

Classification of Croplands Using Sentinel-2 Satellite Images and a Novel Deep 3D Convolutional Neural Network (Case Study: Shahrekord)

ALIREZA TAHERI DEHKORDI^{1*}, MOHAMMAD JAVAD VALADANZOEJ¹

1. Department of Photogrammetry and Remote Sensing, K. N. Toosi University of Technology, Tehran, Iran.

(Received: May. 1, 2021- Revised: June. 15, 2021- Accepted: June. 19, 2021)

ABSTRACT

Agriculture has been recognized as the main motive for economic growth and development in different countries of the world. In the meantime, mapping croplands through the classification of remote sensing images is one of the effective solutions in decision making and providing food security to the community. In this research, croplands are classified into different classes of agricultural products (including wheat, barley, corn, alfalfa, potatoes, and Sugar beets) using multi-temporal optical (Sentinel-2) and synthetic aperture radar (Sentinel-1) satellite images. All the steps related to the preparation of satellite images, have been conducted in the Google Earth Engine online processing platform. A novel three-dimensional deep convolutional neural network is used as the classifier. The designed network, in addition to three-dimensional kernels with the ability to extract spatial and temporal information of each pixel simultaneously, uses some escape connections of the previous layers. These connections, contrary to the feed-forward convolutional networks, feed the output of the previous layers to the new layers. After dividing the ground truth data into two categories of training and evaluation and assessing the performance of the network with 50 different training and evaluation data, the network's overall accuracy was calculated 91.6% on average. According to the final results, the designed escape connections increased the overall accuracy of classification by 2%. The proposed network was also compared with temporal and spatial-temporal Random Forests and Support Vector Machines which showed a better performance with a difference of at least 2.4%.

Keywords: Remote Sensing, Convolutional Neural Network, Deep Learning, Cropland Classification, Sentinel Satellite Images.

*Corresponding Author's Email: alireza.tahery@email.kntu.ac.ir

طبقه‌بندی کاربری اراضی کشاورزی با استفاده از تصاویر ماهواره‌ای سنتینل و شبکه عصبی پیچشی سه‌بعدی عمیق (مطالعه موردی: شهر کرد)

علیرضا طاهری دهکردی^{۱*}، محمدجواد ولدان‌زوج^۱

۱. گروه سنجش از دور و فتوگرامتری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران.
(تاریخ دریافت: ۱۴۰۰/۲/۱۱ - تاریخ بازنگری: ۱۴۰۰/۳/۲۵ - تاریخ تصویب: ۱۴۰۰/۳/۲۹)

چکیده

کشاورزی به عنوان عامل محرک رشد و توسعه اقتصادی در کشورهای مختلف دنیا شناخته شده است. در این بین تولید نقشه‌های سطح زیرکشت به واسطه طبقه‌بندی کاربری اراضی کشاورزی با استفاده از تصاویر سنجش از دوری، یکی از راهکارهای مؤثر در تصمیم‌گیری‌های کلان این حوزه و تامین امنیت غذایی جامعه به‌شمار می‌رود. در این پژوهش اراضی کشاورزی با استفاده از تصاویر چندزمانه نوری (سنتینل-۲) و رادار با روزه مجازی (سنتینل-۱) به کاربری مختلف محصولات کشاورزی پاییزه و بهاره (شامل گندم، جو، ذرت، یونجه، سیب‌زمینی و چغندر) طبقه‌بندی شد. کلیه مراحل مربوط به آماده‌سازی تصاویر ماهواره‌ای، در سامانه برخط گوگل ارث انجام پذیرفته است. جهت طبقه‌بندی نیز، از شبکه عصبی پیچشی عمیق سه‌بعدی با ساختاری نوین استفاده گردید. شبکه طراحی شده، علاوه بر استفاده از کرنل‌های سه‌بعدی با امکان استخراج همزمان اطلاعات همسایگی و زمانی هر پیکسل، از اتصالات فرار لایه‌های قبلی بهره برده است. این اتصالات فرار، برخلاف شبکه‌های پیچشی معمولی پیش‌خور، سبب استفاده از خروجی لایه‌های پیچشی قبلی در لایه‌های جدید می‌شوند. شبکه طراحی شده به کمک داده‌های واقعیت زمینی بدست آمده از بازدیدهای میدانی وسیع از منطقه مطالعاتی واقع در شهر کرد به صورت انتها-به-انتها مورد آموزش و ارزیابی قرار گرفته است. پس از تقسیم‌بندی داده‌های واقعیت زمینی به دو دسته آموزشی و ارزیابی، ارزیابی شبکه طی ۵۰ بار اجرا داده‌های آموزشی و ارزیابی متنوع، به‌طور میانگین ۹۱/۶٪ محاسبه شده است. اتصالات فرار طراحی شده، سبب افزایش دقت طبقه‌بندی هر کاربری شده و دقت نهایی طبقه‌بندی را ۲٪ افزایش دادند. روش ارائه شده با دو نوع زمانی و زمانی-مکانی روش‌های جنگل تصادفی و ماشین بردار پشتیبان نیز مورد مقایسه قرار گرفت که با اختلاف حداقل ۲،۴ درصدی، عملکرد بهتری از خود نشان داد.

واژه‌های کلیدی: سنجش از دور، شبکه عصبی کانولوشن، یادگیری عمیق، کاربری اراضی کشاورزی، تصاویر ماهواره‌ای سنتینل.

مقدمه

کشاورزی به‌عنوان قدیمی‌ترین فعالیت تولیدی و کلید توسعه تمدن بشری، مهم‌ترین موتور رشد و توسعه اقتصادی در تمامی کشورهای جهان شناخته شده است. در این بین، نقشه‌های سطح زیرکشت محصولات مختلف کشاورزی، نقش ویژه‌ای در برنامه‌ریزی‌های کلان مدیریتی ایفا می‌نمایند. به‌نحوی که با در دست بودن این نقشه‌ها، تامین امنیت غذایی جامعه، امکان تصمیم‌گیری درباره صادرات یا واردات و همچنین تعیین نرخ بازار محصولات مرتبط تسهیل می‌گردد (Xiao et al., 2018). امروزه استفاده از فناوری سنجش از دور، به‌سبب در اختیار گذاشتن تصاویر ماهواره‌ای با سطح پوشش وسیع و همچنین دقت‌های مکانی و

زمانی متنوع، به‌عنوان راهکاری مؤثر در کاربردهای مختلف حوزه کشاورزی از جمله تولید نقشه‌های به‌روز کاربری‌های اراضی کشاورزی، نقشه‌های سطح زیرکشت و پایش سلامت محصولات کشاورزی پیشنهاد می‌شود (Karthikeyan et al., 2020; Jin et al., 2018).

تصاویر ماهواره‌ای نوری، به‌عنوان رایج‌ترین تصاویر سنجش از دوری، در مطالعات مختلفی در حوزه کشاورزی نظیر (Van Tricht et al., 2018) مورد استفاده قرار گرفته‌اند. بخصوص آنکه طی چند دهه اخیر، ماموریت‌های فضایی برجسته‌ای نظیر مادیس^۱، لندست^۲ و سنتینل-۲^۳، به اخذ تصاویر نوری رایگان از کره زمین پرداخته‌اند. با پیشرفت فناوری، استفاده از تصاویر

* نویسنده مسئول: alireza.tahery@email.kntu.ac.ir

۱ MODIS
2 Landsat
3 Sentinel-2

سنتینل-۲، ۷۸ درصد تخمین زده شد. استفاده همزمان از تصاویر سنتینل-۱ و ۲ دقت کلی طبقه‌بندی را به ۸۲ درصد رسانید. همچنین با بهره‌گیری از تصاویر سنتینل-۱ و سنتینل-۲، برینخوف و همکاران نقشه پوشش زمینی یک منطقه مطالعاتی در استرالیا را با ۹ کلاس زراعی تولید نمودند (Brinkhoff *et al.*, 2020). در این تحقیق نیز، دقت نهایی طبقه‌بندی در حالت بکارگیری تصاویر راداری سنتینل-۱ در کنار تصاویر نوری سنتینل-۲، به ۸۴٫۲ درصد رسیده که افزایش ۱٫۲ درصدی نسبت به استفاده از تصاویر تک منبعی سنتینل-۲ را نشان می‌دهد. در تحقیق انجام شده توسط چاخار و همکاران در سال ۲۰۲۱ نیز، استفاده از شاخص تفاضل گیاهی نرمال شده^۴ (NDVI) مستخرج از تصاویر سنتینل-۲ در کنار دو قطبش عمودی-عمودی^۵ (VV) و عمودی-افقی^۶ (VH) تصاویر سنتینل-۱ برای یک منطقه مطالعاتی در جنوب شرقی اسپانیا، منجر به افزایش دقت طبقه‌بندی از ۸۷ به ۹۳ گردید (Chakhar *et al.*, 2021).

در عمده مطالعات بررسی شده، از روش‌های کلاسیک نظیر جنگل‌های تصادفی^۷ (RF)، ماشین بردار پشتیبان^۸ (SVM)، شبکه‌های عصبی چندلایه^۹ (MLP)، نزدیکترین همسایگی^{۱۰} (NN)، بیشترین شباهت^{۱۱} (ML) و شاخص‌های مشابهت‌سنجی^{۱۲} (SI) جهت طبقه‌بندی استفاده است. پیشرفت‌های اخیر در حوزه فناوری به‌خصوص در پردازنده‌های گرافیکی^{۱۳} (GPU)، سبب رواج استفاده از شبکه‌های عصبی عمیق^{۱۴} (DNN)، به‌عنوان جدیدترین روش‌های طبقه‌بندی، در کاربردهای گوناگون شده است. تا جایی که این شبکه‌ها، در مطالعات مختلف سنجش از دوری و داده‌کاوی نظیر (Mazzia *et al.*, 2020; Boulze *et al.*, 2020) نیز به‌طور گسترده‌ای مورد استفاده قرار گرفته‌اند. ما و همکاران در سال ۲۰۱۹، کاربردهای مختلف شبکه‌های عصبی عمیق را در تحقیقات مختلف سنجش از دوری بررسی نمودند (Ma *et al.*, 2019). در بین معماری‌های مختلف، شبکه‌های عصبی پیچشی^{۱۵} و نسخه‌های متفاوت آن‌ها از مشهورترین شبکه‌های عصبی در کاربردهای مرتبط با تصویر می‌باشند. کامیلاریس و همکاران در (Kamilaris *et al.*, 2018) و کاتنبورن و همکاران در (Kattenborn *et al.*, 2021)، به بررسی کاربردهای اصلی شبکه‌های عصبی پیچشی عمیق در حوزه‌های مربوط به کشاورزی و پوشش‌های گیاهی از جمله طبقه‌بندی کاربری اراضی کشاورزی

ماهواره‌های رادار با روزه مجازی^۱ (SAR)، به‌دلیل ویژگی‌های منحصر به فرد از جمله توانایی اخذ تصویر در هر شرایط آب و هوایی بخصوص پوشش ابر، بیش از گذشته مرسوم شده است (Joshi *et al.*, 2016). تا جایی که ماهواره سنتینل-۲^۲ نیز با هدف پایش زمین از طریق اخذ تصاویر راداری رایگان در دسترس عموم، به فضا پرتاب شده است.

تصاویر ماهواره‌ای در کاربردهای مختلف سنجش از دوری بویژه حوزه کشاورزی، عمدتاً به‌صورت چندزمانه و سری زمانی استفاده شده و منجر به بهبود نتایج نهایی شده است (Xiao *et al.*, 2018). ژو و همکاران در (Xu *et al.*, 2019) تولید نقشه کاربری اراضی کشاورزی دو منطقه مطالعاتی واقع در چین را با استفاده از سری زمانی تصاویر سنتینل-۱ و روش‌های مشابهت طیفی انجام دادند. ژای و همکاران نیز در (Zhai *et al.*, 2020)، با توسعه یک روش انتخاب ویژگی، به طبقه‌بندی محصولات کشاورزی با استفاده از سری زمانی تصاویر نوری لندست-۸ پرداختند. همچنین پایش و تشخیص اراضی تحت کشت محصول برنج با استفاده از سری زمانی تصاویر سنتینل-۱ در (Mandal *et al.*, 2018; Singha *et al.*, 2020; Chang *et al.*, 2021) انجام پذیرفته است. چاخار و همکاران نیز در سال ۲۰۲۰، به بررسی روش‌های مختلف یادگیری ماشین در طبقه‌بندی اراضی کشاورزی با استفاده همزمان از تصاویر نوری سنتینل-۲ و لندست-۸ به‌صورت چندزمانه، پرداختند (Chakhar *et al.*, 2020).

استفاده همزمان از تصاویر چندمنبعی نوری و راداری نیز طی سال‌های اخیر در مطالعات مختلف انجام شده و نتایج بهتری نسبت به استفاده از تصاویر تک‌منبع بدست داده است. چراکه در هر نوع تصویر، ویژگی‌های خاصی از عوارض مختلف نمایان می‌شود و ترکیب آن‌ها، می‌تواند افزایش دقت نهایی را به‌دنبال داشته باشد. وان و همکاران در سال ۲۰۱۸ نقشه کاربری اراضی کشاورزی بلژیک را به‌واسطه استفاده از روش جنگل تصادفی سلسله مراتبی^۳ تهیه نمودند (Van Tricht *et al.*, 2018). در تحقیق مذکور، استفاده همزمان از تصاویر چندمنبعی نوری (سنتینل-۲) و SAR (سنتینل-۱) افزایش دقت طبقه‌بندی را به‌همراه داشت. به‌نحوی که دقت کلی طبقه‌بندی در حالت استفاده از تصاویر سنتینل-۱، ۷۶ درصد و در حالت استفاده از تصاویر

9 Multi-Layer Perceptron
10 Nearest Neighbors
11 Maximum Likelihood
12 Similarity Indices
13 Graphical Processing Unit
14 Deep Neural Networks
15 Convolutional Neural Network

1 Synthetic Aperture Radar
2 Sentinel-1
3 Hierarchical Random Forest
4 Normalized Difference Vegetation Index
5 Vertical-Vertical
6 Vertical-Horizontal
7 Random Forests
8 Support Vector Machine

زیر خلاصه نمود: ۱- استفاده از تصاویر سنجش از دوری چند-منبعی سنتینل-۱ (نوری) و سنتینل-۲ (SAR) به صورت چند-زمانه جهت تولید نقشه کاربری اراضی کشاورزی، ۲- بکارگیری یک معماری نوین از شبکه‌های عصبی پیچشی مکانی-زمانی (سه-بعدی) عمیق با ساختار انتها-به-انتها^۱ و دارا بودن اتصالات فرار از لایه‌های قبلی جهت تغذیه لایه‌های جدید و ۳- ارزیابی عملکرد روش ارائه شده در یک منطقه مطالعاتی واقع در شهرستان شهرکرد با استفاده از داده‌های مرجع میدانی.

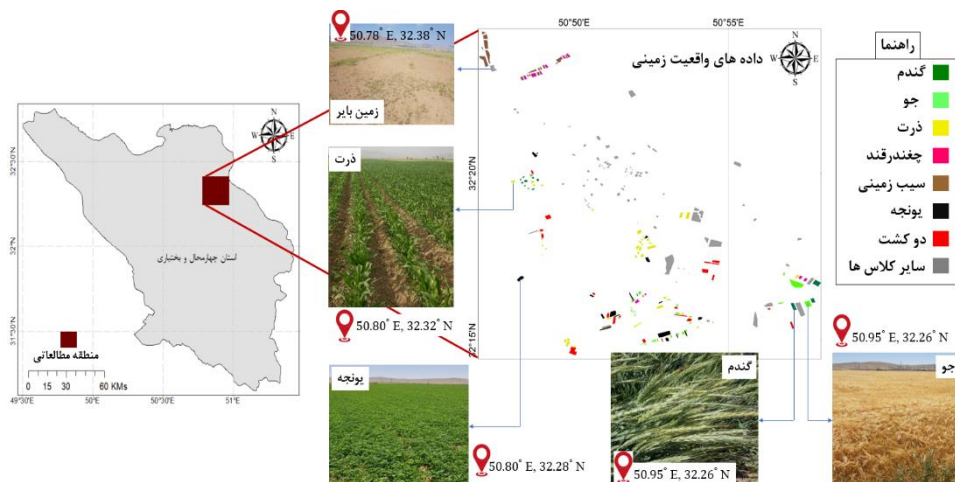
مواد و روش‌ها

منطقه مطالعاتی و داده‌های واقعیت زمینی

منطقه مطالعاتی این پژوهش، در شهرستان شهرکرد، مرکز استان چهارمحال و بختیاری واقع شده که موقعیت آن در شکل (۱) نمایش داده شده است. منطقه مطالعاتی محدوده تقریبی ۵۰٫۷۵ درجه تا ۵۱ درجه شمالی و ۳۲٫۲ تا ۳۲٫۴ درجه شرقی را در بر می‌گیرد که مساحتی بیش از ۳۳۰۰۰ هکتار را پوشش می‌دهد. این منطقه در بخش شرقی سلسله جبال زاگرس قرار گرفته و با ارتفاع متوسط حدود ۱۸۰۰ متر از سطح دریا قرار دارد. این محدوده دارای آب و هوای با تابستان‌های خنک و زمستان‌های سرد است. همچنین درصد قابل توجهی از کل محصولات کشاورزی استان، در این شهرستان استحصال می‌گردد. محصولات اصلی کشاورزی این ناحیه، گندم و جو به صورت کشت پاییزه و همچنین ذرت، سیب‌زمینی و چغندر قند به صورت کشت بهاره می‌باشند. شروع کاشت محصولات پاییزه عمدتاً از آذر ماه هر سال آغاز شده و برداشت محصولات بهاره تقریباً تا پایان آبان‌ماه سال بعد ادامه می‌یابد. لذا به‌طور کلی می‌توان گفت، یک سال زراعی کامل در این منطقه، بازه زمانی آذرماه لغایت پایان آبان‌ماه سال بعد را پوشش می‌دهد.

و شناسایی بیماری گیاهان و محصولات مختلف پرداختند. علی‌رغم مطالعات وسیع انجام شده در حوزه تولید نقشه کاربری اراضی کشاورزی، این امر به دلیل تنوع درون کلاسی و بین کلاسی بالای محصولات کشاورزی، همچنان پیچیده و چالش برانگیز می‌باشد. بکارگیری روش‌های طبقه‌بندی مبتنی بر شبکه‌های عصبی عمیق، به سبب توانایی حل مسائل پیچیده، می‌تواند به عنوان راهکاری مناسب در این حوزه مطرح گردد. در بین انواع مختلف شبکه‌های عصبی عمیق، شبکه‌های پیچشی از جمله معروفترین شبکه‌های عمیق در کاربردهای مختلف مربوط به تصویر نظیر طبقه‌بندی بوده که عملکرد مناسب آن‌ها در مطالعات مختلفی به اثبات رسیده است. در این مطالعه، طبقه‌بندی کاربری اراضی کشاورزی تحت کشت محصولات مختلف پاییزه و بهاره مختلف به واسطه استفاده از تصاویر سنجش از دوری چندمنبعی سنتینل (نوری و راداری) به صورت چندزمانه و بکارگیری یک شبکه عصبی پیچشی عمیق نوین انجام پذیرفته است. در شبکه طراحی شده از فیلترهای سه‌بعدی استفاده می‌شود. به کارگیری فیلترهای سه‌بعدی جهت استخراج توامان ویژگی‌های زمانی و مکانی هر پیکسل تصویری می‌تواند افزایش دقت نهایی طبقه‌بندی را به دنبال داشته باشد. به علاوه، شبکه‌های پیچشی، از جمله شبکه‌های پیش‌خور عادی بوده که هر لایه جدید، به‌طور مستقیم تنها از لایه قبلی تغذیه می‌گردد. طراحی اتصالات فرار مختلف جهت متصل نمودن لایه‌های قبلی به لایه جدید، به سبب امکان بکارگیری دانش تجمعی لایه‌های قبلی در لایه جدید نیز می‌تواند افزایش دقت نهایی را به دنبال داشته باشد. اتصالات فرار همچنین با انتقال سریعتر خطای شبکه به لایه‌های ابتدایی در حین فرآیند پس‌انتشار خطا، می‌توانند از پدیده محوشدگی گرادیان نیز جلوگیری نمایند.

به‌طور کلی اهداف اصلی این پژوهش را می‌توان در موارد



شکل ۱- موقعیت جغرافیایی منطقه مطالعاتی و توزیع مکانی داده‌های واقعیت زمینی در کلاس‌های مختلف

عوارض شهری، مراعات، فضای سبز درون شهری و باغات در محدوده مورد نظر، نمونه‌هایی متعلق به پوشش‌های مذکور، در یک کاربری مجزا (سایر کاربری‌ها)، جهت تفکیک سایر پوشش‌های زمینی از کاربری‌های زراعی در نظر گرفته شده است.

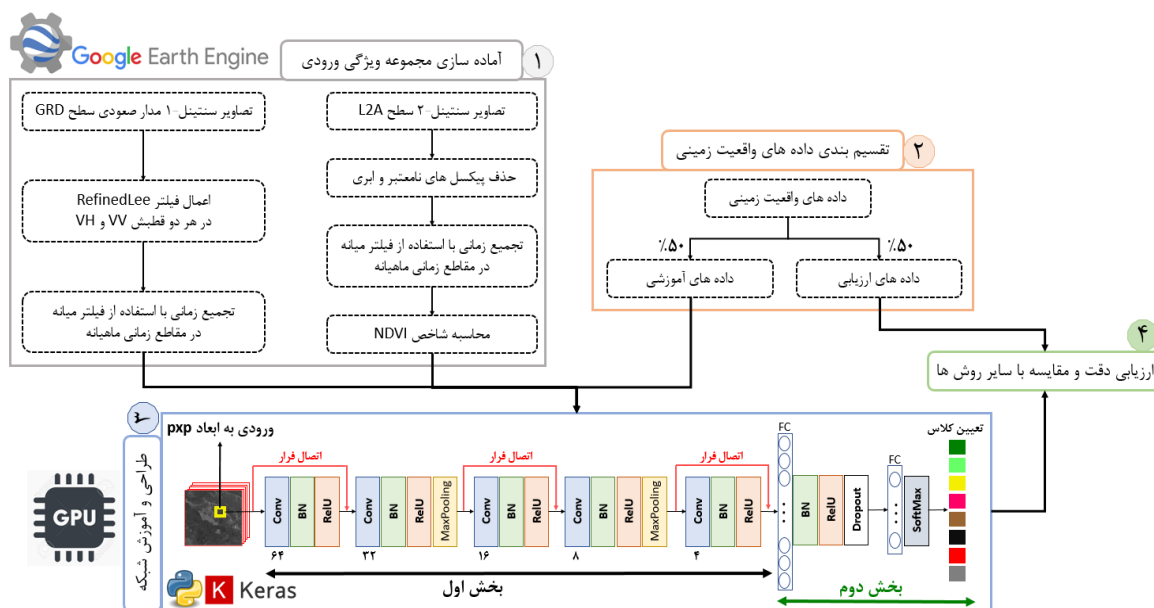
جدول ۱- تعداد نمونه‌های تصویری مرجع داده‌های واقعیت زمینی در کاربری‌های مختلف

کارب	گند	جو	ذرت	چغندر	سی	یونج	دوک	سایر
تعداد	۳۲۷	۵۶۱	۷۳۲	۲۸۰۵	۶۷۵	۶۷۸	۷۶۲	۵۷۸

روش پیشنهادی

روندنمای روش پیشنهادی ارائه شده در این پژوهش ترسیم شده است (شکل ۲). همانطور که مشخص است، روش ارائه شده ۴ گام کلی را شامل می‌شود: ۱- آماده‌سازی مجموعه ویژگی‌های ورودی، ۲- تقسیم‌بندی داده‌های واقعیت زمینی، ۳- طراحی معماری و آموزش شبکه عمیق و ۴- ارزیابی دقت و مقایسه با سایر روش‌ها. در ادامه به تفصیل هر یک از گام‌های مذکور شرح داده می‌شود.

داده‌های واقعیت زمینی این مطالعه طی بازدیدهای میدانی وسیع صورت گرفته از اراضی کشاورزی موجود در منطقه مطالعاتی با ابعاد مختلف در فصل زراعی سال ۹۹-۹۸ بدست آمده است. بازدیدهای میدانی در مقاطع زمانی مختلف و همزمان با اوج سبزی‌نگی محصولات پاییزه و بهار صورت پذیرفت. توزیع مکانی کاربری‌های مختلف داده‌های واقعیت زمینی و تصاویر میدانی از کلاس‌های مختلف به همراه موقعیت مکانی آن‌ها نیز قابل مشاهده است (شکل ۱). داده‌های واقعیت زمینی در ۸ کاربری مختلف جمع‌آوری گردیده که تعداد نمونه‌های تصویری مرجع هر کاربری گزارش شده است (جدول ۱). داده‌های جمع‌آوری شده، کاربری-های زراعی گندم، جو، ذرت، چغندر، سیب‌زمینی و یونجه را شامل می‌شوند. همچنین برخی اراضی کشاورزی موجود در منطقه مطالعاتی، از سیستم زراعت دو کشت متوالی پاییزه و بهار تبعیت می‌نمایند که در کاربری مجزا در نظر گرفته می‌شوند. به دلیل حضور سایر کاربری‌های پوشش زمینی نظیر آب، اراضی بایر،



شکل ۲- روندنمای روش پیشنهادی

سال زراعی ۹۹-۹۸ (آذر ماه سال ۹۸ لغایت آذرماه سال ۹۹) می‌باشد.

تصاویر سنتینل-۲، در ۱۲ باند طیفی در سطح L2A با اعمال تصحیحات اتمسفری، در دسترس عموم قرار گرفته است. پوشش ابر به‌خصوص با توجه به وضعیت آب و هوایی منطقه مطالعاتی، به‌عنوان یک چالش همیشگی در به‌کارگیری تصاویر نوری مطرح شده است. جهت تولید موزائیک‌های تصویری بدون ابر از منطقه مطالعاتی، ۲ گام متوالی انجام شده است: ۱- حذف

آماده‌سازی مجموعه ویژگی‌های ورودی

همانطور که اشاره شد، در این مطالعه به‌طور همزمان از تصاویر نوری سنتینل-۲ و تصاویر SAR سنتینل-۱ جهت طبقه‌بندی اراضی کشاورزی استفاده شده است. کلیه مراحل مربوط به پیش-پردازش تصاویر و آماده‌سازی مجموعه ویژگی‌های ورودی، در سامانه برخط گوگل ارث انجین بدون نیاز به اخذ تصاویر انجام پذیرفته است (Gorelick et al., 2017). همچنین، بازه زمانی در نظر گرفته شده، جهت فراخوانی هر دو نوع تصاویر، مصادف با

داده‌های آموزشی، می‌گردد. ذکر این نکته الزامی است که داده‌های ارزیابی هیچ نقشی در آموزش روش‌های مورد بررسی ایفا نمی‌کنند.

معماری شبکه عمیق طراحی شده

در این پژوهش از یک شبکه عصبی سه‌بعدی پیچشی عمیق با ساختاری نوین جهت طبقه‌بندی اراضی کشاورزی استفاده شده است. در این قسمت از مطالعه، به تشریح ساختار و جزئیات شبکه مذکور پرداخته می‌شود. لازم به ذکر است، مقدمات و روابط ریاضی شبکه‌های پیچشی عمیق در مطالعات مختلف، به‌طور کامل شرح داده شده است (Boulze *et al.*, 2020; Mazzia *et al.*, 2020; Rezaee *et al.*, 2018).

ساختار و معماری شبکه طراحی شده در شکل (۲) نشان داده شده است. همانطور که مشخص است، شبکه طراحی شده، از دو بخش کلی تشکیل شده است. در بخش اول، در مجموع از ۵ لایه استفاده شده که لایه‌های ابتدایی وظیفه استخراج ویژگی‌های سطح پایین و لایه‌های انتهایی وظیفه استخراج ویژگی‌های سطح بالاتر را برعهده دارند. هر ۵ لایه به‌طور مشابه به ترتیب از یک لایه پیچشی (Conv)، یک لایه نرمال‌سازی دسته‌ای^۲ (BN) و یک تابع فعال‌ساز^۳ تشکیل می‌شوند. لایه‌های کانولوشنی از کرنل‌های سه‌بعدی جهت استخراج ویژگی بهره می‌برند. لذا شبکه قادر به استخراج همزمان ویژگی‌های مکانی و زمانی هر پیکسل تصویری و استفاده از آن‌ها در تصمیم‌گیری نهایی خواهد بود. ابعاد تمامی کرنل‌های سه‌بعدی $3 \times 3 \times 3$ در نظر گرفته شده است (Li *et al.*, 2017). لازم به ذکر است جهت امکان عمق‌بخشی به شبکه از طریق افزایش تعداد لایه‌های پیچشی، ابعاد خروجی هر لایه پیچشی، با استفاده از تکنیک لایه‌گذاری^۴، مشابه با ابعاد ورودی آن در نظر گرفته می‌شود. تعداد فیلترهای مورد استفاده در هر ۵ لایه، با استفاده از روش سعی و خطا و با هدف کسب بالاترین دقت ممکن روی داده‌های ارزیابی، به ترتیب ۶۴، ۳۲، ۱۶، ۸ و ۴ در نظر گرفته شده است. خروجی لایه پیچشی توسط لایه BN، با هدف تسهیل آموزش، جلوگیری از بیش‌برازش و تعمیم‌پذیری هرچه بهتر شبکه نرمال می‌گردد (Ioffe & Szegedy, 2015; Zhao *et al.*, 2019). Relu، با هدف توانمند نمودن شبکه در مدل‌سازی روابط غیرخطی، آماده ورود به لایه‌ی بعدی می‌گردد. این تابع علاوه بر سرعت بالا در فرآیند پس انتشار خطا، به‌عنوان رایج‌ترین تابع فعال‌ساز مورد استفاده در شبکه‌های پیچشی، شناخته شده است (Krizhevsky *et al.*, 2012).

پیکسل‌های نامعتبر و ابری تصاویر موجود در بازه زمانی سال زراعی ۹۹ با استفاده از نقشه لایه کیفیت موجود در کنار هر تصویر و ۲- بکارگیری تکنیک تجمیع زمانی با استفاده از فیلتر میانه در مقاطع زمانی ماهیانه (Carrasco *et al.*, 2019). به‌نحوی که، میانه مقادیر هر پیکسل تصویری در تصاویر هر ماه، موزائیک تصویری خالی از ابر را تولید می‌نماید. لازم به ذکر است، طبق بررسی‌های بعمل آمده، کوتاهترین بازه زمانی ممکن جهت ساخت موزائیک-های تصویری در مقاطع زمانی با طول یکسان، هر ماه می‌باشد. با انجام این عملیات، در مجموع ۱۲ تصویر نوری بدون ابر تولید گردید. فقط از شاخص NDVI (حاصل از باند مادون قرمز نزدیک و قرمز) تصاویر تولید شده به‌منظور کاهش افزونگی داده، حجم محاسبات و همچنین توانایی شاخص مذکور در کاربردهای مربوط به حوزه کشاورزی و پوشش گیاهی، در طبقه‌بندی استفاده می‌شود (Chakhar *et al.*, 2021).

تصاویر سطح GRD مدار صعودی تصاویر سنتینل-۱ در دو قطبش VV و VH نیز مورد استفاده قرار گرفت. به‌منظور کاهش اثر اسپکل، به‌عنوان یک پدیده ذاتی در تصاویر راداری، از فیلتر لی‌بهبودیافته^۱ استفاده شده است (Chakhar *et al.*, 2021). مشابه با تصاویر نوری، با استفاده از تکنیک تجمیع زمانی، ۱۲ موزائیک تصویری ماهیانه از تصاویر سنتینل-۱ منطقه مطالعاتی تولید می‌شود. این عملیات به‌نوبه خود نیز، به کاهش دوباره اثر اسپکل می‌انجامد. چراکه این اثر معمولاً خود را به‌صورت نقاط تیره یا روشن در تصاویر نشان می‌دهد و فیلتر میانه به‌کارگذاری آن کمک شایانی می‌نماید (Carrasco *et al.*, 2019).

تقسیم‌بندی داده‌های واقعیت زمینی

روش‌های مورد بررسی، هر کدام ۵۰ بار، به‌واسطه استفاده از داده‌های آموزشی و ارزیابی متنوع در هر بار اجرا، مورد بررسی قرار می‌گیرند. آموزش و ارزیابی روش‌های مورد بررسی با داده‌های آموزشی و ارزیابی متنوع در هر بار اجرا، سبب سنجش هرچه عادلانه‌تر روش ارائه شده و مقایسه دقیق‌تر عملکرد آن با سایر روش‌ها می‌گردد. لازم به ذکر است، داده‌های واقعیت زمینی جمع‌آوری شده، در هر بار اجرا، طور مساوی و به‌صورت کاملاً تصادفی، به دو دسته داده‌های ارزیابی و آموزشی تقسیم‌بندی می‌شوند. این تقسیم‌بندی داده‌های مرجع به دو دسته مساوی سبب در دست بودن مقدار کافی نمونه ارزیابی جهت سنجش هرچه بهتر روش ارائه شده و همچنین جلوگیری از بیش‌برازش احتمالی شبکه طراحی شده با در نظرگیری مقدار بسیار زیادی

(Clark, 2017; Zhao et al., 2019; Krizhevsky et al., 2012) لازم به ذکر است، در لایه اول تمام متصل از تکنیک بیرون‌انداز^۵ با نرخ ۰/۵، جهت جلوگیری از بیش‌برازش و تسهیل فرآیند آموزش شبکه استفاده می‌شود (Boulze et al., 2020; Mazzia et al., 2020).

ورودی شبکه مورد نظر، برای هر نمونه تصویری، یک همسایگی به ابعاد $P \times P \times C$ بوده که در شکل (۲) با رنگ زرد مشخص شده است. کلاس این همسایگی نیز کلاس متناظر نمونه مرکز خواهد بود. شبکه، با هدف تشخیص صحیح کلاس داده‌های آموزشی به صورت انتها-به-انتها آموزش می‌یابد. مقدار بهینه P ، با توجه به خروجی و بررسی مقادیر دقت کلی شبکه روی داده‌های ارزیابی تعیین می‌گردد. C نیز، متناسب با مجموعه ویژگی‌های ورودی، تعداد باندهای تصویری مورد استفاده را نشان می‌دهد. تاثیر استفاده از مجموعه ویژگی‌های مختلف نیز با توجه به دقت خروجی به طور کامل مورد بررسی قرار می‌گیرد. طراحی، پیاده‌سازی، آموزش و ارزیابی دقت شبکه مورد نظر در کتابخانه یادگیری عمیق کراس^۶ به زبان برنامه‌نویسی پایتون^۷ و با بهره‌گیری از پردازنده‌های گرافیکی (GPU^۸) جهت کاهش زمان محاسبات انجام پذیرفته است. جهت آموزش شبکه از تابع هزینه آنتروپی متقابل^۹ به عنوان تابع هزینه اصلی در کاربردهای طبقه‌بندی استفاده شده است (Boulze et al., 2020; Mazzia et al., 2020). آموزش وزن‌های شبکه در ۲۰۰ تکرار زمانی و با هدف یافتن کمینه تابع هزینه، توسط الگوریتم بهینه‌ساز گرادیان نزولی^{۱۰} انجام می‌پذیرد. نرخ بهینه یادگیری نیز، از روش جست‌وجوی شبکه‌ای بین مقادیر ۰/۱، ۰/۰۱، ۰/۰۰۱ و ۰/۰۰۰۱ در راستای کسب بالاترین دقت نهایی روی داده‌های ارزیابی، مقدار ۰/۰۰۱ انتخاب گردید (Carranza-García et al., 2019).

ارزیابی دقت و مقایسه با سایر روش‌ها

ارزیابی دقت روش پیشنهادی و مقایسه عملکرد آن با سایر روش‌ها، به واسطه استفاده از ماتریس ابهام و دو پارامتر دقت کلی و ضریب کاپا طبقه‌بندی انجام گرفت (Van Tricht et al., 2018). به نحوی که ارزیابی عملکرد روش ارائه شده در دو مرحله انجام می‌پذیرد. در مرحله اول تاثیر اتصالات فرار طراحی شده از طریق، مقایسه نتایج بدست آمده از شبکه پیشنهادی با یک شبکه مشابه بدون اتصالات فرار طراحی شده (به اختصار: 3DCNN)، انجام می‌پذیرد. در مرحله دوم نیز، روش پیشنهادی با دو روش مطرح

علاوه بر موارد فوق، در لایه دوم و چهارم بخش اول، از یک لایه انتخاب بیشینه مقدار (MaxPooling) به ابعاد $2 \times 2 \times 2$ استفاده شده که ورودی آن، خروجی تابع فعالساز Relu می‌باشد. این ابعاد به عنوان پراستفاده‌ترین ابعاد لایه MaxPooling در مطالعات مختلف به کار گرفته شده است (Krizhevsky et al., 2012; Zhao et al., 2019). این لایه علاوه بر کاهش حجم محاسبات و حفظ ویژگی‌های اصلی استخراج شده، با کاهش تعداد اتصالات شبکه، منجر به تسهیل آموزش شبکه و کاهش تعداد پارامترهای قابل آموزش شبکه می‌گردد (Guidici & Clark, 2017).

شبکه‌های پیچشی عمیق معمولی (3DCNN^۱)، از یک ساختار پیش‌خور تبعیت می‌نمایند. بدین معنی که ورودی هر لایه، به طور مستقیم از لایه قبلی حاصل می‌شود. شبکه طراحی شده در این مطالعه، از چند اتصال فرار جهت استفاده از ویژگی‌های مستخرج از لایه‌های قبل‌تر در لایه جدید نیز بهره می‌برد. به عبارت بهتر، ورودی یک لایه، تنها حاصل از خروجی لایه قبلی نبوده و لایه‌های قبل‌تر نیز در ورودی لایه جدید نقش ایفا می‌کنند. این مورد سبب استفاده از دانش تجمعی لایه‌های قبلی در لایه جدید شده و امکان افزایش دقت طبقه‌بندی نهایی را فراهم می‌آورد. اتصالات طراحی شده همچنین در فرآیند پس انتشار خطا، به دلیل انتقال سریع تر گرادیان به لایه‌های قبل‌تر، از محوشدگی گرادیان نیز جلوگیری می‌نمایند. لازم به یادآوری است، جهت اتصال دو لایه، یکسان بودن ابعاد خروجی لایه‌ها امری ضروری است. به دلیل استفاده از لایه تجمیع بیشینه^۲ و کاهش بعد خروجی، تنها ۳ اتصال فرار از ویژگی مذکور برخوردار بوده که در شکل (۲) با رنگ قرمز نشان داده شده است.

در بخش دوم نیز از دو لایه نرون‌های تمام متصل استفاده شده است. خروجی بخش اول به طور کامل وارد لایه تمام متصل^۳ اول می‌شود. تعداد نرون‌های لایه اول نیز معادل با ابعاد بردار خروجی بخش اول در نظر گرفته شده است. خروجی لایه تمام-متصل اول، پس از عبور از لایه‌های BN و تابع فعالساز Relu^۴ وارد لایه تمام‌متصل دوم شده که وظیفه‌ی طبقه‌بندی نهایی را برعهده دارد. تعداد نرون‌های لایه دوم تمام متصل نیز به تعداد کلاس‌های خروجی بوده (۸ نرون) که تابع فعالساز آن، SoftMax می‌باشد. از این تابع به عنوان مناسب‌ترین تابع فعالساز در لایه انتهایی کاربردهای مختلف طبقه‌بندی استفاده می‌شود (Guidici

7 Python

8 Graphical Processing Unit

9 Cross Entropy

10 Gradient Descent

1 3D Convolutional Neural Network

2 MaxPooling

3 Fully Connected

4 REctified Linear Unit

5 Dropout

6 Keras

تصاویر نوری به همراه سری زمانی هر دو قطبش VV و VH تصاویر راداری (NDVI+VV+VH). در ادامه به تشریح نتایج بده ست آمده پرداخته می‌شود.

جدول ۲- دقت کلی طبقه‌بندی با استفاده از شبکه طراحی شده به ازای

مقادیر مختلف P					
شبکه	حال	ابعاد پنجره	۳x۳	۵x۵	۷x۷
۱	NDVI	۸/۹۴	۹/۰۲	۸/۴۸	۸/۱۳
۲	NDVI+VV	۹/۳۸	۹/۵۱	۸/۹۲	۸/۴۳
۳	NDVI+VH	۹/۷۶	۹/۰۹	۸/۳۷	۸/۷۹
۴	NDVI+VV+VH	۹/۵۵	۹/۶۹	۸/۹۲	۸/۰۱

همانطور که در جدول (۲) قابل مشاهده است، به ازای یک مقدار P ثابت، مجموعه ویژگی شماره ۴، بالاترین دقت طبقه‌بندی را در بین ورودی‌های مختلف بدست آورده است. به عبارت بهتر، استفاده همزمان از شاخص NDVI در کنار هر دو قطبش VV و VH تصاویر راداری، افزایش دقت طبقه‌بندی را به دنبال داشته است. به کارگیری یکی از قطبش‌های تصاویر راداری نیز (VH یا VV) در کنار شاخص NDVI، بهبود دقت طبقه‌بندی را حاصل می‌کند. البته قطبش VH نسبت به قطبش VV، با توجه به مکانیزم پراکنش حجمی در گیاهان و محصولات کشاورزی، در افزایش دقت طبقه‌بندی نقش قابل توجه‌تری را ایفا می‌نماید. همچنین به ازای یک مجموعه ویژگی ثابت، پنجره ورودی به ابعاد ۵x۵ در بین مقادیر مورد بررسی بهترین نتایج را بدست آورده است. چنان‌که با افزایش P به مقادیر ۷ و ۹، از دقت کلی طبقه‌بندی کاسته می‌شود. در بین تمامی حالات مورد بررسی، همسایگی به ابعاد ۵x۵ با مجموعه ویژگی ورودی NDVI+VV+VH با دقت کلی ۹۱/۶۹ درصد، بهترین حالت مورد بررسی در نظر گرفته شد.

همچنین ماتریس ابهام نرمال شده طبقه‌بندی در حالت P برابر ۵، به ازای ورودی‌های مختلف (حالات ۱ تا ۴) نمایش داده شده است (شکل ۳). همانطور که مشخص است، در حالت استفاده از NDVI+VV+VH، بالاترین دقت تشخیص صحیح نمونه‌های ارزیابی هر کاربری، دقت کلی طبقه‌بندی و ضریب کاپا بدست آمده است. به عنوان مثال برای کاربری جو، در حالت ۱، ۷۴/۳، در حالت ۲، ۷۴/۸، در حالت ۳، ۷۶/۳ و در حالت ۴، ۷۸/۸ درصد از نمونه های ارزیابی به صورت صحیح تشخیص داده شده است. در مورد کاربری گندم، دقت تشخیص از ۸۹/۹ درصد در حالت ۱، به ۹۱/۶ درصد در حالت ۴ رسیده است. استفاده از تصاویر راداری سبب بیشترین افزایش دقت در تشخیص کاربری ذرت در بین کلاس‌های مورد بررسی شده است. تا جایی که دقت تشخیص این کلاس از ۶۷/۳ به ۷۴/۴ درصد افزایش پیدا کرده و بهبود بیش از ۷ درصدی را

حوزه یادگیری ماشین یعنی جنگل تصادفی و ماشین-بردارپشتیبان مورد مقایسه قرار گرفت. همانطور که در بخش پیشینه تحقیق نیز مشاهده شد، این دو روش در مطالعات مختلف به کار گرفته شده و عملکرد مناسب آن‌ها به اثبات رسیده است. لازم به ذکر است، جهت مقایسه عادلانه‌تر روش طراحی شده با دو روش جنگل تصادفی و ماشین بردارپشتیبان، علاوه بر فرمت زمانی این دو روش (RF و SVM) فرمت زمانی- مکانی این دو روش (3DRF و 3DSVM) نیز مورد بررسی قرار گرفتند. به نحوی- که در دو روش 3DRF و 3DSVM، همانند شبکه پیچشی عمیق طراحی شده، ورودی طبقه‌بندی‌کننده یک همسایگی کوچک از پیکسل تصویری هدف خواهد بود. در حالی که در دو روش SVM و RF طبقه‌بندی تنها بر مبنای رفتار زمانی پیکسل هدف انجام می‌پذیرد.

هر یک از دو روش جنگل تصادفی و ماشین بردار پشتیبان، پارامترهای ورودی مختص به خود را دارند. جهت تعیین پارامترهای هر دو روش از تکنیک جست‌وجوی شبکه‌ای استفاده می‌شود. جست‌وجو در مورد روش RF و 3DRF از بین دو پارامتر تعداد درخت با مقادیر (۱۰۰، ۲۰۰، ۳۰۰ و ۴۰۰) و همچنین حداکثر عمق با مقادیر (۴، ۶، ۸، ۱۰، ۱۲) و در مورد روش SVM و 3DSVM برای دو پارامتر نوع کرنل (شعاعی یا خطی) و ضریب C با مقادیر (۰، ۱، ۱۰ و ۱۰۰) انجام می‌پذیرد. لازم به ذکر است هر دو روش جنگل تصادفی و ماشین بردار پشتیبان، پارامترهای ورودی دیگری نیز دارند که با توجه به بررسی‌های انجام شده، تاثیر تغییر این پارامترها در نتیجه نهایی بسیار جزئی است. لذا جست‌وجو تنها برای پارامترهای انجام پذیرفته که تاثیر قابل توجهی در نتیجه نهایی داشته باشند.

نتایج و بحث

بررسی تاثیر ابعاد پنجره ورودی شبکه طراحی شده

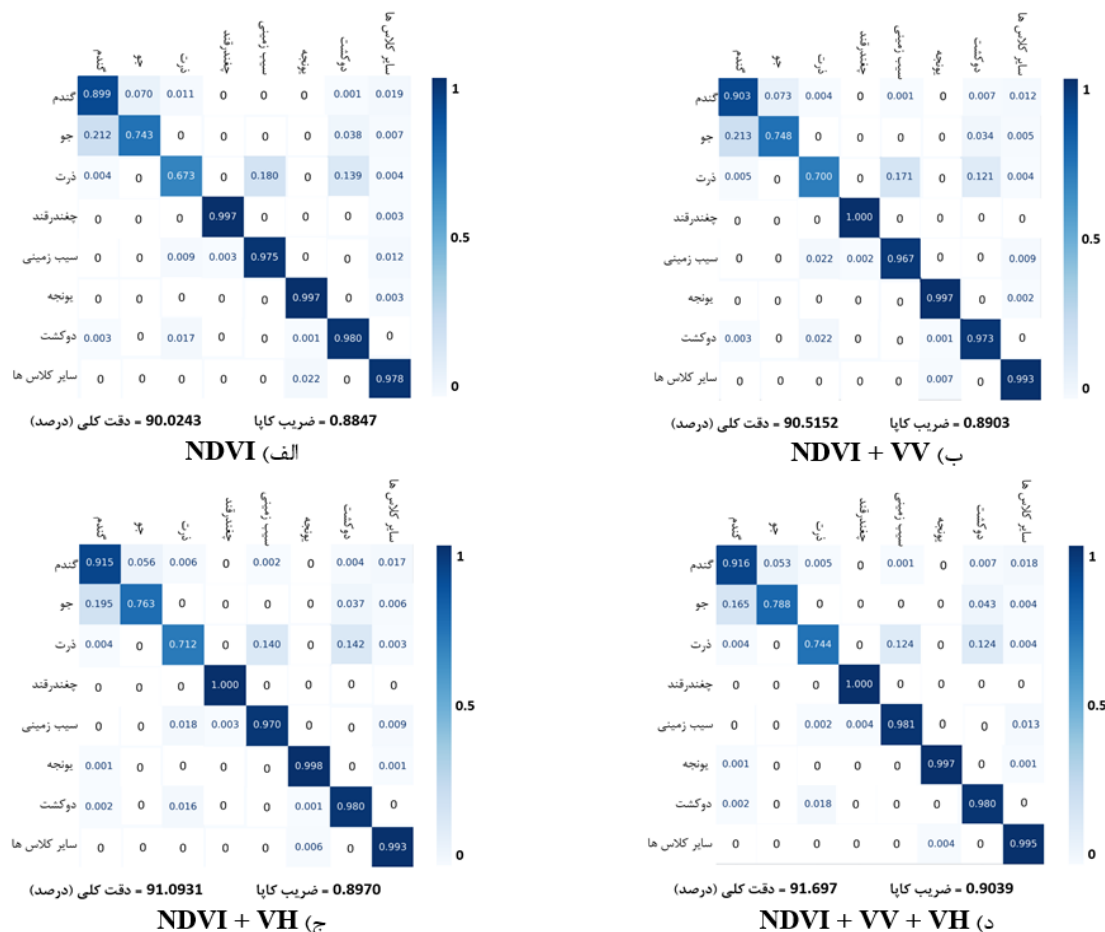
دقت کلی (درصد) حاصل از طبقه‌بندی اراضی کشاورزی به کاربری‌های مختلف بوسیله شبکه پیشنهادی در پنجره‌های ورودی با ابعاد مختلف (P) روی داده‌های ارزیابی محاسبه شده است (جدول ۲). همچنین در این جدول، بررسی تاثیر استفاده از ورودی‌های مختلف تصویری در ۴ حالت مختلف به صورت همزمان انجام پذیرفته است: ۱- سری زمانی شاخص NDVI مستخرج از تصاویر نوری (NDVI)، ۲- سری زمانی شاخص NDVI مستخرج از تصاویر نوری به همراه سری زمانی قطبش VV تصاویر راداری (NDVI+VV)، ۳- سری زمانی شاخص NDVI مستخرج از تصاویر نوری به همراه سری زمانی قطبش VH تصاویر راداری (NDVI+VH) و ۴- سری زمانی شاخص NDVI مستخرج از

در کلاس‌های مختلف به همراه دقت کلی و ضریب کاپا مقایسه شده است (شکل ۴-الف). همانطور که مشخص است، اتصالات فرار طراحی شده، سبب افزایش دقت در کلیه کلاس‌های مورد بررسی و در نتیجه دقت کلی و ضریب کاپا طبقه‌بندی شده است. بیشترین افزایش دقت به ترتیب در کلاس‌های جو با ۷/۳، ذرت با ۶/۳ و گندم با ۲/۹ درصد حاصل شده است. دقت کلی طبقه‌بندی از ۸۹/۶۲ به ۹۱/۶۹ درصد و ضریب کاپا از ۰/۸۸۰ به ۰/۹۰۳ افزایش پیدا کرده است. همچنین ماتریس ابهام طبقه‌بندی حاصل از شبکه 3DCNN نیز نمایش داده شده است (شکل ۴-ب). همانطور که از مقایسه دقت تشخیص کلاس‌های مختلف در حالت استفاده از اتصالات فرار و عدم اتصالات فرار (شکل ۴-ب و شکل ۳-د) قابل درک است، اتصالات فرار طراحی شده سبب افزایش دقت تشخیص و شناسایی کلیه کلاس‌های مورد بررسی شده‌اند. باتوجه به موارد مطرح شده، می‌توان ادعا نمود اتصالات طراحی شده، به سبب امکان استفاده از دانش تجمعی لایه‌های قبلی در لایه جدید، با افزایش بیش از ۲ درصدی دقت کلی طبقه‌بندی، سبب بهبود نتایج نهایی و دقت تشخیص کلیه کلاس‌های مورد بررسی شده‌اند.


نشان می‌دهد. لازم به ذکر است، قطبش VH نسبت به VV عملکرد موثرتری در افزایش دقت طبقه‌بندی و تشخیص نمونه‌های ارزیابی داشته است. چنان‌که در حالت استفاده از قطبش VV دقت کلی طبقه‌بندی ۹۰/۵۱ و در حالت استفاده از قطبش VH، این پارامتر ۹۱/۰۹ تخمین زده شده است. در مجموع می‌توان ادعا نمود، استفاده از تصاویر چندزمانه به صورت چندمنبعی، نسبت به حالت تک‌منبع، افزایش دقت بیش از ۱/۶ درصدی طبقه‌بندی را در پی داشته است. همچنین استفاده از تصاویر راداری (VH و VV) در کنار تصاویر نوری (NDVI)، افزایش دقت تشخیص کلیه کاربری‌های مورد بررسی را به‌رمغان داشته است.

بررسی تاثیر اتصالات فرار طراحی شده

در این قسمت، اثر اتصالات فرار موجود در شبکه عمیق طراحی شده، مورد بررسی قرار گرفته است. بدین‌منظور، از یک شبکه کاملاً مشابه با شبکه طراحی شده بدون اتصالات فرار (3DCNN) استفاده شده است. همچنین، از ویژگی ورودی NDVI+VV+VH و P=5 که در مرحله قبل بالاترین دقت را بدست آوردند، جهت مقایسه بهره برده می‌شود. دقت‌های بدست آمده از هر دو شبکه



شکل ۳- ماتریس ابهام نرمال شده طبقه‌بندی به ازای P=5 در حالت‌های مختلف ویژگی‌های ورودی



شکل ۴- الف) مقایسه دقت شبکه طراحی شده و 3DCNN، ب) ماتریس ابهام طبقه‌بندی شبکه 3DCNN

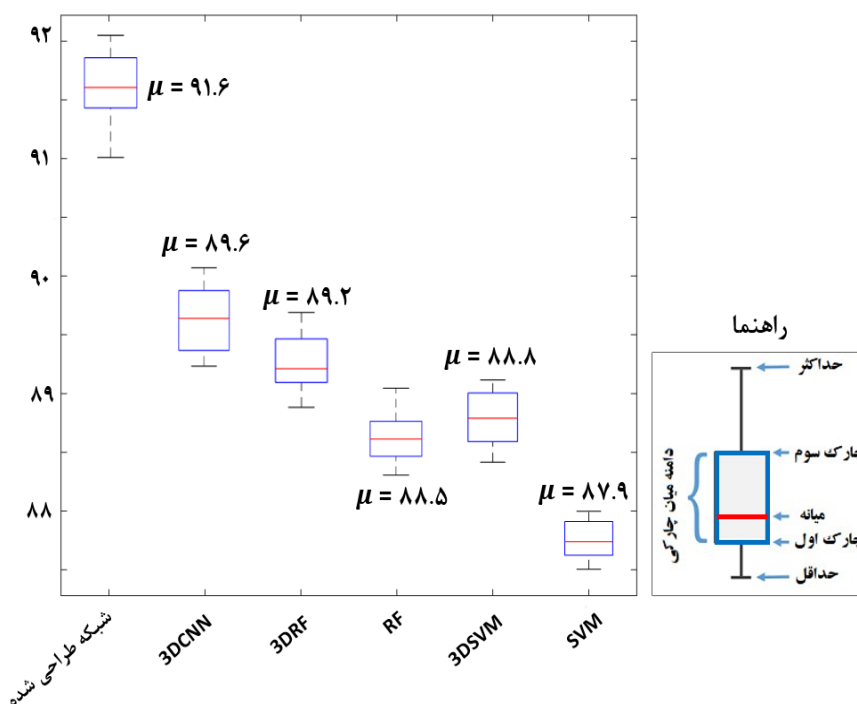
روش‌های جنگل تصادفی و ماشین‌بردار پشتیبان (3DRF و 3DSVM) نیز به ترتیب با دقت کلی میانگین ۸۸٫۸ و ۸۹٫۲ در رتبه سوم و چهارم قرار گرفتند. از بین دو روش SVM و RF (فرمت زمانی) نیز، روش RF با دقت کلی ۸۸/۵ درصد، عملکرد بهتری از روش SVM از خود بجای گذاشته است. 3DSVM و 3DRF نیز به دلیل استفاده از اطلاعات همسایگی، دقت بالاتری نسبت به SVM و RF بدست آورده‌اند. همچنین از آنجایی که روش جنگل تصادفی، یک روش تجمعی^۱ از مجموعه‌ای از درخت-های تصمیم‌گیری بوده نسبت به روش ماشین‌بردار پشتیبان عملکرد بهتری ارائه نموده است. همانطور که مشخص است، در نظرگیری اطلاعات همسایگی در کنار اطلاعات زمانی، منجر به افزایش دقت نهایی طبقه‌بندی شده است. چراکه 3DRF نسبت به RF افزایش دقت ۰٫۷ درصدی و 3DSVM نسبت به SVM افزایش دقت ۰٫۹ درصدی را نشان می‌دهند. همانطور که مشخص است، روش طراحی شده، توانسته عملکرد بهتری در قیاس با سایر روش‌های مورد بررسی از خود نشان دهد.

همچنین مقایسه بصری نقشه طبقه‌بندی شده هر یک از روش‌های مورد بررسی نمایش داده شده است (شکل ۶). قدرت تفکیک مکانی نقشه‌های تولید شده معادل با قدرت تفکیک مکانی تصاویر سنتینل برابر ۱۰ متر است. همانطور که مشخص است، نتایج روش‌های مبتنی بر اطلاعات همسایگی یعنی شبکه طراحی شده، 3DCNN، 3DSVM و 3DRF، به دلیل استفاده همزمان از اطلاعات زمانی و مکانی هر پیکسل مورد بررسی، تمیزتر بوده و حاوی نویزهای نقطه‌ای کمتری است.

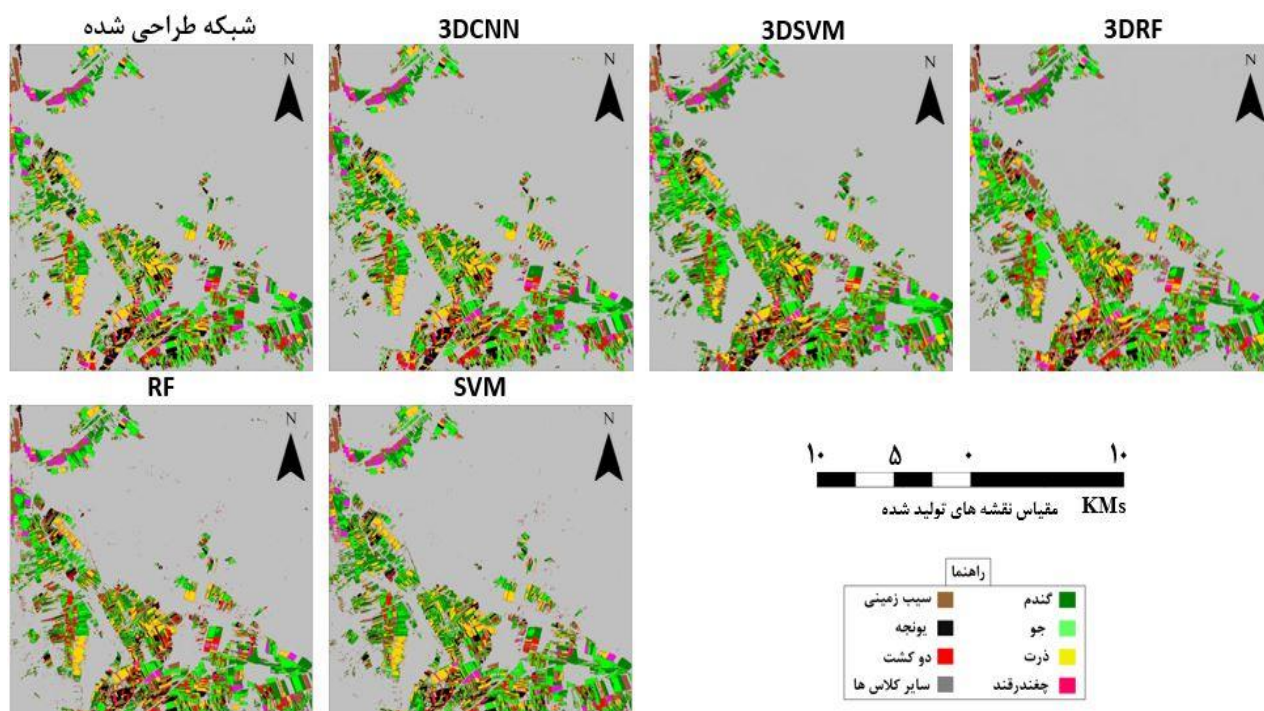
مقایسه روش پیشنهادی با سایر روش‌ها

عملکرد شبکه طراحی شده، با شبکه 3DCNN (مشابه با شبکه طراحی شده بدون اتصالات فرار) و دو روش جنگل تصادفی و ماشین‌بردار پشتیبان در دو فرمت زمانی (RF و SVM) و زمانی- مکانی (3DRF و 3DSVM) در حالت پنجره ورودی به ابعاد ۵x۵ از نظر معیار میانگین دقت کلی، به واسطه ۵۰ بار تکرار طبقه‌بندی با داده‌های آموزشی و ارزیابی متفاوت، مقایسه شده است که نتایج این مقایسه در نمودار جعبه‌ای آماری نشان داده شده است (شکل ۵). میانگین دقت‌های کلی بدست آمده نیز با μ نشان داده شده است. لازم به ذکر است، پارامترهای بهینه روش RF، ۳۰۰ درخت و حداکثر عمق ۱۰، روش 3DRF، ۲۰۰ درخت و حداکثر عمق ۸ و برای هر دو روش SVM و 3DSVM، کرنل شعاعی با ضریب C برابر ۱۰ توسط تکنیک جست‌وجوی شبکه‌ای انتخاب شدند.

همانطور که مشخص است، روش طراحی شده با میانگین دقت ۹۱٫۶ درصد، با اختلاف ۲ درصدی، نسبت به سایر روش‌ها عملکرد مطلوب‌تری از خود به نمایش گذاشته است. در بین روش‌های مورد بررسی، شبکه 3DCNN با میانگین دقت ۸۹٫۶ درصد در رتبه دوم قرار گرفته است. همانطور که مشخص است، هر دو روش شبکه عصبی عمیق طراحی شده و 3DCNN نسبت به دو روش جنگل تصادفی و ماشین‌بردار پشتیبان، به دلیل توانایی در استخراج ویژگی‌های سطح بالاتر، دقت بهتری بدست آورده‌اند. از طرفی روش طراحی شده نسبت به 3DCNN به دلیل اتصالات فرار طراحی شده و استفاده از دانش تجمعی لایه‌های قبلی در لایه جدید دقت بالاتری بدست آورده است. فرمت زمانی- مکانی



شکل ۵- مقایسه دقت کلی روش‌های مختلف



شکل ۶- نقشه طبقه‌بندی نهایی روش‌های مختلف

مقایسه با پژوهش‌های پیشین

مقایسه نتایج مطالعات سال‌های اخیر با مطالعه کنونی نیز در این بخش انجام شده است (جدول ۳). در مطالعات انتخاب‌شده جهت مقایسه، یا از تصاویر مشابه با مطالعه کنونی استفاده شده و یا شبکه‌های عصبی پیچشی عمیق جهت طبقه‌بندی به‌کار گرفته شده است. همانطور که مشخص است، روش پیشنهادی این

مطالعه نسبت به مطالعات سال‌های اخیر، عملکرد قابل قبولی از خود به‌جای گذاشته است. لازم به‌ذکر است، در بین مطالعات مورد بررسی، استفاده از شبکه‌های عصبی پیچشی عمیق، نسبت به روش‌های جنگل تصادفی سلسله‌مراتبی و تلفیق نتایج روش‌های طبقه‌بندی پیکسل‌مبنا و شی‌مبنا عملکرد بهتری از خود نشان داده است.

جدول ۳- مقایسه نتایج بدست آمده با پژوهش‌های پیشین

مطالعه	مجموعه ویژگی ورودی	روش طبقه‌بندی	دقت کلی (درصد)
(Brinkhoff <i>et al.</i> , 2020)	تصاویر سنتینل-۱ و سنتینل-۲	تلفیق روش‌های طبقه‌بندی پیکسل‌مبنا و شی‌مبنا	۸۴/۸
(Zhong <i>et al.</i> , 2019)	تصاویر لندست	شبکه عصبی پیچشی آغازین ^۱ عمیق	۸۵/۵۴
(Van Tricht <i>et al.</i> , 2018)	تصاویر سنتینل-۱ و سنتینل-۲	جنگل تصادفی سلسله مراتبی	۸۲
(Sharma <i>et al.</i> , 2017)	تصاویر لندست	شبکه عصبی پیچشی عمیق معمولی	۸۹/۲۶
مطالعه کنونی	تصاویر سنتینل-۱ و سنتینل-۲	شبکه طراحی شده	۹۱/۶

نتیجه‌گیری

افزایش دقت کلی حداقل ۲،۴ درصدی را فراهم آورد. اتصالات فرار طراحی شده نیز سبب افزایش دقت کلی و ضریب کاپای طبقه‌بندی به ترتیب از ۸۹،۶ درصد و ۰،۸۸، به ۹۱،۶ و ۰،۹ شدند. نتایج بصری نهایی روش پیشنهادی با توجه به استفاده از اطلاعات همسایگی هر پیکسل تصویری، از نوفه کمتری نسبت به سایر روش‌های طبقه‌بندی پیکسل‌مبنا نظیر جنگل تصادفی و ماشین-بردار پشتیبان برخوردار است.

بررسی روش پیشنهادی در سایر مناطق مطالعاتی وسیع‌تر و همچنین با تنوع درون کلاسی و برون کلاسی بالاتر، می‌تواند عملکرد روش پیشنهادی را به‌خوبی مورد ارزیابی قرار دهد. طراحی معماری‌های نوین بر مبنای سایر انواع شبکه‌های عصبی نظیر شبکه‌های عصبی بازگشتی و یا شبکه‌های عصبی رمزنگار، می‌تواند در مطالعات آتی پیگیری شود. همچنین، طراحی شبکه‌های عمیق تجمعی، با قابلیت استفاده از نتایج معماری‌های مختلف نیز، به‌عنوان یکی دیگر از پیشنهادهای جالب در تحقیقات آینده می‌باشد.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

در این مطالعه طبقه‌بندی اراضی کشاورزی با بهره‌گیری از تصاویر سنجش از دوری نوری (سنتینل-۲) و SAR (سنتینل-۱) به صورت چندزمانه انجام پذیرفت. جهت طبقه‌بندی، از روش‌های یادگیری عمیق، به‌عنوان تکنیک‌هایی قدرتمند در یادگیری الگوها و ویژگی‌های کلاس‌های مختلف استفاده شد. به‌نحوی که یک شبکه پیچشی سه‌بعدی عمیق، با ساختاری نوین طراحی گردید. شبکه طراحی شده، علاوه بر استفاده از کرنل‌های سه‌بعدی با قابلیت استفاده از اطلاعات همسایگی و زمانی هر پیکسل تصویری در طبقه‌بندی، از اتصالات فرار لایه‌های قبلی بهره برد. اتصالات فرار به‌نحوی طراحی گردید تا برخلاف شبکه‌های پیچشی عمیق معمولی، امکان استفاده از ویژگی‌های استخراج شده توسط لایه-های پیچشی قبلی، در لایه‌های جدید فراهم شود. روش پیشنهادی، در مقایسه با سایر روش‌های مورد بررسی با توجه به معیارهای ارزیابی بهترین عملکرد را از خود نشان داده است. به-نحوی که روش پیشنهادی در مقایسه با سایر روش‌های مطرح این حوزه نظیر جنگل تصادفی و ماشین بردار پشتیبان نیز،

REFERENCES

- Boulze, H., Korosov, A., & Brajard, J. (2020). Classification of sea ice types in Sentinel-1 SAR data using convolutional neural networks. *Remote Sensing*, 12(13), 2165.
- Brinkhoff, J., Vardanega, J., & Robson, A. J. (2020). Land cover classification of nine perennial crops using sentinel-1 and-2 data. *Remote Sensing*, 12(1), 96.
- Carranza-García, M., García-Gutiérrez, J., & Riquelme, J. C. (2019). A framework for evaluating land use and land cover classification using convolutional neural networks. *Remote Sensing*, 11(3), 274.
- Carrasco, L., O'Neil, A.W., Morton, R.D., & Rowland, C.S. (2019). Evaluating combinations of temporally aggregated Sentinel-1, Sentinel-2 and Landsat 8 for land cover mapping with Google Earth Engine. *Remote Sensing*, 11(3), 288.
- Chakhar, A., Hernández-López, D., Ballesteros, R., & Moreno, M. A. (2021). Improving the Accuracy of Multiple Algorithms for Crop Classification by Integrating Sentinel-1 Observations with Sentinel-2 Data. *Remote Sensing*, 13(2), 243.
- Chakhar, A., Ortega-Terol, D., Hernández-López, D., Ballesteros, R., Ortega, J. F., & Moreno, M. A. (2020). Assessing the accuracy of multiple classification algorithms for crop classification using Landsat-8 and Sentinel-2 data. *Remote Sensing*, 12(11), 1735.
- Chang, L., Chen, Y. T., Wang, J. H., & Chang, Y. L. (2021). Rice-Field Mapping with Sentinel-1A SAR Time-Series Data. *Remote Sensing*, 13(1), 103.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote sensing of Environment*, 202, 18-27.
- Guidici, D., & Clark, M. L. (2017). One-Dimensional convolutional neural network land-cover classification of multi-seasonal hyperspectral imagery in the San Francisco Bay Area, California. *Remote Sensing*, 9(6), 629.

- Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *In International conference on machine learning*, 448-456.
- Jin, X., Kumar, L., Li, Z., Feng, H., Xu, X., Yang, G., & Wang, J. (2018). A review of data assimilation of remote sensing and crop models. *European Journal of Agronomy*, 92, 141-152.
- Joshi, N., Baumann, M., Ehammer, A., Fensholt, R., Grogan, K., Hostert, P., & Waske, B. (2016). A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. *Remote Sensing*, 8(1), 70.
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). A review of the use of convolutional neural networks in agriculture. *The Journal of Agricultural Science*, 156(3), 312-322.
- Karthikeyan, L., Chawla, I., & Mishra, A. K. (2020). A review of remote sensing applications in agriculture for food security: Crop growth and yield, irrigation, and crop losses. *Journal of Hydrology*, 586, 124905.
- Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 24-49.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105.
- Li, Y., Zhang, H., & Shen, Q. (2017). Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network. *Remote Sensing*, 9(1), 67.
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS journal of photogrammetry and remote sensing*, 152, 166-177.
- Mandal, D., Kumar, V., Bhattacharya, A., Rao, Y. S., Siqueira, P., & Bera, S. (2018). Sen4Rice: A processing chain for differentiating early and late transplanted rice using time-series Sentinel-1 SAR data with Google Earth engine. *IEEE Geoscience and Remote Sensing Letters*, 15(12), 1947-1951.
- Mazzia, V., Khaliq, A., & Chiaberge, M. (2020). Improvement in land cover and crop classification based on temporal features learning from Sentinel-2 data using recurrent-convolutional neural network (R-CNN). *Applied Sciences*, 10(1), 238.
- Rezaee, M., Mahdianpari, M., Zhang, Y., & Salehi, B. (2018). Deep convolutional neural network for complex wetland classification using optical remote sensing imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 3030-3039.
- Sharma, A., Liu, X., Yang, X., & Shi, D. (2017). A patch-based convolutional neural network for remote sensing image classification. *Neural Networks*, 95, 19-28.
- Singha, M., Dong, J., Sarmah, S., You, N., Zhou, Y., Zhang, G., & Xiao, X. (2020). Identifying floods and flood-affected paddy rice fields in Bangladesh based on Sentinel-1 imagery and Google Earth Engine. *ISPRS Journal of Photogrammetry and Remote Sensing*, 166, 278-293.
- Van Tricht, K., Gobin, A., Gilliams, S., & Piccard, I. (2018). Synergistic use of radar Sentinel-1 and optical Sentinel-2 imagery for crop mapping: a case study for Belgium. *Remote Sensing*, 1642.
- Xiao, J., Wu, H., Wang, C., & Xia, H. (2018). Land cover classification using features generated from annual time-series Landsat data. *IEEE Geoscience and Remote Sensing Letters*, 15(5), 739-743.
- Xu, L., Zhang, H., Wang, C., Zhang, B., & Liu, M. (2019). Crop classification based on temporal information using sentinel-1 SAR time-series data. *Remote Sensing*, 11(1), 53.
- Zhai, Y., Wang, N., Zhang, L., Hao, L., & Hao, C. (2020). Automatic crop classification in northeastern China by improved nonlinear dimensionality reduction for satellite image time series. *Remote Sensing*, 12(17), 2726.
- Zhao, H., Chen, Z., Jiang, H., Jing, W., Sun, L., & Feng, M. (2019). Evaluation of three deep learning models for early crop classification using sentinel-1A imagery time series—A case study in Zhanjiang, China. *Remote Sensing*, 11(22), 2673.
- Zhong, L., Hu, L., & Zhou, H. (2019). Deep learning based multi-temporal crop classification. *Remote sensing of environment*, 221, 430-443.