *Proceedings of the 9th ACM SIGSPATIAL International Workshop on Analytics for Big Geospatial Data*, pp. 1-8.
- Gholampur, A., 2008. A novel algorithm for detecting wheat and barley. M.Sc. Thesis. Shahid Beheshti University, Tehran, Iran.
- Goodarzashti, S., 2021. Automatic crop detection based on phenological information using Google Earth Engine. M.Sc. Thesis. Shahid Beheshti University, Tehran, Iran.
- Huang, B., Zhao, B. and Song, Y., 2018. Urban land-use mapping using a deep convolutional neural network with high spatial resolution multispectral remote sensing imagery. *Remote Sensing of Environment*. 214, 73-86.
- Johnston, B.F. and Kilby, P., 1982. Unimodal and bimodal strategies of agrarian change. *Rural development: theories of peasant economy and agrarian change*. London: Hutchinson Publishing Group.
- Kang, Y., Khan, S. and Ma, X., 2009. Climate change impacts on crop yield, crop water productivity and food security – A review. *Progress in Natural Science* 19, 1665-1674.
- Khatami, R., Mountrakis, G. and Stehman, S.V., 2017. Mapping per-pixel predicted accuracy of classified remote sensing images. *Remote Sensing of Environment* 191, 156-167.
- King, L., Adusei, B., Stehman, S.V., Potapov, P.V., Song, X.-P., Krylov, A., Di Bella, C., Loveland, T.R., Johnson, D.M. and Hansen, M.C., 2017. A multi-resolution approach to national-scale cultivated area estimation of soybean. *Remote Sensing of Environment* 195, 13-29.
- LeCun, Y., Bengio, Y. and Hinton, G., 2015. Deep learning. *Nature*. 521, 436-444.
- Mingwei, Z., Qingbo, Z., Zhongxin, C., Jia, L., Yong, Z. and Chongfa, C., 2008. Crop discrimination in Northern China with double cropping systems using Fourier analysis of time-series MODIS data. *International Journal of Applied Earth Observation and Geoinformation*. 10, 476-485.
- Peña-Barragán, J.M., Ngugi, M.K., Plant, R.E. and Six, J., 2011. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sensing of Environment*. 115, 1301-1316.

- Ramankutty, N., Mehrabi, Z., Waha, K., Jarvis, L., Kremen, C., Herrero, M. and Rieseberg, L.H., 2018. Trends in global agricultural land use: implications for environmental health and food security. *Annual review of plant biology*. 69, 789-815.
- Sandborn, A., Mueller, R., Boryan, C., Johnson, D., Yang, Z., Ebinger, L., Rosales, A., Willis, P., Seffrin, R., Jennings, R., Deaton, M. and Hamer, H., 2019. NASS Geospatial Applications from the Cropland Data Layer. ISI World Statistics Conference, Malaysia, Aug 18-23, 2019. Posted 8/21/2019.
- Shelestov, A., Lavreniuk, M., Kussul, N., Novikov, A., Skakun, S., 2017. Exploring Google Earth Engine Platform for Big Data Processing: Classification of Multi-Temporal Satellite Imagery for Crop Mapping. *Front. Earth Sci.* 2017, 5, 17.
- Zheng, B., Myint, S.W., Thenkabail, P.S., Aggarwal, R.M., 2015. A support vector machine to identify irrigated crop types using time-series Landsat NDVI data. *International Journal of Applied Earth Observation and Geoinformation* 34, 103-112.
- Zhong, L., Hu, L., Zhou, H., 2019. Deep learning based multi-temporal crop classification. *Remote sensing of environment* 221, 430-443.
- Zhong, L., Hu, L., Zhou, H., Tao, X., 2019b. Deep learning based winter wheat mapping using statistical data as ground references in Kansas and northern Texas, US. *Remote Sens. Environ.* 233, 111411.  
<https://doi.org/10.1016/j.rse.2019.111411>.
- Xu, J., Zhu, Y., Zhong, R., Lin, Z., Xu, J., Jiang, H., Huang, J., Li, H., Lin, T., 2020. DeepCropMapping: A multi-temporal deep learning approach with improved spatial generalizability for dynamic corn and soybean mapping. *Remote Sensing of Environment* 247, 111946.





Environmental Sciences Vol.20 / No.4 / Winter 2023

37-52

Original Article

## Crop classification with deep convolutional neural network based on crop feature

Mohamad Reza Gili,\* Davoud Ashourloo, Hosein Aghighi, Ali Akbar Matkan and Ali Reza Shakiba

Remote Sensing Center, Faculty of Earth Sciences, Shahid Beheshti University, Tehran, Iran

Received: 2021.12.03 Accepted: 2022.04.30

Gili, M.R., Ashourloo, D., Aghighi, H., Matkan, A.A. and Shakiba, A.R., 2023. Crop classification with deep convolutional neural network based on crop feature. *Environmental sciences*. 20(4): 37-52.

**Introduction:** Given that agriculture has the most important role in ensuring food security, it is necessary to prepare a map that shows the spatial distribution, land area and type of crops cultivated with high accuracy. Agricultural land cover is relatively dynamic and variable at relatively short intervals. This makes it difficult to classify crops on satellite imagery. The lack or absence of ground truth data is another cause. Therefore, methods that are less dependent on ground samples and use phenological features derived from time series of bands and vegetation indices to classify crops will be more appropriate. The purpose of this study is to use deep learning method based on convolutional networks to classify the crop types and improve the performance of this network by using feature channels as input image to the network and increase the classification accuracy.

**Material and methods:** In this study, the visible and near-infrared bands of Sentinel-2 satellite on 10 different dates from 2019 for an area in Idaho, USA, as an important agricultural area, and the cropland data layer for extracting the crop types ground labels was used. Then, in MATLAB software, the time series of spectral bands were constructed and using them, temporal profiles of NDVI for any crop were extracted to identifying the unique phenological features of crops. Then, the functions developed based on the phenological characteristics of crops were applied to the time series of the bands and a feature channel was obtained for each crop that in two separate processes, once bands and once again feature channels were used as input to the CNN and the network was trained and the results of network performance on crop classification in the test site, were compared.

**Results and discussion:** In the first stage, the time series of bands formed the input of the deep convolutional neural network and the network was trained in the training area, using the tempo-spectral information of bands

---

\* Corresponding Author: *Email Address*. m\_gili@sbu.ac.ir

as the input channels and crops ground samples as the related labels. Due to the spectral overlap of the crops in some time periods, network training was associated with a relatively high loss and therefore, for the test area, the overall classification accuracy was 69% (percent) and the kappa coefficient was 0.55. In the next step, the functions that were developed as phenological features for crops were applied on the time series of the bands, and for each crop, a feature channel was obtained as the special feature of that crop. Then the algorithm was implemented using these feature channels in the test area and the overall accuracy was upgraded to 86% and the kappa coefficient to 0.82 compared to which indicated a significant improvement in the results compared to the previous case.

**Conclusion:** The deep convolutional neural network is very sensitive to the type of input channels for detecting agricultural crops and selecting the channels with suitable tempo-spectral characteristics for different types of crops, has a great impact on accuracy of network training and can reduce the loss of training network and increase its efficiency in the classification of various crops.

**Keywords:** Time series Images, Classification, Agricultural crop, Temporal profiles of NDVI, Phenologic features, Deep convolutional Network.