

ارائه روش طبقه بندی مبتنی بر یادگیری عمیق در تفکیک انواع محصولات کشاورزی با استفاده از تصاویر ماهواره‌ای سری زمانی

ناهید پورحسن^۱، رضا شاه‌حسینی^{۲*}، سید تیمور سیدی^۳

^۱ کارشناس ارشد نقشه برداری، سنجش از دور - دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی - پردیس دانشکده

های فنی - دانشگاه تهران

nahid.pourhasan@ut.ac.ir

^۲ استادیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی - پردیس دانشکده های فنی - دانشگاه تهران

rshahosseini@ut.ac.ir

^۳ دانشجوی دکتری نقشه برداری، سنجش از دور - دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی - پردیس

دانشکده های فنی - دانشگاه تهران

seydi.teymoor@ut.ac.ir

(تاریخ دریافت فروردین ۱۳۹۹، تاریخ تصویب شهریور ۱۴۰۰)

چکیده

کسب آگاهی و دانش در رابطه با الگوی کشت و سطح زیر کشت نقش مهمی را در مدیریت اراضی کشاورزی و برآورد میزان تولید خالص ایفا می‌کند. ترکیب نتایج حاصل از مشاهدات و اندازه‌گیری‌های زمینی با داده‌های سنجش از دور می‌تواند نقشه‌های به‌هنگام از سطح زیر کشت محصولات ارائه نماید. این امر برای تعریف واحدهای مدیریت و رسیدن به اطلاعات دقیق مورد نیاز کشاورزان و برنامه ریزان ارزشمند است. اکثر روش‌های مورد استفاده به منظور تفکیک محصولات کشاورزی، در مواردی که الگوی کشت محصولات مختلف مانند گندم و جو، شباهت زیادی داشته باشند، عملکردی مناسبی ندارند. لذا هدف از این مقاله ارائه روش طبقه بندی مبتنی بر یادگیری عمیق بر روی تصاویر سری زمانی ماهواره‌ای برای تولید نقشه سطح زیر کشت دقیق انواع محصولات کشاورزی با شباهت فنولوژیکی بالا می‌باشد. به این منظور تصاویر سری زمانی ماهواره Landsat8 بر اساس تقویم زراعی منطقه انتخاب شدند. با استفاده از شاخص تفاضلی نرمال شده پوشش گیاهی (NDVI) بصورت سری زمانی و یک مجموعه داده آموزشی از مزارع کشاورزی مختلف، از شبکه عصبی کانولوشنی (CNN) برای تولید خودکار نقشه محصول در منطقه چناران واقع در استان خراسان شمالی استفاده شد. جهت تفکیک محصولات در این مطالعه، از تلفیق طبقه بندی نظارت شده و تصحیح بصری استفاده شده است. به منظور برآورد صحت نتایج، نقشه‌های تولید شده با نقاط کنترل زمینی بررسی شد و ضریب کاپا و دقت کلی محاسبه شد. نتایج نشان داد که استفاده از داده‌های سری زمانی ماهواره‌ای کارایی بالایی برای شناسایی و تفکیک انواع محصولات کشاورزی دارند. همچنین روش طبقه‌بندی ارائه شده مبتنی بر شبکه عصبی کانولوشنی با دقت کلی ۹۵٫۷۶ دقت بالاتری نسبت به سایر روش‌های مرسوم از جمله روش‌های جنگل تصادفی (دقت کلی: ۸۹٫۸۵)، ماشین بردار پشتیبان (دقت کلی: ۸۸٫۷۸)، شبکه عصبی پرسپترون (دقت کلی: ۸۵٫۷۵) و K نزدیکترین همسایگی (دقت کلی: ۸۹٫۶۰)، در تفکیک و شناسایی محصولات کشاورزی دارد. این اطلاعات برای برنامه‌ریزی‌های کلان منطقه‌ای در قالب تدوین الگوی کشت، تعیین میزان نیاز کشور به واردات محصولات کشاورزی، برنامه‌ریزی جهت توسعه صادرات محصولات کشاورزی مازاد بر نیاز کشور و توسعه مکانیزاسیون در سطح کلان مدیریتی بسیار مفید می‌باشند.

واژگان کلیدی: تفکیک محصولات کشاورزی، سنجش از دور، Landsat8، شاخص تفاضلی نرمال شده (NDVI) شبکه عصبی کانولوشنی (CNN)

* نویسنده رابط

۱- مقدمه

امروزه یکی از بزرگترین مشکلات پیش روی انسان‌ها رشد فزاینده‌ی جمعیت و به تبع آن کمبود منابع در دسترس جهت رفع نیازهای اساسی انسان‌ها می‌باشد. به منظور نظارت بر مشکل کمبود مواد غذایی، تصمیم‌گیران و برنامه‌ریزان نیاز به کسب آگاهی و اطلاعات به روز از کمیت، کیفیت، نوع، نحوه پراکنش و سطح زیر کشت محصولات کشاورزی دارند. بنابراین برنامه‌ریزی و مدیریت کشاورزی در مقیاس محلی و منطقه‌ای نیازمند کسب آگاهی از نحوه توزیع انواع محصولات کشاورزی و سطح زیر کشت آن‌ها می‌باشد. در همین راستا، تهیه نقشه نوع و سطح زیر کشت محصولات زراعی دارای اهمیت فراوانی می‌باشد [۱]. ایران از جمله کشورهایی است که به علت موقعیت جغرافیایی و آب و هوایی، دارای زمین‌های مستعد کشاورزی می‌باشد، به طوری که سهم کشاورزی در اقتصاد کشور ۳۱ درصد می‌باشد. طی سال‌ها چگونگی برآورد سطح زیر کشت محصولات عمده در مناطق مختلف همواره مورد بحث کارشناسان بوده است. از گذشته تا کنون از روش‌های مختلفی برای این کار استفاده می‌شد که همه این روش‌ها زمان‌بر و پرهزینه بودند و دقت پایینی داشتند [۲]. بنابراین تکنیک‌های سنجش از دوری با توجه به پتانسیل بالایشان برای شناسایی و تفکیک محصولات کشاورزی روی کار آمدند. استفاده از داده‌های سنجش از دور به دلیل داشتن ویژگی‌هایی مانند، چند زمانه بودن، چند طیفی بودن، قدرت تفکیک مکانی و رادیومتریکی مناسب و متنوع، دید وسیع و یکپارچه، قادر به تفکیک عارضه ها و محصولات مختلف کشاورزی از جمله سطح، نوع و الگوهای زمانی و مکانی کشت هستند [۳].

از آن جا که در ایران هنوز از روش های سنتی برای تفکیک و تخمین سطح زیر کشت محصولات استفاده می شود و این روش ها خطای زیادی دارند، لزوم دستیابی به الگوریتم های مناسب ضروری می باشد [۲].

شهرستان چناران یکی از قطب‌های تولید محصولات زراعی و باغی استان خراسان محسوب می‌شود و در بخش کشاورزی با تولید ۲۱ رقم محصول زراعی و باغی رتبه اول تا سوم را دارا می‌باشد. اما هر ساله به دلایل گوناگون از جمله تامین آب شرب مشهد توسط دشت چناران شاهد افت شدید آب می‌باشد. با توجه به شرایط موجود و بحران آب در این منطقه آگاهی از وضعیت کاربری اراضی و سطح

زیر کشت محصولات کشاورزی در این ناحیه به عنوان اولین گام در ساماندهی الگوی کشت و مدیریت بهینه اراضی مطرح می‌شود.

پژوهش‌هایی در زمینه‌ی استفاده از تصاویر ماهواره‌ای برای تهیه نقشه‌های کاربری اراضی و سطح زیرکشت محصولات کشاورزی در کشورهای مختلف دنیا و از جمله ایران انجام شده است که در ادامه به نتایج تعدادی از آنها اشاره می‌گردد. پژوهشی در یک منطقه کشاورزی حفاظت شده در مشهد برای شناسایی محصولات تابستانه انجام شد. از دو تصویر ماهواره Landsat و تصاویر سامانه Google Earth برای شناسایی باغات استفاده شد. شاخص NDVI^۱ با استفاده از تصاویر به دست آمد و دو روش شبکه عصبی و حداکثر احتمال به کار گرفته شد [۴]. دقت روش‌های به کار رفته پایین و از دو تصویر برای تفکیک محصولات استفاده شد که با توجه به مراحل مختلف رشد گیاهان عملکرد مناسبی نداشت.

در پژوهشی در منطقه ای از آریزونا در آمریکا که برای محاسبه و کنترل آب مصرفی مربوط بخش کشاورزی انجام شد، از تصاویر سری زمانی ماهواره Landsat و از شاخص NDVI استخراج شده از آنها بر اساس تقویم زراعی منطقه استفاده شد. روش طبقه‌بندی SVM^۲ برای جداسازی و شناسایی محصولات به کار گرفته شد [۵]. در این مطالعه ابعاد داده‌های آموزشی کوچک در نظر گرفته شده که یک نقطه ضعف محسوب می‌شود، چرا که باعث افزایش هزینه و زمان جمع‌آوری داده‌های میدانی می‌شود. از طرفی این روش با روش‌های دیگر مقایسه نشده تا عملکرد روش بهتر مشخص شود. یکی دیگر از مشکلات اساسی روش‌های مبتنی بر پیکسل متکی بودن به محتوای مکانی داده‌ها و نادیده گرفتن محتوای زمانی است [۶].

در پژوهشی دیگر برای شناسایی انواع محصولات کشاورزی در منطقه‌ای در وینیپگ کانادا از تصاویر چندزمانه و پلاریمتری UAVSAR استفاده شد. در این مطالعه از باند L استفاده و ویژگی‌های مختلف با استفاده از روش‌های تجزیه فیزیکی^۳ استخراج شد. سپس با استفاده از روش ماشین بردار پشتیبان منطقه مورد نظر به هفت نوع محصول کاهو، سویا، گندم، جو، برنج، کلزا، علوفه و علف طبقه‌بندی شدند [۷]. اگرچه این مطالعه دقت خوبی در تفکیک محصولات ارائه داد،

^۱ Normalized difference vegetation index

^۲ Support vector machine

^۳ Freeman-durden

(از جمله داده‌های سری‌زمانی) و امکان طبقه‌بندی پیکسل اشتباه در این ساختار بسیار پایین می‌باشد [۹]. در این مطالعه با در نظر گرفتن تقویم زراعی منطقه مورد مطالعه، تعداد تصاویر سری زمانی بگونه‌ای انتخاب شد که مراحل مهم رشد هر محصول به خوبی مدل‌سازی شود. از طرفی داده‌های آموزشی با دقت بالا و توسط گروه نقشه‌برداری جمع‌آوری شد. همچنین ابعاد داده‌های آموزشی که فاکتور مهمی در تعیین دقت الگوریتم‌ها می باشد را بزرگ در نظر گرفتیم.

این مطالعه در چهار بخش سازمان‌دهی شده است: بخش اول مقدمه است که بیان شد؛ بخش دوم، مواد و روش‌ها؛ بخش سوم، منطقه و داده مورد مطالعه؛ بخش چهارم، پیاده‌سازی و ارائه نتایج آمده است. جزئیات الگوریتم‌های مورد استفاده در بخش‌های بعدی شرح داده می‌شود.

۲- مواد و روش‌ها

این بخش به تشریح جزئیات ساختار روش پیشنهادی می‌پردازد. مطابق با شکل (۱)، ساختار کلی کار ارائه شده است. در مرحله پیش پردازش، تصحیحات طیفی و هندسی تصاویر سری زمانی انجام شد. سپس شاخص NDVI تصاویر سری زمانی استخراج می‌شود. با در نظر گرفتن مجموعه داده آموزشی، الگوریتم مورد نظر آموزش داده شده و طبقه‌بندی برای منطقه مورد نظر انجام می‌شود. سپس به منظور بررسی دقت کار الگوریتم طبقه‌بندی پیشنهادی با چهار الگوریتم متدوال طبقه‌بندی مقایسه می‌شود. در مرحله بعد پارامترهای بهینه برای الگوریتم‌های مقایسه‌ای با استفاده از همان داده‌های آموزشی و بکار بردن الگوریتم جستجوی شبکه‌ای^۵ تعیین می‌گردد. پس از محاسبه پارامترهای بهینه، نقشه‌های نهایی انواع محصولات تولید می‌شود و با الگوریتم CNN^۶ مقایسه می‌شود که در ادامه جزئیات کار بیش تر توضیح داده خواهد شد.

۲-۱- شاخص NDVI

NDVI یکی از پرکاربردترین شاخص‌ها برای پایش تغییرات پوشش گیاهی است. اغلب نسبت معینی از باندهای مادون قرمز نزدیک و قرمز برای نقشه‌های پوشش گیاهی و بررسی شرایط آن‌ها مورد استفاده قرار می‌گیرد زیرا این

اما تصاویر راداری به راحتی قابل دسترسی نیستند و هزینه تهیه آن‌ها بالاست به علاوه کار کردن با این نوع داده به علت پردازش‌های سنگین و حجم بالای محاسبات و نویز آن‌ها مشکلات فراوانی به همراه دارد.

پژوهشی دیگر در جنوب شرقی رومانی انجام شد. در در این مطالعه از تصاویر سری‌زمانی ماهواره Sentinel 2 برای تفکیک چهار محصول گندم، ذرت، برنج و آفتابگردان استفاده شد. در این کار رویکرد شی‌مبنا جهت طبقه‌بندی تصاویر مورد استفاده قرار گرفت و یک روش طبقه‌بندی نظارت شده (TWDTW)^۱ با انتخاب خودکار پارامترهای شکل و مقیاس به کار گرفته شد [۸]. در این مطالعه تعداد کلاس‌ها کم و همچنین رویکرد شی‌مبنا با مشکل انتخاب پارامتر روبه‌رو است، چرا که در یک منطقه کشاورزی هم قطعات بزرگ و هم کوچک موجود است و پارامترها هر طور در نظر گرفته شوند دچار خطای بیش‌برازش^۲ یا کم‌برازش^۳ در تعدادی از قطعات خواهیم شد. بعلاوه اشتباه الگوریتم منجر به اشتباه در تشخیص یک قطعه زمین کشاورزی نیز می‌شود.

مشکلات موجود در به کارگیری روش‌های مرسوم طبقه‌بندی محصولات که در بالا بررسی شدند و از طرفی دیگر، کارایی پایین اکثر روش‌های مورد استفاده به منظور تفکیک محصولات کشاورزی، در مواردی که الگوی کشت محصولات مختلف مانند گندم و جو، شباهت زیادی داشته باشند، علت اصلی ایده این مقاله در استفاده از الگوریتم‌های یادگیری عمیق شد. در طی سال‌های اخیر استفاده از روش‌های یادگیری عمیق (DL)^۴ برای پردازش تصاویر سنجش از دور رو به افزایش بوده و اثبات شده است که DL برای پردازش هر دو نوع تصاویر اپتیک و راداری برای استخراج پوشش‌های مختلف زمین مناسب می‌باشد. یادگیری عمیق یک تکنولوژی پیشرفته برای پردازش تصاویر از جمله تصاویر سنجش از دوری می‌باشد. پایه‌های اصلی این ساختار، شبکه‌های عصبی نظارت نشده هستند که برای قطعه‌بندی تصاویر نوری و داده‌هایی که بخشی از اطلاعات آن‌ها به علت ابر یا سایه از دست رفته باشند مناسب می‌باشند. در روش‌های یادگیری عمیق پیدا کردن ویژگی بهینه به صورت خودکار انجام می‌شود و در حل مسائل پیچیده به خوبی عمل می‌کند. همچنین این ساختار برای داده‌های با حجم بالا مناسب است

^۱ Time-Weighted Dynamic Time Warping

^۲ Over fitting

^۳ Under fitting

^۴ Deep Learning


^۵ Grid search

^۶ Convolutional neural network

دو باند به ترتیب با گیاهان جذب و منعکس می‌شوند. وجود یک نسبت بالا نشان دهنده پوشش گیاهی سالم است. در حالی که یک نسبت پایین مبین پوشش گیاهی ناسالم و دچار استرس یا بدون پوشش است. شاخص NDVI از طریق رابطه (۱) محاسبه می‌شود [۱۰].

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (1)$$

ارزش عددی این شاخص بین اعداد +۱ و -۱ در نوسان است و ثابت شده است هر چه عدد به +۱ نزدیک‌تر شود نشان دهنده پوشش گیاهی بیشتر است [۱۱].



شکل ۱- فلوچارت روش پیشنهادی

۲-۲- طبقه بندی

به منظور طبقه‌بندی محصولات کشاورزی روش‌های مختلفی به کار می‌رود که شامل سه رویکرد اصلی می‌شوند: مبتنی بر پیکسل، مبتنی بر شی و مبتنی بر محتوا

[۱۲]. روش‌های مبتنی بر یادگیری عمیق که به تازگی در طبقه‌بندی تصاویر مورد استفاده قرار گرفته‌اند، از محتوای اطلاعات مکانی و زمانی داده‌ها استفاده می‌کنند [۱۳]. این روش‌ها به دو صورت نظارت شده و نظارت نشده عمل می‌کنند. از آن جا که دقت روش‌های نظارت شده در طبقه‌بندی تصاویر ماهواره‌ای بالاتر می‌باشد، در این مطالعه از روش نظارت شده استفاده می‌شود [۱۴]. سپس روش به کار رفته با چهار روش متداول طبقه‌بندی نظارت شده: جنگل تصادفی^۱، ماشین بردار پشتیبان^۲، شبکه عصبی پرسپترون^۳ و K نزدیکترین همسایگی^۴ مقایسه می‌شود [۱۵]. در ادامه روش کار الگوریتم پیشنهادی و الگوریتم‌های مقایسه‌ای به طور خلاصه ارائه می‌گردد.

۲-۲-۱- شبکه عصبی کانولوشنی

یادگیری عمیق (deep learning) یک روش نیرومند یادگیری ماشین است که برای حل طیف وسیعی از کارهای مرتبط با پردازش تصویر، بینایی ماشین، پردازش سیگنال و پردازش زبان طبیعی به کار می‌رود [۱۶]. یکی از مشهورترین معماری‌های یادگیری عمیق شبکه عصبی کانولوشنی (CNNs) می‌باشد که در حوزه‌های مرتبط با تصاویر سنجنش از دوری به کار گرفته می‌شود [۱۷]. این روش یک روش یادگیری نظارت شده می‌باشد و نسبت به سایر معماری‌های یادگیری عمیق در طبقه‌بندی تصاویر سنجنش از دوری دقت بالاتری دارا می‌باشد. این روش تصاویر را از مجموعه‌ای از چندین لایه شامل نرون‌ها یا کرنل‌های کوچک (کانولوشنی) عبور می‌دهد. هر نرون به بخش کوچکی از تصویر نگاه می‌کند و یک خروجی می‌دهد. این خروجی شامل کلاس یا احتمالی برای بهترین توصیف از کلاس‌ها می‌باشد. معماری شبکه عصبی کانولوشنی به کار رفته در این مطالعه در شکل ۲ نشان داده شده است که شامل سه لایه می‌باشد: ۱- کانولوشن: در این لایه کرنل‌ها (وزن‌ها) به آرامی روی تصویر عبور کرده و ویژگی‌های مختلف را استخراج می‌کنند. معماری به کار رفته در این مطالعه شامل سه لایه کانولوشنی می‌باشد. ۲- لایه pooling: این لایه ابعاد داده را در حوزه

^۱ Random forest

^۲ Support vector machine

^۳ Multilayer perceptron

^۴ K nearest neighbors

می‌کند. در به کارگیری این الگوریتم تعیین مناسب پارامتر جریمه C (پارامتر تنظیم) و پارامترهای کرنل از اهمیت بالایی برخوردار است [۲۱].

فرض کنید داده‌های آموزشی l موجود می‌باشد که هر یک با (x_i, y_i) نشان داده می‌شود، x_i بردار ویژگی n بعدی و y_i کلاس آن باشد، ابر صفحه مورد نظر در فضای n بعدی با رابطه (۳) تعیین می‌شود.


$$w^T \phi(x) + b = 0 \quad (3)$$

W بردار وزن، b بردار بایاس و ϕ تابع کرنل برای انتقال داده‌ها به فضای بالاتر است. بیشینه نمودن حاشیه بین دو کلاس معادل کمینه کردن اندازه w می‌باشد که منجر به حل مسئله کمینه‌سازی قید در (۴) می‌شود.

$$\begin{aligned} \text{Min} & \left(\frac{1}{2} \|w\|^2 + C \sum_{i=1}^k \xi_i \right) \\ \text{Subject to : } & y_i (w \phi(x_i) + b) > 1 - \xi_i \quad i = 1, \dots, k \end{aligned} \quad (4)$$

۲-۲-۴- الگوریتم شبکه عصبی پرسپترون چند لایه

در یک تقسیم‌بندی می‌توان شبکه‌های عصبی را به شبکه‌های نظارت شده و نظارت نشده تقسیم کرد. در شبکه‌های نظارت شده فرآیند آموزش شبکه با استفاده از داده‌های آموزشی انجام می‌شود. از جمله شبکه‌های نظارت شده می‌توان به شبکه عصبی پرسپترون اشاره کرد که معمول‌ترین مدل برای طبقه‌بندی تصویر در سنجش از دور است.



شکل ۳- ساختار شبکه عصبی

شکل (۳) یک الگوریتم پرسپترون چند لایه که جزء الگوریتم‌های غیر پارامتریک به شمار می‌رود، معمولاً از یک لایه ورودی، یک یا چند لایه نهفته و یک لایه خروجی تشکیل شده است که به ترتیب اطلاعات را

مکان به منظور کاهش تعداد پارامترها کاهش می‌دهد تا هزینه‌ها را کاهش داده و از پدیده $over\ fitting$ جلوگیری کند. ۳- لایه تماماً متصل: این لایه، لایه‌های ورودی را به یک لایه یک بعدی تبدیل می‌کند [۱۴].

۲-۲-۲- K نزدیکترین همسایگی


الگوریتم KNN از جمله الگوریتم‌هایی است که بسیار ساده عمل می‌کند و یک الگوریتم غیر پارامتریک است [۱۸]. این الگوریتم روشی نظارت شده برای طبقه بندی اشیاء بر اساس نزدیک‌ترین یا مشابه‌ترین نمونه‌های آموزشی در فضای ویژگی است. این نزدیکترین همسایگی بر اساس توابع فاصله تعیین می‌شود. فاصله بین دو نقطه x_1 و x_2 در فضای n بعدی با استفاده از رابطه (۲) به دست می‌آید.

$$\begin{aligned} x_1 &= (x_{11}, x_{12}, \dots, x_{1n}) \\ x_2 &= (x_{21}, x_{22}, \dots, x_{2n}) \\ \text{dist}(x_1, x_2) &= \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \end{aligned} \quad (2)$$

در هنگام محاسبه فواصل برای الگوریتم KNN می‌توان از معیارهای مختلفی از جمله فاصله اقلیدوسی یا Mahalanobis استفاده کرد [۱۹].

۲-۲-۳- الگوریتم ماشین پشتیبان

طبقه‌بندی‌کننده ماشین بردار پشتیبان یک شیوه طبقه بندی نظارت شده و غیر پارامتریک است [۲۰]. ایده اساسی این طبقه‌بندی‌کننده برای جداسازی کلاس‌های مختلف، یافتن یک ابر صفحه بهینه به عنوان سطح تصمیم‌گیری به گونه‌ای می‌باشد که حاشیه بین دو کلاس را بیشینه کند شکل (۲).



شکل ۲- ابر صفحه بهینه، بردارهای پشتیبان

اغلب کلاس‌ها به طور خطی جدایی پذیر نیستند و در چنین مواردی ماشین بردار پشتیبان از توابع کرنل استفاده

۳-۲- بهینه سازی پارامترهای طبقه بندی کننده

هدف از اجرای این بخش به دست آوردن مقادیر بهینه پارامترهای طبقه بندی کننده است. الگوریتم های مورد نظر زمانی کارایی مناسب خواهند داشت که پارامترهای آن ها به دقت اندازه گیری شود. برای این منظور روش های مختلفی ارائه شده است. در این پژوهش به منظور بهینه سازی پارامترهای طبقه بندی کننده از روش جستجوی شبکه ای استفاده شده است. الگوریتم جستجوی شبکه ای، روشی رایج در انتخاب پارامترهای مدل می باشد. در این روش یک شبکه از مجموعه جواب ها در محدوده مورد نظر از پارامترها در نظر گرفته و یک جستجوی کامل بر روی تمام شبکه انجام می شود. برای مقادیر مختلف هر پارامتر مقداری که به ازای آن دقت کلی دارای بیشترین مقدار می شود به عنوان مقدار بهینه در نظر گرفته می شود [۲۷]. در این مطالعه هنگام برداشت زمینی داده ها ۶۶ درصد به عنوان نمونه آموزشی و ۳۶ درصد به عنوان نمونه آزمایشی برای برآورد دقت طبقه بندی استفاده شده است. در ابتدا الگوریتم با مقادیر اولیه پارامترها توسط داده های آموزشی آموزش داده شده و در ادامه نتایج یادگیری آن روی داده آزمایشی ارزیابی می گردد. معیار ارزیابی بر روی داده آزمایشی توسط شاخص کلی (OA) و ضریب کاپا (K) انجام می گیرد. پس از ارزیابی اگر دقت قابل قبول بود، فرآیند یادگیری متوقف می شود و در غیر این صورت مقادیر پارامترهای طبقه بندی کننده بهینه شده و فرآیند یادگیری دوباره انجام می شود. این فرآیند تا زمانی ادامه می یابد که الگوریتم مورد نظر به دقت مطلوب که توسط کاربر تعیین می شود دست یابد.

۳- منطقه مورد مطالعه و داده ها

این بخش به جزئیات منطقه مورد مطالعه و داده های مورد استفاده به منظور ارزیابی عملکرد الگوریتم های استفاده شده برای طبقه بندی محصولات کشاورزی می پردازد.

۳-۱- داده های سری زمانی ماهواره لندست

در این مطالعه از تصاویر ماهواره Landsat8 و سنجنده OLI شامل ۹ باند طیفی با قدرت تفکیک مکانی ۳۰ متر استفاده شد. قدرت تفکیک رادیومتریکی تصاویر این ماهواره ۱۲ بیتی و دوره تکرار آن ۱۶ روز می باشد. به دلیل تشابه

دریافت و پردازش می کند. انتخاب تعداد نرون ها در این الگوریتم مهم می باشد [۲۲]. فرآیند یادگیری شبکه MLP بر اساس نمونه های داده متشکل از بردار ورودی n بعدی x و بردار خروجی m بعدی d به نام مقصد است. با پردازش بردار ورودی x ، MLP بردار سیگنال خروجی $y_k (k=1,2,...,m)$ را تولید می کند که در آن بردار وزن به روز شده می باشد. سیگنال خطای تولید شده نشان دهنده مکانیسم کنترلی الگوریتم یادگیری است. الگوریتم یادگیری MLP بر اساس کمینه سازی تابع خطا در مجموعه آموزشی (x_i, d_i) برای $i=1,...,n$ و به کارگیری نرم اقلیدسی با استفاده از رابطه ۵ تعریف می شود [۲۲].

$$E(w) = \frac{1}{2} \sum_{i=1}^N \|y(x_i, w) - d_i\|^2 \quad (5)$$

۲-۲-۵- الگوریتم جنگل تصادفی

روش جنگل تصادفی یک روش غیرپارامتری و متعلق به خانواده روش های دسته جمعی^۱ است که در اواخر قرن نوزدهم از روش ماشین های یادگیری به دست آمد [۲۳]. جنگل تصادفی از مجموعه ای از درخت های رگرسیونی که با بازسازی داده های آموزشی به کار گرفته شده است ساخته می شود [۲۴]. درختان تصادفی بردار ورودی را گرفته، آن را با هر درخت در جنگل طبقه بندی کرده و خروجی، برچسب های کلاسی هستند که از اکثریت آرا دریافت شده است. جنگل تصادفی درخت های تصمیم زیادی تولید می کند. برای طبقه بندی یک شی جدید بردار ورودی در انتهای هر یک از درختان جنگل تصادفی قرار می گیرد و هر درخت منجر به یک طبقه بندی می شود که گفته می شود این درخت به آن کلاس رای می دهد [۲۵]. ۳ پارامتر باید توسط کاربر برای راه اندازی الگوریتم RF تعیین شوند. این پارامترها عبارت اند از n که تعداد درختان برای رشد و m تعداد ویژگی هایی که به طور تصادفی برای انشعاب در هر گره در یک درخت در نظر گرفته می شود و حداقل اندازه گره نهایی درختان که بیش تر از آن درخت تقسیم نمی شود. این الگوریتم نسبت به مقدار m حساسیتی ندارد و معمولاً به صورت $\sqrt{m}$ در نظر گرفته می شود [۲۶].

^۱ Ensemble

۳-۲- داده آموزشی

پس از انتخاب تصاویر، نمونه‌های آموزشی از سطح منطقه مورد نظر با استفاده از بازدید میدانی با استفاده از GPS جمع‌آوری شدند. این داده‌ها به صورت Shap file استخراج شدند. با هدف سهولت در پردازش داده‌ها به منظور تبدیل داده‌ها به شکل رستری، ابتدا در تصاویر نمونه‌های جمع‌آوری شده مورد نظر را تشخیص داده و مناطق مورد نظر برای هر نمونه آموزشی بصورت پلیگون استخراج شد و برای هر کلاس یک تصویر صفر و یک ایجاد شد که در جدول ۳ ارائه شده است. برای مقایسه روش‌های مختلف طبقه‌بندی، در همه الگوریتم‌های به کار گرفته شده نمونه‌های آموزشی و آزمایشی یکسان در نظر گرفته شدند.

جدول ۳- تعداد داده های آموزشی منطقه مورد مطالعه

تعداد پیکسل‌های هر محصول	محصولات
۱۳۳۳	باغ
۵۲۵	چغندر
۳۶۵۳	گندم و جو دیم
۷۱۶	گندم و جو آبی
۱۰۴۴	گوجه فرنگی
۳۰	خیار
۶۲	کلزا
۱۲	پیاز
۱۸۲	سیب زمینی
۵۰۲	یونجه
۵۰۲	زعفران
۱۲۹۳	ذرت

۳-۳- منطقه مورد مطالعه

این بخش به جزئیات، منطقه مطالعاتی می‌پردازد. چناران از شهرهای استان خراسان رضوی می‌باشد که در فاصله ۵۰ کیلومتری شمال غربی مشهد و ۴۵ کیلومتری شمال غربی شهر شاندیز واقع شده است. چناران در منطقه مورد نظر دارای طول جغرافیایی ۵۹ درجه و ۷ دقیقه و ۶ ثانیه و عرض جغرافیایی ۳۶ درجه و ۳۸ دقیقه و ۲۴ ثانیه می‌باشد. ارتفاع متوسط منطقه از سطح دریا ۱۱۸۰ متر و میزان بارش سالیانه ۴۸۷ میلیمتر است. آب و هوای آن در فصل بهار اغلب بسیار بارانی و همراه با باد شدید می‌باشد و بیشتر بارندگی این شهرستان در زمستان رخ می‌دهد. چناران با ۴۱ هزار هکتار سطح زیر کشت زراعی بیش از ده

طیفی بین محصولات کشاورزی عمده منطقه نمی‌توان از یک تصویر برای تفکیک و استخراج الگوی کشت منطقه مورد مطالعه استفاده کرد [۲۸]. در تحقیقی که در منطقه شمال ویسکانسین انجام شد، به این نتیجه رسیدند که تشابه طیفی بین گونه‌های خزان کننده صحت تفکیک پذیری را کاهش می‌دهد [۲۹]. در این تحقیق از تصاویر سری‌زمانی و شاخص NDVI برای تفکیک محصولات مختلف از یکدیگر استفاده شد. منظور از تصاویر سری‌زمانی اخذ مجموعه‌ای تصاویر ماهواره‌ای در زمان‌های مختلف از یک منطقه یکسان است. در این مطالعه برای تعیین دامنه زمانی مناسب به منظور تهیه تصاویر، با مراجعه به اطلاعات دریافتی از سازمان جهاد کشاورزی شهرستان چناران، تصاویر مورد نظر بر اساس تقویم زراعی منطقه و مراحل مهم کاشت، داشت و برداشت محصولات انتخاب شد (جدول ۱).

جدول ۱


محصولات	کاشت	برداشت
چغندر	اردیبهشت تا خرداد	آبان تا آذر
سیب زمینی	اسفند تا خرداد	تیر تا آبان
گوجه فرنگی	اسفند تا فروردین	خرداد تا آبان
ذرت	خرداد تا تیر	مرداد تا آبان
گندم دیم و آبی	آبان تا آذر	تیر تا مرداد
جو دیم و آبی	مهر تا آبان	تیر تا مرداد

پس از بررسی‌های لازم در یک بازه یک ساله، ۱۵ تصویر از سایت USGS دانلود شد. از میان تصاویر دانلود شده تعدادی از تصاویر درصد ابر بالایی داشتند و به همین علت کنار گذاشته شدند. در نهایت ده تصویر به گونه‌ای انتخاب شدند که تقریباً برای هر ماه یک تصویر وجود داشته باشد (جدول ۲).

جدول ۲- تصاویر ماهواره‌ای مورد استفاده از سنجنده ETM+

تصاویر	تاریخ
تصویر ۱	۹۴/۰۶/۱۹ شهریور
تصویر ۲	۹۴/۰۷/۲۰ مهر
تصویر ۳	۹۴/۰۹/۰۸ آذر
تصویر ۴	۹۴/۱۱/۱۲ بهمن
تصویر ۵	۹۵/۰۱/۰۱ فروردین
تصویر ۶	۹۵/۰۲/۰۲ اردیبهشت
تصویر ۷	۹۵/۰۳/۰۳ خرداد
تصویر ۸	۹۵/۰۴/۲۰ تیر
تصویر ۹	۹۵/۰۵/۲۱ مرداد
تصویر ۱۰	۹۵/۰۶/۰۶ شهریور

درصد از محصولات کشاورزی استان را تولید می‌کند. عمده‌ترین محصولات این منطقه سیب زمینی، گوجه فرنگی، چغندر قند و ذرت می‌باشد (شکل ۴).



شکل ۴- موقعیت جغرافیایی منطقه مورد مطالعه

۴- پیاده سازی و ارائه نتایج

برای ارزیابی دقت و عملکرد الگوریتم‌های پیشنهادی از تصاویر سری‌زمانی استفاده شده است. پیش از شروع پیاده سازی لازم است یک سری پیش پردازش‌ها بر روی تصاویر سری زمانی و داده‌های آموزشی انجام شود. در قسمت‌های بعدی جزئیات این کار شرح داده خواهد شد.

۴-۱- پیش پردازش داده ها

داده‌های مورد نیاز در این مطالعه به علت وجود شرایط محیطی و دستگاهی نیاز به یک سری پردازش‌ها دارند. تصاویر سری‌زمانی اخذ شده توسط سنجنده ETM+ نیازمند دو سری پردازش می‌باشد. پیش پردازش این تصاویر در دو مرحله انجام می‌گیرد که شامل: تصحیحات طیفی^۱ و تصحیحات مکانی (هندسی)^۲ است. تصحیحات طیفی بر روی مقادیر درجات خاکستری و تصحیحات مکانی برای روی موقعیت پیکسل‌ها به منظور منطبق نمودن آنها با پیکسل زمینی انجام می‌گیرد. تصحیحات طیفی شامل تبدیل مقادیر خام درجات خاکستری به رادیانس بالای اتمسفری و نهایتاً به مقادیر انعکاس واقعی بر روی زمین است [۳۰]. این رویه در مرحله اول یعنی تبدیل مقادیر درجات خاکستری به رادیانس بالای اتمسفر با اعمال ضرایب سنجنده انجام می‌گیرد و در ادامه مقادیر رادیانس توسط مدل تصحیح اتمسفری فلش^۳ به ضرائب انعکاس روی زمین تبدیل می‌گردد. از آنجا که برداشت‌های زمینی با استفاده از جی پی اس دستی انجام

شده است، به منظور تصحیح موقعیت مکانی پیکسل‌ها و زمین مرجع نمودن آنها، ابتدا نقاط کنترل زمینی جمع آوری و سپس تصاویر توسط نقاط کنترل جمع‌آوری شده، زمین مرجع گردید. خطای ریشه میانگین مربعات خطا^۴ زمین مرجع نمودن زیر ۰,۳ پیکسل می‌باشد و باز نمونه- برداری نقاط توسط الگوریتم درونیایی خطی^۵ انجام گرفت.


۴-۲- پیاده‌سازی

در این مطالعه به منظور ارزیابی و تحلیل نتایج و خروجی‌های به دست آمده از تحلیل‌های بصری و کمی استفاده شده است. تحلیل کمی نتایج با استفاده از شاخص دقت کلی و ضریب کاپا انجام شده است. پردازش-های مورد نیاز در این مطالعه با استفاده از رایانه‌ای با مشخصات، پردازنده ۵ هسته‌ای اینتل، حافظه ۴ گیگا بایت، گرافیک ۲ گیگا بایت و ویندوز ۶۴ بیتی انجام شده است. در این مطالعه از چهار الگوریتم طبقه‌بندی متداول به منظور تولید نقشه محصولات کشاورزی منطقه و مقایسه نتایج آن با الگوریتم پیشنهادی استفاده شد، که جزئیات آن‌ها در بخش‌های قبلی ارائه گردید. با توجه به اینکه الگوریتم‌های مورد استفاده در پژوهش حاضر به صورت نظارت شده عمل می‌کنند، در نتیجه نیاز به داده آموزشی به عنوان یکی از مراحل اصلی برای حصول نتایج است. کیفیت و کمیت داده آموزشی از اهمیت بالایی برخوردار است و به صورت قابل توجهی روی نتایج نهایی تاثیر گذار است. اگرچه استاندارد کلی برای تعیین کمیت و کیفیت داده آموزشی تا کنون تعریف نشده، اما در پژوهش حاصل سعی گردید حدود ۶۶ درصد از داده‌های میدانی را به عنوان داده آموزشی و مابقی آن به عنوان داده آزمایشی در نظر گرفته شود. ارزیابی نتایج بر روی داده‌های آزمایشی صورت می‌گیرد، بدین صورت که ابتدا الگوریتم پیشنهادی طبقه‌بندی با استفاده از داده‌های آموزشی، آموزش داده و پارامترهای لازم آنها بهینه و در مرحله بعدی با استفاده از داده آزمایشی مورد ارزیابی قرار می‌گیرد. پس از انجام پیش پردازش‌های لازم برای هر کدام از تصاویر سری‌زمانی که جزئیات آنها در قسمت قبل تشریح گردید، شاخص NDVI برای هر کدام از آنها

۴ Root mean square Error
۵ Bi Linear Interpolation

۱ Radiometric Error
۲ Geometric Error
۳ FLAASH

معماری شبکه CNNs به کار رفته در این مطالعه همان گونه که در شکل ۵ نشان داده شده است، دارای سه لایه کانولوشنی یک لایه Max Pooling و یک لایه Fully Connected می باشد. تابع کرنل به کار رفته دارای ابعاد 3×3 و تابع فعالسازی Relu می باشد. تعداد فیلترهای به کار رفته در لایه کانولوشنی اول ۱۶، در لایه کانولوشنی دوم ۳۲ و در لایه کانولوشنی سوم ۶۴ عدد در نظر گرفته شد. آموزش شبکه به صورت back-propagation انجام شد و برای بهینه سازی الگوریتم مورد استفاده از الگوریتم Adam استفاده شد. در نهایت نرخ یادگیری شبکه 10^{-4} در نظر گرفته شد.




شکل ۵- معماری شبکه عصبی کانولوشن کانولوشنی


های انجام شده مشخص می شود که توانایی الگوریتم پیشنهادی در تشخیص محصولاتی مثل پیاز و خیار و زعفران که داده های آموزشی کمی داشتند، بیشتر بوده است. همچنین این روش توانسته است زمین های دارای محصول بیشتری شناسایی کند. توانایی شناسایی محصول یونجه نیز در این روش بیشتر از سایر روش ها بوده است. با توجه به اینکه نمی توان صرفا به دید بصری اکتفا کرد، برای اثبات کارایی و بازدهی بیشتر روش پیشنهادی، کلیه الگوریتم ها مورد بررسی کمی قرار گرفته اند. برای این منظور از دو شاخص دقت کلی و ضریب کاپا استفاده شده است که نتایج بدست آمده در جدول شماره ۴ قابل مشاهده می باشد. دقت روش پیشنهادی بالاتر از سایر روش ها می باشد. الگوریتم طبقه بندی پیشنهادی CNNs دارای دقت کلی ۹۵٫۷۶ و ضریب کاپا ۸۸٫۲۵ درصد می باشد که نسبت به سایر روش ها در تفکیک و شناسایی محصولات دقیق تر عمل کرده است. بنابراین هم نتایج کمی و هم نتایج کیفی دقت و کارایی بالای روش پیشنهادی را نشان می دهند که این عملکرد بالای روش CNNs به دلیل استفاده همزمان از ویژگی های زمانی و مکانی می باشد.

محاسبه شد. در هر مرحله با در اختیار داشتن موقعیت پیکسل های هرکدام از داده های آموزشی و آزمایشی، از داده سری زمانی ماهواره ای استخراج گردید. شاخص NDVI استخراج شده از تصاویر و نمونه های آموزشی جمع آوری شده به عنوان داده های ورودی الگوریتم های طبقه بندی، در نظر گرفته شد. با توجه به این که نمونه ها آموزشی مربوط به سه کلاس پیاز، زعفران و خیار به نسبت سایر محصولات کمتر بودند، و به منظور ایجاد تعادل میان نمونه های آموزشی در فرآیند آموزش الگوریتم پیشنهادی مبتنی بر شبکه عصبی کانولوشنی، به این کلاس ها وزن بیشتری اختصاص داده شد. ماتریس وزن توسط روش Glorot normal initializer تولید شد.



در پیاده سازی الگوریتم KNN. تعداد همسایگی ها برابر با ۴ در نظر گرفته شد. در پیاده سازی الگوریتم طبقه بندی SVM پارامتر $C=500$ و تابع کرنل RBF با پارامتر $\gamma=0/001$ استفاده شده است. در روش MLP تعداد نرون ها در لایه اول برابر تعداد شاخص ها یعنی ۱۰ عدد و تعداد نرون های لایه پنهان بر اساس سعی و خطا ۲۰ عدد در نظر گرفته شد. در الگوریتم RF تعداد درختان $n=89$ در نظر گرفته شد. نتایج نقشه های طبقه بندی شده در شکل های ۷ و ۸ و ۹ و ۱۰ ارائه شده است. با توجه به نتایج ارائه شده، طبقه بندی محصولات با استفاده از الگوریتم های به کار رفته نسبتا قابل قبول می باشد و با استفاده از این روش ها دوازده نوع محصول شامل باغ، چغندر قند، گندم و جو دیم، گندم و جو آبی، گوجه فرنگی، خیار، کلزا، پیاز، سیب زمینی، یونجه و زعفران با دقت بالایی از یکدیگر تفکیک شدند. اما دقت روش پیشنهادی مبتنی بر شبکه عصبی کانولوشنی در مجموع بالاتر از سایر روش ها می باشد. مهم ترین خصوصیت و قابلیت اصلی روش پیشنهادی نسبت به سایر رقبا خود عملکرد بهتر و موفق تر آن در شناسایی همه محصولات به ویژه کلاس های دارای وسعت کم در منطقه می باشد. بر اساس دید بصری طبقه بندی -




شکل ۶- نقشه طبقه بندی محصولات کشاورزی منطقه چناران با الگوریتم CNN



شکل ۷- نقشه طبقه بندی محصولات کشاورزی منطقه چناران با الگوریتم KNN





شکل ۱۰- نقشه طبقه بندی محصولات کشاورزی منطقه چناران با الگوریتم RF

نشان داد و توانست به طرز موثری بر چالش‌های موجود غلبه کند. وجود نقشه‌های دقیق سطح زیر کشت انواع محصولات کشاورزی در هر منطقه اهمیت زیادی دارد، چرا که این آگاهی می‌تواند در زمینه‌های مختلفی از جمله اصلاح الگوی کشت محصولات کشاورزی، برنامه‌ریزی در زمینه منابع آبی مورد نیاز بخش کشاورزی، برآورد بودجه مورد نیاز به منظور اختصاص ماشین آلات مورد نیاز هر بخش مورد استفاده قرار بگیرد. بنابراین استفاده از این روش با صرف هزینه و زمان بهینه برای تولید نقشه محصولات زراعی توصیه می‌شود. در تحقیقات آتی به منظور دستیابی به نقشه‌های سطح زیر کشت با دقت بالاتر و قدرت تفکیک مکانی بهتر، از تلفیق تصاویر راداری و نوری ماهواره سنتینل ۱ و ۲ و شبکه‌های یادگیری عمیق استفاده خواهد شد.

تقدیر و تشکر

مؤلفین مقاله بر خود لازم می‌دانند تا از سازمان فضایی ایران و سازمان جهاد کشاورزی برای کمک در جمع‌آوری داده‌های میدانی تشکر و قدردانی نمایند.

جدول ۴- دقت روش پیشنهادی و سایر روش‌ها به صورت کمی

روش	دقت کلی	ضریب کاپا (%)
Proposed CNN	۹۵,۷۶	۸۸,۲۵
KNN	۸۹,۶۰	۸۳,۱۲
SVM	۸۸,۷۸	۸۵,۴۵
MLP	۸۵,۷۵	۷۸,۳۳
RF	۸۹,۸۵	۸۴,۵۱

۵- نتیجه گیری

پژوهش حاضر به منظور بررسی عملکرد روش طبقه بندی CNN در تولید نقشه سطح زیر کشت محصولات کشاورزی شهرستان چناران با استفاده از تصاویر سری- زمانی ماهواره Landsat8 انجام شد. چالش‌ها و مشکلات موجود در بحث شناسایی محصولات کشاورزی و استفاده از تصاویر ماهواره‌ای پیش‌تر عنوان گردید. نتایج نشان داد که استفاده از الگوریتم طبقه بندی پیشنهادی مبتنی بر CNN در شناسایی محصولات کشاورزی با توجه به نمونه- های آموزشی یکسان و دو معیار ارزیابی دقت کمی، نسبت به سایر روش‌های مورد استفاده عملکرد بهتری از خود

- [1] N.Abaszade Tehrani, M. Beheshtifar, M. Morabi. (2011). "Estimation of the following product in Qazvin province using multi-time image IRS-LISS3". Environmentally research.Vol.2, No.3, PP.96-87, (in Persian).
- [2] P. Zyaeeian Firozabadi, L .Sayad Bidhendi, M.Eskandari Node.(2009)." Map production and estimate of the area of rice cultivation in Sari county Using images (RADARSAT)". Natural geography research. No.68, (in Persian).
- [3] A. Kross, H. McNairn, D. Lapen, M. Sunohara, and C. Champagne. (2015). "Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops," International Journal of Applied Earth Observation and Geoinformation, vol. 34, pp. 235-248.
- [4] F. Alipour, M. Aghkhani, M. Abasspour-Fard, and A. Sepehr. (2016)."Demarcation and estimation of agricultural lands using etm+ imagery data (case study: Astan ghods razavi great farm)," Journal of Agricultural Machinery, (in Persian).
- [5] B. Zheng, S. W. Myint, P. S. Thenkabail, and R. M. Aggarwal.(2015). "A support vector machine to identify irrigated crop types using time-series Landsat NDVI data," International Journal of Applied Earth Observation and Geoinformation, vol. 34, pp. 103-112.
- [6] S. Dutta, B. Manideep, S. Rai, and V. Vijayarajan.(2017). "A comparative study of deep learning models for medical image classification," in Materials Science and Engineering Conference Series. vol. 263, no. 4, pp. 042097.
- [7] B. Yekkehkhani. (2015)."The presentation and evaluation of a hybrid classification method using time - polarized radar images", (in Persian).
- [8] O. Csillik and M. Belgiu. (2017)."Cropland mapping from Sentinel-2 time series data using object-based image analysis," in Proceedings of the 20th AGILE International Conference on Geographic Information Science Societal Geo-Innovation Celebrating. vol. 20.
- [9] N. Kussul, M. Lavreniuk, S. Skakun, and A. Shelestov. (2017). "Deep learning classification of land cover and crop types using remote sensing data," IEEE Geoscience and Remote Sensing Letters, vol. 14, no. 5, pp. 778-782.
- [10] R. A. Schowengerdt.(2006). Remote sensing: models and methods for image processing. Elsevier.
- [11] I. Pôças, M. Cunha, L. S. Pereira, and R. G. Allen.(2013). "Using remote sensing energy balance and evapotranspiration to characterize montane landscape vegetation with focus on grass and pasture lands," International Journal of Applied Earth Observation and Geoinformation, vol. 21, pp. 159-172.
- [12] J. D. B. Castro, R. Q. Feitoza, L. C. La Rosa, P. M. A. Diaz, and I. D. A. Sanches.(2017). "A Comparative analysis of deep learning techniques for sub-tropical crop types recognition from multitemporal optical/SAR image sequences," in 2017 30th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI). pp. 382-389: IEEE.
- [13] A. Romero, C. Gatta, and G. Camps-Valls.(2015). "Unsupervised deep feature extraction for remote sensing image classification," IEEE Transactions on Geoscience and Remote Sensing, vol. 54, no. 3, pp. 1349-1362.
- [14] S. Dutta, B. Manideep, S. Rai, and V. Vijayarajan.(2017). "A comparative study of deep learning models for medical image classification," in Materials Science and Engineering Conference Series.vol. 263, no. 4, p. 042097.
- [15] R. O. Duda and P. E. Hart.(1973)."Pattern classification and scene analysis". Wiley New York.
- [16] Y. LeCun, Y. Bengio, and G. Hinton .(2015). "Deep learning. Nat. 521, 436–444," ed.
- [17] H. Lyu, H. Lu, and L. Mou. (2016). "Learning a transferable change rule from a recurrent neural network for land cover change detection," Remote Sensing, vol. 8, no. 6, pp. 506.
- [18] H.Saied kaboli, A.Akhond ali, A.Mesbah boani, and F.Radmanesh.(2011)."presenting a down scaling model of climate data based on non parametric method of neighbourhood",Journal of water and soil, vol.26, No.4, pp.779-808, (in Persian).

- [19] M. Moradian and A. Baraani.(2009). "KNNBA: K-NEAREST-NEIGHBOR-BASED-ASSOCIATION ALGORITHM," Journal of Theoretical & Applied Information Technology, vol. 6, no. 1.
- [20] F.Jahanbalhshi, M.Ekhtesasi.(2017)."performance evaluation of three methods image classification: random forest, support vector machine and maximum similarity (in land use map)," Journal of water and soil,vol.22, No.4, (in Persian).
- [21] C.-H. Wu, G.-H. Tzeng, Y.-J. Goo, and W.-C. Fang. (2007). "A real-valued genetic algorithm to optimize the parameters of support vector machine for predicting bankruptcy," Expert systems with applications, vol. 32, no. 2, pp.397-408.
- [22] E. Zanaty.(2012)."Support vector machines (SVMs) versus multilayer perception (MLP) in data classification," Egyptian Informatics Journal, vol. 13, no. 3, pp. 177-183.
- [23] T. G. Dietterich. (2000). "An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization," Machine learning, vol. 40, no. 2, pp. 139-157.
- [24] X. Yu, J. Hyypä, M. Vastaranta, M. Holopainen, and R. Viitala. (2011)."Predicting individual tree attributes from airborne laser point clouds based on the random forests technique," ISPRS Journal of Photogrammetry and remote sensing, vol. 66, no. 1, pp. 28-37.
- [25] A.Talebi, S.Godarzi, H.Pourghasemi.(2016). "examining the possibility of mapping the risk of landslide using a random forest algorithm ," Natural Environment hazards,vol.7, No.16, pp.45-64, (in Persian).
- [26] Z.Ghavami, H.Arefi, B.Bigdeli and M.Janalipour.(2016)." Comprehensive study on non-parametric classification methods in order to separate urban duty using lidar data and aerial imagery with high spatial resolution," engineering and spatial information, vol.5, No.3, pp.77-97,(in Persian).
- [27] C. I. Chang.(2007). Hyperspectral data exploitation: theory and applications. John Wiley & Sons.
- [28] P. Jönsson and L. Eklundh.(2004)."TIMESAT—a program for analyzing time-series of satellite sensor data," Computers & geosciences, vol. 30, No. 8, pp. 833-845.
- [29] L.Kodakarami, A.R.Sofyanian.(2011)."Application of remote sensing to determine the area under cultivation," Science and agricultural techniques and Natural Resources,vol.16, No.59, (in Persian).
- [30] D. Scheffler and P. Karrasch.(2013). "Preprocessing of hyperspectral images: a comparative study of destriping algorithms for EO1-hyperion," in Image and Signal Processing for Remote Sensing XIX, vol. 8892, p. 88920H: International Society for Optics and Photonics