

پایش تغییرات سطح زیر کشت محصولات کشاورزی با استفاده از روش مبتنی بر الگوریتم یادگیری عمیق و تصاویر فراطیفی چند زمانه

مرجان آهنگرها^۱، محمد سعادت سرشت^۲، رضا شاه حسینی^۳، سید تیمور سیدی^۴

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

دانشگاه تهران

ahangarha.marjan@ut.ac.ir

^۲ دانشیار دانشکده مهندسی نقشه برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران

msaadat@ut.ac.ir

^۳ استادیار دانشکده مهندسی نقشه برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران

rshahosseini@ut.ac.ir

^۴ دانشجوی دکتری سنجش از دور - دانشکده مهندسی نقشه برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی -

دانشگاه تهران

seyedi.teymoor@ut.ac.ir

(تاریخ دریافت خرداد ۱۳۹۸، تاریخ تصویب مرداد ۱۳۹۹)

چکیده

آشکارسازی تغییرات باهدف تجزیه و تحلیل دو یا چند تصویر از یک منطقه که در زمان‌های مختلف به دست آمده‌اند، انجام می‌گیرد که به‌طور کلی یکی از مهم‌ترین کاربردهای تصاویر ماهواره‌ای در تحلیل توسعه شهری، پایش محیطی و کشاورزی، ارزیابی خطر و ارزیابی تخریب بلایای طبیعی است. از آنجایی که حل مسائل مربوط به آشکارسازی تغییرات به صورت دستی یک عملیات وقت‌گیر است، به همین دلیل در این پژوهش یک روش کشف تغییرات مبتنی بر الگوریتم یادگیری عمیق جهت تولید نقشه تغییرات در مناطق کشاورزی ارائه شده و از شبکه‌های یادگیری عمیق به منظور استخراج خودکار ویژگی‌ها استفاده شد. هدف در این مقاله بکارگیری الگوریتم‌های یادگیری عمیق از نوع شبکه‌های کانولوشنی به منظور شناسایی سطح زیر کشت محصولات کشاورزی با استفاده از تصاویر فراطیفی است. یکی از انگیزه‌های اصلی این کار، قابلیت مناسب این شبکه‌های یادگیری عمیق در شناسایی تغییرات در مناطق با پیچیدگی طیفی بالا هستند. پس از به دست آوردن تصاویر اختلاف با استفاده از الگوریتم حد‌آستانه گذاری اتسو، نقشه تغییرات دودویی اولیه تولید می‌شود. در مرحله بعد با استفاده از شبکه‌های کدگذار خودکار به استخراج ویژگی پرداخته و از شبکه‌های کانولوشنی جهت طبقه‌بندی پیکسل‌ها به دو کلاس تغییر و کلاس بدون تغییر استفاده شد. نهایتاً با ساخت مدل یادگیری عمیق و ارزیابی دقت، نقشه تغییرات نهایی تولید شد. نتایج حاصل، نشان‌دهنده پتانسیل بالای استفاده از روش‌های یادگیری عمیق در مسائل آشکارسازی تغییرات با استفاده از تصاویر فراطیفی می‌باشد. به منظور ارزیابی دقت و کارایی روش پیشنهادی، از تصاویر اخذ شده توسط سنجنده هایپریون مربوط به دو مجموعه داده ابرطیفی از مزارع کشاورزی هرمیستن واقع در آمریکا، و منطقه دارای پوشش‌های گیاهی متنوع در اطراف تالاب شادگان واقع در جنوب خوزستان، استفاده و الگوریتم پیشنهادی مورد ارزیابی قرار گرفته است. روش پیشنهادی کشف تغییرات مبتنی بر یادگیری عمیق دارای دقت کلی ۹۵٪ و ضریب کاپا ۰.۸۶ می‌باشد.

واژگان کلیدی: یادگیری عمیق، آشکارسازی تغییرات، شبکه‌های عصبی کانولوشنی، شبکه‌های کدگذار خودکار، سنجش از دور، تصاویر فراطیفی

۱- مقدمه

افزایش رشد جمعیت و نیاز به تأمین محصولات کشاورزی، منجر به تغییرات کاربری اراضی از اراضی جنگلی و مرتعی به اراضی کشاورزی شده است [۱]. از آنجایی که برای برنامه‌ریزی‌های دقیق در زمینه میزان واردات و صادرات محصولات کشاورزی و برورسانی نقشه‌های سطح زیر کشت سالیانه، نیاز به پایش و تولید نقشه‌های دقیق تغییرات سطح زیر کشت محصولات کشاورزی با کمترین میزان عملیات میدانی است، نیاز به روش‌های دقیق تولید نقشه‌های تغییرات در این مناطق از اهمیت فراوانی برخوردار است [۲]. در این راستا داده‌های سنجش‌ازدور به دلیل پوشش وسیع به عنوان یک منبع ایده‌آل در زمینه مطالعات آشکارسازی تغییرات تبدیل‌شده‌اند [۳]. در این میان تصاویر سنجش از دوری فراطیفی با قدرت تفکیک طیفی و مکانی مناسب امکان پایش تغییرات در کلاس‌های پیچیده طیفی در این مناطق را امکان‌پذیر می‌سازد. آشکارسازی تغییرات باهدف تجزیه و تحلیل دو یا چند تصویر از یک منطقه که در زمان‌های مختلف به دست آمده‌اند، انجام می‌گیرد که به‌طور کلی یکی از مهم‌ترین کاربردهای تصاویر ماهواره‌ای در پایش‌های محیطی و کشاورزی است [۴]. از جمله چالش‌های اصلی در آشکارسازی تغییرات سطح زیر کشت در مناطق کشاورزی با استفاده از تصاویر فراطیفی، نیاز به داده‌های آموزشی زیاد، وابستگی دقت الگوریتم‌ها به شرایط جوی در زمان اخذ تصاویر، نیاز به تعیین حد آستانه بهینه جهت تعیین کلاس تغییر، انتخاب باندهای بهینه، حجم بالای محاسبات و نیاز به تنظیم پارامترهای الگوریتم‌ها، است [۵ و ۶].

در سال‌های اخیر، استفاده از الگوریتم‌های یادگیری عمیق^۱ به یکی از متداول‌ترین و جدیدترین روش‌های مبتنی بر یادگیری ماشین، تبدیل‌شده است و نشان‌دهنده عملکرد و پتانسیل بالای آن در حوزه تشخیص الگو می‌باشد [۷]. در روش‌های مبتنی بر یادگیری عمیق از مدل‌های محاسباتی که ساختار چند لایه ای دارند، استفاده می‌شود که کاربردهای مختلفی دارند. از کاربردهای الگوریتم‌های یادگیری عمیق در حوزه پزشکی می‌توان به طبقه‌بندی تصاویر پزشکی، تجزیه و تحلیل توالی ژنوم، تشخیص بیماری‌ها [۸ و ۹] و در حوزه بینایی کامپیوتر اعم از ردیابی

افراد و یا عابرین پیاده [۱۰]، دسته‌بندی تصاویر، قطعه‌بندی معنایی [۱۱ و ۱۲]، شناسایی گفتار، پردازش زبان طبیعی [۲] و تشخیص کاراکترهای دست‌نویس [۱۳] و هزاران کاربرد دیگر اشاره کرد.

این ویژگی منحصر به فرد الگوریتم‌های یادگیری عمیق، آن را از سایر روش‌های مبتنی بر یادگیری ماشین متمایز ساخته است. همچنین به دلیل توانایی یادگیری این الگوریتم‌ها، توجهات زیادی را به خود جلب کرده است [۷-۱۴]. با توجه به توانایی بالای الگوریتم‌های یادگیری عمیق در پردازش و استخراج اطلاعات، استفاده از این الگوریتم‌ها در کاربردهای مختلف به یک موضوع بسیار جذاب میان محققان این حوزه تبدیل شده است که به اختصار به برخی از آنها در حوزه سنجش از دور و تشخیص الگو پرداخته می‌شود [۱۰، ۱۵ و ۱۶].

گونگ و همکاران در سال ۲۰۱۵ از شبکه‌های یادگیری عمیق RBM^۲ به منظور آشکارسازی تغییرات در تصاویر چندزمانه راداری با روزه مصنوعی SAR^۳ استفاده کردند. هدف از این تحقیق آشکارسازی تغییرات در قالب دو کلاس تغییر و بدون تغییر با طراحی شبکه یادگیری عمیق از نوع نظارت‌نشده شبکه RBM بوده است و برای طبقه‌بندی از روش تنظیم‌سازی نرم و به صورت نظارت‌شده استفاده کردند [۱۷].

لی و همکاران در سال ۲۰۱۶ یک روش طبقه‌بندی مبتنی بر روی هم گذاری بر مبنای رمزگذار خودکار یادگیری عمیق برای طبقه‌بندی پوشش زمین با استفاده از تصاویر سنجش‌ازدور در مقیاس بزرگ ارائه دادند. سپس روش SAE^۴ را با روش‌های مرسوم طبقه‌بندی مانند: RF, ANN, SVM مقایسه کردند [۱۸]. ارزیابی دقت نتایج نشان‌دهنده دقت کلی ۷۸٫۹۹٪ برای الگوریتم SAE و دقت‌های کلی ۷۷٫۷۴٪، ۷۶٫۰۳٪ و ۷۷٫۸۶٪ به ترتیب برای روش‌های SVM^۵، RF^۶ و ANN^۷ بود. همچنین تعداد نمونه آموزشی برای هر طبقه‌بندی‌کننده ۵۳۴،۳۹۶ و تعداد نمونه‌های تست ۲۶،۲۸۲ در نظر گرفته شد که در روش SAE به بالاترین دقت رسیده‌اند.

^۲ Restricted Boltzmann Machine

^۳ Synthetic Aperture Radar

^۴ Sparse Auto Encoder

^۵ Support Vector Machines

^۶ Random Forest

^۷ Artificial Neural Network

^۱ Deep Learning

۲- مناطق مورد مطالعه و داده فراطیفی

هرمیستن شهری در شهرستان بومیتلا ایالت اورگن است و در سرشماری سال ۲۰۱۱ میلادی، ۱۶,۷۴۵ نفر جمعیت داشته که نسبت به سال ۲۰۱۰، ۰,۷۲ درصد رشد جمعیت داشته است. این منطقه با مختصات $28^{\circ} 45' 50''$ شمالی و $119^{\circ} 17' 30''$ غربی از نوع کشاورزی است. منطقه مورد مطالعه دیگر مربوط به تالاب شادگان در جنوب غربی ایران در استان خوزستان می باشد که پهناوری آن ۴۰۰ هزار هکتار است. مختصات این منطقه $30^{\circ} 45' 17''$ شرقی و $48^{\circ} 30' 28''$ غربی است. این تالاب در پایین دست رودخانه جراحی بین شهرهای شادگان، آبادان، ماهشهر، رامهرمز و اهواز در استان خوزستان واقع شده است. داده‌های فراطیفی مربوط به مناطق مورد مطالعه توسط سنجنده فضا برد هایپریون نصب شده بر روی ماهواره EO-1^۱ اخذ شده است. مشخصات این سنجنده در جدول (۱) ارائه شده است.

جدول ۱- مشخصات سنجنده فراطیفی هایپریون

پوشش طیفی	توان تفکیک رادیومتریکی	توان تفکیک طیفی	پهنای باند	توان تفکیک مکانی	گستره طیفی
به صورت طیفی	۱۶ بیتی	۱۰ نانومتر	۵,۷ کیلومتر	۳۰ متر	۰,۴ تا ۲,۵ میکرو متر

در این تحقیق به منظور آشکارسازی تغییرات کاربری اراضی با استفاده از تصاویر فراطیفی از داده‌های مربوط به مناطق کشاورزی استفاده شده است. این داده‌ها به فاصله زمانی سه سال از مزارع شهر هرمیستن واقع در آمریکا توسط سنجنده هایپریون اخذ شده است. این داده در تاریخ‌های ۷-اردیبهشت-۱۳۸۳ و ۳-اردیبهشت-۱۳۸۶ اخذ شده و ابعاد آن 241×381 پیکسل می‌باشد. به منظور ارزیابی هر چه بهتر روش پیشنهادی مجموعه داده دوم که مربوط به پوشش های گیاهی اطراف تالاب شادگان می باشد، انتخاب گردید. این تصاویر در بازه زمانی ۲۱ روزه در خرداد سال ۱۳۸۵ اخذ گردیده است. ابعاد این تصویر 123×220 پیکسل می باشد. یکی از مزایای این داده این است که تنوع تعداد کلاسی بسیار بالا و از پیچیدگی طیفی زیادی برخوردار است. بنابراین، با ارزیابی روش کشف

ژو و همکاران (۲۰۱۷) از یک روش مبتنی بر شبکه‌های عصبی کانولوشن برای شناسایی سطح زیر کشت بادام زمینی با تصاویر مربوط به ماهواره لندست ۸ در کشور چین استفاده کردند. نتایج تجربی به دست آمده در این تحقیق اعم از دقت کلی ۹۶,۴۲٪ و ضریب کاپا ۰,۹۴۴ نشان دهنده عملکرد خوب این شبکه بوده است. محاسبات آماری نشان می‌دهد که منطقه کاشت بادام زمینی در این منطقه در سال ۲۰۱۷ نسبت به ۲۰۱۵ دارای ۱۲,۱٪ افزایش داشته است [۱۹]. تحقیقات پیشین انجام شده در زمینه کشف تغییرات نشان می‌دهند که یادگیری عمیق به عنوان روشی کارآمد در این زمینه ایفای نقش می‌کند. اما اکثر این پژوهش‌ها با رویکرد نظارت شده به پایش تغییرات پرداخته‌اند. از آنجایی که حل مسائل مربوط به آشکارسازی تغییرات به صورت غیر خودکار یک عملیات زمانبر است، لذا هدف اصلی از این تحقیق استفاده از شبکه‌های یادگیری عمیق به منظور استخراج خودکار ویژگی‌های تغییر است. انجام این فرآیند منجر به تولید نقشه‌های تغییر با دقت بالاتری در مقایسه با روش های خودکار دیگر شده است. اخیراً، شناسایی تغییرات چند گانه با استفاده از تصاویر با توجه به اینکه تصاویر فراطیفی مورد توجه قرار گرفته است. از طرف دیگر، تصاویر فراطیفی محتوای اطلاعات طیفی بسیار بالایی برخوردار هستند. لذا برای دستیابی به نقشه تغییرات چندگانه؛ لازم است یه نقشه دودویی با دقت بالا تولید گردد و نهایتاً، با ماسک کردن نقشه دودویی نقشه تغییرات چندگانه به راحتی تولید میگردد. اما جهت تولید نقشه باینری با قابلیت اطمینان بالا؛ استفاده از پتانسیل بالای الگوریتم های یادگیری عمیق اجتناب ناپذیر است.


در این پژوهش یک روش نوین آشکارسازی تغییرات مبتنی بر مفاهیم یادگیری عمیق ارائه شده است. مشارکت اصلی و نوآوری این پژوهش عبارتند از:

- ۱- ارائه یک چارچوب خودکار آشکارسازی تغییرات بر پایه یادگیری عمیق با بکارگیری داده های فراطیفی چند زمانه
- ۲- ارائه یک روش کاملاً بدون نظارت با قابلیت استخراج اطلاعات آشکارسازی تغییرات با دقت بالا بدون نیاز به هرگونه داده آموزشی
- ۳- ارائه راهکاری مناسب در تولید نقشه کشف تغییرات با استفاده از داده‌های فراطیفی چندزمانه با کلاس‌های پیچیده طیفی با استخراج ویژگی های تغییر مبتنی بر الگوریتم یادگیری عمیق


^۱ Earth Observing-1

تغییرات پیشنهادی بر روی این داده می‌توان یک معیار مناسب برای سنجش عملکرد روش پیشنهادی و سایر


روش های متدوال در نظر گرفت. شکل (۱) نمایش ترکیب رنگی کاذب مناطق مورد مطالعه را ارائه می دهد.




الف) نمایش ترکیب رنگی کاذب داده فراطیفی سال ۱۳۸۳




ب) نمایش ترکیب رنگی کاذب داده فراطیفی سال ۱۳۸۶




ج) واقعیت زمینی مربوط به داده اول



د) موقعیت جغرافیایی داده اول




الف) نمایش ترکیب رنگی کاذب داده فراطیفی ۶ خرداد



ب) نمایش ترکیب رنگی کاذب داده فراطیفی ۲۹ خرداد



ج) واقعیت زمینی مربوط به داده دوم




د) موقعیت جغرافیایی داده دوم

شکل ۱- نمایش ترکیب رنگی کاذب مناطق مورد مطالعه

۲- روش شناسی

این بخش به تشریح فلوچارت روش پیشنهادی در این مقاله پرداخته شده است (شکل ۲).



شکل ۲- فلوچارت روش پیشنهادی کشف تغییرات مبتنی بر الگوریتم یادگیری عمیق


۲-۱ - پیش پردازش داده فراطیفی

تصاویر این سنجنده به دلیل وجود شرایط محیطی و دستگاهی نیاز به یک سری پیش پردازش دارند. این پیش پردازش ها به دودسته کلی تقسیم می شوند: دسته اول پیش پردازش های طیفی هستند که خود به زیر بخش هایی تقسیم می گردند که عبارت اند از: حذف جابجایی یک پیکسل، حذف باندهای بدون داده، حذف اثرات نوار شدگی و نوفه، تصحیح اثر انحنای طیفی، تبدیل رادیومتریکی، تصحیح جوی و یکنواخت سازی داده در بازه صفر و یک است [۵]. یکنواخت سازی از تأثیر باندهای با محدوده عددی بالاتر بر باندهای با محدوده کوچک تر می کاهد. همچنین باعث کمینه شدن اثرات نوفه می شود. پیش پردازش های مکانی به موقعیت پیکسل ها ارتباط دارد که از تصحیح هندسی استفاده می شود و یک تصویر به عنوان مرجع ثابت در نظر گرفته می شود و تصویر دوم نسبت به آن ثبت هندسی می شود.

۲-۲ - انتخاب داده آموزشی

هدف از اجرای این بخش انتخاب داده آموزشی جهت تعیین پارامترهای CNN^۱ است. وجود برخی عوامل از جمله: مقادیر نوفه، شرایط جوی و عدم شفافیت قله های نواحی تغییر و بدون تغییر در هیستوگرام و آمیخته شدن این قله ها، باعث می شود که نمونه های انتخابی بعد از آستانه گذاری از قطعیت کمتری برخوردار باشند. بنابراین استفاده از تمامی نمونه های آموزشی بدون پالایش کردن آنها منجر به یادگیری اشتباه توسط طبقه بندی کننده می گردد. بنابراین جهت آموزش صحیح الگوریتم؛ نیاز به پالایش نمونه های آموزشی داریم. در این راستا؛ جهت افزایش قطعیت و اعتمادپذیری داده آموزشی، انتخاب داده آموزشی بر اساس چهار مرحله می باشد: (۱) تهیه نقشه اولیه در دو کلاس تغییر و بدون تغییر توسط الگوریتم اتسو و قدر مطلق تصویر تفاضل، (۲) استخراج پیکسل های تغییر و بدون تغییر از خروجی الگوریتم در دو کلاس مجزا، (۳) به کارگیری مجدد الگوریتم طبقه بندی بر روی پیکسل های هر کدام از کلاس های مرحله قبل (تغییر و بدون تغییر)، (۴) از هر کدام از کلاس ها دو دسته داده آموزشی و داده آزمایشی استخراج

شده تا در مراحل بعدی الگوریتم های یادگیری عمیق را مورد آموزش و ارزیابی دقت قرار دهیم. همچنین هر کدام از ۲ کلاس اصلی به سه ناحیه تقسیم می شوند. علت انتخاب کلاس میانی، افزایش اعتمادپذیری در انتخاب داده آموزشی است. افزایش اعتمادپذیری از دو عامل سرچشمه می گیرد: (الف) کلاس نوفه که معمولاً در ابتدا و انتهای هیستوگرام ایجاد می گردد و بنابراین انتخاب کلاس میانی باعث عدم تأثیرپذیری این کلاس از نوفه می شود و (ب) به علت آمیخته شدن قله های هیستوگرام کلاس تغییر و بدون تغییر، انتخاب حد آستانه با دقت پایینی انجام می گردد. بنابراین انتخاب کلاس میانی، به علت روند انتخاب حد آستانه باعث، مرتفع نمودن اثرات این عوامل می شود. پس از انجام مراحل فوق، نمونه های آموزشی با درصد اطمینان بالاتری به منظور یافتن پارامترهای بهینه هسته وارد فرآیند می شود. شکل (۳) نحوه انتخاب داده آموزشی را ارائه می دهد.



شکل ۳- نحوه انتخاب داده آموزشی

۲-۳ - استخراج ویژگی مبتنی بر شبکه SAE


در این بخش به استخراج ویژگی با استفاده از شبکه SAE پرداخته می شود. ورودی این بخش، پیکسل های به دست آمده حاصل از الگوریتم تفاضل گیری بین تصاویر قبل و بعد از تغییر است. پس از استخراج ویژگی بر روی کل پیکسل ها و از طرفی با به دست آمدن موقعیت داده های شبه آموزشی، این پیکسل ها وارد شبکه CNN جهت بهینه سازی پارامترها می شوند. علاوه بر آن، لازم است که پارامترهای اولیه شامل: تعداد تکرار و اندازه قطعه، معماری شبکه و سایر پارامترها تعیین گردند.

۲-۴ - بهینه سازی پارامترهای شبکه CNN

در این قسمت با استفاده از داده های آزمایشی که در قسمت قبل توضیح داده شدند، به بهینه سازی پارامترها می پردازیم. آموزش شبکه با استفاده از داده های آموزشی، و ارزیابی آن به کمک داده آزمایشی با استفاده از شاخص

^۱ Convolution Neural Network

یک لایه طبقه‌بندی‌کننده نهایی می‌باشند، تشکیل شده است. شکل (۴) نمایی کلی از این شبکه را ارائه می‌دهد که در ادامه هر قسمتی از این معماری به‌طور جداگانه توضیح داده خواهد شد.



شکل ۴- معماری کلی شبکه‌های کانولوشنی عمیق [20]

۳-۱-۱- لایه کانولوشن

ورودی لایه کانولوشن یک آرایه سه‌بعدی با r لایه ویژگی دویبعی با سائز $m \times n$ هست. هر المان نمایش‌دهنده $x_{m,n}^i$ است و هر لایه ویژگی نمایانگر مثالی از x^i است. خروجی این آرایه سه‌بعدی $m_1 \times n_1 \times k_1$ ترکیبی از k لایه ویژگی با اندازه $m \times n$ است. لایه کانولوشن دارای k فیلتر قابل‌آموزش در سائز $l \times q$ بوده که بانک فیلتر w نیز نامیده می‌شود که لایه ویژگی ورودی را به لایه ویژگی خروجی متصل می‌کند. لایه کانولوشن خروجی لایه ویژگی از رابطه ۱ به دست می‌آید [۷]:

$$z^s = \sum_{t=1}^q w_t^s * x^i + b_{s1} \quad (1)$$

در این رابطه $*$ یک عملگر دویبعی گسسته کانولوشن و b پارامتر قابل‌آموزش بایاس می‌باشد.

۳-۱-۲- لایه غیرخطی

در CNN قدیمی، این لایه صرفاً شامل یک تابع غیرخطی استوار است که به هر جزء در یک لایه ویژگی اضافه شده است. لایه غیرخطی خروجی نقشه ویژگی با استفاده از رابطه ۲ محاسبه می‌شود:

$$a^s = f(z^s) \quad (2)$$

تابع f معمولاً به‌صورت تابع Relu انتخاب می‌شود که این تابع به صورت $f(x)$ با ماکزیمم مقدار $(0, x)$ می‌باشد، تعریف می‌شود [۷].

۳-۱-۳- لایه کاهش ابعاد

از آنجایی که ابعاد ویژگی‌ها همیشه بالاست به جهت جلوگیری از Over Fitting از لایه Pooling به‌منظور کاهش

صحت کلی^۱ و کاپا انجام می‌گیرد. فرآیند تکرار تا زمانی انجام می‌گیرد که نتایج قابل قبولی ارائه شود که در این-صورت به مرحله بعدی می‌رویم و در غیر این‌صورت به قسمت بهنگام‌سازی پارامترها رفته و پیکسل‌ها دوباره طبقه‌بندی می‌شوند تا حدی که به جوابی قابل قبول برسند.

۲-۵- تولید نقشه تغییرات نهایی

در این قسمت با خروجی‌هایی که از قسمت قبل به‌دست آمده‌اند و انجام مرحله استخراج ویژگی با انتخاب پارامترهای بهینه CNN به ساخت مدل می‌رسیم. در مرحله آخر بعد از اعمال این شبکه به تصاویر تفاضلی، نقشه تغییرات نهایی به دست می‌آید.

۳- یادگیری عمیق

یادگیری عمیق یکی از شاخه‌های مهم یادگیری ماشین است که سعی می‌کند مفاهیم انتزاعی را به‌وسیله شبیه‌سازی مکانیزم شناختی از مغز انسان و کشف الگوی پنهان با ساختار عمیق ایجاد کند. وقتی داده به یک شبکه عمیق تغذیه می‌شود، ویژگی‌ها می‌توانند لایه به لایه آموزش داده شوند و خروجی یک لایه به‌عنوان ورودی لایه بعدی استفاده می‌شود. هراندازه که شبکه عمیق‌تر باشد، ویژگی‌های انتزاعی بیشتری را می‌توان از طریق شبکه عمیق آموخت. یادگیری عمیق دارای شبکه‌های بسیاری اعم از CNN, DBN, SAE و غیره هست که در ادامه به توضیح مختصری از این شبکه‌ها که در این پژوهش استفاده شده‌اند، می‌پردازیم [۴].

۳-۱- شبکه‌های عصبی کانولوشن

CNN دارای یک معماری با چندین لایه قابل‌آموزش است که از مراحل مختلف استخراج ویژگی تشکیل شده است. این شبکه‌ها شامل سه لایه اصلی اعم از لایه کانولوشن، لایه غیرخطی و لایه کاهش ابعاد می‌باشند. معماری CNN به‌گونه‌ای طراحی شده است تا از ساختار دویبعی تصویر ورودی استفاده کند. یک CNN معمولی از یک، دو یا سه مرحله استخراج ویژگی که به دنبال آن یک شبکه چندلایه، لایه‌های تماماً متصل و

^۱ Overall Accuracy

در Encoder از ورودی یا x ویژگی‌ها را تولید کرده که در رابطه ۴ مشخص است [۳]:


$$h = \text{sigm}(\omega_1 a + ab) \quad (4)$$

در قسمت Decoder از ویژگی‌ها، x را بازسازی می‌شود (شکل (۵)). بعد از این که شبکه آموزش داده شد به این معنی که ویژگی‌های خوبی تولید شده، در هر مرحله قسمت Decoder را کنار می‌گذاریم و با ویژگی‌ها دوباره آموزش را شروع می‌کنیم. به این صورت که با استفاده از داده‌های ورودی و ویژگی‌ها، مرحله آموزش را با استفاده از برچسب‌ها برای طبقه‌بندی استفاده گردد. همچنین در مرحله کدگذاری پراکنده^۲، پارامتر اضافی Sparsity که برای حل مسئله انحطاط با Over Completeness معرفی شده است، اضافه می‌کنیم.

تابع هزینه‌ی این شبکه‌ها با مجموعه‌ای از m بردار ورودی با رابطه (۵) نشان داده می‌شود:

$$\min_{a, \phi} \sum_{j=1}^m \|x^j\|^2 - \sum_{i=1}^k a_i^j \phi_i^j + \lambda \sum_{i=1}^k s(a_i^j) \quad (5)$$

در این رابطه $s(\cdot)$ یک تابع هزینه Sparsity بوده که از پارامتر a_i به عنوان پارامتر پناالتی استفاده می‌کند تا مقدار آن از صفر فاصله بگیرد. اولین المان Sparse Coding به عنوان یک عبارت بازسازی شده، در تلاش است تا الگوریتم را مجبور کند تا یک نمایش مناسب از ورودی یا همان x داشته باشد، تعریف می‌شود. عبارت دوم نیز به عنوان پراکندگی اضافی تعریف شده تا ورودی را به صورت پراکنده نشان دهد [۲۱].



شکل ۵- ساختار شبکه‌های کدگذار خودکار [۳]

ابعاد استفاده می‌گردد که بعد از لایه‌های کانولوشن قرار می‌گیرند و دارای روش‌های مختلفی نیز هستند. معروف‌ترین آن‌ها Max Pooling است که لایه‌های تماماً متصل کلاس‌های مربوط به تصویر ورودی را نمایش می‌دهند. با توجه به گام و اندازه پنجره‌ای که در نظر می‌گیریم، ماکزیمم مقدار هر ناحیه از تصویر که یک عدد مربوط به هر ناحیه است را به عنوان خروجی در نظر گرفته و ابعاد تصویر ما کوچک می‌گردد. پس از انجام مرحله چندگانه استخراج ویژگی، کل شبکه با یک تابع هزینه نظارت شده مثل خروجی کمترین مربعات کلاسیک و به صورت پس انتشار آموزش داده می‌شود و خروجی هدف ما (γ) به صورت یک بردار ستونی با بعد k نشان داده می‌شود که در آن k تعداد خروجی و L تعداد لایه‌ها است [۷ و ۲۱]:

$$j(\theta) = \sum_{i=1}^N \left(\frac{1}{2} \|h(x_i, \theta) - \gamma\|^2 \right) + \lambda \sum_{l=1}^L \text{sum}(\|\theta^l\|^2) \quad (3)$$

که در آن، L تعداد لایه‌ها، λ آیتم مرتب‌سازی و $\| \cdot \|^2$ نرم دوم را نشان می‌دهد. هدف کمینه‌سازی تابع $j(\theta)$ نسبت به پارامتر θ است. به منظور آموزش CNN، از روش بهینه‌سازی گرادیان نزولی اتفاقی^۱ استفاده می‌شود. اخیراً CNN به عنوان یک روش متداول یادگیری عمیق مورد استفاده قرار گرفته است و کارایی مناسبی در تشخیص بصری در مقیاس بزرگ دارد.

۳-۲- شبکه‌های کدگذار خودکار

این شبکه‌ها اولین مدل‌هایی بودند که در حوزه یادگیری عمیق از یادگیری بدون نظارت استفاده کردند. ساده‌ترین حالت یک شبکه کدگذار خودکار از سه لایه تشکیل شده است. لایه ورودی $a = \{a_1 a_2, \dots, a_n\}$ به صورت بردار است. لایه میانی یا پنهان $h = \{h_1 h_2, \dots, h_n\}$ ویژگی‌ها را ارائه می‌دهند و لایه خروجی $c = \{c_1 c_2, \dots, c_n\}$ بازسازی لایه ورودی هست. به این معنی که در یک مرحله ورودی به فضای ویژگی انتقال داده می‌شود. به عبارتی دیگر، چند ویژگی Encode شده و در مرحله بعد باید از این ویژگی‌ها دوباره بتوانیم داده‌هایمان را بازسازی کنیم و اصطلاحاً این ویژگی‌ها به داده‌های اولیه Decode شود [۴].

^۲ Sparse Coding

^۱ Stochastic Gradient Descend

۵- پیاده‌سازی

به‌منظور ارزیابی دقت و مقایسه کارایی و دقت الگوریتم پیشنهادی با سایر روش‌های متداول آشکارسازی تغییرات از تصاویر فرایطیفی در مناطق کشاورزی استفاده شده است. برای نیل به این هدف، لازم است یکسری از پیش‌پردازش‌ها بر روی تصاویر فرایطیفی صورت گیرد. در قسمت‌های بعدی در مورد جزئیات این پیش‌پردازش‌ها، نتایج به‌کارگیری الگوریتم پیشنهادی و مقایسه آن‌ها با سایر روش‌ها بیشتر توضیح داده خواهد شد.

۶- ارزیابی نتایج

پس از انجام پیش‌پردازش‌هایی که در قسمت پیاده‌سازی به آن‌ها اشاره شد، الگوریتم پیشنهادی بر روی داده موردنظر پیاده‌سازی شد. پس از به‌کارگیری الگوریتم حدآستانه‌گذاری Otsu، اولین مرحله انتخاب داده آموزشی و آزمایشی توسط الگوریتم پیشنهادی انجام شد. به‌منظور کاهش روند محاسباتی از ۶۰۰۰ پیکسل انتخاب‌شده به‌طور تصادفی، ۴۰۰۰ پیکسل به‌عنوان داده آموزشی و ۲۰۰۰ پیکسل به‌عنوان داده آزمایشی برای داده اول انتخاب شد. همچنین برای داده دوم از مجموع ۴۰۰۰ پیکسل، تعداد ۲۵۰۰ پیکسل به داده آموزشی و ۱۵۰۰ پیکسل هم به عنوان داده آزمایشی بکار گرفته شد. معماری کلی شبکه CNN که در این پژوهش برای هر دو داده عبارت است از: ۴ لایه که ۲ لایه آن کانوولوشنی و ۲ لایه کاهش ابعاد، که لایه کانوولوشن اول در ابعاد 3×3 ، لایه کاهش ابعاد با سایز 2×2 ، لایه کانوولوشن دومی در ابعاد 6×6 ، لایه کاهش ابعاد در مقیاس 2×2 می‌باشند. پارامترهای الگوریتم CNN با استفاده از داده آزمایشی و الگوریتم جست‌وجوی شبکه‌ای بهینه می‌شود. مقادیر بهینه پارامترهای الگوریتم CNN در جدول (۲) ارائه شده است.

جدول ۲- پارامترهای بهینه CNN

داده	تعداد اپک‌ها	اندازه قطعه	مقدار آلفا
اول	۴۷	۵	۰٫۹۵
دوم	۳۳	۵	۰٫۹۱

به‌منظور بررسی عملکرد روش پیشنهادی از آنالیز کمی و کیفی بهره گرفته شد. شکل (۶) نشان‌دهنده نتایج حاصل از آشکارسازی تغییرات بر روی داده فرایطیفی با استفاده از روش پیشنهادی و سایر روش‌های متداول آشکارسازی تغییرات است. شکل (۶-الف) نتایج حاصل از روش یادگیری


عمیق را ارائه می‌دهد، شکل (۶-ب) و (۶-ج) به ترتیب نشان‌دهنده نتایج حاصل از روش شناسایی تغییرات مبتنی بر زیر فضا و روش شناسایی تغییرات چند متغیره با وزندهی تکراری می‌باشند که در آن‌ها نواحی رودخانه به‌صورت اشتباه به عنوان ناحیه تغییر توسط الگوریتم شناسایی شده است. روش پیشنهادی مبتنی بر الگوریتم یادگیری عمیق اکثر مناطق تغییر یافته را به عنوان کلاس تغییرات و به درستی شناسایی کرده است. این موضوع نشان‌دهنده عملکرد بسیار خوب روش پیشنهادی مبتنی بر یادگیری عمیق است که علاوه بر شناسایی صحیح تغییرات، دارای اشتباهات کمتری نیز می‌باشد.




ب) شناسایی تغییرات مبتنی بر زیر فضا



الف) روش پیشنهادی یادگیری عمیق



د) تحلیل بردار تغییرات فشرده



ج) تکنیک شناسایی تغییرات چند متغیره با وزندهی تکراری



ه) واقعیت زمینی

شکل ۶- نتایج حاصل از آشکارسازی تغییرات بر روی داده اول


است. به منظور اثبات کارایی روش پیشنهادی، در جدول (۳) نتایج تحلیل کمی از به کارگیری هر کدام از این روش‌ها نشان داده شده است. از دو معیار برای تحلیل دقت استفاده شده است. با توجه به نتایج بدست آمده، نتایج حاصل از روش پیشنهادی نسبت به سایر روش‌ها دارای دقت بالاتری است. روش شناسایی تغییرات چند متغیره با وزندهی تکراری دارای دقت کلی ۸۳٪ که نسبت به روش شناسایی تغییرات مبتنی بر زیر فضا که ۷۷٪ دقت کلی دارد، روش بهتری است. همچنین روش تحلیل بردار تغییرات فشرده با ۸۴٪ دقت کلی نسبت به دو روش قبلی عملکرد بهتری دارد. درحالی که استفاده از الگوریتم‌های یادگیری عمیق پیشنهادی دقت نقشه تغییرات را به دقت کلی ۹۵٪ و شاخص کاپا ۰.۸۹ رسانده است. هردوی تحلیل بصری و کمی نشان‌دهنده عملکرد بسیار خوب روش پیشنهادی در مقایسه با سایر روش‌ها را نشان می‌دهد. همچنین آنالیزهای کمی برای داده دوم، روند مشابهی نسبت به داده اول دارد. به این صورت که روش شناسایی تغییرات مبتنی بر زیرفضا حساسیت کمتری به منطقه تغییر دارد، به همین دلیل، همان طور که مشخص است، تغییرات به خوبی استخراج نشده است. روش تکنیک شناسایی تغییرات چند متغیره با وزندهی تکراری از آنجایی که تعدادی از مناطق در این داده تحت نفوذ آب بوده است، این روش به اشتباه آنها را مناطق تغییر تشخیص داده است که در حقیقت چنین نیست.

با توجه به نتایج ارائه شده در جدول (۳)، روش پیشنهادی کشف تغییرات در مقایسه با سایر روش‌های مورد مقایسه، دقت قابل قبولی را ارائه نموده است. همچنین دقت بالای نتایج کمی و کیفی روش پیشنهادی برای هر دو مجموعه داده نشان دهنده کارا بودن روش پیشنهادی برای داده‌های فراطیفی مربوط به مناطق با کلاس‌های طیفی مختلف است.


جدول ۳- تحلیل کمی روش پیشنهادی و دیگر روش‌های متداول

شاخص کاپا	دقت کلی (%)	داده	روش آشکارسازی تغییرات
۰.۴۱۹	۸۴.۵۷۵	اول	تحلیل بردار تغییرات فشرده
۰.۵۳۹	۸۸.۲۶	دوم	
۰.۳۰۴	۸۳.۸۵۳	اول	شناسایی تغییرات چند متغیره با وزندهی تکراری
۰.۴۹۸	۸۶.۰۶	دوم	
۰.۴۰۰	۷۷.۸۵۵	اول	شناسایی تغییرات مبتنی بر زیرفضا
۰.۱۴۴	۶۳.۸۶	دوم	
۰.۸۶۲	۹۵.۹۰	اول	روش پیشنهادی
۰.۸۲۰	۹۴.۲۸	دوم	


همچنین نتایج بکارگیری روش پیشنهادی بر روی داده دوم در شکل (۷) نمایش داده میشود.



الف) روش پیشنهادی یادگیری عمیق
ب) شناسایی تغییرات مبتنی بر زیر فضا



ج) تکنیک شناسایی تغییرات چند متغیره با وزندهی تکراری
د) تحلیل بردار تغییرات فشرده



ه) واقعیت زمینی

شکل ۷- نتایج حاصل از آشکارسازی تغییرات بر روی داده دوم

به منظور ارزیابی مقایسه‌ای روش پیشنهادی، از روش‌های آشکارسازی تغییرات ارائه شده در مقالات شامل شناسایی تغییرات چند متغیره با وزندهی تکراری (IR-^۱ MAD [۲۳]، تحلیل بردار تغییرات (CVA)^۲ [۲۴]، شناسایی تغییرات مبتنی بر زیرفضا^۳ [۲۵] استفاده شده

^۱ Iteratively Re-weighted Multivariate Alteration Detection

^۲ Change Vector Analysis

^۳ Sub-space Based Change Detection

نتایج حاصل از ارزیابی‌ها نشان می‌دهد که استفاده از داده‌های فراطیفی به‌عنوان یک منبع اطلاعاتی می‌تواند نقش مهمی را در شناسایی تغییرات کشاورزی ایفا نماید. با توجه به پیچیدگی مناطق کشاورزی و تنوع کلاس‌ها، نیاز به یک روش کارآمد که به تغییرات حساس باشد، دیده می‌شود. نتایج بصری حاکی از آن است که بعضی از روش‌ها توانایی شناسایی تغییرات کوچک را نداشته و یا به مناطق آبی حساس هستند. شناسایی و پایش مناطق کشاورزی همیشه موردتوجه مدیران بوده است که در این راستا ارزیابی و به دست آوردن اطلاعات دقیق و بهنگام امری ضروری به نظر می‌رسد. بنابراین جهت به دست آوردن این اطلاعات به ابزارهای مناسب و روش‌های کارآمد نیاز می‌باشد.

۷- نتیجه‌گیری

در این پژوهش یک روش نوین آشکارسازی تغییرات با استفاده از الگوریتم‌های یادگیری عمیق بر روی تصاویر سنجش‌ازدوری فراطیفی ارائه شده است. این روش قادر است مشکلات چالش‌های موجود در روش‌های

آشکارسازی تغییرات را به حداقل برساند. به‌منظور ارزیابی عملکرد روش پیشنهادی از دو مجموعه داده فراطیفی دو زمانه استفاده گردیده و نتایج آن را با روش‌های متداول آشکارسازی تغییرات فراطیفی مقایسه نموده‌ایم. برپایه ارزیابی انجام شده می‌توان دریافت که (۱) تصاویر فراطیفی پتانسیل خوبی به‌منظور پایش تغییرات کاربری در مناطق کشاورزی را دارا است، (۲) روش پیشنهادی قادر است تغییرات با دقت بالایی نسبت به سایر روش‌ها به دست آورد، به‌طوری‌که دقت کلی آن بالای ۹۵٪ می‌باشد، (۳) روش پیشنهادی کاملاً بدون نظارت بوده و نیاز به انتخاب هیچ‌گونه حد آستانه و یا داده آموزشی ندارد. این در حالی است که بسیاری از روش‌های آشکارسازی تغییرات نیاز به این دو مشخصه دارد. به عنوان توسعه الگوریتم پیشنهادی می‌توان به امکان سنجی استفاده تلفیقی از داده‌های سری زمانی راداری و نوری ماهواره‌های چندطیفی سنتینل و همچنین استفاده از سایر شبکه‌های یادگیری عمیق به منظور پایش دقیق تغییرات سطح زیر کشت محصولات کشاورزی پرداخته شود.

مراجع

- [1] A. Rashki, D. G. Kaskaoutis, A. S. Goudie, and R. A. Kahn, 'Dryness of ephemeral lakes and consequences for dust activity: the case of the Hamoun drainage basin, southeastern Iran', *Science of the Total Environment*, vol. 463, pp. 552–564, 2013.
- [2] R. Collobert and J. Weston, 'A unified architecture for natural language processing: Deep neural networks with multitask learning', in *Proceedings of the 25th international conference on Machine learning*, 2008, pp. 160–167.
- [3] M. Moradi and M. R. Sahebi, 'Feature-Based Change Detection of Urban Areas using Particle Swarm Optimization and Genetic Algorithm', *JGST*, vol. 7, no. 1, pp. 203–222, 2017.
- [4] M. Gong, H. Yang, and P. Zhang, 'Feature learning and change feature classification based on deep learning for ternary change detection in SAR images', *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 129, pp. 212–225, 2017.
- [5] S. T. Seydi and M. Hasanlou, 'A new land-cover match-based change detection for hyperspectral imagery', *European Journal of Remote Sensing*, vol. 50, no. 1, pp. 517–533, 2017.
- [6] M. Hasanlou, S. T. Seydi, and R. Shah-Hosseini, 'A Sub-Pixel Multiple Change Detection Approach for Hyperspectral Imagery', *Canadian Journal of Remote Sensing*, vol. 44, no. 6, pp. 601–615, 2018.
- [7] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. MIT press, 2016.
- [8] P. Mamoshina, A. Vieira, E. Putin, and A. Zhavoronkov, 'Applications of deep learning in biomedicine', *Molecular pharmaceutics*, vol. 13, no. 5, pp. 1445–1454, 2016.
- [9] T. Ching et al., 'Opportunities and obstacles for deep learning in biology and medicine', *Journal of The Royal Society Interface*, vol. 15, no. 141, p. 20170387, 2018.
- [10] S. Ji, W. Xu, M. Yang, and K. Yu, '3D convolutional neural networks for human action recognition', *IEEE transactions on pattern analysis and machine intelligence*, vol. 35, no. 1, pp. 221–231, 2013.
- [11] X. Cheng, S. Kura, and D. Boas, 'Vessel segmentation with deep learning (Conference Presentation)', in *Three-Dimensional and Multidimensional Microscopy: Image Acquisition and Processing XXVI*, 2019, vol. 10883, p. 108830W.

- [12] J. C. Caicedo et al., 'Evaluation of Deep Learning Strategies for Nucleus Segmentation in Fluorescence Images', BioRxiv, p. 335216, 2019.
- [13] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, 'Gradient-based learning applied to document recognition', Proceedings of the IEEE, vol. 86, no. 11, pp. 2278–2324, 1998.
- [14] Y. Chu, G. Cao, and H. Hayat, 'Change detection of remote sensing image based on deep neural networks', in 2016 2nd International Conference on Artificial Intelligence and Industrial Engineering (AIIE 2016), 2016.
- [15] S. Khan, N. Islam, Z. Jan, I. U. Din, and J. J. C. Rodrigues, 'A Novel Deep Learning based Framework for the Detection and Classification of Breast Cancer Using Transfer Learning', Pattern Recognition Letters, 2019.
- [16] X. X. Zhu et al., 'Deep learning in remote sensing: A comprehensive review and list of resources', IEEE Geoscience and Remote Sensing Magazine, vol. 5, no. 4, pp. 8–36, 2017.
- [17] M. Gong, J. Zhao, J. Liu, Q. Miao, and L. Jiao, 'Change detection in synthetic aperture radar images based on deep neural networks', IEEE transactions on neural networks and learning systems, vol. 27, no. 1, pp. 125–138, 2016.
- [18] W. Li et al., 'Stacked autoencoder-based deep learning for remote-sensing image classification: a case study of African land-cover mapping', International Journal of Remote Sensing, vol. 37, no. 23, pp. 5632–5646, 2016.
- [19] Z. Zhou and S. Li, 'Peanut planting area change monitoring from remote sensing images based on deep learning', in 2017 4th International Conference on Systems and Informatics (ICSAI), 2017, pp. 1358–1362.
- [20] <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>
- [21] L. Zhang, L. Zhang, and B. Du, 'Deep learning for remote sensing data: A technical tutorial on the state of the art', IEEE Geoscience and Remote Sensing Magazine, vol. 4, no. 2, pp. 22–40, 2016.
- [22] P. Marpu, P. Gamba, and J. A. Benediktsson, 'Hyperspectral change detection using IR-MAD and feature reduction', in Geoscience and Remote Sensing Symposium (IGARSS), 2011 IEEE International, 2011, pp. 98–101.
- [23] L. Bruzzone and F. Bovolo, 'A novel framework for the design of change-detection systems for very-high-resolution remote sensing images', Proceedings of the IEEE, vol. 101, no. 3, pp. 609–630, 2013.
- [24] C. Wu, B. Du, and L. Zhang, 'A subspace-based change detection method for hyperspectral images', IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 6, no. 2, pp. 815–830, 2013.