



## کاربرد شبکه کانولوشنی LSTM در طبقه‌بندی محصولات کشاورزی با استفاده از سری زمانی NDVI

محمد رضا گلی<sup>۱</sup>، داود عشورلو<sup>۲\*</sup>، حسین عقیقی<sup>۳</sup>، علی اکبر میکان<sup>۳</sup>، علیرضا شکیبا<sup>۴</sup>

۱. دانشجوی دکترای مرکز سنجش از دور، دانشکده علوم زمین، دانشگاه شهید بهشتی

۲. استادیار مرکز مطالعات سنجش از دور، دانشکده علوم زمین، دانشگاه شهید بهشتی

۳. استاد مرکز مطالعات سنجش از دور، دانشکده علوم زمین، دانشگاه شهید بهشتی

۴. دانشیار مرکز مطالعات سنجش از دور، دانشکده علوم زمین، دانشگاه شهید بهشتی

تاریخ پذیرش مقاله: ۱۴۰۱/۰۲/۲۷

تاریخ دریافت مقاله: ۱۴۰۰/۰۹/۰۹

### چکیده

تغییرات رشد محصولات کشاورزی در فواصل زمانی نسبتاً کوتاه، ناهمزنایی کشت محصولات مشابه، شباهت طیفی میان محصولات گوناگون در برخی از زمان‌های دوره کشت و کمبود داده‌های زمینی، طبقه‌بندی محصولات زراعی در تصاویر ماهواره‌ای را به کاری چالش‌برانگیز مبدل می‌کند. تغییر مقدار درصد پوشش و سبزینگی، در طول فصل رشد، از بر جسته‌ترین ویژگی پوشش‌های گیاهی از جمله محصولات کشاورزی است که می‌توان بر آن نظرتاریک کرد. این کار با استفاده از سری زمانی شاخص‌های گیاهی انجام می‌شود که اطلاعات بسیار مفیدی از توالی ویژگی‌های فنولوژیک محصولات کشاورزی در اختیار ما قرار می‌دهد. استفاده از روش‌های یادگیری عمیق با توانایی یادگیری اطلاعات متوالی حاصل از این سری‌ها می‌تواند، در طبقه‌بندی محصولات کشاورزی و کاهش وابستگی به داده‌های زمینی، مفید باشد. شبکه Long-Short Term Memory (LSTM) یکی از انواع شبکه‌های عصبی بازگشته در تجزیه و تحلیل داده‌های متوالی است که توانایی یادگیری توالی‌های بلندمدت در سری زمانی را دارد؛ بنابراین در این مطالعه، پس از محاسبه ساختار NDVI از باندهای ماهواره سنتینل-۲ در نه تاریخ متفاوت و تشکیل سری زمانی آن شاخص برای ورود به شبکه، دو ناحیه متفاوت در دشت مغان در نظر گرفته شد که محصولات کشت‌شده در آنها، طی عملیات زمینی، برداشت شده بود. در ناحیه اول، شبکه کانولوشنی LSTM برای طبقه‌بندی محصولات آموزش دید و در ناحیه دیگر، کارآبی این شبکه آموزش دیده در طبقه‌بندی محصولات ارزیابی شد و دقت کلی ۸۲٪ و ضریب کاپای ۰/۸ بدست آمد. افزایش تعداد نمونه‌های زمینی و انتخاب مزدقيق محصولات، می‌تواند کارآبی روش مورد استفاده را افزایش دهد.

**کلیدواژه‌ها:** یادگیری عمیق، حافظه کوتاه‌مدت بلند، سری زمانی، سنتینل-۲، طبقه‌بندی، محصولات کشاورزی.

## ۱- مقدمه

تغییرات در مقدار سبزینگی یکی از برجسته‌ترین ویژگی‌های پوشش گیاهی و به‌ویژه، محصولات کشاورزی در طول فصل رشد است. از این‌رو سنجش از دور چندماهه منبعی کارآمد در مشاهدات سری زمانی، به‌منظور نظارت بر تغییرات زمانی رشد و طبقه‌بندی پوشش گیاهی، Rogan et al., 2002; Xie et al., 2008) محسوب می‌شود (.

به‌دلیل ماهیت شبکه‌های عصبی بازگشتی<sup>۲</sup> در تجزیه و تحلیل داده‌های متوالی، این شبکه‌ها اغلب نخستین کاندیدای طبیعی برای یادگیری رابطه زمانی در سری زمانی تصاویر و الگوهای مدل تغییر پوشش زمین در نظر گرفته می‌شود (Mou & Zhu, 2018).

برای بهبود فرایند یادگیری شبکه، معمولاً از انواع RNN‌ها استفاده می‌شود که شناخته شده‌ترین آنها شبکه LSTM<sup>۳</sup> یا حافظه کوتاه‌مدت بلند است. این نوع حافظه، در واقع، واحد ویژه‌ای از RNN است که وابستگی زمانی را در فواصل زمانی متفاوت، با اتصالات بازگشتی دروازه‌ای، نشان می‌دهد (Hochreiter & Schmidhuber, 1997).

لیو<sup>۴</sup> و همکاران (۲۰۱۶) از یک مدل LSTM برای آموزش بازنمایی ویژگی مشترک طیفی-زمانی و از یک جفت تصویر دور زمانه برای بارزسازی تغییرات استفاده کردند.

مو<sup>۵</sup> و ژو<sup>۶</sup> (۲۰۱۸)، با استفاده از لایه‌های کانولوشن دو بعدی به منزله استخراجگرهای ویژگی مکانی برای تهیه ورودی به LSTM، کار را گسترش دادند. طبق گزارش آنها، با به کارگیری وابستگی زمانی، شبکه پیشنهادی نتایج بهتری را در مقایسه با الگوریتم‌های سنتی بارزسازی تغییرات که عملکردشان براساس تفاضل یا انباستگی ساده تصاویر است، به دست می‌آورد.

- 
1. Hebbian
  2. Recurrent Neural Networks (RNNs)
  3. Long Short Term Memory
  4. Lyu
  5. Mou
  6. Zhu

ذهن انسان برای شناخت پیرامون خود از ویژگی‌های همچون شکل، اندازه، رنگ، بو و سایر ویژگی‌های دریافتی از راه حواس پنجگانه استفاده می‌کند. هنگام مشاهده هر پدیده، تعدادی از نورون‌های مغز فعال می‌شوند که مطابق اصل هبیان<sup>۱</sup>، به هم سیم یا وصل می‌شوند (Szegedy et al., 2015). تجربه یادگیری در انسان، هنگام مواجهه با اجسام مشابه و شناسایی آنها، از طریق فعال‌سازی همین نورون‌ها در مغز شکل می‌گیرد. شبکه‌های عصبی مصنوعی با الهام از نورون‌های بیولوژیک، به‌منظور یادگیری و ایجاد دانش پدید آمده‌اند. شبکه عصبی مجموعه‌ای از نورون‌های است که با قرار گرفتن در لایه‌های گوناگون، معماری خاصی را بر مبنای ارتباطات وزنی بین خود در لایه‌های متفاوت ورودی، پنهان و خروجی شکل می‌دهند. شبکه‌های عصبی عمیق، در واقع، شبکه‌های عصبی با بیش از یک لایه مخفی اند که از طریق اعمال یک تابع فعال‌ساز غیرخطی روی جمع وزنی ورودی‌های هر نورون، خروجی هر نورون را محاسبه و از آن به منزله ورودی لایه بعدی استفاده می‌کنند؛ از این راه، ویژگی‌های داده ورودی را به صورت سلسله‌مراتبی، بازنمایی می‌کنند. در نهایت، این ویژگی‌های استخراج شده‌اند که برای قطعه‌بندی، رگرسیون و طبقه‌بندی داده‌های ورودی به کار می‌روند. در حوزه هوش مصنوعی، الگوریتم‌های یادگیری عمیق در واقع زیرمجموعه الگوریتم‌های یادگیری ماشین محسوب می‌شوند که قادرند سطوح متعدد ویژگی‌های داده ورودی را بازنمایی کنند (Krizhevsky et al., 2017) و در حل مسائلی همچون دسته‌بندی تصاویر، شناسایی اشیا، قطعه‌بندی معنایی و برآورد ژست انسان به کار روند. به طور کلی این روش‌ها بر چهار گونه متفاوت‌اند:

Restricted Auto Encoder;  
Convolutional Neural Networks;  
Restricted Boltzmann Machines,  
Sparse Coding.

شاخص NDVI از تصاویر ماهواره سنتیل-۲ استفاده می‌کنیم. این سری زمانی شامل دنباله‌ای از اطلاعات در زمینه الگوی رشد محصولات کشاورزی است و ما قصد داریم از آن بهمنزله ورودی به شبکه کانولوشنی LSTM که توانایی یادگیری توالی‌های بلندمدت و حفظ دامنه فضایی و طیفی داده‌ها را دارد، استفاده کنیم. همچنین در ناحیه آموزش، واقع در کشت‌وصنعت مغان که نمونه‌های زمینی آن در عملیات میدانی برداشت شده، شبکه را آموزش دهیم. در انتهای نیز دقیق این شبکه آموزش‌دیده را در ناحیه تست، واقع در منطقه کشت‌وصنعت مغان، از راه مقایسه نتیجه طبقه‌بندی ناحیه تست با نمونه‌های زمینی برداشت شده، بررسی کنیم.

## ۲- مواد و روش‌ها

### ۱-۲- منطقه مورد مطالعه

شرکت کشت‌وصنعت مغان، واقع در شمال غرب ایران، بین عرض جغرافیایی  $39^{\circ}46'N$  تا  $39^{\circ}61'E$  و طول جغرافیایی  $47^{\circ}54'E$  تا  $48^{\circ}00'E$  شرقی قرار گرفته است (شکل ۱) و یکی از مهم‌ترین شرکت‌های کشت‌وصنعت در ایران به شمار می‌رود. وسعت زمین‌های زراعی این شرکت حدود بیست‌هزار هکتار است. آب‌وهای این منطقه، در تابستان‌ها، گرم و خشک است و زمستان‌های ملایم، معتدل و مرطوبی دارد. بارش سالیانه در آن بین ۲۰۰ تا ۳۰۰ میلی‌متر است که اغلب در بهار و پاییز رخ می‌دهد. خاک قهوه‌ای داشت برای کشاورزی مطلوب است و تابستان‌های گرم و خشک آن برای تولید محصولات با کیفیت بالا، همچون پنبه، بسیار مناسب است. ارتفاع این داشت معمولاً کمتر از ۱۵۰ متر از سطح آب‌های آزاد است. کشاورزی در این داشت به مدد سد میل-مغان و کanal‌های آبرسانی آن، در بیش از ۹۰٪ اراضی، به صورت آبی و در مابقی نیز به صورت دیم انجام می‌شود. خاک‌های منطقه

روسوُرم<sup>۱</sup> و کرنر<sup>۲</sup> (۲۰۱۷)، برای استخراج نمایه‌های زمانی دینامیک، از LSTM و تصاویر با توالی طولانی تر استفاده کردند تا انواع محصول را طبقه‌بندی کنند. آنها در مطالعه اخیر خود در سال ۲۰۱۸، با افزودن لایه‌های کانولوشن دو بعدی به منزله استخراج‌گرهای ویژگی فضایی و انصال سلول‌های تکراری به شیوه دوجهت، ساختار را بهبود دادند تا ارتباط زمانی به سمت تصاویر گام‌های بعدی را کاهش دهند. لیو و همکاران (۲۰۱۶) دریافتند، در آزمایش‌های متعدد، دقیق روش LSTM تا ۹۵٪ می‌رسد؛ در صورتی که دقیق در روش SVM حدود ۸۰٪ و در روش درخت تصمیم‌گیری حدود ۷۰٪ است.

روسوُرم و کرنر (۲۰۱۷) دقیق ۹۰٪ را با مدل LSTM چندزمانه‌ای گزارش کردند که کمی بالاتر از CNN<sup>۳</sup> (۸۹٪) و بسیار بیشتر از SVM (۴۰٪) بود. طی مجموعه آزمایش‌های مو و ژو (۲۰۱۸) نیز، استفاده ترکیبی از CNN و LSTM به دقیق حدود ۹۸٪ رسید که بیشتر از SVM، با دقیق ۹۵٪ و درخت تصمیم‌گیری، با دقیق ۸۵٪ بود.

جیا<sup>۴</sup> و همکاران (۲۰۲۰) از LSTM برای یادگیری الگوی گذار پوشش زمین بهره برداشت و در هر گام زمانی، پوشش زمین را به منزله خروجی متوالی پیش‌بینی کردند. این مطالعات، به منظور نشان دادن مزیت استفاده از LSTM به منزله استخراج‌گر ویژگی‌های زمانی نیز، نتایج طبقه‌بندی با استفاده از این مدل را با روش‌های دیگر مقایسه کرد.

هنگام پردازش سری زمانی، LSTM اغلب نقطه شروعی طبیعی تلقی می‌شود. در مقابل، شبکه‌های CNN معمولاً در دامنه فضایی و طیفی به کار می‌روند اما در طول ابعاد زمانی در مطالعات سنجش از دور، از نظر محاسباتی، کارآبی چندانی ندارند؛ با این حال کانولوشن ۱D، از لحاظ نظری، در تشخیص الگوهای زمانی در مقیاس‌های گوناگون مؤثر است (Zhong et al., 2019).

بنابراین در این مطالعه، از استخراج سری زمانی

1. Rußwurm

2. Korner

3. Convolutional Neural Network

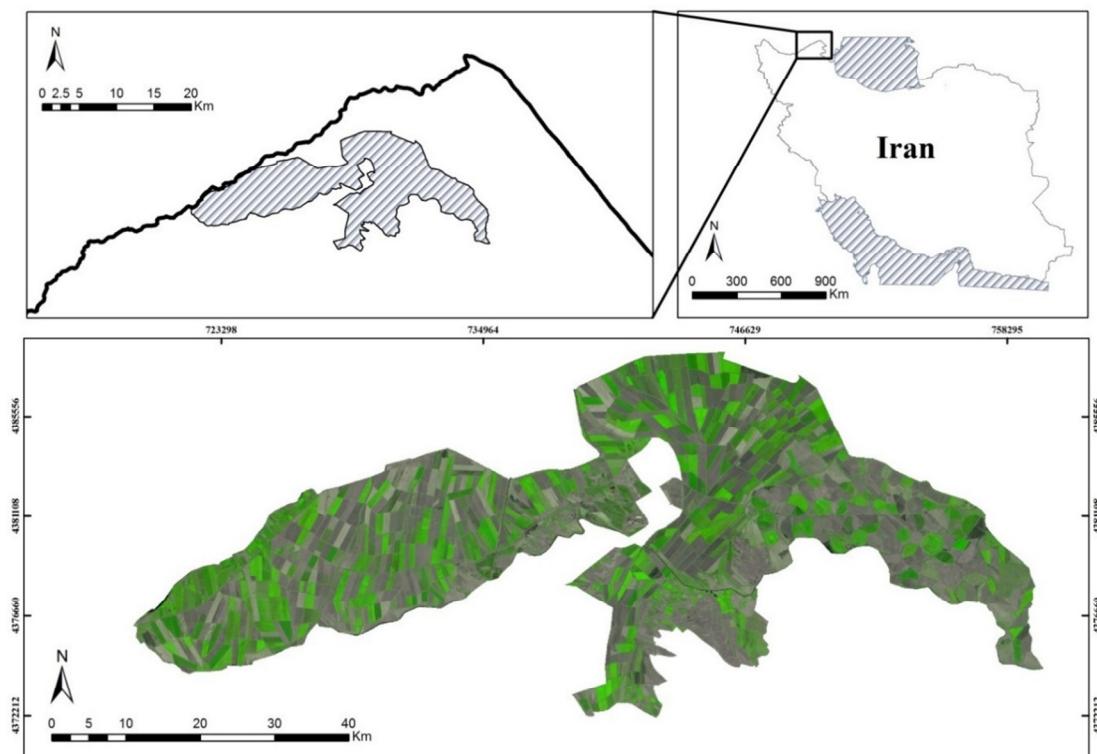
4. Jia

تصویربرداری می‌کند، برای پایش مداوم مزارع کشاورزی بسیار مناسب است؛ ازین‌رو در این مطالعه، با درنظر گرفتن دوره رشد محصولات و نیز محدودیت پوشش ابر، از تصاویر نه تاریخ متفاوت در سال ۲۰۱۹، شامل باندهای مرئی (Green: G, Red: R) و مادون قرمز نزدیک (Near infrared: NIR) استفاده شد. در انتخاب تصاویر مطابق تقویم شمسی از اسفند تا پایان مهر، تا جایی که فقدان پوشش ابر اجازه می‌داد، سعی شد هر ماه یک تصویر برداشت شود تا بتوان از اطلاعات ناشی از تغییرات رشد محصولات کشاورزی، در کشت‌های اول و دوم، به صورت ماهیانه بهره برد. جدول ۱ تاریخ تصاویر استفاده شده را براساس تعداد روزهای سپری شده از ابتدای سال میلادی<sup>۱</sup>، نشان می‌دهد.

از جنس لوم، سیلت و رس است. محصولات مهم منطقه شامل گندم، جو، یونجه، کلزا، پنبه، ذرت، چغندرقند و آفتابگردان می‌شود. منطقه مورد نظر یکی از پیشرفته‌ترین مناطق کشاورزی ایران است که شبکه آبیاری و زهکشی و ماشین آلات پیشرفته کشاورزی دارد؛ بنابراین می‌توان آن را از مناطق مهم و پیشرفته کشاورزی ایران دانست که اطلاعات و داده‌های زمین‌های کشاورزی آن از چند دهه پیش ثبت شده است.

## ۲-۲- تصاویر ماهواره‌ای مورد استفاده

با توجه به اینکه ماهواره‌های A و B سنتینل-۲ دارای زمان بازدید مجدد پنج روزه است و در طیف‌های مرئی و مادون قرمز، تصاویر با تفکیک مکانی ۱۰ و ۲۰ متر



شکل ۱. نقشه دشت مغان و تصویر ماهواره‌ای سنتینل-۲ با ترکیب رنگی کاذب قرمز، مادون قرمز نزدیک و آبی

1. Julian Days

گوناگون (افزایش واریانس درون کلاسی)، به همراه شباهت‌های طیفی میان انواع محصولات (کاهاش واریانس بین کلاس‌ها)، سبب می‌شود طبقه‌بندی محصولات زراعی روی تصاویر ماهواره‌ای و تهیه نقشه محصولات کشاورزی به کاری چالش برانگیز تبدیل گردد (Bargiel, 2017). این مسئله، به ویژه در تصاویر چندطیفی با تعداد محدود باند طیفی، کاملاً مشهود است (Bargiel, 2017; Peña-Barragán et al., 2011) زیرا، اگر فقط در یک زمان نامناسب از تصویری چندطیفی استفاده شود، ممکن است دقت نقشه‌برداری به شدت محدود شود (Shelestov et al., 2017).

برای رفع این مشکل، باید به ویژگی‌های فنولوژیک سنجش از دوری محصولات گوناگون یا، به عبارت دیگر، نمود انعکاسی محصولات روی سری زمانی تصاویر ماهواره‌ای، در بازه زمانی کاشت تا برداشت، توجه ویژه‌ای شود زیرا در این بازه زمانی، محصولات متفاوت رفتارهای منحصر به فردی بروز می‌دهند و ممکن است از نظر زمان کاشت و برداشت، سرعت رشد، شبیب رشد، زمان رسیدن به اوج سبزینگی، سرعت پیری، شبیب پیری، شرایط سبزینگی در زمان برداشت و آثار بر جاماندگی پس از برداشت محصول، با یکدیگر تفاوت‌هایی داشته باشند؛ به بیان بهتر، الگوی فنولوژیک متفاوتی داشته باشند. به همین دلیل، استفاده از این ویژگی‌ها ممکن است برای طبقه‌بندی محصولات کشاورزی، راهگشا باشد. از سوی دیگر، مهم‌ترین محدودیت طبقه‌بندی دقیق محصولات زراعی در تصاویر ماهواره‌ای، به ویژه در مناطق وسیع، کمبود یا فقدان داده‌های دارای برچسب واقعیت زمینی است (Gadiraju & Vatsavai, 2020) زیرا با اینکه تهیه بانک اطلاعاتی این داده‌ها که حاوی موقعیت اراضی و نوع محصولات کشت شده در این زمین‌هاست، برای استخراج ویژگی‌های فنولوژیک آنها و آموزش مدل‌های طبقه‌بندی نظارتی گوناگون ضروری است، این کار بسیار هزینه‌بر، زمان‌بر و دشوار است؛ بنابراین روش‌هایی مناسب‌ترند که به نمونه‌های زمینی وابستگی کمتری دارند و از ویژگی‌های فنولوژیک حاصل از سری

جدول ۱. تاریخ تصاویر استفاده شده براساس تعداد روزهای سپری شده از ابتدای سال میلادی

تعداد روزها	تاریخ میلادی	از ابتدای سال میلادی	دریافت تصاویر
۶۴	۲۰۱۹/۳/۵		
۱۰۴	۲۰۱۹/۴/۱۴		
۱۲۹	۲۰۱۹/۵/۹		
۱۵۹	۲۰۱۹/۶/۸		
۱۷۴	۲۰۱۹/۶/۲۳		
۱۹۹	۲۰۱۹/۷/۱۸		
۲۳۴	۲۰۱۹/۸/۲۲		
۲۵۹	۲۰۱۹/۹/۱۶		
۲۸۹	۲۰۱۹/۱۰/۱۶		

پس از آن، ناحیه واقع در محدوده ۷۲۶۳۰۰ متر تا ۷۳۴۲۰۰ متر طول شرقی و ۴۳۷۶۶۰ متر تا ۴۳۸۴۰۰۰ متر عرض شمالی، به منزله سایت آموزش شبکه و محدوده بین ۷۴۴۶۲۷ متر تا ۷۵۰۶۷۷ متر طول شرقی و ۴۳۸۲۰۲۷ متر تا ۴۳۸۷۹۰۷ متر عرض شمالی، به منزله سایت تست کارآیی شبکه آموزش دیده، انتخاب شد. علت انتخاب این دو سایت وجود نمونه‌های زمینی در این دو ناحیه بود.

### ۳-۲- الگوهای رشد محصولات مورد مطالعه

پوشش اراضی کشاورزی برخلاف بیشتر انواع پوشش‌های زمین، در فواصل زمانی کوتاه، بسیار متغیر است زیرا فنولوژی گیاهان زراعی در طول دوره کاشت تا برداشت، چندین بار تغییر می‌کند. این موضوع باعث می‌شود، روی تصاویر ماهواره‌ای، مزارع محصولات گوناگون در برخی از روزهای تقویم زراعی، به رغم تفاوت در نوع محصول، با یکدیگر شباهت‌های طیفی داشته باشند. اراضی اختصاص یافته به یک محصول خاص، مانند گندم، نیز به دلایل متعددی همچون آبی یا دیم‌بودن، نوع رقم زراعی، اختلاف زمانی کاشت و شرایط متفاوت از نظر نوع آبیاری و حاصلخیزی خاک، روی تصویر به صورت‌های متفاوتی ظاهر می‌شوند. اختلافات طیفی میان یک نوع محصول در مزارع

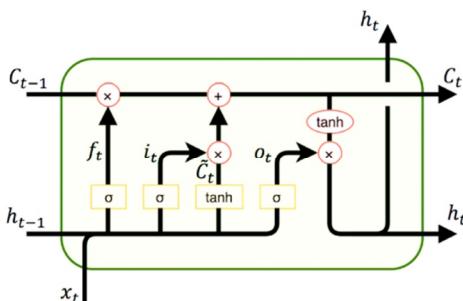
کاهش تأثیر پس زمینه خاک و تابش مستقیم خورشیدی و آشکارشدن پوشش‌های گیاهی، در قیاس با دیگر پوشش‌ها، روی این تصاویر می‌شود. این شاخص‌ها بر مبنای دو باند قرمز و مادون قرمز طیف الکترومغناطیس، به منظور ارزیابی وضعیت کمی و کیفی گیاهان، استفاده می‌شوند. از مزایای مهم آنها می‌توان به حساسیت پایین در برابر برخی عوامل مانند خاک پس زمینه، پستی و بلندی، عناصر غیرفتولوژیکی خاک و اتمسفر اشاره کرد (Huete et al., 1994; Huete & Tucker, 1991). جدول ۲ برخی از این شاخص‌ها را نشان می‌دهد که به منظور تهیه نقشه محصولات زراعی استفاده شده‌اند.

زمانی باندها و شاخص‌های گیاهی، در طبقه‌بندی محصولات، استفاده می‌کنند (Ashourloo et al., 2020). از آن جاکه مقادیر شاخص‌های پوشش گیاهی با میزان سبزینگی محصولات کشاورزی در بازه زمانی کاشت تا برداشت، همبستگی بالایی را نشان می‌دهند، در بررسی و نمایش ویژگی‌های فنولوژیک محصولات کشاورزی کاربرد دارند. این شاخص‌ها براساس تابعی از عملیات ریاضی بین باندهای گوناگون و در ارتباط با پارامترهای متفاوت سبزینگی مانند میزان کلروفیل، شاخص سطح برگ، بایومس و مقدار تابش فعال (Hatfield & Prueger, 2010) توسعه یافته‌اند. اعمال این شاخص‌ها بر باندهای تصاویر ماهواره‌ای سبب

جدول ۲. شاخص‌های پوشش گیاهی به کاررفته در تخمین تولید محصولات کشاورزی

منبع	توضیحات	رابطه	شاخص
Tucker & Sellers, 1986	مقدار بازتابندگی باند مادون = $\rho_{NIR}$ قرمز = $\rho_{Red}$	$NDVI = \frac{(\rho_{NIR} - \rho_{Red})}{(\rho_{NIR} + \rho_{Red})}$	Normal Difference vegetation Index (NDVI)
Bannari et al., 1995	مقدار بازتابندگی باند سبز = $\rho_{Green}$ مقدار بازتابندگی باند قرمز = $\rho_{Red}$	$GNDVI = \frac{(\rho_{Green} - \rho_{Red})}{(\rho_{Green} + \rho_{Red})}$	Green Normal Difference Vegetation Index (GNDVI)
Adams et al., 1999	مقدار بازتابندگی باند سبز = $\rho_{Green}$ مقدار بازتابندگی باند آبی = $\rho_{Blue}$	$NDVI = \frac{\rho_{Green} - \rho_{Blue}}{\rho_{Green} + \rho_{Blue}}$	Normal Difference Yellowness Index (NDYI)
Tucker & Sellers, 1986	مقدار بازتابندگی باند مادون = $\rho_{NIR}$ قرمز = $\rho_{Red}$	$SR = \frac{(\rho_{NIR})}{(\rho_{Red})}$	Simple Ratio (SR)
Richardson & Wiegand, 1977	مقدار بازتابندگی باند مادون = $\rho_{NIR}$ قرمز = $\rho_{Red}$ مقدار بازتابندگی باند قرمز = $\rho_{NIR}$ مقدار بازتابندگی باند مادون = $\rho_{NIR}$ شیب خط خاک = $\beta$ عرض از مبدأ خط خاک = $C_2$	$PVI = \frac{\rho_{NIR} - \varphi \rho_{Red} - \beta}{\sqrt{1 + \varphi^2}}$	Perpendicular Vegetation Index (PVI)
Huete et al., 1994	مقدار بازتابندگی باند مادون = $\rho_{NIR}$ قرمز = $\rho_{Red}$ ضرایب تصحیح اتمسفری $C_1$ و $L$ = $C_2$	$EVI = 2.5 \times \frac{\rho_{NIR} - \rho_{Red}}{(\rho_{NIR} + C_1 \times \rho_{Red} - C_2 \times \rho_{Blue} + L)}$	Enhanced vegetation index (EVI)
Gitelson et al., 2003	مقدار بازتابندگی باند مادون = $\rho_{NIR}$ قرمز = $\rho_{Red}$ ضریب تصحیح اتمسفری $L$ = $C_2$	$EVI2 = 2.5 \times \frac{\rho_{NIR} - \rho_{Red}}{(\rho_{NIR} + 2.4 \times \rho_{Red} + 1)}$	Enhanced vegetation index (EVI2)
Bannari et al., 1995	مقدار بازتابندگی باند مادون = $\rho_{NIR}$ قرمز = $\rho_{Red}$ شیب خط خاک = $\beta$ عرض از مبدأ خط خاک = $L$	$TSAVI = \frac{\varphi(\rho_{NIR} - \varphi \rho_{Red} - \beta)}{\varphi \rho_{NIR} + \rho_{Red} + \varphi \beta + 0.08(1 + \varphi^2)}$	Transformed Soil-Adjusted Vegetation Index (TSAVI)
Huete & Tucker., 1991; Qi et al., 1994	مقدار بازتابندگی باند مادون = $\rho_{NIR}$ قرمز = $\rho_{Red}$ عامل تنظیم‌کننده خاک = $L$	$SAVI = \frac{(\rho_{NIR} - \rho_{Red})}{(\rho_{NIR} + \rho_{Red} + L)} (1 + L)$	Soil Adjust Vegetation Index (SAVI)
Huete et al., 1994	مقدار بازتابندگی باند مادون = $\rho_{NIR}$ قرمز = $\rho_{Red}$	$OSAVI = 1.16 \times \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red} + 0.16}$	Optimized Soil Adjusted Vegetation Index

بازگشتی است که توانایی یادگیری و به خاطرسپاری وابستگی‌های بلندمدت در داده‌های متوالی را دارد. داده‌های متوالی مورد نظر، در این مقاله، همان سری زمانی شاخص NDVI با  $\lambda$  باند است که هر باند اطلاعاتی در زمینه شاخص NDVI در یکی از زمان‌های دریافت در منطقه معنای را دربر دارد. این شبکه‌ها را اولین بار هوخرایتر<sup>۱</sup> و اشميدوهوب<sup>۲</sup> (۱۹۹۷) معرفی کردند. در حقیقت، هدف از طراحی شبکه‌های LSTM حل مشکل به‌یادسپاری اطلاعات درمورد بازه‌های زمانی بلندمدت بود. ساختار این شبکه‌ها به صورتی است که اطلاعات خیلی دور را به‌خوبی فراموشند. شکل ۲ یک واحد LSTM را در زمان  $t$  نشان می‌دهد.



شکل ۲. سلول LSTM در زمان  $t$

با توجه به شکل ۲، این مازول دارای سه دروازه فراموشی<sup>۳</sup>، ورودی<sup>۴</sup> و خروجی<sup>۵</sup> است که روابط زیر بر ورودی‌های آنها اعمال می‌شود.

$$i_t = \sigma(x_t * U^i + h_{t-1} * W^i) \quad (1)$$

$$f_t = \sigma(x_t * U^f + h_{t-1} * W^f) \quad (2)$$

$$o_t = \sigma(x_t * U^o + h_{t-1} * W^o) \quad (3)$$

$$\tilde{C}_t = \tanh(x_t * U^g + h_{t-1} * W^c) \quad (4)$$

$$C_t = \sigma(f_t * C_{t-1} + i_t * \tilde{C}_t) \quad (5)$$

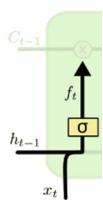
- 1. Hochreiter
- 2. Schmidhuber
- 3. Forget Gate
- 4. Input Gate
- 5. Output Gate

در این مطالعه، شاخص NDVI به دلیل سادگی محاسبه، مقبولیت و کاربرد عام آن به کار رفت و این شاخص درمورد هریک از  $\lambda$  تاریخ دریافت تصویر، با استفاده از باندهای طیفی R (قرمز) و NIR (مادون قرمز نزدیک) متعلق به آن تاریخ، محاسبه شد. سپس کانال‌های به دست آمده، به ترتیب تاریخ صعودی، مرتب و پس از پشت‌سازی با یکدیگر، مکعبی تصویری با  $\lambda$  باند تشکیل شد. این مکعب تصویری، در واقع، همان سری زمانی NDVI با  $\lambda$  باند است که باندهای ۱ تا ۹، به ترتیب، متعلق به شاخص محاسبه شده از اولین تا آخرین تاریخ دریافت در منطقه مطالعاتی است. هر پیکسل از این تصویر حاوی دنباله اطلاعات متوالی مربوط به شاخص NDVI در  $\lambda$  تاریخ متفاوت از فصل کشت است. از این اطلاعات دنباله‌ای به منزله تصویر ورودی به شبکه، ترسیم پروفایل زمانی شاخص برای محصولات کشت‌شده و بررسی الگوی رشد آن محصولات، در طول دوره کاشت تا برداشت، استفاده می‌شود. از شاخص‌های جزئی (دوره‌ای) حدوداً سه‌ماهه، متعلق به بیشینه NDVI که بیانگر سرعت رشد محصولات است، برای تقویت حافظه بلندمدت شبکه و بهبود نتایج طبقه‌بندی استفاده خواهد شد.

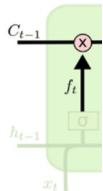
#### ۴-۲- شبکه‌های کانولوشنی LSTM

شبکه‌های عصبی بازگشتی که مخفف آن RNN است، در حقیقت به شکل زنجیره‌ای تکرارشونده از واحدهای شبکه‌های عصبی‌اند که برای کار روی داده‌های دنباله‌ای یا سری‌های زمانی طراحی شده‌اند. این شبکه‌ها، اگرچه به صورت نظری قادر به یادگیری و لحاظ‌کردن وابستگی‌هایی با فواصل طولانی‌اند، در عمل، مشکل وابستگی بلندمدت دارند و حین آموزش روی داده‌های آموزشی، دچار انفجار یا محوش‌گی گردیدند. Bengio et al., 1994; Hochreiter & Schmidhuber, 1997 می‌شوند. به عبارت دیگر، این شبکه‌ها روی سری‌های طولانی عملکرد مطلوبی نشان نمی‌دهند. شبکه LSTM زیرمجموعه شبکه‌های عصبی

اطلاعات حافظه بلندمدت انتقالی از  $C_{t-1}$  حذف شود. مقدار ۱ یعنی تمامی اطلاعات در  $C_{t-1}$  باید به مرحله بعد انتقال یابد و مقدار صفر یعنی تمامی اطلاعات آن باید حذف شود. شکل‌های ۳ و ۴، به ترتیب، مراحل یادشده را نشان می‌دهد.



شکل ۳. اعمال تابع سیگموئید روی ورودی‌ها و محاسبه خروجی دروازه فراموشی



شکل ۴. عملیات ضرب خروجی دروازه فراموشی در اطلاعات حافظه بلندمدت  $C_{t-1}$

گام ۲) دستیابی به اطلاعات حافظه بلندمدت مختص به مرحله  $t$  با افزودن اطلاعات جدید به نوار حافظه بلندمدت

در دروازه ورودی، ابتدا خروجی‌های دو لایه شبکه عصبی سیگموئید و تائزانت هایپربولیک (شکل ۵) محاسبه می‌شود. سپس با ضرب نقطه‌به‌نقطه آنها در یکدیگر، اطلاعات مناسب گزینش می‌شود و از طریق عملگر جمع نقطه‌به‌نقطه، این اطلاعات به اطلاعات پیشین حافظه بلندمدت اضافه می‌شود (شکل ۶). خروجی  $h_t$  که با اعمال تابع فعال‌ساز  $\sigma$  عددی بین صفر و یک است، در خروجی  $\tilde{C}_t$  که به دلیل اعمال تابع  $tanh$  عددی بین -۱ و ۱ است، ضرب می‌شود. با این کار تصمیم گرفته می‌شود که چه مقدار از اطلاعات به دست آمده به حافظه بلندمدت اضافه شود. در واقع،

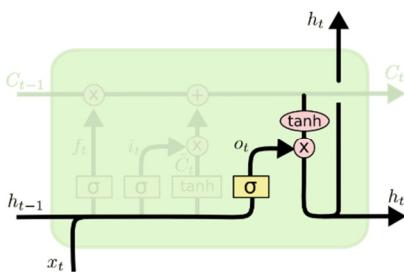
$$h_t = \tanh(C_t) * o_t \quad \text{رابطه (۶)}$$

در روابط (۱) تا (۶)،  $x_t$  برابر با مقدار شاخص NDVI در زمان  $t$ ،  $h_{t-1}$  مقدار خروجی سلول قبل،  $\tilde{C}_t$  مقدار اولین مسیر دروازه ورودی پس از اعمال تابع سیگموئید ( $\sigma$ ) بر ورودی‌های  $x_t$  و  $h_{t-1}$  و مقدار دومین مسیر آن دروازه، پس از اعمال تابع تائزانت هایپربولیک ( $\tanh$ ) روی همان ورودی‌هاست.  $f_t$  مقدار دروازه فراموشی،  $o_t$  مقدار دروازه خروجی،  $C_t$  نشان‌دهنده اطلاعات حافظه بلندمدت شبکه در زمان  $t$  و  $h_t$  خروجی نهایی سلول در زمان  $t$  و  $W^g, W^o, W^f, W^i$  نشان‌دهنده وزن‌ها یا، به عبارت بیشتر، کرنل‌های کانولوشن مربوط به  $h_{t-1}$  است.  $U^i, U^o, U^f$  و  $U^g$  نیز معرف کرنل‌های کانولوشن متعلق به  $x_t$  در مبادی ورودی دروازه‌هاست و اندیس بالای آنها بیانگر گیت یا دروازه‌ای است که از آن عبور می‌کنند. اندیس  $g$  به مسیر دوم دروازه ورودی مرتبط است که پیش‌تر به آن اشاره شد.

در شبکه LSTM، حافظه بلندمدت به شکل نواری، تمامی سلول‌ها را به یکدیگر متصل می‌کند. این همان نواری است که  $C_{t-1}$  را به  $C_t$  در شکل ۱ وصل کرده و شبکه، از طریق دروازه‌ها و عملگرهای ضرب و جمع، این توانایی را دارد که اطلاعات جدیدی را به آن بیفزاید یا از آن حذف کند. مطابق شکل ۱، این کار طی مراحل زیر انجام می‌شود:

گام ۱) تصمیم‌گیری درباره حذف یا نگهداری اطلاعات نوار حافظه بلندمدت واردشده به سلول این کار با استفاده از یک لایه شبکه عصبی سیگموئید، به همراه یک عملگر ضرب نقطه‌به‌نقطه انجام می‌شود. در مرحله نخست، خروجی دروازه فراموشی که پس از اعمال تابع فعال‌ساز  $\sigma$ ، عددی بین صفر و یک است، محاسبه می‌شود (شکل ۳). در مرحله دوم، این خروجی در مقدار  $C_{t-1}$  ضرب (شکل ۴) و بنابراین، در دروازه فراموشی تصمیم گرفته می‌شود که چه میزان از

سطرهای پیشین، گزینش می‌شود و به نوار حافظه بلندمدت انتقال می‌یابد و اطلاعات آن را تحت تأثیر قرار می‌دهد؛ در نهایت نیز، خروجی سلول محاسبه می‌شود. در این مطالعه، کانال‌ها یا باندهای تصویر حاوی سری زمانی NDVI نقش  $x_t$  را دارند و با توجه به اینکه این سری زمانی حاوی نُه کانال است، شبکه LSTM شامل نُه واحد یا سلول خواهد بود.

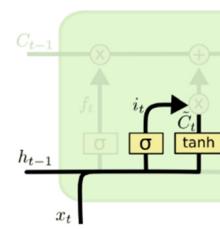


شکل ۷. محاسبه  $h_t$  (خروجی سلول در زمان t)

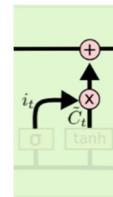
## ۵-۲-آماده‌سازی داده‌های ورودی و برچسب‌های زمینی متناظر برای آموزش شبکه

برای مطالعه الگوی رشد محصولات کشاورزی در فصل کشت و استخراج ویژگی‌های فنولوژیک سنجش از دوری از این الگوها، به منظور استفاده در تفکیک محصولات گوناگون کشت شده در منطقه مورد مطالعه، با توجه به وجود پوشش ابر، در نهایت باندهای R و NIR ماهواره سنتینل-۲ دانلود شد. این کار طی نُه تاریخ مختلف، با فواصل زمانی تقریباً یکماهه، انجام شد. با استفاده از نرمافزار متلب، شاخص NDVI هر تاریخ محاسبه و کانال‌های مذکور، در نرمافزار ArcGIS به ترتیب تاریخ صعودی مرتب و با یکدیگر stack شدند و تصویر مربوط به سری زمانی NDVI با نُه کانال (باند) تشکیل دادند. هر کانال شامل شاخص NDVI محسوبه شده درمورد پیکسل‌ها، در یکی از تاریخ‌های دریافت تصویر است. پس از آن، با استفاده از نواحی آموزش و تست، تصاویر سری زمانی NDVI این دو ناحیه از روی سری زمانی NDVI کل منطقه، برش

در این دروازه، مجموع ورودی‌های  $x_t$  و  $h_{t-1}$  یک بار از تابع  $\sigma$  و بار دیگر از تابع  $\tanh$  گذر می‌کند و در هم ضرب می‌شوند. حاصل این ضرب به اطلاعات موجود در حافظه بلندمدت افزوده می‌شود و با این کار، اطلاعات حافظه بلندمدت متعلق به مرحله  $C_t$  به دست می‌آید.



شکل ۵. محاسبه  $i_t$  و  $\tilde{C}_t$  در دروازه ورودی



شکل ۶. عملیات ضرب نقطه‌ای  $i_t$  و  $\tilde{C}_t$  در یکدیگر و جمع نتیجه آن با اطلاعات جاری در حافظه بلندمدت

## گام (۳) محاسبه خروجی سلول

در این مرحله، باید تصمیم گرفته شود که چه اطلاعاتی از حافظه بلندمدت  $C_t$  باید به خروجی برد شود. برای این منظور، اطلاعات حافظه بلندمدت  $C_t$  ابتدا از یک تابع تائزانت هایپربولیک گذر می‌کند و در تابع سیگموئید اعمال شده بر مجموع ورودی‌های  $x_t$  و  $h_{t-1}$  ضرب می‌شود (شکل ۷). در این مرحله نیز، تابع سیگموئید و عملگر ضرب نقطه‌ای کار گزینش اطلاعات و انتقال آن به خروجی، یا همان  $h_t$  را انجام می‌دهند. در واقع، محاسبه  $h_t$  آغازی است بر تکرار محاسبات گام‌های ۱ تا ۳ درمورد سلول بعدی.

بنابراین مطابق گام‌های ۱ تا ۳، در هر سلول از شبکه، اطلاعاتی به منزله حافظه کوتاه‌مدت ایجاد می‌شود. این اطلاعات، پس از فرایندهای یادشده در

به نوار حافظه بلندمدت پنجم، هنگام ورود به سلول، اضافه شده است.

### ۳- نتایج و بحث

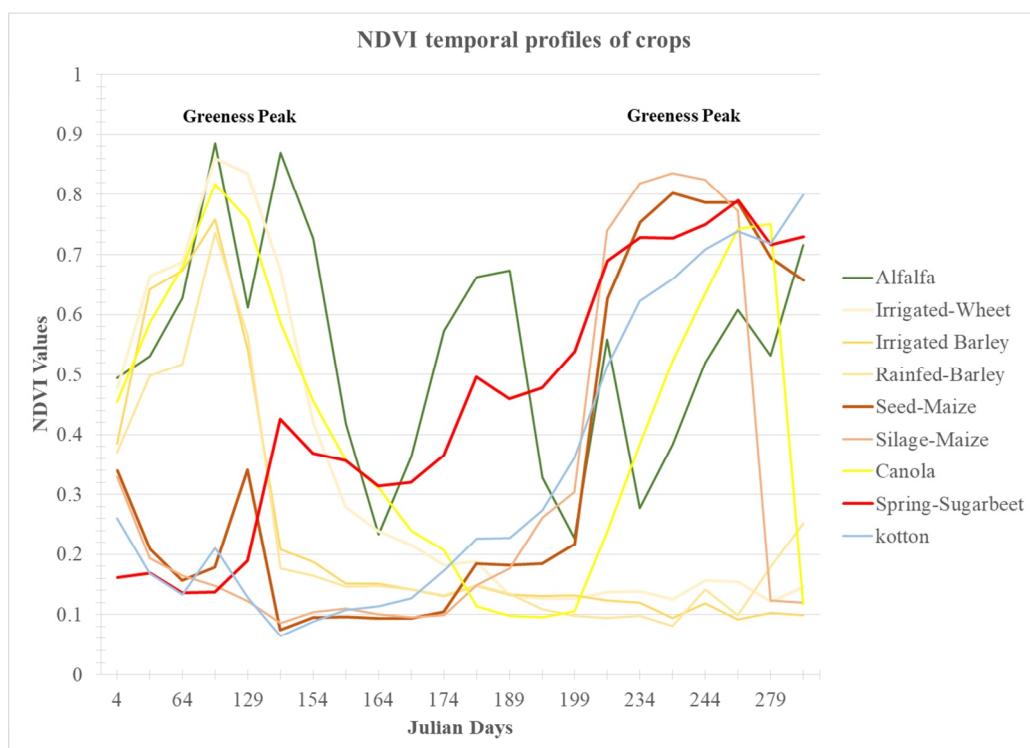
**۱-۱- بررسی الگوی زمانی NDVI برای محصولات سری‌های زمانی شاخص‌های مرتبط با پوشش‌های گیاهی که از محاسبه این شاخص‌ها در زمان‌های گوناگون و پشت‌سازی<sup>۱</sup> کانال‌های حاصل به دست می‌آید، اطلاعات مفیدی درباره ویژگی‌های فنولوژیک فراهم می‌کند. از جمله این ویژگی‌ها، می‌توان به زمان‌های کاشت و برداشت، شب رشد و پیری، زمان رسیدن به اوج سبزینگی و به‌طور کلی الگوی رشد محصولات اشاره کرد. این سری‌های زمانی در بردارنده اطلاعاتی متواالی درمورد میزان سبزینگی محصول، در گام‌های زمانی مشخص، برای هر پیکسل از تصویر منطقه مطالعاتی هستند و هر گام وابسته به گام قبل است. روش‌های مبتنی بر فنولوژی، برای تهیه نقشه محصولات، معمولاً از سری زمانی شاخص‌های طیفی گیاهی مانند NDVI (شاخص پوشش گیاهی بهبودیافته) و نرمال شده)، EVI (شاخص پوشش گیاهی بهبودیافته) و دیگر شاخص‌های پوشش گیاهی به منظور نشان دادن منحنی رشد محصولات طی فصل رشد استفاده می‌کنند (Foerster et al., 2012); از این‌رو می‌توان آنها را در روش‌های یادگیری عمیقی به کار برد که از داده‌های متواالی برای آموزش الگوریتم خود و طبقه‌بندی محصولات استفاده می‌کنند. در این مطالعه، از شاخص NDVI استفاده کردیم؛ دلیل این کار سادگی محاسبه و کاربرد عام این شاخص بود. شکل ۸ پروفیل زمانی NDVI را برای محصولات مورد مطالعه نشان می‌دهد. به منظور محاسبه شاخص مذکور برای هر محصول طی هر دوره زمانی، مقدار میانگین شاخص در مزارع گوناگون لحظه شده است. بررسی این پروفیل**

داده شد. یکی از این دو تصویر در مرحله آموزش و دیگری در مرحله تست، به منزله ورودی به شبکه LSTM، به کار رفت. با توجه به تعداد نه تاریخ برای شبکه LSTM، متناظر با هر تاریخ، یک سلول و در مجموع، نه سلول در نظر گرفته شد؛ ورودی هر سلول کanal NDVI هم‌تاریخ با آن خواهد بود. سپس مختصات زمینی نوع محصولات کشتشده در نواحی آموزشی و تست، به روش میدانی و با استفاده از GPS دستی، برداشت شد. محدوده محصولات زراعی در این دو ناحیه، از روی تصاویر، به صورت برداری رقومی شد و فرمت آن به دو ماتریس رستری با طول و عرض برابر با تصاویر نواحی آموزشی و تست تبدیل شد. در ادامه، با استفاده از تصویر سری زمانی NDVI متعلق به سایت آموزشی و ماتریس رستری داده‌های زمینی متناظر با آن به منزله ورودی شبکه و خروجی صحیح، در دوازده مرحله یا اپوک با نرخ یادگیری ۰/۴، آموزش شبکه LSTM در ناحیه آموزش انجام شد. از طریق مقایسه خروجی شبکه با خروجی صحیح، عملیات بهینه‌سازی شبکه با استفاده ازتابع آنتروپی متقاطع انجام پذیرفت و وزن‌های شبکه بهینه شد. در انتهای، از این شبکه آموزش دیده در طبقه‌بندی محصولات کشاورزی در ناحیه تست استفاده شد و خروجی طبقه‌بندی، با ماتریس رستری داده‌های زمینی متعلق به سایت تست، مقایسه و دقت شبکه ارزیابی شد. در این مطالعه، به منظور تقویت اطلاعات حافظه بلندمدت شبکه و به دلیل تفاوت سرعت رشد محصولات گوناگون با یکدیگر، اطلاعات درمورد سرعت رشد محصولات را به نوار حافظه بلندمدت افزودیم؛ بدین صورت که به نوار وارد شده به سلول‌های سوم، پنجم، هفتم و نهم شبکه، اطلاعات دو تاریخ پیش از آن سلول در زمینه سرعت رشد یا پیری محصولات را اضافه کردیم. این اطلاعات شامل بیشینه شاخص NDVI، در دو زمان قبل، برای سلول‌های مذکور است. برای نمونه، بیشینه NDVI کانال‌های سوم و چهارم سری زمانی NDVI که به زمان‌های سوم و چهارم دریافت تصویر اختصاص دارد،

1. Stack

برگ وسیع‌تری که دارد، به‌جز در اواخر دوره، بالاتر از سه محصول دیگر قرار دارد. با نگاه به شکل ۸، درمی‌یابیم که حدوداً در میانه مهر و پس از گذشت حدود ۲۵۰ روز از ابتدای سال میلادی، مقدار شاخص ذرت علوفه‌ای، در مقایسه با ذرت دانه‌ای بهشدت افت می‌کند. این نشان می‌دهد که محصول علوفه‌ای مورد اشاره، در حالی که هنوز سبز است برداشت می‌شود. مطابق شکل ۸، مقدار شاخص محصول یونجه در برخی دوره‌های زمانی به محصولات دیگر بسیار نزدیک است. این نشان از همپوشانی طیفی میان این محصولات و به‌عبارت دیگر، کاهش واریانس میان کلاسی دارد. از دیگرسو، محصولی مانند یونجه یا کلزا، به‌دلایلی همچون محدودیت دسترسی هم‌زمان به ماشین‌آلات کشاورزی برای آماده‌سازی زمین یا کاشت محصول، در زمین‌های متفاوت معمولاً با اختلاف زمانی کشت می‌شوند. همین باعث می‌شود، از نظر مقدار شاخص در زمانی خاص، نمودهای متفاوتی داشته باشند که

زمانی نشان داد که الگوی فنولوژیکی یا، به‌عبارت دیگر، روند تغییر سبزینگی محصولات گوناون، از مرحله کاشت تا زمان برداشت، در شکل کلی با یکدیگر متفاوت است؛ اگرچه در برخی مقاطع زمانی، این الگوها به هم نزدیک می‌شود. همان‌طور که در شکل ۸ مشاهده می‌شود، مقدار شاخص از اوایل تا اواخر دوره درمورد محصولی مانند یونجه، با افت و خیزهایی متناوب همراه است که نشان از برداشت دوره‌ای یونجه دارد. اوج سبزینگی محصولاتی مانند گندم، جو و کلزا حدوداً ۱۲۹ روز پس از آغاز سال میلادی، یعنی دهه اول ماه مارس، برابر با دهه دوم اردیبهشت اتفاق می‌افتد. پس از آن، دوره پیری تا زردشدن و رسیدن این محصولات آغاز و مقدار شاخص برای آنها نزولی می‌شود؛ درصورتی که مقدار شاخص دیگر محصولات مورد مطالعه، یعنی ذرت علوفه‌ای و دانه‌ای، چند در قند بهاره و پنبه، در این دوره زمانی صعودی است و این محصولات در حال رشد هستند. البته چند در قند (خط قرمز) به‌دلیل سطح



شکل ۸. پروفیل زمانی NDVI محصولات براساس تعداد روز از ابتدای سال میلادی، در منطقه مورد مطالعه

تنظیم شود؛ یعنی ماتریس داده‌های زمینی به ماتریسی با عمق برابر با تعداد نمونه‌های زمینی تبدیل و هر عمق این ماتریس به یک محصول اختصاص یابد. سپس، در این عمق، برچسب محصول مورد نظر به مقدار ۱ و برچسب محصولات دیگر به مقدار صفر تغییر یابد. در تصویر ورودی نیز، مطابق ماتریس داده‌های زمینی، مقادیر پیکسل‌های متعلق به محصول یونجه بدون تغییر باقی می‌ماند و سایر پیکسل‌ها مقدار صفر می‌گیرند. به بیان گویا، کanal حاوی داده‌های زمینی پس از تنظیم به روش hot one، به صورت نقطه‌به‌نقطه در تک‌تک کanal‌های تصویر ورودی ضرب می‌شود. با این کار، هنگام اعمال کرنل‌های کانولوشن روی تصویر ورودی در هر مرحله، فقط ویژگی یک محصول استخراج می‌شود. پس از محاسبه خروجی شبکه و مقایسه آن با خروجی صحیح، خطای شبکه به دست می‌آید و در عملیات بهینه‌سازی، با تنظیم وزن‌های شبکه، این خطای کمینه می‌شود. بدین طریق کanal حاوی برچسب‌های واقعیت زمینی برای تمامی کلاس‌های موجود، به روش hot one تنظیم و مطابق آن، تصویر ورودی نیز برای آموزش شبکه آماده می‌شود. شکل ۹ نمودار آموزش شبکه LSTM در این مطالعه را در دوازده اپوک و با نرخ یادگیری  $0.4/0$  نشان می‌دهد. همان‌گونه که مشخص است، خطای آموزش، از اپوک ششم به بعد تقریباً به حد ایستایی رسیده است.

**۳-۳- طبقه‌بندی با استفاده از شبکه آموزش دیده LSTM**  
بررسی پروفیل زمانی شاخص NDVI مربوط به محصولات مورد نظر، در طول دوره رشد، نشان داد که الگوی فنولوژیکی یا روند تغییر سبزینگی محصولات گوناگون، از مرحله کاشت تا زمان برداشت، تفاوتی کلی با یکدیگر دارد؛ اگرچه در برخی مقاطع زمانی این الگوها به هم نزدیک می‌شود. ازان جاکه تفاوت در

افزایش واریانس درون کلاسی را در پی خواهد داشت. این موارد لزوم استفاده از پروفایل‌های زمانی شاخص‌های گیاهی و استفاده از اطلاعات متوالی استخراج شده از آنها را بیش از پیش آشکار می‌سازد. ازان جاکه شبکه LSTM قادر به یادگیری و ذخیره اطلاعاتی با توالی زمانی بلندتر از نمونه‌های آموزشی است، یعنی ویژگی‌های منحصر به فردی همچون زمان‌های کاشت، برداشت، گل‌دهی، اوج سبزینگی و شبکه‌های رشد و پیری؛ بنابراین استفاده از آن در طبقه‌بندی و شناسایی محصولات راهگشاست زیرا روش‌های معمول طبقه‌بندی از جهاتی مشکل و پیچیده است.

### ۲-۳- آموزش شبکه

آماده‌سازی مجموعه داده‌های آموزشی به صورت زوج مرتب تصویر، به منزله ورودی و داده‌های زمینی، به منزله خروجی صحیح، در یادگیری نظارت شده، اهمیت بسیار زیادی در زمینه آموزش شبکه دارد. به عبارت دیگر، ورودی شبکه‌های کانولوشنی در یادگیری با نظارت به شکل تصویری است که برچسب‌های زمینی منتظر با پیکسل‌های آن به منزله خروجی صحیح شبکه مشخص می‌شود؛ از این‌رو به دلیل روابط همسایگی میان پیکسل‌های تصویر ورودی، هنگام پیش‌خور<sup>۱</sup> دادن آن به شبکه طی فرایند آموزش، باید در نظر داشت که کرنل‌های کانولوشن روی تصویر ورودی می‌لغزند و لذا ممکن است کرنل در موقعیتی قرار گیرد که پیکسل‌های زیر آن به بیش از یک نوع کلاس مربوط باشند. در این صورت پس از انجام شدن عملیات کانولوشن، نتیجه یا ویژگی حاصل متعلق به یک کلاس نخواهد بود. با توجه به تأثیر این ویژگی در استخراج ویژگی‌های مراحل بعدی، این نکته به کاهش دقیقت آموزش شبکه منجر خواهد شد. این مسئله، به خصوص در طبقه‌بندی محصولات کشاورزی و با توجه به همسایگی محصولات گوناگون با هم، تشدید خواهد شد. برای پیشگیری از آن، ابتدا باید ماتریس one hot encoding رستری داده‌های زمینی به روش

1. feed forward

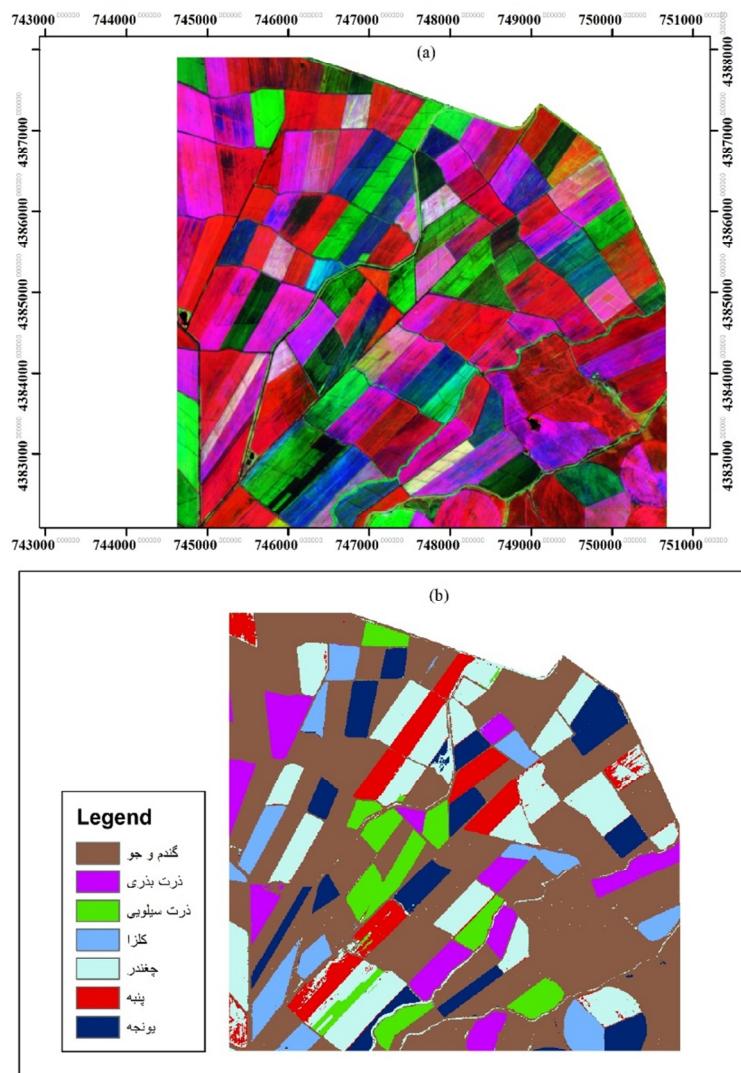


شکل ۹. نمودار فرایند آموزش شبکه در دوازده اپوک

رنگی کانال‌های شماره ۱، ۵ و ۹ به متنزله کانال‌های نمایش رنگی R، G، B نشان می‌دهد. شکل ۱۰ نیز نتیجه طبقه‌بندی شبکه آموزش‌دیده LSTM روی داده‌های تست را که برای حذف کلاس‌های تک‌پیکسل، یک مرحله فیلتر اکثربت بر آن اعمال شده، نمایش می‌دهد.

جدول ۳ ماتریس اغتشاش یا ماتریس خطای نتیجه طبقه‌بندی محصولات را با استفاده از این شبکه آموزش‌دیده و شکل ۱۰ نمودار دقت و هزینه این آموزش را نشان می‌دهد. مطابق جدول ۳ و شکل ۱۰، شبکه به خوبی توانسته است، با استفاده از سری زمانی شاخص NDVI آموزش ببیند و محصولات را از هم تفکیک کند. قطعاً تقویت نوار حافظه بلندمدت شبکه، با افزودن بیشینه NDVI دو زمان قبل برای هر سلول، با توجه به تفاوت سرعت رشد محصولات گوناگون، در آموزش بهتر شبکه تأثیرگذار بوده است. استفاده از ویژگی‌هایی که بتوانند تباین میان محصولات گوناگون را افزایش دهند دقت و کارآبی الگوریتم را بهبود می‌بخشد.

الگوی رشد محصولات گوناگون به تفاوت در منحنی زمانی شاخص NDVI می‌انجامد، می‌توان از این منحنی زمانی که توالی مقدار سبزینگی محصولات را در طول دوره زراعی نشان می‌دهد، برای تفکیک آنها روی تصاویر ماهواره‌ای بهره جست. به همین منظور، در این مطالعه پس از تشکیل سری زمانی شاخص NDVI با استفاده از باندهای قرمز و مادون قرمز نزدیک ماهواره سنتیل-۲، در نه تاریخ متفاوت، شبکه LSTM با نه سلول تشکیل شد. سپس کانال رستری حاوی برچسب‌های زمینی محصولات، به صورت one hot برای تمامی محصولات موجود در آن تنظیم شد و کانال‌های سری زمانی نیز، مطابق گفته‌های پیش‌تر، متناسب با برچسب‌ها تنظیم شدند. در ادامه، هریک از کانال‌های ۱ تا ۹ مربوط به سری زمانی مذکور، به صورت قطعاتی با ابعاد  $256 \times 256$  پیکسل، به متنزله ورودی به سلول هم‌شماره خود در شبکه LSTM در نظر گرفته شد. شبکه پس از آموزش، با استفاده از نمونه‌های زمینی و تنظیم کرنل‌ها، روی منطقه تست اجرا شد. شکل ۱۰ تصویر رنگی کادبی را از سری زمانی NDVI، با ترکیب



شکل ۱۰. نمایش رنگی کاذب (a); طبقه‌بندی مجموعه داده‌های تست با استفاده از شبکه آموزش دیده LSTM (b)

جدول ۳. ماتریس ابعام مربوط به نتیجه طبقه‌بندی محصولات با استفاده از شبکه LSTM

جمع	یونجه	پنبه	چغندر	کلزا	ذرت بذری	ذرت سیلوبی	گندم / جو	گندم / جو
140	2	1	0	11	1	3	122	گندم / جو
93	1	1	2	0	3	77	9	ذرت سیلوبی
74	0	0	1	0	64	1	8	ذرت بذری
93	8	10	0	69	0	0	6	کلزا
94	1	4	84	0	2	3	0	چغندر
83	0	67	1	0	8	7	0	پنبه
73	56	0	2	4	2	1	8	یونجه
650	68	83	90	84	80	92	153	جمع
دقت کلی (بر حسب درصد) = ۸۲					ضریب کاپا = ۰/۸۰			

#### ۴- نتیجه‌گیری

مطالعه را کمبود داده‌های زمینی و نیز اختصاص برچسب زمینی به علف‌های هرز موجود در مرز مزارع دانست زیرا افزایش داده‌های زمینی دارای برچسب برای آموزش شبکه و نیز در نظرنگرفتن محدوده‌های مرزی اراضی می‌تواند دقت طبقه‌بندی را افزایش دهد. شایان ذکر است که گردآوری داده‌های زمینی، به خصوص در موضوع نقشه‌برداری از محصولات، بسیار وقت‌گیر و پرهزینه و دشوار است. البته روش‌های دارای قابلیت یادگیری الگوهای زمانی رشد محصولات، برای یادگیری، به حجم بالای داده‌های زمینی نیاز دارند اما، اگر خوب آموزش ببینند، واستنگی دوباره آنها به داده‌های زمینی کاهش خواهد یافت و بدون نیاز به گردآوری مجدد داده‌های واقعیت زمینی بسیار، می‌توان از آنها طی سال‌های آتی، در همان منطقه و یا در مناطق دیگر استفاده کرد.

#### ۶- منابع

- Adams, M.L., Philpot, W.D. and Norvell, W.A., 1999. **Yellowness index: an application of spectral second derivatives to estimate chlorosis of leaves in stressed vegetation**. International Journal of Remote Sensing, 20(18), pp.3663-3675.
- Ashourloo, D., Shahrabi, H.S., Azadbakht, M., Rad, A.M., Aghighi, H. & Radiom, S., 2020, **A Novel Method for Automatic Potato Mapping Using Time Series of Sentinel-2 Images**, Computers and Electronics in Agriculture, 175, P. 105583.
- Bannari, A., Morin, D., Bonn, F. & Huete, A., 1995, **A Review of Vegetation Indices**, Remote Sensing Reviews, 13, PP. 95-120.
- Bargiel, D., 2017, **A New Method for Crop Classification Combining Time Series of Radar Images and Crop Phenology Information**, Remote Sensing of Environment, 198, PP. 369-383.
- Bengio, Y., Simard, P. & Frasconi, P., 1994, **Learning Long-Term Dependencies with Gradient Descent is Difficult**, IEEE Transactions on Neural Networks, 5, PP. 157-166.

تفاوت در منحنی زمانی شاخص NDVI، برای محصولات گوناگون کشاورزی، گواه این مطلب است که این محصولات در طول فصل زراعی، الگوی رشد نسبتاً متفاوتی بروز می‌دهند؛ هرچند در برخی مقاطع زمانی، این الگوها به یکدیگر نزدیک می‌شوند. به ویژه در مورد محصولاتی مانند گندم و جو، این الگوی طیفی- زمانی، رشد بسیار به یکدیگر شبیه است و به همین دلیل، در نقشه‌ طبقه‌بندی ارائه شده، این دو محصول یک کلاس در نظر گرفته شده‌اند. با توجه به همپوشانی طیفی محصولات در برخی مقاطع زمانی طی فصل کشت، تفکیک آنها با استفاده از تصاویر تک‌زمانه بسیار دشوار و با خطای بالای همراه است؛ در صورتی که مطابق تایج این مطالعه، استفاده از سری زمانی شاخص NDVI که الگوی زمانی رشد محصولات و سایر ویژگی‌های مرتبط را می‌توان از آن استخراج کرد، در روش یادگیری عمیقی همچون شبکه کانولوشنی LSTM که توانایی یادگیری بلندمدت این ویژگی‌های زمانی را دارد، چه بسا برای تفکیک محصولات کشاورزی مفید باشد. البته باید به این نکته بسیار مهم توجه ویژه داشت که این شبکه، در تشخیص محصولات کشاورزی، به گام‌های زمانی انتخابی برای کانال‌های ورودی بسیار حساس است؛ انتخاب زمان‌های مناسب در دقت آموزش شبکه بسیار تأثیرگذار است و می‌تواند هزینه یا خطای آموزش شبکه را کاهش دهد و کارآیی آن را در طبقه‌بندی محصولات گوناگون، بیفزاید. در این میان، از نقش پراهمیت داده‌های زمینی نباید غفلت کرد. برچسب‌های زمینی اشتباہ ممکن است به راحتی تأثیر گام‌های زمانی مناسب را از بین ببرند و با استخراج ویژگی‌های منتبه به یک برچسب زمینی همچون محصول یونجه که به محصول یا گیاه دیگری متعلق است، شبکه را گمراه کنند. روش‌های یادگیری عمیق، برای یادگیری ویژگی‌های داده‌های ورودی، به حجم بالای داده‌های زمینی نیاز دارند؛ با توجه به این نکته، می‌توان دلایل اصلی رسیدن به دقت طبقه‌بندی، یعنی ۸۲٪ برای دقت کلی و ۰٪ برای ضریب کاپا در این

- Foerster, S., Kaden, K., Foerster, M. & Itzerott, S., 2012, **Crop Type Mapping Using Spectral-Temporal Profiles and Phenological Information**, Computers and Electronics in Agriculture, 89, PP. 30-40.
- Gadiraju, K.K. & Vatsavai, R.R., 2020, **Comparative Analysis of Deep Transfer Learning Performance on Crop Classification**, In, Proceedings of the 9th ACM SIGSPATIAL International Workshop on Analytics for Big Geospatial Data (PP. 1-8).
- Gitelson, A.A., Viña, A., Arkebauer, T.J., Rundquist, D.C., Keydan, G. and Leavitt, B., 2003. **Remote estimation of leaf area index and green leaf biomass in maize canopies**. Geophysical research letters, 30(5).
- Hatfield, J.L. & Prueger, J.H., 2010, **Value of Using Different Vegetative Indices to Quantify Agricultural Crop Characteristics at Different Growth Stages under Varying Management Practices**, Remote Sensing, 2, PP. 562-578.
- Hochreiter, S. & Schmidhuber, J., 1997, **Long Short-Term Memory**, Neural Computation, 9, PP. 1735-1780.
- Huete, A. & Tucker, C., 1991, **Investigation of Soil Influences in AVHRR Red and Near-Infrared Vegetation Index Imagery**, International Journal of Remote Sensing, 12, PP. 1223-1242.
- Huete, A., Justice, C. & Liu, H., 1994, **Development of Vegetation and Soil Indices for MODIS-EOS**, Remote Sensing of Environment, 49, PP. 224-234.
- Jia, X., Khedelwal, A., Carlson, K.M., Gerber, J.S., West, P.C., Samberg, L.H. & Kumar, V., 2020, **Automated Plantation Mapping in Southeast Asia Using Modis Data and Imperfect Visual Annotations**, Remote Sensing, 12, P. 636.
- Krizhevsky, A., Sutskever, I. & Hinton, G.E., 2017, **ImageNet Classification with Deep Convolutional Neural Networks**, Communications of the ACM, 60, PP. 84-90.
- Lyu, H., Lu, H. & Mou, L., 2016, **Learning a Transferable Change Rule from a Recurrent Neural Network for Land Cover Change Detection**, Remote Sensing, 8, P. 506.
- Mou, L. & Zhu, X.X., 2018, **RiFCN: Recurrent Network in Fully Convolutional Network for Semantic Segmentation of High Resolution Remote Sensing Images**, arXiv preprint arXiv:1805.02091.
- Peña-Barragán, J.M., Ngugi, M.K., Plant, R.E. & Six, J., 2011, **Object-Based Crop Identification Using Multiple Vegetation Indices, Textural Features and Crop Phenology**, Remote Sensing of Environment, 115, PP. 1301-1316.
- Qi, J., Chehbouni, A., Huete, A.R., Kerr, Y.H. and Sorooshian, S., 1994. **A modified soil adjusted vegetation index**. Remote sensing of environment, 48(2), pp.119-126.
- Richardson, A.J. and Wiegand, C.L., 1977. **Distinguishing vegetation from soil background information**. Photogrammetric engineering and remote sensing, 43(12), pp.1541-1552.
- Rogan, J., Franklin, J. & Roberts, D.A., 2002, **A Comparison of Methods for Monitoring Multitemporal Vegetation Change Using Thematic Mapper Imagery**, Remote Sensing of Environment, 80, PP. 143-156.
- Rußwurm, M., & Körner, M., 2017, **Temporal Vegetation Modelling Using Long Short-Term Memory Networks for Crop Identification from Medium-Resolution Multi-Spectral Satellite Images**, In, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (PP. 11-19).
- Rußwurm, M. and Körner, M., 2018. **Convolutional LSTMs for cloud-robust segmentation of remote sensing imagery**. arXiv preprint arXiv:1811.02471.
- 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**, frontiers in Earth Science, 5, 17.

- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. & Rabinovich, A., 2015, **Going Deeper with Convolutions**, In, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (PP. 1-9).
- Tucker, C.J. and Sellers, P.J., 1986. **Satellite remote sensing of primary production**. International journal of remote sensing, 7(11), pp.1395-1416.
- Xie, Y., Sha, Z. & Yu, M., 2008, **Remote Sensing Imagery in Vegetation Mapping: A Review**, Journal of Plant Ecology, 1, PP. 9-23.
- Zhong, L., Hu, L. & Zhou, H., 2019, **Deep Learning Based Multi-Temporal Crop Classification**, Remote Sensing of Environment, 221, PP. 430-443.



سنجش از دور

، GIS ایران

سال چهاردهم، شماره اول، بهار ۱۴۰۱  
Vol.14, No. 1, Spring 2022

سنجش از دور و GIS ایران  
Iranian Remote Sensing & GIS

89-106



## Employing the Convolutional LSTM Network in Crop Classification using NDVI Time Series

Gili M.R.<sup>1</sup>, Ashourloo D.<sup>2\*</sup>, Aghighi H.<sup>2</sup>, Matkan A.A.<sup>3</sup>, Shakiba A.R.<sup>4</sup>

1. Ph.D. Student in Remote Sensing Center, Shahid Beheshti University
2. Assistant Prof. of Remote Sensing Center, Faculty of Earth Sciences, Shahid Beheshti University
3. Prof. of Remote Sensing Center, Faculty of Earth Sciences, Shahid Beheshti University
4. Associate Prof. of Remote Sensing Center, Faculty of Earth Sciences, Shahid Beheshti University

### Abstract

Changes in crop growth at relatively short intervals, asymmetry of cultivation of similar crops, the spectral similarity between different crops at certain times of the growing season, and lack of ground data make classifying crops in satellite imagery a challenging task. Changing the amount of canopy and greenness during the growing season is one of the most prominent characteristics of vegetation, including agricultural products, which can be monitored by using time series of vegetation indices that have useful information about the sequence of phenological features of crops. The use of deep learning methods with the ability of learning sequential information obtained from these time series can be useful in crop mapping and reducing dependence on ground data. The LSTM network is one of the types of RNNs in sequential data analysis that has the ability to learn long-term sequences of time-series information. Therefore, in this study, after extracting the NDVI time-series of 9 different dates from Sentinel-2 satellite images for a region located in Moghan plain, with ground labeled data related to the type of crops cultivated, we trained a convolutional LSTM network. Then we used this trained network to classify agricultural products in another region of the plain as a test site, and achieved an overall accuracy of 82% and a kappa coefficient of 0.8. Increasing the number of ground samples and selecting the exact boundary of crops, can increase the efficiency of the method used.

**Keywords:** Deep learning, LSTM, NDVI time-series, Sentinel-2, Crop classification.

\* Correspondence Address: R.S. & GIS Research Center, Shahid Beheshti University, Tehran. Tel: 021-22431723 09123750186 – 02122431723  
Email: Ashourloo@gmail.com